

Tobias Schmohl, Alice Watanabe, Kathrin Schelling (Hg.)
Künstliche Intelligenz in der Hochschulbildung

Editorial

Hochschulbildung geschieht in einem breiten Spektrum wissenschaftlicher und künstlerischer Institutionen. Sie ist eine treibende Kraft sich wandelnder Lebensverhältnisse (etwa durch Digitalität, Medialität, Vernetzung) und gesellschaftlicher Beziehungen (etwa durch Internationalisierung und Globalisierung). Ihr Spezifikum besteht in der Verschränkung mit Wissenschaft: Lerngegenstände und Vermittlungsformen orientieren sich an Forschung und Stand der wissenschaftlichen Diskurse. Als Teil des Bildungssystems trägt sie maßgeblich zur wissenschaftlichen Ausformung der individuellen und kollektiven Bezüge zur Welt sowie der Befähigung zu ihrer Gestaltung bei und ist Scharnier zwischen beruflichen wie auch gesellschaftlichen Handlungsfeldern und Wissenschaft.

Im Kontext sozialen und kulturellen, ökologischen, wirtschaftlichen und politischen Wandels steht Hochschulbildung heute selbst vor weitreichenden Transformationsanforderungen: Neben fachlicher Expertise werden zunehmend auch Fähigkeiten zur inter- und transdisziplinären Zusammenarbeit notwendig. Lehre und Studium sollen auf professionelles Handeln in der Praxis vorbereiten, Beschäftigungsfähigkeit und Teilhabe am öffentlichen Leben fördern: *proficiency, employability, citizenship*.

Die Reihe bietet ein Forum für die Transformation der Hochschulbildung und den Beitrag der Hochschuldidaktik dazu im Kontext der Hochschulentwicklung und lädt zum Austausch ein über deren Einflussfaktoren, Diagnosen und Ausgestaltungen im 21. Jahrhundert.

Die Reihe wird herausgegeben von Tobias Schmohl und Johannes Wildt.

Tobias Schmohl ist Hochschulbildungswissenschaftler. Seine Forschung befasst sich mit der Analyse und Gestaltung inter- und transdisziplinärer Lehr- und Lernsettings. Fachlich ist seine Arbeit im Schnittfeld von Wissenschafts-, Hochschul- und Bildungsforschung einzuordnen.

Alice Watanabe (M.A.), Philosophin und Bildungswissenschaftlerin, arbeitet als wissenschaftliche Mitarbeiterin an der Technischen Hochschule Ostwestfalen-Lippe und der Hochschule für Angewandte Wissenschaften Hamburg. Ihre Forschungsschwerpunkte liegen in der Politischen Philosophie, Technik-Ethik und der bildungsphilosophischen Forschung.

Kathrin Schelling (M.A.) arbeitet als wissenschaftliche Mitarbeiterin an der Technischen Hochschule Ostwestfalen-Lippe. Darüber hinaus ist sie als Honorardozentin für Rhetorik und Kreatives Schreiben sowie als freiberufliche Texterin und Lektorin tätig.

Tobias Schmohl, Alice Watanabe, Kathrin Schelling (Hg.)

Künstliche Intelligenz in der Hochschulbildung

Chancen und Grenzen des KI-gestützten Lernens und Lehrens

[transcript]

Gefördert durch das Ministerium für Kultur und Wissenschaft des Landes Nordrhein-Westfalen (MKW NRW)

Ministerium für Kultur und Wissenschaft des Landes Nordrhein-Westfalen



Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.



Dieses Werk ist lizenziert unter der Creative Commons Attribution-ShareAlike 4.0 Lizenz (BY-SA). Diese Lizenz erlaubt unter Voraussetzung der Namensnennung des Urhebers die Bearbeitung, Vervielfältigung und Verbreitung des Materials in jedem Format oder Medium für beliebige Zwecke, auch kommerziell, sofern der neu entstandene Text unter derselben Lizenz wie das Original verbreitet wird.

Die Bedingungen der Creative-Commons-Lizenz gelten nur für Originalmaterial. Die Wiederverwendung von Material aus anderen Quellen (gekennzeichnet mit Quellenangabe) wie z.B. Schaubilder, Abbildungen, Fotos und Textauszüge erfordert ggf. weitere Nutzungsgenehmigungen durch den jeweiligen Rechteinhaber.

Erschienen 2023 im transcript Verlag, Bielefeld

© **Tobias Schmohl, Alice Watanabe, Kathrin Schelling (Hg.)**

Umschlaggestaltung: Maria Arndt, Bielefeld

Umschlagabbildung: Bildbearbeitung auf Basis einer Abbildung von Albarubescens/Wikimedia Commons (https://commons.wikimedia.org/wiki/File:Rotational_symmetries_in_designs_produced_by_a_kaleidoscopeDSCN2440.jpg). Creative-Commons-Lizenz CC BY-SA 4.0 (<https://creativecommons.org/licenses/by-sa/4.0/deed.de>)

Druck: Majuskel Medienproduktion GmbH, Wetzlar

<https://doi.org/10.14361/9783839457696>

Print-ISBN 978-3-8376-5769-2

PDF-ISBN 978-3-8394-5769-6

Buchreihen-ISSN: 2749-7623

Buchreihen-eISSN: 2749-7631

Gedruckt auf alterungsbeständigem Papier mit chlorfrei gebleichtem Zellstoff.

Besuchen Sie uns im Internet: <https://www.transcript-verlag.de>

Inhalt

Künstliche Intelligenz in der Hochschulbildung:

Chancen und Grenzen des KI-gestützten Lernens und Lehrens

Eine Einführung in die Beiträge des Bandes

Tobias Schmohl, Alice Watanabe und Kathrin Schelling 7

Learning Analytics in Hochschulen und Künstliche Intelligenz

Eine Übersicht über Einsatzmöglichkeiten, erste Erfahrungen und Entwicklungen
von KI-Anwendungen zur Unterstützung des Lernens und Lehrens

Sandra Schön, Philipp Leitner, Jakob Lindner und Martin Ebner 27

Ménage à trois

Zur Beziehung von Künstlicher Intelligenz, Hochschulbildung und Digitalität

Cathleen M. Stützer, Stephanie Gaaw, Sabrina Herbst und Norbert Pengel 51

Ethische Perspektiven auf Künstliche Intelligenz im Kontext der Hochschule

Dirk Ifenthaler 71

Künstliche Intelligenz in der Hochschulbildung und das

Transparenzproblem: Eine Analyse und ein Lösungsvorschlag

Dominikus Herzberg 87

Studierende im KI-Diskurs

Wie Studierende in einem Workshopformat über den KI-Einsatz informiert und
zum Nachdenken über KI-gestütztes Lehren und Lernen angeregt werden

Alice Watanabe 99

Digitale Lernumwelten, studentische Diversität und Learning Outcomes:

Empirische Befunde und Implikationen für die digitale Hochschulbildung

Anja Gottburgsen, Yvette E. Hofmann und Janka Willige 119

»Wie kann ich dich unterstützen?«

Chatbot-basierte Lernunterstützung für Studienanfänger:innen

Anne-Kathrin Helten, Uwe Wienkop, Diana Wolff-Grosser und Christina Zitzmann 145

KI-basierte Erstellung individualisierter Mathematikaufgaben für MINT-Fächer

Markus Lange-Hegemann, Tobias Schmohl, Alice Watanabe, Kathrin Schelling,

Stefan Heiss und Jessica Rubart 161

Das Motivationspotenzial von Spielen erschließen

Künstliche Intelligenz als Lotse im Prozess der kreativen Gestaltung
von motivierenden Lerngelegenheiten

Thomas Bröker, Thomas Voit und Benjamin Zinger 173

Künstliche Intelligenz und forschendes Lernen – ein ideales Paar im Hochschulstudium!?

Silke E. Wrede, Christina Gloerfeld, Claudia de Witt und Xia Wang 195

Künstliche Intelligenz zur Studienindividualisierung

Der Ansatz von SIDDATA

Maren Lübcke, Johannes Schrumpf, Funda Seyfeli-Özhizalan und Klaus Wannemacher 213

Natural Language Processing im akademischen Schreibprozess – mehr Motivation durch Inspiration?

Positionspapier basierend auf einer Fallstudie an der Fachhochschule Kiel

Eike Meyer und Doris Weßels 227

Transdisziplinäre Entwicklung von Chatbots in der Betriebswirtschaftslehre und der Wirtschaftspsychologie

Anwendung von KI-Technologien ohne Programmierkenntnisse

Denis Pijetlovic 253

Wie wollen wir leben?

Ulf-Daniel Ehlers 271

Peer Review 279

Verzeichnis der Videos 281

Künstliche Intelligenz in der Hochschulbildung: Chancen und Grenzen des KI-gestützten Lernens und Lehrens

Eine Einführung in die Beiträge des Bandes

Tobias Schmohl, Alice Watanabe und Kathrin Schelling

»Artificial Intelligence (AI) is currently high on the political and research agendas around the world. With the emergence of every new technology, there is always both a lot of hype and scepticism around its implications for society and the economy« (Tuomi, 2018, S. 1).

Einführung: KI in der Hochschullehre

Video: <https://link.transcript-open.de/5769/video/001>

© Tobias Schmohl



Dieser kurze Auszug aus dem von der Europäischen Union veröffentlichten *JRC Science Policy Report* »The Impact of Artificial Intelligence on Learning, Teaching, and Education« verdeutlicht, dass mit dem Aufkommen neuer Technologien neben allen euphorischen Reaktionen stets auch vielfältige Abwehrreflexe verbunden sind.

Sind technische Neuerungen in der Lage, Technologien oder Dienstleistungen zumindest in Teilen zu ersetzen, steigt mit ihrem Aufkommen auch der Bedarf an Orientierungswissen für politische und wirtschaftliche Stakeholder. Wissenschaftliche Disziplinen richten ihr Erkenntnisinteresse entsprechend auf die jeweils in ihre Zuständigkeitsbereiche fallenden lokalen Wissensdomänen aus. Die Bildungswissenschaften sind im Falle der Neuerungen, die KI-Technologien mit sich bringen, besonders betroffen: Bereits 2019 prognostizierte der *EDUCAUSE Horizon Report*, dass die Zahl der KI-Anwendungen im Bildungssektor international bis 2022 um fast 48 % steigen würde (Alexander et al., 2019). Die COVID-19-Pandemie und der dadurch ausgelöste Digitalisierungsschub haben diese Entwicklung noch weiter beschleunigt. So wiesen die *EDUCAUSE*-Autor:innen im Jahr 2021 künstliche Intelligenz als emergente Schlüsseltechnologie für die Hochschulbildung aus (Pelletier et al., 2021, S. 13). Der Report 2022 präsentiert bereits zwei distinkte Anwendungsformen als aktuelle Trend-Themen in der internationalen Bildungslandschaft: Die Kombination von KI mit Learning Analytics und die Entwicklung KI-basierter Lern-tools (Pelletier et al., 2022, S. 16f.).

Obwohl sich der internationale Diskurs zum Thema *Künstliche Intelligenz* in den vergangenen Jahren stark intensiviert hat, ist der mögliche Einsatz von KI in der Hochschulbildung – im internationalen Kontext oft als »AI in Education« (AIED) bezeichnet – bereits seit etwa dreißig Jahren Gegenstand der Forschung unterschiedlicher akademischer Disziplinen (Hwang et al., 2020, S. 1; Zawacki-Richter et al., 2019, S. 2), wobei die theoretische Auseinandersetzung mit diesem Themenkomplex noch deutlich weiter zurückreicht. So wurde bereits am 13. Juli 1956 in New Hampshire auf der sogenannten *Dartmouth Conference* diskutiert, was später anhand technologischer Soft- und Hardwarelösungen zu damals noch kaum vorstellbaren Lösungen führen sollte: die Annahme, »that every aspect of learning or any other feature of intelligence can in principle be so precisely described that a machine can be made to simulate it« (McCarthy et al., 1955, S. 2).

Der KI-Diskurs an deutschen Hochschulen

Als Vorreiter im Bereich des technologiegestützten Lernens, zu dem auch der Einsatz KI-basierter Tools in Lehr-Lernkontexten zählt, gelten heute die USA, China, Israel und die Türkei (Zawacki-Richter et al., 2019). Gleichzeitig sind aber auch in Australien und Japan derzeit viele weit fortgeschrittene Pilotprojekte angesiedelt (Büching et al., 2019; Obari & Lambacher, 2019; Shirouzou, 2018). In Deutschland hingegen wächst das hochschulpolitische Interesse nach Jahrzehnten der eher zurückhaltenden Auseinandersetzung mit der Thematik erst seit kurzem – dafür nun umso rasanter.

Die Intensität, mit der Bund und Länder die Hochschulen beim Einstieg in den KI-Diskurs unterstützen, spiegelt sich insbesondere in der Förderinitiative »Künstliche Intelligenz in der Hochschulbildung«. Im Rahmen einer gemeinsamen Konferenz beschlossen Bund und Länder im November 2020, Fördermittel in Höhe von insgesamt 133 Millionen Euro für eine Ausweitung des Lehrangebots zum Thema KI sowie für die Erforschung und Implementierung von KI-Anwendungen in der Hochschullehre zur Verfügung zu stellen (Kötting, 2020). Im Juni 2021 wurden 40 Einzelanträge und 14 Verbundprojekte bewilligt, an denen bis Ende 2025 insgesamt 52 Hochschulen aus ganz Deutschland arbeiten werden (BAnZ AT, 23.12.2022 B8).

Welches disruptive Potenzial KI hierzulande insgesamt zugeschrieben wird, zeigen u.a. die aktuellen Förderrichtlinien des Bundesministeriums für Forschung und Bildung. »Künstliche Intelligenz (KI) wird in den kommenden Jahren weltweit Gesellschaft, Wirtschaft und den Alltag der Menschen verändern«, heißt es hier (BMBF, 2021). Um dieser Herausforderung zu begegnen, seien nun insbesondere die Hochschulen gefragt, nicht nur als Forschungs- und Innovationszentren, sondern ganz explizit auch in der Lehre, da sie »Studierende auf qualifizierte berufliche Tätigkeiten vorbereiten, bei der die Anwendung von KI immer wichtiger werden wird« (ebd.). Sowohl den Trend zur KI als auch den daran geknüpften Bildungsauftrag haben viele Hochschulen frühzeitig antizipiert und für sich angenommen: Bereits 2019 gab es in Deutschland mindestens 75 Studiengänge mit KI-Schwerpunkt und insgesamt 192 Professor:innen, die Forschung und Lehre zu diesem Themenbereich betrieben (Mah & Büching, 2019). Bis Ende 2022 werden voraussichtlich mindestens vier weitere KI-Studiengänge und über 20 Professuren für KI-Spezialist:innen hinzukommen (ebd.) – Tendenz steigend.

Dieser kontinuierliche Ausbau des Lehrangebots ist allerdings nur ein Teil der Entwicklung, die sich aktuell in der Hochschullandschaft abzeichnet. Dank zahlreicher neuer Förderlinien ist auch die Zahl der langfristigen Forschungsprojekte zum Thema KI in der Hochschulbildung in den vergangenen Jahren deutlich gestiegen. Einen ersten Überblick über Anwendungen und Entwicklungsprojekte, in denen KI-Technologien in Deutschland aktuell zum Einsatz kommen, vermittelt etwa die interaktive Landkarte der Plattform Lernende Systeme.¹ Parallel zur technischen Entwicklung nimmt auch der Diskurs über KI in der Hochschulbildung zunehmend Fahrt auf.

1 <https://www.plattform-lernende-systeme.de/ki-in-deutschland.html>

Chancen und Risiken von KI an der Hochschule

Der Einsatz intelligenter selbstlernender Systeme in der Hochschulbildung zielt allgemein darauf ab, organisationale Strukturen einer Bildungsinstitution anzupassen, konkrete Lernsettings zu optimieren und Lehr-Lernsituationen effizienter zu gestalten. Gerade Prozesse rund um das komplexe didaktische Geschehen im Hochschulkontext lassen sich mit Hilfe von KI-Anwendungen vereinfachen, beschleunigen oder teilweise sogar vollständig automatisieren. So arbeiten derzeit etwa Einrichtungen des postsekundären Bildungsbereichs in aller Welt daran, durch Maschinelles Lernen die Kosten für den Studienbetrieb zu reduzieren oder durch personalisierte Lernangebote ihre Absolvent:innenzahlen zu erhöhen (Hwang et al., 2020; de Witt et al., 2020). Gleichzeitig gelten KI-Anwendungen aber auch als Chance, um aktuellen hochschulpolitischen Anforderungen zu begegnen. Herausforderungen wie etwa die vergleichsweise hohen Studienabbruchquoten in den MINT-Fächern (Heublein et al., 2018; Hinkelmann & Jordine, 2019; Russell, Smith & Larsen, 2020; Behr et al., 2021), die wachsende Diversität der Lernenden (Wissenschaftsrat, 2017; Russell et al., 2019) oder die infolge der Corona-Pandemie stark verringerte internationale Mobilität der Studierenden (DAAD, 2021) erfordern differenzierte, passgenau auf die jeweiligen Zielgruppen zugeschnittene Ansätze. Vieles, das bislang nur mit enormem Zeit- und Personalaufwand zu bewältigen wäre, scheint durch KI schneller, zuverlässiger und vor allem kostengünstig lösbar. Im Kontext der Hochschulbildung eingesetzte KI-Anwendungen lassen sich dabei grundsätzlich in drei Ebenen unterteilen (Ulrich & Heckmann, 2017; Watanabe, 2022).

Auf der **Mikroebene** können KI-Anwendungen im Rahmen konkreter Lehr-Lernprozesse zum Einsatz kommen. Die Auswirkungen der neuen Technologie auf Lernen und Lehre können daher auf dieser Eben sowohl aus der Perspektive der Lehrenden als auch aus der Perspektive der Studierenden betrachtet werden. Für Studierende bergen KI-Anwendungen dabei das Potenzial, ihr eigenes Lernverhalten besser zu kontrollieren und individuelles Feedback zu erhalten. Darüber hinaus können KI-gestützte Systeme die individuellen Lernvoraussetzungen und -vorlieben der Studierenden analysieren und ihnen daran angepasste Lernunterstützung bieten. Forschung in diesem Bereich fokussiert entsprechend die Frage, wie mit Hilfe von KI und Learning Analytics adaptives Lernen erreicht werden kann (Schumacher & Ifenthaler, 2021, 2018; de Witt et al., 2020). Für Lehrkräfte liefern KI-Anwendungen indes schon heute detaillierte Informationen über das Lernverhalten ihrer Studierenden. Das birgt das Potenzial, Lerninhalte didaktisch zielgerichteter zu vermitteln, leistungsschwache Studierende frühzeitiger zu identifizieren und sie effektiver zu fördern. Zudem können Lehrende die KI-basierten Anwendungen dafür nutzen, ihre eigenen Lehr-Strategien auf den Prüfstand zu stellen und Verbesserungspotenziale in ihrer Didaktik zu erkennen (Glick et al.,

2019; de Witt et al., 2020). Derzeit mangelt es jedoch insbesondere an empirischen Studien zur Lernwirksamkeit mit KI, die über singuläre Anwendungen hinausgehen. Darüber hinaus besteht bislang keine systematische Verknüpfung bildungstheoretischer Modelle und Ergebnisse mit den empirischen Lösungen oder den praktischen Umsetzungen.

Auf der **Mesoebene** kann KI in die Gestaltung des Curriculums integriert werden. In diesem Kontext stellen KI-Technologien vor allem eine Chance im Bereich der Qualitätssicherung für Curricula und deren Bildungsdesign dar, indem etwa mit Hilfe von KI fachliche Lücken oder Redundanzen identifiziert werden (Ifenthaler et al., 2018; Lockyer, Heathcote et al., 2013). So lassen sich insbesondere auch Diskrepanzen zwischen Lernzielen (*Intended Learning Outcomes*) und der Struktur eines Studienprogramms feststellen (Somasundaram, Latha et al., 2020). Die KI erfasst so beispielsweise einführende Lerninhalte, die für fortgeschrittene Module vorausgesetzt werden. Sie unterbreitet auf dieser Grundlage Vorschläge für Sperrfächer, empfiehlt spezifische Vorkurse oder angepasste Studienverlaufspläne. Darüber hinaus werden Chancen für den Einsatz von KI auf der administrativen Ebene gesehen, z. B. bei der Abwicklung von Bewerbungs- und Zulassungsverfahren (Adakitán & Noma-Osaghae, 2019) oder bei der Unterstützung von Studienberatungen (Jones, 2019). Die letztgenannten Möglichkeiten können auch auf der Makroebene der Universität zum Tragen kommen, was zeigt, dass eine spezifische Zuordnung von KI-Chancen nicht immer möglich ist. Ein spezifisches Desiderat der Mesoebene besteht in der didaktischen Forschung zur Qualifizierung von Lehrpersonal, insbesondere zur hochschul- und fachdidaktischen Kompetenzentwicklung im Umgang mit KI-Anwendungen sowie zur kritischen pädagogischen Reflexion der technologischen Neuerungen.

Auf der **Makroebene** sind die Chancen des Einsatzes von KI eher im Bereich der Hochschulpolitik – auf der institutionellen Ebene der Hochschule – einzuordnen. Mit Klutka et al. (2018) können die damit einhergehenden Chancen wie folgt zusammengefasst werden: Verbesserung der Ergebnisse, Verbesserung des Zugangs, Erhöhung der Verweildauer, Senkung der Kosten und Verkürzung der Zeit bis zum Abschluss. Auf dieser Ebene liegt der Schwerpunkt vor allem auf der Senkung der Studienkosten und der Erhöhung der Absolvent:innenzahlen (Hwang et al., 2020, de Witt et al., 2020). Je stärker die Zahl der Einsatzmöglichkeiten wächst, desto vehementer melden sich allerdings auch hier kritische Stimmen zu Wort. Neben Fragen des Datenschutzes (Büching et al. 2019; Kieslich et al., 2019; Alexander et al., 2019) und ethischen Bedenken (Selznick & Titareva, 2022) werden dabei insbesondere die möglichen Auswirkungen der KI auf die Qualität der Lehre thematisiert. Ein allzu naiver Umgang mit einer emergenten Technologie, deren Schwachstellen erst im Lauf ihrer Anwendung sichtbar werden könnten – so das zentrale Argument – könnte schließlich gravierende Auswirkungen auf Lehr-Lernprozesse und den gesamten Bildungsweg der Studierenden haben. So befürchten etwa sowohl Lehrende

als auch Lernende, dass der vermehrte Einsatz von KI-Anwendungen auf der Mikroebene der Hochschulbildung eine übermäßige Fokussierung auf technologiegestützte Lehrformate zur Folge haben könnte (Castañeda & Selwyn, 2018; Selwyn et al., 2020). Neben der Möglichkeit des Stellenabbaus in der Lehre wird dabei insbesondere die potenzielle Reduktion der sozialen Interaktion im Studium als problematisch diskutiert (Bates et al., 2020). Aus Perspektive der Studierenden kommt außerdem die Sorge hinzu, dass der Einsatz von KI die Lehrenden dazu verleiten könnte, sich in ihrer Bewertung von Studienleistungen allzu stark auf die vermeintliche Objektivität automatischer Assessments zu verlassen (Keim & Sattler, 2020).

Gestaltet sich die Datenverarbeitung durch die KI intransparent, besteht schlimmstenfalls sogar die Gefahr struktureller Diskriminierung durch den Algorithmus (Kieslich et al., 2019; Alexander et al., 2019). Auf der Mikroebene könnte diese beispielsweise durch eine systematische Verzerrung (*Bias*) in der KI-basierten Leistungsbewertung entstehen, die den Lernerfolg der Studierenden durch Generierung zu einfacher oder zu schwerer Aufgaben unterminiert. Noch gravierender könnte sich ein solcher Bias auf der Makroebene auswirken. Analog zu bereits bekannten Fällen aus dem Human Resource Management, in denen KI-basierte Systeme Bewerber:innen aufgrund ihres Geschlechts oder Alters vorrangig Stellenanzeigen aus bestimmten Fachbereichen anzeigten (vgl. beispielsweise Köchling & Wehner, 2020), könnte etwa ein KI-basierter Studierfähigkeitstest, wie er an manchen Hochschulen obligatorischer Bestandteil der Bewerbung ist, ganzen Gruppen von Studieninteressent:innen den Zugang zu bestimmten Studienfächern erleichtern oder erschweren.

Sorgen wie diesen können die Hochschulen bislang nur durch abstrakte Argumentation begegnen. Die Zahl der Tools für die Hochschulbildung, die bereits den Sprung aus dem Pilotprojekt in den Regelbetrieb geschafft haben, ist gering (Bates et al., 2020: 1; de Witt et al., 2020). Selbst zu erfolgreich implementierten Anwendungen gibt es nur wenige empirische Erhebungen, von bildungswissenschaftlichen Forschungsansätzen ganz zu schweigen (Bates et al., 2020). Diese auffällige Diskrepanz zwischen dem hochschulpolitischen Ziel, KI im postsekundären Bildungssektor zu verankern, und der realen Entwicklung an den Hochschulen lässt sich jedoch leicht erklären: Während die Entwicklung der Anwendungen auf Hochtouren läuft, schreiten die Vorbereitungen für die Implementierung im Lehrbetrieb schleppend voran. Für einen routinierten Umgang mit KI-basierten Anwendungen mangelt es Hochschulen – im Übrigen nicht nur nicht nur in Deutschland – oftmals an technischem Equipment, an Fachkräften sowie an Organisationsstrukturen, die eine Einbettung der Anwendungen in Lehr-Lernkontexte ermöglichen würden (Buckingham Shum & McKay, 2018). Erschwerend kommt außerdem hinzu, dass es großen Wirtschaftsunternehmen wie LinkedIn, Amazon oder Coursera, die tagtäglich enorme Datenmengen generieren, deutlich leichter fällt, komplexe Algorithmen zu trainieren (Bates et al., 2020). Während die Hochschulen noch damit

beschäftigt sind, ihre digitale Infrastruktur auszuweiten und Rahmenbedingungen für einen sicheren Umgang mit Nutzungsdaten zu schaffen (Watanabe, 2021; Gierdowski et al., 2020), schreitet die Entwicklung KI-basierter Bildungsangebote andernorts fort – und die Kluft zwischen Anspruch und Realität der Hochschulbildung wächst weiter.

Die Beiträge dieses Sammelbands

Künstliche Intelligenz kann in der Hochschulbildung sehr unterschiedliche Funktionen erfüllen. Der vorliegende Sammelband richtet den Fokus auf die Mikroebene – auf Lehr-Lernprozesse. Hier kann KI in zwei Grundformen Einzug finden: Als Thema oder als Tool (Watanabe, 2022; Wannemacher & Bodmann, 2021). Aktuell ist KI vor allem in Form einzelner Funktionsbereiche innerhalb umfassender didaktischer Systeme etabliert. So verfügen beispielsweise immer mehr Lernsoftwares bzw. -plattformen und Bildungscloids über KI-basierte Features und auch Kollaborationswerkzeuge, Tutoring-Systeme oder Assessment-Tools für (teil-)automatisierte Bewertungen nutzen zunehmend KI, um durch Automatisierung neue oder schlicht effizientere Funktionen zu ermöglichen. Im didaktischen Kontext werden unter dem Schlagwort »KI-Technologien« insbesondere folgende Anwendungsfelder diskutiert (Schmid, Blanc & Toepel, 2021):

- Intelligente tutorielle Systeme (ITS)
- Natürliche Sprachverarbeitung, automatisierte Spracherkennung und automatisierte Textgenerierung (NLP, ASR, NLG)
- Automatisierte Bewertung und Benotung
- Multimediale Mensch-Maschine-Interaktion (beispielsweise Chatbots, Learning Companions)
- Learning (Predictive) Analytics, Data-Mining im Bildungsbereich (LA, LPA, EDM)
- Adaptives Lernen, Empfehlungsdienste

Als Gegenstand der Forschung und Lehre beschäftigt KI speziell auf dieser Ebene längst nicht mehr nur diejenigen Fachbereiche, die sich mit der technischen Entwicklung und Evaluation intelligenter Systeme befassen. In Anbetracht der fortschreitenden Digitalisierung durchdringt der KI-Diskurs inzwischen nahezu alle akademischen Disziplinen. So bereiten etwa die Rechtswissenschaften Studierende auf die Auseinandersetzung mit den Auswirkungen technischer Innovation auf Ge-

sellschaft und Recht vor,² die Philologien diskutieren den Mehrwert KI-gestützter Übersetzungstools³ und die Medizin nutzt intelligente Systeme, um Ärzt:innen bei der Auswertung umfangreicher Datensätze für die Diagnostik zu unterstützen.⁴

Neben dieser *Lehre über KI* öffnet sich der postsekundäre Bildungssektor inzwischen auch zunehmend für die *Lehre mit KI*. Die Hochschulen stellen »ein anwendungsorientiertes Wirkungsfeld [dar], in dem neue Möglichkeiten in den Bereichen Forschung und Lehre durch und mittels KI-Technologien bereits zur Anwendung kommen oder entwickelt werden« (Wannemacher & Bodmann, 2021, S. 9). Mit Blick auf die organisatorischen Strukturen der Hochschulen bedeutet das, dass KI-basierte Tools sowohl vor als auch hinter den Kulissen der Lehre zum Einsatz kommen: Sie können einerseits die Studienorganisation unterstützen und andererseits dazu beitragen, Lehr-Lernkontexte flexibler, individueller und erfolgreicher zu gestalten.

Auch wenn es gewiss zahlreiche Schnittstellen zwischen der Lehre *mit* KI und der Lehre *über* KI gibt, liegt der Fokus des vorliegenden Sammelbandes auf dem Einsatz von KI in Lehr-Lernkontexten. In Anbetracht der Vielfalt dieses Themenkomplexes haben wir uns für eine Beitragsauswahl entschieden, die unterschiedliche Perspektiven auf Chancen, Grenzen und mögliche Fallstricke der Technologie zur Sprache bringt. Durch diese Heterogenität wollen wir den aktuellen Stand eines Diskurses abbilden, der nicht nur Konzepte des Lernens und Lehrens auf den Prüfstand stellt, sondern auch die Hochschulen als Innovationstreiber anspricht und sie dazu anregt, ihre Rolle als Vermittler zwischen Gesellschaft und Technik neu zu denken.

Um einen Eindruck davon zu vermitteln, wie viele verschiedene Problemfelder der Hochschulbildung durch den KI-Einsatz neu bearbeitet werden können, haben wir die nachfolgenden Beiträge anhand des Student Lifecycle gegliedert – eines Konzepts, das viele Hochschulen als Managementinstrument nutzen. Der Student Lifecycle untergliedert das Hochschulstudium in Phasen, die vom ersten Kontakt der Studieninteressent:innen mit ihrer künftigen Hochschule über Bewerbung, Immatrikulation und Studium bis hin zum Abschluss reichen (Morgan, 2013). Im Mittelpunkt jeder Phase stehen zentrale Erfahrungen, die Studierende mit hoher Wahrscheinlichkeit zum jeweiligen Zeitpunkt in ihrer Hochschulkarriere machen.


2 Ein aktuelles Anwendungsbeispiel dafür wäre das Projekt »Leipziger Ausbildungsprogramm für Digitalisierung und Recht« (LeADeR), das darauf abzielt, die juristische Ausbildung an deutschen Hochschulen an technologische Entwicklungen – insbesondere aus dem Bereich der Künstlichen Intelligenz – anzupassen (Paal & Wais, 2022).

3 Vgl. hierzu beispielsweise Dreesen & Bubenhofer (2020), die mit Blick auf KI-gestützte maschinelle Übersetzungen die Frage nach dem (Mehr-)Wert menschlicher Übersetzungstätigkeit im Zeitalter der digitalen Technologien aufwerfen.

4 Einen Überblick über die möglichen Anwendungsbereiche der sogenannten »medical AI« liefern beispielsweise Rajpurkar et al., 2022.

Diese Fokussierung auf die Erfahrungswelt der Studierenden ermöglicht es einerseits, zu evaluieren, welche Herausforderungen es im Lauf eines Studiums zu bewältigen gilt – und welche Serviceangebote die Hochschulen ihren Studierenden zu welchem Zeitpunkt zur Verfügung stellen sollten, um einen möglichst reibungslosen Verlauf zu gewährleisten. Andererseits kann der Student Lifecycle aber auch als Struktur für hochschuldidaktische Überlegungen herangezogen werden. Exemplarisch sei etwa auf Schulmeister (2007) verwiesen, der anhand des Student Lifecycle aufzeigt, welche E-Learning-Anwendungen Studierenden dabei helfen können, zentrale Herausforderungen des Bachelor- und Masterstudiums zu meistern. Spezifisch mit Blick auf die Anwendung von KI in der Hochschullehre sind außerdem Khare et al. (2018) zu erwähnen, die anhand des SEPT-Modells (Morgan 2013, 2018) – einer auf Transitionsphasen im Studienverlauf fokussierten Variante des Student Lifecycle – Datenquellen identifizieren, aus denen unterschiedliche KI-basierte Anwendungen für die Hochschullehre gespeist werden könnten (Khare et al., 2018, S. 71f.).

*Abbildung 1: Student Lifecycle nach Schulmeister (2007, S. 230)
(eigene Darstellung).*



Allerdings ist der Student Lifecycle nicht als starr sukzessive Abfolge zu verstehen (Khare et al., 2018). Die Phasen sind nicht streng voneinander abgegrenzt und weisen oft auch inhaltliche Überschneidungen auf, sodass das Modell individuellen Lernbiografien sowie den verschiedenen Schwerpunkten innerhalb der einzelnen Studiengänge Rechnung tragen kann. Aus diesem Grund können auch die meisten Beiträge in diesem Sammelband mehreren Phasen des Student Lifecycle zugeordnet werden.

Der erste unserer insgesamt fünf Themenschwerpunkte spürt der KI-Frage aus Sicht der Hochschule nach. Die Themenschwerpunkte zwei bis vier rücken hingegen die Studierenden, ihre Ansichten, Wünsche und Bedürfnisse in unterschiedlichen Phasen des Studiums in den Fokus. Der Band endet mit einem Essay, der in Form eines kritischen Denkanstoßes verfasst ist und dabei nochmals eine übergeordnete Perspektive einnimmt, indem er künstliche Intelligenz und menschliches Lernen als komplementäre Vorgänge in den Blick nimmt.

Themenschwerpunkt 1: Grundlegende Überlegungen zu KI in der Hochschulbildung

Es ist müßig, über die möglichen Auswirkungen KI-basierter Anwendungen auf Lehr- und Lernprozesse zu diskutieren, bevor geklärt ist, inwiefern sich die technischen Lösungen überhaupt in den Regelbetrieb der Bildungseinrichtungen integrieren lassen. Aus diesem Grund muss die Diskussion über KI in der Hochschulbildung lange vor dem Moment beginnen, an dem Studierende zum ersten Mal mit konkreten Anwendungen in Kontakt kommen. Zuerst sind Forschende, Lehrende und insbesondere die Hochschulen in ihrer Rolle als Bildungsanbieter gefragt: Wie lässt sich KI überhaupt gewinnbringend in Lehr-Lernsituationen einbinden? Die ersten vier Beiträge unseres Sammelbandes zeigen anhand konzeptioneller Überlegungen zu Technik, Didaktik, Ethik und Bildungsfolgenforschung grundlegende Bedingungen für die erfolgreiche Implementierung von KI in der Hochschulbildung auf.

Sandra Schön, Philipp Leitner, Jakob Lindner und Martin Ebner widmen sich in ihrem Artikel dem Thema Learning Analytics. Sie vergleichen gängige Definitionen für diese Technologie und grenzen sie gegen das Konzept der künstlichen Intelligenz ab. Damit liefern sie eine trennscharfe terminologische Grundlage, die in Beiträgen über KI in der Hochschulbildung häufig fehlt. Vor diesem Hintergrund zeigen die Autor:innen dann auf, in welcher Form und mit welcher Zielsetzung Learning Analytics mit Nutzung von KI-Anwendungen bereits an internationalen Hochschulen zum Einsatz kommt und welche Potenziale der Einsatz von KI für diese Anwendungen birgt.

Der Beitrag von **Cathleen M. Stützer, Stephanie Gaaw, Sabrina Herbst und Norbert Pengel** schließt nahezu nahtlos an diese Thematik an. Sie gehen der Frage

nach, welche Voraussetzungen erfüllt sein müssen, um KI-gestützte Anwendungen erfolgreich in den Lehrbetrieb und ggf. auch in die Organisationsstrukturen im postsekundären Bildungssektor einzubinden. Die Autor:innen präsentieren ein Modell zur wirksamen und nachhaltigen Implementierung von KI in der Hochschulbildung, das Konzepte der Adoptionsforschung sowie Überlegungen zur organisationalen Ebene von Hochschulen aufgreift.

Dirk Ifenthaler erweitert die Liste der Bedingungen für den erfolgreichen Einsatz von KI an Hochschulen um eine ethische Dimension. Sein Beitrag verbindet eine kritische Bestandsaufnahme zu Reifegrad und Wirkkraft von KI-Anwendungen für die Hochschulbildung mit verschiedenen ethischen Ansätzen. Dabei skizziert Ifenthaler einerseits Grenzen und Gefahren der Technologie und zeigt andererseits auf, wie sich der transparente, verantwortungsvolle Umgang mit den persönlichen Daten der User:innen an der Hochschule an ethischen Richtlinien orientieren kann.

Dominikus Herzberg stellt schließlich die Frage, was geschehen würde, wenn schon heute vollständig ausgereifte KI-Anwendungen für die Hochschulbildung zur Verfügung stünden. Würden – *dürften* – Hochschulen diese Tools wirklich nutzen? Herzberg plädiert in seinem Beitrag für eine zeitgemäße Form der Bildungsfolgenforschung, die sich diesen Herausforderungen stellt und bei Bedarf auch zwischen augenscheinlichen Gegensätzen wie der Black Box der Künstlichen Intelligenz und dem Recht der User:innen auf Transparenz zu vermitteln vermag.

Themenschwerpunkt 2: Der Einstieg ins Studium

Da der Student Lifecycle ursprünglich als Managementinstrument konzipiert wurde, setzt das Modell noch vor der Einschreibung an einer Hochschule an. Die ersten Phasen umfassen die studienvorbereitenden Recherche und Organisation sowie den Bewerbungsprozess und die Zulassung an einer Hochschule. Da sich unser Sammelband mit der Rolle von KI in der Hochschulbildung beschäftigt, sind diese Schritte hier ausgespart. Unsere Betrachtung beginnt stattdessen im ersten Semester, der Phase des Student Lifecycle, in der sich die Studierenden erstmals mit Strukturen, Abläufen und Anforderungen der Hochschullehre vertraut machen.

Alice Watanabe schlägt mit ihrem Beitrag die Brücke zwischen den Gelingensbedingungen für die erfolgreiche Implementierung KI-basierter Tools in der Hochschulbildung und dem Student Lifecycle. Denn obwohl die Akzeptanz der Studierenden dafür ausschlaggebend ist, werden ihre Einstellungen zur KI-Frage bislang nur selten erforscht. Als Beispiel dafür, wie Hochschulen ihre Studierenden für die Chancen und Herausforderungen des KI-Einsatzes sensibilisieren und zugleich Akzeptanzforschung betreiben können, stellt Watanabe ein Workshopkonzept vor, das anhand animierter Erklärvideos zur Diskussion über mögliche KI-Zukunftsszenarien anregt.

Anja Gottburgsen, Yvette E. Hofmann und **Janka Willige** thematisieren in ihrem Beitrag indes die Bedeutung technologiegestützter Umwelten für die Förderung von studentischer Vielfalt. Wir verorten auch diesen Artikel bewusst zu Beginn des Student Lifecycle, da Diversitätsmerkmale von der Wahl des Studienfachs bis hin zu Auslandsaufenthalten die gesamte Hochschulerfahrung beeinflussen können. Digitale Angebote können einen Beitrag dazu leisten, die Hochschulbildung diverser zu gestalten, doch – wie die Autorinnen dieses Artikels zeigen – zählen auch die Medienkompetenz bzw. die Medienpräferenz der Studierenden zu den Diversitätsmerkmalen, die es bei der Gestaltung neuer, KI-gestützter Ansätze zu bedenken gilt.

Eine weitere Herausforderung, mit der sich Studierende in ihren ersten Hochschulse mestern konfrontiert sehen, ist die Umstellung auf akademische Lehr- und Lernprozesse. Im Gegensatz zum stark vorstrukturierten Schulalltag setzt das selbstorganisierte Lernen an der Hochschule ein hohes Maß an Methodenkompetenz und Selbstmanagement voraus. **Anne-Kathrin Helten, Uwe Wienkop, Diana Wolff-Grosser** und **Christina Zitzmann** zeigen am Beispiel des im Rahmen des Initiativprogramms BayernMINT entwickelten OSABot, wie ein Chatbot Studierende bei der Entwicklung dieser für den Studienerfolg entscheidenden Kompetenzen unterstützen kann.

Themenschwerpunkt 3: Kompetenzentwicklung im Studienverlauf

Auf den erfolgreichen Einstieg in akademische Lehr-Lernprozesse folgt im Student Lifecycle eine Phase, die sich – grob vereinfacht – als das eigentliche Studium beschreiben ließe. Die Studierenden haben sich an der Hochschule eingewöhnt und sich die Grundlagen des wissenschaftlichen Arbeitens angeeignet, die es ihnen nun erlauben, fachspezifische Wissensbestände zu erschließen. In dieser Phase des Student Lifecycle kann KI auf zweifache Weise zur Verbesserung der Studienbedingungen und Lernerfolge beitragen. Zum einen bieten neue Anwendungen die Chance, bereits bekannte Probleme in Lehr-Lernkontexten zu lösen und optimale Lernbedingungen zu schaffen. Zum anderen regt der Einsatz von KI aber auch dazu an, das Curriculum neu zu denken: Welche Kompetenzen werden in Anbetracht der neuen technischen Möglichkeiten obsolet und über welche Fähigkeiten sollten Studierende der »Generation KI« (Pelletier et al., 2021, S. 13) stattdessen verfügen, um sich in der Informationsgesellschaft der Zukunft zu behaupten?

In dieser Phase des Student Lifecycle kommt außerdem der Retention eine immer größere Rolle zu – und damit auch dem Aufbau solider Grundkenntnisse im jeweiligen Fachbereich. Je größer die Wissenslücken, desto größer ist schließlich auch die Gefahr der Überforderung und infolgedessen das Risiko eines Studienabbruchs. Der Beitrag von **Markus Lange-Hegemann, Tobias Schmohl, Alice Watanabe, Kathrin Schelling, Jessica Rubart** und **Stefan Heiss** zeigt, wie KI und Learning

Analytics mit einem fachdidaktischen Konzept verknüpft werden können, um individualisierte Mathematikaufgaben für MINT-Fächer zu generieren, die dem aktuellen Lernstand der Studierenden entsprechen.

Eng mit dem Lernerfolg und damit auch mit der Studienabbruchquote verbunden ist zudem die Lernmotivation. Sie fördert die intensive Auseinandersetzung mit Lernmaterialien und trägt maßgeblich dazu bei, dass Studierende auf eventuelle Rückschläge mit Resilienz statt Resignation reagieren. **Thomas Bröker, Thomas Voit** und **Benjamin Zinger** zeigen, wie KI dabei helfen kann, Lehr-Lernsituationen motivierend zu gestalten. Sie präsentieren in ihrem Beitrag ein im Rahmen des Forschungsprojekts EMPAMOS entwickeltes System, das sowohl Lernende als auch Lehrende einsetzen können, um durch Gamification-Elemente die Lernmotivation zu steigern.

Auch **Silke E. Wrede, Christina Gloerfeld, Claudia de Witt** und **Xia Wang** präsentieren ein Projekt, von dem Studierende im Zuge ihrer Neuorientierung zum Ende des Studiums besonders profitieren. Das AI.EDU Research Lab der Fernuniversität Hagen entwickelt KI-basierte Module, die Studierende bei der Entwicklung von Studienarbeiten unterstützen sollen. Die dabei umgesetzte Kombination von forschendem Lernen und KI zielt darauf ab, neben der Problemlösekompetenz der Studierenden auch die Entwicklung von »21st Century Skills« (Bellanca & Brandt, 2010), i.e. die Kompetenzen im Umgang mit moderner Informationstechnologie zu fördern.

Schließlich stellen **Maren Lübcke, Johannes Schrupp, Funda Seyfeli-Özhizalan** und **Klaus Wannemacher** ein KI-basiertes System zur individuellen Förderung der Studierenden vor, das bereits in der Hochschulpraxis erprobt wird: Das Studienassistenzsystem SIDDATA unterstützt seine User:innen sowohl bei der Auswahl passender Lerntechniken und -materialien als auch bei der Organisation von Auslandssemestern und Lerngruppen. In ihrem Beitrag präsentieren die Autor:innen erste empirische Ergebnisse zu einem KI-basierten Recommender-System, über das SIDDATA Studierende automatisch auf Lehrveranstaltungen hinweist, die ihren individuellen fachlichen Interessen entsprechen.

Themenschwerpunkt 4: Vorbereitung auf Berufseinstieg und weiterführendes Studium

Im Lauf eines jeden Hochschulstudiums stellt sich früher oder später die Frage, wie es nach dem Abschluss weitergehen soll. Studierende beginnen, das Für und Wider eines Aufbau- oder Zweitstudiums zu eruieren, und auch das Fachwissen, das sie sich in ihren Lehrveranstaltungen aneignen, wird in dieser Phase des Student Lifecycle zunehmend unter dem Gesichtspunkt der Berufsorientierung betrachtet. Diese Neuorientierung zum Ende des Studiums können Hochschulen in zweifacher Hinsicht unterstützen: Durch Einblicke in die Bewerbungs- und Berufspraxis sowie

durch Methodentraining, das den Absolvent:innen den Übergang in die Arbeitswelt bzw. in ein Aufbau- oder Promotionsstudium erleichtert.

Eine der Kompetenzen, die es in diesem Kontext neu zu bewerten gilt, ist das wissenschaftliche Schreiben. Für eine erfolgreiche Abschlussarbeit ist ein gewisses Maß an Schreibkompetenz ebenso unerlässlich wie für die Promotion oder eine Karriere in der Wissenschaft. Doch was bedeutet es für den Stellenwert dieser Kompetenz, wenn KI die wissenschaftliche Textproduktion übernehmen kann? **Eike Meyer** und **Doris Weißels** veranschaulichen anhand eines Workshops, wie Studierende an den konstruktiven Umgang mit KI-basierten Textgeneratoren herangeführt werden können und welche Fragen zur wissenschaftlichen Praxis vor dem Hintergrund dieser Tools neu gestellt werden müssen.

Denis Pijetlovic stellt in seinem Beitrag wiederum ein Studienprojekt vor, das Einblicke in den aktuellen KI-Diskurs mit praktischer Erfahrung in der transdisziplinären Zusammenarbeit verknüpft. Das *HumanRoboLab* bringt Studierende der Betriebswirtschaftslehre und der Wirtschaftspsychologie mit Praxispartner:innen aus der Wirtschaft zusammen, um gemeinsam Chatbots zu entwickeln. Kooperationen wie diese können das Lehrangebot um praxisnahe Aufgabenstellungen erweitern, die Studierenden unterschiedlicher Fachrichtungen Einblicke in aktuelle IT-Themen geben und ihnen zugleich praktische Erfahrungen in Projektentwicklung und -management ermöglichen.

Denkanstoß: Künstliche Intelligenz – menschliches Lernen?

Unser Sammelband schließt mit einem Essay⁵ von **Ulf-Daniel Ehlers**. Ausgehend von der Frage, in welchem Verhältnis künstliche Intelligenz zu menschlichem Denken und Lernen steht, entfaltet dieser Beitrag eine ebenso kritische wie hoffnungsvolle Perspektive auf die Rolle von KI für die Gesellschaft der Zukunft. Dabei beschränkt sich Ehlers nicht auf die Technikfolgenabschätzung im Bildungssektor, sondern entwickelt ein Plädoyer für menschliche Verantwortung im Umgang mit dem disruptiven Potenzial der künstlichen Intelligenz, das von Kunst bis Politik unterschiedliche Bereiche unserer Gesellschaft umspannt.

5 Da es sich bei diesem Text nicht um einen wissenschaftlichen Aufsatz im strengeren Sinne, sondern um einen Denkanstoß handelt, ist dieser Beitrag der einzige im vorliegenden Sammelband, der keinem Peer-Review-Verfahren unterzogen wurde.

Literatur

- Adekitan, A. I. & Noma-Osaghae, E. (2019). Data mining approach to predicting the performance of first year student in a university using the admission requirements. *Education and Information Technologies*, (24, S. 1527–1543).
- Alexander, B., Ashford-Rowe, K., Barajas-Murphy, N., Dobbin, G., Knott, J., McCormack, M., Pomerantz, J., Seilhamer, R. & Weber, N. (eds.) (2019). *EDUCAUSE Horizon Report: 2019 Higher Education Edition*. Louisville, CO: EDUCAUSE.
- Bates, T., Cobo, C., Mariño, O., & Wheeler, S. (2020). Can Artificial Intelligence Transform Higher Education? *International Journal of Educational Technology in Higher Education*, (17(42), S. 1–12).
- Behr, A., Giese, M., Teguin, H. & Theune, K. (2021). Motives for dropping out from higher education—An analysis of bachelor's degree students in Germany. *European Journal of Education* (56, S. 325–343).
- Büching, C., Mah, D.-K., Otto, S., Paulicke, P., & Hartman, E. (2019). Learning Analytics an Hochschulen. In V. Wittpahl (Hg.), *Künstliche Intelligenz: Technologie, Anwendung, Gesellschaft* (S. 142–160). Berlin, Heidelberg: Springer VS.
- Buckingham Shum, S. & McKay, T. A. (2018). Architecting for learning analytics. Innovating for sustainable impact. *EDUCAUSE Review*, (53(2), S. 25–37).
- Bundesanzeiger (BAnZ), Amtlicher Teil (AT). (23.12.2020). Bund-Länder-Vereinbarung gemäß Artikel 91b Absatz 1 des Grundgesetzes über die Förderinitiative »Künstliche Intelligenz in der Hochschulbildung« vom 10. Dezember 2020. B8. https://www.gwk-bonn.de/fileadmin/Redaktion/Dokumente/Papers/BLV_KI_in_der_Hochschulbildung.pdf
- Bundesministerium für Bildung und Forschung (2021). Bekanntmachung. Richtlinie zur Bund-Länder-Initiative zur Förderung der Künstlichen Intelligenz in der Hochschulbildung. <https://www.bmbf.de/foerderungen/bekanntmachung-3409.html>.
- Castañeda, L. & Selwyn, N. (2018). More than tools? Making sense of the ongoing digitizations of higher education. *International Journal of Educational Technology in Higher Education*, (15, S. 1–10).
- DAAD (2021). *Corona und die Folgen für die internationale Studierendenmobilität in Deutschland Ergebnisse der zweiten DAAD-Befragung von International Offices und Akademischen Auslandsämtern im Wintersemester 2020/21*. https://static.daad.de/media/daad_de/pdfs_nicht_barrierefrei/der-daad/analysen-studien/corona_a_p_final_dt.pdf
- de Witt, C., Rampelt, F., & Pinkwart, N. (2020). *Künstliche Intelligenz in der Hochschulbildung. Whitepaper*.
- Dreesen, P. & Bubenhofer, N. (2020). Das Konzept »Übersetzen« in der digitalen Transformation. *Germanistik in der Schweiz (GiS)* 16, 26–49.

- Gierdowski, D. C., Brooks, C., & Galanek, J. D. (2020). *EDUCAUSE 2020 Student Technology Report: Supporting the Whole Student*. Research Report. Louisville, CO: EDUCAUSE.
- Glick, D., Cohen, A., Festinger, E., Xu, D., Li, Q. & Warschauer, M. (2019). Predicting success, preventing failure. In D. Ifenthaler, D.-K. Mah & J. Y.-K. Yau (Eds.), *Utilizing learning analytics to support study success* (S. 249–273). Cham: Springer.
- Heublein, U., & Schmelzer, R. (2018). Die Entwicklung der Studienabbruchquoten an den deutschen Hochschulen: Berechnungen auf Basis des Absolventenjahrgangs 2016. Deutsches Zentrum für Hochschul- und Wissenschaftsforschung. <https://idw-online.de/en/attach-mentdata66127.pdf>.
- Hinkelmann, M. & Jordine, T. (2019). The LAPS project: using machine learning techniques for early student support. In D. Ifenthaler, J. Y.-K. Yau & D.-K. Mah (Eds.), *Utilizing learning analytics to support study success* (S. 105–117). Cham: Springer.
- Hwang, G.-J., Xie, H., Wah, B. W., & Gašević, D. (2020). Vision, Challenges, Roles and Research Issues of Artificial Intelligence in Education. *Computers and Education: Artificial Intelligence*, (1 2020, 100001, S. 1–5).
- Ifenthaler, D., Gibson, D. C. & Dobozy, E. (2018). Informing learning design through analytics: Applying network graph analysis. *Australasian Journal of Educational Technology*, (34(2), S. 117–132.
- Jones, K. M. L. (2019). Advising the whole student: eAdvising analytics and the contextual suppression of advisor values. *Education and Information Technologies*, (24, S. 437–458).
- Keim, D., & Sattler, K.-U. (2020). Von Daten zu KI – Intelligentes Datenmanagement als Basis für Data Science und den Einsatz Lernender Systeme. Plattform Lernende Systeme. https://www.plattform-lernende-systeme.de/files/Downloads/Publikationen/AG1Whitepa-per_Von_Daten_zu_KI.pdf.
- Khare, K., Stewart, B., & Khare, A. (2018). Artificial Intelligence and the Student Experience: An Institutional Perspective. *Journal of Education*, (6(3), S. 63–78).
- Kieslich, K., Lünich, M., Marcinkowski, F., & Starke, C. (2019). Hochschule der Zukunft: Einstellungen von Studierenden gegenüber Künstlicher Intelligenz an der Hochschule. Institute for Internet und Democracy. https://diid.hhu.de/wp-content/uploads/2019/10/DIID-Precis_Kieslich-et-al_Fin.pdf.
- Klutka, J., et al. (2018). Artificial Intelligence in Higher Education: Current Uses and Future Applications. Louisville: Learning house.
- Köchling, A., Wehner, M.C. (2020). Discriminated by an algorithm: a systematic review of discrimination and fairness by algorithmic decision-making in the context of HR recruitment and HR development. *Bus Res* 13, 795–848.
- Kötting, R. (2020). Bund und Länder stärken die Förderung von Künstlicher Intelligenz. *Gemeinsame Wissenschaftskonferenz (GWK). Informationsdienst Wissenschaft*. <https://idw-online.de/de/news757882>.

- Lockyer, L., Heathcote, E. & Dawson, S. (2013). Informing Pedagogical Action. *American Behavioral Scientist*, 57(10), 1439–1459.
- Ma, Y. & Siau, K. L. (2018). Artificial Intelligence Impacts on Higher Education. *MWAIS Proceedings*, 42(5). <https://aisel.aisnet.org/mwais2018/42>.
- McCarthy, J., Minsky M. L., Rochester, N. & Shannon, C. E. (1955). *A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence*. <http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf>.
- Morgan, M. (2013). The Student Experience Practitioner Model. In M. Morgan (Ed.), *Improving the student experience: A practical guide for universities and colleges*, (S. 69–88).
- Morgan, M. (2018). *What is the SEPT Model? Improving the student experience in higher education: Support and advice for staff*. <http://www.improvingthestudentexperience.com/student-practitioner-model/what-isSET/>.
- Obari, H., & Lambacher, S. (2019). Improving the English Skills of Native Japanese Using Artificial Intelligence in a Blended Learning Program. *EUROCALL 2019*. <https://eric.ed.gov/?id=ED600973>.
- Paal, B. P. & Wais, N. (2022). Leipziger Ausbildungsprogramm für Digitalisierung und Recht. In: Mah, D.-K. & Toner, C. (Hg.) (2022). *Künstliche Intelligenz mit offenen Lernangeboten an Hochschulen lehren. Erfahrungen und Erkenntnisse aus dem Fellowship-Programm des KI-Campus*. Berlin: KI-Campus, S. 93–99.
- Pelletier, K., Brown, M., Brooks, D. C., McCormack, M., Reeves, J. & Arbino, N. (2021). *2021 EDUCAUSE Horizon Report, Teaching and Learning Edition*. Louisville, CO: EDUCAUSE.
- Pelletier, K., McCormack, M., Reeves, J., Jenay, R., Arbino, N. (2022). *2022 EDUCAUSE Horizon Report, Teaching and Learning Edition*. Louisville, CO: EDUCAUSE.
- Rajpurkar, P., Chen, E., Banerjee, O. et al. (2022). AI in health and medicine. *Nat Med* 28, 31–38.
- Russell, J., Smith, A. & Larsen, R. (2020). Elements of Success: Supporting at-risk student resilience through learning analytics. *Computers & Education*, (152).
- Russell, J., Hodge, S. R., Frank, A. M. & Vaughn, M. (2019) Academic Administrators' Beliefs About Diversity, *Quest*, (71(1), S. 66–89).
- Schmid, U., Blanc, B. & Toepel, M. (2021). *KI@Bildung: Lehren und Lernen in der Schule mit Werkzeugen Künstlicher Intelligenz. Schlussbericht im Auftrag der Deutschen Telekom Stiftung*. Berlin, Essen, Bonn: mmb Institut.
- Schulmeister, R. (2007). Der »Student Lifecycle« als Organisationsprinzip für E-Learning. In Keil, R., Michael, K., Schulmeister, R. (Hg.). *eUniversity – Update Bologna. Education Quality Forum 2006*. Münster: Waxmann, S. 229–261.
- Schumacher, C. & Ifenthaler, D. (2018). The importance of students' motivational dispositions for designing learning analytics. *Journal of Computing in Higher Education*, (30(3), S. 599–619).

- Schumacher, C. & Ifenthaler, D. (2021). Investigating prompts for supporting students' self-regulation – A remaining challenge for learning analytics approaches? *The Internet and Higher Education*, (49(100791)).
- Selznick B. S. & Titareva T. N. (2022). Postsecondary Administrative Leadership and Educational AI: An Ethical Shared Approach. In F. Almaraz Menéndez et al. (Hg.): *Strategy, Policy, Practice, and Governance for AI in Higher Education Institutions*, (S. 73–100). Hershey, Pennsylvania, USA.: IGI. Global.
- Selwyn, N., Hillman, T., Eynon, R., Ferreira, G., Knox, J., Macgilchrist, F., & Sancho-Gil, J. M. (2020). What's next for Ed-Tech? Critical Hopes and Concerns for the 2020s. *Learning, Media and Technology*, (45(1), S. 1–6).
- Shirouzou, H. (2018). How AI is Helping to Transform Education in Japan, IBM Client Success Field Notes. IBM. <https://www.ibm.com/blogs/client-voices/how-ai-is-helping-transform-education-in-japan/>.
- Somasundaram, M., Latha, P. & Pandian, S. S. (2020). Curriculum Design Using Artificial Intelligence (AI) Back Propagation Method. *Procedia Computer Science*, 172, 134–138.
- Statistisches Bundesamt (2022). Studienanfänger nach Semester, Nationalität und Geschlecht im Zeitvergleich. GENESIS-Online. <https://www-genesis.destatis.de/genesis/online?sequenz=tabelleErgebnis&selectionname=21311-0010#abreadcrumb>.
- Tuomi, I. (2018). The Impact of Artificial Intelligence on Learning, Teaching, and Education. Policies for the Future. *European Comission. JRC Science for Policy Report*.
- Ulrich, I., & Heckmann, C. (2017). Taxonomien hochschuldidaktischer Designs und Methoden aus pädagogisch-psychologischer Sicht samt Musterbeispielen aus der aktuellen Forschung. die hochschullehre. <http://www.hochschullehre.org/?p=951>.
- Wannemacher, K., & Bodmann, L. (2021). *Künstliche Intelligenz an den Hochschulen – Potenziale und Herausforderungen in Forschung, Studium und Lehre sowie Curriculumentwicklung. Hochschulforum Digitalisierung (Arbeitspapier Nr. 59, 2021)*. Berlin: Hochschul-forum Digitalisierung.
- Watanabe, A. (2021). Künstliche Intelligenz in der Hochschullehre. Eine explorative Interviewstudie zu Akzeptanzfaktoren aus Studierendenperspektive. Masterarbeit, Universität Hamburg.
- Watanabe, A. (2022). Let's Talk about Artificial Intelligence. How Scholarship of Teaching and Learning Can Enhance the AI Scientific Discourse in Higher Education. In F. Almaraz Menéndez et al. (Hg.): *Strategy, Policy, Practice, and Governance for AI in Higher Education Institutions*, (S. 48–72). Hershey, Pennsylvania, USA: IGI. Global.
- Wissenschaftsrat (2017). Strategien für die Hochschullehre. Positionspapier, (Drs. 6190–17). <https://www.wissenschaftsrat.de/download/archiv/6190-17.html>.

Zawacki-Richter, O., Marín, V., Bond, M., & Gouverneur, F. (2019). Systematic Review of Research on Artificial Intelligence Applications in Higher Education – Where Are the Educators? *International Journal of Educational Technology in Higher Education*, (16, S. 1–27).

Learning Analytics in Hochschulen und Künstliche Intelligenz

Eine Übersicht über Einsatzmöglichkeiten, erste Erfahrungen
und Entwicklungen von KI-Anwendungen zur Unterstützung
des Lernens und Lehrens

Sandra Schön, Philipp Leitner, Jakob Lindner und Martin Ebner

Abstract: »Learning Analytics« ist die Interpretation von Daten, um individuelle Lernprozesse gezielt zu verbessern (Ebner et al., 2013; Greller & Drachsler, 2012). Learning-Analytics-Anwendungen geben dabei Empfehlungen, damit Lernende ihr Lernverhalten oder Lehrende das didaktische Setting bzw. die Lehr- und Lernsituation verbessern können. Der Beitrag führt zunächst in Learning Analytics in der Hochschulbildung ein, um dann auf Einsätze von Künstlicher Intelligenz (KI) in der Hochschule überzuführen und Überschneidungen zu identifizieren. Dabei werden vier internationale Beispiele im Themenfeld referiert und vorgestellt (Literatur-/Projektrecherche). Der Beitrag schließt mit einem Ausblick auf Potentiale und Herausforderungen für KI für Learning Analytics in Hochschulen (u.a. Buckingham Shum & Luckin, 2019).

»Learning analytics« is the interpretation of data in order to improve individual learning processes in a targeted manner (Ebner et al., 2013; Greller & Drachsler, 2012). Learning analytics applications provide recommendations so that learners can improve their learning behaviour or teachers can improve the teaching and learning situation and setting. The article first introduces learning analytics in higher education, then moves on to the use of artificial intelligence (AI) in higher education and identifies overlaps. Four international examples in the field are presented (literature/project research). The article concludes with an outlook on potentials and challenges for AI for learning analytics in higher education (e. g. Buckingham Shum & Luckin, 2019).

Keywords: Learning Analytics, Künstliche Intelligenz, Hochschullehre / Learning Analytics, Artificial Intelligence, Higher Education.

Learning Analytics in Hochschulen und Künstliche Intelligenz

Video: <https://link.transcript-open.de/5769/video/002>

© Martin Ebner



1 Einleitung

Durch die zunehmende Nutzung von Informationssystemen beim Lernen und die entsprechende Verwaltung von Lernenden fallen viele Daten an, die eine Basis für Informationen und Anwendungen geben können, um das Lernen und die Lehre an Hochschulen zu verbessern. Solche Datenanalysen, -interpretationen und -anwendungen zur Unterstützung individueller Lernprozesse werden dem Bereich von »Learning Analytics« (LA) zugeordnet (Ebner et al., 2013; Greller & Drachsler, 2012). In den letzten zehn Jahren hat LA als ein schnell wachsendes und vielversprechendes Forschungsfeld im Bereich des technologiegestützten Lernens immer mehr Aufmerksamkeit erhalten (Ferguson, 2012; Khalil & Ebner, 2015). Seit der ersten Erwähnung als bedeutsame Zukunftstechnologie im Horizon-Bericht von 2012 (Johnson et al., 2012), wurden verschiedene Instrumente eingesetzt und Initiativen durchgeführt. Damit scheint LA nun an dem Punkt angelangt, an dem es Forschung und Praxis, aber auch Politik- und Entscheidungsfindung beeinflussen wird (Gašević, Dawson & Siemens, 2015). Durch die Möglichkeiten und Verbreitung der sog. »Künstlichen Intelligenz« (KI) erweitern sich insbesondere die Analyseverfahren und Anwendungen von LA.

Inwieweit bei der Datenanalyse und -interpretation Anwendungen der KI im Bereich von Learning Analytics im Kontext der Hochschulen und der Hochschullehre eingesetzt werden, möchten wir in diesem Beitrag genauer unter die Lupe nehmen. Forschungsleitend sind dabei folgende Fragen: (a) Wie wird derzeit Learning Analytics (LA) an Hochschulen verstanden und umgesetzt, was sind also die Rahmenbedingungen für den Einsatz von Künstlicher Intelligenz (KI)? (b) Welche Beispiele für den Einsatz von KI-Verfahren im Rahmen von LA gibt es bereits? (c) Welche Herausforderungen lassen sich aus dem Einsatz von KI in LA ableiten?

Dieser Beitrag basiert dabei auf eigenen Vorarbeiten rund um LA (u.a. Schön & Ebner, 2013; Ebner, Neuhold & Schön, 2013; Leitner, Khalil & Ebner, 2017; Leitner et al., 2019, Ebner, 2019). Zudem haben wir für diesen Beitrag eine Literaturrecherche zu LA und KI in der Hochschullehre durchgeführt. Dazu wurden alle Beiträge mit Erscheinungsjahr 2018 und jünger in der ERIC Datenbank sowie bei Google Scholar zu den Stichworten »Higher Education« und »Artificial Intelligence« und »Learning Analytics« danach ausgewertet, ob darin konkrete Anwendungen beschrieben werden und vier Beispiele für diesen Beitrag ausgewählt. Die abschließende Zusammenstellung von Herausforderungen der Nutzung von KI bei LA beruht dabei auf einem Abgleich entsprechender Beiträge und persönlicher Perspektive und wird daher auch als Diskussionsgrundlage vorgeschlagen.

2 Learning Analytics an Hochschulen: Verständnis und Prozesse

In diesem Abschnitt führen wir in Learning Analytics (LA) an Hochschulen ein und beschreiben dabei unterschiedliche Verständnisse, verwandte Zugänge, konkrete Beispiele aus dem Hochschulkontext und nennen problematische und herausfordernde Aspekte von LA.

2.1 Verständnis von Learning Analytics und Verfahren

Es werden derzeit verschiedene Definitionen für den Begriff »Learning Analytics« verwendet (Leitner, Ebner & Ebner, 2019). Bei der ersten Konferenz zu Learning Analytics (»International Conference on Learning Analytics and Knowledge«, kurz LAK, 2011; s. Long & Siemens, 2011) wurde Learning Analytics als »die Messung, Sammlung, Analyse und Berichterstattung von Daten über Lernende und ihre Kontexte zum Zweck des Verständnisses und der Optimierung des Lernens und des Umfelds, in dem es stattfindet« bezeichnet (eigene Übersetzung). Duval (2012) fasste LA mit den Worten zusammen: »Bei Learning Analytics geht es darum, Spuren zu sammeln, die Lernende hinterlassen, und diese Spuren zur Verbesserung des Lernens zu nutzen« (eigene Übersetzung). LA sollte immer handlungsrelevante Erkenntnisse liefern (Siemens et al., 2011). Schön und Ebner (2013) definieren LA als: »Learning Analytics ist die Interpretation von lernerspezifischen Daten, um individuelle Lernprozesse gezielt zu verbessern« (Abschnitt 3). Für (österreichische) Hochschulen wurde LA folgendermaßen definiert (Leitner et al., 2019, S. 8): »Learning Analytics umfasst die Analyse, Darstellung und Interpretation von Daten aus Lehr- und Lernsettings mit dem Zweck, dass Lernende ihr Lernen unmittelbar verändern können.«

Bei Anwendungen von Learning Analytics gibt mehrere Stakeholder und Perspektiven (s. Leitner et al., 2019, S. 9): Lernende, im Kontext dieses Beitrags sind das


Studierende, verwenden LA-Anwendungen, um Einblicke in das eigenen Lernverhalten zu erhalten und gegebenenfalls Rückmeldungen oder auch Empfehlungen zu erhalten. Lehrende sind daran interessiert, mit Hilfe von LA-Anwendungen die Studierenden beim Lernen zu unterstützen. Aggregierte Lerner/innen-Daten helfen hier, das eigene Lehrverhalten bzw. die Ressourcen und das didaktische Design ggf. zu verbessern. Mittelbar werden LA-Anwendungen auch von Wissenschaftler/innen genutzt, um Einsichten zum Lernen und Lernverhalten zu erhalten.

Das Ziel, das Lernen zu unterstützen, kann mit Hilfe unterschiedlicher Analyseverfahren erfolgen. Nach Grandl et al. (2017) haben Learning-Analytics-Maßnahmen die Zielsetzungen Lernverhalten und -erfolge vorherzusagen, um ggf. einzugreifen, Empfehlungen zu geben, den Lernprozess zu personalisieren, die Reflexion des bisherigen Lernverhaltens anzuregen und auch mit anderen zu vergleichen. Bei LA-Analysen kommen dabei unterschiedliche Methoden zum Einsatz (s.a. Grandl et al., 2017, Calvet & Perez, 2015): u.a. statistische Analysen, Visualisierungen, Analyse von Zusammenhängen, Mustererkennung, Identifizierung von Ausreißern und Abweichungen, soziale Netzwerkanalyse, Vorhersagen, Verlaufsanalysen, Textanalysen und Knowledge Tracing. Die Zielrichtung der Analyse ist dabei unterschiedlich. Manchmal steht eine rückblickende Analyse der Lernaktivitäten im Vordergrund. Andere Verfahren versuchen Aussagen über zukünftige Entwicklungen zu geben, sind also prognostische Verfahren. LA-Einsätze an Hochschulen sollten jedoch immer das Lernen von Studierenden möglichst unmittelbar unterstützen, auch wenn es Komponenten der Bewertung und des Controllings hat (Ebner et al., 2015): Es ist wichtig, dass jede/r Lernende über seinen aktuellen Stand im Lernprozess informiert ist und weiß, wie sie/er ihn anhand der verfügbaren Daten verbessern kann.

2.2 Abgrenzungen zu verwandten Zugängen

LA setzt sich mit der definierten Unterstützung von Lerner/inne/n von verwandten Forschungsgruppen und -zugängen ab, die auch Daten von Lernenden nutzen (s. Abb. 1). So versucht das sog. »Educational Data Mining« (EDM) allgemein Muster in Daten zu erkennen, die (neue) Einsichten zum Lernen ermöglichen könnten, z.B. Lernprozesse identifizieren und besser verstehen lassen. Es gibt wohl Überschneidungen der Arbeitsgebiete von LA und EDM (Siemens & Baker, 2012): Beides sind datenintensive Ansätze und sie verwenden ähnliche Methoden (Ebner et al., 2013). Im Unterschied zum EDM unterstützt LA in jedem Fall aber gezielt und konkret das Lernen und gibt Rückmeldung an Lernende. Im Rahmen von LA werden so Anwendungen entwickelt, in denen Studierende gut nachvollziehen können, welche Leistungen und Aktivitäten sie bereits für einen Lehrgang oder ihr Studium erbracht haben und welche noch offen sind (z.B. de Laet et al., 2018).

Abbildung 1: Zielgruppen und Zwecke der Nutzung von Daten von Lernenden aus Perspektive von Learning Analytics, Educational Data Mining, Academic Analytics sowie Higher Level Analytics an Hochschulen (eigene Darstellung).



LA ist auch von »Academic Analytics« abzugrenzen, bei der es sich um Datenanalysen zur Verbesserung des administrativen und organisatorischen Ablaufes der Universität dreht, beispielsweise Darstellung von Prüfungsaktivitäten oder Prüfungserfolgen innerhalb einer Studierendenkohorte (Leitner et al., 2019). Auf noch abstrakter Ebene sind sog. »High Level Analytics« zu verorten, worunter Analysen fallen, die generell für die Hochschulentwicklung notwendig sind und die primär administrativer und organisatorischer Natur sind, z.B. Datenanalysen für Hochschulrankings und Wissensbilanzen (Ferguson 2014, Leitner et al., 2019).


Abbildung 1 gibt einen Überblick über die hier abgegrenzten Formen, Zielgruppen und Zwecke der Nutzung von Lerner/innen-Daten an Hochschulen.

2.3 Beispiele für und Stand von Learning Analytics an Hochschulen

Ein einfaches Beispiel für eine Variante einer LA-Anwendung ist der Einsatz von einem Audience-Response-System in einer Massenlehrveranstaltung (s. Ebner et al., 2014): Der Lehrende bittet die Anwesenden um die Beantwortung einer Frage mit mehreren Antwortoptionen, die Studierenden beantworten sie mit Hilfe ihrer mobilen Endgeräte. Zum einen sehen die Studierenden durch eine entsprechende Datenvisualisierung prompt, ob sie den Stoff bereits erfasst haben, hören ggf. entsprechend aufmerksam den Erläuterungen zu, wenn dies nicht der Fall ist. Der Lehrende kann auch eine hohe Fehlerquote zum Anlass nehmen, das bereits Präsentierte noch einmal anhand eines weiteren Beispiels zu erklären.

Anders als in diesem einfachen Beispiel sollten LA-Anwendungen Studierenden dauerhaft zur Verfügung stehen. Sie sind deshalb häufig in Lernmanagementsystemen implementiert (vgl. Schwendimann et al., 2017). Ein Beispiel für eine solche Implementation ist in Abbildung 2 zu sehen: ein Dashboard für Studierende, das im Rahmen eines Forschungsvorhabens als Moodle-Plug-In entwickelt und aktuell in einer Lehrveranstaltung der Wirtschaftspädagogik an der Universität Graz erprobt wird. Die Aktivitäten im Lernmanagementsystem werden so dargestellt, dass die Studierenden zum einen ihre bisherigen Aktivitäten und Punktestand visualisiert bekommen, auch im Vergleich zu ihren Kommilitonen. Zum anderen dient die Timeline als Planungshilfe, es zeigt alle wichtigen (Lern-)Aktivitäten der Lehrveranstaltung und kann durch eigene Marker ergänzt werden. (Lipp et al., 2021)

Abbildung 2: Lernenden-Dashboard der Universität Graz, Prototyp entwickelt und eingesetzt im Rahmen des Projekts »Learning Analytics: Auswirkungen von Datenanalysen auf den Lernerfolg« (Lipp et al., 2021).




LA-Anwendungen werden auch häufig in MOOC-Plattformen implementiert, auch weil sich dort viele selbstgesteuerte Lerner/innen finden. Die Online-Kurs-Plattform iMooX.at hat sich so auf die Durchführung von offenen lizenzierten Online-Kursen für Viele (sog. Massive Open Online Courses, kurz MOOC) spezialisiert (McAuley et al., 2010; Ebner et al., 2016). Genutzt wird dazu das Lernmanagementsystem Moodle mit etlichen Anpassungen und Erweiterungen. Dazu gehören auch die Entwicklung und Erprobung von LA-Anwendungen. So wurde beispielsweise ein motivationssteigerndes Tool für die Kursteilnehmer/innen entwickelt, die *Gamify-Bat*. Dieses Tool basiert auf der Vorarbeit von Khalil und Ebner (2017) und hat zum

Ziel unerfüllte Aufgaben innerhalb des Kurses zu verfolgen und den Kursteilnehmer/innen durch den Einsatz eines Gamification-Elements entsprechend zu visualisieren und damit zu motivieren, sowie letztendlich das Verhalten zu beeinflussen und das Engagement zu erhöhen.


Ebenso wurde ein hochgradig konfigurierbares und interaktives Dashboard, das *LA Cockpit* entwickelt, um Manager/innen, Forscher/innen und vor allem Kursleiter/innen bei der Auswertung des Engagements und der Beteiligung von Kursteilnehmer/innen innerhalb eines MOOCs zu unterstützen (Leitner, Maier & Ebner, 2020). Darüber hinaus soll der Vergleich der individuellen Aktivität der Lernenden mit den kursweiten Durchschnittswerten die Selbsteinschätzung der Kursteilnehmer/innen verbessern, sie zur Teilnahme motivieren und die Abschlussraten erhöhen. Abbildung 3 zeigt das LA-Cockpit der iMooX-Plattform.

Abbildung 3: LA Cockpit (LA Cockpit der MOOC-Plattform iMooX.at der TU Graz).



An der TU Graz gibt es seit Dezember 2020 für alle Studierende von BA-Studiengängen ein Studiendashboard, das Informationen zum Lernen auf dem Level von Lehrveranstaltungen anbietet. Das Dashboard wurde dabei auf Wunsch und gemeinsam mit Studierenden entwickelt, die auch die einzigen sind die Informationen und Visualisierungen einsehen können (s. Leitner et al., 2021). Wie in Abbildung 4 gezeigt, erhalten Studierende einen Überblick über die bisherigen Lehrveranstaltungsabschlüsse, auch im Vergleich zu den anderen Studierenden und erhalten Einblicke in die Notenverteilung bei den noch zu belegenden Lehrveranstaltungen.

Abbildung 4: Studiendashboard der TU Graz (TU Graz, 2021).



In welchem Ausmaß LA-Anwendungen in Hochschulen täglich zum Einsatz kommen, ist schwierig zu bestimmen, auch weil es davon abhängt wie komplex eine LA-Anwendung ist bzw. was als LA-Service interpretiert wird und auch selten Daten zur Nutzung vorliegen. So bieten viele Lernmanagementsysteme einzelne (kleine) Anwendungen, die Lernendendaten visualisieren und könnten theoretisch in vielen Lehrveranstaltungen genutzt werden. Wir teilen jedoch die Einschätzung von Ifenthaler und Drachsler (2018), dass die praktische, vor allem auch flächendeckende Anwendung von LA an Hochschulen noch in den Kinderschuhen steckt.

2.4 Argumente für LA in Hochschulen

Die Arbeitsgruppe zu LA des Forum Neue Medien in der Lehre Austria (Leitner et al., 2019, S. 4) sieht sechs Argumente für LA und Möglichkeiten der Verbesserung der Lehre: 1. Verbesserung der Lehr- und Lernqualität, 2. besseres Verständnis für

Lehr- und Lernprozesse, 3. Erhöhung des Studienerfolgs, Verminderung der Drop-out-Rate und gezielte Unterstützung von Inklusion, 4. Verbesserung der Transparenz und der Prüfungsaktivität, 5. wissenschaftliche Nutzung und Sensibilisierung, 6. Optimierung von Prozessen der außercurricularen Studienberatung und Studienbegleitung. Auch Slater, Peasgood und Mullan (2016) beschreiben in einer Fallstudienanalyse für JISC weitreichende Chancen von LA-Anwendungen in der Hochschule. Sie sehen LA demnach als eine Maßnahme zur Qualitätssicherung und -verbesserung, für höhere Verbleibraten und als eine Möglichkeit mit unterschiedlichen Ergebnissen bei Studierenden umzugehen. Sie sehen LA zudem als Ermöglicher für die Entwicklung und Einführung von adaptiven Lernsystemen. Auch der Trendstudie zur Hochschulbildung im Jahr 2030 zufolge (Orr et al., 2020) werden offene Systeme für Hochschulen höhere Anforderungen daran stellen, dass Lernempfehlungen und Lernpfade für Studierende und Lehrende transparent bleiben, dazu werden LA und ähnliche Methoden empfohlen.

2.5 Herausforderung von LA in der Hochschulbildung

Ein einfaches Beispiel zeigt, dass LA-Anwendungen negativ verstärkende und damit unerwünschte Effekte haben können: Ein schlechtes Abschneiden und Vergleich mit der Kohorte können so fehlerhaft dazu führen, dass Studierende es als eigene »Unfähigkeit« oder mangelndes »Talent« interpretieren. Aus Studien zur Selbstwirksamkeit im Fach Mathematik im Schulbereich wissen wir, dass es hier signifikante Unterschiede zwischen den Geschlechtern gibt, ob schlechtes Abschneiden auf fehlendem Fleiß oder Talent zurückzuführen ist (z.B. Lloyd, Walsh & Shehni Yailagh, 2005). Bei entsprechenden Kontextinformationen und Wissen, beispielsweise dass die meisten Mitstudierenden aus anderen Schulformen kommen und entsprechendes Vorwissen mitbringen, könnte das zur Klärung und Aufrechterhalten der Studienmotivation führen. LA-Anwendungen sind also kein Selbstläufer, sondern müssen entsprechend sensibel eingeführt und betrieben werden.

Greller und Drachsler (2012, 2016) haben ein bekanntes Rahmenmodell für die Entwicklung und Einsatz von LA-Anwendungen entwickelt. Leitner, Ebner und Ebner (2019) haben darauf aufbauend Herausforderungen bei der Entwicklung von Learning-Analytics-Anwendungen im Hochschulkontext analysiert (insbesondere Ferguson et al., 2016) und fokussieren auf sieben Herausforderungen (siehe Abbildung 4): In den Mittelpunkt stellen Leitner, Ebner und Ebner (2019) Zweck und Nutzen der Learning-Analytics-Anwendung. Sie stellen dazu fest: »Die Erwartungen in Bezug auf die Verbesserung des Lernens und Lehrens sind extrem hoch, wenn über LA in der Hochschulbildung gesprochen wird. Auf institutioneller Ebene ist die Grenze zwischen LA und Academic Analytics jedoch verschwommen.« (Abschnitt 3.1, eigene Übersetzung). Einige Projekte und Vorhaben, die nicht vorrangig im Interesse von Lerner/innen stehen, werden unter der Bezeichnung »Learning Analy-

tics« geführt. Man könnte salopp sagen, hier wird unter dem positiv besetzten LA als Deckmantel agiert. Es ist daher wichtig, mit größtmöglicher Transparenz zu arbeiten (s. Leitner, Ebner & Ebner, 2019). Weitere wichtige Aspekte sind der Schutz der Privatsphäre und die Entwicklung eines klaren Vorgehens in Bezug auf gewünschte und unerwünschte Szenarien (Ethik), eine solide und fehlerfreie Datenbasis, die Infrastruktur, die Entwicklung und der Betrieb (inkl. Einschätzung absehbarer Kosten), sowie weitere Aktivitäten, z.B. Einschulungen von Betreuer/innen.

Abbildung 5: Herausforderungen von LA in der Hochschulbildung (Leitner, Ebner & Ebner, 2019, eigene Übersetzung).



Buckingham Shum (2012) verweist in einem Beitrag für die UNESCO auf eine weitere, allgemeine Herausforderung: Ihm zufolge ist die Einschätzung, dass LA auf »Fakten« beruht, da es ja auf »Daten« basiert, ein großer Irrtum: »Im Kontext der Learning Analytics ist jeder Schritt des Lebenszyklus – von den Daten über die Analyse bis hin zur Einsicht und Intervention – von **menschlichen Urteilen abhängig**. Kurz gesagt, es ist ebenso naiv zu glauben, dass »Daten für sich selbst sprechen«, wie zu glauben, dass ein Text eine einzige, objektiv erkennbare Bedeutung für alle Kontexte hat.« (S. 8). Außerdem muss es auch nicht sein, dass wir genau dort Einsichten zum Lernen mit Learning Analytics erhalten, wo wir auch Daten erfassen: Dieser Effekt wird auch »**Straßenlampeneffekt**« genannt und bezieht sich auf den Witz, in dem ein Mann seinen verlorenen Schlüssel im Schein der Straßenlampe sucht, weil es dort eben hell ist – und nicht dort, wo er den Schlüssel eigentlich vermutet (Freedman, 2010, Ochoa, 2017, S. 128).

3 Wenn KI auf LA trifft

Im diesem Abschnitt wird zunächst das aktuelle Verständnis von KI skizziert und dann Gemeinsamkeiten und Unterschiede von LA und KI beschrieben.

3.1 KI im Hochschulbereich

Der Bedeutungsinhalt des Begriffs KI ist nicht einheitlich, sondern abhängig vom fachlichen Kontext und dessen Zielvorgaben. Dies verhindert eine klare Abgrenzung. Historisch gesehen lassen sich vier inhaltlich grundsätzlich verschiedene Bedeutungen in der Verwendung erkennen: nämlich die Bezeichnung von Systemen die menschlich denken, die menschlich handeln, die rational denken und die rational handeln (Norvig & Russel, 2019). Jeder dieser Begriffe bringt spezifische Einschränkung mit sich, auf die in Norvig und Russe (2019) eingegangen wird. Die momentan dominante Bedeutung versteht unter KI solche Systeme, die »rational« handeln, also so, dass die Eintrittswahrscheinlichkeit des besten Ergebnisses maximiert wird (vgl. Norvig & Russel, 2019). Wichtige Verfahren, die bei KI-Systemen oder ihrer Entwicklung eingesetzt werden, sind automatische Sprachanalysen, Wissensrepräsentation, Automated Reasoning, Maschinenlernen, Computer Vision und Robotics. Hwang et al. (2020) adressieren mit »KI im Bildungsbereich« (auf Englisch »Artificial Intelligence in Education«, kurz AIED) den Einsatz von KI-Technologien, d.h. menschliche Intelligenz simulieren, um Schlussfolgerungen, Urteile oder Vorhersagen zu treffen und damit Lernende und Lehrende beispielsweise mit personalisierter Anleitung, Unterstützung oder Rückmeldung oder bei Entscheidungsfindungen von Lehrenden und politischen Entscheidungsträgern bei der Entscheidungsfindung zu helfen. Eine von mehreren Darstellungen ist die Unterteilung im Literaturreview von Zawacki-Richter et al. (2019) für KI-Anwendungen im Hochschulbereich nennt, der als vier Bereiche für den Einsatz von KI-Technologien für Bildungszwecke folgende vier Bereiche nennt: Profiling und Vorhersagen, Assessment und Evaluation, adaptive Systeme sowie intelligente Tutoren.

3.2 Überschneidungen und Unterschiede von KI und LA

Tabelle 1: Unterschiede des Einsatzes von KI-Technologien in der Bildung und LA-Anwendungen im Überblick.

ASPEKT	KI IM BILDUNGSBEREICH	LEARNING ANALYTICS
Verwendete Daten und Datenmodelle	Analyse der Daten von Lerner*innen, aber auch bei der Analyse von Wissensbeständen oder dem Vorgehen von Expert*innen (breiter)	Daten von Lernenden (enger)
Eingesetzte Verfahren der Datenanalyse	Methoden der Künstlichen Intelligenz (enger)	Datenanalyseverfahren und Visualisierungen aller Art (breiter)
Zweck im Bezug zur Bildung	Unterstützung von Lernenden, Lehrenden und Bildungspolitik (breiter)	Unterstützung von Lerner*innen bzw. Verbesserung des Lernens und der Lernunterstützung (enger)
Rolle der Lernenden	Lernende erhalten „optimale“ Lernpfade und Vorschläge für weitere Aufgaben und Lernaktivitäten, z. B. anhand eines Wissensmodells.	Lernende erhalten Einblicke in ihren Lernfortschritt und ggf. Empfehlungen für das weitere Vorgehen. Sie behalten dabei aber weitestgehend die Kontrolle und Übersicht über ihre Daten und Vorschläge des Systems
Rolle der Lehrenden	Insbesondere bei intelligenten Tutoren und adaptiven Lernsystemen sollen Lehrende weitestgehend entlastet bzw. ersetzt werden.	Lehrende erhalten durch LA-Anwendungen Rückmeldungen, ob und wie sie ihre Lernmaterialien, Lernumgebungen didaktisches Design oder Interventionen verbessern können.
Transparenz	Werden KI-Technologien wie maschinelles Lernen eingesetzt, ist nicht einfach (er-)klärbar, auf welcher Grundlage von Daten und Zusammenhängen Entscheidungen getroffen werden. Damit besteht auch allgemein die Gefahr eine Verstärkung aktueller, aber unerwünschter Verhältnisse (u. a. Shah, 2018)	Gerade bei der Nutzung sensibler Daten wird großen Wert auf Nachvollziehbarkeit der genutzten Daten, der Analysen und Ergebnisse gelegt.

Um deutlich darzustellen, wo Gemeinsamkeiten und Unterschiede bei dem Einsatz von KI-Technologien und LA-Anwendungen bestehen, haben wir in Tabelle 1 unterschiedliche Merkmale gegenübergestellt. Hierbei wird deutlich, dass KI im Vergleich zu LA mit einer spezifischen Auswahl an Methoden und Verfahren der Datenanalyse arbeitet. LA hingegen hat einen engeren Fokus beim Zweck, indem es sich auf die (mittelbare) Unterstützung von Lernenden bezieht. Betrachtet man die Anwendungen und Beispiele fällt auf: KI-Anwendungen sind häufig so konzipiert und beabsichtigt, dass sie Lehrende weitestgehend entlasten bzw. ersetzen

und Lernenden wenig Wahlmöglichkeiten gibt, sondern eher die »optimale« Lernunterstützung anbieten. Picciano (2019) antizipiert so sogar den drohenden Verlust des Zwecks von Hochschulen durch KI. In LA-Anwendungen sind Lerner/innen und Lehrende wichtige Entscheider/innen und nutzen die Systeme für eine reflektierte und bewusste Entscheidung für weitere (Lern-)Aktivitäten oder deren Anpassung (vgl. Jivet et al., 2020, Cukurova, 2019).

4 Beispiele für den Einsatz von KI für (mögliche) LA-Anwendungen in der Hochschulbildung

Auch wenn es naheliegend ist, das KI-Verfahren in LA im Hochschulbereich eingesetzt werden, gibt es bislang nach unseren Recherchen kaum entsprechende Beispiele. Auch vermeintlich einfache Anwendungen sind oft komplex und die derzeitige Forschung beschäftigt sich mit den Grundlagen, die notwendig sind, um robuste System praxistauglich umzusetzen und in den Hochschulalltag integrieren zu können. Alle folgenden Beiträge beschreiben ihre Verfahren explizit als der KI zugehörig und entwickeln Anwendungen, die wir LA zuordnen würden.

4.1 Beispiele für Grundlagenforschung

Die folgenden zwei Beispiele zeigen Untersuchungen und Entwicklungen, bei denen Verfahren der KI genutzt werden, um grundlegende Zusammenhänge in Daten zu erkennen, auf denen potentiell zukünftige LA-Anwendungen aufbauen können.

Tabelle 2: Überblick über das Beispiel »Der Klang der Unaufmerksamkeit« (Gliser et al., 2020).

DER KLANG DER UNAUFMERKSAMKEIT (GLISER ET AL., 2020)	
Hochschule	University of Waterloo u.a. (USA)
Status	Grundlagen für LA-Anwendungen
Einsatz von KI	Automatische Analyse der Sprachaufzeichnungen und Korrelationen
LA-Anwendung	(potentiell) Einsatz für Echtzeitfeedback-System für Vortragende

Gliser et al. (2020, siehe Tabelle 2) untersuchen so, inwieweit akustische Merkmale in Vorträgen – Höhen, Pausen, Lautstärke – sich auf die Fokussierung der Zuhörer/innen auswirkt und welche Merkmale ein Abschweifen ihrer Gedanken be-

einflussen. Dazu haben 76 Zuhörer/innen während eines Vortrags ein Protokoll zu ihrem »Gedankenschweifen« verfasst, das mit den akustischen Profilen verglichen wurde. Hohe statistische Korrelationen zwischen dem protokollierten Abschweifen der Gedanken bei den Zuhörer/inne/n und den akustischen Merkmalen des Vortrags sollen solche Merkmale identifizieren, die hilfreich sind, um sie in zukünftigen Echtzeit-Feedback-Systemen für Vortragende zu verwenden (S. 212).

Tabelle 3: Überblick über das Beispiel Fehlerkorrektur beim Programmierenlernen mit MACER (Chhatbar, Ahmed & Kar, 2020).

MÖGLICHE HINWEISGEBUNG ZUR FEHLERKORREKTUR BEIM PROGRAMMIEREN FÜR STUDIERENDE	
Hochschule	National University of Singapore, Indian Institute of Technology Kanpur
Status	Funktionstüchtiger Ansatz
Einsatz von KI	Hierarchische Klassifizierung
LA-Anwendung	Anwendung zur Unterstützung von Fehlerkorrekturen beim Programmierenlernen

Chhatbar, Ahmed und Kar (2020, siehe Tabelle 3) stellen MACER vor, »A Modular Framework for Accelerated Compilation Error Repair«. Die Hinweise von MACER dienen als Ergänzung zu den eigentlichen Kompilierfehler-Nachrichten und ermöglichen besonders Programmieranfänger/inne/n das schnelle Erkennen und Ausbessern von Fehlern. So soll das Lernen verbessert werden.

4.2 Beispiele zur Verbesserung von LA-Services

Die folgenden zwei Beispiele sind Forschungsarbeiten, die dazu führen (könnten), dass vorhandene LA-Anwendungen mit Hilfe der Beiträge besseren Service bieten.

Tabelle 4: Überblick über das Beispiel »Automatische Fragenbeantwortung zur Lehrunterstützung in Online-Kursen« (Zylich et al., 2020).

AUTOMATISCHE FRAGENBEANTWORTUNG ZUR LEHRUNTERSTÜTZUNG IN ONLINE-KURSEN	
Hochschule	University of Massachusetts (USA)
Status	Funktionstüchtiger Ansatz
Einsatz von KI	Analysen von vorhanden Fragen und Diskussion in Online-Kursen, u.a. mit Natural Language Processing
LA-Anwendung	Virtueller Lehrassistent für Online-Kurse

Zylich et al. (2020, s. Tabelle 4) erproben einen neuen Ansatz zur automatischen Beantwortung von organisatorischen Fragen von Studierenden in Online-Kursen. Studierende sollen damit schnell die benötigten Antworten erhalten und Lehrende sollen dadurch mehr Zeit für jene Fragen aufwenden können, die komplizierter sind. Der vorgeschlagene (aber kompliziert in der Kürze darzustellende) Ansatz zur automatischen Beantwortung von organisatorischen Fragen erzielt bessere Ergebnisse als bisherige Ansätze. Das gewonnene Wissen könnte helfen bessere virtuelle Lehrassistenten-Services zu entwickeln und den Weg zur automatisierten Beantwortung von allgemeinen Fragen zu ebnen.

Tabelle 5: Überblick über das Beispiel »Notenbezogene Kursempfehlung« der University of Minnesota (Morsy & Karypis, 2019).

NOTENBEZOGENE KURSEMPFEHLUNG	
Hochschule	University of Minnesota, USA
Status	Funktionstüchtiger Ansatz
Einsatz von KI	Neuronale Netzwerkanalyse
LA-Anwendung	Studierenden werden Lehrveranstaltungen vorgeschlagen, für die ihnen die besten Noten prognostiziert werden.

Morsy und Karypis (2019, siehe Tabelle 5) nutzen die Daten der Studierenden der Universität Minnesota und neuronale Netzwerkanalysen um Studierenden Kursempfehlungen zu geben, die solche Kurse empfehlen, bei denen für die Studierenden aufgrund ihrer Vorleistungen die besten Noten prognostiziert werden. Das Sys-

tem unterstützt damit Lernende, priorisiert aber den Abschluss des Studiums vor dem Wissenserwerb. Dennoch sollte von diesem Ansatz Studierende als auch Hochschulen profitieren, da auf beiden Seiten Zeit und Kosten gespart werden könnten.

5 Herausforderungen des Einsatzes von KI in LA in Bezug auf Transparenz, Nachvollziehbarkeit und Datenschutz

Die vier Beispiele zeigen, dass KI-Technologien gut bei der Entwicklung und dem Einsatz von LA-Anwendungen genutzt werden können. Durch den Einsatz von KI-Verfahren, insbesondere bei der Datenanalyse, aber auch bei der Darstellung von möglichen Handlungsoptionen (z.B. bei adaptiven Lernsysteme) für LA ergeben sich neue Möglichkeiten und Einsichten, aber auch Herausforderungen. Auf diese möchten wir abschließend eingehen und sehen diesem Abschnitt als Diskussionsgrundlage für weitere Beiträge, die die Problematik auch empirisch aufzeigen bzw. bewerten können.

Der wichtigste Kritikpunkt bezieht sich dabei auf die geringe bzw. fehlende **Transparenz**: Auf welcher Grundlage Vorschläge und Rückmeldungen beruhen, ist bei der Nutzung von KI-Verfahren (noch) schwieriger oder gar nicht mehr möglich nachzuvollziehen und zu erklären, v.a. bei Verfahren, die sich auch dynamisch weiterentwickeln (»lernen«). Die bei LA geforderte Transparenz zu schaffen, ist beim Einsatz von KI oft schlichtweg nicht möglich. Besonders frappierend wird dies in Settings, bei denen Studierende LA-Anwendungen nutzen können ohne entsprechende Informationen und Beratungen zu erhalten.

Eine markante und deutliche Kritik an LA und KI bzw. deren Kombination wurde von Buckingham Shum und Luckin (2019) vorgelegt. Sie weisen darauf hin, dass die vorhandenen Systeme das Potential haben »Verfolgung und Quantifizierung menschlicher Aktivitäten in immer höherer Auflösung zu liefern – ein Traum für Bürokraten, Marketingexperten und Forscher« (erster Abschnitt, eigene Übersetzung). KI und LA bieten so auch Grundlagen für **Überwachungsszenarien**, die wir uns in unserer Kultur nicht wünschen und vorstellen mögen. Buckingham Shum und Luckin (2019), weisen hier beispielsweise auf den Einsatz von Gesichtserkennungsanwendungen im Klassenzimmer hin, die das Interesse der Schüler/innen analysieren (Chen & Xu, 2018). Die Referenz auf China zeigt eine ethische Herausforderung und eine Notwendigkeit der Klärung, dass sich nicht nur auf die »korrekte« Fokussierung von LA auf die Unterstützung des Lernens von Studierenden abzielt: Wir haben eine eigene normative, kulturell geprägte Vorstellung, wie sich Lernen in unserer Gesellschaft, insbesondere im Studium, gestaltet und welche Formen der Unterstützung wir als passend empfinden. Es genügt also nicht, sich nur auf den »richtigen« Fokus und Absicht bei LA einzuschließen – im Interesse zum Wohle der Lernenden –, sondern muss auch davon begleitet werden

zu beschreiben, welche Formen des Lernens und dessen Unterstützung wir uns im Studium wünschen.

Wir vermuten, dass dies auch in den Fachkulturen und Disziplinen unterschiedlich bewertet wird, wenn man sich z.B. die unterschiedliche Bedeutung und Akzeptanz des sog. »Bulimielernen« vor Prüfungen betrachtet oder die Rolle von Transfer- und Anwendungswissen in akademischen Prüfungen. LA-Anwendungen sollten aus Perspektive von Buckingham Shum und Luckin (2019) **nicht eine »behavioristische« Instruktionspädagogik** fördern und unterstützen, sondern Raum für vielfältiges, selbstgesteuertes Lernen bieten. Um zum einen Klarheit und Transparenz über die Nutzung der Daten sowie eine Reflexion über entsprechende Wissens- und Lernmodelle anzuregen, müssen Entwickler/innen hier allgemein mit großer Offenheit, Reflexion und Sorgfalt vorgehen.

Hochschulen in der Europäischen Union sind besonders stark von der Durchsetzung der **Allgemeinen Datenschutzverordnung** (GDPR) der EU betroffen (Leitner et al., 2018). Die Fragen des Datenbesitz und des Datenschutzes haben dabei große Bedeutung, der Standort und die Zugänglichkeit der Daten müssen im Auge behalten werden (Leitner et al., 2018). Solche Überlegungen schließen weitreichende Nutzungen von **cloudbasierten Services oder KI-Anwendungen mit Datenspeicherung außerhalb der EU** faktisch aus.

Aus unserer Sicht wäre es hilfreich, immer stets auf den **empfehlenden und fehlbaren Charakter von LA-Maßnahmen** hinzuweisen. LA und KI können kaum Empfehlungen und Interpretationen liefern, bei denen von Eindeutigkeit oder Objektivität gesprochen werden kann. Die Daten und Auswertungen reichen nicht aus, um ein komplexes Vorgehen wie einen Lernprozess adäquat abzubilden: Die Verwendung der zugänglichen Daten ist in aller Regel unzureichend, um die komplexen Lern- und Lebenssituationen von Studierenden adäquat zu erfassen und zu beschreiben, die entsprechenden Interpretationen und Empfehlungen beinhalten also zahlreiche Fehler bzw. mögliche Fehlinterpretationen. LA und KI ist eben nur ein Hilfsmittel, das zu Beginn einmal einem besseren Verständnis des Prozesses dienen kann (Leitner, Ebner & Ebner, 2019). Hier entsprechend deutlich auf mögliche Fehler, Fehleinschätzungen oder Einschränkungen der Datengrundlage hinzuweisen, in den Applikationen wie auch bei den Akteur/inn/en, könnte eine hilfreiche Maßnahme sein, um den wachsenden Herausforderungen der Kombination von KI und LA zu begegnen.

6 Diskussion und Ausblick

Im Beitrag haben wir zunächst Learning Analytics beschrieben, insbesondere in Abgrenzung zu ähnlichen Zugängen und Verfahren bei denen Daten von Lerner/innen die Grundlage sind, haben Beispiele, Chancen und Herausforderungen benannt.

Darauf aufbauend haben wir den Einsatz von KI im Bildungsbereich allgemein und dann in LA beschrieben. Vier Beispiele wurden ausgewählt und beschrieben um vorzustellen, wie KI in LA-Anwendungen oder zur Entwicklung von LA-Anwendungen zum Einsatz kommt. Dieser Einsatz wurde abschließend problematisiert. Wie dargestellt, erweitern Verfahren der im engeren Sinne KI die möglichen Datennutzungen, Analysen und Interpretationen – allerdings in aller Regel mit der Herausforderung geringerer Transparenz und Nachvollziehbarkeit. Hier schlagen wir dringend vor, Einschränkungen von LA insbesondere bei der Einbindung und Etablierung von Maßnahmen klar zu kommunizieren.

Neben den Chancen und Potentialen von LA für Studierende möchten wir abschließend drei (weitere) Herausforderungen nennen, mit denen wir uns zukünftig verstärkt beschäftigen werden: So erleben wir es als problematisch, dass Entwicklungen im Kontext von LA, z.B. gewonnen Daten, Auswertungen und Einsichten, auch für Administration und Behörden interessant sind und dann nicht mehr nur im Interesse der Lernenden verwendet werden (könnten). Wir setzen hier auf **eindeutige (ethische) Regelungen zur Verwendung der Daten und Einsichten**. Gleichzeitig arbeiten wir daran, **technische Standards** für den Datenaustausch zu entwickeln und zu etablieren (Ifenthaler & Drachsler, 2018). LA-Anwendungen sollten schließlich zukünftig auch **dynamisch** Wissensstrukturen von Lernenden analysieren können und sich deren Bedürfnissen anpassen (Ebner et al., 2015).

Danksagung

Die vorliegende Publikation entstand im Rahmen des Projektes »Learning Analytics: Auswirkungen von Datenanalysen auf den Lernerfolg« unter Zusammenarbeit des Zentrums für Digitales Lehren und Lernen, des Instituts für Wirtschaftspädagogik (beide Karl-Franzens-Universität Graz) sowie der Organisationseinheit »Lehr- und Lerntechnologien« der Technischen Universität Graz. Die Autor/inn/en bedanken sich für die Förderung des Projektes im Rahmen der Ausschreibung »Auswirkungen der Digitalisierung auf die berufliche Kompetenzentwicklung« des Zukunftsfonds Steiermark (www.zukunftsfonds.steiermark.at/).

Sandra Schön: Technische Universität Graz, Lehr- und Lerntechnologien;
sandra.schoen@tugraz.at

Philipp Leitner: Technische Universität Graz, Lehr- und Lerntechnologien;
philipp.leitner@tugraz.at

Jakob Lindner: Technische Universität Graz, Lehr- und Lerntechnologien;
jakob.lindner@tugraz.at

Martin Ebner: Technische Universität Graz, Lehr- und Lerntechnologien;
martin.ebner@tugraz.at

Literatur

- Buckingham Shum, S.J. & Luckin, R. (2019). Learning analytics and AI: Politics, pedagogy and practices. In: *British Journal of Educational Technology*, 50 (6) (2019), 2785–2793.
- Calvet L. & Pérez, Á. A. (2015). Educational Data Mining and Learning Analytics. In: *International Journal of Educational Technology in Higher Education*, 12(3), 98–112.
- Chen, L.-Y., Luo, Z., & Xu, R. (2018). Application of intelligent systems in analyzing students' interest in classroom environment. *e-Education Research*, 304(8), 91–96.
- Chhatbar D., Ahmed U.Z. & Kar P. (2020). MACER: A Modular Framework for Accelerated Compilation Error Repair. In: I. Bittencourt, M. Cukurova, K. Muldner, R. Luckin, E. Millán (Hrsg), *Artificial Intelligence in Education. AIED 2020. Lecture Notes in Computer Science*, vol 12163. Springer, Cham.
- Cukurova, M. (2019). Learning Analytics as AI Extenders in Education: Multimodal Machine Learning versus Multimodal Learning Analytics. In: *Conference: International Conference on Artificial Intelligence and Adaptive Education*. URL: https://www.researchgate.net/publication/333756017_Learning_Analytics_as_AI_Extenders_in_Education_Multimodal_Machine_Learning_versus_Multimodal_Learning_Analytics.
- De Laet, T., Broos, T., van Staalduinen, J.-P., Ebner, M. & Leitner, P. (2018). Transferring learning dashboards to new contexts: experiences from three case studies. In: *Conference Proceeding Open Educational Global Conference 2018*, Delft, Netherlands.
- Drachslar, H., & Greller, W. (2016). Privacy and analytics – it's a DELICATE issue: A checklist to establish trusted learning analytics. *Proceedings of the 6th International Conference on Learning Analytics and Knowledge*, 89–96.
- Duval, E. (2012). Learning Analytics and Educational Data Mining, In: Erik Duval's Weblog, 30 January 2012, URL: <https://erikduval.wordpress.com/2012/01/30/learning-analytics-and-educational-data-mining/>.
- Ebner, M. (2019). Learning Analytics – eine Einführung. *Bildung und Beruf*. Ausgabe Februar 2019. 46–49.
- Ebner, M.; Haintz, C.; Pichler, K. & Schön, S. (2014). Technologiegestützte Echtzeit-Interaktion in Massenvorlesungen im Hörsaal. Entwicklung und Erprobung eines digitalen Backchannels während der Vorlesung. In: Klaus Rummler (Hg.), *Lernräume gestalten – Bildungskontexte vielfältig denken*, GMW 2014 Tagungsband, Münster: Waxmann, 567–578. URL: <http://www.waxmann.com/fileadmin/media/zusatztexte/3142Volltext.pdf>
- Ebner, M.; Neuhold, B. & Schön, M. (2013). Learning Analytics – wie Datenanalyse helfen kann, das Lernen gezielt zu verbessern. In A. Hohenstein & K. Wil-

- bers (Hg.), Handbuch E-Learning. Expertenwissen aus Wissenschaft und Praxis. Strategien, Instrumente, Fallstudien. Köln: Dt. Wirtschaftsdienst (2013), Loseblattausgabe, 48. Erg.-Lfg., [Stand] August 2013, 3.24, 20 S.
- Ebner, M., Lorenz, A., Lackner, E., Kopp, M., Kumar, S., Schön, S. & Wittke, A. (2016). How OER enhance MOOCs – A Perspective from German-speaking Europe. In: Open Education: from OERs to MOOCs. Jemni, M., Kinshuk, Khribi, M. K. (Hg.). Springer. Lecture Notes in Educational Technology, 205–220.
- Ebner, M., Taraghi, B.; Saranti, A. & Schön, S. (2015). Seven features of smart learning analytics – lessons learned from four years of research with learning analytics. In: eLearning Papers, Issue 40, January 2015, URL: https://www.researchgate.net/publication/271504715_Seven_features_of_smart_learning_analytics_-_lessons_learned_from_four_years_of_research_with_learning_analytics#fullTextFileContent.
- Ferguson, R. (2012). Learning analytics: Drivers, developments and challenges. International Journal of Technology Enhanced Learning (IJTEL), 4(5/6), 304–317.
- Ferguson, R. (2014). Learning analytics FAQs [Präsentation]. <https://de.slideshare.net/R3beccaF/learning-analytics-fa-qs>
- Ferguson, R., Hoel, T., Scheffel, M., & Drachsler, H. (2016). Guest editorial: Ethics and privacy in learning analytics. In: Journal of learning analytics, 3(1), 5–15. URL:
- Freedman, D. H. (2010). Why scientific studies are so often wrong: The streetlight effect. In: Discover Magazine, 26. URL: <http://discovermagazine.com/2010/jul-aug/29-why-scientific-studies-often-wrong-streetlight-effect>.
- Gašević, D., Dawson, S., & Siemens, G. (2015). Let's not forget: Learning analytics are about learning. In: TechTrends, 59(1), 64–71.
- Gliser I., Mills C., Bosch N., Smith S., Smilek D. & Wammes J.D. (2020). The Sound of Inattention: Predicting Mind Wandering with Automatically Derived Features of Instructor Speech. In: I. Bittencourt, M. Cukurova, K. Muldner, R. Luckin, E. Millán (Hrsg), Artificial Intelligence in Education. AIED 2020. Lecture Notes in Computer Science, vol 12163. Springer, Cham.
- Grandl, M., Taraghi, B., Ebner, M., Leitner, P. & Ebner, M. (2017). Learning Analytics. In: K. Wilbers & A. Hohenstein (Hg.), Handbuch E-Learning. Expertenwissen aus Wissenschaft und Praxis – Strategien, Instrumente, Fallstudien. Köln: Deutscher Wirtschaftsdienst (Wolters Kluwer Deutschland). 72. Erg.-Lfg. Dezember 2017.9.1, 1–16.
- Greller, W. & Drachsler, H. (2012). Translating Learning into Numbers: A Generic Framework for Learning Analytics. Educational Technology & Society, 15, 42–57.
- Hwang, G., Xie, H., Wah, B.W. & Gašević, D. (2020). Vision, challenges, roles and research issues of Artificial Intelligence in Education, Computers and Education: Artificial Intelligence, Volume 1, 2020, URL: <https://www.sciencedirect.com/science/article/pii/S2666920X20300011>.

- Ifenthaler, D. & Drachsler, H. (2018). Learning Analytics. Spezielle Forschungsmethoden in der Bildungstechnologie. In: H. Niegemann H. A. Weinberger A. (Hg.), Lernen mit Bildungstechnologien. Berlin: Springer Reference Psychologie, 1–20.
- International Conference on Learning Analytics and Knowledge (2011). Banff, Alberta, February 27–March 1, 2011, URL: <https://tekri.athabasca.ca/analytics>.
- Jivet, I., Scheffel, M., Schmitz, M., Robbers, S., Specht, M. & Drachsler, H. J. (2020). From students with love: An empirical study on learner goals, self-regulated learning and sense-making of learning analytics in higher education. In: The Internet and Higher Education. 47, 14 S., 100758.
- Johnson, L., Adams, S., Cummins, M., Estrada, V., Freeman, A. & Ludgate, H. (2012). The NMC Horizon Report: 2012 Higher Education Edition. The New Media Consortium.
- Khalil, M. & Ebner, M. (2015). Learning analytics: principles and constraints. In: Proceedings of world conference on educational multimedia, hypermedia and telecommunications, 1326–1336.
- Khalil, M., & Ebner, M. (2017). Driving student motivation in MOOCs through a conceptual activity-motivation framework. In: Zeitschrift für Hochschulentwicklung, 12(1), 101–122.
- Leitner, P., Broos, T. & Ebner, M. (2018). Lessons Learned when transferring Learning Analytics Interventions across Institutions. In: Companion Proceedings 8th International Conference on Learning Analytics & Knowledge, 621–629.
- Leitner, P., Ebner, M., Ammenwerth, E., Andergassen, M., Csanyi, G., Gröbinger, O., Kopp, M., Reichl, F., Schmid, M., Steinbacher, H.-P., Handle-Pfeiffer, D., Zitek, A., Zöserl, E. & Zwiauer, C. (2019). Learning Analytics: Einsatz an österreichischen Hochschulen. Whitepaper, Forum Neue Medien in der Lehre (FNMA). URL: <https://www.fnma.at/content/download/1896/8814>.
- Leitner, P., Ebner, M. & Ebner, M. (2019). Learning Analytics Challenges to Overcome in Higher Education Institutions. In: D. Ifenthaler, D.K. Mah, D.K. & J.K. Yau (Hg.), Utilizing Learning Analytics to Support Study Success. Springer, Cham, 91–104.
- Leitner, P.; Ebner, M.; Geisswinkler, H. & Schön, S. (in Druck, 2021). Visualisation of learning for students: A dashboard for study progress. Development, design details, implementation, and user feedback. In: D. Ifenthaler & M. Sahin (Hg.), Visualisation and LA, Cham: Springer.
- Leitner, P., Khalil, M. & Ebner, M. (2017). Learning analytics in higher education – a literature review. In Learning Analytics: Fundaments, Applications, and Trends, Springer, Cham, 1–23.
- Leitner, P., Maier K. & Ebner M. (2020). Web Analytics as Extension for a Learning Analytics Dashboard of a Massive Open Online Platform. In: Ifenthaler D.,

- Gibson D. (eds) *Adoption of Data Analytics in Higher Education Learning and Teaching. Advances in Analytics for Learning and Teaching*. Springer, Cham.
- Lipp, S.; Dreisiebner, G.; Leitner, P.; Ebner, M.; Kopp, M. & Stock, M. (in Druck, 2021). *Learning Analytics – Didaktischer Benefit zur Verbesserung von Lehr-Lernprozessen? Implikationen aus dem Einsatz von Learning Analytics im Hochschulkontext*. In: *bwp@ Berufs- und Wirtschaftspädagogik – online, Ausgabe 40 (>Didaktisierung des Digitalen<)*, <https://www.bwpat.de/>.
- Lloyd, J.E.V., Walsh, J., & Shehni Yailagh, M. (2005). Sex Differences in Performance Attributions, Self-Efficacy, and Achievement in Mathematics: If I'm so Smart, Why Don't I Know It? *Canadian Journal of Education/Revue Canadienne De L'éducation*, 28(3), 384–408.
- Long, P. & Siemens, G. (2011). Penetrating the fog: Analytics in learning and education. *EDUCAUSE review*, 46(5), 30. Retrieved from <https://er.educause.edu/articles/2011/9/penetrating-the-fog-analytics-in-learning-and-education>.
- McAuley, A., Stewart, B., Siemens, G. & Cormier, D. (2010). *Massive Open Online Courses Digital ways of knowing and learning, The MOOC Model for Digital Practice*. URL: http://davecormier.com/edblog/wp-content/uploads/MOOC_Final.pdf.
- Morsy, S. & Karypis, G. (2019). Will This Course Increase or Decrease Your GPA? Towards Grade-Aware Course Recommendation. In: *Journal of Educational Data Mining*, v11, n2, 20–46 Sep 2019, URL: <https://arxiv.org/pdf/1904.11798.pdf>.
- Norvig P. & Russel S. (2019). *Artificial Intelligence A Modern Approach*. 2nd Ed. Pearson Series in Artificial Intelligence.
- Ochoa, X. (2017). Multimodal Learning Analytics, in Lang, C., Siemens, G., Wise, A. and Gasevic, D. (Hg.), *Handbook of Learning Analytics*, Society for Learning Analytics Research (SoLAR), 129–147.
- Orr, D., Luebecke, M., Schmidt, J.P., Ebner, M., Wannemacher, K., Ebner, M. & Dohmen, D. (2020). *Higher Education Landscape 2030. A Trend Analysis Based on the AHEAD International Horizon Scanning*. Springer: Briefs in Education. 978-3-030-44896-7.
- Picciano, A.G. (2019). Artificial Intelligence and the Academy's Loss of Purpose. In: *Online Learning*, 23, 3, 270–284.
- Schmohl, T., Löffl, J. & Falkemeier, G. (2019). Künstliche Intelligenz in der Hochschullehre – In: T. Schmohl, & D. Schäffer, Dennis (Hg.), *Lehrexperimente der Hochschulbildung. Didaktische Innovationen aus den Fachdisziplinen*. 2., vollständig überarbeitete und erweiterte Auflage. Bielefeld: wbv 2019, 117–122.
- Schön, M., Ebner, M. & Kothmeier, G. (2012). It's Just About Learning the Multiplication Table, in: *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK '12)*, New York, USA 2012, 73–81.
- Schön, M. & Ebner, M. (2013). Das Gesammelte interpretieren. *Educational Data Mining und Learning Analytics*. In M. Ebner & S. Schön (Hg.), *Lehrbuch für Lernen*

- und Lehren mit Technologien (L3T). URL: <https://l3t.tugraz.at/index.php/LehrbuchEbner10/article/view/119> urn:nbn:de:0111-opus-83673.
- Schwendimann, B. A., Rodríguez-Triana, M. J.; Vozniuk, A.; Prieto, L.P., Boroujeni, M.S. and Holzer, A., Gillet, D., Dillenbourg, P. (2017). Perceiving Learning at a Glance: A Systematic Literature Review of Learning Dashboard Research, in *IEEE Transactions on Learning Technologies*, vol. 10, no. 1, pp. 30–41, 1 Jan.-March 2017.
- Slater, N., Peasgood, A. & Mullan, J. (2016). Learning Analytics in Higher Education: A review of UK and international practice Full report. JISC. URL: <https://www.jisc.ac.uk/reports/learning-analytics-in-higher-education>.
- Shah, H. (2018). Algorithmic accountability. In: *Philosophical Transactions A*, Volume 376, Issue 2128.
- Siemens, G. & Baker, R. S. J. (2012). Learning Analytics and Educational Data Mining: Towards Communication and Collaboration. In: *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK '12)*, New York, USA 2012, 252–254.
- Siemens, G., Gasevic, D., Haythornthwaite, C., Dawson, S., Buckingham Shum, S., Ferguson, R., Duval, E., Verbert, K., Baker, RSJD (2011). Open learning analytics: an integrated & modularized platform. Proposal to design, implement and evaluate an open platform to integrate heterogeneous learning analytics techniques.
- Zawacki-Richter, O., Marín, V.I., Bond, M. & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? In: *International Journal of Educational Technology in Higher Education*, 16, 39 (2019).
- Zylich, B., Viola, A., Toggerson B., Al-Hariri L. & Lan A. (2020) Exploring Automated Question Answering Methods for Teaching Assistance. In: I. Bittencourt, M. Cukurova, K. Muldner, R. Luckin, E. Millán (Hrsg), *Artificial Intelligence in Education. AIED 2020. Lecture Notes in Computer Science*, vol 12163. Springer, Cham.

Ménage à trois

Zur Beziehung von Künstlicher Intelligenz, Hochschulbildung und Digitalität

Cathleen M. Stützer, Stephanie Gaaw, Sabrina Herbst und Norbert Pengel

Abstract: *Der Einsatz innovativer Technologien im Kontext des Lehrens und Lernens an Hochschulen gilt bildungs- und hochschulpolitisch als Hoffnungsträger. Hierbei soll insbesondere die Implementierung von Künstlicher Intelligenz (KI) im Lehr- und Lernkontext zur Verbesserung der Hochschulbildung beitragen. Um allerdings Innovationspotentiale von intelligenten und disruptiven Systemen vollumfänglich nutzen zu können, müssen neben Fragen zur technischen Implementierung auch didaktische und organisationale Aspekte sowie ethisch-rechtliche Rahmenbedingungen in den Blick genommen werden. Hier setzt der vorliegende Beitrag an und versucht, sich der Frage zu nähern, inwieweit transdisziplinäre Ansätze und methodische Zugänge zur Bewertung einer potentiell wirksamen und nachhaltigen Implementierung von KI in der Hochschulbildung beitragen können.*

The use of innovative technologies in the context of teaching and learning at universities is seen as a beacon of hope in education policy. In particular, the implementation of artificial intelligence (AI) in the teaching and learning context is expected to contribute to the improvement of higher education. However, in order to fully exploit the innovation potential of intelligent and disruptive systems, in addition to questions of technical implementation, didactic and organizational aspects as well as ethical-legal conditions must be taken into account. Thus, this paper attempts to address the question of which transdisciplinary approaches and methodological aspects can contribute to the evaluation of a potentially effective and sustainable implementation of AI in higher education.

Keywords: *Künstliche Intelligenz, Hochschulbildung, Digitalität, Digitale Transformation, Bereitschaft, Adoption, Akzeptanz / Artificial Intelligence, Higher Education, Digital Transformation, Readiness, Adoption, Acceptance.*

1 Einführung und Ausgangslage

Digitalisierung ist in der nationalen Hochschullandschaft seit Mitte der 2000er Jahre ein prominentes Thema. Frühzeitig wurde an den deutschen Hochschulen begonnen, sowohl in Verwaltung als auch in Studium und Lehre technische Unterstützungsangebote bereitzustellen, um den Digitalisierungsprozess voranzutreiben. Dennoch konnte sich dieser an den Hochschulen vor der Corona-Pandemie nicht flächendeckend durchsetzen und digitale Lehre beschränkte sich zumeist auf eine Anreicherung der klassischen Lehre mit digitalen Medien (Deimann et al. 2020). Entsprechend wurde zu Beginn der Corona-Pandemie deutlich, dass der Stand der Digitalisierung in der Hochschulbildung weit hinter den eigentlichen Erwartungen der Bildungs- und Hochschulpolitik lag. Zudem waren – mit Blick auf den kurzfristigen Bedarf zur Umstellung der Lehre von überwiegend präsent auf digital – Lehrende und Studierende in vielerlei Hinsicht nicht umfassend auf die anstehenden Herausforderungen vorbereitet (Schumacher et al. 2021). Im weiteren Verlauf der Pandemie zeigte sich jedoch, dass das Erfordernis der Umstellung dem bis dato langsamen Digitalisierungsprozess der Hochschulbildung einen Schub versetzte, sodass die digitale Hochschulbildung nunmehr enorme Fortschritte erzielen konnte (ebd.; CHE 2020).

Der auf den Bestrebungen zur Digitalisierung der Hochschulbildung aufbauende und viel diskutierte Einsatz intelligenter Technologien und Systeme erscheint vor diesem Hintergrund nun realistischer u.a. mit Blick auf die nun bessere Ausgangslage hinsichtlich notwendiger technischer Rahmenbedingungen. Allerdings wurden durch die umfassende Nutzung digitaler Technologien im Zuge des letzten Jahres zunehmend auch neue Problemlagen offengelegt. Diese heizten die Diskussionen und Fragen rund um geeignete didaktische Gestaltungskonzepte, adäquate organisationale Implementierungsansätze sowie notwendige ethisch-rechtliche Rahmenbedingungen u.a. für eine Sicherstellung von Chancengerechtigkeit im Rahmen digitaler Lehre an (Seyfeli et al. 2020). Durch den immer stärker werdenden Einfluss digitaler Transformationsprozesse im Bildungssektor sind für Hochschulen die Anforderungen an eine nachhaltige Implementierung einer dynamisch-anpassbaren Infrastruktur gestiegen (DIPF-Bildungsbericht 2020). Bei der Entwicklung erfolgreicher Implementierungsstrategien von KI im Hochschulkontext kann diese Auseinandersetzung zudem nicht ohne Reflexion des gesamtgesellschaftlichen digitalen Transformationsprozesses sowie aktorsbezogener und hochschulkultureller Rahmenbedingungen erfolgen. Hierzu lassen sich sowohl aus der Adoptions- als auch Diffusionsforschung vielseitige Handlungsfelder ablesen, die aktuell vor allem auf die multiperspektivische Beforschung der Konzepte *Akzeptanz* und *Vertrauen* verweisen (Scheuer 2020; Kieslich et al. 2019). Auf organisationaler Ebene wird insbesondere im Unternehmenssektor das Konzept der *Bereitschaft* (engl. *readiness*) in den Blick genommen, um einerseits als Entscheidungsinstrument und an-

dererseits als konzeptionelle Rahmung der Wirksamkeit von KI innerhalb von Unternehmen, Organisationen bzw. Institutionen beitragen zu können (Mazaraki et al. 2020; Hizam et al. 2020). Vor diesem Hintergrund soll sich im Folgenden der Frage genähert werden, inwieweit transdisziplinäre Ansätze und methodische Zugänge zur Bewertung einer potentiell wirksamen und nachhaltigen Implementierung von KI in der Hochschulbildung beitragen.

Ausgehend vom aktuellen Forschungsstand werden zunächst Potentiale und Herausforderungen, die insbesondere mit der Implementierung intelligenter Technologien und Systeme im Hochschulkontext einhergehen, diskutiert. Nachfolgend wird sich mit Ansätzen und Methoden auseinandergesetzt, die zur Einschätzung des Implementierungspotentials von KI-Infrastrukturen in der Hochschulbildung beitragen. Daraus abgeleitet, wird ein Modell zur wirksamen und nachhaltigen Implementierung von KI in der Hochschulbildung vorgestellt, welches das Zusammenspiel von Künstlicher Intelligenz, Hochschulbildung und Digitalität abbildet. Es werden Konzepte der Adoptionsforschung auf Akteursebene (KI-Akzeptanz) sowie auf organisationaler Ebene (KI-Bereitschaft) zusammengeführt, um die grundlagenorientierte Auseinandersetzung mit dem Thema KI in der Hochschulbildung zu unterstützen. Zudem nimmt der Beitrag die Operationalisierung und Instrumentenentwicklung zur soziotechnischen Beforschung des KI-Implementierungspotentials in der Hochschul- und Bildungsforschung in den Blick.

2 Potentiale und Herausforderungen von KI in der Hochschulbildung

Der Einsatz digitaler Technologien wird im Kontext der Hochschulbildung bereits seit mehreren Dekaden mit großen Hoffnungen für die Weiterentwicklung und Qualitätsverbesserung der Lehre verbunden. So wird konstatiert, dass trotz bzw. gerade durch Digitalisierung grundsätzlich die Qualität der Hochschulbildung steigt. Dabei wird insbesondere innovativen Technologien großes Potential u.a. bei der Individualisierung der Hochschulbildung und dem Umgang mit Diversität sowie der Teilhabe am Bildungsprozess an Hochschulen zugesprochen (Getto et al. 2018; Ferguson et al. 2016).

Die rasante Entwicklung von intelligenten und algorithmenbasierten Technologien und Systemen wie Machine Learning, Recommender Systems, Virtual und Augmented Reality etc. in der letzten Dekade legt hierzu zudem zahlreiche weitere Potentiale offen (Fürst 2020; de Witt et al. 2020). So werden neben intelligenten Tutorsystemen zunehmend skalierbare sowie smarte Unterstützungstechnologien, bezogen auf Lernerfolg und zur Lernbegleitung, für den Bildungskontext in Aussicht gestellt (Zawacki-Richter et al. 2019). Weiterführend dazu wird diskutiert, inwiefern der Einsatz intelligenter Technologien und Systeme die Qualität und Wirksamkeit einer berufsbefähigenden und kompetenzorientierten Aus- und Wei-

terbildung befördern kann (Luttrell et al. 2020; Kirchherr et al. 2018). Mit der Implementierung von Chatbots sowie adaptiven Unterstützungssystemen werden so beispielsweise neue Möglichkeiten in der Lernbegleitung eröffnet, da sie sich sowohl den Bedürfnissen (durch personalisierte Angebote etc.) als auch den Lernständen der Studierenden dynamisch anpassen können, um z.B. bei der Organisation von Lerninhalten bzw. bei Rückkopplungsprozessen durch Feedback und Empfehlungen zu unterstützen (Büching et al. 2019). Auch Lehrende sollen vom Einsatz intelligenter Technologien und Systeme in der akademischen Lehre profitieren können. Es wird prognostiziert, dass der Einsatz datenbasierter Zugänge das Reflexionspotential der eigenen Lehrleistung steigern sowie die Nutzung intelligenter Interventionen zur Erhöhung der Lehrqualität führen kann (Seufert et al. 2020; Kieslich et al. 2019). Der Einsatz in Form von prädiktiven bzw. präskriptiven Systemen liefert zudem hohes Interventionspotential zur Qualitätsverbesserung auf organisationaler Ebene. Hierbei sollen intelligente Frühwarnsysteme in Echtzeit u.a. zur Optimierung von Studienverläufen, der Curriculum-Entwicklung, Prüfungsorganisation etc. beitragen können, um Studiengangs-, Instituts- wie auch Hochschulleitungen in ihren Entscheidungsprozessen dynamisch-angepasst zu unterstützen. Zwar illustrierte der Horizont Report bereits 2017, dass Big Data- und KI-Technologien an Hochschulen Einzug halten werden (Adams Becker et al. 2017). Allerdings sind mit dieser Implementierung auch neue Schwierigkeiten verbunden. Hierbei zeichnet sich besonders ab, dass Herausforderungen, die sich bereits bei der Implementierung von E-Learning in der Hochschullehre gestellt haben, mit Blick auf den potentiellen Einsatz von Data Analytics, Big Data und KI noch verschärfen bzw. in größerem Umfang auftreten werden (Hochschulforum Digitalisierung 2016). Allgemein lässt sich mit Blick auf die Nutzbarmachung von Data Analytics, Big Data und KI für die Unterstützung digitalen Lernens und Lehrens an Hochschulen festhalten, dass vor allem ihre praktischen Implikationen als Herausforderung wahrgenommen werden (Gasevic et al. 2019). Es zeigt sich bereits, dass sich die digitale Lehre insbesondere mit Blick auf den Einsatz intelligenter Technologien und Systeme um ein Vielfaches häufiger mit Vertrauens- und Akzeptanzproblemen und deren Messbarkeit auseinandersetzen muss als vergleichbare Präsenzangebote (Kieslich et al. 2019). Entsprechend scheint es von besonderer Bedeutung zu sein, dass neben der Bereitstellung technischer Infrastrukturen vor allem auch mediendidaktische und organisationale Unterstützungsangebote zur Verfügung stehen, die den Bildungsprozess unter Berücksichtigung veränderter Anforderungen entlang der gesamten Wertschöpfungskette begleiten (Gilch et al. 2019; Getto et al. 2018). Hinzu kommt, dass auf gesellschaftlicher Ebene zunehmend neue soziale Problemlagen identifiziert werden, die u.a. auch zu einer digitalen Kluft und mit Blick auf den Bildungsprozess an Hochschulen zur *digitalen Ungleichheit* führen können (Breitenbach 2021; van Deursen 2020). Vor diesem Hintergrund scheint es notwendig, soziale Kontextfaktoren des Lehrens und Lernens in die Betrachtung mediendidaktischer Angebote

sowie organisationaler Infrastrukturen einfließen zu lassen, um als Hochschule im Zeitalter der vierten Industriellen Revolution innovationsfähig zu bleiben (Pensel et al. 2017; van Ackeren et al. 2017).

3 Ansätze und methodische Zugänge zur Einschätzung des Implementierungspotentials von KI

Mit Blick auf die Herausforderungen bei der Implementierung von KI in der Hochschulbildung stellt sich insgesamt die Frage, wie Hochschulen als Akteure digitaler Bildung diesen begegnen müssen, um zur erfolgreichen Implementierung von KI beitragen zu können. Auf Basis der bisherigen Ausführungen werden hierzu drei Handlungsebenen im Implementierungsprozess als relevant für die sozialwissenschaftliche Betrachtung erachtet: (1) die *technische/methodische*, (2) die *individuelle/akteursbezogene* sowie (3) die *organisationale/institutionelle* Handlungsebene. Hierzu soll im Folgenden kurz ausgeführt werden, welche Ansätze und Methoden auf diesen Handlungsebenen bereits genutzt werden, um zur Erarbeitung eines ganzheitlichen Implementierungsansatzes beitragen zu können.

3.1 Technische/Methodische Handlungsebene

In der Analyse des Forschungsstandes zur Implementierung technischer und methodischer Artefakte wird zunächst deutlich, dass intelligente Technologien und Systeme vor allem in Form von Tools und Verfahren zur Bewertung des Lehr- und Lernerfolgs eingesetzt werden. So werden im Bereich der *Learning Analytics* und des *Educational Data Mining* mittels algorithmenbasierter Lernstands- und Lernpfadanalysen Nutzende in ihrem Lernprozess unterstützt (Baker & Inventado 2014; Ferguson 2012). Um auch zur Qualitätsverbesserung von Bildungsprozessen auf organisationaler Ebene beitragen zu können, wurde im Bereich der Bildungstechnologie zudem der Ansatz der *Academic Analytics* verfolgt (Stuetzer et al. 2013; Campbell et al. 2007). Hierzu soll die datengetriebene Beforschung mit interdisziplinären Methoden u.a. aus dem Bereich der *Data Science* und *Computational Science* zur evidenten Qualitäts- und Leistungsbewertung von Institutionen bzw. Hochschulen aus Makroperspektive beitragen (Stützer 2017). Es ist allerdings zu beobachten, dass die Implementierung datengetriebener Forschungsansätze sowohl auf individueller als auch auf organisationaler Ebene deutlich langsamer in der Hochschulbildung Einzug hält als prognostiziert. Doch bezüglich der Auswirkungen der Corona-Pandemie seit dem Frühjahr 2020 und dem in diesem Zusammenhang forcierten digitalen Transformationsprozess in der Hochschulbildung ist zu erwarten, dass sich Themenfelder rund um Big Data und KI nun zeitnah aus der Forschung hinein in die Hochschul- und Bildungspraxis bewegen werden.

Mit Blick auf die aktuelle Situation bleibt festzustellen, dass es sich bei ersten Anwendungen von KI in der Hochschulbildung vorwiegend um vereinzelte didaktische Interventionen handelt, um zunächst Lehrende bei der Bewältigung ihrer alltäglichen Aufgaben zu unterstützen (Schmohl et al. 2019). Abseits dieser *Insellösungen* fehlt es aktuell noch an übergreifenden Nutzungsszenarien beim Einsatz von intelligenten Technologien und Systemen und im weiteren Sinne an *Best Practices* für eine übergreifende Implementierungsstrategie von KI in der Hochschulbildung. Neben der Frage, was mit deren Einsatz konkret erreicht werden soll, müssen auch die Voraussetzungen an eine (sozio-)technische Infrastruktur näher beleuchtet werden. Dies gilt etwa mit Blick auf den bestehenden Datenhunger intelligenter Technologien und Systeme und die damit einhergehende Notwendigkeit von Trainingsdatensätzen. Mühlhoff (2019) wirft dazu u.a. die Frage auf, inwieweit sich ein Interface, eine Plattform oder ein *Use Case* so konstruieren lassen, um zugleich als Infrastruktur zur Gewinnung von Daten durch freiwillige menschliche Mitarbeit dienen zu können (2019, S. 57). Im Anschluss muss zudem gefragt werden, wie es gelingen kann, rasch aber wirksam zur Entwicklung übergreifender Nutzungsszenarien von KI in der Hochschulbildung beizutragen, um die dafür notwendigen technischen und organisationalen Infrastrukturen (Datenzugänge, Schnittstellen, Sensoren usw.) identifizieren und bereitstellen zu können.

3.2 Individuelle/Akteursbezogene Handlungsebene

Auf der individuellen und akteursbezogenen Handlungsebene stellen sich bei der Implementierung von KI in der Hochschulbildung vor allem Fragen zu vorhandenen (digitalen) Kompetenzen sowie zur Einstellung gegenüber diesen Technologien und zum Nutzungsverhalten. Da subjektive Nutzenabschätzungen von Stakeholdern bedeutend für die Akzeptanz von Technologien sind, muss folglich in den Blick genommen werden, wie KI für Lehrende und Studierende so anschlussfähig wie möglich in digitale Lehr- und Lernprozesse implementiert werden kann. Technologieakzeptanzmodelle wie das *Technology Acceptance Model* (TAM) und die *Unified Theory of Acceptance and Use of Technology* (UTAUT) geben aus Sicht der Technologienutzung einen Überblick über Indikatoren, die entsprechend zu berücksichtigen sind (Davis et al. 1989; Venkatesh & Davis 2000; Venkatesh & Bala 2008; Venkatesh et al. 2003). Das Modell der UTAUT etwa diskutiert die Nutzen- und Aufwandserwartung der Akteure, die allgemeine Einstellung zur betrachteten Technologie, soziale Einflüsse, Rahmenbedingungen für die Nutzung, die Selbstwirksamkeitswahrnehmung der Nutzenden sowie mögliche Skepsis bzw. Ängste in Bezug auf den Einsatz und die Nutzung einer neuen Technologie. Diese Faktoren wirken als direkte und/oder indirekte Determinanten auf die Nutzungsintention ein. Mit Blick auf die rasante Entwicklung neuer digitaler Technologien, erscheint die reine Verwendung ausschließlich aus Perspektive der Technologienutzung hergeleiteter Akzep-

tanzmodelle wie TAM und UTAUT jedoch unzureichend. Aus Sicht von Hansen-Cassteel (2020) muss der soziotechnische Kontext in der Triade *Technologie-Umfeld-Nutzende* mit in den Blick genommen werden (ebd.), um eine prospektive Einschätzung der Akzeptanz bei der Entwicklung von Technologien vornehmen zu können. Sie nimmt auf den drei Ebenen jeweils eine Kategorien- und Indikatorenbildung vor, anhand derer die zu entwickelnden Technologien, die potentiellen Nutzenden und das Einsatzumfeld klassifiziert werden, um bereits während der Technologieentwicklung Rückschlüsse auf die Akzeptanz ziehen zu können (ebd.). Scheuer (2020) weist mit Blick auf KI-Technologien ebenso darauf hin, dass eine Betrachtung allein aus Perspektive der Technologienutzung unzureichend ist. Anders als bisherige (onlinegestützte) Technologien tritt KI in *Interaktion* mit den Nutzenden und wird von diesen je nach konkreter Ausgestaltung mehr oder weniger als eigenständige Persönlichkeit wahrgenommen. Zudem wird nach Scheuer die Lernfähigkeit solcher Systeme in gängigen Technologieakzeptanzmodellen bisher nicht berücksichtigt. Für die Untersuchung von Einflussfaktoren, die sich auf die KI-Akzeptanz auswirken, schlägt er daher vor, neben den reinen Technologieakzeptanzmodellen weitere Perspektiven aus beispielsweise Psychologie und Philosophie einzubringen, um einen Bezug zu interaktionsfähigen intelligenten Technologien und Systemen zu gewährleisten. Seinen Ansatz verarbeitet und erprobt er im *KI-Akzeptanzmodell* (kurz: KIAM).

3.3 Organisationale/Institutionelle Handlungsebene

Wenn Fragen zu Adoptionsprozessen auf Ebene der Lehrenden und Studierenden in der Beforschung zu KI in der Hochschulbildung adressiert werden, liegt es nahe, auch nach Handlungsfeldern auf organisationaler Ebene zu fragen. Zwar steckt die Beforschung und Entwicklung von KI im Lehr-Lernkontext noch in den Kinderschuhen, gleichzeitig steigt aber der Wille zur Implementierung intelligenter Technologien und Systeme und datengetriebenen Anwendungen in der Hochschulbildung. In der Hochschulpraxis – mit Bezug zu den Bund-Länder-Initiativen der letzten Jahre – werden hierzu sogenannte *Leuchtturmprojekte* in Aussicht gestellt, allerdings zeigen Hochschulen zunehmend den Bedarf, zeitnah den eigenen Transformationsprozess mitgestalten zu können (Die Bundesregierung 2018).

Vor diesem Hintergrund wird zudem zunehmend danach gefragt, ob Hochschulen grundsätzlich bereit für intelligente Technologien und Systeme im Kontext des akademischen Lehrens und Lernens sind, um Rückschlüsse mit Bezug zur Adoption von KI-Interventionen auf institutioneller bzw. organisationaler Ebene ziehen zu können (Limani et al. 2019; Rohayani et al. 2015). Mit Blick auf die Operationalisierung fehlt es hierbei allerdings an einer ganzheitlichen Betrachtungsweise für den Bildungskontext. Hierzu lohnt der Blick auf den Unternehmenssektor. Ob ein Unternehmen für KI bereit ist oder nicht, wird dort u.a. mit der *KI-Bereitschaft*

(engl. *AI-Readiness*) bewertet. KI-Bereitschaft meint im Allgemeinen »die Kompetenz von Unternehmen, Anwendungen der künstlichen Intelligenz einzuführen. Dies bezieht sich auf technische Kompetenzen und Infrastruktur, die strategische Ausrichtung des Unternehmens und die Bereitschaft der Mitarbeiter, solche Veränderungen voranzutreiben« (DFKI 2020). Als methodisches Instrument zur Entscheidungsunterstützung wird hierzu der sogenannte *KI-Readiness-Check* von verschiedenen Tech-Unternehmen angeboten (DFKI 2020; Intel Corporation 2018). Unternehmensleitungen werden dabei zum einen um die Angabe von Leistungsindikatoren (u. a. Umsatz, Größe, technische Ausstattung etc.) sowie zum anderen um eine Einschätzung vorhandener digitaler Kompetenzen bei den Beschäftigten gebeten, um Unternehmen in ihrer Entscheidung, KI-Anwendungen im Unternehmen zu implementieren, zu unterstützen.

Auch Hochschulen stellen sich Fragen zur Bereitschaft. Jedoch scheint es hier an Rahmenkonzepten für eine umfassende Einschätzung ihrer bestehenden soziotechnischen Infrastruktur zu mangeln. Unter Berücksichtigung des Umstandes, dass Hochschulen in ihren organisationalen Entscheidungen zumeist nicht als Einzelakteure agieren, sondern vielmehr in eine Umwelt aus weiteren Hochschulen, Hochschul- und Bildungspolitik usw. eingebettet sind, sollten neben monetären (ökonomischen und materiellen) vor allem nicht-monetäre (soziale und kulturelle) Einflussfaktoren zur Beurteilung der Bereitschaft berücksichtigt werden (Schumacher et al. 2021). Mit Bezug zu Themen wie Wirksamkeit, Nachhaltigkeit und Datenethik werden zudem neue Problemlagen adressiert, die als Einflussfaktoren nicht hinreichend operationalisiert werden können, wenn die Hochschulumwelt unberücksichtigt bleibt (Pedró et al. 2019; Weber 2019; Heumann & Zahn 2018).

Die Erarbeitung eines Modells zur soziotechnischen Bewertung von KI in der Hochschulbildung erscheint vor dem Hintergrund bestehender spezifischer Kontextfaktoren an Hochschulen also notwendig. Zum einen soll dies zur wirksamen und nachhaltigen Implementierung intelligenter Technologien und Systeme in der Hochschulbildung beitragen, zum anderen sollen sich Hochschulen auf weitere Handlungsfelder (u. a. Evaluationen und Voranalysen, Aufbau von Governance-Strukturen, Prozesse zur Adoption, Qualitätsmanagement) vorbereiten können, die damit verbunden sind.

4 Modell zur wirksamen und nachhaltigen Implementierung von KI in der Hochschulbildung


Die Diskussionen rund um die Implementierung von intelligenten Technologien und Systemen an Hochschulen bzgl. ihrer Wirksamkeit (Büching et al. 2019), Nachhaltigkeit (Seufert et al. 2019) und Fragen der Datenethik (Hasenbein 2020) verweisen darauf, dass insbesondere im Kontext Hochschulbildung eigene und spezifisch

angepasste Entscheidungskriterien und Einflussfaktoren in den Blick genommen werden müssen. Dabei scheinen, wie eben aufgezeigt, soziotechnische Kontextfaktoren mit Blick auf die Vielseitigkeit der Bedarfe der adressierten Interessengruppen besonders wichtig. Mit dem im folgenden Abschnitt vorgestellten Modell wird versucht, wesentliche Einflussfaktoren auf individueller und organisationaler Ebene systematisch sowie auf Basis des vorliegenden Forschungsstandes in ein übergreifendes Rahmenkonzept zu überführen. Um dabei dem Anspruch der Ganzheitlichkeit begegnen zu können, bezieht sich das vorliegende Modell u.a. auf die Rekonstruktion von *Wechselwirkungen*¹. Dabei liegt der Fokus nicht auf Entitätsebene (Akteur, Organisation, Gesellschaft), sondern auf dem Wirkungsgrad der Wechselbeziehungen dazwischen. Dieser wird für den Hochschulkontext zunächst über das Konstrukt *Implementierungspotential* operationalisiert. Es kann als ein Kriterium zur Bewertung der Reife bzw. Güte der notwendigen Voraussetzungen für eine Implementierung von KI auf organisationaler Ebene beschrieben werden und gibt Auskunft über die grundsätzliche Bereitschaft als Hochschule intelligente sowie potentiell disruptive Technologien und Systemen zu implementieren. Hierbei basiert der Reife- bzw. Gütegrad auf dem Zusammenspiel der *Technologie*-, *Einsatz*- sowie *Transformationsbereitschaft*. Ein hohes Implementierungspotential wird grundsätzlich dann erzielt, wenn ein hinreichend hohes Level auf jeder Bereitschaftsebene sowie eine Balance zwischen allen Entitäten der Ebenen erreicht wurde (vgl. Abb. 1).

Das soziotechnische Modell zur wirksamen und nachhaltigen Implementierung von KI in der Hochschulbildung führt das Konstrukt der *Bereitschaft* mit dem Konstrukt der *Akzeptanz* zusammen. Der Rückgriff auf eine systemische Perspektive auf den Implementierungsprozess erlaubt zudem, eine leistungs- bzw. zweckorientierte Ausdifferenzierung des KI-Implementierungspotentials innerhalb des Funktionssystems Hochschulbildung vorzunehmen. Im Modell wird *Hochschulbildung* als eine Entität im Hochschulkontext begriffen, die anhand ihrer Akteure, Bildungsziele, Curricula, Didaktiken etc. in ihrer Leistungsfähigkeit bewertet werden kann. Das Artefakt *Künstliche Intelligenz* bezieht sich zunächst auf die zu implementierende Technologie und steht für die Bewertung der Funktions- und Einsatzfähigkeit u.a. von Chatbots, intelligente Tutoresysteme etc. Das Konstrukt *Digitalität* bildet Einflussfaktoren des Hochschulumfelds ab, die sich aus gesellschaftlichen Wandlungsprozessen sowie kulturellen Rahmenbedingungen ergeben. Zunächst wird die jeweilige Beziehung zwischen Künstlicher Intelligenz, Hochschulbildung sowie Digitalität in den Blick genommen. Für jede Beziehung lassen sich unterschiedliche Arten der Bereitschaft und Einflussfaktoren für das Implementierungspotential operationalisieren.

1 Simmel (1890) beschreibt Wechselwirkungen als gegenseitige dynamische Beziehungsgeflechte, die zur Erklärung sozialer Gesellschaftssysteme dienen.

Abbildung 1: Soziotechnisches Modell zur wirksamen und nachhaltigen Implementierung von KI in der Hochschulbildung (eigene Darstellung).



Die **Technologiebereitschaft** (engl. *technology readiness*) bezieht sich auf die Bereitschaft, digitale und intelligente Technologien und Systeme zu implementieren und notwendige technische Infrastrukturen bereitzustellen, um Infrastrukturziele im Hochschul- und Bildungskontext zu erreichen. Zur Operationalisierung werden als Indikatoren vor allem Funktionalität, Zuverlässigkeit, Benutzbarkeit, Effizienz und Portabilität, aber auch Kriterien zu Cybersicherheit und Datensouveränität formuliert.

Die **Einsatzbereitschaft** (engl. *operational readiness*) meint die subjektbezogene Bereitschaft der Stakeholder (Studierender und Lehrender) bezüglich des Einsatzes digitaler, intelligenter Technologien und Systeme. Diese umfasst etwa Akzeptanz, Vertrauen, Nutzung, Kompetenzen/Fähigkeiten, soziale Einflüsse etc. Sowohl Studierende als auch Lehrende sind im Bildungskontext Wissens- und Erfahrungsträger und tragen mit ihrer Haltung maßgeblich zur Einsatzbereitschaft von KI an Hochschulen bei.

Die **Transformationsbereitschaft** (engl. *transformational readiness*) bezieht sich auf die Bereitschaft der Hochschule auf gesellschaftliche Veränderungsprozesse zu reagieren und die organisationale Entwicklung hinsichtlich des Einsatzes von Technologien unter besonderer Berücksichtigung hochschulkultureller Rahmenbedingungen zu unterstützen. Hierfür werden die Adoption bzw. Diffusion von Technologien, organisationale Infrastrukturen, Governance & Compliance, Nachhaltigkeit sowie ethisch-rechtliche Regelungen in den Blick genommen.

Im Zusammenspiel zwischen **Technologie- und Einsatzbereitschaft** lassen die herausgearbeiteten Einflussfaktoren auf technischer/methodischer sowie individueller/akteursbezogener Ebene insbesondere Rückschlüsse zur *bildungstechnologischen Güte* bzw. Reife (z.B. soziotechnische Infrastruktur, KI-gestützte Settings etc.) der Hochschule zu.

Im Wechselspiel zwischen **Technologie- und Transformationsbereitschaft** lassen sich vor allem soziotechnische Indikatoren (z.B. Kontrolle, Legitimität, Erklärbarkeit, soziale Erwünschtheit etc.) verorten und Erkenntnisse zum *Grad der digitalen Transformation* der Hochschule erzielen.

Mit Blick auf die Wechselwirkungen zwischen **Einsatz- und Transformationsbereitschaft** lässt sich maßgeblich Auskunft über die *Dimensionierung kultureller Praktiken* der Hochschule geben (z.B. Digitalisierung der Lehr-Lernprozesse, medienpädagogische Praktiken, der Einfluss gesellschaftlicher Trends auf das akademische Lehren und Lernen etc.).

5 Implikationen und Fazit

Die Ausdifferenzierung des Implementierungspotentials in Technologie-, Einsatz- und Transformationsbereitschaft von Hochschulen weist einen hohen Komplexitätsgrad auf. In der Folge müssen auch die Zugänge zur Operationalisierung entsprechend vielseitig ausgestaltet sein. Das vorgestellte Modell versteht sich dabei zunächst als Handlungsrahmen, um die Einbindung von KI in das Hochschulsystem theoretisch-erklärend zu begleiten und dabei der Heterogenität der Bedarfe zu begegnen. Hierfür mangelt es allerdings noch an empirischer Evidenz. Um diese zu erreichen, wird das Modell im Rahmen des Verbundprojektes *tech4comp*² begleitend in die aktuelle Forschungspraxis übertragen, um eine erfolgreiche Implementierung von KI in der Hochschullehre zu unterstützen. Für die Beforschung des

2 Der transdisziplinäre BMBF-geförderte Forschungsverbund *tech4comp* setzt sich mit intelligenten Unterstützungstechnologien in der Hochschulbildung auseinander und stellt sich u.a. Fragen zu Gelingensbedingungen und Wirksamkeit digitaler Hochschulbildung, um prospektiv zur erfolgreichen Implementierung KI-basierter adaptiver Mentoringssysteme beizutragen (vgl. <https://tech4comp.de/>).

Einsatzes intelligenter Technologien und Systeme im Hochschulkontext wird auf einem Methodenmix sowohl aus reaktiven und non-reaktiven Verfahren als auch auf verschiedenen Forschungsansätzen der qualitativen und quantitativen Sozialforschung aufgebaut. Die diskutierten und zum Teil bereits eingesetzten Ansätze und Methoden zur Operationalisierung sind in der *Tabelle 1* überblickshaft dargestellt.

Tabelle 1: Ansätze und Methoden zur Operationalisierung und Bemessung.

	Technologiebereitschaft	Einsatzbereitschaft	Transformationsbereitschaft
Technologiebereitschaft	Technikevaluationen	Usability-Tests, User Experience (UX)-Forschung	Bereitschaftstests (AI Readiness), Technikfolgeabschätzung, Methoden der ethischen Evaluation
Einsatzbereitschaft	Usability-Tests, User Experience (UX)-Forschung	Learning Analytics & EDM, Akzeptanzforschung (UTAUT/TAM/KIAM) Mediennutzungs- & Kommunikationsstudien	Stakeholder- und Umfeldanalyse, Wirksamkeitsanalysen
Transformationsbereitschaft	Bereitschaftstests (AI Readiness), Technikfolgeabschätzung, Methoden der ethischen Evaluation	Stakeholder- und Umfeldanalyse, Wirksamkeitsanalysen	Academic Analytics & EDM, Adoptions- & Innovationsforschung, Benchmarkstudien, Key Performance-Analysen

Während einige dieser Ansätze und Methoden bereits in der Bildungs- und Hochschulforschung zum Einsatz kommen, haben andere ihren Ursprung primär in der angewandten Forschung u.a. im Unternehmenskontext und müssen entsprechend für den Hochschulkontext adaptiert werden. Anhand einiger Beispiele soll verdeutlicht werden, wie der Einsatz des vorgestellten Modells bedarfs- und kontextspezifisch erfolgen kann, um zur Bewertung des Implementierungspotentials von KI-Technologien beizutragen. Anschließend soll auf weiterführende Forschungsbedarfe sowie bestehende Limitationen des Modells bzw. seiner empirischen Anwendung eingegangen werden.

Eines der bewährtesten Instrumente zur Bewertung von Technologieentwicklungen sind Evaluationen zur Überprüfung vordefinierter Qualitätsmerkmale, wie Zuverlässigkeit, Funktionalität, Fehlertoleranz und Übertragbarkeit. Da es sich bei intelligenten Technologien und Systemen in der Regel um erst zu entwickelnde bzw. für den jeweiligen Kontext zu adaptierende Technologien handelt, lassen sich Technikevaluationen auch zur Bemessung der **Technologiebereitschaft**

anwenden (vgl. Tab. 1). So kann mittels dieser zunächst der Stand vorhandener technischer Infrastrukturen überprüft und der Frage nachgegangen werden, an welcher Stelle KI einzubetten ist. Im späteren Verlauf der Implementierung kann dieses zudem wiederum auf die genannten Qualitätsmerkmale hin überprüft werden, um beispielsweise sicherzustellen, dass das Zusammenspiel mit bestehender Infrastruktur (u.a. Lernmanagementsysteme) funktioniert.

Zur Operationalisierung der Bereitschaft von Studierenden und Lehrenden für den Einsatz von KI in der Hochschulbildung kann in umfassendem Maße auf bestehende Akzeptanzmodelle zurückgegriffen werden. Aus ihnen lassen sich die wichtigsten Einflussfaktoren für das hier im Modell benannte Konstrukt der **Einsatzbereitschaft** ableiten (vgl. Tab. 1). In der Forschungspraxis werden diese u.a. in einer Reihe von Kurzbefragungen integriert, die digital während Onlineveranstaltungen durchgeführt werden und Aufschluss über die Nutzungsintention Studierender und Lehrender geben sollen. In einer ganzheitlichen Befragung werden zudem Indikatoren zur Technik- und KI-akzeptanz operationalisiert, um das Einstellungsverhalten zu technologischen Artefakten (Chatbots, Recommender Systems wie Topic Recommender etc.) zu bemessen. Operationalisiert werden zudem spezielle Einflussfaktoren, die sich auf die KI als *wahrgenommene* Persönlichkeit sowie auf KI als Artefakt mit *Eigenlogik* während der Nutzung beziehen. Darüber hinaus werden Learning Analytics-Instrumente eingesetzt, um weitere Erkenntnisse über das Nutzerverhalten Studierender und Lehrender zu generieren.

Zur Bewertung der **Transformationsbereitschaft** lassen sich vor und während des Einsatzes von intelligenten Technologien und Systemen mittels Methodenmix Erkenntnisse erzielen (vgl. Tab. 1). Die Vielfalt an Informationen, die aus datengetriebenen Forschungsverfahren gewonnen werden, können Hochschulen Erkenntnisse dazu liefern, inwieweit intelligente Technologien und Systeme tatsächlich zum Studienerfolg beitragen. Großes Potential für die Nutzbarmachung komplexer Daten für Entscheidungsprozesse bieten *Frühwarnsystemen* sowie *Decision Support Systems*. Dennoch ist der Einsatz solcher Verfahren, z.B. von Academic Analytics, in der aktuellen Forschungspraxis mit enormen Herausforderungen (z.B. ethisch-rechtliche Rahmenbedingungen) verbunden, denen die Hochschulen in weiten Teilen noch nicht begegnen können. Um im Rahmen von *tech4comp* trotz dieser Hindernisse zu einer Bewertung der Transformationsbereitschaft beitragen zu können, werden hierzu zunächst Key Performance-Analysen unternommen sowie *Benchmarks* elaboriert bzw. für den Hochschulkontext adaptiert.

Kombiniert man die Methoden zur Bewertung der *Technologiebereitschaft* mit Instrumenten zur Bewertung der *Einsatzbereitschaft*, etwa aus der User Experience (UX)-Forschung oder der Usability-Forschung werden im Ergebnis Aussagen zum **Grad der bildungstechnologischen Reife** möglich. Um die KI auf ihre Funktionsfähigkeit sowie ihre Passung auf die konkreten Bedarfe des jeweiligen didaktischen Settings zu überprüfen, ist der Einsatz formativer Evaluationen, die sowohl for-

male Qualitätsstandards der entwickelten Technikinterventionen als auch die User Experience der Nutzenden in den Blick nehmen, dienlich.

Durch eine Verknüpfung von Methoden zur Bewertung der *Technologiebereitschaft* und Ansätzen zur Bemessung der *Transformationsbereitschaft* erhält man Auskunft zum **Grad der digitalen Transformation** an einer Hochschule. Eine besondere Herausforderung ist dabei die parallele Begleitung von technischer und organisationaler Implementierung. Mit Blick auf Governance und Compliance ist dies aber unabdingbar, um formale Prozesse sowie Rahmenvorgaben durch evidente Forschungsergebnisse mitzugestalten. Bereitschaftstests, Methoden der ethischen Evaluation (vgl. Weber 2019) und Ansätze der Technikfolgenabschätzung (z.B. Szenariomethode) tragen dazu bei, Risiken des KI-Einsatzes zu identifizieren (z.B. Diskriminierung, Blackboxing) und daran anschließend Einsatzbedingungen entsprechend zu verhandeln. Um eine nachhaltige Implementierung zu erreichen, muss das KI-basierte Lehr- Lernsetting u.a. rechtlichen Anforderungen und Rahmenbedingungen entsprechen. Dies erfordert auch die Formulierung von ethisch-rechtlichen Qualitätsstandards für intelligente Technologien und Systeme und somit auch die Weiterentwicklung des generellen Qualitätsmanagements an Hochschulen als wesentlicher Teil des Implementierungsprozesses. Auf diese Weise wird indirekt auch die Transformationsbereitschaft der Hochschulen vorangetrieben.

Die Kombination der Methoden der *Einsatz- und Transformationsbereitschaft* unterstützt die Bewertung der **Dimensionen kultureller Praktiken**. Führt man beispielsweise die Ergebnisse von Bereitschaftschecks und Akzeptanzerhebungen in umfassenderen Stakeholder- und Umfeldanalysen zusammen, lassen sich zahlreiche Informationen zu Bedarfen des Hochschulsystems und seiner Akteure identifizieren sowie potentielle Hindernisse für die Implementierung aufzeigen. Darüber hinaus können diese Bedarfserhebungen zur späteren Bewertung der Qualität und Wirksamkeit KI-basierter Lehr- und Lernsettings beitragen.

Zusammenfassend kann festgehalten werden, dass eine empirische Begleitung vor und während des Implementierungsprozesses von intelligenten Technologien und Systemen im Lehr- und Lernkontext an Hochschulen notwendig ist, um zur wirksamen und nachhaltigen KI-Implementierung in der Hochschulbildung beizutragen. Zur systematischen Bewertung dessen wurde hierzu ein soziotechnisches Modell entwickelt, das darauf abstellt, sowohl technische, organisationale als auch individuelle Einflussfaktoren in den Blick zu nehmen. Die Komplexität der Bewertung – von der Eigenlogik einer KI bis hin zu einflussnehmenden Kontextfaktoren und gesellschaftlichen Transformationsprozessen – macht deutlich, dass eine rein technisch vorangetriebene KI-Implementierung nur bedingt zum erfolgreichen Einsatz beitragen kann. Hierzu müssen neben den Technologien selbst, sowohl die Nutzenden in ihrem Nutzungsumfeld als auch bestehende soziotechnische Infrastrukturen frühzeitig in den Blick genommen werden, um die Akzeptanz auf Individualebene sowie die Bereitschaft auf organisationaler Ebene zu unterstützen.

Um Einflussfaktoren und Wirkmechanismen für den Hochschulkontext zu operationalisieren, wurde hierzu ein Methodenmix vorgeschlagen, der u.a. klassische Methoden der empirischen Sozialforschung, Instrumente der angewandten Forschung sowie datengetriebene Forschungsansätze kombiniert. In der aktuellen Forschungspraxis verlangt dies allerdings ein umfangreiches und transdisziplinäres *Know how*, um der Heterogenität der Voraussetzungen und Einflussfaktoren gerecht zu werden.

Weiterhin lässt sich auf Basis der bisherigen Ausführungen schlussfolgern, dass insbesondere durch das Zusammenspiel zwischen IT, Hochschuldidaktik und Qualitätsmanagement an Hochschulen, zur wirksamen KI-Implementierung sowie zu einer nachhaltigen Instrumentenentwicklung zur soziotechnischen Beforschung von KI in der Bildungs- und Hochschulforschung beigetragen werden kann. Zentrale Einrichtungen an Hochschulen sollten demnach gemeinsam zu Rate gezogen werden, um beispielsweise sicherzustellen, dass einzubettende intelligente Technologien und Systeme mit bereits bestehenden technischen und organisationalen Infrastrukturen kompatibel sind. Weiterhin können sie auch zur Überwachung bzw. Überprüfung der Funktionalität eingebetteter KI beitragen. Während die Hochschuldidaktik durch die Ausweitung ihrer Schulungs-, Austausch- und Informationsangebote maßgeblich die Einsatzbereitschaft Studierender und Lehrender beeinflussen kann, können im Qualitätsmanagement an die besonderen Herausforderungen der Implementierung intelligenter Technologien und Systeme angepasste Qualitätsstandards entwickelt und überprüft werden. Weiterhin zeigt das vorgestellte Modell auf, dass zudem der Austausch und die transdisziplinäre Zusammenarbeit zwischen diesen drei Hochschulinstitutionen maßgeblich dafür sein kann, KI-Implementierungen in der Hochschulbildung erfolgreich auszugestalten.

Cathleen M. Stützer: Technische Universität Dresden, Dezernat Planung und Organisation | Akademisches Controlling und QM; Cathleen.Stuetzer@tu-dresden.de

Stephanie Gaaw: Technische Universität Dresden, Zentrum für Qualitätsanalyse (ZQA)/Kompetenzzentrum für Bildungs- und Hochschulforschung (KfBH); Stephanie.Gaaw@tu-dresden.de

Sabrina Herbst, Technische Universität Dresden, Zentrum für Qualitätsanalyse (ZQA)/Kompetenzzentrum für Bildungs- und Hochschulforschung (KfBH); Sabrina.Herbst@tu-dresden.de

Norbert Pengel, Universität Leipzig, Institut für Bildungswissenschaften; Norbert.Pengel@uni-leipzig.de

Literatur

- Adams Becker, S., Cummins, M., Davis, A., Freeman, A., Hall Giesinger, C., & Ananthanarayanan, V. (2017). *NMC Horizon Report: 2017 Higher Education Edition*. Austin. https://www.unmc.edu/elearning/_documents/NMC_HorizonReport_2017.pdf (03.04.2021).
- Baker, R. S., & Inventado, P. S. (2014). Educational Data Mining and Learning Analytics. In J. A. Larusson & B. White (Hg.), *Learning Analytics: From Research to Practice* (S. 61–75). New York, NY: Springer New York.
- Breitenbach, A. (2021). *Digitale Lehre in Zeiten von Covid-19: Risiken und Chancen*. Marburg. <https://www.pedocs.de/volltexte/2021/21274/> (01.04.2021).
- Büching, C., Mah, D., Otto, S., Paulicke, P., & Hartmann, E. A. (2019). Learning Analytics an Hochschulen. In V. Wittpahl (Hg.), *Künstliche Intelligenz* (S. 142–160). Berlin, Heidelberg: Springer.
- Campbell, J. P., DeBlois, P., & Oblinger, D. (2007). Academic Analytics: A New Tool for a New. *EDUCAUSE Review*, 42(4), S. 40–57.
- CHE Centrum für Hochschulentwicklung (2020). *CHECK – Digitalisierung an deutschen Hochschulen im Sommersemester 2020*. Gütersloh. https://www.che.de/download/digitalisierung-hochschulen-2020/?ind=1594986398076&filename=CHECK_Digitalisierung_an_deutschen_Hochschulen_im_Sommersemester_2020.pdf&wpdmdl=15118 (01.04.2021).
- Deimann, M., Friedrich, J.D., Neubert, P., & Stelter, A. (2020). Das digitale Sommersemester 2020: Was sagt die Forschung? *Hochschulforum Digitalisierung*, https://hochschulforumdigitalisierung.de/sites/default/files/dateien/kurz_und_kompakt-Das_digitale_Sommersemester_2020.pdf (01.04.2021).
- de Witt, C., Rampelt, F., & Pinkwart, N. (2020). Künstliche Intelligenz in der Hochschulbildung. Berlin. *KI-Campus*, https://ki-campus.org/sites/default/files/2020-10/Whitepaper_KI_in_der_Hochschulbildung.pdf (01.04.2021).
- DFKI Deutsches Forschungszentrum für Künstliche Intelligenz (2020). *KI-Readiness-Check*. Berlin. <https://werner.dfki.de/readiness-welcome> (01.04.2021).
- Die Bundesregierung (2018). *Strategie Künstliche Intelligenz der Bundesregierung*. https://www.bmbf.de/files/Nationale_KI-Strategie.pdf (01.04.2021).
- Ferguson, R. (2012). Learning analytics: drivers, developments and challenges. *International Journal of Technology Enhanced Learning*, 4 (5/6), S. 304–317.
- Ferguson, R., Brasher, A., Clow, D., Griffiths, D., & Drachsler, H. (2016). Learning Analytics: Visions of the Future. In *Proceedings 6th International Learning Analytics and Knowledge (LAK) Conference*. <http://oro.open.ac.uk/45312/1/LAK16%20LACE%20panel%20final.pdf> (01.04.2021).
- Fürst, R. A. (2020). Digitale Bildung und künstliche Intelligenz in Deutschland: Nachhaltige Wettbewerbsfähigkeit und Zukunftsagenda. *AKAD University Edition*. Wiesbaden: Springer.

- Gasevic, D., Tsai, Y.S., Dawson, S., & Pardo, A. (2019). How do we start? An approach to learning analytics adoption in higher education. *International Journal of Information and Learning Technology*, 36(4), S. 342–353.
- Getto, B., Hintze, P., & Kerres, Michael (2018). (Wie) Kann Digitalisierung zur Hochschulentwicklung beitragen? Digitalisierung und Hochschulentwicklung. In Proceedings 26. Tagung Der Gesellschaft Für Medien in Der Wissenschaft (GMW), S. 13–25.
- Gilch, H., Beise, A. S., Krempkow, R., Müller, M., Stratmann, F. & Wannemacher, K. (2019). *Digitalisierung der Hochschulen. Ergebnisse einer Schwerpunktstudie für die Expertenkommission Forschung und Innovation*. Berlin: Expertenkommission Forschung und Innovation (EFI).
- Hansen-Casteel, S. (2020). *Indikatorenbasiertes Modell für die prospektive Technologieakzeptanz-Abschätzung*, RWTH Aachen. <http://publications.rwth-aachen.de/record/788930/files/788930.pdf> (01.04.2021).
- Hasenbein, M. (2020). Ethik in Zeiten von Digitalisierung und künstlicher Intelligenz. In *Der Mensch im Fokus der digitalen Arbeitswelt*, S. 183–200. Springer, Berlin, Heidelberg.
- Heumann, S., & Zahn, N. (2018). *Benchmarking National AI Strategies: Why and How Indicators and Monitoring Can Support Agile Implementation*. Berlin: Stiftung Neue Verantwortung. https://www.stiftung-nv.de/sites/default/files/benchmarking_ai_strategies.pdf (01.04.2021).
- Hochschulforum Digitalisierung (2016). The Digital Turn – Hochschulbildung im digitalen Zeitalter. *Arbeitspapier Nr. 27*. Berlin. <https://www.stifterverband.org/download/file/fid/2877> (01.04.2021).
- Intel Corporation (2018). *Das KI-Bereitschaftsmodell: So evaluieren Sie, ob ein Unternehmen mit künstlicher Intelligenz geschäftlichen Nutzen generieren kann*. <https://www.intel.de/content/dam/www/public/emea/de/de/documents/white-papers/ai-readiness-model-whitepaper-de.pdf> (01.04.2021).
- Kieslich, K., Lünich, M., Marcinkowski, F., & Starke, C. (2019). *Hochschule der Zukunft – Einstellungen von Studierenden gegenüber Künstlicher Intelligenz an der Hochschule*. https://diid.hhu.de/wp-content/uploads/2019/10/DIID-Precis_Kieslich-et-al_Fin.pdf (01.04.2021).
- Kirchherr, J., Klier, J., Lehmann-Brauns, C., & Winde, M. (2018). *Future Skills: Welche Kompetenzen in Deutschland fehlen*. Essen. <https://stifterverband.org/download/file/fid/6360> (01.04.2021).
- Limani, Y., Hajrizi, E., Stapleton, L., Retkoceri, M., & Stapleton L., Kopacek P., Topalov A. (2019). Digital transformation readiness in higher education institutions (HEI): The case of kosovo. *IFAC-PapersOnLine*, 52(25).
- Luttrell, R., Wallace, A., McCollough, C., & Lee, J. (2020). The Digital Divide: Addressing Artificial Intelligence in Communication Education. *Journalism & Mass Communication Educator*, 75(4), S. 470–482.

- Mazaraki, A., Drozdova, Y., & Bay, S. (2020). Theoretical and methodological principles for assessment the readiness of socio-economic systems for changes. *Baltic Journal of Economic Studies*, 6(1), S. 80–86. <http://www.baltijapublishing.lv/index.php/issue/article/view/769> (01.04.2021).
- Mühlhoff, R. (2019). Menschengestützte Künstliche Intelligenz. Über die soziotechnischen Voraussetzungen von »deep learning«. *Zeitschrift für Medienwissenschaft*, 11(2), S. 56–64.).
- Pedró, F., Subosa, M., Rivas, A., & Valverde, P. (2019). *Artificial intelligence in education: challenges and opportunities for sustainable development*. Paris: UNESCO. <https://www.gcedclearinghouse.org/sites/default/files/resources/190175eng.pdf> (01.04.2021).
- Pensel, S., & Hofhues, S. (2017). *Digitale Lerninfrastrukturen an Hochschulen. Systematisches Review zu den Rahmenbedingungen für das Lehren und Lernen mit Medien an deutschen Hochschulen*. Köln.
- Rohayani, A. Hetty, H., Kurniabudi, & Sharipuddin (2015). A Literature Review: Readiness Factors to Measuring e-Learning Readiness in Higher Education. *Procedia Computer Science*, 59(2), S. 230–234.
- Scheuer, D. (2020). *Akzeptanz von Künstlicher Intelligenz: Grundlagen intelligenter KI-Assistenten und deren vertrauensvolle Nutzung*. Wiesbaden: Springer.
- Schmohl, T., Löffl, J., & Falkemeier, G. (2019). Künstliche Intelligenz in der Hochschullehre. In T. Schmohl & D. Schäffer (Hg.), *TeachingXchange: Lehrexperimente der Hochschulbildung: Didaktische Innovationen aus den Fachdisziplinen* (2. Aufl., S. 117–122). Bielefeld: wbv. <https://core.ac.uk/download/pdf/343126556.pdf> (01.04.2021).
- Schumacher, F., Ademmer, T., Bültner, S., & Kneiphoff, A. (2021). Hochschulen im Lockdown. Lehren aus dem Sommersemester 2020, 4(58). *Hochschulforum Digitalisierung*, https://hochschulforumdigitalisierung.de/sites/default/files/dateien/HFD_AP_58_Hochschulen_im_Lockdown.pdf (01.04.2021).
- Seufert, S., Guggemos, J., & Moser, L. (2019). Digitale Transformation in Hochschulen: auf dem Weg zu offenen Ökosystemen. *Zeitschrift für Hochschulentwicklung*, 14(2), S. 85–107.
- Seufert, S., Guggemos, J., & Sonderegger, S. (2020). Digitale Transformation der Hochschullehre: Augmentationsstrategien für den Einsatz von Data Analytics und Künstlicher Intelligenz. *Zeitschrift Für Hochschulentwicklung*, 15(1), S. 81–101.
- Seyfeli, F., Elsner, L., & Wannemacher, K. (2020). *Vom Corona-Shutdown zur Blended University?: ExpertInnenbefragung Digitales Sommersemester*. Baden-Baden: Tectum. https://www.tectum-elibrary.de/10.5771/9783828876484.pdf?download_full_pdf=1 (01.04.2021).
- Simmel, G. (1890). *Über sociale Differenzierung*. Sociologische und psychologische Untersuchungen. Leipzig: Duncker & Humblot.

- Stuetzer, C. M., Breiger, R., & Koehler, T. (2013, August). Social Academic Analytics in Higher Education. In Proceedings *Social Media 2013-18th International Education Technology Conference*, Hong Kong.
- Stützer, C. M. (2017). *Academic Analytics: Zur Bedeutung von (Big) Data Analytics in der Evaluation*. Gesellschaft für Evaluation e.V. DeGEval – Jahrestagung 2017, Mainz. https://www.degeval.org/fileadmin/jahrestagung/Mainz_2017/Externe_Posterpraesentation/Poster_DEGEVAL2017_Stuetzer_fertig.pdf (01.04.2021).
- van Ackeren, I., Bilo, A., Blotevogel, U., Gollan, H., Heinrich, Sandrina, Hintze, Patrick, Liebscher, Julia, & Petschenka, A. (2018). Vom Strategiekonzept zur Entwicklung der Lehr-/Lernkultur?: Ein Überblick über bisherige Rahmenbedingungen und Maßnahmen der E-Learning Strategie. *Flexibles Lernen mit digitalen Medien ermöglichen – Strategische Verankerung und Erprobungsfelder guter Praxis an der Universität Duisburg-Essen*, S. 35–55.
- van Deursen, A. (2020). Digital Inequality During a Pandemic: Quantitative Study of Differences in COVID-19–Related Internet Uses and Outcomes Among the General Population. *Journal of Medical Internet Research*, 22(8).
- Weber, K. (2019). Methoden der ethischen Evaluation von IT. Draude, C.; Lange, M.; Sick, B. (Hg.): *INFORMATIK 2019: 50 Jahre Gesellschaft Für Informatik – Informatik Für Gesellschaft* (Workshop-Beiträge), S. 431–444.
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16(39), S. 1–27. <https://educationaltechnologyjournal.springeropen.com/articles/10.1186/s41239-019-0171-0> (01.04.2021).

Ethische Perspektiven auf Künstliche Intelligenz im Kontext der Hochschule

Dirk Ifenthaler

Abstract: *Im Kontext der Hochschule werden vermehrt Daten und Algorithmen zur Unterstützung von Lernen und Lehren, für Assessments, zur Weiterentwicklung von Curricula sowie zur Optimierung von Hochschulserviceangeboten eingesetzt. Frühzeitig wurde das Spannungsfeld von Künstlicher Intelligenz (KI) in der Hochschule zwischen Potentialen und ethischen Grundsätzen erkannt. Vorliegende konzeptionelle und empirische Beiträge zu Ethik und KI im Kontext der Hochschule zeigen, dass Datenschutz und Persönlichkeitsrechte einen zentralen Problembereich bei der Implementation von KI darstellen. Aus holistischer Sicht eröffnet der vorliegende Beitrag ethische Perspektiven auf KI im Hochschulbereich. Hochschulen müssen sich der Datenschutzthemen und ethischen Leitprinzipien, die in Verbindung mit KI stehen, annehmen. Ein Kernproblem beim Einsatz von KI in Hochschulen ist die Kontextabhängigkeit, Fragmentierung und Verzerrung verfügbarer Daten. Ziel der aktuellen Forschung sind Systeme mit KI, die theoretisch fundierte und transparente Datenanalysen mit pädagogisch relevanten Indikatoren und verlässlichen Interventionen ermöglichen. Es wird ein Diskurs um ethische Leitprinzipien im Zusammenhang mit KI im Kontext der Hochschule angeregt. Daraus sollen auf KI basierte Fehlentscheidungen vermieden und Schäden für Beteiligte der Hochschulen abgewendet werden.*

In the context of higher education, data and algorithms are increasingly being used to support learning and teaching, for assessments, for the further development of curricula and to optimize university service offers. The tension between the potential of artificial intelligence (AI) and ethical principles was recognized at an early stage. Existing conceptual and empirical contributions on ethics and AI in the context of higher education show that data protection and personal rights represent a key concern in the implementation of AI. From a holistic point of view, this contribution opens up ethical perspectives on AI in the context of higher education. Universities need to address the privacy issues and guiding ethical principles associated with AI. Key issues interrelated with the use of AI in higher education are the contextual idiosyncrasies and dependency as well as fragmentation and distortion of available data. The aim of current research are AI systems that enable theoretically sound and transparent data analyzes with pedagogically relevant indicators and reliable interventions. A discourse on ethical guiding principles in connection with AI in the context of higher education is encouraged. This

should avoid wrong decisions based on AI and prevent damage to those involved in the higher education arena and beyond.

Keywords: Hochschule, Ethik, Künstliche Intelligenz, Learning Analytics / Higher Education, Ethics, Artificial Intelligence, Learning Analytics.

Ethische Perspektiven auf Künstliche Intelligenz im Kontext der Hochschule

Video: <https://link.transcript-open.de/5769/video/003>

© Dirk Ifenthaler



1 Einleitung

Künstliche Intelligenz (KI) hält mit einer atemberaubenden Geschwindigkeit und nahezu unbegrenzten Möglichkeiten Einzug in das Alltagsleben der Menschen. Tägliche Berührungspunkte mit KI sind u.a. Muster-, Bild- und Spracherkennung, Autovervollständigung oder Korrekturvorschläge bei digitalen Suchanfragen. Seit den 1950er Jahren wird KI nicht nur in der Ursprungswissenschaft Informatik, sondern auch interdisziplinär in Fachrichtungen wie Philosophie, Kognitionswissenschaft, Neurowissenschaft sowie Ökonomie rezipiert (Tegmark, 2018). KI bezeichnet den Versuch Maschinen zu entwickeln, welche Dinge tun können, die zuvor nur durch menschliche Kognition möglich waren (Zeide, 2019). Im Gegensatz zu Menschen können KI-Systeme jedoch eine um vielfaches größere Datenmengen in Echtzeit verarbeiten (De Laat, Joksimovic & Ifenthaler, 2020). Seit Beginn der 2010er werden auch im Kontext der Hochschule vermehrt Daten und Algorithmen zur Unterstützung von Lernen und Lehren, für Assessments, zur Weiterentwicklung von Curricula sowie zur Optimierung von Hochschulserviceangeboten eingesetzt (Pinkwart & Liu, 2020). Eine systematische Übersichtsarbeit von Zawacki-Richter, Marín, Bond und Gouverneur (2019) zeigt verschiedene Anwendungsfelder von KI im Kontext der Hochschulbildung auf: (a) die Modellierung von Studieren-

enddaten, um Vorhersagen über den Studienerfolg bzw. den Studienabbruch zu treffen; (b) intelligente Tutorensysteme, welche Lernartefakte präsentieren oder Hilfestellungen und Rückmeldungen geben; (c) adaptive Systeme, welche Lernprozesse unterstützen und im Bedarfsfall Vorschläge für Lernunterstützungen anbieten; (d) automatisierte Prüfungssysteme zur Klassifikation von Lernleistungen. Darüber hinaus werden (e) Unterstützungsfunktionen im Bereich pädagogischer Entscheidungen von Lehrenden (Arthars et al., 2019) sowie der (f) Weiterentwicklung von Kursinhalten und Curricula implementiert (Ifenthaler, Gibson & Dobozy, 2018a). Zu den Potentialen von KI im Kontext der Hochschule liegen jedoch nur wenige belastbare empirische Studien hinsichtlich deren Wirkung vor (Ifenthaler & Yau, 2020). Auch stehen systemweite Implementierungen der unterschiedlichen KI-Anwendungsfelder im Hochschulkontext derzeit nach aus (Gibson & Ifenthaler, 2020; Ifenthaler, 2020a). Darüber hinaus sind KI Anwendungen im Alltag von Stakeholdern der Hochschule denkbar, wie z.B. die Unterstützung bei Bewerbungs- und Verwaltungsprozessen.

Frühzeitig wurde das Spannungsfeld von KI in der Hochschule zwischen Potentialen und ethischen Grundsätzen erkannt (Slade & Prinsloo, 2013). Ifenthaler und Tracey (2016) führten den Diskurs um ethische Fragen, Datenschutz und Privatheit von Daten im Rahmen von KI-Anwendungen weiter. Die vorliegenden konzeptionellen und empirischen Beiträge zu Ethik und KI im Kontext der Hochschule zeigen, dass Datenschutz und Persönlichkeitsrechte einen zentralen Problembereich in der Implementierung von KI darstellen.

Der vorliegende Beitrag eröffnet ethische Perspektiven auf KI im Kontext der Hochschule. Zunächst werden KI und deren Anwendungsfelder in der Hochschule beleuchtet. Darauf aufbauend werden Ethikansätze im Zusammenhang mit KI in der Hochschule diskutiert und mit praktischen Ansätzen verknüpft. Zuletzt folgt ein Ausblick und damit verbundene Forschungsperspektiven.

2 Künstliche Intelligenz in der Hochschule

Dem Einsatz von KI wird ein disruptiver Innovationsschub innerhalb der digitalen Transformation von Hochschulen beigemessen. Dabei gilt es, das Konstrukt KI näher zu bestimmen und Anwendungsfelder der KI im Kontext der Hochschule herauszuarbeiten.

2.1 Das Konstrukt Künstliche Intelligenz

Aus konzeptueller Sicht bezeichnet KI die Abfolge und Anwendung von Algorithmen, welche bestimmte Befehle für die Transformation eines Daten-Inputs zu einem Daten-Output ermöglichen. Folgt man der Definition von Graf Ballestrem, Bär,

Gausling, Hack und von Oelffen (2020) ist mit KI ein System gemeint, welches intelligentes Verhalten zeigt, indem es die Umgebung analysiert und mittels gewisser Freiheitsgrade gezielte Maßnahmen ergreift, um spezifische Ziele zu erreichen. In diesem Zusammenhang wird intelligentes Verhalten mit der menschlichen Kognition in Verbindung gebracht. Dabei stehen die menschlichen kognitiven Funktionen wie Entscheidungsfindung, Problemlösen und Lernen im Vordergrund (Bellman, 1978). KI sind folglich von Menschen entwickelte Maschinen, die komplexe Ziele (teil-)autonom erreichen können. Durch Anwendung von Techniken des maschinellen Lernens werden diese Maschinen immer mehr in die Lage versetzt, die Anwendungsumgebung und deren Kontext zu analysieren und sich an veränderte Rahmenbedingungen anzupassen (De Laat et al., 2020).

Daugherty und Wilson (2018) analysieren das Zusammenwirken von Menschen und KI. Dabei identifizierten sie drei Tätigkeitsfelder: (a) Tätigkeiten, welche von Menschen ausgeführt werden, z.B. Teams führen, Standpunkte verdeutlichen, Dinge erschaffen oder Situationen beurteilen. (b) Tätigkeiten, welche von Maschinen ausgeführt werden, z.B. Prozesse durchführen und beliebig wiederholen, Zielzustände prognostizieren oder Abläufe anpassen. Dazwischen befinden sich die (c) Mensch-Maschine-Allianzen. Menschen werden in dieser Allianz benötigt, um KI-Systeme zu entwickeln, zu trainieren und zu managen – zu befähigen. Maschinen erweitern in dieser Allianz die Fähigkeiten der Menschen, um große Datenmengen aus unzähligen Quellen in (nahezu) Echtzeit zu analysieren. In diesen Allianzen sind Menschen und Maschinen keine Konkurrenten, vielmehr werden sie zu symbiotischen Partnern, welche sich gegenseitig zu höheren Leistungen antreiben. Der Paradigmenwechsel von Computern als Werkzeuge hin zu Computern als Partnern differenziert sich in unterschiedlichen Anwendungsfeldern immer weiter aus (Wesche & Sonderegger, 2019), auch im Kontext der Bildung.

2.2 Künstliche Intelligenz im Kontext der Hochschule

Folgt man den Analysen von Bates, Cobo, Mariño und Wheeler (2020) verharret KI im Kontext der Hochschule als schlafender Riese. Trotz der großen Aufmerksamkeit für das Thema KI in Hochschulen bleibt die praktische Anwendung von KI hinter den antizipierten Potentialen weit zurück (Buckingham Shum & McKay, 2018). Als Gründe werden Defizite in organisatorischen Strukturen sowie mangelnde personelle und technologische Ausstattungen der Hochschulen genannt (Ifenthaler, 2017). Abbildung 1 stellt für KI vier Reifegrad-Stufen und deren zusammenhängende Wirkkraft für Hochschulen vor:


- *Wahrnehmungsphase:* Aktuell befindet sich die Mehrzahl von Hochschulen in der Wahrnehmungsphase von KI. Analysen aus Datenbanken zu Lernergebnissen

und Lernverhalten werden durchgeführt und einfache Berichte aus diesen Analysen für ausgewählte Stakeholder erstellt.

- *Experimentierphase*: In der Experimentierphase zu KI befinden sich eine ständig wachsende Zahl an Hochschulen. Dabei werden die manuell erstellten Berichte aus der Wahrnehmungsphase in Dashboards überführt und einem erweiterten Stakeholderkreis zur Verfügung gestellt. Für umfassendere Analysen werden Daten aus mehreren Systemen zusammengeführt und berichtet.
- *Implementationsphase*: Hochschulen in der Implementationsphase von KI sind nur wenige aufzufinden. In dieser Phase wird die Wirkkraft für mehrere Stakeholder (Lernende, Lehrende etc.) mittels spezieller Dashboards erreicht. Darüber hinaus werden adaptive Unterstützungen in nahezu Echtzeit (d.h. wenn Unterstützungsbedarf besteht) angeboten.
- *Transformationsphase*: Die Transformationsphase setzt eine organisationsweite Implementation von KI voraus, welche zu einer Veränderung der Lernkultur in der Hochschule führt und einen offenen Informationsaustausch unter allen Stakeholdern fördert.

Trotz der zögerlichen Implementierung birgt KI weit mehr Potentiale um die Hochschulen zu verändern, als jede Technologie zuvor. Durch KI ermöglichte Potentiale für Hochschulen sind u.a. die Erweiterung von Hochschulzugängen, die Steigerung von Studienerfolg, die Verbesserung des Studienverbleibs, die Senkung von Kosten und die Verringerung der Studiendauer. Die Anwendung von KI-Systemen im Kontext der Hochschule kann mindestens zwei Ebenen zugeordnet werden (Bates et al., 2020).

Abbildung 1: Reifegrad und Wirkkraft von künstlicher Intelligenz im Kontext der Hochschule (eigene Darstellung).



Die erste Ebene zielt auf institutionelle Prozesse. Hierzu zählen skalierbare Anwendungen zur Bewältigung von Bewerbungs- und Zulassungsverfahren (Adekintan & Noma-Osaghae, 2019) sowie KI-basierte Unterstützung für Studienberatungen und -services (Jones, 2019a). Ein weiteres Anwendungsfeld zielt auf die Identifikation von Risikostudierenden und die Vermeidung von Studienabbrechenden ab (Azcona, Hsiao & Smeaton, 2019; Hinkelmann & Jordine, 2019; Russell, Smith & Larsen, 2020).

Die zweite Ebene zielt auf die Unterstützung von Lern- und Lehrprozessen ab. Hierzu zählt die Empfehlung relevanter nächster Lernschritte und Lernmaterialien (Schumacher & Ifenthaler, 2021), die Automatisierung von Assessments und Feedback (Ifenthaler, Greiff & Gibson, 2018b), Förderung der Reflektion und des Bewusstseins über den Lernprozess (Schumacher & Ifenthaler, 2018), soziales Lernen zu unterstützen (Gašević, Joksimović, Eagan & Shaffer, 2019), unerwünschtes Lernverhalten und -schwierigkeiten aufzuspüren (Nespereira, Vilas & Redondo, 2015), den aktuellen Gefühlszustand der Lernenden ausfindig zu machen (Taub et al., 2020) sowie den Lernerfolg vorherzusagen (Glick et al., 2019). Auch werden KI-Systeme für die Qualitätssicherung von Curricula und den dazugehörigen didaktischen Arrangements (Ifenthaler et al., 2018a) sowie zur Unterstützung von Lehrenden verwendet (Arthars et al., 2019).

Um diese und weitere Implementierungen entwickeln zu können, müssen KI-Systeme auf umfangreiche Daten (Big Educational Data) aus verschiedenen Kontexten bzw. Datenquellen der Hochschulen zugreifen. Yau und Ifenthaler (2020) konnten als Ergebnis einer systematischen Übersichtsarbeit ein umfangreiches Spektrum an Indikatoren für spezifische KI-Anwendungen wie folgt identifizieren:

- Eine Gruppe von KI-Indikatoren basiert auf Daten, die durch Online-Verhalten gesammelt wurden, hauptsächlich Logfiles und Trace-Data. Dies sind Forumsinteraktionen (z.B. Beiträge, Antworten, Länge der Beiträge), der Zugriff auf Lernartefakte (z. B. ePortfolio, Vortragsfolien, Videos, Aufgaben, Selbsteinschätzungen) und die allgemeine Interaktion mit einer digitalen Lernumgebung auf der Grundlage von Logfiles.
- In ähnlicher Weise werden Daten von Websites oder Lernmanagementsystemen (z.B. ereignisbasierte Zeitstempel) in Kombination mit Noten zur Vorhersage des Abbrecherrisikos von Lernenden verwendet, wobei die detaillierte Analyse von Clickstream- oder Trace-Daten auch zur Vorhersage von Studienabbruch, Lernprozessen oder Lernleistungen verwendet wird.
- Andere Faktoren, welche für die Identifikation und Vorhersage von Lernerfolg verwendet werden basieren auf Informationen über die Lernenden wie z.B. demografische Daten (z.B. Alter, Geschlecht), sozioökonomischer Status (z.B.

Familieneinkommen, Hintergrund, Ausgaben) oder vorherige akademische Erfahrung und Leistung.

- Zusätzlich zu demografischen Variablen werden das akademische Selbstkonzept von Lernenden, die akademische Historie und arbeitsbezogene Daten zur Vorhersage der Lernleistung verwendet.
- Andere KI-Systeme analysieren den Notendurchschnitt (GPA), die akademische Belastung und den Zugang zur Beratung, den finanziellen Hintergrund der Lernenden oder vorhergehende akademische Leistungen.
- Daten, welche durch Umfragen erhoben wurden, wie z.B. die Selbstauskunft der Lernenden über erwartete Noten, die (Lern-)Motivation sowie die akademische und technologische Kompetenz bilden eine weitere Gruppe der Datenanalysen.
- Schließlich konnten Faktoren identifiziert werden, welche auf multimodaler Basis gebildet werden, d.h. sie verwenden Daten aus verschiedenen Quellen, wie z.B. Logfiles oder Trace-Data (nicht reaktive Datenerhebung), Bewertungen und Umfragedaten (reaktive Datenerhebung), sowie aus aggregierten Informationen oder historischen Daten.

Im Hinblick auf die Vielzahl und Vielfaltigkeit der notwendigen Daten für KI-Systeme, müssen sich Stakeholder der Hochschulen der Themen annehmen, die in Verbindung mit KI stehen (Ifenthaler & Tracey, 2016; West, Huijser & Heath, 2016). Dazu gehören Zugriffsrechte, Speicherdauer, Analysen und Schlussfolgerungen. KI-Systeme greifen dabei auf Daten aus verschiedenen Kontexten zu, etwa aus der Studierenden-, Studien- und Prüfungsverwaltung, der Lernumgebung oder sozialen Interaktionen. Die Bereitschaft Daten preiszugeben, kann in den jeweiligen Kontexten unterschiedlich ausgeprägt sein. Entsprechend den Annahmen der »kontextuellen Integritätstheorie« sind Informationen, die in einem spezifischen Kontext preisgegeben wurden, nicht übertragbar auf einen anderen Kontext, ohne die Bedeutung zu beeinträchtigen oder die Privatsphäre zu verletzen (Ifenthaler & Schumacher, 2016). Datenschutzprinzipien für KI-Systeme unterstreichen dabei die aktive Rolle der Studierenden in ihren Lernprozessen, den temporären Charakter und die Unvollständigkeit von vorhandenen Daten sowie insbesondere Transparenz hinsichtlich Nutzung, Analysen, Zweck, Zugriff, Kontrolle und Eigentumsverhältnisse der anfallenden Daten (Hoel & Chen, 2018; Jones, 2019b). Neben Standards zur Sicherung der Privatsphäre und zum Datenschutz unter Einhaltung der EU-DSGVO sowohl für Einzelpersonen als auch für die Hochschule werden Richtlinien zur Einhaltung von ethischen Gesichtspunkten benötigt.

3 Ethische Perspektiven auf künstliche Intelligenz in der Hochschule

Neben datenschutzrechtlichen Anforderungen an künstliche Intelligenz ethische Aspekte eine notwendige Basis für aktuelle und zukünftige Implementierungen im Kontext der Hochschule. Zum ethischen Grundverständnis im Umgang KI gehören Rechenschaft, Verantwortung und Transparenz. Auch Bedarf es einfacher Instrumente für Hochschulen, um das Bewusstsein der involvierten Stakeholder rund um Ethik in Verbindung mit KI zu steigern.

3.1 Ethikansätze

Ethikansätze fanden ihren Ursprung bei den antiken griechischen Philosophen, welche sich mit der Frage beschäftigt haben, wie durch moralisch verantwortungsvolles Handeln ein gutes Leben geführt werden kann. Dabei bezieht sich diese grundsätzliche ethische Fragestellung sowohl auf die Einzelperson als auch auf Personengruppen, Organisationen bzw. die Gesellschaft. Folglich ist Ethik die Theorie der Moral und Moral die praktische Anwendung von Ethik (Hasenbein, 2020). Ethische Grundsätze und moralische Entscheidungen finden sich im gesamten Spektrum menschlichen Handelns. Eine sehr vereinfachte Konzeption von Ethik berücksichtigt moralische Entscheidungen, welche von einzelnen Personen bzw. der Gesellschaft als gut bzw. richtig betrachtet werden. Demgegenüber stehen schlechte bzw. falsche moralische Entscheidungen. Die konsequentialistische Ethik bevorzugt diejenigen Handlungen, welche für einen möglichst großen Personenkreis positive Auswirkungen erzeugen. Die deontologische Ethik bemüht sich hingegen um Regeln und Pflichten für spezifische Handlungssituationen. Dennoch entstehen für Beteiligte in moralischen Entscheidungssituationen immer wieder Dilemmata, deren Auflösung nicht immer vollumfänglich möglich ist (Kvalnes, 2015).

Seit geraumer Zeit beschäftigen sich Ethikansätze auch mit dem digitalen Wandel (Berberich, 2019). Von zentralem Interesse ist das moralisch angemessene Verhalten mit und von digitalen Systemen. Die sogenannte digitale Ethik bzw. KI-Ethik fokussiert Fragen zum guten und richtigen Leben und Zusammenleben in einer von digitalen Technologien und KI-Systemen geprägten Welt (BVDW, 2019). Im Zentrum ethischer Fragen im Zusammenhang mit KI steht die Fähigkeit der Maschine, moralisch zu handeln. Durch moralisch geprägte Algorithmen soll den Maschinen die Möglichkeit gegeben werden, Prozesse und Analysen entlang ethischer Prinzipien zu regulieren. Die umfassenden Fragestellungen der KI-Ethik werden von interdisziplinär Forschenden und zukünftig nutzenden Personen aus den Anwendungsbereichen diskutiert. Ziel des Diskurses muss es sein, ethische Leitlinien für moralisch akzeptiertes Handeln mit und für KI-Systeme zu entwickeln (Hasenbein, 2020).

Mit der Anwendung von KI-Systemen bleiben deren Ergebnisse und Vorhersagen für Einzelpersonen oder die Gesellschaft nicht immer erklärbar und im Einzelnen vollständig nachvollziehbar. Dellermann, Ebel, Söllner und Leimeister (2019) plädieren daher für eine erklärbare, faire, sichere und transparente KI (engl. Explainable Artificial Intelligence). Aus diesem Anspruch werden KI-Systeme gefordert, welche für die Beteiligten jederzeit nachvollziehbar sind und somit eine Diskriminierung ausschließen. Der Diskurs um ethische Fragen zu KI lässt sich auf spezifische Anwendungsfelder und -situationen übertragen. Dazu zählen KI-basierte Alltagsanwendungen wie die Wahl eines TV-Programms für Kinder, Alltagssituationen wie die eines autonomen Fahrzeugs im Straßenverkehr, komplexe medizinische KI-Anwendungen im Intensivbereich aber auch vielfältige KI-Anwendungen und Situationen in der Hochschulbildung.

3.2 Ethisch reflektierte Anwendung künstlicher Intelligenz im Kontext der Hochschule

Charakteristisch für KI-Systeme im Kontext der Hochschule sind deren Autonomie, Interaktivität und Adaptabilität. Diese Eigenschaften ermöglichen eine effektive Bewältigung der dynamischen und vielfach unvollständig erfassbaren Lern-Lehr-Prozesse. Jedoch sind KI-Systeme mit diesen Eigenschaften schwer einzuschätzen und deren Vorhersagen bzw. Empfehlungen können zu unerwartetem Verhalten bzw. ungewollten Aktivitäten führen (Black-Box). Slade und Prinsloo (2013) haben in diesem Zusammenhang holistische Kriterien für KI-Anwendungen im Kontext der Hochschule formuliert. Dazu zählen Transparenz, Besitz, Zugang und Kontrolle über Daten, Validität und Reliabilität von Daten, institutionelle Kommunikation, Verantwortung und Verbindlichkeit, Inklusion und Einverständnis sowie kulturelle Werte und Handlungskompetenz der Stakeholder. Dignum (2017) integriert die Vielzahl ethischer Kriterien in den sogenannten ART-Prinzipien (Accountability, Responsibility, Transparency).

- Rechenschaft (Accountability) bezieht sich auf die Anforderung, KI-Entscheidungen und KI-Handlungen allen Beteiligten zu erklären und zu rechtfertigen. Dafür müssen KI-Entscheidungen aus den verwendeten Algorithmen ableitbar und nachvollziehbar sein. Die Rechenschaft ist notwendig, um Vertrauen in die Verwendung von KI zu fördern und wird auch im Rahmen der EU-DSGVO gefordert. Die Rechenschaft sollte auf moralischen und sozialen Prinzipien beruhen, einschließlich geltender Werte, sozialer Normen, organisatorischer Gewohnheiten und individueller Motive und Ziele (Miller, 2019).
- Verantwortung (Responsibility) bezieht sich auf die Rolle der Beteiligten selbst im Umgang mit KI-Systemen. Verantwortung meint dabei jedoch nicht nur das Regulieren von intelligenten Maschinen, vielmehr muss geklärt werden, wie mit

aus KI-Systemen erzeugten Daten umgegangen wird und in welchem Umfang diese geteilt werden können. Verantwortung bedeutet nachhaltige Strukturen für Mensch-Maschine-Allianzen in einer KI-geprägten Gesellschaft zu etablieren.

- Transparenz (Transparency) bezieht sich auf die Notwendigkeit, die Mechanismen zu beschreiben, zu prüfen und zu reproduzieren, mittels derer KI-Systeme Lernen und Entscheidungen treffen. Um Klarheit über Daten und Algorithmen zu schaffen, bedarf es speziellen Methoden, welche KI-Prozesse und deren Ergebnisse für die Beteiligten analysierbar machen. Transparenz erfordert die Minimierung bzw. Ablösung der algorithmischen Black-Box.

Hochschulen müssen sich der ART-Prinzipien annehmen und einen verantwortungsvollen, transparenten sowie erklärbaren Umgang mit KI-Systemen gewährleisten. Erste Studienergebnisse weisen darauf hin (Howell, Roberts, Seaman & Gibson, 2018; Ifenthaler & Schumacher, 2016; West et al., 2016), dass Studierende trotz antizipierter Vorteile nicht bereit sind, alle Daten für KI-Anwendungen preiszugeben. Es wird zwar Bereitschaft signalisiert, lernbezogene Daten zu teilen, nicht aber persönliche Informationen oder soziale Nutzerpfade. Insbesondere bei der Implementierung der vielseitig geforderten adaptiven KI-Systeme, welche auf eine Vielzahl an Daten angewiesen sind, bleibt dies ein kritischer Aspekt.

Richards und Dignum (2019) schlagen einen wertefokussierten Design-Ansatz vor, welcher ethische Prinzipien in jeder Phase der Entwicklung und Verwendung von KI-Systemen für Hochschulen berücksichtigt. Diesem Ansatz folgend müssen für KI-Systeme an Hochschulen (a) relevante Stakeholder bestimmt werden; (b) Werte und Anforderungen der Beteiligten ermittelt werden; (c) Möglichkeiten zur Aggregation der Werte und Werteinterpretation aller Beteiligten bereitgestellt werden; (d) Verknüpfung von Werten und Systemfunktionalitäten zur Unterstützung von Implementierungsentscheidungen sowie einer nachhaltigen Anwendung gewährleistet werden; (e) Unterstützung bei der Auswahl von Systemkomponenten (von innerhalb oder außerhalb der Organisation) vor dem Hintergrund ethischer Prinzipien angeboten werden.

Werden zukünftige KI-Systeme in Entscheidungsprozesse der Hochschulen involviert, z.B. in Zulassungsverfahren oder für automatisierte Prüfungsverfahren, erfolgt eine Übertragung der Entscheidungsprozesse auf KI-Systeme (Prinsloo & Slade, 2014; West et al., 2016; Willis, Slade & Prinsloo, 2016). Die Verantwortung wird an Algorithmen abgegeben. Hochschulen und deren Beteiligte werden folglich vor dem Hintergrund ethischer Prinzipien entscheiden, ob diese Verantwortung an KI delegiert werden kann. Gleichzeitig müssen die Beteiligten an der jeweiligen Hochschule beurteilen, in wieweit KI-Systeme in der Lage sind, Verantwortung für die getroffenen Entscheidungen zu übernehmen.

3.3 Checkliste für Ethik und Datenschutz an Hochschulen

Schließlich liegt es an den einzelnen Hochschulen, ethische und datenschutzrechtliche Richtlinien und Maßnahmen für die Nutzung von KI einzuführen (Hoel & Chen, 2018; Jones, 2019b). Die sogenannte DELICATE (Determination, Explain, Legitimate, Involve, Consent, Anonymise, Technical, External) Checkliste (Drachsler & Grelle, 2016; Ifenthaler & Drachsler, 2020) bietet ein einfaches Instrument für Hochschulen, um das Bewusstsein der Stakeholder einer Hochschule rund um Ethik und Datenschutz in Verbindung mit KI zu steigern. DELCIATE möchte helfen, das Thema zu demystifizieren und aus der komplexen Welt von juristischen Texten zu extrahieren, um es in der Hochschule verständlich und praktikabel zu machen (Ifenthaler & Drachsler, 2020). In Anlehnung an die DELICATE Checkliste sollen Hochschulen mit KI-Systemen folgende Prinzipien umsetzen (Ifenthaler, 2020b):

- *Begründung* (Determination): Das Potential von KI und Datenanalysen im Allgemeinen sowie Learning Analytics im Besonderen wird aus Sicht der Organisation und der einzelnen Stakeholdergruppen verdeutlicht. Aktuell geltende Datenschutzrechte werden umgesetzt.
- *Erklärung* (Explain): Eine transparente Speicherung und Analyse von Daten und Klarstellung derer Verwendungszwecke wird sichergestellt. Auskünfte bezüglich Speicherdauer und Zugriffsrechten werden in allen Fällen der Datenspeicherung bzw. -analyse gewährleistet.
- *Legitimation* (Legitimate): Die Notwendigkeit der Datennutzung sowie die Erlaubnis auf Daten zugreifen zu können sind legitimiert.
- *Einbeziehung* (Involve): Jegliche Datenschutzbedenken werden transparent kommuniziert und vollständig geklärt. Individueller Zugang zu gespeicherten Daten wird ermöglicht. Informations- und Weiterbildungsangebote für alle Stakeholder sind verfügbar.
- *Einverständnis* (Consent): Individuelle Stakeholder müssen aktiv der Datennutzung, -speicherung und -analyse zustimmen (opt-in). Das Einverständnis der Datennutzung kann jederzeit widerrufen werden.
- *Anonymisierung* (Anonymise): Daten werden im höchstmöglichen Maß anonymisiert, pseudonymisiert oder aggregiert.
- *Aktualisierung* (Technical): Der Datenzugriff wird permanent geprüft. Bei technischen oder organisatorischen Veränderungen wird ein erneutes Einverständnis bei den Stakeholdern eingeholt. Technische Systeme sind auf aktuellem technologischen Stand.
- *Distribution* (External): Externe Zugriffe auf Daten und Analyseergebnisse sind zweckgebunden und eindeutig geregelt. Die geltenden Regularien und Gesetze für die Hochschule müssen auch von externen Stakeholdern eingehalten werden.

4 Ausblick

KI in der Hochschule verbindet sozio-technologische Data-Mining-, Analyse- und Interventionspraktiken mit dem Ziel, individuelle und systemische Bildungsprozesse zu unterstützen. Wie in systematischen Übersichtsarbeiten dokumentiert (Ifenthaler & Yau, 2020; Larrabee Sønderlund, Hughes & Smith, 2018; Zawacki-Richter et al., 2019), sollten KI-Systeme aktives und selbstorganisiertes Lernen ermöglichen, z.B. durch adaptive Hilfestellungen oder durch die Unterstützung von Lehrpersonen beim Kuratieren und Bearbeiten von Daten über die Lernenden und Lerninhalte.

Ein Kernproblem des Einsatzes von KI in Hochschulen ist die Kontextabhängigkeit, Fragmentierung und Verzerrung verfügbarer Daten. KI-basierte Entscheidungen, welche aus umfangreichen Trainingsdaten hervorgehen, können bei unzureichender Datengrundlage und mangelnder Transparenz zu Einseitigkeiten oder Befangenheiten führen. Eine Diskriminierung von Personen durch KI-Systeme ist somit nicht mehr auszuschließen.

Folglich sind holistische KI-Systeme, die theoretisch fundierte und transparente Datenanalysen mit pädagogisch relevanten Indikatoren und verlässlichen Interventionen ermöglichen, Ziel der aktuellen Forschung. Dabei ist zu erwarten, dass neben bereits bestehenden datenschutzrechtlichen Standards auch ethische Leitprinzipien zum Austausch und der Analyse von Daten aus dem Bildungskontext weiterentwickelt werden. Aus Sicht des Konsequentialismus sind KI-Systeme im Kontext der Hochschule ethisch vertretbar, sollten diese positive Ergebnisse für die Beteiligten erzielen. Folgt man der Deontologie sind KI-Systeme und deren autonome Entscheidungen über Bildungsprozesse grundsätzlich unethisch.

Der Diskurs um ethische Leitprinzipien im Zusammenhang mit KI im Kontext der Hochschule muss breit und tief geführt werden. Nur dann können KI-basierte Fehlentscheidungen vermieden und Schäden für Beteiligte der Hochschulen abgewendet werden. Es gilt, die Potentiale des Zusammenwirkens von Menschen und KI kritisch zu reflektieren. Während die KI dem Menschen in Kapazität und Geschwindigkeit bei Datenanalysen und -prognosen überlegen ist, überzeugt der Mensch aufgrund seiner Empathiefähigkeit bei ethischen Urteilen. Daraus kann ein Konsens für die ethisch verantwortungsvolle Verwendung von KI in der Hochschule etabliert werden. Dieser Konsens befindet sich irgendwo zwischen übertriebener Vorsicht und unkalkulierbaren Risiken.

Dirk Ifenthaler: Universität Mannheim, Chair of Economic and Business Education – Learning, Design and Technology; Curtin University, UNESCO Deputy Chair of Data Science in Higher Education Learning and Teaching; dirk@ifenthaler.info, ifenthaler@uni-mannheim.de

Literatur

- Adekitan, A. I. & Noma-Osaghae, E. (2019). Data mining approach to predicting the performance of first year student in a university using the admission requirements. *Education and Information Technologies*, 24, 1527–1543.
- Arthars, N., Dollinger, M., Vigentini, L., Liu, D. Y., Kondo, E. & King, D. M. (2019). Empowering teachers to personalize learning support. In D. Ifenthaler, D.-K. Mah & J. Y.-K. Yau (Hg.), *Utilizing learning analytics to support study success* (S. 223–248). Cham: Springer.
- Azcona, D., Hsiao, I. & Smeaton, A. F. (2019). Detecting students-at-risk in computer programming classes with learning analytics from students' digital footprints. *User Modeling and User-Adapted Interaction*, 29, 759–788.
- Bates, T., Cobo, C., Mariño, O. & Wheeler, S. (2020). Can artificial intelligence transform higher education? *International Journal of Educational Technology in Higher Education*, 17(42), 1–12.
- Bellman, R. (1978). *An introduction to artificial intelligence: can computers think?* SAN Francisco, CA: Boyd & Fraser.
- Berberich, N. (2019). Künstliche Intelligenz und Ethik. KI oder nicht KI? Das ist hier nicht die Frage. In K. Kersting, C. Lampert & C. Rothkopf (Hg.), *Wie Maschinen lernen* (S. 229–239). Wiesbaden: Springer.
- Buckingham Shum, S. & McKay, T. A. (2018). Architecting for learning analytics. Innovating for sustainable impact. *EDUCAUSE Review*, 53(2), 25–37.
- BVDW. (2019). *Mensch, Moral, Maschine. Digitale Ethik, Algorithmen und künstliche Intelligenz*. Berlin: Bundesverband Digitale Wirtschaft (BVDW) e.V.
- Daugherty, P. R. & Wilson, H. J. (2018). *Human + machine: Reimagining work in the age of AI*. Boston, MA: Harvard Business Review Press.
- De Laat, M., Joksimovic, S. & Ifenthaler, D. (2020). Artificial intelligence, real-time feedback and workplace learning analytics to support in situ complex problem-solving: a commentary. *International Journal of Information and Learning Technology*, 37(5), 267–277.
- Dellermann, D., Ebel, P., Söllner, M. & Leimeister, J. M. (2019). Hybrid intelligence. *Business & Information Systems Engineering*, 61(5), 637–643.
- Dignum, V. (2017). *Responsible autonomy*. Paper presented at the Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence, Melbourne, VIC, AUS.
- Drachler, H. & Geller, W. (2016). Privacy and analytics – it's a DELICATE issue. A checklist for trusted learning analytics, *Sixth International Conference on Learning Analytics & Knowledge*. Edinburgh, UK.
- Gašević, D., Joksimović, S., Egan, B. R. & Shaffer, D. W. (2019). SENS: Network analytics to combine social and cognitive perspectives of collaborative learning. *Computers in Human Behavior*, 92, 562–577.

- Gibson, D. C. & Ifenthaler, D. (2020). Adoption of learning analytics. In D. Ifenthaler & D. C. Gibson (Hg.), *Adoption of data analytics in higher education learning and teaching* (S. 3–20). Cham: Springer.
- Glick, D., Cohen, A., Festinger, E., Xu, D., Li, Q. & Warschauer, M. (2019). Predicting success, preventing failure. In D. Ifenthaler, D.-K. Mah & J. Y.-K. Yau (Hg.), *Utilizing learning analytics to support study success* (S. 249–273). Cham: Springer.
- Graf Ballestrem, J., Bär, U., Gausling, T., Hack, S. & von Oelffen, S. (2020). *Künstliche Intelligenz. Rechtsgrundlagen und Strategien in der Praxis*. Wiesbaden: Springer Gabler.
- Hasenbein, M. (2020). Ethik in Zeiten von Digitalisierung und künstlicher Intelligenz. In M. Hasenbein (Hg.), *Der Mensch im Fokus der digitalen Arbeitswelt* (S. 183–200). Berlin: Springer.
- Hinkelmann, M. & Jordine, T. (2019). The LAPS project: using machine learning techniques for early student support. In D. Ifenthaler, J. Y.-K. Yau & D.-K. Mah (Hg.), *Utilizing learning analytics to support study success* (S. 105–117). Cham: Springer.
- Hoel, T. & Chen, W. (2018). Privacy and data protection in learning analytics should be motivated by an educational maxim—towards a proposal. *Research and Practice in Technology Enhanced Learning*, 13–20.
- Howell, J. A., Roberts, L. D., Seaman, K. & Gibson, D. C. (2018). Are we on our way to becoming a »helicopter university«? Academics' views on learning analytics. *Technology, Knowledge and Learning*, 23(1), 1–20.
- Ifenthaler, D. (2017). Are higher education institutions prepared for learning analytics? *TechTrends*, 61(4), 366–371.
- Ifenthaler, D. (2020a). Change management for learning analytics. In N. Pinkwart & S. Liu (Hg.), *Artificial intelligence supported educational technologies* (S. 261–272). Cham: Springer.
- Ifenthaler, D. (2020b). Gelingensbedingungen zum Einsatz von Learning Analytics. In K. Wilbers (Hg.), *Handbuch E-Learning* (85, S. 1–16). Köln: Wolters Kluwer.
- Ifenthaler, D. & Drachsler, H. (2020). Learning Analytics. In H. M. Niegemann & A. Weinberger (Hg.), *Lernen mit Bildungstechnologien* (S. 515–534). Heidelberg: Springer.
- Ifenthaler, D., Gibson, D. C. & Dobozy, E. (2018a). Informing learning design through analytics: Applying network graph analysis. *Australasian Journal of Educational Technology*, 34(2), 117–132.
- Ifenthaler, D., Greiff, S. & Gibson, D. C. (2018b). Making use of data for assessments: harnessing analytics and data science. In J. Voogt, G. Knezek, R. Christensen & K.-W. Lai (Hg.), *International handbook of IT in primary and secondary education* (2, S. 649–663). New York, NY: Springer.
- Ifenthaler, D. & Schumacher, C. (2016). Student perceptions of privacy principles for learning analytics. *Educational Technology Research and Development*, 64(5), 923–938.

- Ifenthaler, D. & Tracey, M. W. (2016). Exploring the relationship of ethics and privacy in learning analytics and design: implications for the field of educational technology. *Educational Technology Research and Development*, 64(5), 877–880.
- Ifenthaler, D. & Yau, J. Y.-K. (2020). Utilising learning analytics to support study success in higher education: a systematic review. *Educational Technology Research and Development*, 68(4), 1961–1990.
- Jones, K. M. L. (2019a). Advising the whole student: eAdvising analytics and the contextual suppression of advisor values. *Education and Information Technologies*, 24, 437–458.
- Jones, K. M. L. (2019b). Learning analytics and higher education: a proposed model for establishing informed consent mechanisms to promote student privacy and autonomy. *International Journal of Educational Technology in Higher Education*, 16–24.
- Kvalnes, Ø. (2015). Moral dilemmas. In Ø. Kvalnes (Hg.), *Moral reasoning at work: re-thinking ethics in organizations* (S. 9–17). London: Palgrave Macmillan.
- Larrabee Sønderlund, A., Hughes, E. & Smith, J. (2018). The efficacy of learning analytics interventions in higher education: A systematic review. *British Journal of Educational Technology*, 50(5), 2594–2618.
- Miller, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence*, 267, 1–38.
- Nespereira, C., Vilas, A. & Redondo, R. (2015). Am I failing this course?: risk prediction using e-learning data, *Conference on Technological Ecosystems for enhancing Multiculturality* (S. 271–276).
- Pinkwart, N. & Liu, S. (Hg.). (2020). *Artificial intelligence supported educational technologies*. Cham: Springer.
- Prinsloo, P. & Slade, S. (2014). Student data privacy and institutional accountability in an age of surveillance. In M. E. Menon, D. G. Terkla & P. Gibbs (Hg.), *Using data to improve higher education. Research, policy and practice* (S. 197–214). Rotterdam: Sense Publishers.
- Richards, D. & Dignum, V. (2019). Supporting and challenging learners through pedagogical agents: Addressing ethical issues through designing for values. *British Journal of Educational Technology*, 50(6), 2885–2901.
- Russell, J.-E., Smith, A. & Larsen, R. (2020). Elements of Success: Supporting at-risk student resilience through learning analytics. *Computers & Education*, 152.
- Schumacher, C. & Ifenthaler, D. (2018). The importance of students' motivational dispositions for designing learning analytics. *Journal of Computing in Higher Education*, 30(3), 599–619.
- Schumacher, C. & Ifenthaler, D. (2021). Investigating prompts for supporting students' self-regulation – A remaining challenge for learning analytics approaches? *The Internet and Higher Education*, 49, 100791.

- Slade, S. & Prinsloo, P. (2013). Learning analytics: Ethical issues and dilemmas. *American Behavioral Scientist*, 57(10), 1510–1529.
- Taub, M., Azevedo, R., Rajendran, R., Cloude, E. B., Biswas, G. & Price, M. J. (2020). How are students' emotions related to the accuracy of cognitive and metacognitive processes during learning with an intelligent tutoring system? *Learning and Instruction*.
- Tegmark, M. (2018). *Life 3.0: Being human in the age of artificial intelligence*. London: Penguin Books.
- Wesche, J. S. & Sonderegger, A. (2019). When computers take the lead: The automation of leadership. *Computers in Human Behavior*, 101, 197–209.
- West, D., Huijser, H. & Heath, D. (2016). Putting an ethical lens on learning analytics. *Educational Technology Research and Development*, 64(5), 903–922.
- Willis, I. J. E., Slade, S. & Prinsloo, P. (2016). Ethical oversight of student data in learning analytics: a typology derived from a cross-continental, cross-institutional perspective. *Educational Technology Research and Development*, 64(5), 881–901.
- Yau, J. & Ifenthaler, D. (2020). Reflections on different learning analytics indicators for supporting study success. *International Journal of Learning Analytics and Artificial Intelligence for Education*, 2(2), 4–23.
- Zawacki-Richter, O., Marín, V. I., Bond, M. & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16(39), 1–27.
- Zeide, E. (2019). Artificial intelligence in higher education: applications, promise and perils, and ethical questions. *EDUCAUSE Review*, 54(3), 21–39.

Künstliche Intelligenz in der Hochschulbildung und das Transparenzproblem: Eine Analyse und ein Lösungsvorschlag

Dominikus Herzberg

Abstract: Es ist hochgradig attraktiv, das kognitive Potenzial Künstlicher Intelligenz (KI) in der Hochschulbildung beim Lernen und Lehren auf allen hochschuldidaktischen Ebenen zu den verschiedensten Zwecken heranzuziehen und zu nutzen: von der Lernassistenten über Tutor-systeme bis hin zu Planungssystemen zur Ausrichtung der Curricula. Einmal angenommen, solche KI-Systeme stünden uns morgen in den Hochschulen zur Verfügung: Sollten wir sie einsetzen? Überraschenderweise ist uns die Entscheidung bereits abgenommen. Die Antwort lautet »Nein«, wenn man die sogar rechtlich verankerte Forderung an die Transparenz von KI ernst nimmt, womit die Nachvollziehbarkeit, Erklärbarkeit und Interpretierbarkeit ihres Verhaltens verlangt wird. Dieser Beitrag zeigt auf, dass KI mit dem Transparenz-Prinzip unverträglich ist. Dieses Dilemma muss gesellschaftlich aufgelöst werden. Gleichwohl kann die hochschulische Bildungsforschung Rahmenbedingungen schaffen, die die Intransparenz von KI integriert und nicht ausschließt, indem sie den KI-Einsatz durch eine Bildungsfolgenforschung und wissenschaftliche »Echtzeit«-Methoden begleitet. Es wäre damit denkbar, die Forderung nach Transparenz abzuschwächen oder aufzugeben.

It is highly attractive to use the cognitive potential of Artificial Intelligence (AI) in higher education in learning and teaching on all levels of higher education didactics for a wide variety of purposes: from learning assistance to tutoring systems to planning systems for aligning curricula. Let's assume for a moment that such AI systems would be available for us tomorrow in higher education institutions: Should we use them? Surprisingly, the decision is already taken from us. The answer is »no« if we take seriously the even legally enshrined requirement for AI to be transparent, thereby demanding that its behaviour be comprehensible, explainable, and interpretable. This paper shows that AI is incompatible with the transparency principle. This dilemma needs to be resolved by society. Nonetheless, higher educational research can create conditions that integrate rather than exclude the intransparency of AI. And this can be done by accompanying the use of AI with educational impact research and scientific »real-time« methods. It would thus be conceivable to weaken or abandon the demand for transparency.

Keywords: Künstliche Intelligenz (KI), Transparenz, Bildungsfolgenforschung, Bildungsforschung, Design-Based Research (DBR) / Artificial Intelligence (AI), transparency, educational impact research, educational research.

1 Einleitung

Die Künstliche Intelligenz (KI) ist ein – aus der Sicht der Informatik – altes Forschungsgebiet. Der Computer war kaum erfunden und zu einem kommerziellen Produkt geworden, da entstanden bereits in den 1950er Jahren die ersten Überlegungen zu einem »General Problem-Solver« (Newell, Shaw & Simon, 1959). Problemlösen wurde dabei als ein zielgerichtetes Anwenden von Heuristiken (S. 5) verstanden. Historisch interessant ist, dass damals schon die Zielfindung als Reduktion eines Unterschieds zwischen zwei Zuständen interpretiert wurde (S. 9) – diese Grundidee prägt aktuell als *Gradient Descent* die Lernalgorithmen künstlicher neuronaler Netze (Anderson, 2019). Newell & Simon (1961) waren seinerzeit davon überzeugt, dass ein derartig generelles, heuristisches Problemlöseverfahren das menschliche Denken simuliere. So beeindruckend die Erfolge bis hin zu den Expertensystemen in den 1980er Jahren waren, zeigte sich doch, dass symbolische Regelsysteme, so etwa manifestiert in der Programmiersprache Prolog (Sterling & Shapiro, 1994), über bestimmte Leistungsgrenzen in ihren Fähigkeiten nicht hinaus kamen. Das führte zu einer gewissen Ernüchterung, der Menschheitstraums von einer denkenden Maschine wollte sich nicht erfüllen.

Unabhängig von den Bestrebungen, den Maschinen das Denken beizubringen und mit Qualitäten auszustatten, die über eine programmatische Algorithmik hinausgehen, ist die Vision, Maschinen als Hilfsmittel beim Lehren und Lernen einzusetzen, älter als es der Computer ist. In den 1920er Jahren entwickelte Sidney L. Pressey einen einfachen Automaten für Multiple Choice Tests, und der bekannte Psychologe B.F. Skinner stellte Ende der 1950er Jahre einen Apparat vor, der die Idee des programmierten Lernens umsetzte und Lernende positiv bei ihren Lernbemühungen unterstützte (Skinner, 1958). Das notwendig Repetitive des Lehrens und Lernens, aber auch die Möglichkeiten des individualisierten und stimulierenden Lernens im eigenen Tempo machen die Maschine zu einem reizvollen Partner als Assistenz in der Lehre (ebd.). Die Fortschreibungen dieser Ansätze werden unter dem vielschichtigen Begriff der Educational Technology, kurz EdTech, zusammengefasst (Januszewski & Molenda, 2008).

Zurück zur KI: Neue Fortschritte wurden in den 1990er Jahren mit dem sogenannten Machine Learning (ML) gemacht, als man sich von den symbolischen Regelsystemen entfernte und auf Methoden der Statistik und Wahrscheinlichkeitsrechnung setzte (Langley, 2011). Wie wir heute wissen, kam es erst durch eine Wiederentdeckung der künstlichen neuronalen Netze, gepaart mit der Rechenleistung

heutiger Computer, zu einem Quantensprung in der Nachbildung menschlicher kognitiver Fähigkeiten, dem sogenannten *Deep Learning*. Die Firma DeepMind – ein britisches Startup, das Google 2014 aufgrund der Fortschritte in der Programmierung von KI übernahm –, hat dabei die öffentliche Wahrnehmung durch eine Reihe bahnbrechender Entwicklungen geprägt: In 2016 trafen die künstliche Intelligenz AlphaGo (Silver et al., 2016) und der Weltklasse-Spieler Lee Sedol in einem medial inszenierten Spektakel aufeinander, um fünf Partien des Brettspiels Go gegeneinander zu spielen (Kohs, 2017). Bis dahin galten die kombinatorische Vielfalt der Spielmöglichkeiten und die strategische Komplexität des Spiels als uneinnehmbare Bastion für die KI und Go als die Messlatte für KI schlechthin. AlphaGo gewann 4:1 gegen Sedol. Mittlerweile ist DeepMinds KI unter dem Namen MuZero in der Lage, sich Spiele wie Go und Schach oder ein Atari-Videospiel in wenigen Stunden selbst beizubringen und dann mit einem Spielniveau aufzuwarten, dem Menschen nicht gewachsen sind (Schrittwieser et al., 2020). Das zementiert den Mythos, das dem Menschen jedwede intellektuelle Domäne abgerungen werden kann, es bedarf nicht einmal mehr speziell angepasster Programmierung.

Seit die Forschung und große Tech-Unternehmen so konsequent mit künstlichen neuronalen Netzen arbeiten und sie einsetzen, erobert die KI nicht nur eine menschlich-kognitive Domäne nach der anderen: Deep Learning beginnt zudem, bisherige algorithmische Verfahren erfolgreich abzulösen. Das beflügelt zu mehreren Ansätzen im Hochschulbereich: Zum einen scheint jede Wissenschaft zur Erkenntnisgewinnung vom KI-Einsatz profitieren zu können. Es wird zunehmend erfolgskritisch, KI als Kompetenz und Lehrgebiet in die wissenschaftliche Ausbildung einfließen zu lassen, was eine Diskussion ethischer und datenschutzrechtlicher Aspekte einschließt. Zum anderen befeuert die KI mit ihren Architekturen und Verfahren die Erforschung kognitiver Prozesse und Fähigkeiten und damit auch die Lehr- Lernforschung auf eine ganz neue Weise. Und zu guter Letzt bietet sich KI als Assistenz in der Hochschulbildung an und zwar auf allen Ebenen: auf der Mikroebene z.B. als Lernhilfe, auf der Mesoebene z.B. als Studienverlaufsbegleitung und auf der Makroebene etwa als Schöpfer neuer Studiengänge; mehr dazu im folgenden Kapitel.

Dieser Beitrag befasst sich mit der KI-Assistenz in der Hochschulbildung, was einerseits die »Teaching Machine« von Pressey und Skinner fortschreibt, andererseits weit darüber hinausgeht. Den Möglichkeiten und Chancen stehen Forderungen nach Transparenz, d.h. nach Erklärbarkeit und Nachvollziehbarkeit von KI-Systemen gegenüber, die zwar verständlich und wünschenswert sind, jedoch – so die Argumentation dieses Beitrags – eine inhärente Widerspruchslogik in sich tragen, die sich wissenschaftstheoretisch und am Gegenstand der KI begründen lässt. Auch wenn die Widerspruchslogik nicht auflösbar ist, so heißt das nicht, dass die Bildungs- und Hochschulforschung den KI-Einsatz im Hochschulbereich nicht beglei-

ten und beforschen könnte. Es bedarf einer Bildungsfolgenabschätzung und geeigneter Forschungsmethoden.

2 Mit Künstlicher Intelligenz lehren und lernen

Das Whitepaper »Künstliche Intelligenz in der Hochschulbildung«, herausgegeben von de Witt, Rampelt und Pinkwart (2020), bietet eine umfassende und aktuelle Übersicht zu »den Möglichkeiten und Herausforderungen von Künstlicher Intelligenz in Studium und Lehre« (S. 5). Für den KI-Einsatz als Lehr- und Lern-Partner werden eine Reihe von Gründen genannt, die Potenziale vorzeichnen und erkennen lassen. Ein paar Beispiele: Studierende können etwa »ihr eigenes Lernverhalten noch intensiver kennenlernen« und »Lehrende erfahren die Wirksamkeit ihrer didaktischen Methoden«; KI kann nicht nur beim Wissenserwerb und beim Verständnis, sondern auch bei der Ausbildung metakognitiver Fähigkeiten unterstützen; Risiko-Studierende werden identifiziert, »so dass personalisierte Interventionsstrategien vorzeitig entwickelt und Drop-out-Quoten reduziert werden können«; KI kann Studierende bei Aufgaben »durch individualisiertes Feedback unterstützen« und Lehrende können bei Ihrer Lehrstrategie unterstützt werden (S. 11f.).

Am Beispiel der Learning Analytics, also der Auswertung von erhobenen Daten rund um Lernvorgänge zum Zwecke des Verständnisses, der Optimierung und Vorhersage des Lernverhaltens und des Lernerfolgs, lässt sich aufzeigen, wie alle hochschuldidaktischen Ebenen und die Rollen der Lernenden, Lehrenden und der Organisation von KI-Innovationen erreichbar sind, siehe Abb. 1. Die individuelle Ebene des Lernens bis hin zur Entwicklung und Neugestaltung von Studiengängen ist adressierbar.

Abbildung 1: Beispiele für Learning Analytics aus de Witt et al. (2020, Tab. 2, S. 14).

	LERNENDE	LEHRENDE	ORGANISATIONEN
Mikroebene (Lernsequenz)	Adaptive Lernsoftware zur Klausurvorbereitung	Informationen zu Schwierigkeiten des Kurses über eine Aufgabe	Dynamische Bereitstellung von Ressourcen, z.B. Servern
Mesoebene (Semester, Kurs)	Monitoring des eigenen Lernerfolgs über ein Semester	Analyse von Gruppenlernprozessen in großen Onlinekursen	Unterstützung bei der zeitlichen Planung des Lehrangebots
Makroebene (langfristig)	Langfristige ePortfolios, Passung zu Jobprofilen	Weiterentwicklung als Lehrkraft, Erkenntnisse zu Erfolgsfaktoren	Monitoring und Revision von Studiengängen

Die möglichen »Segnungen« des Einsatzes von KI in der Hochschule sind umfassend und übergreifend. Jedes von Hochschuldidaktiker:innen nur erdenkbare Problemfeld scheint mit KI lösbar zu sein. Aber auch das muss konstatiert werden, wie Bates, Cobo, Mariño und Wheeler (2020) in ihrer Untersuchung zeigen: Die Versprechungen des KI- Einsatzes im Bildungssektor sind hoch, »but as yet, little has been achieved« (S. 4). Die Gründe sind vielfältig und haben u.a. damit zu tun, dass viel an technischer und hochschuldidaktischer Expertise, an Rechenleistung und Datenerfassung zusammenkommen müssen. Man darf damit rechnen, dass die KI-Innovationen durch Tech-Giganten von außen an das Bildungssystem herangetragen werden (S. 11f.).

Auch wenn die KI ihren Weg in den Hochschulalltag noch nicht gefunden hat, für den möglichen Einsatz werden neben ethischen und datenschutzrechtlichen Maßstäben darüber hinausgehende Forderungen an solche Systeme formuliert: Dem Ausgeliefertsein von Menschen gegenüber KI-Interventionen möchte man gesetzlich mit Transparenz begegnen (Stichwort »Explainable AI«, was noch Thema sein wird), um eine Nachvollziehbarkeit der KI- Entscheidungen zu gewährleisten (Burchardt, 2020). Ähnlich lautet es in der KI-Strategie der Bundesregierung, dass die »Transparenz, Nachvollziehbarkeit und Überprüfbarkeit der KI-Systeme herzustellen« ist (Bundesregierung, 2018, S. 38). In der Kurzfassung des Abschlussberichts der Enquete-Kommission Künstliche Intelligenz heißt es: Je nach Kritikalität muss über den Einsatz von KI informiert werden und dort, »wo Menschen von den Folgen einer Entscheidung auf Basis eines KI-Systems betroffen sind, müssen sie genügend Informationen erhalten, um ihre Rechte angemessen wahrnehmen und die Entscheidung ggf. infrage stellen zu können« (Deutscher Bundestag, 2020, S. 16).

Die Hochschulen müssen bei einer KI-Assistenz in der Hochschulbildung also stets der Forderung nach Transparenz, d.h. Nachvollziehbarkeit, Erklärbarkeit und Überprüfbarkeit der eingesetzten Systeme nachkommen. Diese Forderung erscheint mehr als vernünftig und verständlich, sieht doch nicht zuletzt die europäische Datenschutzverordnung ein »Recht auf Erklärung« vor. Beispielsweise sollte Studierenden erklärt werden, welche Gründe eine KI für eine personalisierte Studienverlaufsplanung hat. Doch so plausibel das Transparenzprinzip ist: Ist diese Forderung überhaupt erfüllbar? Die folgenden zwei Kapitel sprechen dagegen. Aus wissenschaftstheoretischer Sicht und aus inhärent technologischen Gründen können KI-Systeme nicht transparent sein.

3 Wie arbeitet die Wissenschaft, die KIs baut?

Die KI ist als Teilgebiet der Informatik den Technikwissenschaften zuzurechnen (vgl. Herzberg, 2019; Luft, 1988). Zu den Technikwissenschaften gibt es eine ausgear-

beitete Wissenschaftstheorie, die sich gegen die traditionell naturwissenschaftlich, empirisch ausgerichtete Wissenschaftstheorie deutlich absetzt und die den Technikwissenschaften in ihren Eigenarten und Besonderheiten als Wissenschaftsdisziplin gerecht wird (vgl. Kornwachs, 2012, 2018; Poser, 2012). Das beginnt bei einem unterschiedlichen Theoriebegriff: In den Erfahrungswissenschaften (was die Naturwissenschaften einschließt) wird aus einer Theorie eine Hypothese abgeleitet, die sich im Experiment bewähren muss und, abhängig vom Ausgang des Experiments, die Theorie verifiziert. Die Theorie ist somit ein Konstrukt, aus dem sich Wahrheitsbehauptungen generieren lassen, während die experimentelle Ebene vermutete Begründungszusammenhänge bestätigt. In den Technikwissenschaften dagegen ist eine Theorie eine Machbarkeits- bzw. Herstellungsvermutung durch Handlungen. Aus der Theorie werden Regeln abgeleitet, die einem Test unterworfen werden und, je nach Ausgang des Tests, die Effektivität der Regeln belegen und die Theorie validieren. In den Technikwissenschaften geht es demnach nicht um Ursache-Wirkungs-Beziehungen, sondern um Zweck-Mittel-Relationen der Funktionserfüllung (Kornwachs, 2012, S. 25).

Angewendet auf die wissenschaftliche Beschäftigung mit KI bedeutet das: Die KI-Forschung sucht nach informatischen Mitteln zum Zweck des Baus automatisierter und autonomer Lernsysteme und misst den Erfolg in der Effektivität der Zielerreichung. Sofern möglich, ist ein Begründungswissen zur Erklärung und zur planvollen Konstruktion hilfreich und nützlich, aber nicht notwendig. Denn technische Theorien müssen nicht auf »wahren« Theorien und Erklärungsmodellen beruhen, um effektiv zu sein und funktionierende Lösungen hervorzubringen (vgl. König, 2010).

Die KI-Forschung und die Entwicklung von KI-Anwendungen für verschiedenste Einsatzgebiete gerieren sich als Suche nach Lösungen, die funktionieren. Dabei entwickelt sich die KI zusehends zu einer Technikdisziplin, die sich aus einem rapide wachsenden Wissensstand an Modellen und Architekturen des maschinellen und »tiefen« Lernens bedient und ihre Bauten an herausfordernden Szenarien erprobt. Das führt zu einer konstruktiven Beherrschung solcher Systeme und zu einer Vermutungsbehauptung bestimmter Konfigurationen für definierte Einsatzzwecke – so zeigt es sich beispielhaft, wenn man die Entwicklung von AlphaGo zu MuZero studiert. Und selbstverständlich versucht man, die Vorgänge in einem neuronalen Netz in den verschiedenen neuronalen Schichten zu verstehen, um Systeme in Funktionskomponenten zerlegen zu können. Als Google einen Bildklassifizierer für eine solche Untersuchung »invertierte«, generierten die Neuronenschichten bizarr anmutende, traumartige Bilder, was eine Idee davon vermittelte, wie diese KI funktionierte (Mordvintsev, Olah & Tyka, 2015). Das impliziert jedoch nicht, dass man stets begründen könne oder verstünde, warum eine KI so oder so handelt, entscheidet oder sich verhält; geschweige denn, dass eine KI über ihre eigenen Beweggründe Auskunft geben könnte. Und das leitet über zur Explainable AI.

4 Vom Fehlen eines Begründungswissens

Die Forschung zur sogenannten Explainable AI (kurz XAI, AI steht für *Artificial Intelligence*) ist so alt wie die KI selbst und befasst sich mit dem Problem der Transparenz, d.h. mit der Frage, ob und inwieweit das Verhalten einer KI nachvollziehbar, erklärbar und interpretierbar ist (Holzinger, 2018). Es geht um die Erfassung von Kontexten, kausales Schlussfolgern, für Menschen geeignete Darbietungsformen und informationelle Verdichtung (ebd.).

Noch recht einfach verhält es sich mit den in der Einleitung erwähnten symbolischen, regelbasierten Ansätzen. Die Schlussfolgerungsketten und Heuristiken sind grundsätzlich protokollierbar und analysierbar. Allerdings sind regelbasierte Systeme wenig robust und für moderne KI-Anwendung eher uninteressant, da sie nicht mit Unsicherheit und widersprüchlichen Daten zurechtkommen (Pearl & Mackenzie, 2019, Kap. 3). Anspruchsvoll und problematisch wird es mit den statistischen und wahrscheinlichkeitsorientierten Verfahren des Machine Learning. Statistische Verfahren erfassen Korrelationen und keine Kausationen. Ohne Kausalbeziehungen gibt es keine kausalen Erklärungen. Und da, formal betrachtet, auch die neuronalen Netze des Deep Learning statistischer Natur sind, stößt man an eine prinzipielle Grenze der Transparenz. Neuronale Netze sind für uns schwarze Boxen, die wir nicht verstehen (vgl. Buder, 2020, S. 19). »Even AlphaGo's programmers cannot tell you why the program plays so well. [...] They simply experimented, and it did.« (Pearl & Mackenzie, 2019) – Dieses Ausprobieren auf der Suche nach effektiven Lösungen steht im Einklang mit einer technikwissenschaftlichen Disziplin, die Technik lösungsorientiert und zweckgebunden konstruiert.

Es bleibt die Aufgabe der Explainable AI, zu erkunden, welche KI-Systeme mit welchem Leistungspotenzial welchen Grad an Transparenz erlauben. Aber je anspruchsvoller die Nachbildung kognitiver Fähigkeiten ist, desto weniger darf man auf Transparenz hoffen. Dyson (2019, S. 39) hat das pointiert als drittes Gesetz der KI formuliert: »The third law states that any system simple enough to be understandable will not be complicated enough to behave intelligently, while any system complicated enough to behave intelligently will be too complicated to understand.« Eine Aussage, die sich auch formal belegen lässt (Alfonseca et al. 2021).

Müssen wir uns damit abfinden, dass wir KI benötigen, die uns die Handlungen von KI erklärt? Das hätte zwar eine humoristische Pointe, wird aber als Forschungsergebnis der XAI nicht zu erwarten sein.

5 Perspektivwechsel: Bildungsfolgenforschung und geeignete Forschungsansätze

Für all die hochschuldidaktischen Szenarien, für die ein KI-Einsatz infrage kommt und interessant ist, müssen vermutlich Systeme zum Einsatz kommen, die der Forderung nach Transparenz der KI-Entscheidungen nicht gerecht werden können. Je »brauchbarer« oder »nutzbringender« z. B. Learning Analytics sein sollen (siehe Abb. 1, die alle Ebenen der Hochschule adressiert), desto weniger wird verständlich sein, was den Interventionsvorschlag einer KI jenseits eines Verweises auf statistische Korrelationen kausal, formal-logisch oder anderweitig erkenntnisleitend begründet. Wie dargelegt, wird dieser »Mangel« an Transparenz nicht den Erfolg und die Weiterentwicklung der KI behindern. Die Informatik als Technikwissenschaft arbeitet nach dem Effektivitätsprinzip.

Es ist eine Frage, wie der Konflikt zwischen der Forderung nach Transparenz und dem Bedarf an problemlösender KI gesellschaftlich, ethisch und datenschutzrechtlich aufgelöst werden kann. Eine andere Frage ist, wie die hochschulische Bildungsforschung mit der Intransparenz von KI-Systemen umgeht bzw., so ist es treffender formuliert, umgehen könnte, denn noch ist vom KI-Einsatz in der Hochschule nicht viel zu sehen. Ich sehe eine große Chance für die Bildungsforschung darin, sich im Anwendungskontext der Hochschule in die Diskussion einzubringen mit geeigneten Forschungsmethoden und einem zu etablierenden Forschungszweig, den ich in Anlehnung an die Technikfolgenabschätzung als Bildungsfolgenabschätzung bezeichnen möchte. Welche Folgen hat der KI-Einsatz für die Studierenden, für die Lehrenden, auf das Bildungssystem, auf die mit der Hochschule verzahnte Berufspraxis, die Kultur, die Gesellschaft? Das sind schwierige Fragen von der Art, wie sie die Technikfolgenabschätzung immer wieder und immer wieder neu zu beantworten versucht (vgl. Kornwachs, 1991), selbst wenn ein technisches System intransparent in seinen Wirkmechanismen ist und in den Wechselwirkungen seines Anwendungsfelds und seines Einsatzzwecks nicht vollständig verstanden ist, was bei der Komplexität heutiger Systeme rundweg unterstellt werden muss. Eine Bildungsfolgenforschung sollte in Abgrenzung dazu nicht allein von der Technik kommend argumentieren, sondern den Kontext der Bildung u. a. als gesellschaftliches Konstrukt und die Veränderung der Bildungslandschaft mit in den Blick nehmen und normative Aspekte einbeziehen.

Bildungsfolgenforschung versucht sich an einem Blick in die Zukunft. Es bedarf aber auch Forschungsmethoden, die den Einsatz von KI als Intervention im konkreten Einsatzszenario verstehen und in der Lage sind, – um es in Anlehnung an Mukerji & Mannino (2020) zu formulieren – mit den Auswirkungen in Echtzeit umzugehen: Bildungsforschung zum KI-Einsatz in Echtzeit, um auf eine KI in ihrem Gestaltungseinfluss reagieren zu können. Das ist für eine Bildungs- und Hochschuldidaktikforschung nötig, die das Transparenzproblem integriert und nicht negiert.

Eine Forschungsmethodologie, die sich dafür andient, ist das Design-Based Research (Reinmann, 2017). »Design-Based Research ist ein Forschungsansatz in den Bildungswissenschaften, der sich mit Interventionen im Praxiseinsatz beschäftigt und den gesamten Zyklus einer Intervention in den Blick nimmt, von ihrer Gestaltung bei gleichzeitiger theoretischer Fundierung bis hin zur Umsetzung, Evaluation und Reflektion unter den Bedingungen eines Anwendungsumfeldes vielfältiger Wechselwirkungen und Abhängigkeiten. DBR geht davon aus, dass die Komplexität sozialer Bezüge (inkl. der Involviertheit der Gestaltenden, der Anwendenden und der Betroffenen) und die Kompliziertheit der Wirkmechanismen ein sich herantastendes, erschließendes Vorgehen unumgänglich machen. Ziel ist es, trotz der Unbestimmbarkeit des vollständigen Kontextes und der Unmöglichkeit der Identifikation und Isolation aller Einflussgrößen, sowohl zu praxisrelevanten Handlungsempfehlungen wie auch zu theoriebildenden Erkenntnissen zu gelangen.« (Herzberg & Joller-Graf, 2020). Eine Maschine muss nicht transparenter sein als es ein Mensch sein könnte. In gestaltungsbasierten Forschungsansätzen wird eine KI selbst zum Moment der Gestaltung, was entweder ihre Konfigurierbarkeit und Adaptierbarkeit, ihre Lernfähigkeit und Anpassungsfähigkeit, ihre Vertrauenswürdigkeit und Zuverlässigkeit oder ihre Rolle und Bedeutung in dem entsprechenden Bildungsszenario betrifft.

Die offene Frage ist, ob man angesichts dieser skizzierten Möglichkeiten des Umgangs mit Intransparenz bereit ist, die gesellschaftlich, rechtliche Transparenzforderung an KI-Systeme abzuschwächen oder aufzugeben. Die hier vorgestellte Alternative ist, den KI-Einsatz stattdessen mittels einer Bildungsfolgenforschung und einer forschenden Echtzeitbegleitung gleichsam »unter Aufsicht zu stellen«. Denn es gibt auch aus bildungstheoretischer Sicht gute Gründe dafür, das zu tun. Um mit Sesink (1990) zu argumentieren: Maschinen mit KI-Fähigkeiten sind vollzogene Abstraktionen, die nicht im Lebensvollzug agieren. Dem Menschen wohnt mit seinen Lebensbezügen ein revolutionäres Potenzial inne. »Sie [die Menschen] sind nur bereit, das soziale System, in dem sie leben, anzuerkennen, sofern ihre Lebensverhältnisse in ihm gut aufgehoben sind. Nicht die Systemreproduktion, sondern ihre Lebensreproduktion ist ihnen oberstes Ziel.« (Ebd.) Bildung versteht Sesink als »Entdeckungsreise«, wobei mehr als fraglich ist, ob eine KI dem gerecht werden kann. Und de Witt & Leineweber (2020) ergänzen: »In diesem Sinne setzt Bildung die Differenz zwischen dem Subjekt und seinen sozialen Verhältnissen voraus, Handlungs- und Urteilsfähigkeit setzt die Differenz zwischen Problemen und ihren Lösungen voraus und Intelligenz setzt schliesslich die Differenz zwischen Wissen und Nichtwissen voraus.« (S. 43). Das verweist KI im Bildungskontext auf ihre Plätze und deutet die Notwendigkeit an, KI nicht ohne eine wissenschaftlich reflektierte Begleitung in Hochschulszenarien einzusetzen.

Dominikus Herzberg: Technische Hochschule Mittelhessen, Fachbereich Mathematik, Naturwissenschaften und Informatik (MNI); Universität Hamburg, Hamburger Zentrum für Universitäres Lehren und Lernen (HUL); dominikus.herzberg@mni.thm.de

Literatur

- Alfonseca, M., Cebrian, M., Fernandez Anta, A., Coviello, L., Abeliuk, A. & Rahwan, I. (2021). Superintelligence Cannot be Contained: Lessons from Computability Theory. *Journal of Artificial Intelligence Research*, 70, 65–76.
- Anderson, C. (2019). Gradient Descent. In J. Brockman (Hg.), *Possible Minds. Twenty-five ways of looking at AI* (Kap. 14). New York: Penguin Books.
- Bates, T., Cobo, C., Mariño, O. & Wheeler, S. (2020). Can artificial intelligence transform higher education? *International Journal of Educational Technology in Higher Education*, 17.
- Buder, J. (2020). Wieviel Mensch steckt in der Maschine? *Information – Wissenschaft & Praxis*, 71(1), 17–22.
- Bundesregierung. (2018). *Strategie Künstliche Intelligenz der Bundesregierung*. (Stand: November 2018).
- Bundesministerium Wirtschaft und Energie (BMWi). Zugriff am 12.01.2021. Verfügbar unter: <https://www.bundesregierung.de/breg-de/service/publikationen/strategie-kuenstliche-intelligenz-der-bundesregierung-2018-1551264>.
- Burchardt, A. (2020). Transparenz und Vertrauen schaffen. In *Künstliche Intelligenz in der Hochschulbildung*. *Whitepaper* (S. 39–40). Berlin. KI-Campus.
- de Witt, C. & Leineweber, C. (2020). Zur Bedeutung des Nichtwissens und die Suche nach Problemlösungen. *Bildungstheoretische Überlegungen zur Künstlichen Intelligenz. MedienPädagogik: Zeitschrift für Theorie und Praxis der Medienbildung*, (39, Orientierungen), 32–47. <https://doi.org/10.21240/mpaed/39/2020.12.03.X>.
- de Witt, C., Rampelt, F. & Pinkwart, N. (2020). *Künstliche Intelligenz in der Hochschulbildung*. *Whitepaper*. Berlin: KI-Campus. <https://doi.org/10.5281/zenodo.4063722>.
- Deutscher Bundestag. (2020, 27. Oktober). *Kurzfassung des Abschlussberichts der Enquete-Kommission Künstliche Intelligenz*. Enquete-Kommission Künstliche Intelligenz. Zugriff am 12.01.2021. Verfügbar unter: https://www.bundestag.de/ausschuesse/weitere_gremien/enquete_ki/sonstige_veroeffentlichungen.
- Dyson, G. (2019). The Third Law. In J. Brockman (Hg.), *Possible Minds. Twenty-five ways of looking at AI* (Kap. 4). New York: Penguin Books.

- Herzberg, D. (2019). *Die Bachelorarbeit in der Praktischen Informatik im Spagat zwischen Wissenschaftsanspruch und Wirklichkeit*. Masterarbeit. Universität Hamburg, Hamburg.
- Herzberg, D. & Joller-Graf, K. (2020). Forschendes Lernen mit DBR: Eine methodologische Annäherung. *Impact Free-Journal für freie Bildungswissenschaftler*, (33), 1–16. Zugriff am 29.03.2021. Verfügbar unter: https://gabi-reinmann.de/wp-content/uploads/2020/11/Impact_Free_33.pdf.
- Holzinger, A. (2018). Explainable AI (ex-AI). *Informatik-Spektrum*, 41(2), 138–143.
- Januszewski, A. & Molenda, M. (Hg.). (2008). *Educational Technology. A Definition with Commentary* (2. Aufl.). New York: Routledge.
- Kohs, Greg (Regie). (2017). *AlphaGo – The Movie. Full Documentary* [YouTube]. Verfügbar unter: <https://www.alphagomovie.com/>.
- König, W. (2010). Werte, Wissen und Wissensintegration in den Technikwissenschaften. In K. Kornwachs (Hg.), *Technologisches Wissen. Entstehung, Methoden, Strukturen* (Acatech diskutiert, S. 63–80). Berlin, Heidelberg: Springer.
- Kornwachs, K. (Hg.). (1991). *Reichweite und Potential der Technikfolgenabschätzung*. Stuttgart: Poeschel. Kornwachs, K. (2012). *Strukturen technologischen Wissens. Analytische Studien zu einer Wissenschaftstheorie der Technik*. Berlin: Edition Sigma.
- Kornwachs, K. (2018). *Philosophie für Ingenieure* (3., überarbeitete Auflage). München: Hanser. Langley, P. (2011). The changing science of machine learning. *Machine Learning*, 82(3), 275–279.
- Luft, A. L. (1988). *Informatik als Technik-Wissenschaft. Eine Orientierungshilfe für das Informatik-Studium*.
- Mannheim, Wien, Zürich: BI Wissenschaftsverlag.
- Mordvintsev, A., Olah, C. & Tyka, M. (2015, 17. Juni). *Inceptionism: Going Deeper into Neural Networks*. Google AI Blog, Google. Zugriff am 12.01.2021. Verfügbar unter: <https://ai.googleblog.com/2015/06/inceptionism-going-deeper-into-neural.html>.
- Mukerji, N. & Mannino, A. (2020). *Covid-19: Was in der Krise zählt. Über Philosophie in Echtzeit* (Reclams Universal-Bibliothek (Was bedeutet das alles?), Bd. 14053, 4. Aufl.). Ditzingen: Reclam.
- Newell, A., Shaw, J. C. & Simon, H. A. (1959). *Report on a General Problem-Solving Program* (Revision vom 9.2.1959) (P-1584). Rand Corporation. Zugriff am 11.01.2021. Verfügbar unter: https://home.mis.u-picardie.fr/~furst/docs/Newell_Simon_General_Problem_Solving_1959.pdf.
- Newell, A. & Simon, H. A. (1961). GPS, A Program that Simulates Human Thought. In H. Billing (Hg.), *Lernende Automaten* (Elektronische Rechenanlagen, Bd. 3, S. 109–124). München: Oldenbourg.
- Pearl, J. & Mackenzie, D. (2019). *The Book of Why. The New Science of Cause and Effect* (Penguin Science). London: Penguin.

- Poser, H. (2012). *Wissenschaftstheorie. Eine philosophische Einführung* (Reclams Universal-Bibliothek, Bd. 18995, 2., überarbeitete und erweiterte Auflage). Stuttgart: Philipp Reclam jun.
- Reinmann, G. (2017). Design-Based Research. In D. Schemme & H. Novak (Hg.), *Gestaltungsorientierte Forschung-Basis für soziale Innovationen. Erprobte Ansätze im Zusammenwirken von Wissenschaft und Praxis* (Berichte zur beruflichen Bildung, S. 49–61). Bielefeld: Bertelsmann.
- Schrittwieser, J., Antonoglou, I., Hubert, T., Simonyan, K., Sifre, L., Schmitt, S. et al. (2020). Mastering Atari, Go, chess and shogi by planning with a learned model. *Nature*, 588(7839), 604–609.
- Sesink, W. (1990). »Künstliche Intelligenz«, Systemreproduktion und Bildung. *Neue Sammlung*, 30(2), 193–207.
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., van den Driessche, G. et al. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484–489.
- Skinner, B. F. (1958). Teaching Machines. From the experimental study of learning come devices which arrange optimal conditions for self instruction. *Science (New York, N.Y.)*, 128(3330), 969–977.
- Sterling, L. S. & Shapiro, E. Y. (1994). *The Art of Prolog* (2nd ed.). Cambridge, Mass: MIT Press.

Studierende im KI-Diskurs

Wie Studierende in einem Workshopformat über den KI-Einsatz informiert und zum Nachdenken über KI-gestütztes Lehren und Lernen angeregt werden

Alice Watanabe

Abstract: Künstliche Intelligenz (KI) wird zukünftig die Entwicklung von Hochschulen prägen (Aldosari, 2020). Während Unsicherheiten im Datenschutz (Büching et al., 2019) und ethische Fragestellungen (Ocaña-Fernández et al., 2019) als maßgebliche Probleme gelten, die gelöst werden müssen, um technologiegestütztes Lernen erfolgreich in das Bildungsangebot der Hochschulen einzubinden, werden andere potenzielle Hindernisse bislang weit weniger intensiv diskutiert. So findet etwa die Frage, wie die Akzeptanz und Meinungen von Studierenden zum KI-gestützten Lehren und Lernen erforscht werden können, bislang weniger Beachtung (Seufert et al., 2020).

Diese Überlegung dient als Ausgangspunkt für das Forschungsprojekt KI in der Hochschullehre, welches 2020–2022 an der Technischen Hochschule Ostwestfalen-Lippe in Lemgo durchgeführt wurde. Der nachfolgende Artikel beschreibt die Konzeption eines Workshops, der aus diesem Projekt hervorgegangen ist. Das Ziel des Workshops besteht darin, Studierende über Chancen und Gefahren von KI im Hochschulkontext zu informieren und zur selbständigen Auseinandersetzung mit dem Thema anzuregen.

Artificial intelligence (AI) will shape the development of higher education in the near future (Aldosari, 2020). But data protection (Büching et al., 2019) and ethical concerns (Ocaña-Fernández et al., 2019) are considered vital issues that need to be resolving before AI-supported teaching and learning can be successfully integrated into higher education, and other potential obstacles receive less attention. There is, for instance, little research on students' acceptance of and opinions on AI-based systems in higher education (Seufert et al., 2020).

With the project »AI in university teaching« (2020–2022), the Technical University of Applied Sciences and Arts Ostwestfalen-Lippe addresses this blind spot in research. The following article describes a workshop created as part of the project. The workshop aims to inform students about the opportunities and perils of AI in higher education and encourage them to both form and share their opinions on AI-supported teaching and learning.

Keywords: *KI-gestütztes Lehren und Lernen*, *Akzeptanzforschung*, *explorative Interviewstudie*, *KI-Videos*, *Zukunftsszenarien*, *KI-Diskurs*, *Partizipation / AI-supported learning and teaching*, *acceptance research*, *exploratory interview study*, *AI videos*, *future scenarios*, *AI discourse*, *participation*.

1 Einleitung

Der KI-Hype im tertiären Bildungssektor nimmt weltweit zu (Humble & Mozelius, 2019). Vor allen in den MINT-Fächern (Bates et al., 2020), aber auch in den Bildungswissenschaften (Aldosari, 2020; de Witt et al., 2020; Tuomi, 2018; Wannemacher & Bodmann, 2021) werden KI-Anwendungen und deren Einsatz in der Hochschullehre aus unterschiedlichen Perspektiven erforscht. Einerseits erhoffen sich Wissenschaftler:innen vom KI-Einsatz neue Chancen für die Hochschulbildung – etwa individuellere Betreuung für Studierende, effizientere Studiengestaltung oder eine Erhöhung der Abschlussquoten (Klutka et al., 2018). Andererseits thematisieren Kritiker:innen aber auch ethische Bedenken (Ocaña-Fernández et al., 2019; Seufert et al., 2020) und warnen vor Datenmissbrauch sowie vor der Missachtung der Privatsphäre von Studierenden (Büching et al., 2019).

Ein in der Forschung bisher kaum beachteter Aspekt ist jedoch, dass an deutschen Hochschulen die Akzeptanz und Meinungen von Studierenden zu dem Einsatz von KI-gestützten Technologien nicht oder zumindest nur sporadisch (z.B. durch einzelne Umfragen) berücksichtigt werden, wie etwa eine Studie des *Institute for Internet and Democracy* verdeutlicht (Kieslich et al., 2019). Zugleich ist allerdings davon auszugehen, dass die Einstellung und Zustimmung von Studierenden für die erfolgreiche Implementierung von KI-Anwendungen in der Hochschule von integraler Bedeutung sind (Marcinkowski & Starke, 2019). So zeigt die bereits erwähnte Studie des *Institute for Internet and Democracy*, dass die Studierenden der Universität Düsseldorf KI-Anwendungen abhängig von ihrem Nutzungsbereich bewerten: Während die Mehrheit der Studierenden KI in der Hochschulverwaltung nicht ablehnt, werden KI- und Learning-Analytics-Anwendungen, die in direktem Zusammenhang mit den Studierenden und ihren Leistungen stehen, als kritisch bewertet (Kieslich et al., 2019). Dies lässt eine große Differenz zwischen dem hochschulpolitischen Ziel, KI in der Lehre anzuwenden, und der gegensätzlichen Haltung der Studierenden erkennen und veranschaulicht, wie relevant die Einbeziehung der Studierenden für die Umsetzung künftiger KI-Projekte in der Hochschullehre ist (Watanabe, 2021).

Das vom Wissenschaftsministerium Nordrhein-Westfalen 2020–2022 geförderte Forschungsprojekt *KI in der Hochschullehre* (Förderkennzeichen: 224–1.80.01.05) hat sich daher zum Ziel gesetzt, die Perspektive der Studierenden auf aktuelle KI-Trends sowie Chancen, Gefahren und Bedingungen des KI-gestützten Lehrens

und Lernens zu ermitteln. Auf Grundlage dieser Ergebnisse wurde ein Workshop entwickelt, in dem Studierende Informationen zum Themenkomplex erhalten und beginnen, sich mit unterschiedlichen Perspektiven auf den KI-Einsatz auseinanderzusetzen.

Der vorliegende Beitrag zeigt anhand eines Fallbeispiels in Gestalt eines Workshopformats exemplarisch auf, mithilfe welcher didaktischen Maßnahmen Studierende über den Einsatz von KI informiert werden können und wie sich in einem solchen Format ein kritischer Diskurs anstoßen und moderieren lässt. Anhand theoretischer und empirischer Vorarbeiten werden zunächst aktuelle KI-Anwendungen sowie mögliche Potenziale und Risiken zum KI-Einsatz in der Hochschullehre thematisiert. Auf dieser Basis werden für den Workshop KI-Szenarien in Form von animierten Videos entworfen, die verschiedene KI-Trends vorstellen und die herausgearbeiteten Chancen und Gefahren beim Einsatz von KI in der Hochschullehre überspitzt darstellen. Durch diese Art der Wissensvermittlung sollen Studierende auf niedrigschwellige Weise an das Thema *KI-gestütztes Lehren und Lernen* herangeführt werden und verschiedene Aspekte des KI-Diskurses kennenlernen. Im Anschluss an die Videos sollen die Studierenden dann eigenständig über Chancen und Gefahren des KI-Einsatzes in Lehr-Lern-Kontexten diskutieren.

Der vorliegende Artikel legt einen Fokus auf die konzeptionelle Entwicklung und Umsetzung der KI-Zukunftsszenarien und deren Darstellung in Form von Videos. Ferner wird aufgezeigt, wie die Studierenden sich mit dem KI-gestützten Lehren und Lernen auseinandersetzen und im Rahmen des Workshops gezielt dazu angeregt werden, darüber nachzudenken, welche Bedingungen sie selbst an den KI-Einsatz in der Hochschullehre knüpfen würden.

2 Theoretische und empirische Grundlagen

In diesem Kapitel werden die theoretischen und empirischen Grundlagen erläutert, auf denen das Projekt fußt. Zunächst werden verschiedene Einsatzbereiche für KI an der Hochschule präsentiert und die wichtigsten KI-Trends zusammengefasst (2.1). Im Anschluss werden die Erkenntnisse der qualitativen Interviewstudie dargestellt und Chancen und Gefahren bezüglich des KI-Einsatzes in der Hochschullehre herausgearbeitet (2.2). Auf Basis dieser Darstellung können die zentralen Themen des zu entwickelnden Workshops theoretisch abgeleitet werden. Die hier vorgestellten Ergebnisse basieren auf der Hochschulschrift *Künstliche Intelligenz in der Hochschullehre. Eine explorative Interviewstudie zu Akzeptanzfaktoren aus Studierendenperspektive* (Watanabe, 2021). Für den vorliegenden Beitrag wurden einige Aspekte kompakter zusammengefasst (z. B. wurden Primäraussagen aus den Interviews nicht übernommen) und der Text durch neue Quellen aktualisiert.

2.1 KI-Anwendungen in der Hochschullehre

In Bezug auf den KI-Einsatz in der Hochschulbildung lassen sich verschiedene technische Anwendungen unterscheiden, welche einerseits über die Hochschulebenen kategorisiert werden können, auf denen sie zum Einsatz kommen (können). Dabei kann zwischen KI-Anwendungen differenziert werden, die erstens in einzelnen Lehr-Lernkontexten (Mikro-Ebene), zweitens im Studium bzw. innerhalb der Fakultät (Meso-Ebene) oder drittens für die gesamte Hochschule (Makro-Ebene) genutzt werden (Watanabe, 2022). Andererseits können KI-Anwendungen aber auch anhand der Hochschulakteur:innen strukturiert werden, die diese Technologien einsetzen. So verwenden beispielsweise Khare et al. (2018) das Student Experience Practitioner Transitions Model (Morgan, 2018), um aufzuzeigen, inwiefern KI den Studierenden in verschiedenen Phasen des Studiums Unterstützung bietet. Neben den Studierenden gelten dabei auch die Hochschuladministration sowie die Lehrenden als mögliche Zielgruppen, die von KI-Anwendungen profitieren können. Vor allem in Lehr-Lernkontexten kann der Einsatz KI-basierter Technologien als Möglichkeit gesehen werden, um Dozierende zu unterstützen und zu entlasten (de Witt et al., 2020). Dabei kann zwischen zwei Typen von KI-Anwendungen unterschieden werden: Zum einen gibt es Anwendungen, die nur für Vor- bzw. Nachbereitung und Organisation von Lehre verwendet werden – beispielsweise für die Aufbereitung von Video-/Audioaufnahmen mittels Spracherkennung – und die Studierende nicht direkt tangieren. Ihnen stehen KI-Technologien gegenüber, die einen direkten Einfluss auf Studierende haben, etwa durch automatische Kontrolle von Übungen oder Klausuren.

Im Rahmen des hier präsentierten Forschungsprojekts *KI in der Hochschullehre* werden ausschließlich erstere aufgegriffen: KI-Anwendungen, die in Lehr-Lernkontexten Anwendung finden und damit die Studierenden unmittelbar betreffen. Dieses Vorgehen liegt in der eingangs erwähnten Studie des *Institute for Internet and Democracy* begründet, die zeigt, dass Studierende KI-Anwendungen wesentlich kritischer begegnen, wenn diese einen direkten Bezug zu ihren Studienleistungen aufweisen (Kieslich et al., 2019). Um einen strukturierten Überblick zu den unterschiedlichen KI-Anwendungen zu erhalten, werden diese im Folgenden in drei Gruppen geclustert. Diese Einteilung basiert auf den Systematic Review von Zawacki-Richter et al. (2019), allerdings wurden bei der hier vorliegenden Darstellung Intelligente Tutorsysteme und adaptive Lernumgebungen wegen ihrer inhaltlichen Nähe zusammengefasst:

- a) Intelligente Tutorsysteme (ITS) und adaptive Lernumgebungen unterstützen Studierende bei der Aneignung von Studieninhalten, indem sie z.B. Grundlagenwissen vermitteln oder abfragen. In diese Kategorie fallen auch viele KI-gestützte Chatbots, die beispielsweise das Erlernen einer Fremdsprache un-

terstützen. Allerdings sind diese KI-Anwendungen noch nicht flächendeckend im Studienbetrieb angekommen, sondern werden aktuell vor allem im Rahmen von Forschungs- oder Pilotprojekten eingesetzt (Fryer et al., 2017; Gallacher et al., 2018).

- b) KI-Frühwarnsysteme sind passiver, sie analysieren unterschiedliche Daten von Lernenden und errechnen auf dieser Basis, ob Studierende gefährdet sind, einen Kurs nicht zu bestehen oder gar ihr Studium abzubrechen. Das Ziel dieser Frühwarnsysteme besteht darin, sogenannte Risikostudierende zu identifizieren, sodass durch frühzeitige Interventionen der Studienerfolg gesichert werden kann (de Witt et al., 2020). Ein Beispiel für ein Learning-Analytics-gestütztes Vorhersagemodell wäre die an der Purdue University in Indiana (USA) eingesetzte Anwendung Course Signal (Arnold & Pistilli, 2012).
- c) Durch Bewertungs- und Evaluationstools erhalten Studierende individuelle, automatisierte Rückmeldungen zu ihren Studienleistungen, wodurch Lehrende entlastet werden. Vor allem im Bereich der Prüfungen spielen diese KI-Anwendungen eine wichtige Rolle: So können einerseits Prüfungen automatisch ausgewertet werden und andererseits Täuschungsversuche von Studierenden durch KI-Analysen aufgedeckt werden (Zawacki-Richter et al., 2019). Infolge der Corona-Pandemie werden inzwischen auch vermehrt sogenannte »AI-based proctoring systems« entwickelt, durch die Online-Prüfungen von KI überwacht werden können (Nigam et al., 2021).

Mit Blick auf die inhaltliche Unterteilung der KI-Anwendungen fällt auf, dass diese in der Lehre verschiedene Funktionen erfüllen. Sie stellen entweder unterstützende Tools dar, die den Dozierenden lediglich die Probleme der Studierenden oder verbesserungswürdige Aspekte der Lehrveranstaltung aufzeigen (z.B. die Frühwarnsysteme) oder nehmen eine aktivere Rolle im Lehr-Lernkontext ein, indem sie Aufgaben aus Bereich der Wissensvermittlung und -abfrage übernehmen (etwa im Fall der ITS und adaptiven Lernumgebungen) und dadurch die Lehrenden entlasten bzw. teilweise ersetzen. Anhand der KI- Bewertungs- und Evaluationstools wird allerdings auch deutlich, dass manche Anwendungen beide Funktionen erfüllen und die Lehrenden sowohl unterstützen als auch entlasten.

Darüber hinaus wird durch die inhaltliche Einteilung die Unmöglichkeit einer klaren Abgrenzung der KI-Anwendungen erkennbar. Z.B. können KI-Systeme zur Bewertung und Evaluation ebenfalls als essenzieller Aspekt der adaptiven Systeme oder der ITS gesehen werden (Watanabe, 2021). Zudem können intelligente KI-Tutoren eine Funktion bei adaptiven Systemen darstellen, welche Studierenden helfen sich auf der Lernplattform zurecht zu finden oder diese individuell beim Lernprozess unterstützen. Es kommt somit vor, dass adaptive Lernumgebungen mit ITS verschmelzen. Beispielsweise beschreibt das Whitepaper des KI-Campus das ITS

MathSpring (Arroyo et al., 2014) als adaptive Lernumgebung (de Witt et al., 2020) und zeigt damit, wie schwer eine genaue Unterscheidung der beiden KI-Trends ist.

Die hier beschriebenen theoretischen Überlegungen bilden die Grundlage für die inhaltliche Gestaltung des Workshops. Anhand der drei vorgestellten KI-Anwendungen (ITS und adaptive Lernumgebungen, Frühwarnsysteme und Bewertungs- und Evaluationstools) konnten drei inhaltliche Schwerpunkte für die KI-Szenarien im Videoformat abgeleitet werden:

1. **KI-gestütztes Lernen:** Das KI-gestützte Lernen ist ein wichtiger KI-Schwerpunkt in der Hochschullehre, weil es die Lernprozesse der Studierenden signifikant verbessern und sich dadurch direkt auf den Studienerfolg auswirken soll. Es umfasst adaptive Systeme und ITS, da diese Anwendungstypen Studierende beim Lernen unterstützen. In den Videos über die KI-Zukunftsszenarien, die für den Workshop entwickelt wurden, verdeutlicht dieser Schwerpunkt, wie KI-Anwendungen in Lehr-Lernkontexten eine aktive Lehr-Rolle einnehmen können.
2. **KI-Frühwarnsysteme:** Anhand des skizzierten Forschungsstands wird deutlich, dass großes hochschulpolitisches Interesse daran besteht, KI-gestützte Vorhersagen und insbesondere die Identifizierung von Risikostudierenden in Lehr-Lernkontexten auszuweiten. Gleichzeitig wurde jedoch in der Umfrage des Institute for Internet and Democracy deutlich, dass diese KI-Anwendungen von Studierenden besonders kritisch gesehen werden (Kieslich et al., 2019). Um die Positionen der Studierenden über KI-Frühwarnsysteme weiter zu erforschen, wäre ein Austausch über diese KI-Anwendungen im Rahmen eines Workshops hilfreich, in dem Studierende perspektivenreich über diese Systeme nachdenken und diskutieren. In den Videos zu den KI-Zukunftsszenarien kann anhand dieses Schwerpunkts außerdem aufgezeigt werden, wie KI-Anwendung durch das passive Sammeln und Analysieren von Daten Einfluss auf die Bewertung der Studierenden nehmen können.
3. **KI und Prüfungen:** In diesem Themenkomplex werden KI-Anwendungen referiert, die bei Evaluation, Bewertung und Korrektur oder bei der Überwachung von Prüfungen unterstützen. Anhand dieses KI-Schwerpunktes werden in den Videos Zukunftsszenarien gezeigt, in denen KI-Anwendungen sowohl passiv die Lehrenden unterstützen als auch einen aktiven Part einnehmen und eigenständige Bewertungen vornehmen.

2.2 Ergebnisse der explorativen Interviewstudie über KI-Akzeptanzfaktoren

Um die Gestaltung der Videos zu den KI-Zukunftsszenarien gezielt auf Themen auszurichten, die Studierende beschäftigen, wurden in einer explorativen Interview-

studie Chancen und Gefahren des KI-gestützten Lehrens und Lernens aus Studierendenperspektive herausgearbeitet. Dazu wurden sechs Studierende aus unterschiedlichen Fachrichtungen und Studienphasen im Rahmen eines *problemzentrierten Interviews* nach Witzel (Witzel, 1985) über den KI-Einsatz in der Hochschullehre befragt. Zur Strukturierung der Interviews und für die Herleitung des Fragebogens wurden im Vorfeld der aktuelle Forschungsstand zum KI-gestützten Lernen sowie verschiedene Akzeptanzmodelle¹ erfasst. Im Interview wurden die Studierenden dann sowohl zu Chancen und Gefahren als auch zu möglichen Bedingungen des KI-Einsatzes befragt. Folgende Potentiale von KI-Anwendungen konnten anhand der explorativen Interviewstudie identifiziert werden:²

1. **Optimierung des Studiums**

Durch die Inhaltsanalyse konnte aufgezeigt werden, dass aus Studierendenperspektive die Optimierung des Studiums einen wesentlichen Anteil der Chancen von KI-Anwendungen ausmacht. Dabei fokussieren die Studierenden vor allem die Förderung bzw. Verbesserung eines individualisierten, modernen, flexiblen, kontinuierlichen und effizienteren Lernens. Damit verbunden sind weitere Themen wie die Verbesserung der Betreuung oder das schnellere, zuverlässigere Erreichen des Studienabschlusses. Zudem thematisieren die Studierenden das Erkennen individueller Schwächen und Stärken durch die KI-Anwendungen und erhoffen sich, dass KI-Anwendungen ihnen dabei helfen, ihren Interessen und Fähigkeiten entsprechende Kurse auszuwählen.

2. **Bewertung und Feedback**

Besonders häufig sprechen die Studierenden bei der Befragung das individuelle Feedback durch die KI-Anwendungen an. Ergänzend wird auch die Leistungseinschätzung thematisiert. Die Studierenden gehen davon aus, dass KI-Anwendungen sowohl ihre Selbsteinschätzung als auch die Bewertung ihrer Leistung durch die Dozierenden unterstützen können. Die Überlegungen der Proband:innen zeigen in diesem Zusammenhang deutlich, dass sie sich von der Leistungseinschätzung durch KI-Anwendungen vor allem objektivere Bewertungen erhoffen. Darüber hinaus glaubt ein Proband, dass Lehrende durch den Einsatz von KI administrative Aufgaben (wie z.B. die Kontrolle von

1 Erfasst wurden z.B. die Diffusionstheorie (Rogers, 2003), die Theory of Reasoned Action und deren Weiterentwicklung, die Theory of Planned Behavior (Fishbein & Ajzen, 1975;1975, Ajzen, 2002) sowie das Technology Acceptance Model (Davis 1985, 1989).

2 Die hier vorgestellten Chancen und Gefahren wurden bereits in ausführlicher Version und nahezu identischem Wortlaut in der Masterarbeit *Künstliche Intelligenz in der Hochschullehre. Eine explorative Interviewstudie zu Akzeptanzfaktoren aus Studierendenperspektive* veröffentlicht (Watanabe, 2021).

Übungsaufgaben) minimieren und dadurch mehr Zeit für die Betreuung der Studierenden haben könnten.

3. **Motivation**

Die Aussagen der Proband:innen deuten darauf hin, dass Studierende sich von KI-Anwendungen Hilfe bei der Kurswahl erhoffen – was wiederum ihre Leistungsbereitschaft steigern könnte. Darüber hinaus erweist sich die Motivation der Studierenden auch als eng verflochten mit der Bewertung durch eine Maschine. So sind einige der Befragten der Meinung, dass sie eine geringere Hemmschwelle und eine größere Motivation hätten, Fragen zu stellen, wenn kein Mensch, sondern ein KI-System diese beantworten würde.

Neben den Chancen konnten vier Kategorien für die Gefahren des KI-Einsatzes abgeleitet werden:

1. **Bewertung**

Die Analyse der Interviews zeigt, dass die befragten Studierenden die KI-gestützte Bewertung teils kritisch sehen. Dabei werden einerseits mögliche Auswirkungen der automatischen Bewertung auf die Lernenden aufgegriffen. Andererseits wird die Frage aufgeworfen, inwieweit die KI-gestützte Bewertung die Lehrenden negativ beeinflussen könnte. Ergänzend stellt ein Proband die Frage, ob KI die menschliche Bewertung ersetzen oder zumindest eine Vernachlässigung derselben bewirken kann.

2. **Technische Umsetzung**

Als weitere Gefahr wird die technische Umsetzung der KI-Anwendungen angesprochen. In diesem Zusammenhang bezweifeln die Studierenden, dass eine KI komplexes Lernverhalten nur auf Grundlage von Daten bewerten kann. Zudem besteht bei einigen Proband:innen die Sorge, dass die KI zu rigide bewerten und Faktoren wie die individuellen Lerngewohnheiten der Studierenden nicht berücksichtigen könnte.

3. **Daten**

Dieser Kategorie werden all jene Aussagen zugeordnet, die negative Aspekte bezüglich der Datenverwendung ansprechen. Die Inhaltsanalyse zeigt, dass einige Proband:innen der persönlichen Datenfreigabe als Voraussetzung für die KI-Anwendung generell abgeneigt sind. Als konkreter Grund dafür wird unter anderem die Angst vor Datenmissbrauch durch die Hochschule oder andere Akteur:innen – z.B. Hacker:innen oder mit den Hochschulen kooperierende Unternehmen – angeführt. In einem engen Zusammenhang damit steht auch die Sorge um die eigene Privatsphäre. Zudem verweisen die Studierenden auf die Gefahr struktureller Diskriminierung durch die KI. Ergänzend thematisieren manche Proband:innen auch eine Abwägung zwischen den Risiken der Datenfreigabe und der Genauigkeit beziehungsweise dem grundsätzlichen Funktio-

nieren der KI-Anwendung. Dabei wird die Verweigerung der Freigabe für bestimmte persönliche Datentypen (z.B. Freizeitdaten) grundsätzlich als relevanter bewertet als eine optimal arbeitende KI.

4. **Verlust von selbstzweckhaften Elementen im Studium**

Als vierte Gefahr konnte das durch KI-Anwendungen bedingte Fehlen oder die Reduktion selbstzweckhafter Elemente im Studium identifiziert werden. Einige der Befragten befürchten, dass das Studium durch KI-gestütztes Lehren und Lernen nur noch auf Optimierung und Effizienz ausgerichtet wird und Themen, die nicht prüfungsrelevant sind, zunehmend verdrängt werden. Außerdem thematisieren die Proband:innen, dass Studierende durch KI-Anwendungen die Fähigkeit verlieren könnten, eigene Lernstrategien zu entwickeln oder Probleme selbstständig zu erkennen.

Die in diesem Kapitel aufgezeigten Chancen und Gefahren werden in den KI-Zukunftsszenarien überspitzt aufgegriffen und ermöglichen es so, unterschiedliche Aspekte des KI-Einsatzes in der Hochschullehre dazustellen.

3 **Konstruktion des Workshops**

Nachdem im vorherigen Kapitel die theoretischen und empirischen Grundlagen dargestellt wurden, erläutert dieses Kapitel den Aufbau und die Bestandteile des Workshopkonzeptes sowie die geplante Umsetzung. Im ersten Teil des Workshops steht die Wissensvermittlung über das KI-gestützte Lehren und Lernen im Mittelpunkt. Um in das Thema einzuführen und Studierende sowohl für die Chancen als auch für die Gefahren des KI-Einsatzes zu sensibilisieren, wurden mögliche Zukunftsszenarien in Form von animierten Videos entwickelt, die sich die Teilnehmenden zum Einstieg ansehen. Die dahinterstehenden didaktischen Überlegungen (3.1) und die konkrete Umsetzung der Videos (3.2) werden im Folgenden dargestellt. Danach wird der zweite Teil des Workshops erläutert, der den Studierenden Raum für Austausch und eigenständiges Nachdenken über KI in der Hochschullehre bietet. Abschließend werden erste Pilotveranstaltungen sowie die weiteren Pläne für die Umsetzung des Workshopkonzeptes skizziert (3.3).

3.1 **KI-Zukunftsszenarien zur Wissensvermittlung**

Vor dem Hintergrund der theoretischen Überlegungen zu aktuellen KI-Trends (2.1) und der darauf aufbauenden Interviewstudie (2.2) konzentrieren sich die Zukunftsszenarien auf drei KI-Schwerpunkte: a) KI-gestütztes Lernen, b) KI-Frühwarnsysteme sowie c) KI und Prüfungen. Dabei wird pro Video je ein positives und ein negatives Szenario zu ein- und demselben Thema präsentiert, um verschiedene Perspek-

tiven auf den KI-Einsatz in der Hochschullehre aufzuzeigen. Für den Einstieg in den Workshop wurden diese Zukunftsszenarien in Form von animierten Videos umgesetzt, da diese eine anschauliche Darstellung der unterschiedlichen KI-Trends sowie der möglichen Chancen und Gefahren des KI-gestützten Lernens ermöglichen. Darüber hinaus verwenden Bildungswissenschaftler:innen das Medium Film häufig zur Vermittlung von Lehrinhalten und mediendidaktischer Aktivierung (Meinhard et al., 2014; Persike, 2020). Gerade im Zusammenhang mit Zukunftsforschung in der Hochschulbildung fördern Filme und kurze Videoclips die Vorstellungskraft, das Problembewusstsein und die Diskussionsbereitschaft der Studierenden. Wenn es um den Einsatz von neuen Technologien geht, greifen Lehrende daher gerne auf audiovisuelle Darstellungsformen zurück, um ein bestimmtes Problem greifbarer zu machen. So wird z.B. gerne auf die Filme *Minority Report* (2002) oder *Matrix* (1999) verwiesen, wenn Studierende sich kritisch mit neuen Technologien auseinandersetzen sollen (Tiberius, 2011). Als mediendidaktisches Werkzeug bietet dabei insbesondere das animierte Videoformat großes Potenzial, da es – im Vergleich zum Realfilm – auch imaginierte Zukunftsszenarien flexibel, kostengünstig und kreativ darstellen kann. Hinzu kommt, dass die Animation ein Digitales Storytelling ermöglicht, das komplexe und abstrakte Themen – wie das KI-gestützte Lehren und Lernen – aufbricht und erfahrbar macht (Jahn et al., 2018). Im konkreten Fall der KI-Zukunftsszenarien für den Workshop fiel die Entscheidung außerdem auch aus wirtschaftlichen Gründen auf animierte Videos, da eine Video-Produktion mit Schauspieler:innen die finanziellen Mittel des Projektes überstiegen hätte.

Grundsätzlich sind alle drei Zukunftsszenarien so aufgebaut, dass die Protagonistin Daria, eine wissbegierige und forschende Studentin, gemeinsam mit ihrem Mitbewohner Dan eine What-If-Else-Maschine benutzt, um verschiedene Parallelwelten zu besuchen, in denen entweder positive oder negative Aspekte eines ausgewählten KI-Trends erlebt werden. Die für die Videos gewählte Erzählform kann dem Genre der *Storytime Animation* zugeordnet werden. »Storytime animation is a form of short animated content [...], characterized by autobiographical, usually comedic stories, recognizable personas, [...] as well as simplistic, animatics-style animation« (Ratelle, 2020). Sie zeichnet sich insbesondere dadurch aus, dass eine Figur – hier: Daria – eine Geschichte erzählt. In der Animation werden dann verschiedene Elemente dieser Geschichte aufgegriffen, visualisiert und dadurch erlebbar gemacht. Storytime Animation erfreut sich derzeit z.B. auf der Plattform YouTube ((Ratelle, 2020) großer Beliebtheit und bildet damit eine gute Grundlage, um Studierende für das Thema zu begeistern. Für den Workshop wurde diese Form der Darstellung allerdings vor allem aus einem anderen Grund gewählt: Storytime Animation ist in der Lage, komplexe Themenfelder für Studierende auf einfache und amüsante Weise erfahrbar zu machen, und kann somit einen niedrigschwelligen Zugang zur Diskussion über KI ermöglichen.

3.2 Konkrete Umsetzung der KI-Szenarien im Videoformat

Alle Videos dauern circa fünf Minuten und sind nach demselben Prinzip aufgebaut, sodass die Episoden sowohl gemeinsam als auch allein in Lehr-Lernkontexten eingesetzt werden können. Jedes Video umfasst ein kurzes Intro und zwei Versionen eines KI-Zukunftsszenarios, in denen entweder die Chancen oder die Gefahren des jeweiligen KI-Trends beleuchtet werden. Zum Schluss fordert Protagonistin Daria die Zuschauer:innen zur Diskussion über das jeweilige Thema auf. Mithilfe von Farbwechseln werden die Chancen (helles Blau) und Gefahren (leuchtendes Orange) in den Videos auch visuell unterstrichen und als unterschiedliche Perspektiven kenntlich gemacht. Das Video zum KI-gestützten Lernen wird in diesem Kapitel kurz inhaltlich umrissen. Alle drei KI-Zukunftsszenarien sind unter folgenden Link verfügbar:

Studierende im KI-Diskurs

Video 1: <https://link.transcript-open.de/5769/video/004>

© Alice Watanabe, Tobias Schmohl, Larissa Jablotschkin, Clarissa Gora, Conrad Dreyer, Laura Zuckschwerdt



Video 2: <https://link.transcript-open.de/5769/video/005>




Video 3: <https://link.transcript-open.de/5769/video/006>



Das Video über KI-gestütztes Lernen führt zunächst in das Thema ein, indem sich die beiden Protagonist:innen über die Chancen und Gefahren von KI im Allgemeinen austauschen. In der nächsten Szene beschließen sie, ihre Diskussion zu vertiefen, und reisen mit einer What-If-Else-Maschine in zwei Parallelwelten, in denen KI bereits in Lehr-Lernkontexten eingesetzt wird. Daria beschreibt das im Voiceover wie folgt:

Ich habe natürlich meine »What-If-Else-Machine« rausgeholt und bin mit [Dan] auf ein Abenteuer durch die Best und Worst Cases unseres Disputs gegangen, um die Lernunterstützung durch Künstliche Intelligenz aus nächster Nähe begutachten zu können.


Abbildung 1: Darstellung der What-If-Else-Machine (eigene Darstellung).



In der ersten Parallelwelt wird der Fokus auf die positiven Aspekte des KI-gestützten Lernens gelegt und bewusst überspitzt aufgezeigt, welche Vorteile durch diese Technologie in der Hochschullehre entstehen können:

Außerdem sammelt die KI Daten zu [Dans] Lernverhalten, wie z.B. die Geschwindigkeit der Aufgabenlösung, wie fokussiert er ist oder ob er sich irgendwie ablenkt. Und dann gibt sie darauf basierend Tipps, Erklärungen, Ermahnungen oder einen sanften Impuls zum Weiterarbeiten. Durch diese Eins-zu-eins-Betreuung ist Dan viel effizienter, muss weniger Zeit ins Lernen stecken und kommt obendrein noch besser voran.


Abbildung 2: Daria erklärt die KI-Lernunterstützung (eigene Darstellung).



Im darauffolgenden Teil des Videos werden hingegen die Gefahren und Grenzen des KI-Einsatzes in der Hochschullehre thematisiert, wobei der Fokus auf fehlerhaften und schlechten Umsetzungen der KI-Anwendung liegt.

Dan [...] hat anfangs einige Flüchtigkeitsfehler gemacht. Die KI hat danach entsprechend leichte Aufgaben gewählt, um Dan zu fördern. Und als er die dann, nachdem er sich beruhigt hatte, in einem Wahnsinnstempo durchgezogen hat, hat die KI ihm unterstellt, er würde schummeln. Hat er natürlich nicht, aber das mussten wir dem Admin der Übung erstmal erklären.

Abbildung 3: Die KI wirft Dan vor, er schummle bei der Übung (eigene Darstellung).



3.3 Diskussion über die Chancen, Gefahren und Bedingungen von KI

Ziel des Workshops ist es, dass Studierende Informationen über den KI-Einsatz in der Hochschullehre erhalten und beginnen, sich mit dem KI-gestützten Lernen auseinanderzusetzen. Dabei sollen sie Argumente für und gegen die KI-Nutzung abwägen. Um eine bessere Vorstellung von der Workshopgestaltung zu erhalten, wird im Folgenden der genaue Ablauf umrissen. Durch diese Beschreibung wird deutlich, welche qualitativen Daten im Rahmen des Workshops gesammelt werden können. Der Workshop umfasst zwei dreistündige Seminarsitzungen sowie eine asynchrone Gruppenarbeitsphase zwischen den Sitzungen. Zu Beginn der ersten Sitzung schauen sich die Studierenden alle drei Zukunftsszenarien im Videoformat an. Danach wählen sie eines der darin vorgestellten Themen – KI-gestütztes Lernen, KI-Frühwarnsysteme oder KI und Prüfungen – aus und werden basierend auf ihrer Auswahl in Gruppen zu je vier Studierenden eingeteilt. In diesen Gruppen diskutieren sie dann auf Grundlage der Videos über die Gefahren, Chancen und Bedingungen des KI-Einsatzes in der Hochschullehre.

Um eine facettenreiche Diskussion zu ermöglichen, wird der Austausch gemäß der Methode der *Six Thinking Hats* nach Edward de Bono (Aithal et al., 2016) strukturiert. Dabei betrachten die Studierenden das KI-Thema ihrer Gruppe stets im Hinblick auf einen einzelnen Aspekt. Jede dieser Perspektiven wird einem sogenannten Denk-Hut zugeordnet:

- Spontane Gefühle (roter Hut)
- Positive Aspekte (gelber Hut)
- Negative Aspekte (schwarzer Hut)
- Benötigte Informationen (weißer Hut)

- Kreative Ideen (grüner Hut)
- Bedingungen (blauer Hut): Der Aspekt der Organisation (blauer Hut) wird im Workshop durch die Perspektive der Bedingungen ersetzt, unter denen die Studierenden dem KI-Einsatz im jeweiligen Anwendungskontext zustimmen würden (Aithal et al., 2016).

Abbildung 4: Six Thinking Hats (eigene Darstellung).



Während der Gruppendiskussion halten die Studierenden ihre Überlegungen schriftlich fest. Nach Ende dieser Arbeitsphase stellen sie ihre Ergebnisse im Plenum vor und bekommen somit auch Einblicke in die unterschiedlichen Diskussionsschwerpunkte und Argumente der anderen Gruppen. Im Anschluss halten Mitarbeitende des Forschungsprojektes einen kurzen Vortrag, in dem noch einmal strukturiert mögliche Chancen und Gefahren sowie der aktuelle KI-Forschungsstand für die Studierenden zusammengefasst werden.

In der asynchronen Arbeitsphase wählen die Studierenden in ihren Gruppen einen KI-Schwerpunkt aus den Videos aus und diskutieren in einem gemeinsamen Essay (ca. drei Seiten) eine der Chancen und eine der Gefahren. Dabei können sie entweder auf die vom Workshop-Team vorgestellten Potentiale oder Risiken zurückgreifen oder eigens überlegte Aspekte thematisieren. In ihren Essays leiten die Studierenden zusätzlich mögliche Bedingungen ab, unter denen der von ihnen gewählte KI-Trend in der Hochschullehre eingeführt werden könnte. Ihre Diskussi-

on und die herausgearbeiteten Bedingungen präsentieren die Studierenden sowohl in dem Essay als auch in einem kurzen Erklärvideo (ca. 2–3 Minuten). Dieses Video erstellen die Studierenden mit dem kostenfreien Tool *SimpleShow*, das es ihnen ermöglicht, in kurzer Zeit professionelle Legefilme zu gestalten. Die besondere Machart des Legefilms, welche sich durch das Finden und die Anordnung von passenden bildlichen Gegenständen auszeichnet, und die zeitliche Begrenzung (max. 3 Minuten) hilft den Studierenden dabei, ihre wichtigsten Erkenntnisse pointiert zusammenzufassen.

In der folgenden Sitzung schauen sich die Studierenden zunächst die unterschiedlichen Erklärvideos an und hinterlassen schriftliches Feedback auf einer digitalen Plattform für ihre Mitstudierenden. Durch dieses Vorgehen erhalten die Lernenden Einblicke in unterschiedliche KI-Themenbereiche. Zum Abschluss erfolgt eine inhaltliche Diskussion, in der zunächst die Studierenden ihre Hauptkenntnisse erläutern. Der Workshop endet mit einer Evaluation, in der sowohl der Inhalt als auch die didaktische Umsetzung thematisiert werden.

Die Konzeption des Workshops ist bereits abgeschlossen. Eine verkürzte Variante wurde als Pilotformat im Rahmen des digitalen *University Future Festival* am 04.11.2021 und bei der Delfi-Fachtagung zu neuen Bildungstechnologien am 12.09.2022 durchgeführt. Im nächsten Schritt wird der Workshop im Wintersemester 2022/23 in zwei jeweils dreistündigen Sitzungen des Seminars *Mediendidaktik* an der Technischen Hochschule Ostwestfalen-Lippe stattfinden. Sowohl das Essay als auch das Erklärvideo fließen über eine Portfolio-Prüfung in die Seminarnoten der Studierenden ein.

4 Ausblick

Da aktuell erst die Konzeption des Workshops abgeschlossen ist, wird nun die Durchführung im Mittelpunkt stehen. Das im Workshop entstehende Datenmaterial (Stichpunkte der Gruppendiskussion, Essays und Erklärvideos) wird zudem eine Grundlage für bildungswissenschaftliche Begleitforschung zum Thema *Akzeptanz von KI in der Hochschullehre* bilden. Auf Basis der Daten kann im Folgenden erforscht werden, welche Aspekte und Bedingungen beim KI-Einsatz für Studierende eine Rolle spielen. Das langfristige Ziel des Projektes ist es, auf Basis der gewonnenen Daten einen Leitlinienkatalog zu entwickeln, welcher die Ergebnisse aus den Workshops zusammenfasst. Durch diesen Leitlinienkatalog können KI-Projekte und Hochschulen eine erste Orientierung hinsichtlich der Frage erhalten, welche KI-Themenkomplexe von Studierenden unter welchen Bedingungen akzeptiert werden.

Jenseits dieses primären Forschungsvorhabens lassen sich die KI-Szenarien im Videoformat aber auch in anderen Kontexten verwenden. Z.B. können die Videos

als Einleitung für Seminare über das KI-gestützte Lehren und Lernen genutzt werden. Darüber hinaus ist es ebenfalls möglich, dass Studierende die Videos als Denkanstoß benutzen, um sich eigenständig mit dem KI-Einsatz in Lehr-Lernkontexten auseinanderzusetzen. In diesem Zusammenhang ist geplant, auch eine Variante der KI-Videos mit interaktiven Elementen zu entwickeln. So sollen etwa Studierende über in die Videos eingebettete Umfragen erste Einschätzungen zu den KI-Trends geben können und dadurch zum Nachdenken über KI angeregt werden.

Damit möglichst viele Lehrende und Studierende von den KI-Videos profitieren, ist intendiert, diese kostenfrei der wissenschaftlichen Öffentlichkeit zur Verfügung zu stellen. Studierende, Lehrende, Stiftungen oder Forschungszentren und Schulen (vor allem in der Oberstufe) können die KI-Zukunftsszenarien verwenden, um eigene Forschung oder Lehre im Bereich der Akzeptanzforschung zu KI betreiben. Das Vorhaben eröffnet somit weitere Forschungsfelder.

Auch wenn bislang noch keine soliden Datenerhebungen zu eventuellen Limitationen der Videos oder des Workshops vorliegen, weil bis zum Zeitpunkt der Manuskriptlegung nur erste Tests durchgeführt wurden, ist es abschließend dennoch wichtig, auf die Limitation des Projektes insgesamt einzugehen. Zwar stellt der Workshop eine Möglichkeit dar, um Studierende zur Auseinandersetzung mit dem KI-Einsatz und insbesondere zum Einnehmen verschiedener Perspektiven auf das Thema anzuregen, doch bietet dieses Format keine Gelegenheit zur Vertiefung oder zur eingehenden Evaluation des Gelernten. Infolgedessen reicht der Workshop allein nicht aus, um Studierenden ein umfassendes Bild von KI zu vermitteln. Das Vorhaben ist daher nicht als umfangreiches Konzept zur Förderung der individuellen Meinungsbildung, sondern vielmehr als ein erster Denkanstoß zu verstehen, auf dessen Basis das KI-gestützte Lehren und Lernen weiter erschlossen werden kann.

Alice Watanabe: Technische Hochschule Ostwestfalen-Lippe, Forschungsprojekt HANs; alice.watanabe@th-owl.de & Hochschule für Angewandte Wissenschaften Hamburg, Fachbereich VWL; alice.watanabe@haw-hamburg.de

Literatur

- Aithal, S., Shailashri, V. T. & Kumar, S. (2017). Factors & Elemental Analysis of Six Thinking Hats Technique Using ABCD Framework. *International Journal of Advanced Trends in Engineering and Technology*, (1), 85–95.
- Ajzen, I. (2002). Perceived Behavioral Control, Self-Efficacy, Locus of Control, and the Theory of Planned Behavior. *Journal of Applied Social Psychology*, 32(4), 665–683.
- Aldosari, S. A. M. (2020). The Future of Higher Education in the Light of Artificial Intelligence Transformations. *International Journal of Higher Education*, 9(3), 145–151.

- Arnold, K. E. & Pistilli, M. D. (2012). Course Signals at Purdue. Using Learning Analytics to Increase Student Success. In S. Dawson, C. Haythornthwaite, S. Buckingham Shum, D. Gasevic & R. Ferguson (Hrsg.), *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge* (S. 267–270). New York.
- Arroyo, I., Woolf, B. P., Burelson, W., Muldner, K., Rai, D. & Tai, M. (2014). A Multimedia Adaptive Tutoring System for Mathematics that Addresses Cognition, Metacognition and Affect. *International Journal of Artificial Intelligence in Education*, 24(4), 387–426.
- Bates, T., Cobo, C., Mariño, O. & Wheeler, S. (2020). Can Artificial Intelligence Transform Higher Education? *International Journal of Educational Technology in Higher Education*, 17(42), 1–12.
- Büching, C., Mah, D.-K., Otto, S., Paulicke, P., & Hartman, E. (2019). Learning Analytics an Hochschulen. In V. Wittpahl (Hrsg.), *Künstliche Intelligenz. Technologie, Anwendung, Gesellschaft* (S. 142–160). Berlin: Springer.
- Davis, F. D. (1989). Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *Management Information Systems Quarterly*, 13(3), 319–340.
- Davis, F. D. (1985). *A Technology Acceptance Model for Empirically Testing New End-User Information Systems. Theory and Results*. Cambridge, Massachusetts: Massachusetts Inst. of Technology.
- de Witt, C., Rampelt, F. & Pinkwart, N. (2020). *Whitepaper "Künstliche Intelligenz in der Hochschulbildung"*. Berlin: KI-Campus.
- Fishbein, M. & Ajzen, I. (1975). *Belief, Attitude, Intention and Behavior. An Introduction to Theory and Research*. Boston: Addison-Wesley.
- Fryer, L. K., Nakao, K. & Thompson, A. (2019). Chatbot Learning Partners: Connecting Learning Experiences, Interest and Competence. *Computers in Human Behavior*, 93, 279–289.
- Gallacher, A., Thompson, A. & Howarth, M. (2018). "My robot is an idiot!" – Students' Perceptions of AI in the L2 Classroom. In P. Taalas, J. Jalkanen, L. Bradley & S. Thouësný (Hrsg.), *Future-proof CALL: Language Learning as Exploration and Encounters – Short Papers from EUROCALL 2018* (S. 70–76).
- Humble, N. & Mozelius, P. (2019). Artificial Intelligence in Education – A Promise, a Threat or a Hype. In P. Griffiths & M. N. Kabir (Hrsg.), *Proceedings of the European Conference on the Impact of Artificial Intelligence and Robotics* (S. 149–156). UK: Academic Conferences & Publishing.
- Jahn, D., Tress, D., Attenberger, C. & Chmel, L. (2018). Lernvideos können mehr als nur Erklären: Eine Studie zum Einsatz von narrativen Film-Ankern in einer hochschuldidaktischen Online-Weiterbildung. In J. Buchner, C. F. Freisleben-Teutscher, J. Haag & E. Rauscher (Hrsg.), *Inverted classroom, vielfältiges Lernen* (S. 149–163). St. Pölten: Fachhochschule St. Pölten.

- Khare, K., Stewart, B. & Khare, A. (2018). Artificial Intelligence and the Student Experience: An Institutional Perspective. *IAFOR Journal of Education*, 6(3), 63–78.
- Kieslich, K., Lünich, M., Marcinkowski, F., & Starke, C. (2019). Hochschule der Zukunft: Einstellungen von Studierenden gegenüber Künstlicher Intelligenz an der Hochschule. *Institute for Internet und Democracy*. Zugriff am 17.09.2022. Verfügbar unter: https://www.researchgate.net/profile/kimon-kieslich/publication/336588629_hochschule_der_zukunft_einstellungen_von_studierenden_gegenueber_kuenstlicher_intelligenz_an_der_hochschule.
- Klutka, J., Ackerly, N., & Magda, A. J. (2018). *Artificial Intelligence in Higher Education: Current Uses and Future Applications*. Louisville: Learning house.
- Marcinkowski, F. & Starke, C. (2019). Wann ist Künstliche Intelligenz (un-)fair? Ein sozialwissenschaftliches Konzept von KI-Fairness. In J. Hofmann, N. Kersting, C. Ritzi & W. Schünemann (Hrsg.), *Politik in der digitalen Gesellschaft. Zentrale Problemfelder und Forschungsperspektiven* (S. 269–288). Bielefeld: transcript.
- Meinhard, D. B., Clames, U. & Koch, T. (2014). Zwischen Trend und Didaktik – Videos in der Hochschullehre. *Zeitschrift für Hochschulentwicklung*, 9(3).
- Morgan, M. (2013). The Student Experience Practitioner Model. In M. Morgan (Hrsg.), *Supporting Student Diversity in Higher Education. A Practical Guide* (S. 69–88). London: Routledge.
- Nigam, A., Pasricha, R., Singh, T. & Churi, P. (2021). A Systematic Review on AI-based Proctoring Systems: Past, Present and Future. *Education and Information Technologies*, 26(5), 6421–6445.
- Ocaña-Fernández, Y., Valenzuela-Fernández, L. A. & Garro-Aburto, L. L. (2019). Artificial Intelligence and Its Implications in Higher Education. *Journal of Educational Psychology – Propósitos Y Representaciones*, 7(2), 553–568.
- Persike, M. (2020). Videos in der Lehre: Wirkungen und Nebenwirkungen. In H. Niegemann & A. Weinberger (Hrsg.), *Handbuch Bildungstechnologie* (S. 271–301). Berlin: Springer.
- Ratelle, A. (2020). Konstantinos Pappis: The Odd Ones Out: The Rise of YouTube Storytime Animation. *Animation Studies. Journal for Animation History and Theory*, (15). Zugriff am 19.09.2022. Verfügbar unter: <https://journal.animationstudies.org/konstantinos-pappis-the-odd-ones-out-the-rise-of-youtube-storytime-animation/>.
- Rogers, E. M. (2003). *The Diffusion of Innovations* (5. Aufl.). New York: Free Press.
- Seufert, S., Guggemos, J. & Sonderegger, S. (2020). Digitale Transformation der Hochschullehre: Augmentationsstrategien für den Einsatz von Data Analytics und Künstlicher Intelligenz. *Zeitschrift für Hochschulentwicklung*, 15(1), 81–101.
- Tiberius, V. (2011). *Hochschuldidaktik der Zukunftsforschung*. Berlin, Wiesbaden: Springer.
- Tuomi, I. (2018). The Impact of Artificial Intelligence on Learning, Teaching, and Education. Policies for the Future. *European Commission. JRC Science for Policy Report*.

- Wannemacher, K., & Bodmann, L. (2021). *Künstliche Intelligenz an den Hochschulen. Potenziale und Herausforderungen in Forschung, Studium und Lehre sowie Curriculumentwicklung* (Arbeitspapier Nr. 59). Berlin: Hochschulforum Digitalisierung.
- Watanabe, A. (2021). *Künstliche Intelligenz in der Hochschullehre. Eine explorative Interviewstudie zu Akzeptanzfaktoren aus Studierendenperspektive* (Masterarbeit). Hamburg: Universität Hamburg
- Watanabe, A. (2022). Let's Talk about Artificial Intelligence. How Scholarship of Teaching and Learning Can Enhance the AI Scientific Discourse in Higher Education. In F. Almaraz Menéndez et al. (Hrsg.): *Strategy, Policy, Practice, and Governance for AI in Higher Education Institutions* (S. 48–72). Hershey, Pennsylvania, USA.: IGI. Global.
- Witzel, A. (1985). Das problemzentrierte Interview. In G. Jüttemann (Hrsg.): *Qualitative Forschung in der Psychologie. Grundfragen, Verfahrensweisen, Anwendungsfelder* (S. 227–255). Weinheim: Beltz.
- Zawacki-Richter, O., Marín, V., Bond, M., & Gouverneur, F. (2019). Systematic Review of Research on Artificial Intelligence Applications in Higher Education: Where Are the Educators? *International Journal of Educational Technology in Higher Education*, 16(1), 16–39.

Digitale Lernumwelten, studentische Diversität und Learning Outcomes: Empirische Befunde und Implikationen für die digitale Hochschulbildung

Anja Gottburgsen, Yvette E. Hofmann und Janka Willige

Abstract: *Digitalen Lernumwelten, die Künstliche Intelligenz (KI) einsetzen, wird zugeschrieben, dass sie der Diversität Studierender, ihren unterschiedlichen Lebenslagen und differierenden Lernvoraussetzungen sowie -erfahrungen besser gerecht werden, indem sie flexibles, zeit- und ortsunabhängiges sowie personalisiertes Lernen ermöglichen und somit zum individuellen Lern- und Studienerfolg beitragen können. Dieser Beitrag gibt einen Überblick, in welcher Weise die Vielfalt der Studierenden bisher in die empirische Forschung zur digitalen Hochschulbildung (unter Einbeziehung von KI) Eingang gefunden hat. Während diversitätsorientierte Studien zur ICT-Literacy sowie zu Mediennutzung und -präferenzen diverser Studierendengruppen international vorhanden sind, werden die Effekte digitaler Lernumwelten bzw. Lernformate oder die Auswirkungen von KI auf die Learning Outcomes einer divers zusammengesetzten Studierendenschaft (z.B. Lernerfolge, Mobilität) auch international selten thematisiert. Der vorliegende Beitrag stellt daher exemplarisch aktuelle Befunde zum Einfluss digitaler Lernumwelten auf die Mobilität diverser Studierender vor und zeigt, welche Ansatzpunkte und Herausforderungen für künftige Forschung zur digitalen Hochschulbildung bestehen.*

Digital learning environments using artificial intelligence (AI) are viewed as better able to accommodate the diversity of students, their different life situations, different learning conditions and experiences, as they allow individuals to learn more flexible and more personalised, independent of time and place, and thus contribute to their success in learning and studying. This paper provides an overview of the ways in which student diversity has been included in empirical research on digital higher education (involving AI) to date. While diversity-oriented studies on ICT literacy and on the media use or media preferences of various student groups are available internationally, effects of digital learning environments, different digital learning formats or even AI on the learning outcomes of a diverse student body (e.g. learning success, mobility) are rarely addressed. Therefore, we present current findings on the influence of digital learning environments on the mobility of diverse students as an example and point out the starting points, but also challenges that exist for future research in this area.

Keywords: *Diversitätsdimensionen, digitale Lehr-Lernformate, digitale Lernumgebungen mit künstlicher Intelligenz, Learning Outcomes / dimensions of diversity, digital teaching/learning formats, digital learning environments using artificial intelligence, learning outcomes.*

1 Einleitung

Die Corona-Pandemie löste in der Hochschulbildung in Deutschland einen weitreichenden Digitalisierungsschub aus: Innerhalb kürzester Zeit wurde zum Sommersemester 2020 der Lehr- und Studienbetrieb weitgehend digitalisiert. Dabei gelang die fast vollständige Umstellung auf digitale Lehr-Lernformate (Lörz, Marczuk, Zimmer, Multrus, & Buchholz, 2020; Winde, Werner, Gumbmann, & Hieronimus, 2020). Der Begriff »digitale Lernumwelt« umfasst allerdings ein noch deutlich größeres Spektrum technischer Möglichkeiten, um Lehr-Lernprozesse zu unterstützen, als selbst in der Pandemie ausgeschöpft wurde. So werden darunter nicht nur die bereits seit Jahren an den Hochschulen etablierten digitalen Medien (z.B. Clicker, Lehrveranstaltungsaufzeichnungen) oder jene rein digitalen Lehr-Lernformate verstanden, die vor dem Hintergrund des Social Distancing so rasant an Beliebtheit gewonnen haben (reines Online-Lernen im Vergleich zum Blended Learning, z.B. in Form des Umgekehrten Unterrichts im Inverted/Flipped Classroom). Darüber hinaus umfasst der Begriff »digitale Lernumwelten« auch zahlreiche Möglichkeiten, die es erst noch zu erschließen gilt – Technologien, die es ermöglichen, durch den Einsatz von KI-Applikationen, personalisierte und adaptive Lernumgebungen zu schaffen (z.B. Chatbots, persönliche virtuelle Assistenten, intelligente Systeme für kollaboratives Lernen, automatisiertes Assessment, vgl. de Witt, Rampelt, & Pinkwart, 2020; Zawacki-Richter, Marín, Bond, & Gouverneur, 2019). Dass die Gestaltung digitaler Lernumwelten in der deutschen Hochschulbildung vor Beginn der Corona-Pandemie nur zögerlich aufgenommen worden war, belegen die Angaben von Studierenden und Lehrenden zum Wintersemester 2019/2020. So fanden Winde et al. (2020) in ihrer Befragung von 1.800 Lehrenden, dass diese vor Corona gerade einmal 12 Prozent ihrer Lehrangebote digital zur Verfügung gestellt hatten (vgl. auch Hofmann, 2020), während sich dieser Anteil in der Pandemie bei den Befragten auf 91 Prozent erhöhte. Auch in der Befragung von Lörz et al. (2020) bestätigen die Angaben von rund 25.000 Studierenden zu ihren Erfahrungen mit dem digitalen Lehr- und Studienbetrieb diesen Befund für das Wintersemester 2019/20: Nur 5 % der befragten Studierenden berichten, dass bereits alle ihre Lehrveranstaltungen in Online-Formaten stattgefunden haben, bei nur 3 % waren es mehr als die Hälfte (1 %) oder etwa die Hälfte (2 %), während für 88 Prozent der Studierenden vor Corona kein besuchtes Lehrangebot digital verfügbar war.

Die bisherige Zurückhaltung beim Einsatz vollständig digitalisierter Lehr-Lernformate und auch von KI in der Hochschulbildung in Deutschland (vgl. Aktionsrat Bildung; 2018; Schmid, Goertz, Radomski, Thom, & Behrens, 2017; Bond, Marín, Dolch, Bedenlier, & Zawacki-Richter, 2018) erstaunt insofern als gerade diese die vor dem Hintergrund expandierender Studierendenzahlen bei gleichzeitig wachsender Diversität (Aktionsrat Bildung, 2018) gebotene Flexibilisierung, Mobilität und Individualisierung der Hochschulbildung im Sinne der Europäischen Studienreform 2.0 (KMK/HRK, 2015–16) ermöglichen. Die umfassende Digitalisierung der studentischen Lernumwelten kann dabei nicht nur das flexible zeit- und ortsunabhängige Lernen der Einzelnen fördern, sondern gleichzeitig auch zur Internationalisierung der Hochschulen beitragen, da Bildungsangebote standortunabhängig international offeriert und genutzt werden können (Wissenschaftsrat, 2018). Digitale Lernumwelten können zudem die Inklusion vielfältiger Studierendengruppen, das individualisierte bzw. personalisierte Lernen oder auch Learning Outcomes wie z.B. die (internationale) Mobilität von Studierenden (Willige, 2016) erleichtern bzw. verbessern. Diese positiven Effekte digitaler Lernumwelten für die Teilhabechancen und die Learning Outcomes diverser Studierendengruppen werden vielfach postuliert (Mayrberger, 2016; de Witt, 2019; Hochschulforum Digitalisierung, 2016; Schmid, Goertz, Radomski, Thom, & Behrens, 2017), aber der Aspekt Diversität in der Forschung zu digitalen Lernumwelten noch selten empirisch umgesetzt (Lack, 2015).

Die Forschung zur digitalen Hochschulbildung beschäftigt sich mit der Diversität von Studierenden vor allem im Hinblick auf diversitätsbedingte Unterschiede hinsichtlich ihrer »Information and Communication Technology (ICT)-Literacy«¹ (vgl. Aktionsrat Bildung, 2018; Thöing, Bach, Vossen, & Jeschke, 2016) und ihrer lernbezogenen Mediennutzung (vgl. z.B. Steffens, Schmitt, & Aßmann, 2017). Beide sind von den Studierenden dringend benötigte Voraussetzungen, um Learning Outcomes sowohl auf formal-quantitativer Ebene (z.B. Zugang zu und Verbleib an der Hochschule, Studiennoten, Studiendauer, Studienabbruch, Abschlüsse und Zertifikate) als auch auf qualitativ-inhaltlicher Ebene (z.B. Kompetenzen, Lernzufriedenheit, Mobilität etc.) in digitalen Lernumwelten zu erzielen. Ob jedoch verschiedene digitalisierte Lehr-Lernformate, wie z.B. das Lernen mit MOOCs (Eriksson, Adawi, & Stöhr, 2017), Online vs. Blended vs. Face-to-Face Learning (vgl. Means, Toyama, Murphy, & Baki, 2013) oder KI-Applikationen wie ChatBots, intelligente Tutorsysteme, Empfehlungssysteme und auch Learning Analytics die Learning Outcomes von Studierenden mit differierenden Diversitätsmerkmalen in unterschiedlicher Weise beeinflussen, wird selten thematisiert oder empirisch

1 (ICT)-Literacy beschreibt die technologischen Kompetenzen für digitale Anwendungen sowie die Fähigkeit sowohl zu deren kritischer Reflexion als auch zur inhaltlich-qualitativen Einschätzung digitaler Informationen und Quellen (vgl. Aktionsrat Bildung, 2018; Ng, 2012; Riis, 2017).

untersucht. Learning Analytics sind eines der aktuell wichtigsten Beispiele für den Einsatz von KI zur Lernunterstützung und Verbesserung von Lernprozessen (für einen Überblick z.B. der Sammelband von Peña-Ayala, 2017). Um Lernprozesse in der Hochschulbildung besser zu verstehen und auch gezielt zu modellieren, werden hierbei Daten über Studierende und ihr Lernverhalten erhoben, analysiert und als Grundlage für die Entwicklung neuer bzw. Optimierung bestehender Lehr-Lernformate herangezogen.

Der vorliegende Beitrag soll einen bislang fehlenden systematischen Überblick über die empirischen Befunde zum *Zusammenhang* von Diversität und digitaler Lernumwelt geben, indem er die Ergebnisse solcher empirischen Studien in den Fokus rückt, die diese beiden Aspekte miteinander verknüpfen oder zumindest thematisieren. Zu diesem Zweck werden zunächst wesentliche Erkenntnisse zur studentischen Diversität in der Hochschulbildung skizziert und die Potenziale digitaler Lernumwelten für studentische Learning Outcomes beleuchtet (Abschnitt 2). Im Anschluss werden Befunde ausgewählter diversitätsorientierter Studien zur ICT-Literacy und zur Mediennutzung/-präferenz sowie zu den Wirkungen verschiedener digitaler Lehr-Lernformate zusammengefasst. Dabei werden auch Learning Analytics als wichtiges Beispiel für den Einsatz von KI in der Hochschulbildung thematisiert (Abschnitt 3). Inwiefern sich digitale Lernumwelten unterschiedlich auf Studierende mit verschiedenen Diversitätsmerkmalen auswirken können, wird dann am Beispiel des Learning Outcomes »Internationale Mobilität« dargestellt. Um die Zusammenhänge zu veranschaulichen, wird dabei exemplarisch ein diversitätsorientiertes Untersuchungsdesign vorgestellt (Abschnitt 4). Im abschließenden Ausblick werden Implikationen für eine vermehrt diversitätsorientierte empirische Forschung zur digitalen Hochschulbildung formuliert und die Herausforderungen für den Einsatz von KI aus Diversitäts-Perspektive skizziert.


2 Studentische Diversität und die Potenziale digitaler Lernumwelten

In allen OECD- und Partnerländern ist der Anteil der 25- bis 34-Jährigen, die einen Abschluss im tertiären Bildungsbereich erwerben, zwischen 2009 und 2019 erheblich angestiegen. In Deutschland stieg der Anteil der Absolvent:innen mit tertiärem Bildungsabschluss von 26 % im Jahre 2009 auf 33 % in 2019 (OECD, 2020, S. 47). Noch ausgeprägter spiegelt sich die sich expandierende Teilhabe an tertiärer Bildung in den gestiegenen Studierendenzahlen, so betrug im Wintersemester 2020/21 die Anzahl der Studierenden über 2,9 Millionen (Statistisches Bundesamt, 2020). Aber nicht nur die Zahl der Studierenden hat sich erhöht, auch die Studierendenschaft setzt sich deutlich diverser zusammen als in früheren Jahren (Aktionsrat Bildung, 2018). Ihre Diversität, verstanden als »Vielfalt in der sozialen Zusammensetzung von Gruppen, Organisationen und Gesellschaften« (Müller & Sander, 2011,

S. 72) hinsichtlich verschiedener sozial konstruierter Merkmale (z.B. Geschlecht, Alter, sexuelle Orientierung, eventuelle Beeinträchtigungen, Migration, Elternschaft, Bildungshintergrund, Nationalität) (Cox, 1991, 1993; Krell, 2008), hat sich vergrößert (vgl. Middendorff & Wolter, 2021). So zeigen z.B. die Ergebnisse der für Deutschland repräsentativen 21. Sozialerhebung (n = 55.219; Middendorff et al., 2017), dass von den befragten Studierenden 68 % erwerbstätig sind und 48 % der Studierenden über eine nicht-akademische Bildungsherkunft verfügen. Darüber hinaus sind 33 % aller Studierenden im Erststudium älter als 25 Jahre, 28 % verfügen über weniger als 735 Euro pro Monat, 11 % geben eine Beeinträchtigung an und 6 % betreuen Kinder. 20 % der Studierenden haben selbst oder über ihre (Groß-)Eltern Migrationserfahrungen, ihre Hochschulzugangsberechtigung aber in Deutschland erworben – wohingegen 9 % internationale Studierende mit einer nicht in Deutschland erworbenen Hochschulzugangsberechtigung (DAAD & DZHW, 2017) sind.

Für Hochschulen geht diese wachsende Vielfalt mit neuen Herausforderungen einher: Es stellt sich die Frage, wie sich studentische Diversität anhand verschiedener Dimensionen und Diversitätsmerkmale strukturieren lässt und welche dieser Merkmale sich in der Hochschulbildung als relevant erweisen. Angelehnt an die »Four Layers of Diversity« (Gardenswartz & Rowe, 1998, S. 25) lässt sich studentische Diversität anhand von vier Dimensionen bzw. Ebenen erfassen: Persönlichkeit, innere und äußere sowie organisationale Dimension, die als ineinander liegende konzentrische Kreise konzeptualisiert werden, deren verschiedene Aspekte ineinander greifen und einander bisweilen auch bedingen (vgl. Abbildung 1). Während die Merkmale auf der zweiten Ebene (»innere Dimension«, wie z.B. Geschlecht, Alter, Nationalität, Migrationserfahrung, Bildungshintergrund, sexuelle Orientierung sowie geistige und körperliche Fähigkeiten) außerhalb der Kontrolle der Individuen und damit relativ unveränderbar sind, üben die Merkmale auf der dritten Ebene (»äußere Dimension« mit Diversitätsmerkmalen wie z.B. Habitus/Auftreten, Religion/Weltanschauung, Wohn-/Studienort, sozio-ökonomische Lebensbedingungen, Fürsorgeaufgaben oder Art der Hochschulzugangsberechtigung), ebenfalls einen großen Einfluss aus, sind aber für die Individuen kontrollierbarer bzw. relativ veränderbar. Auf der vierten Ebene liegen all jene Merkmale, die erst durch die Zugehörigkeit zur Organisation Hochschule (»organisationale Dimension«) entstehen, wie z.B. die Zugehörigkeit zu einem Fachbereich oder Institut, einem Studiengang oder die Teilnahme an den Lehrveranstaltungen eines bestimmten Moduls, die jeweilige Studienphase, das Hochschul- bzw. Fachsemester oder auch ein studentisches Arbeitsverhältnis als studentische Hilfskraft.

Abbildung 1: Diversitätsmerkmale im Hochschulkontext nach Boomers und Nitschke (2012).



Bezüglich einer Reihe von Merkmalen auf der Ebene »innere Dimension« können deutliche soziale Ungleichheiten belegt werden, die sich etwa auf den Übergang ins Studium (der z.B. bei nicht-akademischer Bildungsherkunft sowie für Frauen seltener erfolgt) oder eventuelle Studienabbrüche (die z.B. häufiger Studierende mit nicht-akademischer Bildungsherkunft, internationale Studierende oder Studierende mit Migrationserfahrung betreffen) auswirken (vgl. Überblick in Lörz, 2019). Teilhabe- und Erfolgchancen an der Hochschule strukturieren sich dabei nicht nur entlang eines einzelnen Diversitätsmerkmals: Verschiedene Merkmale wirken vielmehr miteinander gekoppelt in intersektionaler Verschränkung (Gottburgsen & Gross, 2012; Gross, Gottburgsen, & Phoenix, 2016; Lörz, 2019). So zeigen sich beispielsweise international (z.B. Alba & Waters, 2011; Heath & Brinbaum, 2016) wie national systematische Zusammenhänge zwischen Migrationserfahrung – insbesondere in Verbindung mit einer nicht-akademischen Bildungsherkunft –

und einer verlängerten Studiendauer (Autorengruppe Bildungsberichterstattung, 2016; Kristen, 2014; vgl. auch die aktuellen Beiträge in Jungbauer-Gans & Gottburgsen, 2020) oder einem erhöhten Risiko für den Studienabbruch (Ebert & Heublein, 2017 mit Einfluss studentischer Erwerbstätigkeit).

Vor diesem Hintergrund stellt sich die Frage, welche Potenziale eine Digitalisierung der Lernumwelten bietet, um die Learning Outcomes dieser diversen Studierenden sowohl auf formal-quantitativer Ebene (z.B. Zugang und Verbleib, Studiennoten, Studiendauer, Studienabbruch, Abschlüsse und Zertifikate) als auch auf qualitativ-inhaltlicher Ebene (z.B. Kompetenzen, Lernzufriedenheit, Mobilität etc.) zu verbessern.

Zu erwartende positive Effekte digitaler Lernumgebungen begründen sich vor allem in der *Flexibilisierung von Zeit und Lernort*. Grundsätzlich kann sich die Unabhängigkeit von bestimmten Lernzeiten und -orten als förderlich für die Learning Outcomes aller Studierenden erweisen, doch vor allem könnten davon all jene Studierenden profitieren, deren Diversitätsmerkmale im Hochschulalltag mit systematischen Nachteilen einhergehen.² So zeigt sich beispielsweise, dass das höhere Maß an Selbstbestimmtheit bezüglich des Lerntempos und der Lernstrategien, das digitale Lernumwelten ermöglichen, internationalen Studierenden entgegenkommt, die sich in einem ihnen nicht vertrauten, zumeist fremdsprachigen Hochschulsystem orientieren müssen. Zugleich erweist es sich für sie – und auch für Studierende mit Migrationserfahrung und/oder nicht-akademischer Bildungsherkunft – als positiv, dass digitale Lernumwelten die Qualität und Häufigkeit der Interaktion von Lehrenden und Lernenden sowie den Austausch unter den Studierenden steigern (Henderson, Selwyn, & Aston, 2017; Willige, 2016). Darüber hinaus finden sich auch empirische Hinweise darauf, dass Studierende, die neben dem Studium einer Erwerbstätigkeit und/oder Care-Aufgaben nachkommen, von digitalen Lernumwelten mit ihren anpassbaren Lernzeiten und -orten erheblich profitieren (Zawacki-Richter, 2015; Zawacki-Richter, Kramer, & Müskens, 2016). Dabei belegen die Befunde von Zawacki-Richter (2015), dass dies insbesondere für nicht-traditionelle Studierende zutrifft, da diese ihr Studium erst nach einer Berufsausbildung oder Berufstätigkeit, ohne reguläre schulische Hochschulzugangsberechtigung oder im Teilzeit-, Abend- und Fernstudium aufnehmen und daher zumeist älter sind als ihre Kommiliton:innen.

Besonders förderlich wirken sich das flexible, zeit- und ortsunabhängige Lernen sowie die für eine barrierefrei gestaltete digitale Lernumwelt eingesetzten Technologien außerdem auch für Studierende mit Beeinträchtigungen aus (Fichten, Olenik-Shemesh, Asuncion, Jorgensen, & Colwell, 2020; Seale et al., 2020; Seale &

2 Empfehlungen zur Förderung einer gender- und diversitätssensiblen Lehr- und Lernkultur finden sich beispielsweise bei Gottburgsen und Arbeitskreis Gender & Diversity in der Lehre (2015).

Christie, 2020; Seale, Georgeson, Mamas, & Swain, 2015; van Rooij & Zirkle, 2016). So zeigen beispielsweise Seale et al. (2020), dass mobilitäts- und sehbeeinträchtigte Studierende oftmals erst durch die technologischen Möglichkeiten einer digitalen Lernumwelt in die Lage versetzt werden, die auf Lernmanagementsystemen online zur Verfügung gestellten digitalisierten Lernmaterialien mit entsprechenden Hilfsmitteln (Screenreader etc.) in einem ihnen gemäßen Lerntempo zu bearbeiten. Darüber hinaus berichten mobilitäts- und/oder psychisch beeinträchtigte Studierende, dass sie sich durch eine digitale Lernumwelt auch von zu Hause aus als Teil der Lerngemeinschaft fühlen, da ihnen die Nutzung von barrierefreien Lernmanagementsystemen die Teilnahme an virtuellen Arbeitsgruppen erleichtert (Fichten et al., 2020). Insbesondere vor dem Hintergrund der positiven Effekte erlebter sozialer Integration auf die psychische Widerstandsfähigkeit und Lern- und Studienerfolge gewinnt dieser Aspekt zusätzlich – nicht nur für Studierende mit besonderen Bedürfnissen – an Bedeutung (Hofmann, Müller-Hotop, & Datzer, 2020).

Weitreichende positive Effekte für die *Individualisierung des Lernens über die Schaffung personalisierter, adaptiver Lernumgebungen* verspricht indes vor allem der Einsatz von KI-Technologien in der digitalen Hochschulbildung (de Witt et al., 2020; Zawacki-Richter et al., 2019 für einen Überblick zu diesem rasch expandierenden Forschungsfeld). KI-Technologien, die gewaltige Datenmengen miteinander verknüpfen können und selbst lernfähig sind, können Lehr-Lernprozesse umfassend fördern und unterstützen – und dies aus der Sicht der Lernenden ebenso wie aus Sicht der Lehrenden. Nach de Witt et al. (2020, 11f.) sollen Lehr-Lernprozesse mit KI für alle Beteiligten transparenter, verstehbarer und nachvollziehbarer werden. Zu diesem Zweck soll mittels KI-gestützter Technologien der Wissensstand der Studierenden ermittelt sowie der Wissens- und Kompetenzerwerb durch personalisierte Empfehlungssysteme und individualisiertes Feedback besser als bisher im standardisierten Studium gefördert werden. Aus Diversitätsperspektive bedeutsam sind die neuen Möglichkeiten, die KI eröffnet, vor allem aufgrund der auswertbaren großen Datenmengen, (un-)günstige Muster in Studienverläufen zu erkennen und Rückschlüsse für deren Verbesserung zu ziehen. Vorhersagealgorithmen und -systeme ermöglichen dabei die Identifikation von gefährdeten Studierenden, sodass personalisierte Interventionsstrategien dabei helfen können, mögliche Studienabbrüche frühzeitig zu verhindern. Wie de Witt et al. (2020, 11) ausführen, ist mit dem Einsatz von KI die Hoffnung verbunden, »(...) die individuellen Lernergebnisse der Studierenden zu steigern, ihre Verbleibsquote zu erhöhen, den Studienabbruch zu verringern oder auch die Zeit bis zur Beendigung des Studiums zu verkürzen«. Die bislang in der Hochschulbildung immer wieder belegten, systematischen Nachteile bezüglich der Learning Outcomes von Studierenden mit ganz bestimmten Diversitätsmerkmalen ließen sich demnach mit dem Einsatz von KI möglicherweise ausgleichen.


3 Studentische Diversität als Gegenstand in der Forschung zur digitalen Hochschulbildung

Im Folgenden werden bisher vorliegende Erkenntnisse und Befunde zum Zusammenhang zwischen digitalen Lernumwelten, studentischer Diversität und Learning Outcomes in eine Heuristik eingeordnet und mit Fokus auf die hier relevante Phase »Lehre und Studium«³ systematisiert (siehe Abbildung 2).

Generell zeichnen sich digitale Lernumwelten durch eine Vielzahl von Variationen bezüglich der eingesetzten Lehr-Lernformate aus (Aktionsrat Bildung, 2018). Diese reichen von reinen Online-Formaten (z.B. MOOCs, Online-Studiengänge) über Blended Learning (z.B. Inverted/Flipped Classroom) bis hin zum Präsenzlernen, für das digitale Medien eingesetzt (z.B. Clicker, Lehrveranstaltungsaufzeichnungen), Lehrmaterialien über Lernmanagementsysteme digital zur Verfügung gestellt oder Lernfortschritte beispielsweise durch KI-gestützte Methoden aus dem Spektrum der sogenannten Learning Analytics gefördert werden.

3 Im Allgemeinen wird in der Hochschulbildung zwischen den Phasen Studienentscheidung und Hochschulwahl, Einschreibung und Erstorientierung, Lehre und Studium sowie Abschlussarbeit und Studienabschluss unterschieden und diesen Phasen die jeweils eingesetzten Technologien und Methoden zugeordnet (vgl. Aktionsrat Bildung, 2018, 167, Abbildung 17).

Abbildung 2: Heuristik zum Zusammenhang digitaler Lernumwelten, studentischer Diversität und Learning Outcomes in der Hochschulbildung (eigene Darstellung).



Der Einsatz digitaler Lernumwelten kommt den diversen Studierendengruppen in unterschiedlicher Weise zugute, da diese – vermittelt unter anderem über ihre Diversitätsmerkmale – über unterschiedliche digitale Lernvoraussetzungen im Hinblick auf ihre ICT-Literacy und ihre studienbezogene Mediennutzung sowie eventuelle Medienpräferenzen verfügen. Die digitale Gestaltung der jeweiligen Lernumwelt trifft entsprechend auf eine studentische »Digital Diversity« (vgl. dazu Beiträge in Angenent, Heidkamp, & Kergel, 2019). Diese digitale Diversität von Studierenden wird insofern zu einem relevanten Drehpunkt für Lehr-Lernprozesse und Learning Outcomes, als sie darüber entscheidet, ob Studierende die Vorteile KI-gestützter Technologien nutzen können, um eventuell aus ihren Diversitätsmerkmalen erwachsende Nachteile in Bezug auf Faktoren wie Studiendauer oder Studienerfolg auszugleichen. Um zu eruieren, inwiefern sich digitale Diversität von Studierenden auf ihre Learning Outcomes auswirken kann, werden im Folgenden zunächst empirische Befunde zur studentischen ICT-Literacy und studienbezogenen Mediennutzung/-präferenz als zentrale Größen für Lehr-Lernprozesse zusammengefasst und im Anschluss daran vorliegende Ergebnisse zu den Effekten verschiedener Lehr-Lernformate auf verschiedene Learning Outcomes skizziert.

ICT-Literacy

Wie neuere Studien zeigen, führt das Phänomen der Generation sogenannter »Digital Natives« nicht dazu, dass sich die Studierenden in einer digitalisierten Lernumwelt zwangsläufig besser zurecht finden (vgl. Literaturüberblicke in Aktionsrat Bildung, 2018; Thöing et al., 2016). Zwar sind heutige Studierende häufig in hohem Maße mit digitalen Medien vertraut und verfügen über stark ausgeprägte Kompetenzen in der Anwendung verschiedener Technologien, doch nutzen sie diese eher selten studienbezogen. Zudem fehlen ihnen oftmals relevante Fähigkeiten, um beispielsweise technologische Anwendungen oder digitale Informationen und Quellen kritisch zu reflektieren oder hinsichtlich ihrer Qualität einzuschätzen. Gemeinsam bilden diese Kompetenzen die sogenannte *Information and Communication Technology (ICT)-Literacy* ab (Ng, 2012; Riis, 2017). Zum Diversitätsmerkmal »Geschlecht« finden beispielweise Senkbeil, Schöber, and Ihme (2018) in ihrer Auswertung von ICT-Tests im Rahmen des Nationalen Bildungspanels (n = 1.998 Studierende im 6. Fachsemester) über alle untersuchten Studienfächer hinweg deutliche Kompetenzvorsprünge von Studenten im Vergleich zu Studentinnen. In eine ähnliche Richtung weisen auch die Ergebnisse von Huang, Hood und Yoo (2013), die von einer deutlich höheren Zurückhaltung und Besorgnis (»anxiety«) bei Studentinnen gegenüber der lernbezogenen Nutzung verschiedener Web-2.0-Anwendungen⁴ berichten. Darüber hinaus zeigen Nicolaos, Tzafea und Thanaos (2019), dass Studierende mit niedrigem sozio-ökonomischen Status (operationalisiert über den elterlichen Beruf und Bildungsstand) über eine geringere ICT-Literacy verfügen als Studierende mit einem höheren sozio-ökonomischen Status.

Empirisch belegte Diversitätseffekte finden sich auch für die Technikaffinität bzw. *Mediennutzung/-präferenzen* – beispielsweise in den »Studies of Undergraduate Students and Information Technologies (ECAR)«,⁵ wie der Blick auf die diversitätsorientierten Befunde der Jahre 2016 bis 2019 zeigt. So belegt etwa die ECAR-Studie 2016 (Brooks, 2016) Geschlechterdifferenzen sowie Unterschiede nach ethnischer Zugehörigkeit und Bildungsherkunft: Die für diese Erhebung befragten Stu-

4 Z.B. Blogs, Wikis, Social Media, Online Video Sharing, Online Gaming oder immersive virtuelle Lernumgebungen.

5 Diese Studien werden seit 2003 jährlich an Hochschulen aller US-Regionen durchgeführt (siehe <https://www.educause.edu/>). An den Befragungen nehmen jeweils mehrere 10.000 Studierende teil, sodass neben zentralen sozialen Merkmalen auch Charakteristika der Lebenslagen der Studierenden systematisch erhoben werden können. Im Einzelnen sind dies Merkmale wie z.B. Alter, Gender, ethnische Zugehörigkeiten wie black/African American oder Hispanic/Latinx, first generation/ohne akademische Familienerfahrung, Partnerschaft und Care-Aufgaben (Kinder, andere Familienangehörige), Beeinträchtigungen unterschiedlicher Art, Erwerbstätigkeit und Pell Grants-Berechtigung (staatliche Unterstützung für das Studium).

dentinnen zeichneten sich durch eine deutlich niedrigere Technikorientierung und eine signifikant niedrigere Technikdisposition (Neigung) sowie durch eine skeptischere Einstellung zum studienbezogenen Technologieeinsatz aus. Im Allgemeinen nutzen sie Technologie eher zurückhaltend. Indes haben sowohl schwarze/afroamerikanische als auch hispanische Studierende im Vergleich zu ihrer Referenzgruppe (»white students«) signifikant positivere Technikdispositionen und Einstellungen in Bezug auf digitale Lehr-Lernsettings und geben zudem an, Technologie häufiger einzusetzen. Hinsichtlich ihres Austauschs mit Lehrenden und Kommiliton:innen sowie ihrer Auseinandersetzung mit Kurs- und Fachinhalten erleben zudem Studentinnen sowie Studierende ohne akademische Familienerfahrung studienbezogene Technologien signifikant häufiger als hilfreich bzw. unterstützend. Letztere bewerten im Vergleich zu ihren Referenzgruppen (Studenten bzw. Studierende mit akademischem Bildungshintergrund) die eingesetzten studienbezogenen Technologien häufiger als größere Bereicherung ihres akademischen Lernens.⁶ Beide Gruppen sehen zudem stärker als ihre Vergleichsgruppen die eigene Leistungsfähigkeit/Selbstwirksamkeit (»efficacy«) durch und mit studienbezogenen Technologien gesteigert und sich selbst infolgedessen dazu befähigt, beispielsweise grundlegende Botschaften zu kommunizieren, technische oder akademische Terminologie richtig zu verwenden, sofort Feedback von anderen zu erhalten oder ihre Ideen in spezifischen Begriffen zu erklären.

Neben diesen Effekten kommt es offensichtlich auch im Hinblick auf sogenannte studienunterstützende Informationssysteme (»student success tools«)⁷, die z.B. beim Organisieren des Studiums helfen sollen, zu signifikanten Unterschieden entlang verschiedener Diversitätsmerkmale (Brooks & Pomerantz, 2017; Galanek, Gierdowski, & Brooks, 2018). Studentinnen bewerten diese signifikant häufiger als nützlich als Studenten. Auch Studierende ohne akademische Familienerfahrung unterscheiden sich von jenen mit akademischer Familienerfahrung, da sie vergleichsweise häufiger die Nützlichkeit dieser Tools angeben. Gleichermäßen beurteilen Studierende mit einer Pell Grants-Berechtigung die Informationssysteme signifikant häufiger als nützlich als Studierende ohne eine solche Berechtigung. Der Nutzen der Tools wird auch von Studierenden mit afroamerikanischem oder hispanischem Hintergrund häufiger als nützlich eingeschätzt als in ihrer Vergleichsgruppe (»white students«).

6 Diese positiven Effekte wurden über Items wie z.B. »Beitrag zum erfolgreichen Abschluss meiner Kurse«, »bereichert meine Lernerfahrungen«, »war relevant für das Erreichen der Lernziele des Kurses«, »hat mir geholfen, grundlegende Konzepte zu verstehen« oder »Verbindungen zu Wissen herzustellen, das in anderen Kursen erworben wurde« erfragt.

7 Diese werden kategorisiert in Systeme, welche (1) zum akademischen Erfolg beitragen, wie z.B. Frühwarnsysteme, oder (2) die Studierenden bei der Studienorganisation unterstützen, wie z.B. Self-Service-Systeme zur Nachverfolgung von Credits oder zur Registrierung (Brooks & Pomerantz; 2017; Galanek et al., 2018).

Mediennutzung/-präferenzen der Studierenden

Die vorliegenden Studienergebnisse geben nicht nur einen guten Einblick in die von US-amerikanischen Studierenden präferierten *Lernumgebungen* bzw. *Lehr-Lern-formate* (online, blended, face-to-face). Sie machen vielmehr deutlich, dass im Lauf der Jahre eine Trendwende stattgefunden hat: Während Studierende in früheren Jahren Blended-Learning-Formate bevorzugten, zeigt sich in der ECAR-Studie 2018 erstmalig eine deutliche Präferenz für Face-to-face-Lernformate (Galanek et al., 2018). Diese Tendenz bestätigt sich auch in der ECAR-Umfrage vom Jahr 2019, die zudem das Bild einer zunehmend diverser werdenden Studierendenschaft zeichnet (Gierdowski, 2019). So zeigt sich, dass insbesondere diejenigen Studierenden reine Präsenzformate (face-to-face) präferieren, die älter als 25 Jahre sind, in einer Partnerschaft leben oder Care-Aufgaben wahrnehmen. Darüber hinaus sprechen sich auch Studierende mit körperlichen und Lernbeeinträchtigungen vergleichsweise häufig für dieses Lernformat aus, bevorzugen jedoch alles in allem Blended-Learning-Formate mit unterschiedlichen Abstufungen (überwiegend face-to-face, halb-und-halb, überwiegend online). Reine Online-Formate präferiert hingegen überwiegend die Gruppe der voll berufstätigen Studierenden, welche 40 oder mehr Stunden pro Woche arbeiten.

Während zur Mediennutzung/-präferenzen internationale Studien belastbare Befunde zu systematischen diversitätsbedingten Unterschieden liefern, fokussieren nationale Untersuchungen in ihren Analysen bis dato eher selten die Diversitätsmerkmale der Studierenden. Dies ist umso erstaunlicher als in den vergangenen Jahren eine Reihe von empirischen Projekten zu diesem Bereich durchgeführt wurde (vgl. z.B. Kuger, Linberg, Bäumer, & Struck, 2018; Schmid et al., 2017; Persike & Friedrich, 2016; Wannemacher, 2016; Willige, 2016) und insgesamt der Aspekt der Diversität in der Hochschulforschung zunehmend berücksichtigt wird (z.B. Lörz, 2019; Buche & Gottburgsen, 2012; Griffin & Museus, 2011; Klein & Heitzmann, 2012). Dennoch werden Ergebnisse nur ansatzweise – und häufig allein bezogen auf eventuelle Geschlechterdifferenzen – vor diesem Hintergrund gespiegelt. Zwei ältere Studien zu geschlechtstypischen Unterschieden in der Mediennutzung/-präferenz führen beispielsweise Grosch und Gideon (2011) sowie Karapanos und Fendler (2015) durch. Erstere berichten, dass sich in ihrem Sample ($n = 1.500$ Studierende des Karlsruher Instituts für Technologie) in Bezug auf den Zugang zu Computer- und Onlinemedien keine geschlechtstypischen Unterschiede zeigen. Karapanos und Fendler (2015) finden in ihrer Befragung von Studierenden der Ingenieurwissenschaften ($n = 423$) ebenfalls keine geschlechtstypischen Differenzen für die Ausführung nicht-lernbezogener Tätigkeiten im Internet oder die Nutzung informations- und kommunikationstechnischer Endgeräte für den Lernprozess. Allerdings schätzen sich die von ihnen befragten Studenten in Bezug auf ihre Computerkompetenz und E-Learning-Affinität signifikant höher ein als die befragten

Studentinnen. Im Vergleich zu Studentinnen nutzen sie zudem signifikant häufiger Videoportale oder Lernmanagementsysteme. Bezüglich anderer spezifischer Lernquellen für das ingenieurwissenschaftliche Studium wiederum zeigen sich keine Geschlechterunterschiede.

Digitalisierte Lernformate, KI und diversitätsbedingte Effekte auf Learning Outcomes

Die Befundlage zu Lernerfolgen in den unterschiedlich digitalisierten Lernumgebungen (online, blended, face-to-face) erweist sich als heterogen und zudem – ähnlich wie die Forschung zur Mediennutzung/-präferenz – nur selten als diversitätsorientiert. In ihrer Meta-Analyse von 22 empirischen Studien stellen Means et al. (2013) fest, dass Studierende in Blended-Lernformaten deutlich besser abschneiden als in Face-to-face-Lernformaten (nicht jedoch in reinen Online-Formaten im Vergleich zu Face-to-face-Lernformaten). Im Gegensatz dazu finden Bowen, Chingos, Lack, and Nygren (2014) in Bezug auf die Lernerfolge der Studierenden keine Vorteile des einen oder anderen Lernformats. Sie zeigen aber, dass die Lernenden in Blended-Lernformaten zum Erreichen ihrer Ergebnisse im Vergleich zu Face-to-face-Lernformaten 25 % weniger Zeit benötigten. Empirisch gut belegt ist zudem, dass sich die Studienabbruchquote durch Blended Learning im Vergleich zu reinen Online-Lernformaten reduziert (López-Pérez, Pérez-López, & Rodríguez-Ariza, 2011; Porter, Graham, Spring, & Welch, 2014). Dies gilt gleichermaßen für nationale wie internationale Studien zu den Studienabbruchsquoten in Massive Open Online Courses (Eriksson et al., 2017) oder zu den Studienangeboten von Distance-Learning-Universitäten (wie z.B. British Open University, Spanish National Distance Teaching University, Athabasca University in Canada; vgl. Simpson, 2013; Gregori, Martínez, & Moyano-Fernández, 2018): Studierende schließen Blended-Learning-Kurse häufiger erfolgreich ab als reine Onlinekurse. Ob und inwieweit diese Disparität in Zusammenhang mit den Diversitätsmerkmalen der Studierenden steht, untersuchen für den deutschen Hochschulraum beispielsweise Stoessel, Ihme, Barbarino, Fisseler und Stürmer (2015). Sie finden in ihrer Analyse von Studierendenendaten der Fernuniversität Hagen ($n = 4.599$), dass das Risiko eines Studienabbruchs für Frauen, für Studierende mit Migrationserfahrungen und für vollzeiterwerbstätige Studierende höher ist (im Vergleich zur jeweiligen Referenzgruppe), dass aber ältere Studierende und Studierende mit Kindern ihr Studium seltener abbrechen.

Die mit dem *Einsatz von KI* angestrebte Verbesserung des individuellen Lernens ist ein insbesondere international prosperierendes Forschungsfeld, wie mittlerweile zahlreiche Meta-Analysen zur Wirkung von Learning Analytics auf Lernfolge zeigen (vgl. z.B. Sclater, Peasgood, & Mullen; Sönderlund, Hughes, & Smith, 2019; Vi-berg, Hatakka, Bälter, & Mavroudi, 2018). Learning Analytics zielen darauf ab, durch


das Erheben, Aggregieren, Analysieren und Auswerten von Daten über Lernende und ihre Lernkontexte eine ebenso direkte wie personalisierte Unterstützung für Studierende zu ermöglichen. Aus einer diversitätsorientierten Perspektive liegt der Nutzen eines solchen Vorgehens vor allem in dessen Potenzial, anhand bestimmter Diversitätsmerkmale – etwa nicht-akademische Bildungsherkunft, Migrationserfahrung oder internationale Studierende – Studierende mit erhöhtem Risiko für einen Studienabbruch oder unterdurchschnittliche Studienleistungen zu identifizieren und diese über verschiedene Maßnahmen (wie z.B. online-Tools oder individuell auf ihre Situationen und Bedarfe zugeschnittene Module in Lernmanagementsystemen) in ihren Lernprozessen zu unterstützen (Sønderlund et al., 2019). Allerdings liegen nur sehr vereinzelt Hinweise auf die positive Wirkung von LA-gestützten Interventionen vor, wie Sønderlund et al. aus ihrer Meta-Analyse schlussfolgern. Diversitätsorientierte Untersuchungen zur Frage, ob und inwieweit der Einsatz von KI unterschiedliche Effekte auf die Learning Outcomes von Studierenden mit bestimmten Diversitätsmerkmalen hat, sollten daher künftig verstärkt vorangetrieben werden.

Zusammenfassend lässt sich für den Moment vor allem eines festhalten: Zur ICT-Literacy sowie Mediennutzung/-präferenz liegen international diversitätsorientierte Studien vor, in den Studien zum deutschen Hochschulraum wird die Diversität der Studierenden hingegen nur selten berücksichtigt. Die Effekte digitaler Lernumwelten, verschiedener Lernformate oder auch der Einsatz von KI auf die Learning Outcomes einer divers zusammengesetzten Studierendenschaft werden auch international noch eher selten untersucht. Insbesondere im deutschen Hochschulraum steht der Einsatz von KI im Lehr-Lernkontext noch am Anfang, so dass derzeit auch noch keine ausreichende Datenbasis für eine systematische Auseinandersetzung vorliegen kann.

4 Empirisches Beispiel: Learning Outcome ›Internationale Mobilität‹

Wie ertragreich ein Untersuchungsdesign zu etwaigen Wirkungszusammenhängen zwischen digitaler Lernumwelt, studentischer Diversität und deren Effekten auf Learning Outcomes sein kann, zeigt eine Analyse zur internationalen Mobilität von Studierenden (Gottburgsen & Willige, 2018). Die Daten wurden in einer Online-Befragung des DZHW-Online-Access-Panels »HISBUS-Studierendenpanel« (Feldzeit: 2016; n = 4.375 Fälle) erhoben und unter der leitenden Fragestellung »Mehr Mobilitätserfahrungen durch digitale Medien? Zu den Effekten von studentischer Diversität und Lernumweltmerkmalen auf internationale Mobilität« sekundäranalytisch ausgewertet.

Abbildung 3: Effekte studentischer Diversität und der Charakteristika der Lernumwelten auf digitale und tatsächliche internationale Mobilität (eigene Darstellung).⁸



In das diversitätsorientierte Analysemodell integriert wurden dabei sowohl die studentische Diversität auf individueller Ebene als auch die Digitalisierung der Lernumwelt in den drei Abstufungen (1) grundständiges digitalisiertes Lern- und Lehrumfeld (z. B. online zur Verfügung gestellte Vorlesungsaufzeichnungen und lehrver-

8 Dargestellt werden die Average Marginal Effects (AME) einer logistischen Regression mit einem Konfidenzintervall von 95 %, d.h. die Irrtumswahrscheinlichkeit für ein signifikantes Ergebnis ist kleiner als 5 %. Die horizontalen Linien geben das Konfidenzintervall an, in dem sich der Schätzer für die einzelnen Variablen befindet. Rechts der vertikalen 0-Achse liegende Intervallschätzer zeigen signifikant positive, links der 0-Achse liegende Schätzer signifikant negative Effekte an. Schneidet der Schätzer die Null-Linie, liegen keine signifikanten Unterschiede vor. Referenzen (in Klammern) sind jeweils: männlich (weiblich); Bildungsinland (deutsche Staatsangehörigkeit); nicht-akademisches Elternhaus (akademisches Elternhaus); Altersgruppen (bis 25 Jahre); ohne Partnerschaft (mit Partnerschaft); Elternschaft (ohne Kinder); Fachhochschulen (Universitäten); Sprach- und Kulturwissenschaften bis Ingenieurwissenschaften (Wirtschaftswissenschaften); digitale Lern- und Lehrformate und digitale Lehrveranstaltungen und Studiengänge (grundständiges digitales Lernumfeld).

anstellungsbegleitende Materialien des eigenen Studiengangs, von den Studierenden im Rahmen ihrer Kurse soziale Medien wie WhatsApp sowie von Lehrenden geführte Blogs), (2) spezifische digitale Lehr- und Lernformate (z.B. Inverted Teaching, Flipped Classroom und Game-Based Learning) und (3) eigenständige digitale Lehrveranstaltungen und Studiengänge (z.B. Open Course bzw. MOOC, Online-Praktikum, Online-Exkursion, Online-Studiengang).

Die Ergebnisse belegen zum Teil deutliche Auswirkungen auf studienbezogene internationale Lernerfahrungen durch digitale und tatsächliche internationale Mobilität entlang der Diversitätsmerkmale der Studierenden (Abbildung 3).

Für Geschlecht, Bildungsinland bzw. Migrationshintergrund, Bildungsherkunft, Altersgruppenzugehörigkeit, Partnerschaft und Elternschaft zeichnet sich das folgende Bild: Männliche Studierende nutzen mit signifikant höherer Wahrscheinlichkeit Angebote, die sie digital international mobil sein lassen. Daneben zeigt sich für sie ein signifikant negativer Effekt bezüglich der Wahrscheinlichkeit, tatsächliche studienbezogene Auslandsaufenthalte durchzuführen. Ohne statistisch relevante Auswirkungen auf die Teilhabe an digitaler und tatsächlicher Mobilität bleibt indes das Merkmal Bildungsinland jener Studierenden, die ihre Hochschulzugangsberechtigung in Deutschland erworben haben, aber keine deutsche Staatsangehörigkeit zu besitzen. Allerdings ist dieses Ergebnis aufgrund der geringen Fallzahl und deutlichen Streuung der Werte nur als erster Hinweis auf die Notwendigkeit weiterer vertiefender Analysen unter Einbeziehung weiterer Datensätze zu sehen.

Für die Bildungsherkunft finden sich in Bezug auf digitale und tatsächliche studienbezogene Mobilität statistisch signifikante negative Effekte für Studierende aus einem nicht-akademischen Elternhaus. Positiv signifikante Effekte des Alters finden sich lediglich im Zusammenhang mit der Durchführung studienbezogener Auslandsaufenthalte für die Studierenden der mittleren Altersgruppe, die häufiger studienbezogen ins Ausland gehen als jüngere Studierende. Dagegen zeigen sich für das Merkmal Partnerschaft tendenziell positive (jedoch nicht signifikante) Effekte für ungebundene Studierende – ohne Partnerschaft – im Hinblick auf digitale und tatsächliche Mobilität. Insbesondere das Merkmal Elternschaft erweist sich als hemmender Faktor für digitale und tatsächliche Mobilität: Studierende, die im eigenen Haushalt Kinder betreuen, haben eine geringere Wahrscheinlichkeit, digital wie tatsächlich Auslandsmobilitätserfahrungen zu sammeln als Studierende ohne Kinder.

Für die ebenfalls untersuchten Diversitätsmerkmale der Lernumwelt Hochschulart und Fächergruppen finden sich im Vergleich zur jeweiligen Referenzgruppe vorwiegend negative Effekte, sowohl auf die digitale als auch die tatsächliche Auslandsmobilität. Für die digitale internationale Mobilität lassen sich lediglich für die Fächergruppen Rechtswissenschaften signifikante negative sowie für Mathematik und Naturwissenschaften signifikante positive Effekte im Vergleich zu

den Wirtschaftswissenschaften feststellen.⁹ Bei der konkreten Durchführung studienbezogener Auslandsaufenthalte finden sich für alle Fächergruppen signifikant negative Effekte im Vergleich zur Referenz der Wirtschaftswissenschaften.

Die Befunde zu dem für diesen Beitrag zentralen Effekt einer digitalen Lernumwelt scheinen zunächst kontraintuitiv, denn spezifische digitale Lern- und Lehrformate wie auch eigenständige digitale Lehrveranstaltungen haben im Vergleich zu einer »grundständigen« digitalen Basisausstattung keine Effekte auf digitale und tatsächliche internationale Mobilität. Dies mag einerseits auf die gewählte Operationalisierung des Merkmals »digitale Lernumwelt« zurückzuführen sein, das in den oben beschriebenen drei Abstufungen in die Analyse einging. Andererseits wird mit dem Learning Outcome Internationale Mobilität ein komplexes Konstrukt erfasst, dessen Organisation ein vor allem grundständiges digitalisiertes Lern- und Lehrumfeld mit vorhandenem Lernmanagementsystem, Online-Prüfungsteilnahmen und weiteren Angeboten im administrativen Bereich erfordert.

Dass im Vergleich zum grundständigen digitalen Lehrumfeld, das nur als Supplement zur Präsenzlehre dient, eigenständige digitale Lehrveranstaltungen und Studiengänge einen signifikant positiven Effekt auf digitale internationale Mobilität zeigen, verwundert dagegen nicht. So weisen Studierende, die in einem solchen Format lernen, eine signifikant höhere Wahrscheinlichkeit auf, digitale Angebote internationaler Hochschulen zu nutzen und somit digital international mobil zu werden, als Studierende, die lediglich in einem grundständig digitalen Lern- und Lehrumfeld studieren.

Die Ergebnisse unterstreichen die Berechtigung eines derartigen Blickwinkels, indem die systematischen Vergleiche ein detailliertes Bild der Effekte von Digitalisierung auf Learning Outcomes unter Berücksichtigung von Diversitätsdimensionen zeichnen. Ergänzt werden sollten derartige Analysemodelle jedoch durch eine differenzierte Prüfung potenzieller Interaktionseffekte (z.B. zwischen den Merkmalen Geschlecht und Fächergruppenzugehörigkeit), wie sie eine intersektionale Perspektive nahelegt.

5 Ausblick und künftige Implikationen

Im Fokus des vorliegenden Beitrags steht der Blick auf die Forschung zu den Themenfeldern *Diversität* und *Digitalisierung* sowie *Learning Outcomes* bzw. zu ihrer möglichen Zusammenführung und Verschränkung. Einerseits ist hochschulpolitisch die Zielsetzung auszumachen, digitale Lernumwelten und digitale Lehr- und

9 Die Wirtschaftswissenschaften wurden als Referenzgruppe gewählt, da 46 % aller Studierenden dieser Fächergruppe studienbezogene Auslandsaufenthalte durchführen im Vergleich zu deutlich niedrigeren Mobilitätsquoten in anderen Fächergruppen (Woisch & Willige, 2015).

Lernformate gerade für eine zunehmend divers zusammengesetzte Studierendenschaft auszugestalten, um damit u.a. individuellen Bedürfnissen nach Teilhabe gerecht zu werden und die Weichen für den erfolgreichen Studienabschluss zu stellen. Andererseits finden sich in entsprechenden Studien oftmals keine (oder nur unsystematische) Aussagen zum Zusammenhang zwischen digitalen Lernumwelten, studentischer Diversität und Learning Outcomes. Während internationale diversitätsorientierte Studien zur ICT-Literacy und Mediennutzung/-präferenz systematische Unterschiede entlang verschiedener sozialer Merkmale von Studierenden belegen, wird bislang eher selten untersucht, wie sich digitale Lernumwelten und -formate – insbesondere mit Blick auf das rapide wachsende Spektrum KI-gestützter Tools für Hochschullehre – auf die Learning Outcomes (z.B. Lernerfolge, Mobilität) einer divers zusammengesetzten Studentenschaft auswirken. Das im Rahmen dieses Artikels exemplarisch vorgestellte empirische Untersuchungsdesign zum Learning Outcome Internationale Mobilität sowie das in Kapitel 3 vorgeschlagene heuristische Modell zur Abbildung der Wechselwirkungen zwischen digitalen Lernumwelten, studentischer Diversität und Learning Outcomes in der Hochschulbildung nehmen dieses Desiderat auf und zeigen Perspektiven einer Verknüpfung.

Implikationen für die künftige Forschung ergeben sich dabei auf mehreren Ebenen. Zum einen scheint es unerlässlich, Diversität und Digitalisierung künftig konsequent »zusammen zu denken«. Dabei sollte Diversität in einem intersektionalen Verständnis in die empirischen Analysen eingehen (vgl. Gottburgsen & Gross, 2012; Gross et al., 2016), um so zugleich auch die Interaktionen der verschiedenen Diversitätsmerkmale abbilden zu können. Zum anderen gilt es, die Forschung zu digital vermittelten Lernprozessen und deren Learning Outcomes nicht nur weiter voran zu treiben, sondern dabei auch die Einbeziehung studentischer Diversität als Forschungsfokus zu stärken. Schließlich stellt der systematische Vergleich der Learning Outcomes studentischer Zielgruppen mit unterschiedlichen Diversitätsmerkmalen in den verschiedenen digitalen Lernformaten insbesondere in Experimentaldesigns und unter konsequentem Einbezug von Kontrollgruppen einen vielversprechenden Forschungsansatz dar. Durch die zunehmende Globalisierung und Digitalisierung ist zu erwarten, dass auch die Diversifizierung der zu adressierenden Studierendengruppen weiter zunehmen wird. Um diesen neuen Herausforderungen in der Hochschulbildung gerecht zu werden, sind belastbare empirische Erkenntnisse zu bestehenden Interdependenzen und Wirkungszusammenhängen unerlässlich. Daher sollte der Verknüpfung von Aspekten digitaler Lernumwelten, studentischer Diversität und Learning Outcomes in künftigen Forschungsdesigns eine entsprechend große Bedeutung zukommen.

In Anbetracht der technologischen Entwicklung gilt es dabei, künftig eine Frage ganz besonders differenziert zu adressieren: Welche Implikationen für die digitale Hochschulbildung ergeben sich durch den künftig vermehrten Einsatz von KI? ICT-

Literacy und Mediennutzung/-präferenzen differieren, so hat der Forschungsüberblick gezeigt, entlang verschiedener Diversitätsmerkmale. Sie könnten sich als die für den studentischen Erfolg in der digitalen Hochschulbildung zentralen Faktoren erweisen und sich zu den ausschlaggebendsten Diversitätsmerkmalen entwickeln. Ein ethisch begründeter und transparenter Einsatz von KI erfordert neue Kompetenzen bezüglich der Auswertung der generierten Datenmengen, gerade auch unter der Prämisse Fehltritte und Diskriminierung zu vermeiden. Datenschutz und Schutz der Privatsphäre, transparente Datenrichtlinien und regelmäßige ethische Datenfolgenabschätzungen der eingesetzten Systeme werden damit zu zentralen Leitlinien digitaler Hochschulbildung. Die Implementierung von KI gilt es, in einer diversitätsorientierten Forschungsperspektive empirisch zu begleiten.

Anja Gottburgsen: Deutsches Zentrum für Hochschul- und Wissenschaftsforschung, Forschung und Change Management; gottburgsen@dzhw.eu

Yvette E. Hofmann: Ludwig-Maximilians-Universität München, Forschungsstelle für Hochschulforschung und -governance; yvette.hofmann@lmu.de

Janka Willige: Deutsches Zentrum für Hochschul- und Wissenschaftsforschung, Abteilung Bildungsverläufe und Beschäftigung; willige@dzhw.eu

Literatur

- Aktionsrat Bildung (2018). *Digitale Souveränität und Bildung: Gutachten*. Münster: Waxmann. Retrieved from http://www.aktionsrat-bildung.de/fileadmin/Dokumente/Gutachten_pdfs/ARB_Gutachten_Digitale_Souveraenitaet.pdf.
- Alba, R. D., & Waters, M. C. (Eds.) (2011). *The next generation: Immigrant youth in a comparative perspective*. New York: New York University.
- Angenent, H., Heidkamp, B., & Kergel, D. (Eds.) (2019). *Diversität und Bildung im digitalen Zeitalter. Digital Diversity: Bildung und Lernen im Kontext gesellschaftlicher Transformationen*. Wiesbaden: Springer Fachmedien Wiesbaden.
- Autorengruppe Bildungsberichterstattung (2016). *Bildung in Deutschland 2016: Ein indikatorengestützter Bericht mit einer Analyse zu Bildung und Migration*. Bielefeld: WBV.
- Bond, M., Marín, V. I., Dolch, C., Bedenlier, S., & Zawacki-Richter, O. (2018). Digital transformation in German higher education: student and teacher perceptions and usage of digital media. *International Journal of Educational Technology in Higher Education*, 15(1), 1–20.
- Boomers, S., & Nitschke, A. K. (2012). *Diversität und Lehre: Empfehlungen zur Gestaltung von Lehrveranstaltungen mit heterogenen Studierendengruppen*. Gemeinschaftsprojekt der Arbeitsbereiche Qualitätssicherung in Studium und Lehre des FB Geschichts- und Kulturwissenschaften und des FB Politik- und Sozialwissen-

- schaften. Berlin. Retrieved from Freie Universität Berlin <https://www.fu-berlin.de/sites/diversitaet-und-lehre/diversitaetsmerkmale/index.html>.
- Bowen, W. G., Chingos, M. M., Lack, K. A., & Nygren, T. I. (2014). Interactive learning online at Public Universities: Evidence from a six-campus randomized trial. *Journal of Policy Analysis and Management*, 33(1), 94–111.
- Brooks, D. C. (2016). *ECAR Study of undergraduate students and information technology*. Louisville, CO. Retrieved from <https://er.educause.edu/~media/files/library/2016/10/ers1605.pdf?la=en>.
- Brooks, D. C., & Pomerantz, J. (2017). *ECAR Study of faculty and information technology 2017: Research Report*. Louisville, CO. Retrieved from <https://library.educause.edu/resources/2017/10/ecar-study-of-undergraduate-students-and-information-technology-2017>.
- Buche, A., & Gottburgsen, A. (2012). Migration, soziale Herkunft und Gender: »Intersektionalität« in der Hochschule. In P. Pielage, L. Pries, & G. Schultze (Eds.), *Soziale Ungleichheit in der Einwanderungsgesellschaft. Kategorien, Konzepte, Einflussfaktoren: Tagungsdokumentation im Auftrag der Abteilung Wirtschafts- und Sozialpolitik der Friedrich-Ebert-Stiftung (WISO Diskurs)* (S. 113–126). Bonn: Friedrich-Ebert-Stiftung.
- Cox, T. H. (1991). The multicultural organization. *Academy of Management Executive*, 5(2), 34–47.
- Cox, T. H. (1993). *Cultural »diversity« in organizations: Theory, research and practice*. San Francisco: Berrett-Koehler.
- DAAD, & DZHW (2017). *Wissenschaft Weltoffen 2017: Daten und Fakten zur Internationalität von Studium und Forschung in Deutschland*. Bielefeld: W. Bertelsmann Verlag.
- de Witt, C. (2019). Digitalisierung in der Lehre – Potenziale und deren Umsetzung. *Forschung & Lehre*. 9/19, 814–815.
- de Witt, C., Rampelt, F., & Pinkwart, N. (Eds.) (2020). *Künstliche Intelligenz in der Hochschulbildung: Whitepaper*. Berlin: KI-Campus.
- Ebert, J., & Heublein, U. (2017). *Ursachen des Studienabbruchs bei Studierenden mit Migrationshintergrund: Eine vergleichende Untersuchung der Ursachen und Motive des Studienabbruchs bei Studierenden mit und ohne Migrationshintergrund auf Basis der Befragung der Exmatrikulierten des Sommersemesters 2014*. Hannover, Essen: DZHW, Stiftung Mercator.
- Eriksson, T., Adawi, T., & Stöhr, C. (2017). »Time is the bottleneck«: A qualitative study exploring why learners drop out of MOOCs. *Journal of Computing in Higher Education*, 29(1), 133–146.
- Fichten, C., Olenik-Shemesh, D., Asuncion, J., Jorgensen, M., & Colwell, C. (2020). Higher education, information and communication technologies and Students with disabilities: An overview of the current situation. In Seale & Christie (Eds.), *Improving Accessible Digital Practices in Higher Education* (S. 21–44). Springer International Publishing.

- Galanek, J. D., Gierdowski, D. C., & Brooks, D. C. (2018). *ECAR Study of undergraduate students and information technology 2018*. Louisville, CO: ECAR. Retrieved from <https://library.educause.edu/~media/files/library/2018/10/studentitstud y2018.pdf?la=en>.
- Gardenswartz, L., & Rowe, A. (1998). *Managing diversity: A complete desk reference and planning guide*. Section 3 (Revised edition). New York: McGraw-Hill.
- Gierdowski, D. C. (2019). *ECAR Study of undergraduate students and information technology 2019*. Louisville, CO. Retrieved from <https://library.educause.edu/~media/files/library/2019/10/studentstudy2019.pdf?la=en&hash=25FBB396AE48 2FAC3B765862BA6B197DBC98B42C>.
- Gottburgsen, A., & Arbeitskreis Gender & Diversity in der Lehre (2015). *Empfehlungen zur Förderung einer gender- und diversitätssensiblen Lehr- und Lernkultur. Working Paper*. Erlangen, Nürnberg. https://www.gender-und-diversity.fau.de/files/201 7/11/2015_0405_empfehlungen_gender_diversittssensible_lehrlernkultur.pdf.
- Gottburgsen, A., & Gross, C. (2012). Welchen Beitrag leistet »Intersektionalität« zur Klärung von Kompetenzunterschieden bei Jugendlichen? In R. Becker & H. Solga (Eds.), *Kölner Zeitschrift für Soziologie und Sozialpsychologie Sonderheft: Vol. 52. Soziologische Bildungsforschung* (Vol. 52, S. 86–110). Wiesbaden: Springer VS.
- Gottburgsen, A., & Willige, J. (2018). Mehr Mobilitätserfahrungen durch digitale Medien? Zu den Effekten von studentischer Diversität und Lernumweltsmerkmalen auf die internationale Mobilität. *Beiträge zur Hochschulforschung*, 40(4), 30–49.
- Gregori, P., Martínez, V., & Moyano-Fernández, J. J. (2018). Basic actions to reduce dropout rates in distance learning. *Evaluation and Program Planning*, 66, 48–52.
- Griffin, K. A., & Museus, S. D. (2011). *Using mixed-methods approaches to study intersectionality in higher education. New directions for institutional research: no. 151, Fall 2011*. San Francisco: Jossey-Bass.
- Grosch, M., & Gidion, G. (2011). *Mediennutzungsgewohnheiten im Wandel: Ergebnisse einer Befragung zur studiumsbezogenen Mediennutzung*. s.l.: KIT Scientific Publishing. Retrieved from <http://www.doabooks.org/doi/fulltext&rid=19433>.
- Gross, C., Gottburgsen, A., & Phoenix, A. (2016). Education systems and intersectionality. In A. Hadjar & C. Gross (Eds.), *Education systems and inequalities : international comparisons* (S. 51–72). Bristol: Policy Press.
- Heath, A., & Brinbaum, Y. (2016). Explaining ethnic inequalities in educational attainment. *Ethnicities*, 7(3), 291–304.
- Henderson, M., Selwyn, N., & Aston, R. (2017). What works and why? Student perceptions of »useful« digital technology in university teaching and learning. *Studies in Higher Education*, 42(8), 1567–1579.
- Hochschulforum Digitalisierung (2016). *The Digital Turn – Hochschulbildung im digitalen Zeitalter. Arbeitspapier Nr. 27*. Berlin. Retrieved from <https://hochschulforum digitalisierung.de/sites/default/files/dateien/Abschlussbericht.pdf>.

- Hofmann, Y. E., Müller-Hotop, R., & Datzer, D. (2020). Die Bedeutung von Resilienz im Hochschulkontext – Eine Standortbestimmung von Forschung und Praxis. *Beiträge zur Hochschulforschung*, 42(1/2), 10–35.
- Huang, W.-H. D., Hood, D. W., & Yoo, S. J. (2013). Gender divide and acceptance of collaborative Web 2.0 applications for learning in higher education. *The Internet and Higher Education*, 16, 57–65.
- Jungbauer-Gans, M., & Gottburgsen, A. (Eds.) (2020). *Higher Education Research and Science Studies. Migration, Mobilität und soziale Ungleichheit in der Hochschulbildung*. Wiesbaden: Springer Fachmedien Wiesbaden.
- Karapanos, M., & Fendler, J. (2015). Lernbezogenes Mediennutzungsverhalten von Studierenden der Ingenieurwissenschaften: Eine geschlechterkomparative Studie. *Journal of Technical Education*, 3(1), 39–55.
- Klein, U., & Heitzmann, D. (Eds.) (2012). *Diversity und Hochschule. Hochschule und Diversity: Theoretische Zugänge und empirische Bestandsaufnahme*. Weinheim, Basel: Beltz Juventa.
- KMK/HRK (2015–16). *Europäische Studienreform. Kultusministerkonferenz vom 08.07.2016. Gemeinsame Erklärung von Kultusministerkonferenz und Hochschulrektorenkonferenz. Beschluss der Hochschulrektorenkonferenz vom 10.11.2015 sowie der Kultusministerkonferenz vom 08.07.2016*. Retrieved from https://www.hrk.de/uploads/tx_szconvention/EUStudienreform_GemErklaerung_KM_K_HRK_2015_2016.pdf.
- Krell, G. (2008). Chancengleichheit für alle und auch als Wettbewerbsfaktor. In G. Krell (Ed.), *Chancengleichheit durch Personalpolitik: Gleichstellung von Frauen und Männern in Unternehmen und Verwaltungen* (5. Aufl., S. 63–80). Wiesbaden: Gabler.
- Kristen, C. (2014). Migrationsspezifische Ungleichheiten im deutschen Hochschulsystem. *Journal für Bildungsforschung*, 6(2), 113–134.
- Kuger, S., Linberg, T., Bäumer, T., & Struck, O. (2018). *Digitale Lernumwelten*.
- Lack, K. A. (2015). *Current status of research on online learning in postsecondary education*. New York. Retrieved from <http://www.sr.ithaka.org/wp-content/uploads/2015/08/ithaka-sr-online-learning-postsecondary-education-may2012.pdf>.
- López-Pérez, M. V., Pérez-López, M. C., & Rodríguez-Ariza, L. (2011). Blended learning in higher education: Students' perceptions and their relation to outcomes. *Computers & Education*, 56(3), 818–826.
- Lörz, M. (2019). Intersektionalität im Hochschulbereich: In welchen Bildungsphasen bestehen soziale Ungleichheiten nach Migrationshintergrund, Geschlecht und sozialer Herkunft – und inwieweit zeigen sich Interaktionseffekte? *Zeitschrift für Erziehungswissenschaft*, 22(S1), 101–124.
- Means, B., Toyama, Y., Murphy, R., & Baki, M. (2013). The effectiveness of online and blended learning: A meta-analysis of the empirical literature. *Teachers College Record*, 115(3), 1–47.

- Middendorff, E., Apolinarski, B., Becker, K., Bornkessel, P., Brandt, T., Heißenberg, S., & Poskowsky, J. (2017). *Die wirtschaftliche und soziale Lage der Studierenden in Deutschland 2016: 21. Sozialerhebung des Deutschen Studentenwerks durchgeführt vom Deutschen Zentrum für Hochschul- und Wissenschaftsforschung*. Bonn, Berlin: Bundesministerium für Bildung und Forschung.
- Middendorff, E., & Wolter, A. (2021). Hochschulexpansion und Diversität: Wird die Zusammensetzung der Studierenden heterogener? *Das Hochschulwesen*, 69(5+6), 138–151.
- Müller, C., & Sander, G. (2011). *Innovativ führen mit Diversity-Kompetenz: Vielfalt als Chance*. Bern: Haupt.
- Ng, W. (2012). Can we teach digital natives digital literacy? *Computers & Education*, 59(3), 1065–1078.
- Nicolaos, K., Tzafeia, O., & Thanaos, T. (2019). University student's skills in using the the internet for educational purposes and the digital divide. *European Journal of Open Education and E-Learning Studies*, 4(1), 60–72.
- OECD (2020). *Bildung auf einen Blick: Oecd Indicators*. Paris: OECD.
- Peña-Ayala, A. (Ed.) (2017). *Studies in systems, decision and control: Vol. 94. Learning Analytics: Fundaments, applications, and trends: A view of the current state of the art to enhance e-Learning*. Cham: Springer International Publishing.
- Persike, M., & Friedrich, J.-D. (2016). *Lernen mit digitalen Medien aus Studierendenperspektive*. Arbeitspapier Nr. 17. Berlin. Retrieved from https://hochschulforumdigitalisierung.de/sites/default/files/dateien/HFD_AP_Nr_17_Lernen_mit_digitalen_Medien_aus_Studierendenperspektive.pdf.
- Porter, W. W., Graham, C. R., Spring, K. A., & Welch, K. R. (2014). Blended learning in higher education: Institutional adoption and implementation. *Computers & Education*, 75, 185–195.
- Riis, S. (2017). ICT Literacy: An imperative of the twenty-first century. *Foundations of Science*, 22(2), 385–394.
- Schmid, U., Goertz, L., Radomski, S., Thom, S., & Behrens, J. (2017). *Monitor Digitale Bildung: Die Hochschulen im digitalen Zeitalter*. Gütersloh: Bertelsmann Stiftung. Retrieved from https://www.bertelsmann-stiftung.de/fileadmin/files/BSt/Publikationen/GrauePublikationen/DigiMonitor_Hochschulen_final.pdf.
- Sclater, N., Peasgood, A., & Mullen, J. *Learning Analytics in higher education: A review of UK and international practice*. Bristol. Retrieved from Jisc website: https://www.jisc.ac.uk/sites/default/files/learning-analytics-in-he-v2_o.pdf.
- Seale, & Christie (Eds.) (2020). *Improving accessible digital practices in higher education*. Springer International Publishing.
- Seale, J., Colwell, C., Coughlan, T., Heiman, T., Kaspi-Tsahor, D., & Olenik-Shemesh, D. (2020). ›Dreaming in colour‹: Disabled higher education students' perspectives on improving design practices that would enable them to benefit from their use of technologies. *Education and Information Technologies*, 26, 1687–1719.

- Seale, J., Georgeson, J., Mamas, C., & Swain, J. (2015). Not the right kind of ›digital capital‹? An examination of the complex relationship between disabled students, their technologies and higher education institutions. *Computers & Education*, 82, 118–128.
- Senkbeil, M., Schöber, C., & Ihme, J. M. (2018). Fit fürs Studium? Computer- und informationsbezogene Basiskompetenzen Studierender und angehender Studierender. *SchulVerwaltung Nordrhein-Westfalen: Zeitschrift für Schulentwicklung und Schulmanagement*, 29(7–8), 221–224.
- Simpson, O. (2013). Student retention in distance education: are we failing our students? *Open Learning: The Journal of Open, Distance and E-Learning*, 28(2), 105–119.
- Sønderlund, L. A., Hughes, E., & Smith, J. (2019). The efficacy of learning analytics interventions in higher education: A systematic review. *British Journal of Educational Technology*, 50(5), 2594–2618.
- Statistisches Bundesamt (2020). *Studierende nach Bundesländern*. Retrieved from <https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Bildung-Forschung-Kultur/Hochschulen/Tabellen/studierende-insgesamt-bundeslaender.html>.
- Steffens, Y., Schmitt, I. L., & Aßmann, S. (2017). *Mediennutzung Studierender: Über den Umgang mit Medien in hochschulischen Kontexten: Systematisches Review nationaler und internationaler Studien zur Mediennutzung Studierender*: Ruhr-Universität Bochum (RUB).
- Stoessel, K., Ihme, T. A., Barbarino, M.-L., Fisseler, B., & Stürmer, S. (2015). Sociodemographic diversity and distance education: Who drops out from academic programs and why? *Research in Higher Education*, 56(3), 228–246.
- Thöing, K., Bach, U., Vossen, R., & Jeschke, S. (2016). »ist digital normal?«: Untersuchung des Mediennutzungsverhaltens Studierender in der ingenieurwissenschaftlichen Lehre. In S. C. Frerich, T. Meisen, A. S. Richert, M. Petermann, S. Jeschke, U. Wilkesmann, & A. E. Tekkaya (Eds.), *Engineering Education 4.0: Excellent teaching and learning in engineering sciences* (S. 675–683). Cham: Springer.
- Van Rooij, S. W., & Zirkle, K. (2016). Balancing pedagogy, student readiness and accessibility: A case study in collaborative online course development. *The Internet and Higher Education*, 28, 1–7.
- Viberg, O., Hatakka, M., Bälter, O., & Mavroudi, A. (2018). The current landscape of learning analytics in higher education. *Computers in Human Behavior*, 89, 98–110.
- Wannemacher, K. (2016). *Digitale Lernszenarien im Hochschulbereich*. Arbeitspapiere des Hochschulforums Digitalisierung: Nr. 15. Berlin.
- Willige, J. (2016). *Auslandsmobilität und digitale Medien*. Arbeitspapier Nr. 23. Berlin. Retrieved from https://hochschulforumdigitalisierung.de/sites/default/files/dateien/HFD_AP_Nr23_Digitale_Medien_und_Mobilitaet.pdf.
- Winde, M., Werner, S. D., Gumbmann, B., & Hieronimus, S. (2020). *Hochschulen, Corona und jetzt? Wie Hochschulen vom Krisenmodus zu neuen Lehrstrategien für die di-*

- gitale Welt gelangen. Future Skills*. Essen. Retrieved from <https://www.stifterverband.org/download/file/fid/9313>.
- Wissenschaftsrat (2018). *Empfehlungen zur Internationalisierung von Hochschulen*. Retrieved from <https://www.wissenschaftsrat.de/download/archiv/7118-18.pdf>.
- Woisch, A., & Willige, J. (2015). *Internationale Mobilität im Studium 2015. Ergebnisse der fünften Befragung deutscher Studierender zur studienbezogenen Auslandsmobilität*. Hannover: DAAD/DZHW.
- Zawacki-Richter, O. (2015). Zur Mediennutzung im Studium: Unter besonderer Berücksichtigung heterogener Studierender. *Zeitschrift für Erziehungswissenschaft*, 18(3), 527–549.
- Zawacki-Richter, O., Kramer, C., & Müskens, W. (2016). *Studiumbezogene Mediennutzung im Wandel. Querschnittsdaten 2012 und 2015 im Vergleich. Schriftenreihe zum Bildungs- und Wissensmanagement*. Retrieved from <https://openjournal.uni-oldenburg.de/index.php/bildungsmanagement/article/view/101>.
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1), 1–27.

»Wie kann ich dich unterstützen?«

Chatbot-basierte Lernunterstützung für Studienanfänger:innen

Anne-Kathrin Helten, Uwe Wienkop, Diana Wolff-Grosser und Christina Zitzmann

Abstract: *Im Initiativprogramm BayernMINT fördert der Freistaat Bayern Maßnahmen zur Senkung der Studienabbruchquoten. An der Technischen Hochschule Nürnberg wird ein regelgeleiteter Chatbot als niedrigschwellige Kommunikationstechnologie zur Lernunterstützung konzipiert und implementiert. Auf Grundlage der Ergebnisse eines testpsychologisch fundierten Allgemeinen Studierfähigkeitstests unterstützt dieser Chatbot Studieninteressierte und vor allem Studienanfänger:innen individuell bei ihren Lernaktivitäten. Winkler und Söllner (2018) zeigen, dass der Einsatz von Chatbots einen signifikant positiven Einfluss auf den Lernerfolg verspricht. Nach erfolgreicher Pilotphase soll die Lehrinnovation in den Regelbetrieb an der Technischen Hochschule Nürnberg übernommen werden. Im aktuellen Chatbot werden KI-Technologien zum Verstehen natürlicher Sprache verwendet. Darüber hinaus bietet der Einsatz von KI weitere Potenziale für die Hochschulbildung, wie z.B. KI-basierte Analysen der Kompetenzen von Studieninteressierten als Grundlage für Empfehlungen für die Studiengangspassung.*

With the BayernMINT program, the Free State of Bavaria supports measures to reduce dropout rates. As part of this project, a rule-based chatbot is being designed and implemented at the Nuremberg University of Applied Sciences as a low-threshold communication technology to support learning. Based on the results of a psychologically based general aptitude test, the chatbot is intended to provide support to individual prospective students and, in particular, first-term students in their learning activities. Winkler and Söllner (2018) show that the use of chatbots promises a significantly positive influence on learning success. After a successful pilot phase, the teaching innovation will be used in regular operation at the University of Applied Sciences, Nuremberg. In the current chatbot, AI technologies are used to understand natural language. In addition, the use of AI offers further potential for higher education, such as AI-based analyses of prospective students' competencies as a basis for recommendations for the choice of studies.

Keywords: Chatbot, Digitale Intervention, Hochschulbildung, Lernunterstützung / chatbot, digital intervention, higher education, learning support.

Ausgangslage und Entstehungshintergrund der Chatbot-basierten Lernunterstützung

Die Hochschulen in Deutschland bewältigen seit mehr als einem Jahrzehnt eine sehr hohe Studiennachfrage (Destatis, 2020). Doch nicht jedes Studium verläuft erfolgreich: 27 % der Bachelorstudierenden und 17 % der Masterstudierenden geben nach aktueller Datenlage ihr Studium wieder auf (Autorengruppe Bildungsberichterstattung, 2020). Hochschulen engagieren sich vor diesem Hintergrund darum, wirksame Maßnahmen zur Erhöhung des Studienerfolges zu entwickeln und effizient umzusetzen.

Eine wichtige Maßnahme zur Erhöhung der Studienerfolgsquote stellt eine gute Passung von Studierenden (bzw. ihrer Kompetenzen) zu den Anforderungen des jeweiligen Studiengangs dar, weshalb auch Studieninteressierte eine relevante Zielgruppe für entsprechende Angebote sind. An der Technischen Hochschule Nürnberg (THN) arbeitet daher seit 2008 im Rahmen des Interventionsprojektes »MINT – Wege zu mehr MINT-Absolventen« ein interdisziplinäres Projektteam aus Psychologie, Informatik und Hochschulleitung an der Konzeption und Implementierung von Online-Self-Assessments (OSAs) für Studieninteressierte. Seit ihrer Einführung haben diese Studieneignungstests bereits nachweislich zur Erhöhung der Studienabschlussquote in den MINT-Fächern beigetragen (Wolff-Grosser, 2018). Diese OSAs wurden im Rahmen von vier Förderprojekten weiterentwickelt und verfolgen die Zielsetzung, Studieninteressierten auf Basis testpsychologischer Verfahren Rückmeldungen bezüglich ihrer Studierfähigkeit und fachspezifischen Kompetenzen zu übermitteln. Dies ermöglicht eine reflektierte Studienwahl durch Ermittlung der Passung eigener Fähigkeiten mit den Anforderungen des Studiengangs.

Die THN bietet Studieninteressierten aktuell einen Allgemeinen Studierfähigkeitstest und 14 fachspezifische OSAs in insgesamt zwölf Bachelorstudiengängen an. Fünf weitere fachspezifische OSAs wurden für andere bayrische Hochschulen entwickelt. Seit der Etablierung eines eigenen OSA-Portals im Herbst 2015 durchliefen über 30.700 Teilnehmende die Tests der THN, davon rund 7.500 den Allgemeinen Studierfähigkeitstest, sodass auf eine umfangreiche Datenbasis zurückgegriffen werden kann. Während in den fachspezifischen OSAs Aufgaben zu den jeweils wichtigen Bereichen des entsprechenden Studiengangs – z.B. Mathematik, Physik, Englisch etc. – enthalten sind, umfasst der Allgemeine Studierfähigkeitstest neben Leistungsaufgaben im sprachlichen, mathematischen und räumlichen Denken zusätzlich Selbsteinschätzungsaufgaben in fünf wichtigen lernorganisatorischen Bereichen: Selbstreguliertes Lernen, Volition (d.h. Willenskraft; Fähigkeit zur willentlichen Umsetzung von Zielen durch Selbststeuerung), Selbstwirksamkeit, Leistungsmotivation und Erwartungen an ein Studium. Nach Abschluss der Tests erhalten die Teilnehmenden eine Rückmeldung über das erzielte Ergebnis und

ggf. daraus abgeleitete weiterführende Empfehlungen, wie beispielsweise den Besuch eines Brückenkurses im Fach Mathematik vor Beginn des Studiums.

Die Aufnahme von Fragestellungen zur Lernorganisation in den Allgemeinen Studierfähigkeitstest beruht auf der Beratungserfahrung, dass nicht nur unbewältigte Leistungsanforderungen, sondern auch lernorganisatorische Defizite einen wesentlichen Grund für Studienabbrüche darstellen. Eine an der Technischen Hochschule Nürnberg durchgeführte Befragung von sog. Studienpionier:innen, die als erste in ihrer Familie eine Hochschule besuchen, bestätigte diese Annahme: So äußerten die befragten Studierenden beispielsweise, dass sie teils bis zu drei Semester benötigten, um sich an die neuen Lernweisen an der Hochschule anzupassen. Dass in dieser Zeitspanne je nach Studiengang umfangreiche Wissenslücken entstehen können, deren Kompensation die Studiendauer erheblich erhöhen kann, ist offensichtlich. Die Wichtigkeit früher Interventionen ist auch durch die Erfahrungen des MINT-Projektteams belegt. So konnte beispielsweise die Erfolgswahrscheinlichkeit für das Bestehen der Klausur »Programmieren I« an der TH-Nürnberg durch kontinuierliche Pflichtübungen studiengangsübergreifend um 60 % erhöht werden (Roderus & Wienkop, 2015).

Vor diesem Hintergrund entstand an der THN das Interesse, den Studieninteressierten frühzeitig die Notwendigkeit eines akademischen Lernens bewusst zu machen und ihnen Angebote zu unterbreiten, die diesen Lernprozess unterstützen. Eine flächendeckende persönliche Unterstützung für alle Studienanfänger:innen ist aus ökonomischen Gründen nicht umsetzbar. Daher wird in einem aktuellen Forschungsprojekt (2019 – 2022) ein prototypischer Chatbot (OSABot) entwickelt, der anhand der Ergebnisse im Allgemeinen Studierfähigkeitstest – also nach einer umfangreichen und langjährig erprobten testpsychologischen Diagnostik – darauf zielt, Studienanfänger:innen noch vor der Kumulation von Wissensrückständen in dialogischer Weise konkrete digitale Interventionsvorschläge zu unterbreiten, um ihr Lernverhalten zu verbessern. Die durch den Chatbot aufgezeigten adaptiven Angebote sollen den Studierenden individuelle Lernpfade aufzeigen und sie im Lernprozess unterstützen.

Einsatz von Chatbots in der Hochschulbildung

Die ursprünglich durch kommerzielle Unternehmen bekannt gewordenen textbasierten Dialogsysteme (Chatbots) werden zunehmend auch bezüglich ihrer Einsatzmöglichkeiten im Hochschulkontext diskutiert und in Pilotprojekten bereits angewandt bzw. evaluiert. Ein Einsatzbereich ist der Chatbot als Assistent für das Lehr- und Verwaltungspersonal hinsichtlich häufiger Anliegen der Studierenden zu (hochschulweiten) administrativen und organisatorischen Prozessen (Clarizia et al., 2018; Goel & Polepeddi, 2016; Hien et al., 2018). So können Chat-

bots beispielsweise Fragen zu Kurswahl, Stundenplan, Prüfungen und Stipendien beantworten oder in Lernmanagementsysteme integriert werden, um diese nach spezifischen Lernmaterialien zu durchsuchen. Darüber hinaus werden Chatbots für die inhaltliche Begleitung spezifischer Seminare konzipiert. *Percy* begleitet beispielsweise ein Grundlagenseminar in Stanford und steht sowohl für organisatorische Fragen (z.B. zu Abgabefristen) als auch bei Rückfragen zu Übungsaufgaben oder Kursinhalten zur Verfügung (Chopra et al., 2016). An der University of Hong Kong unterstützt ein Chatbot die Teilnehmenden in einem Seminar zu kriminaltechnischen Untersuchungen eines Verbrechens (Gonda et al., 2018): Er stellt den Studierenden regelmäßig Fragen zu ihrem aktuellen Ermittlungsstand und gibt ggf. Tipps zur weiteren Spurenanalyse.

Ein grundsätzlicher Tenor wird bei Betrachtung der aktuellen Studienlage jedoch auch deutlich: Bei Chatbots im Bildungskontext handelt es sich um ein sehr junges Forschungsgebiet. Gegenwärtig mangelt es an hochwertigen und systematischen Studien zum Einsatz von Chatbots im Hochschulkontext, die über Pilotstudien hinausgehen. Die Ausführungen zur technischen Umsetzung und inhaltlichen Gestaltung sind meist sehr knapp. Zudem unterscheiden sich Chatbot-Systeme und Einsatzszenarien innerhalb des Bildungskontextes so stark voneinander, dass sich Forschungs- und Projektteams bei der Entwicklung eines neuen Chatbots kaum auf bestehende Arbeiten stützen können (Hobert & Meyer von Wolff, 2019). Ergänzend resümieren Winkler und Söllner (2018), dass es nur sehr wenige Studien gibt, die sich mit der Frage beschäftigen, inwiefern Chatbots Lernprozesse und -erfolge verbessern können. Auch Smutny und Schreiberova (2020) kommen zu dem Schluss, dass sich die Anwendung von Chatbots in einer frühen Phase hin zur Entwicklung intelligenter Lernsysteme befindet (Schwaetzer, 2020, S. 20).

Gleichzeitig wird aber auch immer wieder das Potential dieses Forschungsgebietes betont. Chatbots werden sich weiterentwickeln und in der Zukunft eine wichtige Rolle an Hochschulen weltweit spielen: »Chatbots have the potential to create individual learning experiences for students and therefore increase learning outcomes and support lecturers and their teaching staff« (Winkler & Söllner, 2018, S. 29). Auch Schwaetzer (2020, S. 20) und unser MINT-Projektteam blicken optimistisch in die Zukunft: »Wenn [entsprechende] Rahmenbedingungen berücksichtigt werden und die KI-Tools zunehmend technisch ausreifen, ist ihr Einsatz in der Hochschule vielversprechend.«

Testpsychologische Grundlagen und Architektur der Chatbot-Anwendung

Ausgangspunkt für die Entwicklung des OSABots ist der oben beschriebene Allgemeine Studierfähigkeitstest der Technischen Hochschule Nürnberg. Dieser umfasst insgesamt 125 Items, die sich auf neun Module verteilen: Interessens-

schwerpunkt, Selbstreguliertes Lernen, Selbstwirksamkeit, Volition, Erwartungen an das Studium, Leistungsmotivation, Sprach- und Zahlengebundenen logisches Denken sowie Räumliches Vorstellungsvermögen. Alle Module basieren auf einer fundierten Fragebogenkonstruktion nach testpsychologischen Kriterien und werden regelmäßig evaluiert und angepasst. Nach Abschluss des Tests wird den Teilnehmenden ihre jeweils erreichte Modulpunktzahl in Referenz zur Normierungsstichprobe angezeigt.


Um die Teilnehmenden zur Weiterarbeit an ihrem Lernverhalten zu motivieren, wird im laufenden BayernMINT-Forschungsprojekt eine digitale Intervention in Form eines Chatbots entwickelt, der den Testteilnehmenden konkrete, auf das individuelle Ergebnis zugeschnittene Hilfestellungen vermittelt. Hierzu wurden von den beiden Testpsychologinnen des OSA-Teams drei Module des Allgemeinen Studierfähigkeitstests (Selbstreguliertes Lernen, Selbstwirksamkeit und Volition) ausgewählt und mithilfe einer Faktorenanalyse zu sechs Maßnahmenkategorien des OSABots strukturiert: (1) Lernphase planen und Lernstoff organisieren, (2) Umgang mit belastenden Gedanken und Gefühlen, (3) Vertrauen in eigene Fähigkeiten, (4) Lernstrategien, (5) Abschirmung von Ablenkungen sowie (6) Motivation und Dranbleiben. Für jede der sechs Kategorien wurden von den Psychologinnen Interventionsmaßnahmen auf Basis der Modelle der Positiven Psychologie (Engelmann, 2012, 2014; Hanning & Chmielewski, 2019; Wengenroth, 2017) und Lernberatung (Krenzel, 2018; Rost, 2017; Technische Hochschule Rosenheim, 2020) entwickelt, die die Testteilnehmenden bei Aus- und Aufbau der eigenen lern- und selbstorganisatorischen Fähigkeiten unterstützen sollen. Das Maßnahmenrepertoire besteht derzeit aus über 30 Techniken.

Typisierung, Architektur und Realisierung der Chatbot-Anwendung

Es lassen sich zwei Grundtypen von Chatbots unterscheiden: der regelbasierte und der selbstlernende Chatbot. Der erste Typus reagiert nach einer festen Abfolge von im Programm des Chatbots hinterlegten Regeln. Selbstlernende Chatbots nutzen hingegen maschinelles Lernen, um die Antwort auf die Nutzeranfrage zu ermitteln (Apfel, 2021). Der im Folgenden vorgestellte Chatbot ist regelbasiert und nutzt zudem Natural Language Understanding (NLU) zur Erkennung der Intention von Nutzeraussagen.

Das Gesamtsystem gliedert sich in die folgenden drei Teilbereiche (Abb. 1): Chatbot-Server, OSA-Server und Interventionswebseite. Während viele Chatbots zustandslos realisiert werden, sich also nicht merken, welche Nutzer:innen gerade angemeldet sind, welche Problembereiche für welche Nutzer:innen zu behandeln sind und welche Maßnahmen bereits ausprobiert wurden, besitzt der OSABot genau diese Fähigkeiten.

Abbildung 1: Grundarchitektur der Chatbot-Anwendung (eigene Darstellung).



Nach Anmeldung im Chatbot hat das System Zugriff auf die aggregierten Daten des Allgemeinen Studierfähigkeitstests und verfügt somit über Informationen zur Selbsteinschätzung der Nutzer:innen bzgl. ihrer lernorganisatorischen Fähigkeiten. Auf dieser Basis kann der OSABot die Anwender:innen im Dialog auf Bereiche fachübergreifender Kompetenzen mit geringen Punktwerten aufmerksam machen und entsprechende Interventionen vorschlagen. Wenn sich die Studierenden dann für spezifische Interventionstechniken entscheiden, merkt sich der OSABot diese Auswahl und fragt bei einem erneuten Aufruf nach dem Erfolg der Interventionstechnik. Ausführliche Beschreibungen sowie Abbildungen und Videos zu den verschiedenen Interventionsmaßnahmen sind auf einer eigenen Webseite abgelegt, worauf vom Chatbot aus verlinkt wird. Insgesamt wird durch dieses Verfahren eine Begleitung der Studierenden beim Einüben von Lernunterstützungen angestrebt. So ist es möglich, potenziell allen Studienanfänger:innen eine Lernunterstützung zukommen zu lassen, welche individuelle Lerndefizite und den jeweiligen Interventionsstand berücksichtigt.


Prototypischer Anwendungsverlauf

Besucher:innen des OSA-Portals werden durch eine automatisch angezeigte Nachricht (»Hallo wie geht's? Ich helfe dir gerne weiter«) auf den OSABot aufmerksam gemacht. Nach einem Klick auf das Chatbot-Icon öffnet sich das Dialogfenster und die Nutzer:innen werden nach einer kurzen Begrüßung und Vorstellung des OSABots aufgefordert, ihre E-Mail-Adresse einzugeben. Anhand dieser wird überprüft, ob der Allgemeine Studierfähigkeitstest und insbesondere die Module Selbstreguliertes Lernen, Selbstwirksamkeit und Volition bearbeitet wurden, welche als diagnostische Basis für die Interventionsvermittlung dienen.

Wenn die benötigten Daten vollständig vorliegen, wird weiterhin analysiert, ob Entwicklungspotentiale bestehen, d.h. ob es Kategorien mit geringen Punktwerten gibt. In diesem Fall erfolgt eine dialogische Hinführung zu diesen testdiagnostisch

identifizierten Interventionskategorien, welche im OSABot als Buttons präsentiert werden. Der exemplarischen Nutzerin in Abbildung 2 werden insgesamt vier Interventionskategorien präsentiert; in diesen Kategorien hat sie einen Punktwert unterhalb einer bestimmten Schwelle erzielt, sodass für den Chatbot eine Intervention indiziert ist (Abb. 2 links). Die Auswahl der übergeordneten Interventionskategorie ist somit den Nutzer:innen selbst überlassen. Entscheidet sich die exemplarische Nutzerin für die Interventionskategorie ›Lernphase planen & Lernstoff organisieren‹, greift der Chatbot auf die Datenbank zu. Hier befinden sich für diese Interventionskategorie neun konkrete Techniken zur Verbesserung der selbstorganisatorischen Fähigkeiten von Studierenden, etwa zu Zeitmanagement oder Priorisierung des Prüfungsstoffes. Der OSABot wählt aus diesem Pool nach dem Zufallsprinzip drei Vorschläge aus, die den Anwender:innen jeweils mit einem kurzen Teaser-Text präsentiert werden (siehe Abb. 2 Mitte). Auf diese Weise wird ein kurzer Einblick in die konkrete Technik gegeben, sodass die User:innen wieder selbst über Auswahlbuttons entscheiden können, womit sie sich auseinandersetzen möchten. Wird, wie im Beispiel, die Pomodoro-Technik ausgewählt, erhalten die Nutzer:innen einen Link zum entsprechenden Beitrag auf der zugehörigen Interventionswebseite. Dort wird die Pomodoro-Technik mithilfe eines Videos ausführlich erklärt. Zum Abschluss weist der Chatbot auf eine erneute Kontaktaufnahme nach sieben Tagen hin, wofür er den User:innen eine Erinnerungsemail senden wird, und verabschiedet sich (siehe Abb. 2 rechts).

Abbildung 2: Exemplarische Ausschnitte der prototypischen Interaktion zwischen User:in und OSABot.



Kehren die User:innen nach einer Woche zurück, erkundigt sich der OSABot, ob sie die angewandte Technik als hilfreich erlebt haben. Wird dies verneint, versucht der Chatbot zu eruieren, ob die vorgeschlagene Technik generell ausprobiert wurde oder der Vorschlag von vornherein nicht überzeugen konnte. Der sich anschließende Gesprächsverlauf variiert abhängig von der gegebenen Antwort. Beide Dialogzweige enthalten jeweils Maßnahmen der Psychoedukation zu Aufbau und Etablierung neuer Gewohnheiten sowie motivierende Gesprächselemente. Zunächst ermutigt der Chatbot die User:innen dazu, die empfohlene Technik noch einmal bzw. weiter auszuprobieren; scheitert dieser erneute Motivationsversuch, wird eine alternative Technik vorgeschlagen. Lehnt ein:e User:in die Angebote des OSABots bis zuletzt ab, weist der Chatbot auf andere Anlaufstellen und Unterstützungsangebote der TH Nürnberg hin und stellt ggf. die entsprechenden Kontaktdaten zur Verfügung. Gelingt es dagegen, die User:innen dazu zu motivieren, der Technik eine zweite Chance zu geben, bestärkt der OSABot diese Entscheidung nochmals und verabschiedet sich bis zur nächsten Woche.

Wurde die zuerst ausgewählte Technik als hilfreich erlebt, gibt es zwei Möglichkeiten für den weiteren Verlauf: (1) Die User:innen möchten zunächst nur bei einer Technik bleiben, damit diese zur Routine im Studienalltag werden kann. In diesem Fall erkundigt sich der Chatbot, ob er sich nach sieben Tagen wieder melden soll, und verabschiedet sich. (2) Möchten die Anwender:innen eine weitere Technik ken-

nenlernen, präsentiert der OSABot erneut die Interventionskategorien mit geringen Punktwerten und der Auswahlprozess beginnt von vorne.

Aktueller Entwicklungsstand des OSABots

Eine erste Version des prototypischen OSABots wurde im Rahmen einer Masterarbeit entwickelt (Apfel, 2021). In diesem Kontext testeten zwölf Proband:innen aus dem Umfeld des Masterstudierenden den Chatbot. Für die Evaluation hat der Masterstudierende zudem einen Fragebogen erstellt und die zwölf Tester:innen um Feedback gebeten. Dabei wurde der OSABot von den Proband:innen zu 100 % als hilfreich bewertet und nur ein:e Tester:in sprach sich gegen eine kontinuierliche Nutzung aus. Gegenwärtig wird der OSABot vom MINT-Projektteam intensiv getestet und sowohl inhaltlich als auch technisch optimiert. Nach der vollständigen Anbindung an das OSA-Portal ist der Beginn des Produktivbetriebs zum Sommersemester 2022 geplant.

Chancen und Herausforderungen des OSABots

Mehrwert des OSABots und Vorteile für Hochschulen

Eine Google-Suche mit den Stichworten »Lernen Studium« liefert über 95 Millionen Ergebnisse. Es mangelt folglich nicht an Lerntipps und -strategien, die dabei helfen sollen, das eigene Studium erfolgreich abzuschließen. Gleichzeitig können diese vielen Möglichkeiten schlichtweg überwältigend sein. Genau hier findet sich das Alleinstellungsmerkmal des OSABots: er basiert auf validen, testdiagnostischen Daten. Die vorangestellte Testdiagnostik des Allgemeinen Studierfähigkeitstests ermöglicht das Aufzeigen individueller Entwicklungsfelder und die zielgerichtete Hinführung zu einer hilfreichen Intervention. Eine weitere Stärke des OSABots ist die Konstruktion als Lernbegleiter mit wöchentlichem Kontakt zu den Studierenden. Es braucht Zeit, Übung und viele Wiederholungen, um neue Gewohnheiten aufzubauen und im (Lern-)Alltag zu etablieren. Wöchentliche Erinnerungen können dabei unterstützen, die vorgeschlagenen Strategien und Verhaltenstipps kontinuierlich anzuwenden und sie zu Routinen werden zu lassen.

Darüber hinaus bieten Chatbots einige grundlegende Vorteile im Beratungskontext (Bendig et al., 2019; Bickmore et al., 2010; Clarizia et al., 2018; Winkler & Söllner, 2018): Es handelt sich um ein sehr niederschwelliges Angebot, sodass der Kontakt zu einem Chatbot weniger Hürden mit sich bringt und die Wahrscheinlichkeit steigert, dass sich potenzielle User:innen überhaupt in einem ersten Schritt Unterstützung suchen. Weiterhin sind digitale Interventionsmaßnahmen überall und rund um die Uhr verfügbar, sie ermöglichen eine individuelle Zeiteinteilung sowie

eine Nutzung im eigenen (Lern-)Tempo. Durch wiederholtes Nachfragen kann der OSABot zudem, ähnlich wie eine Smartphone-App, regelmäßig an die intendierte Verhaltensänderung erinnern. Die Vermittlung von Informationen und die damit verbundene Erweiterung des eigenen Wissens fördert darüber hinaus die individuelle Selbstwirksamkeit. Nicht zuletzt ist ein Chatbot vergleichsweise ökonomisch und bindet bei einer potentiellen Nutzung durch tausende Anwender:innen relativ wenig personelle und finanzielle Ressourcen.

Grenzen des Einsatzes von Chatbots

Wenn der Allgemeine Studierfähigkeitstest zahlreiche Entwicklungspotentiale in mehreren Bereichen aufdeckt, ist die Unterstützungsmöglichkeit des Chatbots begrenzt und eine Anbindung an etablierte Beratungsangebote angebracht. In solchen Fällen ist es erforderlich, sich ein Bild über die individuelle Gesamtsituation der Studieninteressierten bzw. -anfänger:innen zu machen und im persönlichen Gespräch zu eruieren, welche Bereiche sinnvollerweise priorisiert werden sollten. Hierfür ist beispielsweise Wissen über die Anforderungen eines Studiums im Allgemeinen und den spezifischen Fachbereich erforderlich, über das der Chatbot nicht verfügt. Die in solchen Situationen erforderliche individualisierte Beratung kann der Chatbot nicht leisten bzw. ersetzen.

Persönliche Gespräche mit den Studien- und Lernberater:innen der TH Nürnberg zeigten zudem, dass Defizite im Bereich der lernorganisatorischen Fähigkeiten eher selten das zentrale Problem der Ratsuchenden sind. Etwas häufiger finden sich noch fachliche Lücken, doch meistens steckt hinter Schwierigkeiten im Studium ein komplexes Konglomerat aus psychologischen, sozialen, familiären und/oder finanziellen Faktoren. Bei derart vielschichtigen Problemstellungen ist daher ebenfalls eine Weiterleitung an entsprechende Beratungsstellen indiziert, um der individuellen Situation der Ratsuchenden gerecht zu werden. Der OSABot verweist in solchen Situationen direkt an die entsprechenden Ansprechpartner:innen innerhalb der Hochschule.

Darüber hinaus ist der Umfang der Äußerungen durch das Chatbot-Dialogfenster deutlich begrenzt. Versucht der Chatbot, diese Einschränkung durch viele oder sehr lange Beiträgen zu kompensieren, wird der Gesprächsverlauf schnell unübersichtlich und die Nutzerfreundlichkeit sinkt rapide – analog zu langen Messenger-Nachrichten. Anzahl und Länge der Chatbot-Sprechblasen sollten daher möglichst übersichtlich sein, sodass die User:innen nicht erst scrollen müssen, um die Aussagen des Chatbots vollständig zu lesen. Daher wurde die Darstellung der Interventionstechniken, wie oben beschrieben, auf eine Webseite ausgelagert. Der Chatbot leitet die Studierenden über einen Link direkt zur passenden Intervention.

Ausblick: Die Zukunft des OSABots

Bereits jetzt schließt der OSABot eine wichtige Lücke in der Beratungslandschaft: Er kann Studierenden mit (umgrenzten) Problemstellungen im Bereich der lernorganisatorischen Fähigkeiten testdiagnostisch abgesicherte Hilfestellung an die Hand geben. Zudem schlägt er als erster anonymer Ansprechpartner eine Brücke zu den etablierten persönlichen Beratungsstrukturen der TH Nürnberg. Perspektivisch soll die regelmäßige und kontinuierliche Begleitung der Studienanfänger:innen bei Aufbau und Etablierung fachübergreifender Studienkompetenzen weiterentwickelt werden.

KI im Chatbot

Im aktuellen Arbeitsstand des OSABots sind erst wenige KI-Komponenten im Einsatz. Gleichwohl bieten sich viele sinnvolle Erweiterungen an, die in der nächsten Zeit verfolgt werden.

Erweiterung des NLU-Benutzerinterfaces

NLU:

- **intent:** Lernunterstützungen

examples:

- Pomodoro
- Trello

Der OSABot verwendet eine KI-Komponente für das Verstehen natürlicher Spracheingaben (NLU). Die von den Anwender:innen eingegebenen Texte werden hierdurch auf sogenannte Absichten abgebildet; so stehen etwa »Hallo«, »hi« oder »hello« für eine Begrüßung. Erweiternd zum oben skizzierten Dialogverlauf kann dieses Verfahren zukünftig genutzt werden, um Anwender:innen die Möglichkeit zu geben, direkt nach konkreten Lernunterstützungen zu fragen. Durch solche ergänzenden und trainierbaren NLU-Erweiterungen kann das System wesentlich anwender:innenfreundlicher gestaltet und ein schnelles Aufrufen gewünschter Interventionen erzielt werden.

KI-gestütztes Vorschlagen von Interventionstechniken

Die aktuellen Forschungen beinhalten eine Untersuchung der Korrelation von OSA-Testergebnissen und späteren tatsächlichen Studienleistungen, sodass zukünftig auch evidenzbasierte Aussagen über die Erfolgswahrscheinlichkeiten im Studium getroffen werden können. Die konstant hohe Anzahl der Studieninteressierten, die an dieser alljährlichen Veranstaltung teilnehmen, sowie die aus dieser Korrelation mit den tatsächlichen Studienleistungen gewonnenen Informationen machen das Training und den Einsatz einer KI-Komponente zur Auswahl der besten Interventionstechniken möglich. Nutzer:innen des OSABots würden dann nicht mehr nur alle Interventionstechniken einer bestimmten Rubrik angeboten werden, sondern es könnten spezifische Empfehlungen für einzelne, zuerst zu probierende Interventionsmaßnahmen gegeben werden.

KI-gestützte Begleitung bei der Durchführung von Interventionen

Beim Einstudieren einer Lerntechnik sieht der OSABot derzeit wöchentliche Abstände beim Erkundigen nach dem Erfolg der Interventionsmaßnahme vor. Diese Zeitspanne ist an wöchentliche Besuche bei (menschlichen)

Lernunterstützer:innen angelehnt, muss aber natürlich nicht bei einem digitalen System gelten. Hier kann zukünftig eine lernende KI-Komponente zum Einsatz kommen, welche die individuellen Besuchszeiten berücksichtigt und, hieran angelehnt, Vorschläge für Folgetermine macht. Ebenso sind unterschiedliche Unterstützungsprofile denkbar, die sich beispielsweise in der Anzahl der gleichzeitig einzustudierenden Interventionsmaßnahmen und in der Begleitungsintensität unterscheiden. Auch hierbei ist der Einsatz einer moderierenden KI-Komponente sinnvoll.

KI-gestützte Empfehlung zur Passung von Studiengängen

Die aktuellen fachspezifischen Teile der OSAs wurden jeweils für einen Studiengang entworfen und zeigen auf, wie gut die vorhandenen Kompetenzen der Studieninteressierten zu dem jeweiligen Studiengang passen bzw. welche sinnvollen Ergänzungsmaßnahmen (z.B. Brückenkurse) empfehlenswert sind. Derzeit werden aber keine Empfehlungen für einen Studiengang auf Basis der vorhandenen Kompetenzen ausgesprochen.

Mit den Erkenntnissen aus den bisherigen OSA-Modulen und der zuvor angesprochenen Korrelation zum späteren Studienerfolg kann eine KI-Komponente trainiert werden, um auf Basis eines fach-unspezifischen Tests Empfehlungen abzugeben, welcher Studiengang sich voraussichtlich wie gut für eine:n Studieninteressierte:n eignet. Tatsächlich werden durch die KI-Komponente keine

Entscheidungen vorgegeben, doch können Bestätigungen hilfreich sein und alternative Empfehlungen auch zu einer bewussteren Auseinandersetzung mit dem präferierten Studiengang führen.

Fazit und Ausblick

Im Rahmen des vorliegenden Beitrages wurde ein Projekt vorgestellt, das durch einen Chatbots dazu beitragen soll, Studienanfänger:innen bei der Entwicklung ihrer lernorganisatorischen Fähigkeiten individuell zu unterstützen und so Studienabbrüche frühzeitig zu verhindern.

Es wurde deutlich, dass die Entwicklung und Implementierung des Chatsbots den Beginn des Einsatzes von Künstlicher Intelligenz innerhalb des OSA-Projektes darstellt. Ein weiteres Projekt zum Themenbereich Künstliche Intelligenz in der Hochschulbildung steht in den Startlöchern: Im Projekt »HAnS« (Hochschul-Assistenz-System) wird an der TH Nürnberg im Verbund mit acht weiteren Hochschulen ein intelligentes Assistenzsystem entwickelt, das Audio- und Videomaterial unterschiedlicher Fächer in einer Learning-Experience-Plattform sammelt und es mit Hilfe von Spracherkennung für weitere KI-Anwendungen aufbereitet. Das Lehrmaterial wird durchsuchbar gemacht und automatisiert nach vorgegebenen Kriterien, wie Fach, Problemstellung, Sprache, Medium und Erfahrung zusammengestellt. Darauf aufbauend wird ein KI-Tutor entwickelt, der automatisiert Übungsaufgaben und Lernzielkontrollen nach vorgegebenen Mustern und Lehrmaterialien generiert.

Vor dem Hintergrund der bereits gesammelten Erfahrungen und den laufenden Forschungsprojekten steht für die TH Nürnberg fest, dass mit KI eine höchst relevante Technologie für den Bereich der Hochschulbildung zur Verfügung steht.

Anne-Kathrin Helten: Technische Hochschule Nürnberg, Team Online Self-Assessments; anne-kathrin.helten@evhn.de

Prof. Dr. Uwe Wienkop: Technische Hochschule Nürnberg, Professor für Informatik, Akademischer Leiter des Instituts für Angewandte Informatik (IFAI); uwe.wienkop@th-nuernberg.de

Diana Wolff-Grosser: Technische Hochschule Nürnberg, Team Online Self-Assessments; diana.wolff-grosser@th-nuernberg.de

Prof. Dr. Christina Zitzmann: Technische Hochschule Nürnberg, Professorin an der Fakultät Sozialwissenschaften, Vizepräsidentin Bildung; christina.zitzmann@th-nuernberg.de

Literatur

- Apfel, A. (2021). Prototypische Konzeption und Implementierung eines Chatbots zur Unterstützung von Studierenden und Studieninteressenten [Unveröffentlichte Masterarbeit]. Technische Hochschule Nürnberg Georg Simon Ohm, Nürnberg.
- Autorengruppe Bildungsberichterstattung (Hg.) (2020). Bildung in Deutschland 2020. Ein indikatorgestützter Bericht mit einer Analyse zu Bildung in einer digitalisierten Welt. wbv Media.
- Bendig, E., Erb, B., Schulze-Thuesing, L. & Baumeister, H. (2019). Die nächste Generation: Chatbots in der klinischen Psychologie und Psychotherapie zur Förderung mentaler Gesundheit – Ein Scoping-Review. *Verhaltenstherapie*, 29(4), 266–280.
- Bickmore, T. W., Mitchell, S. E., Jack, B. W., Paasche-Orlow, M. K., Pfeifer, L. M. & Odonnell, J. (2010). Response to a Relational Agent by Hospital Patients with Depressive Symptoms. *Interacting with computers*, 22(4), 289–298.
- Chopra, S., Gianforte, R. & Sholar, J. (2016). Meet Percy: The CS 221 Teaching Assistant Chatbot. *ACM Transactions on Graphics*, 1(1), 1–8.
- Clarizia, F., Colace, F., Lombardi, M., Pascale, F. & Santaniello, D. (2018). Chatbot: An Education Support System for Students. In A. Castiglione, F. Pop, M. Ficco & F. Palmieri (Hg.), *Lecture Notes in Computer Science. Cyberspace Safety and Security* (Bd. 11161, S. 291–302). Springer Nature Switzerland.
- Destatis (2020). Schnellmeldungsergebnisse der Hochschulstatistik zu Studierenden und Studienanfänger/-innen. Wiesbaden. Statistisches Bundesamt (Destatis).
- Engelmann, B. (2012). *Therapie-Tools Positive Psychologie: Achtsamkeit, Glück und Mut*. Beltz.
- Engelmann, B. (2014). *Therapie-Tools Resilienz*. Beltz.
- Goel, A. K. & Polepeddi, L. (2016). *Jill Watson: A Virtual Teaching Assistant for Online Education*. Georgia Institute of Technology.
- Gonda, D. E., Luo, J., Wong, Y.-L. & Lei, C.-U. (2018). Evaluation of Developing Educational Chatbots Based on the Seven Principles for Good Teaching. In 2018 IEEE International Conference on Teaching, Assessment, and Learning for Engineering (TALE) (S. 446–453). IEEE.
- Hanning, S. & Chmielewski, F. (2019). *Ganz viel Wert: Selbstwert aktiv aufbauen und festigen*. Beltz.
- Hien, H. T., Cuong, P.-N., Nam, L. N. H., Le Nhung, H. T. K. & Thang, L. D. (2018). Intelligent assistants in higher-education environments: the FIT-EBot, a chatbot for administrative and learning support. In *Proceedings of the Ninth International Symposium on Information and Communication Technology – SoICT 2018* (S. 69–76). ACM Press.

- Hobert, S. & Meyer von Wolff, R. (2019). Say Hello to Your New Automated Tutor – A Structured Literature Review on Pedagogical Conversational Agents. In 14th International Conference on Wirtschaftsinformatik.
- Krengel, M. (2018). Golden Rules: Erfolgreich lernen und arbeiten: alles, was du brauchst. Selbstvertrauen, Motivation, Konzentration, Zeitmanagement, Organisation (8. Auflage). Eazybookz.
- Roderus, S. & Wienkop, U. (2015). Verbesserung der Bestehensquoten durch ein Peer Assessment-Pflichtpraktikum. HDI 2014: Gestalten von Übergängen, 9, 45–60.
- Rost, F. (2017). Lern- und Arbeitstechniken für das Studium (8. Aufl.). Springer VS.
- Schwaetzer, E. (2020). Chatbots und Empfehlungssysteme – KI-Tools im Einsatz. In C. de Witt, F. Rampelt & N. Pinkwart (Hg.), Künstliche Intelligenz in der Hochschulbildung. Whitepaper. (S. 18–20). KI-Campus.
- Smutny, P. & Schreiberova, P. (2020). Chatbots for learning: A review of educational chatbots for the Facebook Messenger. Computers & Education, 151, 103862.
- Technische Hochschule Rosenheim (Hg.). (2020). Studieren mit Erfolg. Eine Broschüre über nachhaltiges Lernen. https://www.th-rosenheim.de/fileadmin/user_upload/Fakultaeten_und_Abteilungen/Studienberatung/Dokumente/Lernbroschuere2020_Einzelseiten_final_09.06.2020.pdf.
- Wengenroth, M. (2017). Therapie-Tools Akzeptanz- und Commitmenttherapie (ACT) (2. Auflage). Beltz.
- Winkler, R. & Söllner, M. (2018). Unleashing the Potential of Chatbots in Education: A State-Of-The-Art Analysis. In Academy of Management Annual Meeting (AOM)., Chicago, USA.
- Wolff-Grosser, D. (2018). Online-Self-Assessments an der Technischen Hochschule Nürnberg – Bilanzierung, Reflexion, Zukunftsvision. Beiträge zur Hochschulforschung, 40, 88–105.

KI-basierte Erstellung individualisierter Mathematikaufgaben für MINT-Fächer

Markus Lange-Hegermann, Tobias Schmohl, Alice Watanabe, Kathrin Schelling, Stefan Heiss und Jessica Rubart

Abstract: Die Tendenz zum selbstgesteuerten Lernen an Hochschulen verstärkt sich durch die COVID-19-Pandemie. Allerdings weisen Studierende insbesondere in der Studieneingangsphase teils erhebliche Defizite im Hinblick auf Selbstlernkompetenzen auf. Daher wird in der Fachdidaktik Mathematik versucht, Wissenslücken ab der ersten Studienwoche unter anderem durch Feedback in Kleingruppen oder durch Korrekturen von Übungsaufgaben zu verhindern. Die trotzdem hohe Zahl an Studienabbrecher:innen in MINT-Fächern steht dem wachsenden Bedarf der Wirtschaft an qualifizierten Absolvent:innen gegenüber. Wir schlagen vor, diese Abbruchquote mittels Methodiken des maschinellen Lernens zu adressieren: KI-Algorithmen erstellen Mathematikaufgaben mit passgenauem, individuellem Schwierigkeitsgrad für Studierende. Dies wirkt – so unsere Hypothese – Überforderungen entgegen und steigert die individuelle Studienmotivation. Sowohl der Aufgabentyp als auch der Schwierigkeitsgrad der Übungen hängen von vielen Parametern ab. Diese werden iterativ, beruhend auf End- oder Zwischenergebnissen zuvor bearbeiteter Aufgaben und Learning-Analytics-Daten, durch Bayes'sche Optimierung angepasst.

The COVID-19 pandemic has reinforced the tendency toward self-directed learning in higher education. During the first semesters, however, many students still lack the self-learning skills they need to thrive in this environment. For this reason, attempts are made in mathematics teaching to prevent gaps in students' knowledge by providing feedback in small groups or by correcting their homework. Still, dropout rates in STEM subjects remain high, strongly contrasting with the economy's growing demand for qualified graduates from these academic fields. We therefore propose to address this issue through an instructional design based on AI algorithms that create mathematical exercises with a degree of difficulty tailored individually to students' knowledge and skills. We hypothesise that this intervention will counteract self-assessed feelings of stress and overload while working on these exercises, instead increasing learners' motivation to study. As both the type of exercise and its difficulty depend on many parameters, they are adjusted iteratively by the AI, based on final or preliminary results of previously processed tasks and Learning Analytics data through Bayesian optimisation.

Keywords: *KI-gestützte Aufgabenerstellung, MINT, Personal Learning Environment, Bayes'sche Optimierung (BO) / AI-supported task creation, Personal Learning Environment, Bayesian optimisation (BO), STEM.*

1 Einleitung

In Zeiten der Massenhochschulbildung sind die Studienabbruchquoten in den MINT-Fächern mit durchschnittlich 34 % an Fachhochschulen sehr hoch. Einzelne Fächer weisen sogar deutlich höhere Quoten auf, wie z.B. die Elektrotechnik mit 41 % (Heublein & Schmelzer, 2018). Ein möglicher Grund dafür könnte eine ungenügende Betreuungssituation im Studium sein, wodurch nicht auf die individuellen Bedürfnisse der Studierenden eingegangen werden kann: Das Verhältnis von Lehrpersonen zu Studierenden lag 2020 bei 1:22,1 an Universitäten und bei 1:18,4 an Fachhochschulen (Statistisches Bundesamt, 2021). So kommen derzeit in Deutschland auf jede Professur durchschnittlich 65 Studierende (Krapp, 2022). Grundsätzlich ist dieser Betreuungsschlüssel keine Überraschung: In der Hochschulbildung dient spätestens seit der Bologna-Reform der direkte Kontakt durch Lehrende eher dazu, Impulse zu setzen, als umfangreiche deklarative Wissensbestände zu vermitteln. Darauf sind auch die didaktischen Instrumente entsprechend ausgerichtet (Stratmann, Preußler & Kerres, 2009). Das Vertiefen und Verfestigen der neuen Wissensbestände obliegt den Studierenden, die Lehrveranstaltungen eigenständig vor- und nachbereiten müssen. Unsere eigenen Arbeiten zur digitalen Hochschulbildung¹ zeigen, dass mathematischer Kompetenzerwerb an Hochschulen prinzipiell großes Potenzial für selbstorganisierte Lernformen bietet. Trotzdem hat sich in Anbetracht mangelnder Selbstlernkompetenz auf Seiten der Studierenden eine didaktische Begleitung als notwendig herausgestellt, welche den nächsten Schritt im Lernprozess passend auswählt (Hanft, 2015).

Mittlerweile setzen fast alle deutschen Hochschulen Learning Management Systeme (LMS) wie ILIAS und Moodle ein. Diese decken neben der Präsentation von Lehrinhalten vier weitere Funktionsbereiche ab: LMS bieten auch Werkzeuge zur Erstellung von Übungen, Evaluationshilfe, administrative Unterstützung und Kommunikationswerkzeug (Bäumer et al., 2004). Aufgrund ihrer behavioristischen Ausrichtung stehen diese Systeme allerdings schon seit geraumer Zeit in der Kritik: Lehrende bestimmen den Lerninhalt, was nur »eingeschränkt den aktuellen Vorstellungen des technologiegestützten Lernens und Lehrens« (Taraghi, 2013) und der Heterogenität der Studierenden entspricht.

1 BMBF-Projekte *optes+* (FKZ 01PL17012) und *Praxis OWL* (FKZ 01PL17048 und 01PL17012B), MKW-NRW-Projekt *Künstliche Intelligenz in der Hochschullehre* (FKZ 224-1.80.01.05).

Dieser Heterogenität kann die Hochschulbildung durch (innere) Differenzierung innerhalb heterogener Gruppen von Lernenden Rechnung tragen, indem das Lernmaterial und die Unterstützung an die Studierenden angepasst werden. Die dafür erforderliche Einstufung des aktuellen Lernstands kann entweder von den Lehrenden oder – in Form der sogenannten Selbstdifferenzierung (Leuders & Prediger, 2012) – von den Studierenden vorgenommen werden. Da die Selbstdifferenzierung es den Lernenden ermöglicht, selbst den Schwierigkeitsgrad zu bestimmen, ist diese Form der Differenzierung in höheren Semestern zu bevorzugen – dann, wenn die Studierenden bereits über eine solide Wissensgrundlage verfügen, auf der sie in Übungen aufbauen können. In früheren Semestern führt Selbstdifferenzierung jedoch oftmals zu Prokrastination (Schmohl, 2019), weshalb in dieser Phase des Studiums eine Binnendifferenzierung durch Außenstehende zu bevorzugen ist.

Aufgrund der hohen Anzahl der Studierenden in Mathematikveranstaltungen des ersten Studienjahres ist eine *geschlossene Differenzierung*, bei der das Lernangebot durch die Lehrkraft individuell angepasst wird, auch in Kleingruppen schwer zu erreichen. Diese Gemengelage macht eine datenbasierte, automatisierte Differenzierung interessant. Anstatt Aufgaben lediglich randomisiert zu parametrisieren wie z.B. der KI-gestützte Aufgabengenerator auf aufgabomat.de, der zufällige Übungsaufgaben für Physik und Mathematik generiert, wie Studierende sie etwa in natur- oder ingenieurwissenschaftlichen Fächern bearbeiten, könnte ein KI-basiertes System den Studierenden auch individuell auf sie zugeschnittene Übungsangebote eröffnen. Der dafür erforderliche Grad an Differenzierung zwischen den Lernständen setzt jedoch zunächst eine Annäherung von LMS an Personal Learning Environments (PLE) voraus.

Künstliche Intelligenz, insbesondere maschinelles Lernen (ML), ist dank tiefer neuronaler Netze in vielen Anwendungen – etwa in der Bilderkennung und Sprachverarbeitung – längst unverzichtbar. Für Vorhersagen, die auf geringen Datenmengen (5–1.000 Datenpunkte, typisch im Umgang mit Menschen) beruhen, sind Gaußprozessmodelle (GP) Stand der Technik (Williams & Rasmussen, 2006). Zur Optimierung von Parametern bei geringen Datenmengen wird hingegen typischerweise die Bayes'sche Optimierung (BO) verwendet (Shahriari et al., 2015). BO erfasst iterativ mehr Daten für Parameterwahlen, bei denen eine GP-Modellvorhersage ein vorteilhaftes Ergebnis verspricht oder eine große GP-Modellunsicherheit eine weitere Exploration nahelegt. GP-Modelle werden zwar bereits in der Hochschuldidaktik angewendet (Kapoor et al., 2007; Paassen et al., 2015; Chaouachi et al., 2015), kommen bislang aber noch nicht für das Erstellen von Aufgaben oder im Rahmen von BO zum Einsatz.

In diesem Beitrag schlagen wir daher ein Konzept vor, das GP nutzt, um die Schwierigkeit von Mathematikaufgaben automatisch mit BO an das Lernniveau einzelner Studierender anzupassen und dadurch die Lernprozesse zu unterstützen. So wird eine Differenzierung der Studierenden bis hin zur individuellen Förderung

möglich. Unser Konzept adressiert dabei ganz konkret die MINT-Studienabbrüche aufgrund von Problemen in der Mathematik. Oft stellen Lehrende den Studierenden wöchentlich nur wenige und nicht differenziert ausgewählte Übungsaufgaben zur Verfügung. Das damit einhergehende nicht-differenzierte Niveau der Aufgaben hat in vielen Fällen Überforderung (oder seltener: Langeweile) zur Folge, wodurch die Verweildauer der Studierenden bei den Aufgaben zu kurz für einen hinreichenden Lernerfolg ist. Erschwerend kommt außerdem hinzu, dass es den Lernenden vor allem in den ersten Studiensemestern häufig an den Selbstorganisations-Kompetenzen fehlt, die erforderlich wären, um weiteres, an ihren individuellen Kenntnisstand angepasstes Lernmaterial zu einzuholen. Selbst wenn die Hochschule unterstützende Maßnahmen wie etwa Mentoring anbietet (Schmohl, 2019), nutzen viele Studierende diese Angebote nicht in ausreichendem Umfang, um ihren langfristigen Lernerfolg zu sichern. Infolgedessen werden in den MINT-Fächern viele Studierende in einer schnell voranschreitenden Vorlesung aufgrund mangelnder Übung und Wiederholung abgehängt. Die so entstehenden Wissenslücken können zu anhaltender Überforderung, zu Frustration und schlimmstenfalls sogar zum Abbruch des Studiums führen.

2 Konzept

Im Folgenden wird das technische Konzept für die KI-basierte Erstellung individualisierter Mathematikaufgaben für MINT-Fächer erläutert. Dabei wird zum einen auf die Umsetzung der verschiedenen Aufgabentypen eingegangen und zum anderen der damit in Verbindung stehende Einsatz von KI und LA umrissen.

2.1 Aufgaben

Viele Aufgabentypen der (Hoch-)Schulmathematik lassen sich so parametrisieren, dass unbegrenzt viele Aufgabenvarianten für jeden Schwierigkeitsgrad generiert werden können. Ein Beispiel für einen solchen Aufgabentyp ist die Bestimmung der komplexen Nullstellen eines Polynoms $p(x)$ der Form

$$p(x) = \left((x^{kl} - a)^2 - b\right) \cdot (x^k - c_1) \cdot \dots \cdot (x^k - c_m) \cdot \left(x^k - \frac{d_1}{e_1}\right) \cdot \dots \cdot \left(x^k - \frac{d_n}{e_n}\right)$$

mit $a, b \in \mathbb{R}$, $k, l > 0$, $m, n \geq 0$, und $c_i, d_i, e_i \in \mathbb{Z}$ mit $e_i > 0$. Das Polynom $p(x)$ kann dabei in faktorisierte Form konstruiert werden, um die Lösbarkeit sicherzustellen. Den Studierenden, die diese Aufgabe zu Übungszwecken lösen sollen, wird es jedoch (teil-)ausmultipliziert angegeben. Folgende Parameter bei solch einem Polynom verändern Aspekte der Aufgabe, wodurch der Schwierigkeitsgrad angepasst werden kann:

1. Grad $k > 0$ des Monoms x^k , welches initial substituiert werden kann
2. Anzahl $m \geq 0$ der ganzzahligen Nullstellen für x^k
3. Anzahl $m' \leq m$ der ganzzahligen Nullstellen für x^k , welche nicht ausfaktoriert werden
4. Anzahl $n \geq 0$ der zusätzlichen rationalen Nullstellen für x^k
5. Anzahl $n' \leq n$ der zusätzlichen rationalen Nullstellen für x^k , welche nicht ausfaktoriert werden
6. Vorhandensein eines quadratischen Faktors $(x^{kl} - a)^2 - b$ ohne Nullstellen über $\mathbb{Q}$
7. Bei einem quadratischen Faktor in (6) steuert das Vorzeichen der Diskriminante b das Vorhandensein von komplexen, nicht-reellen Nullstellen
8. Grad $l > 0$ des Monoms x^l , welches im quadratischen Faktor substituiert werden kann

Darüber hinaus kann die Schwierigkeit einer Übung auch durch die sprachliche Komplexität und den Grad der Formalisierung der Aufgabenstellung angepasst werden. Beispielsweise kann statt der Nullstellen auch die Faktorisierung des Polynoms über den rationalen, reellen oder komplexen Zahlen gefordert werden. Falls in einer Lehrveranstaltung nicht alle Aspekte behandelt werden oder der Fokus der Übung auf einem bestimmten Aspekt liegen soll, können die jeweiligen Parameter auf feste Werte gesetzt werden.

Ähnliche Übungen sind für alle typischen Rechenaufgaben in der Hochschulmathematik möglich. Zudem lassen sich viele weitere Aufgabentypen in mathematisch ausgerichteten Lehrveranstaltungen anderer Fächer analog dazu aufarbeiten und parametrieren.

2.2 KI zur Aufgabenerstellung

Wir schlagen vor, die Parametrisierbarkeit von Mathematikaufgaben zu nutzen, um mittels KI individuelle Aufgaben zu erstellen, die individuell an den Lernstand der Studierenden angepasst werden. Die KI sagt dabei die Wahrscheinlichkeit vorher, mit der einzelne Studierenden eine Aufgabe richtig lösen werden. So können die Studierenden sich zu Beginn des Lernprozesses mit leichten Aufgaben an die Inhalte herantasten und das Niveau je nach Lerngeschwindigkeit bzw. Lösungsgrad der Aufgaben langsamer oder schneller steigern. Indem sie den kontinuierlichen Anstieg des Schwierigkeitsgrades an das persönliche Lerntempo der einzelnen Studierenden anpasst, verringert die digitale Differenzierung das Risiko der Demotivation und erhöht zugleich die Verweildauer. Darüber hinaus erhalten die Lernenden zeitnah Feedback, da die Aufgaben automatisiert korrigiert werden – und da die KI in diesem Korrekturprozess eventuelle Lücken im Wissen der Studierenden automatisch erkennt, kann sie weitere Aufgaben anbieten, um ebendiese Lücken ge-

zielt zu schließen. Das Niveau wird dabei automatisch in Richtung Wiederholungen justiert, wann immer neue Aspekte einer Aufgabe Studierenden aktuell zu schwer erscheinen. Das Ziel sind Aufgaben, welche mit einer Wahrscheinlichkeit σ richtig beantwortet werden. Der Parameter σ soll hierfür nach didaktischen Gesichtspunkten wie der Motivation und dem langfristigen Lernerfolg empirisch gewählt werden. Wir gehen von einem geeigneten Wert von $\sigma \approx 80\%$ aus, um motivationalen Aspekten des Studiums Rechnung zu tragen.

Die für dieses Konzept zentrale Wahrscheinlichkeit, mit der Studierende eine Aufgabe richtig lösen werden, sagt dabei ein GP für Klassifikationen vorher. Die probabilistische Natur von GPs macht sie auch bei wenigen Daten robust, da zuverlässig Modellunsicherheiten der Vorhersagen angegeben werden können. Im Modelltraining werden nur wenige Hyperparameter bestimmt, und diese Hyperparameter sind sogar interpretierbar. Diese Modellklasse liefert auch bei geringen Datenmengen zuverlässige Vorhersagen. Das Dazulernen und Vergessen der Studierenden – ein nicht zu vernachlässigender Faktor für die Erstellung personalisierter Übungsaufgaben, die stets dem *aktuellen* Lernstand entsprechen sollen – wird durch eine höhere Unsicherheit richtiger Daten bei zeitlich länger zurückliegenden Aufgaben modelliert. Darauf aufbauend nimmt die BO die Wahl der Parameter vor: Sie wählt unter den Aufgaben mit einer definierten Wahrscheinlichkeit der richtigen Bearbeitung diejenige aus, welche den bisher bearbeiteten Aufgaben am wenigsten ähnelt.

Die Motivation der Studierenden soll bereits beim Einstieg in neue Themenkomplexe hochgehalten werden, damit sie die Bearbeitung der Aufgaben nicht zu schnell abbrechen, sondern sich solide Grundkenntnisse aneignen, auf die sie im weiteren Verlauf ihres Studiums aufbauen können. Aus diesem Grund sollten bereits die allerersten Übungen, die Studierenden zu einem neuen Thema bearbeiten, einen geeigneten Schwierigkeitsgrad haben. Dies ist allerdings nur bei geeigneter Qualität der GP-Modelle möglich, die auch ohne Datenpunkte bei einem Aufgabentyp ein geeignetes a-priori Modell liefern können. Da beim ersten Bearbeiten einer Aufgabe eines Aufgabentyps A durch eine*n Studierende*n S noch keine Daten vorliegen, müssen die Informationen aus anderen Quellen bezogen werden. Wir schlagen daher vor, die Bearbeitung des Aufgabentyps A durch andere Studierende S' als Datengrundlage heranzuziehen. Die Leistungsfähigkeit der Studierenden S und S' vergleichen wir anhand von Daten über die beiden Studierenden, die während der Bearbeitung anderer Aufgabentypen A' erhoben wurden. Es werden also Studierende mit Kommiliton:innen verglichen, deren Leistungsfähigkeit ähnlich ist – damit der Startpunkt im Lernprozess eben nicht auf einem zu hohen Niveau ansetzt. Perspektivisch können zur Verbesserung der Modelle nicht nur die Daten von Studierenden verschiedener Jahrgänge, Kurse oder Fachbereiche erhoben werden: Auch verschiedene Hochschulen könnten Datensätze austauschen, um eine solide Datengrundlage für die Ermittlung der Wissensstände zu schaffen.

2.3 Learning Analytics

Da potenziell viele weitere Studierende S' eine Aufgabe bereits bearbeitet haben, schlagen wir vor, den Vergleich zwischen den Studierenden nach Ähnlichkeit zu gewichten. Studierende sollen dafür z.B. mit Hilfe von Learning-Analytics-Daten verglichen werden.

LA-Ansätze verfolgen das Ziel, Lernprozesse datenbasiert besser zu verstehen und durch Vorhersagen, Eingreifen, Empfehlungen, Reflexion und Iteration (Grandl et al., 2017) zu unterstützen. Der Fokus dieser Unterstützung liegt zumeist auf der »Identifizierung und Unterstützung von Risikostudierenden« (Büching et al., 2019), da die gezielte Förderung dieser Studierenden besonders gut dazu geeignet ist, die Absolvent:innenzahlen an Hochschulen insgesamt signifikant zu erhöhen. Darüber hinaus werden aber auch personalisierte Lernumgebungen und lernsynchrones Feedback an die Studierenden mithilfe von LA realisiert (Gašević et al., 2015). Das Projekt LeAP (Schumacher et al., 2018) sammelt und speichert beispielsweise Studierendendaten aus verschiedenen Systemen, wertet diese aus und stellt den Studierenden über ein Dashboard eine Übersicht über ihren individuellen Lernstatus zur Verfügung.

Die Daten, mit denen LA-Anwendungen arbeiten, stehen im typischen Hochschulbetrieb in großen Mengen zur Verfügung. So werden beispielsweise im Fachbereich Elektrotechnik und Technische Informatik der TH OWL viele Funktionalitäten des LMS ILIAS in den Lehrveranstaltungen Mathematik 1–4 von jährlich 200–250 Studierenden der Professoren Heiss und Lange-Hegermann genutzt. Über das LMS werden dabei zum einen Materialien (u.a. Skripte, Übungsaufgaben, Vorlesungsfolien mit Notizen und Literaturlisten) bereitgestellt. Zum anderen wird aber auch der Übungsgruppenbetrieb in elf Präsenzgruppen in ILIAS durch *Gruppen* mit jeweils eigenem *Forum* abgebildet. Als während der COVID-19-Pandemie der Präsenzbetrieb ausgesetzt war, wurde in den Übungsgruppen (neben einem Audiokanal) auch ILIAS-*Etherpads* als virtuelle Tafel sowohl zur gemeinschaftlichen als auch zur parallelen Bearbeitung von Aufgaben genutzt. Zudem können die Studierenden wöchentlich Lösungen zu Übungsaufgaben (ILIAS-*Übung*) einreichen. Diese werden von studentischen Tutor:innen korrigiert und kommentiert. Ergänzend werden interaktive Online-Tests (ILIAS-*Test*) bereitgestellt, die sowohl statische als auch sich variabel ändernde Aufgaben enthalten (Nutzung zufälliger Parameterwerte in *Formelfragen* und *STACK-Fragen*).

In einem solchen, von einem LMS wie ILIAS geprägten Lehr-Lernkontext ist eine konkrete Umsetzung von LA in Form eines Software-Plugins möglich. So können neben unterschiedlichen ILIAS-Objekten wie z.B. Tests, Etherpads oder Umfragen auch als Datenquellen genutzt werden, die außerhalb des eigentlichen ILIAS-Systems liegen (z.B. Chat-Protokolle aus Videokonferenzsystemen). Softwaretechnisch müssen hierfür sowohl strukturierte als auch semistrukturierte Daten berücksich-

tigt werden. So wird etwa eine Ergänzung des ILIAS-Backends um eine Big-Datentaugliche NoSQL-Datenbank – wie z.B. eine dokumentenorientierte Datenbank, die auch die notwendigen textbasierten Massendaten speichern kann – notwendig (Davoudian et al., 2018). Diese Daten können dann über Text-Mining-Ansätze ausgewertet und semantisch angereichert werden.

Im Fall des in diesem Artikel beschriebenen Konzepts für ein adaptives Übungsangebot würde die Datenbank dann über einen sogenannten Extract-Transform-Load-Prozess automatisch die relevanten Daten integrieren und aufbereiten, um die KI-basierte Anpassung der Mathematikaufgaben vorzubereiten. So können Text-Mining-Ansätze beispielsweise die Auswertung von textbasierten Daten unterstützen und diese etwa durch Part-of-Speech-Tagging, Term-Frequency-Inverse-Document-Frequency-Gewichtung und Lexika semantisch anreichern (Zangerle et al., 2016). Dasselbe Vorgehen ist natürlich abstrakt unabhängig von der konkret eingesetzten Software möglich und funktioniert in einer Moodle-Umgebung ebenso gut wie für ILIAS.

3 Diskussion

Das hier vorgestellte Konzept zielt darauf ab, durch KI-basierte, individuell an die Wissensstände der Studierenden angepasste Aufgaben ein innovatives Lernangebot zu schaffen, das sowohl das hochschuldidaktische Ziel der Berücksichtigung von studentischer Diversität (Wissenschaftsrat, 2017) als auch die damit einhergehende Differenzierung des Lerntempos und der zu bearbeitenden Aufgaben fokussiert. Wir erhoffen uns von der Umsetzung des Konzeptes eine Form bedarfsgerechten Lernwegbegleitung für Studierende, die einen wesentlichen Beitrag zur Verringerung der Abbruchquote in den MINT-Fächern leisten kann.

Allerdings bringt das KI- und LA-gestützte Lernen und Lehren auch einige grundsätzliche Schwierigkeiten mit sich. Die Hauptprobleme bzgl. des Einsatzes von KI und LA im Bildungsbereich lassen sich auf Bedenken im Datenmanagement und ethische Fragen zurückführen. Insbesondere ist derzeit noch nicht klar, wie die Datenqualität, der Datenschutz und das damit in Verbindung stehende Recht auf Privatsphäre in diesem Zusammenhang erfolgreich umgesetzt werden können. In der ethischen Diskussion über KI in der Hochschullehre wird außerdem auf die Unverzichtbarkeit der menschlichen Bewertung im Hochschulkontext sowie auf die Gefahren von Diskriminierung, Verantwortungslosigkeit und mangelnder Transparenz verwiesen (Büching et al. 2019, Kieslich et al. 2019).

Um den Datenschutz in unserem Vorhaben zu garantieren, haben wir uns dafür entschieden, vor allem mit LMS-Plattformen zu arbeiten. Typischerweise werden LMS-Systeme von den jeweiligen Hochschulen selbst betrieben und bedarfsgerecht ausgebaut. Dadurch kann DSGVO-konformer und transparenter Datenschutz ge-

währleistet werden. Allerdings gilt es dabei auch zu beachten, wer Zugriff auf welche Daten erhält. Außerdem müssen die Studierenden selbst über die Verwendung ihrer Daten bestimmen können – was wiederum voraussetzt, dass die Teilnahme an den individualisierten Aufgaben freiwillig ist. Weiter stellen wir uns zur Absicherung des Datenschutzes einen vollständig anonymen Modus vor, welcher ohne Learning-Analytics-Daten auskommt, infolgedessen aber natürlich auch weniger passgenau auf die individuellen Lernstände zugeschnittene Übungsaufgaben bereitstellen kann.

Die Gefahr der strukturellen Diskriminierung ist zudem in jedem technologiegestützten Lehr-Lernkontext zu thematisieren – denn auch KI- und LA-Anwendungen sind davor nicht gefeit. Für das vorliegenden Konzept wird eine bewusste (positive) Diskriminierung der Studierenden nach dem Lernstand vorgenommen, die nötig ist, um individuelle Lücken im Vorwissen durch passgenaue und genügend verfügbare Aufgaben zu schließen. Weitere unterbewusste Diskriminierungen sollen jedoch einerseits durch zusätzliche Kontrollen durch die Lehrenden verhindert werden. Andererseits werden durch den Algorithmus bedingte Diskriminierungen durch Beschränkung der Datenauswahl auf relevante Merkmale vermieden. Dazu werden alle verwendeten Merkmale empirisch auf potenzielle Diskriminierung untersucht und die diskriminierenden Merkmale entweder entfernt oder herausgerechnet (Kehrenberg et al., 2018). So kann die unerwünschte Nutzung von Korrelationen in den Learning-Analytics-Daten ausgeschlossen werden. Über eine solche Beschränkung ließe sich beispielsweise verhindern, dass auf Basis von Daten aus vergangenen Jahrgängen Rückschlüsse über das Leistungsverhalten bestimmter Kohorten gezogen werden. Zeigten etwa im letzten Jahrgang die weiblichen Studierenden einer Vertiefungsrichtung sehr positive Lernleistungen, dann sollten Studentinnen im aktuellen Jahrgang nicht – basierend auf der Korrelation, dass sie Studentinnen derselben Vertiefungsrichtung sind – direkt schwerere Aufgaben erhalten.

Durch bildungswissenschaftliche Begleitforschung sollen sowohl die Chancen, Stärken als auch die Gefahren und Probleme des KI- und LA-gestützten Lernen und Lehren erforscht werden. Folgende Fragen stellen dabei im Mittelpunkt:

1. Welche didaktischen Aspekte/Konzepte müssen bei der Entwicklung der KI-gestützten Aufgaben berücksichtigt werden?
2. Inwiefern können der Lernerfolg und die Motivation der Studierenden durch die KI-basierte Erstellung individualisierter Mathematikaufgaben für MINT-Fächer gesteigert werden?
3. Welche Haltung nehmen die Studierenden in Bezug zum KI- und LA-gestützten Lernen ein?
4. Welche Parameter sind elementar, um die Akzeptanz des KI- und LA-Einsatzes in Lehr-Lern-Kontexten zu fördern?

Hierbei ist uns vor allem eine kritische Auseinandersetzung mit der Verlagerung des Lernens weg von menschlicher Interaktion hin zu automatisierten Aufgabenerstellung und automatischer Korrektur wichtig. Das Ziel eines Studiums besteht nicht ausschließlich in der Aneignung von Fachwissen, sondern umfasst unter anderem auch das Erlernen einer selbstständigen und eigenverantwortlichen Arbeitsweise sowie eine Verbesserung der Fähigkeit zur zwischenmenschlichen Kommunikation. Während sich ein KI-gestützter Ansatz sich gerade in lernintensiven Veranstaltungen wie der Mathematik in den ersten Semestern gut für die Aneignung von Fachwissen eignet, muss trotzdem kritisch untersucht werden, inwieweit und in welchem Format sich dieser Ansatz auch auf andere Lehr-Lernkontexte übertragen lässt.

Auch von der fachdidaktischen Seite stellen sich aktuell noch viele Fragen. Z.B. wird zwar eine Sammlung von hochflexiblen Mathematikaufgaben angestrebt, doch ist bislang unklar, ob sich überhaupt alle relevante Aufgabentypen in die gewünschte Form bringen lassen. Insbesondere Beweis- oder Textaufgaben sind schwer zu individualisieren und auch das Stellen von Aufgaben mit »glatten Zahlen« in Ergebnissen und Zwischenergebnissen ist nicht immer zielführend. Außerdem ist zu untersuchen, ob eine KI darin trainiert werden kann, zu erkennen, welche Fehler beim Bearbeiten der Aufgabe gemacht wurden, z.B. durch Eingabe von Zwischenergebnissen. Schließlich wäre die Möglichkeit einer Übertragung von der Mathematik auf andere MINT-Fächer eine offene Frage.

Prof. Dr. Markus Lange-Hegermann: Technische Hochschule Ostwestfalen-Lippe, Professor für Mathematik und Datenwissenschaften; markus.lange-hegermann@th-owl.de

Prof. Dr. Tobias Schmohl: Technische Hochschule Ostwestfalen-Lippe, Professor für Hochschul- und Fachdidaktik Medien; tobias.schmohl@th-owl.de

Alice Watanabe: Technische Hochschule Ostwestfalen-Lippe, Forschungsprojekt HANs; alice.watanabe@th-owl.de & Hochschule für Angewandte Wissenschaften Hamburg, Fachbereich VWL; alice.watanabe@haw-hamburg.de

Kathrin Schelling: Technische Hochschule Ostwestfalen-Lippe, Forschungsprojekt HANs; kathrin.schelling@th-owl.de

Prof. Dr. Stefan Heiss: Technische Hochschule Ostwestfalen-Lippe, Fachbereich Elektrotechnik und Technische Informatik, Fachgebiet Mathematik und IT-Sicherheit; stefan.heiss@th-owl.de

Prof. Dr. Jessica Rubart: Technische Hochschule Ostwestfalen-Lippe, Fachgebiet Betriebliche Informationssysteme; jessica.rubart@th-owl.de

Literatur

- Bäumer, M., Malys, B., & Wosko, M. (2004). *Lernplattformen für den universitären Einsatz*. eLearning an der Hochschule, 121–140.
- Büching, C., Mah, D. K., Otto, S., Paulicke, P., & Hartman, E. A. (2019). Learning Analytics an Hochschulen. In *Künstliche Intelligenz* (pp. 142–160). Springer Vieweg, Berlin, Heidelberg.
- Chaouachi, M., Jraidi, I., & Frasson, C. (2015, June). MENTOR: a physiologically controlled tutoring system. In *International Conference on User Modeling, Adaptation, and Personalization* (pp. 56–67). Springer, Cham.
- Davoudian, A., Chen, L., & Liu, M. (2018). A survey on NoSQL stores. *ACM Computing Surveys (CSUR)*, 51(2), 1–43.
- Dorloff, A. (2019, February 11). Künstliche Intelligenz als Staatsziel. *Deutschlandfunk*
- Endt, C. (2014, April 10) Eine Software verteilt Prüfungsnoten. *Zeit online*
- Gašević, D., Dawson, S., & Siemens, G. (2015). Let's not forget: Learning analytics are about learning. *TechTrends*, 59(1), 64–71.
- Grandl, M., Taraghi, B., Ebner, M., Leitner, P., & Ebner, M. (2017). Learning Analytics. *Handbuch E-Learning: Expertenwissen aus Wissenschaft und Praxis-Strategien*, 1–16.
- Hanft, A. (2015). Heterogene Studierende–homogene Studienstrukturen. *Herausforderung Heterogenität beim Übergang in die Hochschule*, 13–28.
- Heublein, U., Schmelzer, R. (2018). Die Entwicklung der Studienabbruchquoten an den deutschen Hochschulen. Berechnungen auf Basis des Absolventenjahrgangs 2016. DZHW-Projektbericht.
- Kapoor, A., Burleson, W., & Picard, R. W. (2007). Automatic prediction of frustration. *International journal of human-computer studies*, 65(8), 724–736.
- Kehrenberg, T., Chen, Z., & Quadrianto, N. (2018). Tuning Fairness by Marginalizing Latent Target Labels. *arXiv preprint arXiv:1810.05598*.
- Krapp, C. (2022). Uni-Barometer. Professoren betreuen im Schnitt 65 Studierende. *Forschung & Lehre* 1(22).
- Leuders, T., & Prediger, S. (2012). »Differenziert Differenzieren« – Mit Heterogenität in verschiedenen Phasen des Mathematikunterrichts umgehen. *Differenzierung im mathematisch-naturwissenschaftlichen Unterricht – Implikationen für Theorie und Praxis*, 35–66.
- Paassen, B., Göpfert, C., & Hammer, B. (2016). Gaussian process prediction for time series of structured data. In *Proceedings of the ESANN, 24th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*.
- Shahriari, B., Swersky, K., Wang, Z., Adams, R. P., & De Freitas, N. (2015). Taking the human out of the loop: A review of Bayesian optimization. *Proceedings of the IEEE*, 104(1), 148–175.

- Schmohl, T. (2019). Selbstgesteuertes Lernen. Explorative hochschuldidaktische Formate mit Modellcharakter für vier akademische Statusgruppen. In *Selbstorganisiertes Lernen an Hochschulen. Strategien, Formate und Methoden* (pp. 19–40).
- Schumacher, C., Klasen, D., & Ifenthaler, D. (2018). Evidence-based implementation of a learning analytics dashboard into an existing learning management system.
- Shirouzou, H. (2018, October 11). How AI is helping to transform education in Japan. *IBM Client Success Field Notes*
- Statistisches Bundesamt. (2021). Betreuungsrelation (ohne Humanmedizin) an Universitäten und Fachhochschulen in Deutschland im Jahr 2020 nach Bundesländern. <https://de.statista.com/statistik/daten/studie/197877/>.
- Stratmann, J., Preussler, A. & Kerres, M. (2009). Lernerfolg und Kompetenz: Didaktische Potenziale der Portfolio-Methode im Hochschulstudium. *ZFHE (Zeitschrift für Hochschulentwicklung)*, 4(1).
- Taraghi, B., Ebner, M., & Schön, S. (2013). *Systeme im Einsatz. WBT, LMS, E-Portfolio-Systeme, PLE und andere.*
- Technavio (2018). Artificial Intelligence Market in the US Education Sector 2018–2022.
- Williams, C. K., & Rasmussen, C. E. (2006). *Gaussian processes for machine learning* (Vol. 2, No. 3, p. 4). Cambridge, MA: MIT press.
- Zangerle, E., Illecker, M., & Specht, G. (2016). SentiStorm: Echtzeit-Stimmungserkennung von Tweets. *HMD Praxis der Wirtschaftsinformatik*, 53(4), 514–529.

Das Motivationspotenzial von Spielen erschließen

Künstliche Intelligenz als Lotse im Prozess der kreativen Gestaltung von motivierenden Lerngelegenheiten

Thomas Bröker, Thomas Voit und Benjamin Zinger

Abstract: Spiele bergen ein großes Motivationspotenzial. Sie zeigen, dass Menschen sich nicht nur freiwillig, sondern begeistert mit schwierigen Problemen auseinandersetzen können. Übertragen auf den Bildungskontext könnte dieses Potenzial auch das Lernen beflügeln. Der große Möglichkeitsraum des Spieldesigns überfordert Lehrende und Lernende jedoch oftmals, wenn sie ihn auf Lerngelegenheiten übertragen wollen. Künstliche Intelligenz (KI) kann einen solchen kreativen Gestaltungsprozess unterstützen. Als Teil eines methodischen Vorgehens kann sie den schwer überschaubaren Fundus spielerischer Elemente zugänglich machen. Auch ohne Spieldesignerfahrung können Lehrende und Lernende so das Potenzial von Spielen nutzen, um motivierende Lerngelegenheiten zu gestalten. Dafür haben wir in einen bereits erprobten, kreativen Arbeitsprozess, mit dem Nutzer:innen die Motivation in spielfremden Kontexten analysieren und weiterentwickeln können, eine KI eingebunden und Studierende damit in einem Seminar arbeiten lassen. Als Auftragnehmer hatten sie die Aufgabe Lerngelegenheiten motivierender zu gestalten. Anhand von Fokusgruppeninterviews haben wir explorativ untersucht, ob und wie die KI ihre Kreativität unterstützen konnte.

Games hold great motivational potential. They show that people can deal with difficult problems not only voluntarily but also enthusiastically. This potential could be used to inspire learning in educational contexts. However, the large number of possible structures provided by game design tends to overwhelm both teachers and learners when they try to transfer them to the context of learning. Artificial intelligence (AI) can support this creative design process. As part of a methodical approach, it can make the pool of game elements accessible. Even without any prior experience in game design, teachers, and learners can thus use the potential of games to create motivating learning opportunities. In a seminar with students, we integrated an AI into a tested creative workflow, where users analyze and develop motivation in non-game contexts. Using focus group interviews, we explored whether and how it could support the users' creativity. The results show that the students used the AI to validate their ideas, and that it was predominantly perceived as supporting their creativity.

Keywords: *Gamification, künstliche Intelligenz, Kreativität, Assistenz / Gamification, artificial intelligence, creativity, assistance.*

1 Einleitung

Die uralte kulturelle Leistung des Menschen, Geschichten zu erzählen, versetzt die Zuhörenden in eine passive – konsumierende – Rolle. Sie folgen einem vorgegebenen Verlauf. Spiele hingegen zeigen hier ihr motivierendes Potenzial, indem sie die Beteiligten zu einem Teil der Geschichte machen und ihnen erlauben, deren Verlauf aktiv zu beeinflussen. Wie motivierend sie auf Menschen wirken, zeigt die Geschwindigkeit, mit der die Spieleindustrie seit den 2000er-Jahren zur Filmbranche aufgeholt und sie schließlich überholt hat. Auch in der Bildungsforschung hat sich die Perspektive von den konsumierenden zu den aktiven, Wissen konstruierenden Lernenden verändert. Und so haben auch Spiele mit ihrem Motivationspotenzial das Interesse von Lehrenden und Forschenden geweckt. Wie vorbildlich Spiele Motivation und Lernen verbinden können, zeigen Ergebnisse aus der Spieleforschung (u.a. Squire 2005, Gee 2007, Steinkuehler & Duncan 2008, Mayo 2009, Bröker 2016). Damit Lernprozesse mithilfe von Spielprinzipien motivierend gestaltet werden können, muss das zugrundeliegende Wissen darüber, wie Spiele motivieren, allerdings erst für den Kontext des Lernens erschlossen werden. Dafür greifen wir auf die Ergebnisse des Projekts »Empirische Analyse motivierender Spielelemente« (EMPAMOS) zurück. Die Ergebnisse des Projekts, das methodische Vorgehen und die damit verbundene Künstliche Intelligenz (KI) haben wir in einer Lehrveranstaltung eingesetzt, in der Studierende verschiedene Lerngelegenheiten motivierender gestalten sollten. Anhand von Fokusgruppeninterviews haben wir den Nutzen der KI in diesem kreativen Arbeitsprozess untersucht.

Abschnitt 2 gibt einen Überblick über die Problemstellung und unseren Lösungsansatz. In Abschnitt 3 beschreiben wir die Datengrundlage von EMPAMOS, in Abschnitt 4 das damit verbundene methodische Vorgehen und in Abschnitt 5, wie die KI darin eingebunden ist. In Abschnitt 6 erläutern wir anhand von leitfadengestützten Fokusgruppeninterviews, wie Studierende die Methodik in Verbindung mit der unterstützenden KI einschätzen.

2 Den fehlenden Zugang zum Spieldesign erschließen

Seit vielen Jahren blicken Bildungsforscher:innen und Lehrende hoffnungsvoll auf Spiele. Freiwillig und ohne Zwang setzen sich Spieler:innen intensiv mit den darin gestellten Herausforderungen auseinander und entwickeln Strategien, um sie zu meistern. Das Potenzial von Spielen, Menschen zu motivieren, würden Forscher:in-

nen und Lehrende gerne auf den spielfremden Kontext des Lernens übertragen. Ein spielfremder Kontext ist gegeben, wenn ihm eines oder mehrere Merkmale fehlen, die Huizinga (2009, S. 22) als das Wesen eines Spiels charakterisiert:

Tabelle 1: Wesensmerkmale eines Spiels nach Huizinga (2009, S. 22).

1. Spiel ist freies Handeln ohne Zwang.	6. Spiel hat eine sich wiederholende innere Ordnung.
2. Spiel ist vom gewöhnlichen Leben getrennt.	7. Spiel ist spannend, da das Spielende ungewiss ist.
3. Spiel ist zeitlich und räumlich klar getrennt.	8. Spiel kann Spieler ernsthaft in Beschlag nehmen.
4. Spiel ist keine Lebensnotwendigkeit.	9. Spiel schafft Spielgemeinschaften.
5. Spiel hat eigene Spielregeln.	

Spielerische Erfahrungen, die Menschen motivieren, können allerdings auch in spielfremden Kontexten gefunden oder dort integriert werden (Högberg et al., 2019, S. 620).

Mit der Hoffnung, auch das Lernen motivierender zu gestalten, zog 2011 *Game-based Learning* in die Lehr- und Lerntrends der *Horizon Reports* ein. Ein Trend, der sich in den Folgejahren zunehmend in Richtung *Gamification* veränderte (Kapp 2012, Kapp/Blair/Mesch 2014, Reiners/Wood 2015). Statt Spiele für das Lernen zu entwickeln, erschien es vielversprechender, spielfremde Kontexte mit spielerischen Elementen anzureichern – sie zu gamifizieren. Unter dem Begriff *Gamification* schienen Siegpunkte, Auszeichnungen und Bestenlisten als schnelle und einfache Lösung, um beliebige Situationen motivierender zu gestalten. Das änderte jedoch nichts an der ursprünglichen, nicht motivierenden Situation: Sie kam wieder zum Vorschein, sobald die spielerische Ebene ihre Wirkung verlor. Der Ansatz von *Gamification*, bei dem spielerische Elemente wie eine »Soße« über Situationen gegossen werden, wird daher auch als »chocolate covered broccoli« bezeichnet (Kumar/Herger 2013, S. 12). Aber die Schokolade kann den Brokkoli nur auf den ersten Blick verstecken. Und wenn die Lernenden unter der Schokolade das unliebsame Gemüse entdeckt haben, kann die anfängliche Freude am Spiel in Misstrauen gegenüber spielerischen Elementen umschlagen.

Der Versuch, das motivierende Potenzial von Spielen so auf das Lernen zu übertragen, dass das Spielerische zum festen Bestandteil des Lernprozesses wird, erweist sich als anspruchsvoll. Spielentwickler:innen können ihr implizites Wissen darüber, mit welchen Spielelementen es ihnen gelingt, ein gutes Spiel zu entwi-

ckeln, nur ansatzweise explizieren. Jede taxonomische Liste von Spielelementen bleibt unvollständig, solange sie nur die subjektive Sicht von Spielentwickler:innen widerspiegelt (Schell 2009, S. 130). Das implizite Wissen zu Spielelementen, das die Entwickler:innen durch Erfahrung gewonnen haben, steckt jedoch in den von ihnen gestalteten Spielen. Forschende haben daher ausgehend von den Spielen zahlreiche Design-Elemente identifiziert, die diese charakterisieren und motivierend machen (u.a. Bjork & Holopainen 2005, Gee 2007, Laine & Lindberg 2020). Im Projekt EMPAMOS wurde nicht nur eine umfassende Sammlung dieser Spielelemente empirisch ermittelt. Auch ein methodisches Vorgehen ist Teil der Entwicklung. Damit können diese Elemente zielgerichtet auf spielfremde Kontexte, wie etwa Situationen aus der Arbeitswelt oder in Kultur- und Bildungseinrichtungen übertragen werden. Ziel dieses Vorgehens ist es, die motivierenden Strukturen von Spielen in den jeweiligen Kontext zu integrieren, statt tatsächliche Spiele zu entwickeln.

Da die schiere Zahl der Elemente den Umgang damit schwierig macht, wurde das methodische Vorgehen um eine KI erweitert. Sie soll helfen, die umfangreichen Daten aus der empirischen Spielanalyse zu erschließen und dadurch das implizite Wissen der Spielentwickler:innen in konkrete Design-Vorschläge zu übersetzen.

Wir, als Autoren des vorliegenden Beitrags, greifen auf die Ergebnisse des EMPAMOS-Projekts zurück und setzen es ein, um das motivierende Potenzial von Spielen für das Lernen zu nutzen. Unsere übergeordnete Forschungsfrage lautet daher: Wie können die motivierenden Elemente von Spielen so erschlossen werden, dass Lehrende und Lernende sie kreativ und zielgerichtet für die Gestaltung von Lerngelegenheiten einsetzen können? In einem ersten, explorativen Schritt haben wir hierzu untersucht, wie Studierende die Vorschläge einer KI bewerten, um Lerngelegenheiten motivierender zu gestalten. Wir sind dabei der Frage nachgegangen, wie eine KI den kreativen Prozess unterstützen und fördern kann, bei dem die Nutzer:innen mithilfe von EMPAMOS eine Lerngelegenheit analysieren und weiterentwickeln.

Mit dem Fokus auf Studierende – also die Lernenden – folgen wir dem viel zitierten *shift from teaching to learning* (Berendt 2005), also der Ausrichtung der Lehre an den Lernenden und ihren Lernprozessen. Zudem geht es im Sinne des eigenverantwortlichen Lernens auch darum, Studierende dabei zu unterstützen, ihre eigenen Lernprozesse zu gestalten und sich an der Gestaltung formaler Lerngelegenheiten zu beteiligen.

Wie alle kreativen Prozesse erfordert auch das Entwickeln von Lerngelegenheiten divergentes und konvergentes Denken in und zwischen den beteiligten Domänen. Nutzer:innen bringen ihre jeweiligen fachlichen und überfachlichen Erfahrungen mit, doch die Domäne der Spiele als Ideenpool für motivierende Lerngelegenheiten ist ihnen oftmals unbekannt. Einsteiger:innen sind deshalb häufig überfordert, wenn es darum geht, mit der Vielzahl spielerischer Elemente und dem Viel-

fachen der möglichen Kombinationen umzugehen und diese zielgerichtet in einen Gestaltungsprozess einfließen zu lassen.

Eine KI kann diese kreative Aufgabe nicht übernehmen. Ihr fehlen die impliziten Erfahrungen aus dem jeweiligen Kontext, wie etwa das fachliche Verständnis und Kenntnisse zu Interessen, Gewohnheiten und kognitiven Prozesse der Zielgruppe. Eine KI ist beispielsweise nicht in der Lage, Spielelemente zu identifizieren, die im jeweiligen spielfremden Kontext bereits vorhanden sind, dort aber nur unvollständig und anders als in Spielen üblich implementiert wurden.

Die technischen Möglichkeiten künstlicher Intelligenz erlauben es jedoch, das implizite Wissen von Spielentwickler:innen zu erschließen. Anhand der Vorauswahl der a priori bereits vorhandenen Spielelemente kann eine KI aus der Vielzahl erfolgreicher Kombinationen, Vorschläge für weitere Elemente und Verbindungen generieren. Statt mit dem vollständigen Möglichkeitsraum von Spielen konfrontiert zu werden, können sich die Nutzer:innen auf die Untermenge passender Anschluss-elemente konzentrieren.


3 EMPAMOS – das gesammelte Wissen der Spielentwickler:innen

Das Projekt EMPAMOS (Empirische Analyse motivierender Spielelemente) erfasst das implizite Wissen von Spielentwickler:innen über den Umweg der Spielanalyse. Es identifiziert, welche Elemente sie in Brett- und Gesellschaftsspielen einsetzen und miteinander kombinieren, um dadurch menschliches Handeln und Interaktion zu motivieren. Seit 2016 arbeitet ein Team der Technischen Hochschule Nürnberg und des Deutschen Spielearchivs unter der Leitung von Thomas Voit an diesem Projekt. Die im Rahmen von EMPAMOS durchgeführte Interpretation und Dokumentation der spieltypischen Elemente lehnt sich an die Methodik der Entwurfsmuster von Christopher Alexander in der Architektur an (Alexander/Ishikawa/Silverstein 1977). Jedes Spielelement beschreibt dabei eine praktisch bewährte Designlösung für ein wiederkehrendes Entwurfsproblem (Björk & Holopainen 2005, S. 33). Indem einzelne Elemente eines Spiels gedanklich entfernt und die Folgen dieser Veränderung auf die Motivation betrachtet werden, zeigen sich die Probleme, die ebendiese Elemente lösen. Das Spielelement *Zufall* verhindert beispielsweise, dass der Spielverlauf zu vorhersehbar ist. Außerdem erhält es den Widerspielwert eines Spiels. Alexander bezeichnet solche Probleme in seiner Design-Theorie allgemein als *Misfits*. Misfits sind negative Eigenschaften, die hervortreten, wenn ein Design nur unzureichend an den Kontext und die dort wirksamen Kräfte angepasst ist (Alexander 1964, S. 23).

Spiele werden freiwillig gespielt (Huizinga 2009, S. 22), weil sie die motivationalen Bedürfnisse der Spieler:innen befriedigen (Ryan/Rigby/Przbylski 2006). Misfits in Spielen können also als typische nicht erfüllte motivationale Bedürfnisse

beschrieben werden. Im Anschluss an die Selbstbestimmungstheorie von Deci & Ryan (1985) und dem erweiterten kognitiven Modell (Rheinberg 2006, S. 341) lassen sich diese Bedürfnisse in vier Kategorien einteilen (Sailer 2017, S. 113–125): Autonomieerleben, soziale Eingebundenheit, Kompetenzerleben und Bedeutung. Das Projekt EMPAMOS hat, ausgehend von diesen Bedürfnissen, 25 generische Misfits und rund 100 Spielelemente identifiziert und in Form einer Mustersprache beschrieben. Wie Spielentwickler:innen diese Elemente kombinieren und damit Misfits vermeiden, wurde mithilfe maschineller Lernverfahren aus einem Datensatz von 8.300 Spielen und rund 50.000 empirischen Einzelbelegen gewonnen (Voit et al., 2020). Abbildung 1 visualisiert diesen aus der datengetriebenen Analyse gewonnenen Möglichkeitsraum von über 1.800 dokumentierten Elementkombinationen.

Abbildung 1: Möglichkeitsraum zur Kombination spieltypischer Elemente.



4 EMPAMOS – der Designprozess zur Gestaltung motivierender Lerngelegenheiten

Aus der großen Anzahl von Spielelementen und ihren möglichen Kombinationen ergibt sich ein enormer Möglichkeitsraum. Er kann vom Menschen nur in begrenztem Umfang erfasst und zielgerichtet genutzt werden. Das Arbeitsgedächtnis kann sich nur etwa vier Informationspakete merken. Diese sogenannten *chunks* sind Konzeptsammlungen, die einen starken Bezug zueinander haben (Cowan, 2001). Gleich-

zeitig sind Menschen von einer großen Auswahl überfordert (Iyengar und Lepper, 2000). So bezeichnen Laine und Lindberg (2020) bereits die 54 Designprinzipien von Spielen als »*overwhelming*«, die sie anhand einer Literaturrecherche ermittelt haben. Der noch umfangreichere Möglichkeitsraum von EMPAMOS macht den Überblick umso schwieriger. Um das motivierende Potenzial von Spielen zielgerichtet auf einen spielfremden Kontext zu übertragen und darin zu integrieren, müssen die Nutzer:innen jedoch befähigt werden, Elemente zwischen ihrem Kontext und dem von Spielen wechselseitig zu »übersetzen«. Dieses Übersetzen erfordert, dass sie vorhandene Spielelemente in spielfremden Kontexten (wieder-)erkennen und sich konkrete Umsetzungen für noch nicht vorhandene Spielelemente vorstellen können.


EMPAMOS verbindet daher das Wissen zu Spielen mit einem methodischen Vorgehen, um diesen kreativen Arbeits- und Übersetzungsprozess zu fördern. Dabei entwickeln die Nutzer:innen kein Spiel oder eine zusätzliche Spielebene. Sie betrachten die Situation, mit der sie unzufrieden sind, vielmehr als »kaputtes Spiel«, das motivationale Bedürfnisse nicht adressiert. Dafür begeben sie sich methodisch auf einen Umweg: Sie übersetzen ihre Lerngelegenheit in ein Modellsystem von Spielelementen. Dieses Konzept entspricht der modellgestützten Untersuchungssituation nach Ferstl (1979, S. 80). Hierbei wird ein problembehaftetes Originalsystem zunächst in ein Modellsystem überführt, um auf dieser Modellebene auf ein geeigneteres Lösungsverfahren zurückgreifen zu können. Die Nutzer:innen wechseln durch diesen Übersetzungsprozess ihre Perspektive. Dabei stehen nicht mehr Lernziele im Vordergrund, sondern das angestrebte Verhalten und die dafür notwendigen Motivationsfaktoren. Indem die Nutzer:innen ihren spielfremden Kontext auf der Modellebene der Spieldesign-Elemente als »kaputtes Spiel« rekonstruieren und weiterentwickeln, verändern sie das System selbst, statt eine zusätzliche Schicht darüberzulegen. Im Ergebnis muss das Originalsystem nicht zwangsläufig einen spielerischen Charakter haben. Indem Spielelemente in passende Elemente des Originalsystems übersetzt werden, entstehen Kombinationen, die motivierend wirken, aber keinen offensichtlichen Spielcharakter haben.

Bei näherer Betrachtung enthalten viele spielfremde Kontexte bereits Elemente, die mit Spielelementen vergleichbar sind, die durch EMPAMOS identifiziert wurden. Auch Lerngelegenheiten können solche Elemente enthalten. Lehrende und Lernende bewegen sich auf einem *gemeinsamen Spielfeld*, das beispielsweise in Form eines Curriculums und der darin enthaltenen Themenfelder gegeben ist. Noten sind *Belohnung* oder *Strafe* für Leistungen. Ein *Zeitlimit* begrenzt Seminareinheiten und Prüfungsleistungen. Trotzdem wirken sie nicht motivierend. Weil sie nicht so implementiert und aufeinander bezogen sind wie in Spielen, werfen sie Misfits auf.

Indem die Nutzer:innen mithilfe von EMPAMOS spieltypische Elemente in ihren Lerngelegenheiten wiedererkennen, bauen sie einen abstrahierten Entwurf ihres Kontexts auf. Sie übersetzen ihre Lerngelegenheit in die Sprache von Spielen und

lösen sich damit von vertrauten Denkstrukturen. Im ersten Schritt dieses Prozesses arbeiten sie mit analogen Karten, auf denen typische Spielelemente benannt und kurz beschrieben sind. Anhand des Verbindungskatalogs von EMPAMOS können die Nutzer:innen ermitteln, ob und inwieweit sich die ausgewählten Spielelemente zu einem System verbinden lassen. Fehlende Verbindungen zwischen den Spielelementen oder vollständig isolierte Spielelemente, die sich mit keiner der anderen Karten kombinieren lassen, deuten darauf hin, dass motivationale Mängel vorhanden sind. Erst wenn die abstrahierten Elemente erfasst und Lücken zwischen ihnen klargeworden sind, lassen sich kreative Ideen entwickeln, um das »kaputte Spiel« zu »reparieren«.

Abbildung 2: Designprozess der EMPAMOS-Methodik.



Ausgehend von ihren abstrahierten Elementen können Nutzer:innen mithilfe des Verbindungskatalogs die Spielelemente finden, die ihre Lücken schließen. Um das System durch neue Elemente zu erweitern, müssen sie diese in ihre Lerngelegenheit zurückübersetzen. Die Elemente müssen dabei so ausgewählt und kombiniert werden, dass sie spezifische Motivationsprobleme der Zielgruppe adressieren und sich in den spielfremden Kontext gut einfügen. Abbildung 2 fasst die drei Phasen dieses Designprozesses zusammen.

Die Erfahrungen aus insgesamt 12 Workshops mit über 70 unterschiedlichen Teilnehmenden in unterschiedlichen Anwendungsbereichen (Hochschulbildung, Soziale Arbeit, Unternehmen und Kultur) zeigen, dass die Nutzer:innen in diesem Prozess bereits mit einem Set der 25 häufigsten Spielelemente schnell überfordert sind. Eine webbasierte App mit KI-Funktionen (WebApp) soll die Nutzer:innen deshalb in diesem Prozess unterstützen, ohne ihre eigenen kreativen Ideen einzuschränken.


5 KI als Lotse im Gestaltungsprozess

Um Lehrende und Lernende in die Lage zu versetzen, aus bereits vorhandenen Spielelementen eine kreative Lösung für Motivationsprobleme zu entwickeln, verfolgen wir einen Ansatz, der die menschliche Kreativität der Nutzer:innen mit maschineller Datenanalyse kombiniert. Das Zusammenspiel zwischen den Nutzer:innen und dem KI-System ist hierbei aus einer Werkstattperspektive angelegt (Ferstl/Sinz 2013, S. 126): Der Mensch verantwortet den eigentlichen Prozess der Lösungssuche und kann die KI nach eigenem Ermessen wie einen Lotsen in seine Entscheidungen einbeziehen, wenn sich die eigene Kreativität erschöpft.

Misfits und Spielelemente stehen den Nutzer:innen zunächst unabhängig von der WebApp als haptische Spielkarten zur Verfügung. Indem sie diese Karten über Holzverbindungen zu einem System zusammenfügen, können sie eine Lerngelegenheit als »kaputtes Spiel« dekonstruieren. Abbildung 3 zeigt an einem Beispiel aus dem Hochschulkontext, wie sich Aspekte des spielfremden Kontextes als spieltypische Elemente übersetzen lassen.

Haben die Nutzer:innen ihre Lerngelegenheit übersetzt, können sie das spielerische Netzwerk mit Unterstützung der WebApp umbauen und erweitern. Hier steht ihnen der komplette Möglichkeitsraum spieltypischer Motivationslösungen zur Verfügung (s. Abb. 1). Der Weg von der menschlichen Kreativität zu konkreten KI-basierten Vorschlägen folgt hierbei einem dreistufigen Modell.

Abbildung 3: Beispiel für die Dekonstruktion einer vorhandenen Motivationslösung mithilfe des EM-PAMOS-Kartensets.



Stufe 1: Auf der ersten Stufe (kreativ-manuell) können die Nutzer:innen mithilfe der haptischen Karten eigene Ideen entwickeln. Dafür können sie auf 15 Kreativmethoden zurückgreifen, mit denen sie Misfits identifizieren und erste Lösungsideen legen können. In welcher Form die Misfits und Spielelemente im jeweiligen Kontext vorkommen, halten sie auf blauen Klebezetteln fest. Wie die Misfits und Spielelemente aufeinander bezogen sind, beschreiben sie auf gelben Zetteln. Die Verbindungen sind hierbei gerichtet zu interpretieren: Das jeweils unten positionierte Element steht im Dienst des weiter oben positionierten. In dem Beispiel in Abbildung 3

hilft das Element *Strafe* dem Element *Zeitlimit*, sein motivationales Potenzial zu entfalten: Es bietet einen Anreiz, das Zeitlimit einzuhalten.

Stufe 2: Auf der zweiten Stufe (analytisch-manuell) können die Nutzer:innen einen erweiterten Vorrat von Spielelementen nutzen. Außerdem können sie die WebApp einsetzen, um das explizierte Wissen der Spielentwickler:innen analytisch in ihre manuelle Lösungssuche einzubeziehen. Sie können z.B. nachvollziehen, mit welchen Spielelementen sich ein Misfit lösen lässt oder welche Elementkombinationen sich in Spielen bereits bewährt haben. Abbildung 3 zeigt eine solche Kombination als Verbindung zwischen Zeitlimit und Strafe.

Stufe 3: Auf der dritten Stufe (analytisch-maschinell) können die Nutzer:innen die KI in der WebApp als maschinelle Unterstützung aktivieren. Die KI fungiert als Assistenzsystem und kann Verbindungen zu neuen Spielelementen vorschlagen, an die die Nutzer:innen vielleicht noch nicht gedacht haben. Ebenso kann die KI neue Verbindungen zwischen den bereits vorhandenen Elementen vorschlagen. Dafür greift sie auf den gesamten Vorrat zurück. Wie die Nutzer:innen die KI einsetzen, ob zur Suche nach neuen Elementen oder zur Verbindung bereits vorhandener Elemente, können sie dabei selbst entscheiden. Abbildung 4 zeigt, wie den Nutzer:innen die KI-Empfehlungen für neue Elemente präsentiert werden.

Abbildung 4: KI-generierte Empfehlungen für neue Elementkombinationen in der WebApp.

The screenshot shows the EMPAMOS web application interface. At the top is a blue header with the logo 'EMPAMOS' and navigation icons. Below the header, there are two game cards. The left card is titled '12' and 'Kooperative Spielform' (Cooperative Game Form), featuring a green icon of two people. The right card is titled '89' and 'Spielva' (Game Variant), featuring a grey icon of a person. Both cards display a 5x5 grid of numbers. The left card's grid has numbers: 3, 4, 10, 13, 14; 16, 18, 20; 21, 24, 33, 35, 36; 38, 39; 41, 42, 62, 94. The right card's grid has numbers: 11, 1, 22, 45, 5; 72; 85. To the right of the cards is a sidebar with a green icon of two people and the text '12 Kooperative Spielform'. Below this is a description: 'Alle Spieler verfolgen ein gemeinsames Ziel. Um das Ziel zu erreichen müssen die Spieler ihre Aktionen aufeinander abstimmen und sich gegenseitig unterstützen.' (All players follow a common goal. To achieve the goal, the players must coordinate their actions and support each other.) Below the description is a toggle switch labeled 'Wie kann man die Kooperation fördern bzw. erzwingen?' (How can one promote or enforce cooperation?). Below the toggle is a recommendation box with the number '16' and the text: 'Siegbedingung: Es gibt ein gemeinsames Ziel, das die Spieler nur gemeinsam erreichen können. Der individuelle Beitrag jeden Spielers ist hierfür nötig.' (Winning condition: There is a common goal that the players can only achieve together. The individual contribution of each player is necessary for this.)

Auf jeder Karte – sowohl auf den haptischen Karten wie auch auf den Kartenabbildungen in der WebApp – sind die Nummern der Elemente verzeichnet, die damit bereits kombiniert wurden. Klicken die User:innen in der WebApp auf eine Nummer, erscheint rechts die Beschreibung des Spielelements und der jeweiligen Kombination als Frage und Antwort. Dies entspricht der Nutzung auf Stufe zwei. Die Nutzer:innen wechseln innerhalb der App auf Stufe drei, indem sie in der Kopfzeile die KI aktivieren. Dadurch färben sich die Elementverbindungen auf den Karten ein. Der Sättigungsgrad der Färbung zeigt an, wie stark die KI eine Verbindung zu anderen Elementen empfiehlt. Je gesättigter die Farbe, desto stärker die Empfehlung. In Abbildung 4 empfiehlt die KI den Nutzer:innen, eine Siegbedingung (16) in Form eines gemeinsamen Ziels einzuführen, um damit die Kooperation (12) zu fördern.

Die Nutzer:innen sollen den KI-Vorschlägen dabei weder blind folgen, noch sie im blinden Vertrauen auf ihre eigene Kreativität ignorieren. Daher zeigt die KI alle Vorschläge an, differenziert diese aber nach der Empfehlungsstärke über den Sättigungsgrad der Farbmarkierungen. So können die Nutzer:innen sehen, wie stark sich alternative Vorschläge voneinander abheben.

Mit diesem Design fällt die KI in die Klasse der sogenannten Recommender-Systeme. Um Elemente vorzuschlagen, greift die KI auf die häufigsten Elementkombinationen zurück. Dabei adaptiert sie ein Verfahren, das eine Weiterentwicklung der klassischen Assoziationsanalyse ist (Osadchiy et al. 2018). Mit diesen Verfahren werden z.B. Warenkorbdaten analysiert und Produktempfehlungen ausgesprochen (»Kund:innen, die Produkt X gekauft haben, kauften auch Produkt Y«). Statt jedoch zu untersuchen, welche Produkte gemeinsam gekauft werden, analysiert die KI, welche Elemente die Spielentwickler:innen in ihren Spielen kombinierten.

6 Evaluation des KI-Einsatzes im Rahmen der Lehrveranstaltung

Die WebApp mit der KI haben wir an der Technischen Hochschule Nürnberg im Modul »Gamification von Informations- und Anwendungssystemen« evaluiert, das sich über ein gesamtes Semester erstreckt. Es ist ein Wahlpflichtmodul (5 ECTS) der Fakultät Informatik, das Studierende der drei Masterstudiengänge Informatik, Medieninformatik und Wirtschaftsinformatik belegen können. Im Sommersemester 2021 nahmen 25 Studierende daran teil. In drei Phasen arbeiteten sie mit der Methodik und den Ergebnissen von EMPAMOS.

In einer achtwöchigen seminaristisch organisierten ersten Präsenzphase lernten die Studierenden die theoretischen und methodischen Grundlagen kennen. Anhand einer der 15 Kreativmethoden der Stufe eins bearbeiteten und dokumentierten sie in einer zweiten Phase während der folgenden acht Wochen ein selbstgewähltes Motivationsproblem im Selbststudium. In einer abschließenden viertägigen Block-

phase in Präsenz entwickelten sie in sieben Teams von drei bis vier Studierenden eine spielerische Motivationslösung für zwei vorgegebene, demotivierende Lerngelegenheiten. Die beiden Lerngelegenheiten waren in einem anderen Seminar von Bachelor-Studierenden der sozialwissenschaftlichen Fakultät in Steckbriefen beschrieben worden:

- a) Eine konkrete Zoom-Lehrveranstaltung, bei der die Studierenden aufgrund fehlender Interaktion schnell die Konzentration verlieren.
- b) Die fehlende Selbstorganisation im Semesterverlauf, bei der Lern- und Wochenpläne aufgestellt aber nicht eingehalten werden.

Jedes Team konnte wählen, welches der beiden motivationalen Probleme es lösen wollte, und mit den themengebenden Studierenden Fragen dazu per Videokonferenz abklären. Jedes Team konnte auch selbst festlegen, ob und in welchem Ausmaß es seine Lösung kreativ-manuell (Stufe 1), analytisch-manuell (Stufe 2) oder analytisch-maschinell (Stufe 3) entwickeln wollte.

6.1 Ablauf der Interviews

Am letzten Tag des Blockseminars wurden alle sieben Teams anhand eines Leitfadens für jeweils 30 Minuten über die Webkonferenzsoftware Zoom interviewt. Mit dem Ziel, den Nutzen der KI im Arbeitsprozess zu untersuchen, konzentriert sich das Interview auf die Blockarbeitsphase der Lehrveranstaltung. Nur dort arbeiteten die Studierenden mit der WebApp. Der Interview-Leitfaden umfasste die folgenden fünf Fragen:

- a) Wie schätzen Sie ihr Arbeitsergebnis ein?
- b) Werden Sie EMPAMOS auch nach dem Seminar einsetzen?
- c) Wie schätzen Sie den Beitrag der WebApp für Ihre Lösung ein?¹
- d) Wenn Sie Ihre anfänglichen Erwartungen an EMPAMOS mit Ihrem jetzigen Wissensstand vergleichen: gab es für Sie ein Aha-Erlebnis in Ihrem Arbeitsprozess?
- e) Welche anderen Techniken oder Methoden kennen Sie, um Probleme strukturiert zu lösen?

Themen abseits dieser Fragen entwickelten sich aus der jeweiligen Diskussion heraus. Interviewerin war eine studentische Hilfskraft, die mit EMPAMOS und der Methodik vertraut ist, jedoch in keinem Abhängigkeitsverhältnis zum Dozenten des

¹ Im Interview wurde hier noch zwischen der Übersicht über die Elemente und den Vorschlagsfunktionen der KI unterschieden.

Seminars stand. Die Aussagen der Teams und verschiedene Zitate dokumentierte sie während des Interviews handschriftlich, stichpunktartig und erfasste dabei markante Zitate. Im Anschluss an jedes Interview stand Zeit zur Verfügung, um das jeweilige Protokoll zu vervollständigen.

6.2 Auswertung der Interviewprotokolle

Angelehnt an Ruddat (2012) haben wir anhand der Interviewprotokolle zentrale Themen und Meinungen in den Interviews identifiziert und die Aussagen anhand der Fragen tabellarisch zusammengefasst. Wichtige Zitate haben wir aus den Protokollen übernommen. Die Aussagen haben wir anschließend deduktiv kategorisiert, um die Themenfelder zu den Leitfragen zu überblicken. Dabei haben wir auch berücksichtigt, ob die Aussagen zu einem Thema eher positiv oder eher negativ zu bewerten waren.

6.3 Ergebnisse der Fokusgruppeninterviews

Einschätzung des eigenen Arbeitsergebnisses. Auf die Frage, wie die Teams ihre Arbeitsergebnisse einschätzen, äußerten sie nicht nur, wie zufrieden sie mit dem Ergebnis per se waren, sondern setzten dieses auch in ein Verhältnis zur verfügbaren Zeit und dem Potenzial, das sie im Arbeitsprozess erkannt hatten. Außerdem gab es erste Anmerkungen zum methodischen Ablauf und Details.

Mit Ausnahme eines einzigen Teams waren die Studierenden mit ihren Ergebnissen grundsätzlich zufrieden bis sehr zufrieden (*»ziemlich geil«*). Vier Teams sagten aus, sie hätten das Potenzial des methodischen Vorgehens zwar erkannt, jedoch aufgrund der knappen Zeit nicht ausreizen können. Mehr als der Hälfte der Teams meldete zurück, dass der Gesamtprozess gute Ideen und Denkanstöße geliefert habe. Drei Teams sprachen sogar von zu vielen Ideen für die verfügbare Zeit (*»Je mehr du machst, desto mehr willst du unbedingt machen.«*) – ein Aspekt, den nur ein Team explizit negativ bewertete, weil die Vielzahl der Ideen zu Uneinigkeit in der Gruppe geführt habe.

Die Äußerungen zum methodischen Vorgehen mit EMPAMOS sind sehr unterschiedlich. Ein Team sah das Vorgehen als nicht zwingend notwendig für den Lösungsprozess an. Es sei zu komplex. Gleichzeitig bewertete dieses Team aber den leichten Einstieg und die wiederkehrende Reflexion im Verlauf des Designprozesses positiv. Ein anderes Team wurde durch den Einsatz der KI verwirrt, weil die Vorschläge zu Konflikten mit den Ergebnissen der Kreativmethoden geführt hätten.

Weiterer Einsatz von EMPAMOS. Bei der Frage, ob die Teams EMPAMOS auch nach dem Seminar anwenden würden, bewerteten sie dessen Einsatz vor dem Hinter-

grund unterschiedlicher Einsatzfelder. Teilweise griffen sie auch nur einzelne Teile des Prozesses heraus, die sie für sinnvoll hielten.

Die überwiegende Mehrheit wollte die Methodik weiterverwenden. Zwei Teams sahen sie als zu aufwendig für den Alltag an und hinterfragten das Verhältnis von Nutzen zu Aufwand. Eine Gruppe sah durch das methodische Vorgehen mit EMPA-MOS keinen erweiterten Lösungshorizont, aber eine gute Basis für einen Problemlöseprozess. Eine andere Gruppe sah die Stärke des Vorgehens in der Konzeption von Lösungen für bereits bekannte Probleme und nicht in der Problemanalyse. Drei Gruppen stellten jedoch die neu gewonnene Perspektive auf die Realität als Vorteil in den Vordergrund. Sie fördere das Denken abseits bekannter Lösungswege (*»outside the box«*).

Die Studierenden sahen insgesamt ein breites Feld von Einsatzgebieten. Häufig dachten sie dabei an Projekte und Abschlussarbeiten im Studium – auch für Studierende in anderen Studiengängen. Außerdem sahen sie Einsatzmöglichkeiten im privaten Bereich oder in der Zeit nach dem Studium.

Einschätzung der KI-Unterstützung. Hier sollten die Teams sich sowohl zu den vorgefundenen als auch den vorgeschlagenen Verbindungen durch die KI äußern. In ihren Äußerungen haben die Studierenden dabei nicht nur die KI bewertet, sondern sind auch auf die Wirkung und die Einsatzmöglichkeiten eingegangen.

Die Vorschläge der KI zu den vorgefundenen Verbindungen haben die Teams durchweg positiv bewertet (*»unbedingt nützlich«*). Fast alle Teams bewerteten die KI-Funktion als wichtig, um damit die intuitiv gefundenen Verbindungen zu validieren. Mehr als die Hälfte hat positiv bewertet, dass ihnen die KI gute neue Ideen und Denkanstöße gegeben hat (*»Es hilft, die Kreativität zu steigern!«*). Ein Team bemerkte, dass durch die KI Konflikte zwischen eigenen Gedanken und KI-Vorschlägen entstanden waren. Selbstkritisch reflektierten diese Studierenden jedoch auch, dass sie ihr eigenes Denken zu sehr in den Hintergrund gestellt hatten.

Hinsichtlich der KI-Funktion, Verbindungen auf Basis von Spielelementen oder Misfits vorzuschlagen, wiesen die Meinungen eine größere Bandbreite auf. Drei Teams haben die KI genutzt, um Verbindungen zu validieren. Sie habe auch die Übersicht über die Spielelemente erleichtert. Zwei Teams haben die Verbindungsvorschläge der KI dagegen kaum genutzt. Eins fand die Vorschläge verwirrend – doch das andere Team fand sie grundsätzlich hilfreich. Für zwei weitere Teams hat die KI zwar nur wenige neue Vorschläge gegenüber den kreativen Methoden aus Stufe 1 gebracht, dafür jedoch einen zeitlichen Vorteil. Drei Teams haben bestätigt, dass die KI sie dabei unterstützt hat, neue Ideen zu finden. Eines hat darauf hingewiesen, dass sich mit dem Einsatz der KI eine Kaskade von Folgeelementen und -verbindungen entwickelt habe.

Erwartungen im Vergleich zu den Erfahrungen. Alle Teams haben vor allem den Gesamtprozess bewertet und sich überwiegend positiv oder sehr positiv dazu geäußert. Nur ein Team ging explizit auf die verwendete KI ein. Es kritisierte, dass die KI keine »beste Lösung« geboten habe. Drei Teams sprachen die Bedeutung des Zufalls bei den Kreativmethoden an. Zwei bezeichneten ihn als wichtig (»Der Zufall beim Karten-Ziehen gibt die Denkanstöße! Er ist nicht zu unterschätzen.«), während sich das dritte Team dadurch verwirrt fühlte. Ein weiteres Team bemerkte auch für die Spielelemente, dass der *Zufall* eine überraschend wichtige Rolle spiele.

Weitere Anmerkungen abseits der vorgegebenen Fragen bezogen sich vor allem auf die Nutzer:innenfreundlichkeit der WebApp. Die Teams wünschten sich mehr Übersichtlichkeit und mehr Informationstexte (Tooltips) zur Bedienoberfläche. Außerdem wünschten sie sich eine integrierte Hilfe, die schrittweise den Umgang mit der WebApp erklärt, aber auch grundlegende und vertiefende Informationen zu Spielelementen und deren Vernetzung liefert. Für die zukünftige Weiterentwicklung der WebApp wünschten sich die Studierenden die Möglichkeit die Netze von Spielelementen zu visualisieren und zu speichern oder weiteren Filtermethoden für die Kartenauswahl.

Fragen-übergreifende Interpretation der Kommunikationsinhalte. Ein Fragenschwerpunkt der Interviews lag auf der WebApp und der darin integrierten KI. Die Äußerungen der Teams deuten darauf hin, dass sie dieses Werkzeug nur als einen Teil – und nicht als Hauptteil – des gesamten methodischen Vorgehens sehen. Nur ein Team erwartete, dass die KI auch Lösungen liefert. Als Hilfsmittel, um die eigenen Verbindungen zu validieren, wurde die WebApp von allen Teams intensiv genutzt und durchgehend positiv bewertet. Die tatsächlichen KI-Funktionen zur Erweiterung des eigenen Netzes von Spielelementen wurden jedoch in unterschiedlichem Umfang von den Studierenden eingesetzt. Auch die Bewertung der Funktionen zeigte daher eine größere Bandbreite.

7 Diskussion und Ausblick

Betrachtet man die Aussagen der einzelnen Teams über die verschiedenen Themenfelder, konnten alle Teams positive Erfahrungen aus dem Gesamtarbeitsprozess mit EMPAMOS ziehen. Die Teams zeigten jedoch von kreativ-manuellem (Stufe 1) bis hin zu analytisch-maschinell (Stufe 3) Vorgehen unterschiedliche Vorlieben. Die WebApp mit der KI haben die Studierenden insgesamt als sehr positiv für den Arbeitsprozess wahrgenommen. Entsprechend der Vorlieben wurden deren KI-Funktionen mehr oder weniger von den Teams genutzt. Auch wenn manche Teams sich von den Vorschlagsfunktionen der KI überfordert fühlten, konnten sie Ideen und

kreative Anregungen aus den Stufen 1 und 2 des dreistufigen Modells im Umgang mit den Karten und der WebApp gewinnen.

Mit ihrer Übersicht über die Spielelemente und Misfits und ihren Beschreibungen der Elemente und möglichen Verbindungen hat die WebApp diese grundlegenden Aspekte des Spieldesigns zugänglicher gemacht. So haben alle Teams die Möglichkeit geschätzt, damit ihre eigenen Ideen zu validieren. Zum Teil war es jedoch schwierig, alle Aussagen der Studierenden den KI-Funktionen genau zuzuordnen. Die stichpunktartige Dokumentation der Interviews war sicherlich ein Grund hierfür, die fehlende Erfahrung der Studierenden mit den Fachbegriffen zu den KI-Funktionen möglicherweise ein anderer. Hier hätte eine Aufzeichnung der Interviews die Auswertung erleichtern und die Aussagekraft erhöhen können. Insgesamt überwiegt jedoch der Eindruck, dass die KI-Funktionen wenigstens von der Hälfte der Teams als hilfreich für den kreativen Arbeitsprozess wahrgenommen wurden. Ein Team hat die KI-Funktionen explizit so wahrgenommen, dass die »Vorschläge wie Dominosteine zu Folgeelementen und -verbindungen geführt« haben. Hier könnte eine genauere Beobachtung der Teams während des Arbeitsprozesses helfen, genauer zu verstehen, warum die KI dort so erfolgreich eingesetzt werden konnte. Die Hinweise zur WebApp deuten jedoch auch darauf hin, dass die Akzeptanz der KI erhöht werden könnte, wenn die Nutzer:innenfreundlichkeit verbessert wird.

Die Durchführung und Auswertung der Interviews schränkt die Aussagekraft der Ergebnisse ein. Zum einen verändert die Interviewführung über die Webkonferenzsoftware die Kommunikation. Zum anderen gehen durch die handschriftlichen Gesprächsnotizen unweigerlich Informationen verloren und sind in ihrer Auswahl bereits durch die Protokollantin subjektiv gefärbt. Zudem beschränkt sich die Fokusgruppe bisher auf die Lernenden – also auf die Studierenden – und sollte in weiteren Untersuchungen durch die Fokusgruppe »Lehrende« ergänzt werden. Die Ergebnisse liefern jedoch erste greifbare Daten zu unseren subjektiven Erfahrungen aus Workshops, Arbeitskreisen und Seminaren. Letztlich geben sie ausreichende Hinweise, um vom jetzigen Arbeitsstand ausgehend das methodische Vorgehen und die WebApp weiterzuentwickeln. Gleichzeitig zeigen uns die Ergebnisse Lücken auf, die wir mit den Interviews noch nicht schließen konnten.

Unsere bisherigen Erfahrungen zeigen, dass Studierende sich mit den Spielelementen leichter tun als Lehrende. Sie nähern sich den Problemen eher spielerisch und unvorbelastet. Lehrende hingegen versuchen gleich, strukturiert damit zu arbeiten. So konzentrieren sie sich z. B. darauf, die Beschreibungen der Spielelemente genau zu interpretieren, und wählen dadurch Elemente und Verbindungen nachdenklicher und zögernder aus. Im Vergleich dazu gehen Studierende unbeschwerter und kreativer mit den Karten um und kommen dadurch schneller zu Ergebnissen und zu unterschiedlichen alternativen Lösungen. Auch in den Interviews machte ein Team das deutlich: »Wir haben uns blind daraufeingelassen und einfach mal gemacht.«

Zukünftig wäre es interessant zu vergleichen, ob und wie sich die Kreativität und das Motivationspotenzial der Lösungen aus EMPAMOS zu anderen Kreativitätstechniken verhalten. Langfristig ist auch zu beurteilen, ob die mit EMPAMOS entwickelten Lösungen tatsächlich zu motivierenderen Lerngelegenheiten führen oder ob damit vorhandene Situationen lediglich im Detail verbessert werden. Um dieser Frage nachzugehen, begleiten wir seit dem Wintersemester 2020/2021 einen hochschulübergreifenden Arbeitskreis, in dem Lehrende und Studierende EMPAMOS einsetzen, um gemeinsam an Motivationshindernissen von hochschulischen Lerngelegenheiten zu arbeiten. Gegenüber einzelnen Seminarangeboten bietet das Vorteile: die Teilnehmer:innen können Lehr- und Lerngelegenheiten immer besser und schneller analysieren und Lösungen dafür entwickeln. Durch den kontinuierlichen Austausch mit anderen und die praktische Anwendung der Lösungen können sie zudem gemeinsam ihre Erfahrungen ausbauen und die Wirksamkeit der Methodik reflektieren. Die ersten Projekte in diesem Arbeitskreis zum Wintersemester 2021/22 bieten hier die Chance, konkrete Lerngelegenheiten aus den Hochschulen aus der Perspektive der Lehrenden und Lernenden im Bearbeitungsprozess zu untersuchen.

8 Fazit

Ein großer Vorteil, den Spiele gegenüber institutionellen Lerngelegenheiten haben, ist ihre Fähigkeit, Menschen dazu zu bringen, sich nicht nur freiwillig, sondern auch enthusiastisch mit schwierigen Hindernissen und Problemen auseinanderzusetzen. Dieses zwanglose und interessengetriebene – motivierte – Lernen, das Kleinkinder in ihrem Spielen von sich aus mitbringen, geht mit dem Übergang in den institutionalisierten Bildungskontext oftmals verloren. Damit geht auch der Verlust des Potenzials einher, das in diesem spielerischen Lernen steckt.

Um das zu verhindern, sollten Lehrende wie auch Lernende Profis darin werden, das Lernen auch in den Bildungsinstitutionen motivierend zu arrangieren und zu begleiten. Eine KI kann diese kreative Aufgabe, für deren Lösung Aspekte aus unterschiedlichen fachlichen Bereichen ineinandergreifen müssen, zwar nicht übernehmen, doch kann sie auf Grundlage einer menschlichen (Vor-)Auswahl den Raum der Möglichkeiten auf eine sinnvolle Auswahl von Spielelementen und ihren Verbindungen begrenzen. Da sie dabei in ein kreatives Verfahren eingebettet ist, übernimmt sie jedoch nie die Führungsrolle. Den Nutzer:innen bleibt jederzeit die Möglichkeit, ihre Perspektive zu erweitern und innovative Lösungswege zu gehen, die die KI noch nicht gelernt hat. Die Ergebnisse aus den Interviews zeigen, dass sowohl das methodische Vorgehen als auch die KI von EMPAMOS zu neuen Ideen anregen und einen zielgerichteten Lösungsweg unterstützen. Weitere Möglichkeiten, den Einsatz der Methodik und der KI zu untersuchen, sehen wir in der zunehmenden Verbreitung

von EMPAMOS und der steigenden Anzahl von Nutzer:innen. In Zusammenhang mit den Förderprogrammen der Stiftung Innovation in der Hochschullehre haben bereits erste Lehrende ihr Interesse geäußert, mit EMPAMOS Lehrforschungsprojekte zu bearbeiten.

Thomas Bröker: TH Nürnberg, Forschungs- und Innovationslabor Digitale Lehre; thomas.broeker@th-nuernberg.de

Thomas Voit: TH Nürnberg, Professor für Wirtschaftsinformatik; thomas.voit@th-nuernberg.de

Benjamin Zinger: TH Nürnberg, Forschungs- und Innovationslabor Digitale Lehre; benjamin.zinger@th-nuernberg.de

Literatur

- Alexander, C. (1964). *Notes on the Synthesis of Form*, Cambridge: Harvard University Press.
- Alexander, C., Ishikawa, S., & Silverstein, M. (1977). *A Pattern Language. Towns, Buildings, Construction*. New York: Oxford University Press.
- Berendt, B. (2005). The Shift from Teaching to Learning – mehr als eine ›Redewendung‹: Relevanz – Forschungshintergrund – Umsetzung, in: Welbers, U./Gaus, O. (Hg.): *The Shift from Teaching to Learning. Konstruktionsbedingungen eines Ideals*, Blickpunkt Hochschuldidaktik, Bd. 116, Bielefeld: Bertelsmann, 35–41.
- Björk, S., & Holopainen, J. (2005). *Patterns in Game Design*. Hingham, Massachusetts: Charles River Media.
- Bröker, T. (2016) *Wie kommt das Problem ins Spiel? Designprinzipien und Nutzermodell als Entwicklungsgrundlagen für ein Multiplayer Online Game in der Bauphysik*. Dissertation. Bauhaus-Universität Weimar.
- Codish, D., & Ravid, G. (2014). Academic Course Gamification: The Art of Perceived Playfulness. *Interdisciplinary Journal of E-Learning and Learning Objects*, 10, 131–151.
- Cowan, N. (2001) ›The magical number 4 in short-term memory: A reconsideration of mental storage capacity‹, *Behavioral and Brain Sciences*, 24(1), 87–114.
- Deci, E. L., & Ryan, M. R. (1985). *Intrinsic Motivation and Self-Determination in Human Behaviour*. New York: Plenum Press.
- EMPAMOS (2021). Projekt EMPAMOS. Empirische Analyse motivierender Spielelemente. <https://www.empamos.de> (Zugriff am 21.02.2022).
- Ferstl, O. (1979). *Konstruktion und Analyse von Simulationsmodellen*, Königstein/Ts: Hain.
- Ferstl, O., Sinz, E. (2013). *Grundlagen der Wirtschaftsinformatik*, 7. Aufl., München: Oldenbourg.

- Gee, J. (2007). *What Video Games Have to Teach Us About Learning and Literacy*, New York: Palgrave Macmillan.
- Högborg, J., Hamari, J., & Wästlund, E. (2019). Gameful Experience Questionnaire (GAMEFULQUEST): an instrument for measuring the perceived gamefulness of system use, *User Modeling and User-Adapted Interaction* 29, 619–660..
- Iyengar, S. S. & Lepper, M. R. (2000). »When choice is demotivating: Can one desire too much of a good thing?« *Journal of Personality and Social Psychology*, 79(6), 995–1006.
- Lewis, G. H. (1864). *Aristotle: a chapter from the history of science, including analyses of Aristotle's scientific writings*. London: Smith Elder.
- Harlow, H. F., & Harribert, G.-F. (1983). Fundamentals for preparing psychology journal articles. *Journal of Comparative Psychology*, 55(2), 893–896.
- Huizinga, J. (2009). *Homo Ludens*, 21. Aufl., Reinbek: Rowohlt.
- Kapp, K. M. (2012). *The Gamification of Learning and Instruction: game-based methods and strategies for training and education*, San Francisco: Wiley.
- Kapp, K. M., Blair, L., Mesch, R. (2014). *The Gamification of Learning and Instruction*, San Francisco: Wiley
- Kumar, J., Herger, M (2013). *Gamification at Work. Designing engaging Business Software*, The International Design Foundation: o.O.
- Laine, T. H. & Lindberg, R. S. N. (2020). »Designing Engaging Games for Education: A Systematic Literature Review on Game Motivators and Design Principles«, *IEEE Transactions on Learning Technologies*, 13(4), 804–821.
- Mayo, M.J. (2009). Video games: a route to large-scale STEM education? *Science*, 323(5910), 79–82.
- Osadchiy, T.; Poliakov, I. Olivier, P.; Rowland, M.; Foster, E. (2019): Recommender system based on pairwise association rules, in: *Expert Systems With Applications* 115, 535–542.
- Raab, M., & Voit, T. (2019). Vier Gewinnt? Gamification-Lehre als Kooperation von Hochschule, Uni, Spielearchiv und KMU. In: *Tagungsband zum 4. Symposium zur Hochschullehre in den MINT-Fächern*, 69–77. Nürnberg: Mohr GmbH, https://diz-bayern.de/images/cwattachments/491_fid8d1209f6ebde9058713d97ebf9d29.pdf (Zugriff am 01.10.2021).
- Reiners, T., & Wood, L.C. (Hg.) (2015). *Gamification in Education and Business*, Springer: Cham.
- Rheinberg, F. (2006). Intrinsische Motivation und Flow-Erleben, in: Heckhausen, J., Heckhausen, H. (Hg.): *Motivation und Handeln*, 3. Aufl., Heidelberg: Springer, 331–354.
- Ruddat, M. (2012). Auswertung von Fokusgruppen mittels Zusammenfassung zentraler Diskussionsaspekte. In: *Fokusgruppen in der empirischen Sozialwissenschaft: Von der Konzeption bis zur Auswertung*. Wiesbaden: Springer.

- Ryan, R.M., Rigby, C.S. and Przybylski, A. (2006) ›The Motivational Pull of Video Games: A Self-Determination Theory Approach‹, *Motivation and Emotion*, 30(4), pp. 344–360.
- Sailer, M. (2017). Die Wirkung von Gamification auf Motivation und Leistung. Dissertation. Wiesbaden: Springer.
- Schell, J. (2008). The art of game design. A book of lenses. Morgan Kaufmann: Burlington.
- Squire, K., (2005). Game-based learning: Present and future state of the field. Retrieved May.
- Steinkuehler, C.A. & Duncan, S. (2008). Scientific Habits of Mind in Virtual Worlds. *Journal of Science Education and Technology*, 17(6), 530–543.
- Voit, T. (2015). Gamification als Change-Management-Methode im Prozessmanagement. *HMD Praxis der Wirtschaftsinformatik*, 52(6), 903–914.
- Voit, T., Schneider, A., & Kriegbaum, M. (2020). Towards an Empirically Based Gamification Pattern Language Using Machine Learning Techniques, *CSEE&T 2020 conference proceedings*, <https://ieeexplore.ieee.org/document/9206223> (Zugriff am 12.08.2021).

Künstliche Intelligenz und forschendes Lernen – ein ideales Paar im Hochschulstudium!?

Silke E. Wrede, Christina Gloerfeld, Claudia de Witt und Xia Wang

Abstract: *Universitäre Lehre unterliegt gesellschaftlichen und politischen, aber besonders auch technologischen Entwicklungen wie Künstliche Intelligenz (KI), die an die Gestaltung von Lehre neue Anforderungen formuliert. Ebenso stehen Studierende zukünftig durch KI vor Herausforderungen, denen es mit den sogenannten 21. Century Skills (Bellanca & Brandt, 2010) zu begegnen gilt. Zur Ausbildung dieser Skills bietet das forschende Lernen einen adäquaten Erfahrungsraum. Ziele des forschenden Lernens liegen in der Konstruktion von Wissen, dem aktiven Erfahren von Zusammenhängen in Forschungssituationen und dem kritischen Reflektieren innerhalb sozialer Kontexte (vgl. Dewey 1916/2011; Bogdanow & Kauffeld, 2019). Gegenstand dieses Beitrags sind Überlegungen zu Unterstützungsmöglichkeiten von KI im Prozess des forschenden Lernens und das AI.EDU Research Lab des Forschungsschwerpunkts Digitalisierung, Diversität und Lebenslanges Lernen (D²L²)¹ an der FernUniversität in Hagen als konkretes Fallbeispiel. Hier wird das didaktische Konzept forschenden Lernens nach Wildt (2009) in Kombination mit KI so eingesetzt, dass es einen typischen Forschungszyklus mit Kolbs Lernzyklus (Wildt, 2009) verbindet und auf einen Semesterverlauf überträgt. Mit dem Einsatz eines Automatic Assessment-Tools auf Basis des maschinellen Lernens können Studierenden ihren Wissensstand zu Beginn des Semesters ermitteln (Wang et al. 2020) und ein Unterstützungs- bzw. Recommender-System, basierend auf einem wissensbasierten System, begleitet sie in ihren verschiedenen Forschungs- bzw. Lernphasen. Für eine zukunftsorientierte Hochschullehre gilt es herauszufinden, inwieweit Methoden und Anwendungen von KI den Prozess des forschenden Lernens unterstützen und zur Förderung eines selbstbestimmten Lernens eingesetzt werden können.*

University teaching underlies social and political, but especially technological developments such as AI which formulate new requirements for the design of teaching. And students will face challenges in the future due to AI which must be met with the so-called 21st Century Skills (Bellanca & Brandt, 2010). For the training of these skills, inquiry-based learning offers an adequate experiential space. The goals of this approach are the construction of knowledge,

1 Seit August 2022: CATALPA – Center of Advanced Technology for Assisted Learning and Predictive Analytics

the active experience of contexts in research situations, and critical reflection in a social context (cf. Dewey 1916/2011; Bogdanow & Kauffeld, 2019). In this article, we will consider how AI can support the process of inquiry-based learning. As a concrete case study, the AI.EDU Research Lab of the research focus Digitalization, Diversity and Lifelong Learning (D²L)² at the FernUniversität in Hagen is presented. It uses a didactic concept of inquiry-based learning according to Wildt (2009) together with AI to achieve these goals by combining a typical research cycle with Kolb's learning cycle (Wildt, 2009) and transferring it to a semester course. A recommender system, based on a knowledge-based system, accompanies students in their different research/learning phases; with the use of an auto-assessment tool based on machine learning, they determine their knowledge level at the beginning of the semester (Wang et al., 2020). Ultimately, it is important to find out to what extent methods and applications of AI support the process of inquiry learning and can be used to promote self-directed learning.

Keywords: Künstliche Intelligenz, Recommender-Systeme, forschendes Lernen, Hochschulstudium / Artificial intelligence, recommender systems, inquiry-based learning, higher education.

Künstliche Intelligenz und forschendes Lernen – ein ideales Paar im Hochschulstudium!?

Video: <https://link.transcript-open.de/5769/video/007>

© Silke Wrede, Christina Gloerfeld, Claudia de Witt, Xia Wang



1 Studieren mit Künstlicher Intelligenz

Seit der als Bologna-Prozess bezeichneten Hochschulreform Ende des 20. Jahrhunderts sind Kompetenzen zur Zielkategorie der Studiengänge geworden. Diese Kompetenzorientierung dient insbesondere der Befähigung der Studierenden, in beruflichen Anforderungssituationen professionell zu handeln. Und in den letzten

² Since August 2022: CATALPA – Center of Advanced Technology for Assisted Learning and Predictive Analytics

Jahren haben die digitalen Technologien u.a. Künstliche Intelligenz (KI), die Transformationen in den Hochschulen weiter vorangetrieben. Die Hochschulbildung in der neuen Ära der Datennutzung wird daran gemessen werden, inwieweit sie die sog. »21st Century Skills« (Bellanca & Brandt, 2010) für den Erwerb von Kompetenzen und Wissen für das Partizipieren und Agieren in der zukünftigen Gesellschaft ausbilden kann. Viele der damit adressierten Kompetenzen, beispielsweise Problemlösefähigkeit und kritisches Denken, haben bereits eine lange Tradition im Kontext von Lehren und Lernen; die Umsetzung in den Hochschulen bietet jedoch Raum zur Optimierung (Rotherham & Willingham, 2010). Deshalb wird, neben der Herausstellung der Zielkompetenzen, auch nach didaktischen Umsetzungsmöglichkeiten, curricularen Verankerungsstrategien und erfahrungsgenerierenden Methoden gesucht, die die Ausbildung der 21st Century Skills unterstützen. Dabei sind die Herausforderungen, die sich mit deren Einbindung in die Hochschule (z.B. Seidl, 2020; Dede, 2010) ergeben, zu bewältigen und Lösungen dafür zu finden, wie aktuelle Technologien die Entwicklung von Didaktik, Curriculum und Prüfung unterstützen können. Methoden und Ansätze Künstlicher Intelligenz erfordern also nicht nur 21th Skills, sondern bieten auch Lösungsmöglichkeiten, um den sich verändernden Bedingungen zu begegnen. Mit der Anwendung neuronaler Netze, maschinellem Lernen und Big Data im Hochschulstudium lässt Künstliche Intelligenz Unterstützungsmöglichkeiten erwarten, damit die zukünftig relevanten Skills, in die sich auch Data Literacy einordnen lässt, von den Studierenden individualisiert entwickelt werden können.

Zur Ausbildung dieser Kompetenzen bietet insbesondere das hochschuldidaktische Format des forschenden Lernens für die Studierenden einen adäquaten Erfahrungsraum zur Kompetenzentwicklung, denn Ziele des forschenden Lernens liegen in der Konstruktion von Wissen, dem aktiven Erfahren von Zusammenhängen in Forschungssituationen und dem kritischen Reflektieren innerhalb sozialer Kontexte (vgl. Dewey 1916/2011; Bogdanow & Kauffeld, 2019) und sie bedienen damit die Forderung nach entsprechender didaktischer Rahmung zur Entwicklung der 21th Skills. Eine der zentralen Herausforderungen besteht darin herauszufinden, inwieweit Methoden und Anwendungen von KI den Prozess des forschenden Lernens unterstützen und zur Förderung eines selbstbestimmten Lernens eingesetzt werden können.

In den folgenden Kapiteln ist insbesondere eine bildungswissenschaftliche Perspektive leitend. Zunächst wird ein Überblick zum forschenden Lernen gegeben, um daran anschließend die Möglichkeiten von KI-Systemen zur Unterstützung des didaktischen Ansatzes in einem Hochschulstudium auszuloten. Abschließend wird ein konkretes, sich in der Entwicklung befindendes Umsetzungsbeispiel von KI aus dem AI.EDU Research Lab des Forschungsschwerpunkts D²L² Digitalisierung, Diversität und Lebenslanges Lernen an der FernUniversität in Hagen vorgestellt. Anhand des Beispiels wird gezeigt, wie zur Verwirklichung der Ziele forschenden Ler-

nens entlang des didaktischen Konzepts von Wildt (2009) KI-Anwendungen im Verlauf eines Semesters eingesetzt werden können. Abschließend wird der Einsatz von KI für forschendes Lernen im Hochschulstudium kritisch reflektiert.

2 Forschendes Lernen als Zielkategorie zukunftsfähiger Hochschullehre

Forschendes Lernen ist im Grunde eine jahrhundertealte Lernform. Dem forschenden Lernen eine einzige Bedeutung zuzuschreiben, würde der vielfältigen Auseinandersetzung und den mehrdimensionalen Betrachtungsweisen dieser Lernform nicht gerecht. Forschendes Lernen ist deshalb als Plural zu denken (Straub et al., 2020). Für die Begegnung mit dieser Vielfalt an den Hochschulen lässt sich die Position des forschenden Lernens als Begriff, als Konzept und als Handlungsform fassen (Brinkmann, 2020). Neben der definitorischen Breite schwingt gleichzeitig bei dem Begriff des forschenden Lernens stets ein Ideal mit, welches eine so große Anzahl an Kompetenzen und Erfahrungen umfasst, die in einem Semester oder auch in vielen Bachelorstudiengängen zunächst unerreichbar bleiben (Straub et al., 2020). Aufgrund der Diskrepanzen, die mit dem Anspruch einer einheitlichen Definition und idealisierender Vorstellungen einhergehen, finden andere Begrifflichkeiten Einzug in die Diskussion. So arbeiten Huber und Reinmann (Huber, 2014, S. 38; Huber & Reinmann, 2019) mit dem Begriff des »forschungsnahen Lernens«:

Forschungsnahes Lernen umfasst über forschendes Lernen im engeren Sinne, in dem Studierende einen Forschungsprozess selbst forschend vollständig durchlaufen, hinaus alle diejenigen anderen Formen des Lehrens und Lernens, welche die Studierenden explizit an Forschung als Prozess heranzuführen, indem sie einen solchen nachvollziehbar vor- und zur Diskussion stellen oder die Studierenden Elemente daraus als Ausschnitte aus einem mitgedachten Forschungszusammenhang üben und erlernen lassen. (Huber & Reinmann, 2019, S. 3)

Unter diesem »Dach« lassen sich Differenzierungen des Begriffs vereinen. Huber (2014) sowie Huber und Reinmann (2019) unterscheiden beispielsweise zwischen forschungsbasiertem, -orientiertem und forschendem Lernen. Während forschungsbasiertes Lernen Grund- und Ausgangsfragen für das Lehren und Lernen fokussiert, kennzeichnet das Adjektiv »forschungsorientiert« einen Prozess, bei dem das Lehren und Lernen auf Forschung ausgerichtet ist. Und zuletzt ist mit dem forschenden Lernen der gesamte Lern- und Forschungszyklus gemeint, den die Studierenden eigenständig durchlaufen.

Zur Einordnung jedes speziellen Angebotes in den Kanon des forschungsnahen Lernens lassen sich drei Dimensionen zur Systematisierung vertiefend betrachten: Zunächst wird festgestellt, inwieweit der/die einzelne Studierende bereits selbst aktiv im Forschungsprozess agiert, beschreibbar in einem Kontinuum zwischen

rezeptiv und produktiv. Des Weiteren ermöglicht die Charakterisierung die Beschreibung der Nähe bzw. Enge am eigentlichen Forschungsprozess und den Grad der Selbstbestimmung, d.h. den Autonomiegrad der Einzelnen (Huber & Reinmann, 2019). Vor diesem Hintergrund wird in diesem Beitrag in Anlehnung an Dewey (1916/2011)

forschendes Lernen als eine Form des Lernens verstanden, die Theorie und Praxis miteinander verbindet und Eigenaktivität und Selbstverantwortung für individuelle und soziale Lernprozesse stärkt, indem eine Problemstellung entwickelt, ein Erkenntnisinteresse formuliert, eine Forscherperspektive eingenommen, eine Lösung entwickelt und vorzugsweise in einer Gemeinschaft gearbeitet wird, wobei es dazu gehört, Fehler zu machen und diese reflektieren zu können.

Wildt (2009) liefert mit einer Kombination der Phasen des Lernzyklus – Erfahrung, Reflexion, Konzeption und Erprobung – mit den Schritten eines Forschungsprozesses ein Modell, das für die didaktische Planung und Umsetzung nutzbar ist. Zusammengefasst startet der Kreislauf an der eigenen Erfahrung, der Auseinandersetzung mit der Praxis und Literatur oder auch mit einem Problem. Auf dieser Basis findet eine Reflexion zur Themenfindung und Formulierung von Forschungsfragen statt. Diese münden in der systematischen Konzeption einer Untersuchung und einem Forschungsdesign. Schließlich wird dieses umgesetzt (»Erprobung«) (ebd.).

Abbildung 1: Der Learning Cycle im Format des Forschungsprozesses (Wildt, 2009, S. 6).



Die Aufschlüsselung in einzelne Prozesse und deren Verbindung ermöglicht die gezielte Förderung ausgewählter Handlungsschritte und Herausforderungen der Studierenden. Zur Implementation technologischer Systeme in Lehr- und Lern-

szenarien, die dem forschungsnahen Lernen zugerechnet werden können, sind beispielsweise Kerres und de Witt (2002) zu nennen, die aus mediendidaktischer Perspektive für forschendes Lernen in pragmatistischer Tradition die Anschlussfähigkeit an digitale Lehre herausstellen. Hofhues (2016) stellt unterschiedliche Nutzungsweisen von Medien an unterschiedliche Varianten des forschungsnahen Lernens und deren Herausforderungen vor. Kergel und Heidkamp (2016) erörtern, mit Blick auf das forschende Lernen z.B., mitunter die Veränderungen der Forschung und der Lehre durch technologischen Fortschritt. Technologien bieten weiterhin ein rasantes Veränderungs- und Entwicklungspotenzial, mit welchem, neben den Möglichkeiten der digitalen Lehre, die Zielsetzung einer individuelleren Unterstützung verbunden ist. Der Einsatz von Methoden der KI soll hierfür nutzbar gemacht werden. Inwieweit beurteilt werden kann, ob forschendes Lernen und KI ein ideales Paar sind, ist nach den Ausführungen zum forschenden Lernen als nächstes zu eruieren, was unter KI zu verstehen ist.

3 Einsatz Künstlicher Intelligenz zur Unterstützung Studierender

Eine allgemeingültige Definition von KI gestaltet sich aufgrund der Breite des Verständnisses bezogen auf Technologie, Systeme und Anwendungen als schwierig (de Witt et al., 2020, S. 9), weshalb sich eher eine kontextbezogene Beschreibung anbietet. Für den Bildungsbereich identifizieren Zawacki-Richter et al. (2019) beim Einsatz von KI vier Anwendungsfelder: Profilierung und Vorhersage, Beurteilung und Bewertung, adaptive Systeme und intelligente tutorielle Systeme. Die dazugehörigen 17 Subkategorien ermöglichen die Einordnung verschiedener Anwendungen, verweisen zeitgleich auf die Unschärfe der einzelnen Felder. Blickt man auf die angewendeten Methoden und Ansätze, zeigt sich die Bandbreite der Möglichkeiten: beispielsweise wird maschinelles Lernen zur Mustererkennung und Klassifizierung in der Modellierung von Lernenden-Profilen ebenso wie in der Bewertung und dem Feedback von Studierenden eingesetzt (Zawacki-Richter et al., 2019). Zentral bei der Betrachtung von KI in der Bildung ist die Tatsache, dass es sich bei den Anwendungen, die in Hochschulen zum Einsatz kommen, um schwache KI-Systeme handelt, also um solche Systeme, die spezielle und eingegrenzte Probleme lösen.

3.1 Potenziale von KI-Systemen für die Erfassung des Studierendenverhaltens

Die Grundlage des maschinellen Lernens sind Datenmengen; ihre Nutzung und Analyse wird im Bildungsbereich mitunter durch die beiden Felder Learning Analytics (LA) und Educational Data Mining (EDM) flankiert. LA meint »die Messung, Sammlung, Analyse und Auswertung von Daten über Lernende und ihren Kontext

mit dem Ziel, das Lernen und die Lernumgebung zu verstehen und zu optimieren« (Siemens, 2013). Hingegen liegt beim EDM der thematische Fokus eher auf Techniken und Methoden der Datenanalyse (Lemay et al., 2021). Beide Felder konzentrierten sich in den Jahren 2015 bis 2019 nach Lemay et al. (2021) inhaltlich auf die Performanz der Studierenden, die Lernplattformen und die Modellierung von Lernendenverhalten.

Bei der Auseinandersetzung mit Künstlicher Intelligenz ist die Unterscheidung zu treffen, inwieweit im allgemeinen oder eher konkrete Technologien angesprochen sind und implementiert werden (Christen et al., 2020). Insbesondere Letzteres dient der weiteren Auseinandersetzung und dabei soll zunächst die Frage leitend sein, was genau der Unterschied zwischen einem klassisch technologischen und einem KI-System ist. Dieses zeichnet sich zum einen durch eine erhöhte Komplexität aufgrund der Verwendung von maschinellem Lernen und Deep Learning und einer darin begründeten gewachsenen Dynamik aus, die je nach verwendeter Methode im Gegensatz zum statischen System in der Lage ist, eigenständig zu lernen. Im Vergleich zu klassischen Computersystemen mit persistenten Quellcodes ist die Stabilität durch sich autonom anpassenden Algorithmen eher variabel. Zum anderen sind die Ergebnisse eher probabilistischer Natur. Das KI-System kann sich an den Lernfortschritt und den Kontext anpassen, wobei die Autonomie des Systems mitunter so hoch sein kann, dass sie aufgrund des Kontrollgedankens eher reduziert werden muss, statt sie voll zu nutzen (Scheuer, 2020, 21ff.). Auch wenn hier das KI-System durch den ungenauen beschreibenden Detailgrad eher vage bleibt, sind die Unterschiede ersichtlich.

3.2 KI-Systeme als Werkzeuge zum Lernen

Anhand der eben vorgenommenen Unterscheidung der zentralen Wesenszüge von klassisch technologischem und KI-System, die die Veränderung von technischen Medien skizziert, lässt sich aber auch bereits erahnen, dass sich mit einem entsprechenden Einsatz in Lern-Lehrkontexten ebenfalls mediendidaktische Veränderungen ergeben. Mediendidaktik wird hier verstanden als die Gestaltung von Lehr- und Lernprozessen, in denen der sinnvolle Einsatz von Medien im Vordergrund steht (de Witt & Czerwionka, 2013). Der Medienbegriff erweitert die Träger- und Vermittlungsfunktion von Informationen im Rahmen der Digitalisierungsprozesse und den damit zur Verfügung stehenden Daten um eine Werkzeugfunktion, die sich in den Möglichkeiten der Sammlung, Nutzung und Analyse von Daten zeigt. KI-Systeme können damit mediale Botschaften erzeugen, Inhalte auswählen und zu nutzende Angebote steuern, also Tätigkeiten, die bisher nur vom Menschen ausgeübt werden konnten.

Tulodziecki (2021) verweist darüber hinaus für den Einsatz von technisch autonomen KI-Systemen auf die Bedeutung des Einzelnen im Prozess der Entwicklung

und in der Nutzung hin. Wesentliche Kennzeichen sind Leitkriterien wie sachgerechtes, selbstbestimmtes, kreatives Handeln und soziale Verantwortung. Diese Aspekte sind nicht neu, allerdings werden diese im Rahmen der Entwicklung und Nutzung weitaus zentraler, wenn man bedenkt, dass KI-Systeme anschließend mit Menschen interagieren werden und hierfür das Vertrauen und der Schutz der Individuen eine zentrale Rolle spielen. Aufgabenstellungen für das Lernen und Lehren sollen demnach von Problemen, Entscheidungsfällen, Gestaltungs- und Beurteilungsaufgaben ausgehen und sind damit anschlussfähig an das forschende Lernen.

3.3 Recommender-Systeme als Werkzeuge forschenden Lernens


Für die Unterstützung von Lernenden können Recommender-Systeme als Softwaretools und Techniken eingesetzt werden, die auf eine Person zugeschnittene Empfehlungen zu bestimmten Aspekten geben (Ricci et al., 2015). Als Tool helfen sie, menschliches Lernen mit Künstlicher Intelligenz zu fördern. Recommender-Systeme können Lernwege analysieren und optimieren sowie Empfehlungen auf Datenbasis und -analyse auszusprechen. Ausgehend von einer technologischen Systematisierung von Recommender-Systemen beschreiben Kerres und Buntis (2020), wie diese sich in Lern- und Lehrszenarien ausgestalten können bzw. welche Strategien sie dabei verfolgen. Es werden Experten-, Verhaltens-, Profil-, Kriterien- und soziale Empfehlungen unterschieden. Die Ausgestaltung und der Einsatz dieser Empfehlungen orientieren sich dabei an folgender Grundaussage: »Recommenders do not aim at regulating the learning process; they suggest learning paths and leave the decision to the learner: They offer recommendations but they do not enforce a predefined learning path.« (Kerres & Buntis, 2020, S. 103). Dass Recommender-Systeme Lernpfade empfehlen statt erzwingen und damit die Entscheidung dem/der Lernenden überlassen, ermöglicht eine didaktisch begründete Anbindung an das forschende Lernen. Zum einen bietet grundsätzlich die Zusammenarbeit mit einem KI-System in der Funktion als technologisches Unterstützungssystem und damit als Lernbegleitung neue Erfahrungen. Aus dieser Interaktion mit dem KI-System lassen sich Wirkungen auf zukünftige Handlungsdispositionen und -bereitschaft im Sinne der 21st Skills erwarten. Das KI-System wird hier also selbst zum Forschungsobjekt. Andererseits wird durch dessen Erprobung im Prozess des forschenden Lernens z.B. das Ziel eines Moduls wie die Erstellung der Hausarbeit gefördert. Die Studierenden entscheiden dann eigenständig, ob und wie sie den Empfehlungen folgen; es entsteht damit Raum für das erfahrungsorientierte Lernen. Im Folgenden wird die Entwicklung von Recommender-Systemen für diese individuelle Lernunterstützung anhand eines Initialprojekts exemplifiziert.

4 Forschendes Lernen mit KI im AI.EDU Research Lab

An der FernUniversität in Hagen ist ein semesterbegleitendes Pflichtmodul eines bildungswissenschaftlichen Bachelorstudiengangs auf das forschende Lernen ausgerichtet; hier ist die Verbindung von Lernen und Forschen für das didaktische Konzept leitend. Dieses Modul ist Forschungsgegenstand des AI.EDU Research Labs, das im Forschungsschwerpunkt D²L² der FernUniversität verortet ist und im Jahr 2018 als Initialprojekt zwischen dem DFKI und der FernUniversität startete. Von Beginn an verfolgen die Projektpartner insgesamt drei Szenarien: Im ersten Szenario steht das personalisierte Lernen über ein wissensbasiertes System in Kombination mit maschinellem Lernen und die Ausgestaltung eines Recommender-Systems im Zentrum. Das zweite Szenario betrachtet den gesamten Studienverlauf, untersucht mit Academic Analytics, Learning Analytics und maschinellem Lernen Muster für Studienerfolg und -misserfolg und zielt theoriegeleitet auf ein individuelles Unterstützungssystem zur Selbstregulation. Den Rahmen für das Initialprojekt bildet das dritte Szenario, indem bestehende ethische Rahmenrichtlinien gemeinsam mit den Studierenden beurteilt und für den eigenen Kontext angepasst werden, so dass ein Bewusstsein für dahinterliegende Prozesse und Methoden geschaffen wird.

Insbesondere das erste Szenario widmet sich den Möglichkeiten von KI für das forschende Lernen. In Anlehnung an Wildt (2009) findet im Semesterverlauf des genannten Pflichtmoduls eine Zusammenführung eines typischen Forschungszyklus mit Kolbs »Lernzyklus« statt, indem eine Einteilung des Semesters in drei Phasen mit entsprechender Zuordnung zum Lern- und Forschungsprozess erfolgt (s. Abb. 2).

Abbildung 2: Semesterphasen in Relation zu den Phasen des forschenden Lernens.



In der ersten Phase wird an den vorhandenen Erfahrungen angeknüpft, das Wissen erweitert und vertieft bzw. das Themenfeld erkundet, indem Studienbriefe, die im Rahmen des Fernstudiums der FernUniversität in Hagen die zentralen Studieninhalte darstellen, im Selbststudium aufzubereiten sind. Eine Betreuung findet über das Lernmanagementsystem Moodle statt. In der zweiten Phase erarbeiten die Studierenden eigenständig ein Konzept für ihre Hausarbeit (Benennung des Themas, Fragestellung, vorläufige Gliederung). Die Aufgabe geht mit einer 1:1-Betreuung in Moodle durch die Lehrenden einher, die die dritte Phase, das Schreiben der Hausarbeit, begleiten, so dass durch diese Kombination der individuelle Erfolg der Studierenden ermöglicht wird.

Die Unterstützung der Studierenden an der FernUniversität erhält über die Bedingungen des Fernstudiums eine besondere Bedeutung. 78 % der Studierenden im Bachelorstudium sind berufstätig, damit einher gehen zeitliche Einschränkungen und variierende Studienzeiten. Mit dem Altersschwerpunkt zwischen 29 und 35 Jahren kommen darüber hinaus diverse Lern- und Berufsbiografien zusammen, die unterschiedliche Unterstützungsbedarfe nach sich ziehen. Ein hohes Maß an Selbstregulation mit angemessenen Lernstrategien sind für ein erfolgreiches Abschließen des Studiums unabdingbar. Der Einsatz eines Recommender-Systems setzt an dieser Stelle an und stellt neben der Lehrperson eine weitere Unterstützungsmöglichkeit der Studierende dar (siehe Kap. 3.3). Gleichzeitig ist damit die Erwartung auf Seiten der Lehrenden verbunden, durch die technologische Unterstützung der Studierenden mehr Zeit für einen intensiveren inhaltlichen Austausch zu bekommen.

Für die folgende Darstellung der KI-Anwendungen, die in dem Modul und damit innerhalb des ersten Szenarios zum Einsatz kommen, wird eine Systematisierung zugrunde gelegt, die bei KI-gestützten Bildungstechnologien zwischen der Repräsentationsform, dem Ziel des Systemeinsatzes und der Form von Künstlicher Intelligenz unterscheidet (Pinkwart & Beudt, 2020). Umrahmt ist diese Systematisierung jeweils mit einer kurzen Beschreibung der Anwendung und einer Darlegung des aktuellen Fortschritts mit einem Ausblick.

4.1 Automatic Assessment Tool – AAT

Zu Beginn des Semesters in der letzten Studienphase analysiert ein AAT, ein automatisches Assessment Tool, das Vorwissen der Studierenden anhand von Fragen für Freitextantworten. Der inhaltliche Schwerpunkt ist an ein inhaltlich anknüpfendes Modul der ersten Studienphase angelehnt und dient der Feststellung relevanter Vorkenntnisse des bevorstehenden Semesters. Das System bewertet die Antworten der Studierenden, markiert zentrale Aussagen im Text, verweist auf ähnliche Antworten anderer Studierenden und empfiehlt relevante Konzepte und Textstellen, die entweder zur Reflexion der Antwort dienen oder weiterführende Inhalte behandeln. Das AAT wurde als Standalone Web-Applikation mit dem Flask Framework in Python entwickelt und wird nun als Moodle-Plugin in das laufende Lernmanagementsystem integriert.

Aus Perspektive des forschenden Lernens dient das Vorwissen der Auseinandersetzung mit dem thematischen Feld. Nur durch eine gute Übersicht über das Fachgebiet und entsprechende Kenntnis ist es Studierenden möglich, einer eigenen Forschungsfrage nachgehen zu können. Aus Systemsicht sind die Testfragen ein erster Kontakt zu den Lernenden, indem zunächst der Wissensstand überprüft, hiervon ausgehend Empfehlungen zum weiteren Lernen gegeben werden können und die Fragen mit den Inhalten der Studienbriefe in Verbindung stehen. Diese Informationen werden dann auch für die Erweiterung des Lernendenmodells im wissensbasierten System genutzt, das dem Empfehlungssystem zugrunde liegt.

Die KI-Anwendung

- bewertet die studentischen Antworten: Antworten werden durch automatische Klassifizierung der Studierendenantworten mit maschinellen Lernmodellen ausgewertet.
- hebt die Antworten der Studierenden hervor: Die Hervorhebungen geben spezifische positive und negative Rückmeldungen und reflektieren direkt den aktuellen Wissensstand bzw. das erreichte Wissensniveau.
- gibt Empfehlungen auf der Basis ähnlicher Studierendenantworten: Besonders gelungene Antworten von Studierenden mit ähnlichen Studierendenprofilen

(beispielsweise Teilzeitstudierende mit ähnlichem Studienplan) werden als Empfehlung angezeigt.

- kann verschiedene Empfehlungsrichtungen einschlagen: Empfehlungen werden auf der Basis des identifizierten fehlenden Wissens gegeben und verweisen dann entweder auf nachzuziehende Inhalte oder auf weiterführende Lerninhalte im Anschluss an das bestehende Wissen. Das KI-System agiert auf der Grundlage der selbstentwickelten Domänen-, Lernenden und Didaktikmodellen, die vollständig miteinander verbunden sind. Für die Domäne als auch für das Lernenden-Modell sind Ontologien verfügbar. Zentral ist die Anbindung an die Domäne des Moduls, so dass anschließend weiterführende und erläuternde Empfehlungen gegeben werden können und so die inhaltliche Ausrichtung des Moduls angeeignet wird.

Die zweite Version des AAT-Prototypen liegt vor, das Moodle Plug-In ist entwickelt und im Laufe des kommenden Wintersemesters wird eine erste Testung mit Studierenden erfolgen. Das AAT wird unter Gesichtspunkten der KI-Akzeptanz, motivationaler Aspekte, der Systemfunktionen, der Lernleistung Studierender und der User Experience (UX) evaluiert. Die Benutzeroberfläche ist für Studierende fertiggestellt; ein Konzept für die Lehrenden-Benutzeroberfläche ist in der Entwicklung.

4.2 Intelligent Feedback for Student Exercises – IFSE

Die Anwendung des Intelligent Feedback for Student Exercises, IFSE, besteht aus einer Unterstützung von Studierenden und Lehrenden. Studierenden werden Quizze für eine Wissensstandserhebung angeboten. Anschließend erhalten sie ein korrekatives Feedback. Basierend auf dem Domänenwissen, das in den erstellten Ontologien repräsentiert ist, wird darüber hinaus ein personalisiertes Feedback generiert. Damit sind sowohl Empfehlungen für weitere Lernschritte als auch die Anbindung der Textstellen zu den einzelnen Konzepten möglich. Zu falschen Antworten werden die relevanten Textstellen der Studienbriefe angeboten, zu richtigen Antworten werden weiterführende Inhalte aus der Ontologie mit direktem Bezug zu den Konzepten der zugehörigen Frage empfohlen. Für die Lehrenden wird es eine eigens generierte Ansicht geben, um kontinuierlich neue Quizze zu erstellen und gleichzeitig die Anbindung an das Wissensbasierte System durch die Nennung von Konzepten der Ontologie zu gewährleisten. Das IFSE ist eine KI-basierte Quiz-Web-Applikation, die direkt als Moodle Plugin für das Lernmanagementsystem entwickelt wurde. Es enthält je eine Ansicht für die Studierenden und die Lehrenden.

Ebenso wie das AAT bezieht diese Anwendung die erste Phase des Semesters – die eigenständige Erarbeitung der Inhalte der Studienbriefe mit ein. Das IFSE dient der Reflexion der Studierenden über ihren aktuellen Wissensstand. Mit der anhal-

tenden Interaktion mit dem KI-System werden darüber hinaus Kompetenzen im Umgang mit KI-gestützten Empfehlungen erworben. Die Bearbeitung der Quizze sowohl über das AAT als auch das IFSE bieten die Möglichkeit, den Wissensstand der Studierenden zu erheben und in das Studierendenmodell zu übernehmen und zu visualisieren. Die KI-Anwendung

- trennt Fragen und Antwortoptionen: Die Quizfragen sind von den Antwortoptionen getrennt in zwei Pools gespeichert. Darüber hinaus ist jede Frage und jede Antwortoption mit einem Konzept oder Lernobjekt verbunden (dies ist über einen Wissensgraph definiert, der gerade getestet wird).
- wählt Quiz-Fragen aus: Der KI-Quiz-Algorithmus generiert verschiedene Sets von Quizzen für die Studierenden, abhängig von ihrer Leistung in vorhergehenden Quiz-Antworten. Nachfolgende Fragen werden dynamisch und intelligent in ihrem Schwierigkeitsgrad angepasst und auf das Wissensniveau der Studierenden bezogen.
- gibt Quiz-Rückmeldungen: Direkte individuelle Rückmeldungen und Empfehlungen zu den Quizzen werden automatisch generiert und angezeigt.

Aktuell befinden sich die KI-Anwendungen in der ersten von drei Phasen, in welcher der Algorithmus auf den wissensbasierten semantischen Regeln basiert und auch weitere innovative Ansätze einbezieht. Sobald die Anwendung im Einsatz ist und von Studierenden genutzt wird – das ist die zweite Phase –, werden verschiedene Arten von Lehr- und Lerndaten gesammelt, so dass in der dritten Phase sich der Algorithmus von einem regelbasierten auf einen datenzentrierten Ansatz verlagert und Machine Learning-Modelle und Neuronale Netze in den realen Lernkontexten angewendet werden. Das IFSE ist aktuell in der Entwicklung; eine erste Version für den Testeinsatz ist für das kommende Wintersemester geplant.

4.3 Structural Assistant for Term Paper – SAT

Unterstützt durch die Systeme AAT und IFSE verfügen die Studierenden über eine adäquate Wissensbasis und ein grundlegendes Verständnis der Kursinhalte. Daher wird in der nächsten Studienphase die Erarbeitung der Hausarbeit begonnen. Der SAT unterstützt die Erstellung der Gliederung der Hausarbeit, das spätere Schreiben und die mit einer Hausarbeit verbundenen strukturellen bzw. organisatorischen Planung. Der SAT ist als KI-basierter Chatbot geplant, der personalisiert die Arbeit der Studierenden an ihren Hausarbeiten unterstützend begleitet.

Jedes Semester kommen die Studierenden mit denselben Fragen auf die Lehrenden zu; deren Beantwortung soll nun mit einer entsprechenden KI-Anwendung die Lehrenden entlasten und damit mehr Zeit für die intensive 1:1 Betreuung als auch für weiterführende Lehrangebote bereit stellen. Darüber hinaus ist auch in der letzten

Bachelorphase das Schreiben einer Hausarbeit mit der Erarbeitung einer eigenen Forschungsfrage eine Herausforderung und bedarf weiterer Erprobung des wissenschaftlichen Schreibens. Hier bietet die Anwendung Unterstützung in Form von Informationen, Anbahnung kooperativen Austauschs und Hinleitung zu Übungsräumen an. Die KI-Anwendung

- wird durch einen KI-basierten Konversations-Chatbot als eine Art persönlicher Assistent repräsentiert,
- betreut Studierende bei der Strukturierung ihrer Hausarbeit und
- kommuniziert mit den Studierenden über Themen für die Hausarbeiten, gibt Hilfestellung für die Quellensammlung und die inhaltliche Tiefe der Ausarbeitung usw.

Ausgehend von den Anforderungen zum wissenschaftlichen Schreiben und den Tätigkeiten, die für die Erstellung einer Hausarbeit in dem Modul zentral sind, ist eine Ontologie »Hausarbeit schreiben« entstanden. Diese dient im nächsten Schritt gemeinsam mit einer Analyse der Fragen der Studierenden aus zwei Semestern als Grundlage für die Entwicklung der Use Cases und im Folgenden dann für den Prototypen.

Die Beschreibung der Anwendungen demonstriert die umfangreichen Arbeiten, die für den Einsatz von KI-basierten Empfehlungssystemen für forschendes Lernen in den universitären Regelbetrieb auf der Ebene des Semesterverlaufs notwendig sind. Gemeinsam ist ihnen eine personalisierte Lernunterstützung, die als Bestandteil eines umfassenden didaktischen Gesamtkonzepts zu verstehen ist, die Handlungsautonomie der Studierenden in Interaktion mit intelligenten Technologien fördern und ein Lernen ermöglichen will, das dem Eigeninteresse der Studierenden im Sinne des forschenden Lernens Rechnung trägt.

Dabei sind jedoch die Bedenken mit zu berücksichtigen, dass, je nachdem wie personalisierte Lerntechnologien entworfen, implementiert und bewertet werden, Empfehlungen eher für »Durchschnittsstudierende« zugeschnitten werden statt auf die individuellen Bedürfnisse der Lernenden eingegangen wird. Das Spannende werden daher die dauerhaften Einsätze sein. Dann wird sich zeigen, ob und wie Studierende mit personalisiertem Lernen beispielsweise ihre wissenschaftliche Qualifikation, aber auch ihre eigenen Bildungsziele erreichen.

5 Fazit: Künstliche Intelligenz und forschendes Lernen – eine passende Kombination unter bestimmten Bedingungen

Künstliche Intelligenz bietet für die Begleitung des forschenden Lernens im Hochschulstudium neue didaktische Interaktionsformen. Sie ermöglicht eine individua-

lisiertere Betreuung, bei gleichzeitiger Entlastung der Lehrenden von sich wiederholenden Aufgaben. Damit wird die Position der Lehrenden als Lernbegleitung für einen intensiven inhaltlichen Austausch gestärkt. Forschendes Lernen bietet einen Ansatz, der die Reflexions- und Urteilsfähigkeit der Studierenden bei der Interaktion mit dem Recommender-System und der Entwicklung einer Forschungsfrage trainiert. Forschendes Lernen beschreibt einen Lernprozess, der so weit wie möglich selbstbestimmt und selbstständig durchgeführt werden soll. Eine Begleitung und Unterstützung durch KI-Technologien, in ihren vielfältigen Formen, unterliegt damit aber der gleichen Kritik wie durch eine Lehrperson hinsichtlich des Spannungsfelds zwischen Selbst- und Fremdbestimmung. Eine Automatisierung von Rückmelde-, Bewertungs- oder Vermittlungsprozessen über KI-Anwendungen allein löst die Problematik nicht auf, sondern verschärft sie mitunter, wenn die Fremdbestimmung nicht hinreichend transparent ist.

Zawacki-Richter et al. (2019) zeigen auf, dass der Einsatz von KI in Bildungskontexten kaum von Bildungswissenschaftler:innen begleitet wird. Genau auf diesen Aspekt blickend, ist es zentral, die Anschlussfähigkeit von KI-Anwendungen an bestehende didaktische Konzepte wie das forschende Lehren zu prüfen. Aus bildungswissenschaftlicher Perspektive wird anhand der beschriebenen Anwendungen (AAT, IFSE und SAT) offenbar, dass für einen Einsatz von KI-Technologien Lernprozesse digital nachvollziehbar und abbildbar sein müssen; lediglich auf diese Weise werden Daten generiert und anschließend für personalisierte Angebote nutzbar. Eine wichtige Voraussetzung bei der Einführung und Implementation ist die interdisziplinäre Zusammenarbeit, die den Einsatz von KI-Technologien in einem bildungswissenschaftlichen Modul erst ermöglichen. Nur so ist ein sinnvoller und funktionierender Einsatz gewährleistet, der auch nach Beendigung des Forschungsprojekts die Übertragung in das Regelsystem der Hochschulen ermöglicht. Übertragung meint hier ebenfalls die Nutzung in anderen Modulen, so dass entsprechende Angebote für Hochschulen weiterhin nutzbar sind.

Neben den didaktischen und technologischen Aspekten sind im Laufe des Initialprojekts Rahmenbedingungen zu schaffen, die einer Langzeitaufgabe gleichen. Datenschutzrechtliche und ethische Grundlagen zum Schutz der Individuen sowie Akzeptanz und Bedarfe der Studierenden aus dem Lernkontext heraus sind zu berücksichtigen und zu untersuchen. Die Beschreibung der Rahmenbedingungen und der impliziten Forderungen an entsprechende Forschungsprojekte zeigt die Breite der Herausforderungen und zukünftige Aufgaben, für die im AI.EDU Research Projekt durch die drei Szenarien Lösungen erarbeitet werden.

Silke E. Wrede: FernUniversität in Hagen, CATALPA – Center of Advanced Technology for Assisted Learning and Predictive Analytics; silke.wrede@fernuni-hagen.de
Christina Gloerfeld: Dr., Universität Bremen; c.gloerfeld@uni-bremen.de

Claudia de Witt: FernUniversität in Hagen, Professor für Bildungstheorie und Medienpädagogik; claudia.dewitt@fernuni-hagen.de

Xia Wang: Dr., Deutsches Forschungszentrum für Künstliche Intelligenz (DFKI); xia.wang@dfki.de

Literatur

- Bellanca, J. A., & Brandt, R. (2010). 21st Century Skills: Rethinking How Students Learn. Solution Tree Press.
- Bogdanow, P., & Kauffeld, S. (2019). Forschendes Lernen. In S. Kauffeld & J. Othmer (Hg.), *Handbuch Innovative Lehre* (S. 143–149). Wiesbaden: Springer Fachmedien.
- Brinkmann, M. (Hg.). (2020). *Forschendes Lernen: Pädagogische Studien zur Konjunktur eines hochschuldidaktischen Konzepts. Phänomenologische Erziehungswissenschaft*, 10. Springer Fachmedien Wiesbaden.
- Christen, M., Mader, C., Čas, J., Abou-Chadi, T., Bernstein, A., Braun Binder, N., Dell'Aglio, D., Fábíán, L., George, D., Gohdes, A., Hilty, L., Kneer, M., Krieger-Lamina, J., Licht, H., Scherer, A., Som, C., Sutter, P. & Thouvenin, F. (2020). *Wenn Algorithmen für uns entscheiden: Chancen und Risiken der künstlichen Intelligenz* (1. Aufl.). vdf Hochschulverlag AG, ETH Zürich.
- Dede, C. (2010). Comparing frameworks for 21st century skills. In J. Bellanca, & R. Brandt (Eds.), *21st century skills: Rethinking how students learn* (S. 51–76). Bloomington: Solution Tree Press.
- Dewey, J. (1916/2011). *Democracy and Education/Demokratie und Erziehung*. New York/Weinheim Basel: Beltz.
- de Witt, C. & Czerwionka, T. (2013). *Mediendidaktik* (2. Aufl.). Studentexte für Erwachsenenbildung. Bielefeld: Bertelsmann.
- Ehlers, U.-D. (2019). Future Skills und Hochschulbildung »Future Skill Readiness«. In J. Hafer, M. Mauch & M. Schumann (Hg.), *Teilhabe in der digitalen Bildungswelt* (S. 37–48). Münster/New York: Waxmann Verlag.
- FernUniversität in Hagen. (2021, 15. Juli). Diversität. <https://www.fernuni-hagen.de/diversitaet/>.
- Hofhues, S. (2016). Forschendes Lernen mit digitalen Medien. In J. Lehmann & H. A. Mieg (Hg.), *Forschendes Lernen: Wie die Lehre in Universität und Fachhochschule erneuert werden kann* (S. 410–418). Frankfurt: Campus Verlag.
- Huber, L. (2014). *Forschungsbasiertes, Forschungsorientiertes, Forschendes Lernen: Alles dasselbe? Das Hochschulwesen*, 62(1/2), S. 32–39. <http://www.hochschulwesen.info/inhalte/hsw-1-2-2014.pdf>.

- Huber, L. & Reinmann, G. (2019). Vom forschungsnahen zum forschenden Lernen an Hochschulen. Wege der Bildung durch Wissenschaft. Wiesbaden: Springer VS.
- Kergel, D. & Heidkamp, B. (Hg.) (2016). Forschendes Lernen 2.0. Wiesbaden: Springer Fachmedien Wiesbaden.
- Kerres, M. & de Witt, C. (2002). Quo vadis Mediendidaktik? Zur theoretischen Fundierung von Mediendidaktik. MedienPädagogik. Zeitschrift für Theorie und Praxis der Medienbildung, Heft 6, S. 1–22.
- Kerres, M. & Buntins, K. (2020). Recommender in AI-enhanced Learning: An Assessment from the Perspective of Instructional Design. Open Education Studies, 2(1), S. 101–111.
- Lemay, D. J., Baek, C. & Doleck, T. (2021). Comparison of learning analytics and educational data mining: A topic modeling approach. Computers and Education: Artificial Intelligence, 2, 100016.
- Pinkwart, N. & Beudt, S. (2020). Künstliche Intelligenz als unterstützende Lerntechnologie. Fraunhofer IAO, Stuttgart. <http://publica.fraunhofer.de/dokumente/N-624584.html>.
- Ricci, F., Rokach, L. & Shapira, B. (2015). Recommender Systems: Introduction and Challenges. In F. Ricci, L. Rokach & B. Shapira (Eds.), Recommender Systems Handbook (S. 1–34). Springer US.
- Rotherham, A.J. & Willingham, D.T. (2010). »21st-Century« skills. Not new, but a worthy challenge. American Educator, 17–20. <https://www.aft.org/sites/default/files/periodicals/RotherhamWillingham.pdf>.
- Scheuer, D. (2020). Akzeptanz von Künstlicher Intelligenz: Grundlagen intelligenter KI-Assistenten und deren vertrauensvolle Nutzung. Wiesbaden: Springer.
- Schmoelz, A., Swertz, C., Forstner, A. & Barberi, A. (2014). Does Artificial Tutoring foster Inquiry Based Learning? Science Education International, 25(1), S. 123–129.
- Seidl, T. (2020). Hochschul(aus)bildung im Zeitalter der Digitalisierung – Ziele und Kompetenzanforderungen. In M. Friedrichsen & W. Wersig (Hg.), Synapsen Im Digitalen Informations- und Kommunikationsnetzwerk Ser. Digitale Kompetenz: Herausforderungen für Wissenschaft, Wirtschaft, Gesellschaft und Politik (S. 135–141). Springer Gabler.
- Siemens, G. (2013). Learning Analytics. American Behavioral Scientist, 57(10), S. 1380–1400.
- Straub, J., Ruppel, P. S., Plontke, S. & Frey, B. (2020). Forschendes Lernen an Universitäten: Prinzipien, Methoden, Best-Practices an der Ruhr-Universität Bochum (Research). Wiesbaden: Springer VS.
- Tulodziecki, G. (2021). Mediendidaktik angesichts künstlicher Intelligenz unter der Perspektive humanen Handelns. Medienimpulse, Bd. 59, Nr. 2. <https://journals.univie.ac.at/index.php/mp/article/view/6218/6116>.

- Wang, X. Gülenman, T., Pinkwart, N., de Witt, C., Gloerfeld, C. & Wrede, S. (2020). Automatic Assessment of Student Homework and Personalized Recommendation. 2020 IEEE 20th International Conference on Advanced Learning Technologies (ICALT), Tartu, Estonia, 2020, pp. 150–154.
- Wannemacher, K. & Bodmann, L. (2021). Künstliche Intelligenz an den Hochschulen: Potenziale und Herausforderungen in Forschung, Studium und Lehre sowie Curriculumentwicklung (Nr. 59). Hochschulforum Digitalisierung. https://hochschulforumdigitalisierung.de/sites/default/files/dateien/HFD_AP_59_Kuenstliche_Intelligenz_Hochschulen_HIS-HE.pdf.
- Wildt, J. (2009). Forschendes Lernen: Lernen im ›Format‹ der Forschung. *Journal Hochschuldidaktik* 20(2), S. 4–7.
- Zawacki-Richter, O., Marín, V. I., Bond, M. & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education—Where are the educators. *International Journal of Educational Technology in Higher Education* 16, 39(2019).

Künstliche Intelligenz zur Studienindividualisierung

Der Ansatz von SIDDATA

Maren Lübcke, Johannes Schrumpf, Funda Seyfeli-Özhizalan und Klaus Wannemacher

Abstract: Derzeit wird in unterschiedlichen Forschungszusammenhängen diskutiert, wie Studierende bei der Erreichung individueller Bildungsziele unterstützt werden können. Die Studienindividualisierung wird aktuell insbesondere im Zusammenhang mit der Fähigkeit zum eigenaktiven Studieren erörtert. Neben der Hochschulbildung bieten auch die Diskussion zum lebenslangen Lernen und zur weiteren Differenzierung von Lebensläufen wichtige Anknüpfungspunkte. Die Frage stellt sich jedoch, wie Studienindividualisierung trotz enger curricularer Strukturen ermöglicht werden kann und inwiefern hier auch eine technologische Unterstützung möglich ist. Diese Idee wird durch das BMBF-geförderte Projekt SIDDATA verfolgt. SIDDATA ist ein Studienassistenzsystem, das mit Hilfe von intelligenten und selbstlernenden Algorithmen adaptives und individuelles Studieren unterstützt. Im Fokus stehen KI-gestützte Module, die Studierenden dabei helfen, individuelle Interessen zu definieren und diese im Laufe ihres Studiums zu verfolgen. Dieser Beitrag beschäftigt sich mit dem Konzept des Moduls »Fachliche Interessen«, den darin verwendeten KI-Algorithmen, den ersten Erfahrungen mit Test und Einsatz dieses Moduls sowie mit den Potenzialen und Hindernissen für den Einsatz von KI zur Studienindividualisierung. Die Ergebnisse der ersten Testverfahren mit dem Modul bestätigen, dass der Einsatz von KI in dem digitalen Studienassistenten SIDDATA Möglichkeiten bietet, die Individualisierung im Studium zu fördern, und auf diese Weise einen Beitrag leistet, Potenziale der KI-gestützten Hochschulbildung zu entdecken und diese weiterzuentwickeln.

Self-regulated learning is an important aspect of lifelong and individual learning. In higher education however, the question arises how individualisation of study can be enabled despite narrow curricular structures and to what extent technological support is appropriate to achieve this aim. The idea of supporting an individualisation of study is being pursued by the BMBF-funded project SIDDATA. SIDDATA is a study assistance system that uses intelligent and self-learning algorithms to support adaptive and individualised studying. The focus is on AI-supported modules that help students define individual interests and pursue them throughout their studies. This paper deals with the idea behind the SIDDATA module »Specialised Interests«, the AI algorithms used, the first experiences with testing and using this module as well as with the potentials and obstacles higher education may have to face when using

AI to strengthen individual study approaches for their students. The results of the first test experiences with the module confirm that the use of AI in the digital study assistant SIDDATA offers opportunities to promote individualisation in studies and in this way contributes to discovering potentials of AI-supported higher education and development.

Keywords: Studienindividualisierung, Eigenaktives Studieren, Künstliche Intelligenz / Individualisation of Study, Self-regulated Learning, Artificial Intelligence.

Einleitung

Der Hype um die Möglichkeiten der Künstlichen Intelligenz (KI) macht auch vor der Hochschullandschaft nicht Halt. Grundsätzlich bieten alle Bereiche der Hochschulen die Möglichkeit, Technologien zu nutzen. So können Verwaltungen beispielsweise mit Hilfe von KI-Algorithmen neue Steuerungs- und Servicemöglichkeiten nutzen. Durch Nutzung von Chatbots und persönlichen Sprachassistenten können Verwaltungen ihre Dienste ausweiten oder Service-Roboter als digitale Assistenten einsetzen. In der Forschung verändern KI-Verfahren nicht nur Natur- und Technikwissenschaften, sondern auch Lebens-, Sozial- und Geisteswissenschaften. Verfahren des Machine und Deep Learning werden in verschiedenen Bereichen bereits erfolgreich angewendet. Die Anwendungsbereiche erstrecken sich dabei vom Generieren neuer Kunstwerke im Stil bekannter Künstler:innen aus Fotos (Ji et al., 2020) über das Spielen von Videospielen (Smenov et al., 2017) bis hin zur Erkennung von Lungenkrebs (Alakwaa et al., 2017).

Ein häufiges Einsatzgebiet ist zudem der Bereich des Lehrens und Lernens und der »Learning Analytics«, in dem mit Hilfe intelligenter, selbstlernender Algorithmen das Verständnis von Lernprozessen erweitert wird, um so adaptives und individuelles Lernen zu ermöglichen. In Orientierung an Baker und Smith (2019) unterscheiden Zawacki-Richter, Marin, Bond et al. (2020, S. 504) in diesem Bereich zwischen Anwendungen, die an die Lernenden gerichtet sind (z.B. ein intelligentes Tutoringsystem), Tools für Lehrende (z.B. ein Automated Essay Scoring-System) und Anwendungen, die der Hochschule Informationen liefern (z.B. ein Monitoringsystem zum Studienabbruchverhalten). Für den Bereich der Lernunterstützung bieten KI-Technologien damit eine Vielzahl potenzieller Anwendungsmöglichkeiten. Weniger stark diskutiert, aber ebenfalls ein wichtiges Thema ist die Unterstützung des Studiums selbst. Dabei kommt der Studienindividualisierung besondere Bedeutung zu. Die Studienindividualisierung in der Hochschulbildung wird in Zusammenhang mit der Fähigkeit zum eigenaktiven Studieren angesichts der Diskussionen zum lebenslangen Lernen und zur weiteren Differenzierung von Lebensläufen hohe Relevanz bemessen. Es ist eine der zentralen Zukunftskompetenzen:

»Future-ready students need to exercise agency, in their own education and throughout life. Agency implies a sense of responsibility to participate in the world and, in so doing, to influence people, events and circumstances for the better. Agency requires the ability to frame a guiding purpose and identify actions to achieve a goal.« (OECD, 2018, S. 4)

Die Frage stellt sich jedoch, wie Studienindividualisierung trotz enger curriculärer Strukturen ermöglicht werden kann und wie in diesem Zusammenhang eine KI-basierte Unterstützung möglich ist.

Eine Antwort darauf versucht das BMBF-geförderte Verbundprojekt SIDDATA »Studienindividualisierung durch digitale, datengestützte Assistenten« (<https://www.siddata.de/>) zu geben, an dem die Universitäten Osnabrück, Hannover und Bremen sowie HIS-HE beteiligt sind. Im Fokus steht die Entwicklung eines datengestützten Studienassistenten, der das Studieren, basierend auf personalisierten Empfehlungen, individueller werden lässt. Natürliche Sprachverarbeitungsverfahren sollen für die Analyse und Verarbeitung halbstrukturierter Daten, also Daten aus Campus- und Lernmanagementsystemen, die sowohl Metainformationen als auch einen weiter analysierbaren Inhalt enthalten, angewendet werden. KI-Komponenten helfen dabei, auf individuelle Interessen der Studierenden abgestimmte Inhalte anzuzeigen.

Anhand des konkreten Anwendungsfalls des Moduls »Fachliche Interessen« im Forschungsprojekt SIDDATA beschreibt der vorliegende Beitrag im Folgenden Konzept und Vorhaben hinter dem Modul (Abschnitt 2), die verwendeten KI-Algorithmen (Abschnitt 3) und die ersten Erfahrungen mit Test und Einsatz dieses Moduls (Abschnitt 4), um im Anschluss Potenziale und Hindernisse für den Einsatz von KI zur Studienindividualisierung zu reflektieren (Abschnitt 5). SIDDATA befindet sich im Mai 2021 noch im prototypischen Einsatz: Das Modul »Fachliche Interessen«, das den KI-Algorithmus verwendet, wird in der zweiten Prototypversion von über 1.500 Studierenden der drei Universitäten genutzt. Im Vorfeld war das Modul im Zuge eines Pre-Tests von einer ausgewählten Gruppe von Studierenden aus den drei Standorten erprobt worden. Die Erfahrungen des Pre-Tests mit diesem Modul vom Dezember 2020 vermitteln interessante Erkenntnisse und Ausblicke auf die Möglichkeiten der Unterstützung von Studienindividualisierung durch den Einsatz von KI.

Eigenaktives Studieren und Studienindividualisierung

SIDDATA besteht aus einer Reihe von Modulen, die den Studierenden Unterstützung und Hilfestellung im Studienalltag bieten sollen. Das übergeordnete Ziel von SIDDATA ist dabei die Förderung von eigenaktivem Studieren (in der englischspra-

chigen Diskussion häufig als *self-regulated learning* (SRL) bezeichnet). Vor dem Hintergrund der Diskussionen zum lebenslangen Lernen und zur weiteren Differenzierung von Lebensläufen ist diese Fähigkeit eine der Schlüsselkompetenzen für gelingendes Studieren (Heublein et al., 2017, S. 147f.).

Das eigenaktive Studieren umfasst verschiedene Modelle, Formen und Grade individualisierten Studierens. Für Schmohl (2019) bedeutet selbstgesteuertes Lernen aus didaktischer Perspektive einen noch stärkeren Wechsel des Fokus von den Lerngegenständen zum Lernprozess selbst (Schmohl, 2019, S. 19f.). Ein einheitliches Verständnis davon fehlt jedoch. Zimmermann betont den Unterschied von Theorien des selbstregulierten Lernens zu anderen Lerntheorien:

»Self-regulated learning theories of academic achievement are distinctive from other accounts of learning and instruction by their emphasis (a) on how students select, organize, or create advantageous learning environments for themselves and (b) on how they plan and control the form and amount of their own instruction.« (Zimmerman, 1990, S. 13f.)

In dieser Definition von SRL ist der kognitionspsychologische Hintergrund der Theorie deutlich erkennbar. SRL impliziert ein regulatorisches Verständnis, bei dem die Studierenden ihre inneren und äußeren Zustände in Kongruenz bringen, um ihre eigenen Lernziele individuell und effektiv zu erreichen. Eine Erweiterung dieses Verständnisses wird jedoch erreicht, wenn SRL um das Konzept der *Agency* erweitert wird. *Agency* impliziert ein Gefühl der Verantwortung, an der Welt teilzunehmen und dabei Menschen, Ereignisse und Umstände zum Besseren zu beeinflussen. *Agency* erfordert die Fähigkeit, einen leitenden Zweck zu formulieren und Handlungen zu identifizieren, um ein Ziel zu erreichen, sowohl in der eigenen Bildung als auch im gesamten Leben (OECD, 2018, S. 4). Dieses umfassendere Verständnis entspricht mehr der Konnotation des deutschen Begriffs des eigenaktiven Studierens, bei dem es nicht nur um Regulation geht, sondern um aktives Gestalten. Von Studierenden werden in diesem Zusammenhang die oft strengen curricularen Vorgaben – darunter Pflichtveranstaltungen, vorgeschriebene Themen und Hausarbeiten – kritisiert. Studieren wird häufig als zu stark »verschult« empfunden (Lübcke et al., 2020a, 2020b). Es gebe einen Zwang, nach den Vorgaben von stark und restriktiv strukturierten Studienprogrammen zu studieren, welche ein Studieren im Sinne des eigenaktiven und selbstregulierten Lernens nicht zuließen.

Dabei reicht das eigenaktive Studieren über die reine Organisation des eigenen Lern- und Studienprozesses hinaus. Es geht darum, das Studium stärker zu individualisieren und selbstgewählte Wege einzuschlagen, zu reflektieren und ggf. zu ändern. Dies ist für viele Studierende der Kern des eigenaktiven Studierens: eigene Interessen zu entwickeln, aus einer großen Bandbreite an Möglichkeiten zu wählen und damit einen eigenen individuellen Studienverlauf zu entwickeln (ebenda).

Im Zentrum von SIDDATA stehen deshalb die folgenden Komponenten:

- Persönlichkeitsmodul
- Auslandssemester
- Matchmaking
- Fachliche Interessen

Das »Persönlichkeitsmodul« gibt kognitionspsychologische Hinweise auf Lernvorlieben und versucht, Studierende bei der Optimierung ihres Lernverhaltens zu unterstützen. Durch das Modul »Auslandssemester« sollen die Studierenden bei der Planung und Durchführung eines Auslandsaufenthaltes unterstützt werden. Das Modul »Matchmaking« zielt darauf ab, Studierende mit ähnlichen Interessen auch studiengangs- und standortübergreifend zu vernetzen und zu einem Erfahrungsaustausch anzuregen.

Das Modul »Fachliche Interessen« soll wiederum in zwei Richtungen wirken. Zum einen werden nach Angabe eigener fachlicher Interessen passgenaue Empfehlungen für Veranstaltungen, Seminare, Vorträge, doch auch für Open Educational Resources (OER) und Bücher gegeben. Zum anderen soll diese Komponente dazu dienen, die eigenen fachlichen Interessen stärker zu reflektieren und im Idealfall während des Studienverlaufs zu verfeinern, zu präzisieren oder auch zu modifizieren. Durch Nachfragen, Rückmeldungen und Wiedervorlage der angegebenen fachlichen Interessen will SIDDATA die Reflexion und Auseinandersetzung mit den eigenen Interessen stärken und zu einer Individualisierung des Studierens beitragen.

KI-Algorithmus

Das Modul »Fachliche Interessen« arbeitet KI-basiert. Den Kern dieses Systems bildet »SidBERT«, ein natürliches Sprachverarbeitungssystem auf Grundlage des Sprachverarbeitungssystems Google BERT. Google BERT (Bidirectional Encoder Representations from Transformers; vgl. Devlin et al., 2019) ist ein tiefes neuronales Netzwerk, welches auf der in Vaswani et al. (2017) beschriebenen Transformer-Architektur basiert. Im Vergleich zu anderen natürlichen Sprachverarbeitungsprogrammen erzielt BERT in verschiedenen Benchmarks eine hohe allgemeine Sprachverarbeitungsfähigkeit (Wang et al., 2018; Rajpurkar et al., 2016; Zellers et al., 2018). Die hier genutzte Version von BERT, BERT-base multilingual cased, wurde mittels Wikipedia-Artikeln in insgesamt 104 Sprachen vortrainiert und besitzt dadurch sowohl bereits ein Grundkorpus als auch die Fähigkeit, natürlichsprachliche Informationen syntaktisch und semantisch zu verarbeiten.¹

SidBERT ist damit in der Lage, Eingaben in natürlicher Sprache in eine von insgesamt 534 Wissenskategorien zu klassifizieren. Um Empfehlungen für Studieren-

1 Derzeit läuft SIDDATA nur auf Deutsch.

de nach Wissenskategorien zu generieren, wurde die deutsche Version des Dewey Decimal Classification (DDC) Systems genutzt. Die DDC ist ein in Bibliotheken verwendetes System zur Kategorisierung von Werken. Wissenskategorien innerhalb der DDC werden mit einem eindeutigen Code referenziert.²

Für SidBERT wurden ein Auszug der Bücher im Register der Deutschen Nationalbibliothek sowie die Bibliotheksregister der Universität Osnabrück und der Universität Bremen verwendet. Die Register wurden in einen Gesamtdatensatz zusammengefügt und doppelte Buchtitel sowie Buchtitel mit weniger als drei Zeichen entfernt. 534 DDC-Klassen wurden daraufhin ausgewählt, auf die SidBERT trainiert wurde. Die Auswahl erfolgte anhand statistischer Eigenschaften des Gesamtdatensatzes, sowie der Regel folgend, keine DDC-Klassen unter Level 3 zu nutzen, da diese in der Regel zu allgemein sind, um für die Ziele von SIDDATA nützlich zu sein.³

Die verbleibenden Klassen mit Level ≥ 3 wurden anhand ihrer Verteilungseigenschaften ausgewählt: So wurden DDC-Klassen aufgenommen, die mindestens 250 Buchtitel enthalten. Um eine ungleichmäßige Verteilung der Buchtitel innerhalb der verschiedenen DDC-Klassen zu vermeiden, wurden bis zu 750 Buchtitel für eine DDC-Klasse ausgewählt.

Die Aufgabe von SidBERT ist es, Bildungsressourcen wie z.B. OER, Kurse oder Einzelveranstaltungen sowie zuvor abgefragte Studierendeninteressen in Form von natürlichen Spracheingaben in eine der 534 DDC-Kategorien zu klassifizieren. Um dies zu leisten, besitzt SidBERT neben der BERT-Architektur von 12 Transformer-Encoder-blocks einen sogenannten classification head. Die Transformer-Encoder-Decoder-blocks enthalten die vortrainierten Neuronen des BERT-base-Netzwerkes und verarbeiten einen eingegebenen Text vor. Der classification head besteht aus weiteren Netzwerkschichten (Layers), um eine höhere Kategorisierungspräzision (Performanz) des gesamten Netzwerks zu erzielen und um den Output des Netzwerks einer DDC-Kategorie zuzuordnen zu können. Dieses Vorgehen folgt der Annahme, dass es lediglich einen vernachlässigbaren Unterschied von Buchtiteln in DDC-Klassen zu Titeln von anderen Bildungsressourcen, die das gleiche Thema behandeln, gibt. Um SidBERT zum Klassifizieren von Bildungsressourcen verwenden zu können, muss SidBERT trainiert werden. Dies geschieht, indem der Trainingsdatensatz durchlaufen wird und basierend auf den Fehleinschätzungen des Netzwerkes dessen Parameter angepasst werden. Durch das mehrfache Durchlaufen des Da-

2 So besitzt die Kategorie »Künstliche Intelligenz und Natural Computing« beispielsweise den DDC-Code »006.3«. Die DDC ist nach einem hierarchischem Baumsystem aufgebaut. Dies bedeutet, dass die Wissenskategorie »006.3« eine Unterkategorie der Elternkategorie »006«, »Spezielle Computerverfahren«, ist. Diese ist wiederum eine Unterkategorie in der Elternkategorie »00«, »Informatik, Wissen & Systeme«.

3 Ein Beispiel hierfür ist die Klasse »15«, »Psychologie« oder Klasse »63«, »Landwirtschaft«.

tensatzes kann so die Fehlerrate minimiert werden. Ein Durchlauf eines Trainingsdatensatzes entspricht dabei einer sogenannten »Epoche«.

Insgesamt wird das Modell für zwölf Epochen trainiert: In den ersten zehn Epochen sind die Parameter für den BERT-basierten Anteil eingefroren, das heißt, dass während des Trainings lediglich der classification head trainiert wird, indem dieser die vorverarbeiteten Informationen aus dem BERT-basierten Netzwerk erhält und dann interpretiert. Diese Vorgehensweise basiert auf Erkenntnissen von Lee et al. (2019). Nach zehn Epochen hat der classification head ein lokales Optimum erreicht, sodass das gesamte Netzwerk inklusive der Parameter im BERT-basierten Teil des Netzwerks trainiert wird. Dies führt dazu, dass sich das Netzwerk stärker auf die für die Klassifikation wichtigen Faktoren wie Sprache einstellen kann, ohne die allgemeine Sprachverarbeitungsfähigkeit zu verlieren. Diese Tandem-Training-Strategie führt zu einer Klassifikationspräzision von $\sim 44,8\%$ auf dem Testdatensatz. Der Trainingsprozess benötigt rund 21 Tage.

Bewertung durch die Studierenden

Im Januar 2021 wurde SIDDATA an den Universitäten Bremen, Hannover und Osnabrück als Stud.IP-Plugin freigeschaltet. Die Aktivierung des Plugins und der einzelnen SIDDATA-Module ist den Studierenden freigestellt. Auch die Erhebung und Verarbeitung der Datenquellen, die Grundlage der Empfehlungen des Studienassistenten sind, bestimmen die Nutzenden selbst. Mitte Dezember 2020 wurde das Modul »Fachliche Interessen« als Pre-Test vorab für einen kleinen Nutzendenkreis freigeschaltet. In dieser Pre-Test-Phase beinhaltete das Modul »Fachliche Interessen« Veranstaltungsempfehlungen der drei Standorte, jedoch keine Hinweise auf andere Bildungsressourcen.

Mitte Dezember wurden Studierende, die über die Projektpartner:innen an den drei Standorten rekrutiert wurden, mit der Bitte kontaktiert, das Modul »Fachliche Interessen« zur Gestaltung des eigenen Semesterplans genauer zu erkunden und anschließend einen Online-Fragebogen im Sinne eines Pre-Tests zu bewerten.

Neben demografischen Angaben wurden in dem Themenblock *Nutzungserfahrungen* allgemeine Fragen zum Moduleinsatz wie Zufriedenheit, Nutzen und Relevanz sowie auch KI-orientierte Fragestellungen im Hinblick auf eine intelligente Konstruktion gestellt.⁴

4 Beispielfrage: »Wie stark würde sich Dein Semesterplan von Deinem jetzigen unterscheiden, wenn Du SIDDATA schon zu Beginn des Semesters eingesetzt hättest?« Antwortoptionen: sehr stark, eher stark, eher weniger, überhaupt nicht.

Gruppe der Befragten

An dem Pre-Test haben insgesamt 15 Studierende teilgenommen (71,4 % von der Leibniz Universität Hannover, 21,4 % von der Universität Bremen und 7,1 % von der Universität Osnabrück). Die sehr geringe Teilnehmendenzahl ist auch darauf zurückzuführen, dass durch Verzögerungen in der Freischaltung von SIDDATA erst kurz vor Weihnachten 2020 mit der Rekrutierung begonnen werden konnte. Die folgenden Angaben können vor diesem Hintergrund lediglich als erste Anhaltspunkte interpretiert werden.

Die Mehrheit der Teilnehmenden (57,1 %) sind Studierende eines Bachelorstudiengangs, 42,9 % Studierende eines Masterstudiengangs. Die Befragten kommen aus den Studiengängen der Wirtschaftswissenschaften, Sozialwissenschaften, Chemie, Informatik und aus dem konstruktiven Ingenieurbau. Die Teilnehmenden befinden sich überwiegend in der fortgeschrittenen Studienphase (79,6 % im 5. Semester oder höher). Nur 21,4 % befinden sich hingegen in der Studieneingangsphase (1. Semester). Dass das Feedback zum Modul »Fachliche Interessen« vor allem aus der Gruppe der älteren Studierenden kommt, ist insofern erfreulich, als anzunehmen ist, dass diese Gruppe bereits eigene fachliche Interessen entwickelt hat und routiniert in der Stundenplanung ist. Folglich können die von SidBERT empfohlenen Veranstaltungen durchaus auf Eignung bewertet werden.

Ergebnisse der Befragung

Die Teilnehmenden gaben an, jeweils 1 bis 15 fachliche Interessen formuliert zu haben. Im Durchschnitt wurden fünf fachliche Interessen angegeben. Während rund 71,5 % der Studierenden angaben, dass ihnen die Formulierung von fachlichen Interessen leicht (50 %) bis sehr leicht (21,5 %) gefallen ist, fiel es rund 28,5 % der Studierenden schwer (21,4 %) bis sehr schwer (7,1 %), individuelle Interessen zu formulieren. Es gibt also – trotz der geringen Teilnehmendenzahl – erste Hinweise darauf, dass doch ein relativ großer Anteil an Studierenden Schwierigkeiten hat, solche Interessen zu formulieren.


Qualität der Empfehlungen

Auf Basis der angegebenen Interessen erhielten die Studierenden Veranstaltungsempfehlungen. Die Zufriedenheit mit den Empfehlungen ergibt ein geteiltes Bild: Rund die Hälfte der Studierenden äußerte sich positiv. Demgegenüber waren rund 50 % unzufrieden mit den empfohlenen Veranstaltungen. Dieses Ergebnis wirkt sich zudem direkt auf die Wahrnehmung der Nützlichkeit des Moduls aus. Insgesamt gab die Hälfte der teilnehmenden Studierenden an, dass das Modul einen hohen Nutzen für ihr Studium habe (7,1 % »stimme voll zu«, 42,9 % »stimme eher zu«), wäh-

rend für die andere Hälfte der Befragten das Modul »Fachliche Interessen« keinen hohen Nutzen hatte.

SidBERT war immerhin nach Einschätzung von 64,3 % der Befragten in der Lage, diese auf neue Veranstaltungen aufmerksam zu machen, die sie zuvor nicht berücksichtigt hatten. Dies hätte aber nur bei 21,4 % tatsächlich zu einem anderen Semesterplan geführt, wenn SIDDATA zu diesem Zeitpunkt schon zur Verfügung gestanden hätte. 42,9 % der Studierenden gaben demnach an, dass sich ihr Semesterplan mit der Unterstützung von SIDDATA nicht anders darstellen würde als ohne.

Abbildung 1: Einfluss auf die Semesterplanung durch das Modul »Fachliche Interessen«.



Die durchaus gemischte Beurteilung des Moduls »Fachliche Interessen« durch die Studierenden hatte sich bereits während des Trainings des SidBERT-Netzwerkes angedeutet. Mit 44,8 % Klassifikationspräzision ist die Performanz von SidBERT auf dem Validierungsdatensatz signifikant unter anderen Performanzen von BERT-Architekturen in anderen Aufgabendomänen. Des Weiteren ist SidBERT mit 534 DDC-Klassen nicht in der Lage, eine besonders feine Granularität der vorgeschlagenen Bildungsressourcen zu erreichen. Beide Kritikpunkte lassen sich auf den von uns verwendeten Datensatz zurückführen: Mit einer höheren Anzahl an Trainingsdaten pro Klasse könnte die Performanz von SidBERT gesteigert werden. Gleichzeitig könnte eine höhere Anzahl an Buchtiteln es ermöglichen, mehr DDC-Klassen in SidBERT einzubinden, was eine feinere Granularität in der Klassifizierung von Studienzielen und Bildungsressourcen ermöglichen würde.

Reflexion

Neben dem Empfehlen konkreter Veranstaltungen sollte das Modul »Fachliche Interessen« den Reflexionsprozess der Studierenden zu den eigenen fachlichen Interessen anstoßen. Dies scheint weitestgehend gelungen zu sein: 64,3 % der Befragten geben an, zuvor genannte fachliche Interessen auf Basis der vorgeschlagenen Veranstaltungen modifiziert zu haben. Immerhin knapp ein Drittel (28,5 %) der Studierenden gab an, dass ihnen die Formulierung von fachlichen Interessen schwer bis sehr schwer gefallen sei. Bei 64,3 % der Befragten hat die Frage eine Reflexion über die eigenen fachlichen Interessen angestoßen (21,4 % »stimme voll zu«, 42,9 % »stimme eher zu«). Damit also das KI-Modul richtig funktionieren kann, müssen Studierende bei Bedarf Hilfestellungen zur Formulierung der eigenen fachlichen Interessen erhalten. Denn nur wenn diese richtig benannt sind, kann SIDDATA zufriedenstellende Empfehlungen generieren.

In den offenen Fragen nach dem Mehrwert dieses Moduls kann somit auf diesen Reflexionsaspekt verwiesen werden. Die Möglichkeit, basierend auf eigenen Interessen Veranstaltungsempfehlungen zu erhalten, ermögliche es, »[a]ndere Blickwinkel einzuschlagen« (Auszug aus einem studentischen Eintrag in das Kommentarfeld »Was hat Dir bei der Funktion »Fachliche Interessen« gefallen?«).

Wahrnehmung des Moduls »Fachliche Interessen«

So gemischt die Ergebnisse bewertet wurden, fällt auch die generelle Einschätzung des dahinter liegenden Algorithmus aus. 57,2 % der Befragten geben an, dass das Modul basierend auf eigenen Einträgen individuelle Empfehlungen gibt und damit intelligent konstruiert ist (14,3 % »stimme voll zu«, 42,9 % »stimme eher zu«). 42,9 % können dieser Aussage dagegen nicht zustimmen. Es scheint tendenziell aber ein generelles Interesse an dieser Art der Studierendenunterstützung zu geben (64,3 %). So ist ein solches Angebot nur für rund ein Drittel der Befragten (35,7 %) von geringem Interesse.

Diskussion

Der Grundansatz des SIDDATA-Projekts, Anwendungen aus dem Bereich KI für die Studienunterstützung zu entwickeln und datengestützte Assistenzsysteme einzusetzen, um ein eigenaktives und individuelleres Studium zu ermöglichen, scheint sich anhand erster Erfahrungen mit dem Einsatz des Moduls »Fachliche Interessen« zu bestätigen. Studierende scheinen entsprechende Anwendungen im Grundsatz zu akzeptieren: für 64,3 % der befragten Studierenden ist das KI-basierte Modul von Interesse; 50,0 % attestierten dem Modul bereits einen hohen bis sehr hohen Nut-

zen. Angesichts der Limitationen des durchgeführten Pre-Tests unter ausgewählten Studierenden an den drei Standorten wie einer geringen Teilnehmendenzahl sollen Folgeerhebungen weiteren Aufschluss über studentische Nutzungserfahrungen und die Wahrnehmung des Nutzens des Moduls geben. Bedeutsam erscheint jedoch schon jetzt die Erkenntnis, dass Module, die natürlichsprachliche Eingaben von Nutzenden verarbeiten, eine gute und didaktisch sinnvolle Nutzerunterstützung benötigen. In diesem Fall müssen Studierende in der Lage sein, eigene fachliche Interessen zu formulieren, was keinesfalls eine Selbstverständlichkeit darstellt. Nur wenn man hier Unterstützungsangebote gerade für Studierende der ersten Semester anbietet, können gute Empfehlungen generiert werden. Ansonsten gilt das Motto »garbage in – garbage out«.

Als Herausforderung erweist sich die Notwendigkeit, entsprechende KI-basierte Module bzw. Machine-Learning-Modelle über einen gewissen Zeitraum zu trainieren, bevor sie produktiv verwendet werden können. Je ausgiebiger das Modell anhand einer erheblichen Menge von Daten und Trainingsiterationen kalibriert und nachjustiert wird, desto zufriedenstellender dürften Ergebnisse aus Sicht der Studierenden ausfallen. Eine hierfür wichtige Grundvoraussetzung ist die Verfügbarkeit hinreichend großer Datensätze, die die Struktur der DDC repräsentieren. Je größer die Anzahl der genutzten Buchtitel zum Trainieren der Anwendung und zur Ausdifferenzierung der Klassifizierung von Studienzielen und Bildungsressourcen ist und je mehr das System im Live-Betrieb eingesetzt wird, desto besser kann der Algorithmus werden und desto hilfreicher können Empfehlungen ausfallen.

Während die DDC an sich durch ihren hohen Grad an Kuratierung gut für Machine-Learning-Modelle geeignet ist, bieten große Archive wie die Deutsche Nationalbibliothek keine digitalen Schnittstellen, um einen hinreichend großen Datensatz für das Trainieren von Machine-Learning-Modellen zu generieren. Lokale Universitätsbibliotheken, die ein digitales Register der geführten Werke leicht zur Verfügung stellen können, besitzen in der Regel hingegen lediglich ein kleines Korpus an Werken, die die DDC nicht hinreichend abdecken. Um in Zukunft eine zufriedenstellende Granularität der in diesem Modul verwendeten DDC-Klassen sicherzustellen, müssen solche Schnittstellen geschaffen und genutzt werden.

Auch die Ausweitung auf andere Bildungsressourcen wie OER, Einzelvorträge oder einzelne Veranstaltungen innerhalb eines Kurses wird den subjektiv wahrgenommenen Nutzen und das Potenzial dieser Funktion verbessern. Die aus dem Pre-Test gewonnenen ersten positiven Rückmeldungen von Studierenden aller drei beteiligten Universitäten deuten gegenwärtig daraufhin, dass KI-basierende und ausgiebig mit geeigneten Datensätzen trainierte Studienassistenten tatsächlich helfen können, Möglichkeiten und Spielräume im Studium aufzuzeigen und dadurch zu einer stärkeren Individualisierung beitragen.

Da Potenziale der Nutzung von KI-Komponenten für die Unterstützung Studierender zwar auch in anderen Kontexten diskutiert werden (beispielsweise die

Nutzung eines KI-basierten mobilen Avatars als Coaching-Assistent für die psychologische Unterstützung Studierender oder die Nutzung eines KI-basierten Tutors in Großveranstaltungen, s. Wannemacher & Bodmann, 2021, S. 16, 30f.), jedoch kaum im Hinblick auf den Aspekt der Studienindividualisierung im Engeren, der bei SIDDATA im Vordergrund steht, lassen sich bislang nur sehr eingeschränkt Bezüge des spezifischen Ansatzes und der ersten Evaluationsergebnisse bei SIDDATA zu anderen Forschungsprojekten darstellen. Angesichts der bislang begrenzten Reichweite der Nutzung des Studienassistenten durch eine begrenzte Gruppe von Studierenden an wenigen Hochschulen erscheint eine Validierung der Ergebnisse des Pre-Tests sinnvoll, sobald sich die Nutzung des Systems auf einen breiteren Kreis von Studierenden erweitert hat. Entsprechende Möglichkeiten zeichnen sich in Zusammenhang mit der Verfeinerung des »Fachliche Interessen«-Moduls und weiterer Kernfunktionen des Systems im Rahmen eines weiteren Prototyps und der in diesem Zusammenhang angestrebten breiteren Dissemination des Systems an den Hochschulen ab.

Ausblick

Zukünftige Weiterentwicklungen des »Fachliche Interessen«-Moduls von SIDDATA sollen sowohl individueller als auch reflexiver werden: Mit einer kontextsensitiven Filterung könnten so z. B. nur fachliche Ressourcen empfohlen werden, die dem Wissensstand der Studierenden im jeweiligen Gebiet entsprechen oder die einen möglichst hohen Grad an Differenz in ihren epistemologischen Grundannahmen innerhalb eines Feldes aufweisen. Dies würde dazu beitragen, dass die empfohlenen fachlichen Ressourcen insgesamt noch genauer mit fachlichen Interessen der Studierenden korrespondieren. Eine kontextsensitive Filterung verfügbarer Ressourcen würde die Auswahl geeigneter Studien- und Lernangebote dadurch weiter vereinfachen, dass Studierenden passendere Ressourcen angeboten würden.

Zusätzlich werden die Daten aus dem »Fachliche Interessen«-Modul auch zur Selbstreflexion des eigenen Bildungsweges beitragen, indem die bereits genutzten Bildungsressourcen visuell innerhalb der DDC-Baumstruktur dargestellt und Trends im eigenen Studium erkannt werden können. In Verbindung mit einem allgemeinen Fragebogen zur Reflexion von Studienzielen könnten Studierende hierdurch noch selbstbestimmter ihre Semesterplanung eigenen Interessen anpassen.

Maren Lübcke: HIS-Institut für Hochschulentwicklung, Geschäftsbereich Hochschulmanagement; luebcke@his-he.de

Johannes Schrumpf: Universität Osnabrück, Institut für Kognitionswissenschaft; jschrumpf@uni-osnabrueck.de

Funda Seyfeli-Özhizalan: HIS-Institut für Hochschulentwicklung, Geschäftsbereich Hochschulmanagement; seyfeli@his-he.de

Klaus Wannemacher: HIS-Institut für Hochschulentwicklung, Geschäftsbereich Hochschulmanagement; wannemacher@his-he.de

Literatur

- Alakwaa, W.; Nassef, M.; Badr, A.: Lung cancer detection and classification with 3D convolutional neural network (3D-CNN). In: International Journal of Biology and Biomedical Engineering Bd. 11 (2017), Nr. 8, S. 66–73.
- Baker, T. & Smith, L. (2019). Educ-AI-tion Rebooted? Exploring the future of artificial intelligence in schools and colleges. Nesta Foundation. Abgerufen 15.12.2020, von https://media.nesta.org.uk/documents/Future_of_AI_and_education_v5_WEB.pdf.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. NAACL HLT 2019 – 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies – Proceedings of the Conference, 1(Mlm), S. 4171–4186.
- Heublein, U., Ebert, J., Hutzsch, C., Isleib, S., König, R., Richter, J., & Woisch, A. (2017). Zwischen Studiererwartungen und Studienwirklichkeit (Bd. 1). German Centre for Higher Education Research and Science Studies (DZHW), S. 147f.
- Ji, W.; Guo, J.; Li, Y.: Multi-head mutual-attention CycleGAN for unpaired image-to-image translation. In: IET Image Processing Bd. 14 (2020), Nr. 11, S. 2395–2402.
- Lee, J., Tang, R., & Lin, J. (2019). What Would Elsa Do? Freezing Layers During Transformer Fine-Tuning. Abgerufen 06.01.2021, von <http://arxiv.org/abs/1911.03090>.
- Lübcke, M., Seyfeli, F. & Wannemacher, K. (2020a). What does the future tell us about the present? Learning pathways as future models for universities and a stimulus for student reflection. In: ETH Learning and Teaching Journal, Vol 2, No 2, 20. ICED 2020 proceedings. S. 487–490.
- Lübcke, M., Seyfeli, F., Wannemacher, K. & Rhein, R. (2020b). Nudging self-regulation as a means of study assistance and educational development. In: ETH Learning and Teaching Journal, Vol 2, No 2, 20. ICED 2020 proceedings. S. 523–526.
- OECD (2018): The Future of Education and Skills: Education 2030 Position Paper OECD The future we want. Abgerufen 10.08.2020, von [https://www.oecd.org/education/2030/E2030%20Position%20Paper%20\(05.04.2018\).pdf](https://www.oecd.org/education/2030/E2030%20Position%20Paper%20(05.04.2018).pdf)

- Rajpurkar, P., Zhang, J., Lopyrev, K., & Liang, P. (2016). SQuAD: 100,000+ questions for machine comprehension of text. EMNLP 2016 – Conference on Empirical Methods in Natural Language Processing, Proceedings, ii, S. 2383–2392.
- Schmohl, T. (2019): Selbstgesteuertes Lernen. Explorative hochschuldidaktische Formate mit Modellcharakter für vier akademische Statusgruppen. In: Schmohl et al.: Selbstorganisiertes Lernen an Hochschulen. Strategien, Formate und Methoden. Bielefeld. (wbv).
- Semenov, A.; Romov, P.; Korolev, S.; Yashkov, D.; Neklyudov, K.: Performance of Machine Learning Algorithms in Predicting Game Outcome from Drafts in Dota 2. In: Ignatov, D. I.; Khachay, M. Y.; Labunets, V. G.; Loukachevitch, N.; Nikolenko, S. I.; Panchenko, A.; Savchenko, A. V.; Vorontsov, K. (Hg.): Analysis of Images, Social Networks and Texts. Cham: Springer International Publishing, 2017 — ISBN 978-3-319-52920-2, S. 26–37.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. Advances in Neural Information Processing Systems, 2017-Decem. (Nips), S. 5999–6009.
- Wannemacher, K. & Bodmann, L. (2021). Künstliche Intelligenz an den Hochschulen – Potenziale und Herausforderungen in Forschung, Studium und Lehre sowie Curriculumentwicklung. Berlin: Hochschulforum Digitalisierung (Arbeitspapier Nr. 59).

Natural Language Processing im akademischen Schreibprozess – mehr Motivation durch Inspiration?

Positionspapier basierend auf einer Fallstudie
an der Fachhochschule Kiel

Eike Meyer und Doris Weßels

Abstract: Wer den Einsatz KI-gestützter Werkzeuge zur Schreibunterstützung im akademischen Schreibprozess untersucht, betritt Neuland. Die Fülle der Tools und insbesondere deren dynamische Weiterentwicklung erschweren die Transparenz und Übersicht. Forschungsbedarf besteht insbesondere bei der Frage, in welcher Form der Einsatz dieser KI-gestützten Werkzeuge durch Natural Language Processing (NLP) im Allgemeinen und Natural Language Generation (NLG) im Speziellen den akademischen Schreibprozess und das Schreibverhalten der Anwender beeinflussen wird – im Positiven wie im Negativen. Dieser Beitrag analysiert die Ergebnisse einer zweitägigen KI-Schreibwerkstatt, die im Mai 2021 mit 20 Studierenden an der Fachhochschule Kiel erstmalig durchgeführt wurde. Der Fokus war auf den Einsatz von NLG-Tools gerichtet, d.h. auf das KI-gestützte Generieren fiktiver Texte mittels frei zugänglicher Werkzeuge. Es zeigte sich, dass die Studierenden durch den Einsatz dieser innovativen KI-gestützten Schreibwerkzeuge neue Formen der Inspiration und Schreibunterstützung erlebten. Im Rahmen dieser explorativen Studie zeichnet sich ab, dass diese Werkzeuge im Sinne von Schreibassistenten den Arbeitsprozess erleichtern und auch den Studierenden mehr Freude am Schreiben vermitteln könnten. Mit Blick auf das damit einhergehende Potenzial zur Motivationssteigerung im akademischen Schreibprozess setzt die KI-Werkstatt daher Impulse für den möglichen Einsatz von KI-Tools als Teil der wissenschaftlichen Textproduktion – sowohl in der Hochschullehre als auch in der Forschung. Zugleich werden aber auch neue Forschungsfragen aufgeworfen, die sich von didaktischen Zielsetzungen bis hin zu Data Literacy und den technischen, ethischen sowie rechtlichen Aspekten erstrecken.

Anyone investigating the possible application of AI-based writing tools in academic writing enters uncharted territory. The abundance of tools and the dynamic development of the tool landscape render transparency and overview equally difficult. Considering the crucial role of text production in academia, there is a particular need for research on the question of

how the use of AI-based tools which use the technology of Natural Language Processing (NLP) and, in particular, Natural Language Generation (NLG), will change the academic writing process and influence the writing behaviour of users. These behavioural changes could come in many forms (both positive and negative), especially for students who may find the idea of AI-based assistance appealing when faced with the task of writing texts which adhere to the new and unfamiliar standards of higher education. This paper analyses the results of a case study conducted in May 2021 with 20 students in the form of a two-day AI writing workshop at Kiel University of Applied Sciences. The workshop focused on the use of NLG tools, i.e., on the AI-assisted creation of fictional texts using freely accessible tools. Although the workshop can only be considered an exploratory study, its results suggest that students might derive new forms of inspiration and writing support from their use of AI-assisted writing tools. These tools could facilitate the writing process and bring about more joy in writing, which might have a motivational effect on students in the academic writing process and could reduce or defuse writer's block. At the same time, new research questions are raised, ranging from didactic objectives to data literacy and the technical, ethical and legal aspects.

Keywords: Schreibkompetenz, Natural Language Processing, Natural Language Generation, Data Literacy / Literacy, Natural Language Processing, Natural Language Generation, Data Literacy.

1 Positionsbestimmung – KI-gestützte Textgeneratoren

Die Digitalisierung der Bildung nimmt zunehmend Fahrt auf und führt zu einer großen Produkt- und Toolvielfalt in den verschiedenen Einsatzgebieten (Hart, 2020). Werkzeuge, die den Schreibprozess im akademischen Umfeld unterstützen, stehen ebenfalls in vielfältigsten Formen zur Verfügung, aber selbst noch aktuell anmutende Analysen dieser Werkzeuge aus dem Jahr 2018 konnten das disruptive Potenzial künstlicher Intelligenz für den Schreibprozess nicht vorhersehen (Strobl et al., 2019). In diesem Beitrag ist der Fokus auf den Einsatz von Natural Language Generation (NLG) als Subbereich des Natural Language Processing (NLP) im akademischen Kontext gerichtet. Dabei soll im Speziellen das Generieren von Textsequenzen mit KI-gestützten Schreibwerkzeugen diskutiert werden, die auf leistungsstarken Sprachmodellen wie GPT-2 und GPT-3 basieren. Viele dieser Werkzeuge sind für englischsprachige Textgenerierungen optimiert, sodass für die Produktion deutschsprachiger Texte zusätzliche Übersetzungssoftware erforderlich ist.

Das Sprachmodell GPT-2 wurde im Frühjahr 2019 von der Non-Profit-Forschungsorganisation OpenAI aus Kalifornien veröffentlicht (OpenAI, 2019). Das Akronym GPT steht für »Generative Pretrained Transformer«, ein vortrainiertes Sprachmodell, das nach Eingabe eines Textes eine verständliche Fortsetzung ge-

neriert. Es basiert auf einem neuronalen Netz mit 1,5 Milliarden Parametern und nutzt die Transformer-Architektur von Google. Analog zu den bekannten »Auto-complete«-Funktionen, die vor allem von Messenger-Diensten eingesetzt werden, wurde mit diesem Modell die Vorhersage des nächsten Wortes mit einer Datenbasis von 40 Gigabyte Internet-Texten trainiert. Das Ziel besteht darin, eine Textfortführung zu generieren, die sowohl die Kohärenz als auch die innere Logik des Textes bewahrt. Eine anschauliche Demonstration dieses Prozesses ist auf der Website des amerikanischen Allen Institute for Artificial Intelligence zu sehen (»Language Modeling with the Public 345M Parameter OpenAI GPT-2 Language Model«).


Bereits 2020 wurde der Nachfolger GPT-3 veröffentlicht, an dem Microsoft die exklusiven Lizenzrechte erworben hat (Scott, 2020). Im Vergleich zu den bisherigen KI-Sprachmodellen bietet das GPT-3-Sprachmodell mit seinen 175 Milliarden Parametern eine zehnfache Leistungssteigerung (Brown et al., 2020). Die zugrundeliegende Datenbasis von 45 Terabyte Rohdaten (»Common Crawl«) wurde durch Filterverfahren und Datenaufbereitung auf 570 Gigabyte reduziert (Brown et al., 2020).

Auch die Leistungsstärke von GPT-2-basierten Tools war und ist beeindruckend. Als Beispiel dafür kann das Tool Text Synth (Bellard, 2020) dienen, mit dem das nachfolgende Zitat automatisch fortgeführt werden soll:

Ich schreibe nur, weil ich noch nicht genau weiß, was ich von dem halten soll, was mich so sehr beschäftigt. [...] Ich bin ein Experimentator und kein Theoretiker. [...] Ich bin ein Experimentator in dem Sinne, dass ich schreibe, um mich selbst zu verändern und nicht mehr dasselbe zu denken wie zuvor (Foucault et al., 1996, S. 24).

Nach Eingabe dieses Zitats in Text Synth kann dort ein Text erstellt und nach Belieben durch das Tool fortgeschrieben werden. Abbildung 1 zeigt den Screenshot eines exemplarischen Ergebnisses

Abbildung 1: Textgenerierung mit Text Synth (bellard.org/textsynth).



I am only writing because I do not yet know exactly what to make of what concerns me so much. [...] I am an experimenter and not a theorist. [...] I am an experimenter in the sense that I write in order to change myself and not to think the same as before" (Foucault & Trombadori, 1996, p. 24).

Generate another More

Completed Text:

I am only writing because I do not yet know exactly what to make of what concerns me so much. [...] I am an experimenter and not a theorist. [...] I am an experimenter in the sense that I write in order to change myself and not to think the same as before" (Foucault & Trombadori, 1996, p. 24).

I am an "experimenter in the sense that I write in order to change myself and not to think the same as before" (Foucault & Trombadori, 1996, p. 24). An individual who chooses the term "experimenter" or "experimentalist" is thinking of a theory that can be constructed to deal with these different aspects of the human mind, a theory that can help us to know what is going on inside us, but also what is not going on inside us. "How can you imagine a better world than the one you live in" is the reply of one who is an experimentalist. The individual who does not know this is neither a theorist nor an experimenter.

When Foucault & Trombadori quote from Michel Foucault's essay "On Power", it is taken as a comment by Foucault on the very notion of "experiment". Foucault asks us to consider the idea of "power", which is often associated with "knowledge". Foucault suggests that we choose a theory from among these hypotheses (foucault, 1994, p. 20). We think of ourselves as experimenters, which allows us to see through our thoughts to what is going on inside us. Foucault suggests that what allows us to perceive ourselves is simply the fact that we can perceive something. Thus, "when we know something about ourselves, when we can experience something about ourselves, we are able to act upon those same sensations we possess about the world" (Foucault 1994, p. 21). We may also make choices for ourselves which affect how we experience. We may act upon our feelings which may be good, bad or indifferent; we may decide in our heads as a general principle that "whatever I do (or believe to be the right thing), everything should be this way" (Foucault 1994, p. 21). Foucault's

Dieser in englischer Sprache generierte Text muss nachfolgend noch übersetzt werden, wenn das Ziel darin besteht, einen *deutschen* Text zu generieren. Abbildung 2 stellt das Ergebnis nach der Übersetzung mit dem ebenfalls auf KI-Technologie basierenden Übersetzungswerkzeug DeepL (DeepL Translator, 2020) dar. Im Anschluss an die Übersetzung musste nur eine einzige Korrektur manuell vorgenommen worden, die in Abbildung 2 durch den fett markierten Großbuchstaben F beim Foucault-Quellenverweis im letzten Absatz hervorgehoben ist, bei dem zuvor fälschlicherweise der Kleinbuchstabe stand:

Abbildung 2: Textgenerierung mit Text Synth (nach Übersetzung mit DeepL).

Ich bin ein "Experimentator in dem Sinne, dass ich schreibe, um mich selbst zu verändern und nicht dasselbe zu denken wie vorher" (Foucault & Trombadori, 1996, S. 24). Eine Person, die den Begriff "Experimentator" oder "Experimentalist" wählt, denkt an eine Theorie, die konstruiert werden kann, um mit diesen verschiedenen Aspekten des menschlichen Geistes umzugehen, eine Theorie, die uns helfen kann, zu wissen, was in uns vorgeht, aber auch, was nicht in uns vorgeht. "Wie kann man sich eine bessere Welt vorstellen als die, in der man lebt?", lautet die Antwort eines Experimentators. Derjenige, der das nicht weiß, ist weder Theoretiker noch Experimentator.

Wenn Foucault & Trombadori aus Michel Foucaults Essay "Über die Macht" zitieren, wird dies als ein Kommentar Foucaults zum Begriff des "Experiments" selbst verstanden. Foucault fordert uns auf, die Idee der "Macht", die oft mit "Wissen" assoziiert wird, zu überdenken. Foucault schlägt vor, dass wir eine Theorie aus diesen Hypothesen auswählen (Foucault, 1994, S. 20). Wir sehen uns selbst als Experimentatoren, was uns erlaubt, durch unsere Gedanken hindurch zu sehen, was in uns vorgeht. Foucault meint, dass das, was uns erlaubt, uns selbst wahrzunehmen, einfach die Tatsache ist, dass wir etwas wahrnehmen können. So "wenn wir etwas über uns selbst wissen, wenn wir etwas über uns selbst erfahren können, sind wir in der Lage, nach denselben Empfindungen zu handeln, die wir über die Welt besitzen" (Foucault 1994, S. 21). Wir können auch Entscheidungen für uns selbst treffen, die beeinflussen, wie wir erleben. Wir können nach unseren Gefühlen handeln, die gut, schlecht oder gleichgültig sein können; wir können in unserem Kopf als allgemeines Prinzip entscheiden, dass "was auch immer ich tue (oder glaube, dass es das Richtige ist), alles sollte so sein" (Foucault 1994, S. 21).

Beeindruckend ist an dieser KI-generierten Textsequenz einerseits die inhaltliche Stringenz bzw. die enge stilistische Anlehnung an den Input-Text und andererseits die Verwendung fiktiver Quellenangaben, die selbst fachkundigen Lesern nicht direkt als falsch auffallen. Hinzu kommt, dass die auf diese Weise generierten Texte Unikate sind und auch durch wiederholte Nutzung ein- und desselben Tools nicht reproduziert werden können. Sie stellen somit keine Plagiate dar. Zugleich ist allerdings anzumerken, dass die die Frage nach dem Urheberrecht und der Kennlichmachung derartiger Textpassagen (Weßels, 2020a) derzeit völlig ungeklärt ist.

Dieselbe Ambivalenz in der Nutzung der Werkzeuge gilt auch für die Vielzahl der kontinuierlich neu entstehenden Tools. Als besonders umfangreich und leistungsstark stellt sich die auf GPT-3 beruhende Tool-Plattform Copy.ai (Copy.Ai, 2021) dar, die Textinput in einer Vielzahl von Sprachen versteht und dazu passenden Output generieren kann. Im Gegensatz zu anderen KI-Schreibtools, die bislang nur in englischer Sprache akzeptable Leistungen erzielen, arbeitet Copy.ai (Stand Juni 2021) auch mit deutscher Sprache für In- und Output. Diese Tool-Plattform bietet für die Schreibunterstützung z.B. die Funktion der Gliederungshilfe mit dem Tool »Essay Outline« an. Darauf basierend kann das Tool »Essay Intro« einen Einleitungstext generieren.

Abbildung 3: Screenshot der Eingaben für die Erstellung einer Gliederung bei Copy.ai.

Essay Outline

TipsTutorialsWelcome

WHAT IS YOUR ESSAY TITLE?

Natural Language Processing im akademischen Schreibprozess – mehr Motivation

WHAT IS YOUR ESSAY ABOUT?

In welcher Form wird der Einsatz KI-gestützter Werkzeuge aus dem Bereich des Natural Language Processing den akademischen Schreibprozess verändern? Wie wird sich das Verhalten der Anwender KI-gestützter Schreibwerkzeuge verändern? Können KI-Werkzeuge aus dem Bereich des Natural Language Generation die Kreativität von Studierenden fördern und Schreibblockaden reduzieren oder abbauen?

Abbildung 4: Screenshot der ersten beiden Gliederungsvorschläge von Copy.ai.

Essay Outline

TipsTutorialsWelcome

FIND YOUR FAVORITE RESULTS AND EDIT THEM UNTIL YOU LOVE THEM.

CLICK THE HEART TO SAVE

Abschnitt: Inwiefern wird der Einsatz von KI-unterstützten Werkzeugen aus dem Bereich Natural Language Processing den akademischen Schreibprozess verändern? Wie wird sich das Verhalten der Nutzer von KI-unterstützten Schreibwerkzeugen verändern?

Sektion: Können KI-Werkzeuge aus dem Bereich der Natural Language Generation die Kreativität der Studierenden fördern und Schreibblockaden reduzieren oder beseitigen?

Takeaway: Nutze Tools, um dein Schreiben zu verbessern und zu verändern.

Make more

Abschnitt: Was ist Natural Language Processing (NLP)

Abschnitt: Was ist Natural Language Generation (NLG)

Abschnitt: Wie können NLP-Tools den Prozess des Schreibens einer wissenschaftlichen Arbeit unterstützen?

Abschnitt: Welche Veränderungen im Verhalten der Studierenden sind zu erwarten, wenn solche Werkzeuge eingesetzt werden? Welche Auswirkungen wird es auf die Motivation der Studierenden haben, einen Essay oder eine Hausarbeit zu schreiben?

Sektion: Wie können NLP-Tools den Studierenden helfen, eine Schreibblockade zu überwinden?

Takeaway: Die Studenten werden effizienter werden

Make more

Dieser Ablauf könnte beispielsweise wie folgt aussehen:

- Im ersten Schritt müssen die (menschlichen) Autor:innen das Thema und eine kurze Erläuterung eingeben, wie in Abbildung 3 ersichtlich.
- Auf Basis dieser Eingaben erstellt das Tool dann auf Knopfdruck eine Fülle möglicher Gliederungsarten, unter denen die User:innen wählen können. Zwei solche Gliederungsalternativen sind in Abbildung 4 exemplarisch dargestellt.
- Besonders leistungstark zeigt sich Copy.ai auch bei der Formulierung von Einleitungen über das Tool »Essay Intro«, siehe Abbildung 5.

Abbildung 5: Screenshot von Einleitungstexten von Copy.ai.



Die gängigen KI-Tools bieten die Möglichkeit, mit diesen KI-generierten Texten auf sehr einfache Art und Weise in Textverarbeitungssystemen wie z.B. Microsoft Word und Google Docs weiterzuarbeiten. In der Kombination mit Rewriting-Tools wie z.B. Quillbot (<https://quillbot.com/>) für das Paraphrasieren und Zusammenfassen ermöglichen die NLG-Werkzeuge auch das effiziente Erstellen größerer zusammenhängender Texte.

2 Natural Language Processing für das akademische Schreiben

Der Nutzen KI-gestützter Werkzeuge, die auf Natural Language Processing (NLP) beruhen, ist u. a. von Khaled für den Bildungsbereich am Beispiel des Erlernens einer Sprache (Grammatik, Syntax, Satzbau usw.) untersucht worden. Seine Studie zeigt: »Language is one of the major concerns for the students« (Khaled, 2014, S. 75), weshalb es eine zentrale Aufgabe der Hochschulen sein muss, das Lesen, Verstehen und Schreiben von Lernenden zu unterstützen und zu fördern. Im Bereich von Wissenschaft und Forschung geht es dabei auch um das wissenschaftliche Selbstverständnis, die Professionalität in der Kommunikation und die Akzeptanz der Community: »Jede Fachdisziplin misst Erfolg an Texten: an Publikationen in einschlägigen Zeitschriften, Sammelbänden und Monographien. Auch bei Studierenden zeigt sich in ihren Studententexten, ob sie gelernt haben, zu denken und zu handeln wie Wissenschaftler und Wissenschaftlerinnen ihrer Disziplin« (Lahm, 2016, S. 11).

Die Relevanz der Schreibkompetenz, die sich in diesem Zitat von Lahm widerspiegelt, untermauert die Gesellschaft für Schreibdidaktik und Schreibforschung in ihrem Positionspapier 2018, das den Begriff zudem weiter präzisiert:

»Schreibkompetenz im Studium ist die Fähigkeit, Texte zum Lernen und als Anknüpfungspunkte für eigene Textproduktionen zu nutzen und sich schriftsprachlich angemessen auszudrücken. Diese Fähigkeit setzt sich aus fachübergreifenden und fachspezifischen Komponenten zusammen und kann in drei Dimensionen beschrieben werden:

- Kompetente Schreibende nutzen Schreiben zum kritischen Denken,
- steuern produktiv den eigenen Schreibprozess und
- kommunizieren entsprechend den Textkonventionen der jeweiligen Fachgemeinschaft angemessen«

(Gesellschaft für Schreibdidaktik und Schreibforschung [gefsus], 2018, S. 9).

Die heutige Förderung der Schreibkompetenz wird an vielen Hochschulen über sogenannte Schreiblabore und durch kontinuierliches Training bei der Erstellung von Haus- und Studienarbeiten umgesetzt. Mit Blick in die Zukunft stellt sich nun jedoch die Frage, in welcher Form KI-basierte Werkzeuge an Hochschulen eingesetzt werden sollen oder auch dürfen: Sind Sie aus Sicht der Lehrenden und der Hochschulleitungen Freund oder Feind?

Der in Neuseeland tätige Wissenschaftler Otsuki (Otsuki, 2020) fordert den proaktiven Einsatz von KI als Partner im Schreibprozess und stellt in diesem Zusammenhang auch gleich die generelle Sinnfrage in Bezug auf die Schreibkompetenzförderung an Hochschulen: »What should we judge our students on? All of the above prompts a question we need to consider if we're to live in an AI-friendly world: why do we teach students to write at all?« Im Anschluss an diese provokante Frage weist er auf eine differenzierte(re) Sichtweise auf die Produktion von Texten hin: »If we

teach students to write things a computer can, then we're training them for jobs a computer can do, for cheaper. Educators need to think creatively about the skills we give our students. In this context, we can treat AI as an enemy, or we can embrace it as a partner that helps us learn more, work smarter, and faster«. Auch die in diesem Beitrag vorgestellte KI-Schreibwerkstatt beschreitet auf experimentelle Art und Weise diesen von Otsuki skizzierten Weg des entschieden proaktiven Einsatzes von KI an Hochschulen.

Der bisherige Einfluss von Künstlicher Intelligenz gilt bereits heute als disruptiv, doch diese gerade skizzierte Entwicklungsrichtung führt uns in eine neue Dimension der Herausforderungen für die akademische Bildung, für die die Hochschulen derzeit (noch) keine Vorgehensweisen parat haben. Das Beziehungsgeflecht und die Interdependenzen von Schreiben und Denken werden in diesem Zusammenhang zu vielfältigen Diskussionen und Polarisierungen führen, insbesondere unter der Fragestellung, inwiefern das Schreiben das Denken fördert und lenkt. Im ersten Schritt muss aber das Bewusstsein für diese neue Herausforderung im Bildungsbereich an deutschen Schulen und Hochschulen gefördert werden (Pollmeyer et al., 2020). So findet sich selbst auf großen Übersichtsplattformen zu KI-Anwendungen in Deutschland (noch) nichts zum Thema »Schul-/Hochschulwesen und Textgeneratoren« (Plattform Lernende Systeme). Denselben Handlungsbedarf betont auch die vom Stifterband mit zahlreichen Partner:innen initiierte Data-Literacy-Charta: Sie bewertet Data Literacy in Anlehnung an die bundesweite Datenstrategie als Schlüsselkompetenz des 21. Jahrhunderts (Schüller et al., 2021).

Jenseits der Hochschullehre haben KI-basierte Tools darüber hinaus auch längst das Verlagswesen und damit die Produktion wissenschaftlicher Publikationen erreicht. Besondere Experimentierfreude in Bezug auf den Einsatz KI-basierter Tools für die Produktion von Fachbüchern stellte unlängst der Springer Nature Verlag unter Beweis. Im Jahr 2019 veröffentlichte der Verlag eine strukturierte Zusammenfassung aktueller Forschungsartikel über Lithium-Ionen-Batterien (Writer et al., 2019), die gänzlich automatisch von der KI »Beta Writer« erstellt worden war. Im Mai 2021 folgte die Veröffentlichung eines maschinengenerierten Literaturüberblicks über Klima-, Planeten- und Evolutionswissenschaften, der als kollaborative Publikation von Mensch und Maschine entwickelt worden war (Visconti, 2021). Diese Form der Zusammenarbeit soll laut Aussage des Verlags einen neuen Maßstab für Formen der Arbeitsorganisation setzen, die es menschlichen Autor:innen ermöglichen, die von der KI generierten Literaturübersichten mit ihrer eigenen wissenschaftlichen Expertise in Textform fortzuführen. Professor Visconti – einer der (menschlichen) Autoren, die an diesem Projekt beteiligt waren – betont den generellen Nutzen dieser neuen Form der Mensch-Maschine-Kollaboration, insbesondere in Bezug auf die Effizienzsteigerung, die sie dem akademischen Nachwuchs ermöglicht: »The peculiarities of the topics demonstrate that the same process could be applied to any scientific sector producing summaries which are

very useful for both the professional and academic work or for the students that face for the first time the research literature or pursue PhD objectives« (Springer Nature, 2021).

3 Fallstudie an der Fachhochschule Kiel – KI-Schreibwerkstatt

Während es aus Hochschulperspektive bereits strategische Zielvorstellungen gibt, die diese vielfältigen neuen Herausforderungen thematisieren, fehlt oft der Blick der Studierenden. Um die Möglichkeiten und Grenzen NLP-basierter KI-Werkzeuge, mit dem Fokus auf NLG, im Kontext von Lehren und Lernen zu explorieren, wurde im Rahmen der »Interdisziplinären Projektwochen« der Fachhochschule Kiel daher am 6. und 7. Mai 2021 erstmalig eine KI-Schreibwerkstatt in Form eines Workshops angeboten und durchgeführt. Sie untersucht explizit die studentische Perspektive auf den Einsatz KI-gestützter Textgenerierungswerkzeuge.

Allerdings verfolgt weder der geschilderte Workshop noch der darauf aufbauende vorliegende Beitrag das Ziel, die aktuell frei verfügbaren KI-gestützten Werkzeuge in Bezug auf ihren Mehrwert in spezifisch wissenschaftlichen bzw. akademischen Schreibprozessen zu untersuchen. Dies ist zum einen der Tatsache geschuldet, dass es bislang an Rahmenbedingungen für den Einsatz KI-gestützter Textgenerierungswerkzeuge in der Hochschulbildung mangelt: Inwiefern die unter Zuhilfenahme einer KI erstellten Texte den Anspruch an die Eigenleistung erfüllen (können), die deutsche Hochschulen an Studierende stellen, ist bislang unklar. Zum anderen sind aber auch die derzeit verfügbaren NLP-/NLG-Werkzeuge nicht spezifisch auf die Produktion wissenschaftlicher Texte ausgerichtet. Angesichts der hohen Veränderungsdynamik und schnellen Technologiefortschritte sind zwar in sehr naher Zukunft Werkzeuge zu erwarten, die als wissenschaftliche Schreibbots zur Unterstützung für Wissenschaftler und Forschende zum Einsatz kommen dürften, doch zum Zeitpunkt der Workshop-Durchführung standen nur generalistisch konzipierte Text-Tools zur Verfügung.

Aus diesem Grund versteht sich auch die KI-Werkstatt als rein explorativer Workshop, der einen ersten Eindruck von der allgemeinen Haltung der Studierenden zum Einsatz KI-gestützter Tools in der Textproduktion vermitteln und Impulse für nachfolgende, empirisch reliable Studien setzen soll. Aus diesem Grund standen journalistische Textformen im Mittelpunkt der Aufgaben, denen sich die Studierenden im Verlauf des Workshops widmeten, und auch die Befragung zur Motivation der Studierenden beschäftigte sich neben der Freude am Lesen und Verfassen wissenschaftlicher Texte auch mit zu Literatur und Textproduktion als möglicher Freizeitbeschäftigung der Teilnehmenden.

3.1 Konzeption des Workshops

Der für die Ankündigung verwendete Titel des Workshops war bewusst einladend formuliert. Er sollte Studierende aller Fachbereiche zur Teilnahme motivieren und Neugierde wecken:

»Schreibwerkstatt mit Spaßfaktor für digitale Held:innen: Wir entdecken, nutzen und bewerten KI-gestützte Werkzeuge für die Produktion von Texten.«

Der Aufbau der Veranstaltung ist der Tabelle 1 zu entnehmen.

Tabelle 1: Struktur und zeitlicher Verlauf der KI-Schreibwerkstatt an der FH Kiel am 06. – 07.05.2021.

Teil 1 am 6. Mai 2021 von 10:15-13:45 Uhr	a) Vorstellungsrunde b) Online-Befragung zur Motivation für die Teilnahme und zu Erfahrungen mit Schreibprozessen und KI-gestützter Schreibunterstützung c) Impulsvortrag (Relevanz und Herausforderung der KI-gestützten Textgenerierung und Textmodifikation, Vorstellung ausgewählter Tools und Techniken) d) Vorstellung und Erläuterung der Aufgabenstellung e) Arbeit in den Teams in Zoom-Breakout-Räumen f) Präsentation und Diskussion der erzielten Gruppenergebnisse für den ersten Dokumenttyp Pressemitteilung
Teil 2 am 7. Mai 2021 von 10:15-11:45 Uhr	a) Präsentation und Diskussion der erzielten Gruppenergebnisse für die beiden Dokumenttypen Essay und Interview b) Online-Befragung zu Lessons Learned aus der KI-Schreibwerkstatt c) Reflexion und Diskussion der erzielten Ergebnisse und Ergebnisse der Online-Befragung

Die Anzahl der Teilnehmenden war auf 20 Studierende begrenzt. Die Gruppe wurde nach dem Zufallsprinzip (gesteuert über Zoom-Breakout-Sessions) in 7 Teams mit 2–3 Studierenden aufgeteilt. Die Studierenden kamen aus 4 unterschiedlichen Fachbereichen der FH Kiel (Informatik und Elektrotechnik, Wirtschaft, Soziale Arbeit und Gesundheit, Medien) und unterschiedlichen Bachelor- bzw. Masterstudiengängen. Sie kannten sich untereinander zuvor nicht.

3.2 Aufgabenstellungen in der KI-Schreibwerkstatt

Die Aufgabenstellung für die Auftaktsession am ersten Veranstaltungstag bestand in der Erstellung einer fiktiven Pressemitteilung, die sich thematisch an einem neuen und von den studentischen Teams beliebig auszuwählenden Forschungsvorhaben zu Künstlicher Intelligenz orientieren sollte:

Text 1

Erstellen Sie im Team (2-3 Studierende) eine Pressemitteilung zu diesem Thema:

Neues Forschungsvorhaben zu Künstlicher Intelligenz

Sie dürfen und sollen kreativ sein – Spaß ist erlaubt! Vermeiden Sie aber "unnötige" Eigenleistungen in Form eigener Formulierungen. Versuchen Sie bestmöglich "automatisiert" unter (nahezu ausschließlicher) Nutzung aktueller Werkzeuge (siehe vorgestellte Liste) die obige Pressemitteilung zu erstellen. Stellen Sie das Dokument kurz vor und berichten Sie anschließend über Ihre Erfahrungen im Rahmen der Erstellung. Welche Passagen stammen von welchen Tools und Werkzeugen?

Basierend auf den Ergebnissen des ersten Veranstaltungstags wurde die Aufgabenstellung für den zweiten Veranstaltungstag formuliert:

Text 2

Erstellen Sie eine kurze Abhandlung im Stil eines Essays inklusive kleiner Gliederung im Umfang von ca. 5000 Zeichen zu Ihrer zuvor verfassten Pressemitteilung.

- Versuchen Sie auch ein Interview (Umfang ca. 1500 Zeichen) zu erstellen, in dem Sie z.B. einen fiktiven Forscher bzw. eine Forscherin interviewen. Vermeiden Sie Eigenleistungen in Form eigener Formulierungen.
- Versuchen Sie bestmöglich "automatisiert" unter (nahezu ausschließlicher) Nutzung aktueller Werkzeuge (siehe Liste der vorgestellten Werkzeuge) die obige Abhandlung bis zur morgigen Veranstaltung zu erstellen.
- Stellen Sie beide Dokumente kurz vor und berichten Sie anschließend über Ihre Erfahrungen im Rahmen der Erstellung. Welche Passagen stammen von welchen Tools und Werkzeugen?

Die nachfolgende Abbildung 6 enthält die Übersicht der vorgestellten niedrigschwelligen und als Freemium-Lizenzen in der Startphase kostenlosen und frei zugänglichen Werkzeuge, ergänzt um Hinweise zur Nutzung und Empfehlungen.

Abbildung 6: Übersicht der im Workshop vorgestellten KI-basierten Werkzeuge zur Schreibunterstützung.

NAME DES KI-TOOLS	VERWENDUNG	LINK
DeepL	Übersetzungs-Tool mit Glossar- und Synonym-Funktion	https://www.deepl.com/translator
Write With Transformer	Text-Generator	https://transformer.huggingface.co/doc/distil-gpt2
InferKit	Text-Generator	https://app.inferkit.com/generate
Text Synth	Text-Generator	https://bellard.org/textsynth/
Philosopher AI	Text-Generator	https://philosopherai.com/
thispersondoesnotexist	Tool zur Erstellung von fiktiven Personen	https://thispersondoesnotexist.com/
thisworddoesnotexist	Tool zur Erstellung von fiktiven Wörtern	https://www.thisworddoesnotexist.com/
AI Dungeon	Text-Generator für Adventure-Spiele	https://play.aidungeon.io/main/landing
Quillbot	Tool zum Umschreiben & Zusammenfassen von Texten	https://quillbot.com/
Grammarly	Schreibassistenzsystem & Plagiatserkennungs-Software	https://www.grammarly.com/
Copy.ai	Text-Generator	https://www.copy.ai/

3.3 Ergebnisdarstellung

Die Befragungsergebnisse zur Motivation für die Teilnahme und zu Erfahrungen mit Schreibprozessen und KI-gestützter Schreibunterstützung sind in Tabelle 2 zusammengefasst.

Tabelle 2: Befragungsergebnisse der 20 Studierenden der Fachhochschule Kiel im Rahmen des Auftakts der KI-Schreibwerkstatt am 06.05.2021.


AUSSAGE	ZUSTIMMUNGSINDEX (arithm. Mittel)
1. Mir macht das Schreiben Spaß.	2,55
2. Ich habe Angst vor dem Schreiben meiner Hausarbeiten hier im Studium und/oder auch vor meiner späteren Thesis.	2,95
3. Ich lese Bücher in Form von Unterhaltungsliteratur viel und gerne.	3,05
4. Ich lese Bücher in Form von Fachliteratur viel und gerne.	2,7
5. Ich werde häufiger gebeten, die schriftlichen Arbeiten meiner Kommilitonen oder Kommilitoninnen Korrektur zu lesen.	3,35
6. Ich habe bereits Erfahrungen mit Werkzeugen aus dem Bereich der Künstlichen Intelligenz, die mich beim Schreiben unterstützen.	4,65

Der größte und kleinste Wert für den Zustimmungsggrad zur Motivation für die Teilnahme zeigt sich in Tabelle 2 bei dem ersten und letzten Statement. Das Statement 6 belegt mit einem Zustimmungsinde von 4,65, dass die Studierenden kaum KI-Vorerfahrungen haben. Diese fehlende KI-Erfahrung erweist sich in der Form als nicht überraschend, weil die Werkzeuge noch zu neuartig sind und die Lebenswelt der Studierenden nicht erreicht haben. Die Freude am Schreiben, die im ersten Statement abgefragt wurde, bedarf aber einer näheren Betrachtung, da der Zustimmungsinde von 2,55 die Heterogenität der Gruppe und die große Bandbreite der Einstellungen (Abbildung 7) nicht angemessen widerspiegelt.

Abbildung 7: Der (allgemeine) Spaß am Schreiben – Befragungsergebnisse beim Auftakt der KI-Schreibwerkstatt am 06.05.2021.

Mir macht das Schreiben Spaß.


20 Antworten



Während der Arbeitsphasen zeigten die Teilnehmenden in ihren Teams durchgängig eine hohe Motivation, Neugierde und Interesse am Kennenlernen der Werkzeuge. Das Befragungsergebnis am Ende des Workshops in Abbildung 8 belegt, dass diese neue und ungewohnte Form des Schreibens den Studierenden viel Freude bereitete.

Abbildung 8: Der Spaß beim Schreiben mit KI-Tools – Befragungsergebnisse als Lessons Learned der KI-Schreibwerkstatt am 07.05.2021.

Meine Lessons Learned: Mir hat das Arbeiten mit diesen KI-Tools viel Spaß und Freude bereitet.
17 Antworten




Im Vergleich der beiden Befragungen zeichnet sich ab, dass KI-Anwendungen im Schreibprozess neben der reinen Effizienzsteigerung auch einen zweiten Vorteil haben könnten, der Studierende zur intensiveren Auseinandersetzung mit dem eigenen Schreibverhalten anregen könnte: Durch Einsatz der KI-Tools gewinnt der Schreibprozess einen neuen Erlebniswert. Aus der Aufgabe wird so ein Abenteuer, denn die von GPT-3 generierten Textsequenzen sind Unikate mit unvorhersehbarer Qualität: »Even though it is capable of remarkable creativity and truth telling, so too does it lie and spin with regularity« (Buchanan et al., 2021, S. 49). Darauf, dass diese neue Erlebnisqualität ihrerseits dazu beitragen kann, die Produktivität der Studierenden anzuregen, deutet auch die Befragung am zweiten Tag der KI-Werkstatt hin: Die Förderung von Kreativität und Inspiration durch den Einsatz von KI-Schreibwerkzeugen wurde von den Studierenden mit großer Mehrheit bestätigt, siehe Abbildung 9.

Abbildung 9: Kreativität, Inspiration und Ideen durch KI-generierte Texte – Befragungsergebnisse als Lessons Learned der KI-Schreibwerkstatt am 07.05.2021.

Meine Lessons Learned: Das Schreiben wird durch den Einsatz dieser KI-Werkzeuge kreativer und ich bekomme mehr Inspirationen und bessere Ideen.

17 Antworten




Eine weitere Fragestellung betraf die Auswirkungen dieser neuen Schreiberfahrung auf den Abbau oder die Reduktion potenziell vorhandener Schreibblockaden. Die in Abbildung 10 von den Studierenden geäußerte Einschätzung und Bewertung spiegelt das diesbezügliche Problemlösungspotenzial einer KI-Schreibwerkstatt wider.

Abbildung 10: Abbau von Schreibblockaden – Befragungsergebnisse als Lessons Learned der KI-Schreibwerkstatt am 07.05.2021.

Meine Lessons Learned: Diese KI-Werkzeuge unterstützen Studierende dabei, Schreibblockaden zu vermeiden oder zu überwinden.

20 Antworten



Im Ergebnis stellte sich heraus, dass die Studierenden mit großer Leidenschaft und persönlichem Einsatz »ihre« Texte generierten und bei allen drei Dokumententypen ihre Leistungen im Team als hochwertig bewerteten. Das studentische Resümee und Zitat: »teilweise erschreckend gute Weiterführungen der Texte, besonders gut für Anfänge zu einem Thema oder wenn Ideen zu einem Thema fehlen. Schwierig waren dann teilweise die fehlenden Zusammenhänge, so dass Texte meistens erst nach mehreren Versuchen und aus Kombinationen mit verschiedenen Tools Sinn ergeben haben« beschreibt die Arbeitsweise und die erzielten Ergebnisse sehr anschaulich. Gleichzeitig war allen Beteiligten aber auch bewusst, dass die im Rahmen der KI-Werkstatt erprobten Techniken zur Textproduktion aufgrund der inhaltliche Fiktion der Ergebnisdokumente Risiken der Täuschung für Leser:innen birgt und daher in dieser Form nicht für die Ausarbeitung wissenschaftlicher Texte adaptiert werden kann.

Hervorzuheben ist die Einschätzung der Studierenden in Bezug auf die positiven Eigenschaften des Einsatzes der Tools: Spaß, Kreativität und die Verringerung von Schreibblockaden deuten auf ein mögliches Potenzial hin, das im Rahmen künftiger – umfassenderer – Studien auch speziell in Bezug auf die Produktion wissenschaftlicher Texte weiterverfolgt werden kann und sollte. Diese Erkenntnis bietet einen Ansatz für weitere Forschung, um neben den oft diskutierten Risiken auch die Chancen des Einsatzes entsprechender Tools in Forschung und Lehre zu beleuchten.

4 Ausblick Hochschulen – Herausforderungen durch Natural Language Processing

Wenn Mensch und Maschine (mit NLP- bzw. NLG-Tools) gemeinsam Texte erstellen, modifizieren und veröffentlichen, ergeben sich von urheberrechtlichen Fragestellungen über Prüfungsprozesse und damit zu einer neuen Governance-Herausforderung mit vielfältigen rechtlichen und ethischen Faktoren in allen Phasen der wissenschaftlichen Textproduktion vielfältige neue Herausforderungen für das »System Hochschule«. (Pollmeyer et al., 2020). Im Fokus stehen nun nicht mehr nur menschliche Autor:innen, sondern das kollaborative Konstrukt aus Mensch und Maschine (Weßels, 2020c, 2020b, 2020a), das durch den – schon heute absehbaren – Einsatz von Schreibbots eine symbiotische Struktur aufweist. Neben dem derzeit in der wissenschaftlichen Diskussion vorrangig fokussierten Machine Learning treten perspektivisch immer stärker die damit verbundenen menschlichen Lernprozesse als »Human Learning« mit KI in den Vordergrund – ein Aspekt, der derzeit noch keine ausreichende Beachtung im deutschen Bildungssystem findet.

In diesem Kontext gilt es allerdings auch, urheberrechtliche Fragestellungen in Bezug auf die von Studierenden und Wissenschaftler:innen verfassten Texte als eine neue Komplexität zu bedenken, der vermutlich nur mit einem Paradigmenendenen begegnet werden kann. Dieser Musterwechsel kann für schriftliche Arbeiten im Sinne der »guten wissenschaftlichen Praktiken« zu einer vollständigen Substitution führen: Die Kennzeichnungspflicht fremder Quellen, die mit zunehmender Digitalisierung und der stärkeren Nutzung von Open Access-Dokumenten als ubiquitäres Gut verstanden werden können, wird durch die Pflicht zur Kennzeichnung »eigener Gedanken« ersetzt, wobei dieser Begriff für die bisherige intellektuelle Eigenleistung der menschlichen Autor:innen und auch die (neue) Co-Autorenschaft von Mensch und Maschine steht – in der Rolle des Menschen als »Machine Leader«.

5 Ausblick: Technologie – Sprachmodelle und Suchmaschinen

Weitere Entwicklungen im Bereich Natural Language Processing sind von Suchmaschinen-Anbietern zu erwarten. So steht beispielsweise zum Zeitpunkt der Manuskriptlegung dieses Beitrags das Multitask Unified Model (MUM) von Google bereits in den Startlöchern. Dieses auch auf der Transformer-Architektur basierende Modell soll laut Aussage von Pandu Nayak, Googles Vice President for Search, der nächste Meilenstein für das Verstehen von Suchanfragen sein: Es soll Sprache sowohl verstehen als auch generieren und obendrein natürlich multimodale Inhalte verarbeiten können, d.h. Text und Bilder, zukünftig auch Video- und Audiodaten. Unterschiedliche Sprachen sollen dabei ebenfalls keine Hürden mehr sein – bis da-

to wurde das System bereits mit 75 unterschiedlichen Sprachen trainiert (Nayak, 2021).

Die Vision der Verbindung von Sprachmodellen und Suchmaschinen und der damit einhergehende radikale Wandel einer Suchmaschine fort vom rein mechanischen Ranking-Ansatz hin zu einem lernfähigen KI-Sprachmodell hat ein Google Research Team im Mai 2021 als Aufsatz veröffentlicht, dessen Titel den Anspruch sehr anschaulich widerspiegelt: »Rethinking Search: Making Experts out of Dilettantes«. Der Weg ist allerdings noch sehr weit, bis Sprachmodelle sämtliche Suchanfragen als ein »one giant model« beantworten können (Metzler et al., 2021), denn in der Interaktion mit den Anwender:innen ist die Messlatte sehr hoch gelegt: Das »giant model« soll Fragen wie ein Mensch beantworten und gleichzeitig die Quellenherkunft mit Verweisen belegen, wie User:innen sie beispielsweise aus der Online-Enzyklopädie Wikipedia kennen (Heaven, 2021).

Wie groß die mit den immer mächtigeren Sprachmodellen einhergehenden Herausforderungen tatsächlich sein werden, lässt sich nur schwer vorhersagen. Neue und immer leistungsfähigere Sprachmodelle werden weltweit entwickelt, so z.B. auch mit chinesischen Texten trainierte Sprachmodelle wie das Pangu-Alpha von Huawei mit 200 Milliarden Parametern (Stieler, 2021) und das chinesische Modell Wu Dao 2.0 mit 1,75 Billionen Parametern auf Basis von 4,9 Terabyte an Text- und Bilddaten (Romero, 2021). Wie schmal der Grat zwischen Nutzen und Risiken ist, hat das Forscherteam Ben Buchanan, Andrew Lohn, Micah Musser und Katerina Sedova vom Center for Security and Emerging Technology (CSET) der Georgetown University in Washington im Mai 2021 sehr treffend zusammengefasst: »While GPT-3 has access to wide swaths of human knowledge, it does not hesitate at times to make things up. Even though it is capable of remarkable creativity and truth telling, so too does it lie and spin with regularity. And just as it is adept at following many legitimate instructions, it is at least as capable of learning to use its words to disrupt, divide, and distort« (Buchanan et al., 2021, S. 49).

Das Unternehmen Facebook geht noch einen Schritt weiter. Nach Aussage seines Chief Technologie Officer Mike Schroepfer soll ein neuronaler Sensor entwickelt werden, der Befehle wie z.B. das Tippen von Text erkennt und gleich ausführen kann (Weiß, 2020). Der Mensch bräuchte dann nicht mehr schreiben können – schließlich zählt das Vorlesen von Text bereits heute zu den Standardfunktionen gängiger Textverarbeitungssysteme und mit einem entsprechenden Sensor könnte die Maschine vollends zum vermittelnden Interface zwischen Mensch und Text avancieren. In Abbildung 11 wird im Sinne einer dreistufigen Pyramide die mögliche Entwicklung und Priorisierung dargestellt.

Abbildung 11: Pyramide der Entwicklungsebenen der Kommunikation vom Bewusstsein über die Mündlichkeit zur Schriftlichkeit.

- | |
|---|
| 1. Stufe: Bewusstsein (Denken) |
| 2. Stufe: Mündlichkeit (Sprechen, Hören) |
| 3. Stufe: Schriftlichkeit (Schreiben, Lesen) |

Von Bewusstsein und Denken auf Stufe 1 gehen in der menschlichen Evolution das Sprechen und Verstehen (Hören) auf der zweiten Stufe der Mündlichkeit hervor. KI-gestützte Werkzeuge beherrschen heute bereits die Wandlung von »speech to text« und vice versa, sodass die Stufen 2 und 3 mit den dort zu verortenden Sprach- und Schreibkompetenzbereichen immer stärker verzahnt werden und ein hohes Maß an Digitalisierung durch und mit KI-Unterstützung erfahren. Selbst der sprachliche Disput wird von KI-Entwicklungen tangiert. IBM-Forscher:innen haben mit dem Debater 2021 (Slonim et al., 2021) ein autonomes Debattiersystem vorgestellt, das mit Menschen bereits recht erfolgreich diskutieren und argumentativ überzeugen kann.

6 Weiterer Forschungsbedarf

Die technologische Entwicklung im Bereich der Künstlichen Intelligenz ist überaus dynamisch und – wie bereits in den vorhergehenden Kapiteln aufgezeigt – kaum vorherzusehen. Welche Auswirkungen ergeben sich absehbar für die Lehre an Hochschulen und die Kompetenzentwicklung und -förderung der Studierenden? Die Förderung der Schreibkompetenz stellt zweifelsohne auch zukünftig ein unverrückbares Ziel der akademischen Bildung dar. Auf Basis der dargestellten explorativen Fallstudie lassen zum Abschluss dieses Artikels nun folgende Fragen formulieren, die auf einen weiteren Forschungsbedarf hinweisen:

- In welcher Form wird der Einsatz KI-gestützter Werkzeuge aus dem Bereich des Natural Language Processing den akademischen Schreibprozess verändern?
- Wie wird sich das Verhalten der Anwender:innen KI-gestützter Schreibwerkzeuge im Lese- und Schreibprozess verändern?
- In welchen Formen werden die Verhaltensänderungen bei Studierenden auftreten, wenn sie KI-Werkzeuge für das Schreiben und Forschungsaufgaben einsetzen können?

- Können für Studierende neue Erlebniswerte und Inspirationen durch den Einsatz von KI-Schreibassistenten oder KI-Schreibbots entstehen?
- Können KI-Werkzeuge aus dem Bereich des Natural Language Generation die Kreativität von Studierenden fördern und Schreibblockaden nachhaltig reduzieren oder abbauen?
- Kann der Einsatz KI-gestützter Werkzeuge zu einer motivationsfördernden Wirkung für Studierende im akademischen Schreibprozess führen?
- Welchen Einfluss haben die KI-gestützten Formen des akademischen Schreibens für die Zukunftskompetenzen der Studierenden?
- Wie verändert sich das erforderliche Skill-Set für die Lehrenden an den Hochschulen im Zeitalter der künstlichen Intelligenz?

Ergänzend hierzu und mit Bezug zur Data Literacy Charta (Schüller et al., 2021) wirft diese neue Form des KI-gestützten Schreibens vielfältige rechtliche und ethische Fragestellungen auf. Bei der Datenethik ist neben dem erforderlichen Wissen und den Fähigkeiten die Einhaltung ethischer Grundwerte eine Forderung, dessen Relevanz sich bei der KI-gestützten Generierung von Texten besonders deutlich zeigt. Hochschulbildung muss sich auch dieser Herausforderung zukünftig deutlich stärker widmen.

Eike Meyer: Fachhochschule Kiel, Lehrbeauftragter Fachbereich Wirtschaft; eike.meyer@fh-kiel.de

Doris Weßels: Fachhochschule Kiel, Professorin für Wirtschaftsinformatik; doris.wessels@fh-kiel.de

Literatur

- Bellard, F. (2020). *Text Synth* (Version 9.08.2020) [Computer software]. <https://bellard.org/textsynth/>, Aufruf: 02.06.2021.
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., . . . Amodei, D. (28. Mai 2020). *Language Models are Few-Shot Learners*. <https://arxiv.org/pdf/2005.14165>, Aufruf: 02.06.2021.
- Buchanan, B., Lohn, A., Musser, M. & Sedova, K. (2021). *Truth, Lies, and Automation: How Language Models Could Change Disinformation*. Georgetown University Washington. <https://cset.georgetown.edu/publication/truth-lies-and-automation/>, Aufruf: 02.06.2021.
- copy.ai [Computer software]. (2021). CopyAI, Inc. Tennessee, Memphis – Colonnade. <https://www.copy.ai/app#>, Aufruf: 02.06.2021.

- DeepL Translator [Computer software]. (2020). DeepL GmbH. Köln. <https://www.deepl.com/translator>, Aufruf: 02.06.2021.
- Foucault, M., Trombadori, D., Brühmann, H., Schmid, W. & Hemminger, A. (1996). *Der Mensch ist ein Erfahrungstier: Gespräch mit Ducio Trombadori* (1. Aufl.). Suhrkamp-Taschenbuch Wissenschaft: Bd. 1274. Suhrkamp.
- Gesellschaft für Schreibdidaktik und Schreibforschung (Hg.). (2018). *Schreibkompetenz im Studium*. Positionspapier vom 29.09.2018. Nürnberg. https://gefsus.de/images/Downloads/gefsus_2018_positionspapier.pdf, Aufruf: 02.06.2021.
- Hart, J. (2020). *Top Tools for Learning 2020: Results of the 14th Annual Survey*. <https://www.toptools4learning.com/>, Aufruf: 02.06.2021.
- Heaven, W. D. (2021). KI: Sprachmodelle wie GPT-3 könnten völlig neue Suchmaschinen ermöglichen. <https://www.heise.de/hintergrund/KI-Sprachmodelle-wie-GPT-3-koennten-voellig-neue-Suchmaschinen-ermoenlichen-6048582.html>, Aufruf: 02.06.2021.
- Khaled (2014). Natural Language Processing and its Use in Education. *International Journal of Advanced Computer Science and Applications*, 5(12).
- Lahm, S. (2016). *Schreiben in der Lehre: Handwerkszeug für Lehrende. Kompetent lehren: Band 8*. Verlag Barbara Budrich. <http://www.utb-studi-e-book.de/9783838545738>.
- Language Modeling with the public 345M parameter OpenAI GPT-2 language model [Computer software]. The Allen Institute for Artificial Intelligence. Seattle. <https://demo.allennlp.org/next-token-lm?text=AllenNLP%20is>, Aufruf: 02.06.2021.
- Metzler, D., Tay, Y., Bahri, D. & Najork, M. (5. Mai 2021). *Rethinking Search: Making Experts out of Dilettantes*. <http://arxiv.org/pdf/2105.02274v1>, Aufruf: 02.06.2021.
- Nayak, P. (2021). MUM: A new AI milestone for understanding information [Blogbeitrag]. <https://blog.google/products/search/introducing-mum/>, Aufruf: 02.06.2021.
- OpenAI (Hg.). (2019). *Better Language Models and Their Implications*. <https://openai.com/blog/better-language-models/>, Aufruf: 02.06.2021.
- Otsuki, G. J. (2020). *OK computer: to prevent students cheating with AI text-generators, we should bring them into the classroom*. <https://theconversation.com/ok-computer-to-prevent-students-cheating-with-ai-text-generators-we-should-bring-them-into-the-classroom-129905>, Aufruf: 02.06.2021.
- Plattform Lernende Systeme (Hg.). *KI-Landkarte*. acatech – Deutsche Akademie der Technikwissenschaften e.V. <https://www.plattform-lernende-systeme.de/ki-landkarte.html>, Aufruf: 02.06.2021.
- Pollmeyer, I., Weßels, D. & Wiebusch, A. (2020). Fakten, Fakes und Fiktion: Die wahre Herausforderung nach Corona. *Die Neue Hochschule (DNH)*(04), 14–17.
- Romero, A. (2021): GPT-3 Scared You? Meet Wu Dao 2.0: A Monster of 1.75 Trillion Parameters. Hg. v. towards data science. Online verfügbar unter <https://towardsdatascience.com/gpt-3-scared-you-meet-wu-dao-2-0-a-monster-of-1-75-trillion-parameters-832cd83db484>, Aufruf: 22.10.2021.

- Schüller, K. S., Koch, H. & Rampelt, F. (2021). *Data Literacy Charta*. <https://www.stifterverband.org/charta-data-literacy>, Aufruf: 02.06.2021.
- Scott, K. (2020). *Microsoft teams up with OpenAI to exclusively license GPT-3 language model: Blogbeitrag*. <https://blogs.microsoft.com/blog/2020/09/22/microsoft-teams-up-with-openai-to-exclusively-license-gpt-3-language-model/>, Aufruf: 02.06.2021.
- Slonim, N., Bilu, Y., Alzate, C., Bar-Haim, R., Bogin, B., Bonin, F., Choshen, L., Cohen-Karlik, E., Dankin, L., Edelstein, L., Ein-Dor, L., Friedman-Melamed, R., Gavron, A., Gera, A., Gleize, M., Gretz, S., Gutfreund, D., Halfon, A., Hershcovich, D., Aharonov, R. (2021). An autonomous debating system. *Nature*, 591(7850), 379–384.
- Springer Nature. (4. Mai 2021). *Springer Nature advances its machine-generated tools and offers a new book format with AI-based literature overviews* [Press release]. <https://group.springernature.com/gp/group/media/press-releases/advances-its-machine-generated-tools-with-ai-based-lit-overviews/19129322>, Aufruf: 02.06.2021.
- Stieler, W. (2021). *KI: Forscher zeigen, wie GPT-3 für Desinformations-Kampagnen nutzbar ist: US-Forscher haben das Sprachmodell GPT-3, das Texte selbstständig ergänzen kann, erfolgreich zur Beeinflussung politischer Meinungen eingesetzt*. <https://www.heise.de/hintergrund/KI-Forscher-zeigen-wie-GPT-3-fuer-Desinformations-Kampagnen-nutzbar-ist-6059633.html>, Aufruf: 02.06.2021.
- Strobl, C., Ailhaud, E., Benetos, K., Devitt, A., Kruse, O., Proske, A. & Rapp, C. (2019). Digital support for academic writing: A review of technologies and pedagogies. *Computers & Education*, 131, 33–48.
- Visconti, G. (Hg.). (2021). *Climate, Planetary and Evolutionary Sciences: A Machine-Generated Literature Overview* (1st ed. 2021). Springer International Publishing; Imprint: Springer.
- Weiß, E.-M. (2020). *Facebook will KI Nachrichten zusammenfassen lassen*. Heise Medien GmbH & Co. KG. <https://www.heise.de/news/Facebook-will-KI-Nachrichten-zusammenfassen-lassen-4992653.html>, Aufruf: 02.06.2021.
- Weßels, D. (2020a). »Original oder Plagiat? Hochschulen und wissenschaftliche Arbeiten im Zeitalter künstlicher Intelligenz(en)«. *Forschung & Lehre*, 27(6), 504–505.
- Weßels, D. (2020b). *Digitale Disruption und Künstliche Intelligenz – Hochschulen im Dornröschenschlaf? ePaper*. <https://www.fes.de/themenportal-bildung-arbeit-digitalisierung/artikelseite/digitale-disruption-und-kuenstliche-intelligenz-hochschulen-im-dornroeschenschlaf>, Aufruf: 02.06.2021.
- Weßels, D. (2020c). *Die unerträgliche Leichtigkeit des (wissenschaftlichen) Schreibens: Mit Ghostwritern und Künstlicher Intelligenz auf der Überholspur* [Blogbeitrag]. <https://hochschulforumdigitalisierung.de/de/blog/ghostwriter-und-kuenstliche-intelligenz>, Aufruf: 02.06.2021.

Writer, B., Schoenenberger, H. & Chiarcos, C. (2019). *Lithium-ion batteries: A machine-generated summary of current research*. Springer Nature.

Transdisziplinäre Entwicklung von Chatbots in der Betriebswirtschaftslehre und der Wirtschaftspsychologie

Anwendung von KI-Technologien ohne Programmierkenntnisse

Denis Pijetlovic

Abstract: *Digitale Dialogsysteme, sogenannte Chatbots, sind ein Teilbereich der Künstlichen Intelligenz (KI), der immer häufiger in Arbeits- und Wirtschaftskontexten Anwendung findet. Der wachsende Einsatz, die Funktionalität und der Nutzen von Chatbots sind somit auch für die Hochschullehre der Wirtschaftswissenschaft von Interesse. Daher entwickeln Studierende der Universität Bremen im Fachbereich Wirtschaftswissenschaft im Rahmen des HumanRoboLab (HRL) gemeinsam mit Partner:innen aus der Unternehmenspraxis interdisziplinäre Chatbot-Projekte, um Formen der Mensch-Maschine-Interaktion aus einer anwendungsorientierten Perspektive forschend zu erkunden. Kernziel des HRL ist es, ein didaktisches Konzept für transdisziplinäre Projekte im Bereich der Mensch-Maschine-Interaktion zu erproben, um dieses Konzept anschließend modular in wirtschaftswissenschaftlichen und -psychologischen Studiengängen zu integrieren. Der Zweck eines solchen Moduls ist es, Studierenden ohne Programmierkenntnisse Wissen, Instrumente und Kompetenzen zu vermitteln, die sie dazu befähigen, selbstwirksam digitale KI-Technologien zu erforschen, anzuwenden und aus der Empirie heraus zu hinterfragen – mit anderen Worten: Das HRL soll den Studierenden dabei helfen, eine spezifische Digitalisierungsexpertise zu entwickeln, die in gesellschaftlichen und wirtschaftlichen Kontexten wirksam wird. Sowohl das Konzept des HRL als auch einige Praxisbeispiele und die Rolle der KI in den Chatbot-Projekten sollen im Folgenden skizziert werden und anderen Hochschullehrenden als Übertragungsschablone dienen.*

Digital dialogue systems, so-called chatbots, are an application sub-area in automation which is increasingly used in both work and business contexts. The growing use, functionality and benefits of chatbots are therefore also of interest for university teaching in economics. Therefore, students at the University of Bremen's Department of Economics are developing their own transdisciplinary chatbot project. Working together with partners from different companies within the framework of the HumanRoboLab (HRL), they explore human-machine interaction from an application-oriented perspective. The main objective of the HRL is to test a didactic

concept for transdisciplinary human-machine interaction projects in order to subsequently integrate this concept in business studies and business psychology degree programmes. The purpose of such a module is to provide students without prior experience in programming with the knowledge, tools and competences which enable them to research, apply and question AI technologies in a self-effective manner – in other words: The HRL aims to help students develop a specific expertise with regards to digitization which will be useful to them in both social and economic contexts. The concept of the HRL, as well as some examples of the projects and the role of artificial intelligence (AI) will be outlined in the following article in order to provide a template for other university teachers who might wish to adapt these concepts.


Keywords: *Chatbot, Reallabor, Erkundungsforschung / Chatbot, real lab, exploratory research.*

1 KI-basierte Chatbots in der Hochschullehre – wozu?

Die Entwicklung von Algorithmen im Bereich der Künstlichen Intelligenz (KI) ist ein Themenkomplex der Informatik, der das Ziel verfolgt, das menschliche Denk-, Entscheidungs- und Problemlöseverhalten durch computergestützte Verfahren ab- und nachzubilden (Bendel 2020). Auch Chatbots fallen in diese Kategorie, da sie Elemente der KI einsetzen, um menschliches Kommunikationsverhalten dahingehend zu simulieren, dass sich Menschen in natürlicher Sprache mit ihnen unterhalten können. Allerdings hilft eine solche Definition KI-basierter Chatbots für die anwendungsorientierte Hochschullehre nur bedingt weiter: Sie ist zu allgemein formuliert und setzt Expertise in den Kognitionswissenschaften voraus, um sie operational nutzen zu können. Um dieses Defizit zu umgehen, greift der vorliegende Artikel zur Veranschaulichung auf das *Periodensystem der KI* (Abbildung 1) von Kristian Hammond (2017) zurück, um den Begriff »KI-basierte Chatbots« für den Einsatz in der Hochschullehre praxistauglich zu machen. Eine deutschsprachige Fassung des Periodensystems der KI stellt BITKOM e.V. (2018) in einem Online-Handbuch zur Verfügung. Die Autoren:innen berufen sich dabei auf Kristian Hammond und sein Konzept zur Systematisierung von KI-Funktionen: Hammond betrachtet KI als die Kombination von Grundelementen, ähnlich verschiedener LEGO-Steine. Jedes KI-Element repräsentiert eine Teilfunktion, die sich historisch als gekapselte Funktionalität einer bestimmten Komplexität und Mächtigkeit etabliert hat. Der Autor definiert insgesamt 28 KI-Elemente, die nach generellen Kriterien kombiniert werden können (Bitkom 2018, S. 15).

Dabei lässt sich jedes KI-Element einer von drei Gruppen zuordnen: Assess (Dunkel-/Hellgrün) steht für *Beurteilung*, Infer (Gelb/Orange) für *Erschließen* und Respond (Magenta) für *Antworten*. In Analogie zur Chemie nennt Hammond die tabellarische Anordnung aller KI-Elemente ein Periodensystem der KI.

Abbildung 1: Periodensystem der Künstlichen Intelligenz (Bitkom, 2018, S. 7).



Durch Variation dieser verschiedenen Elemente der KI lassen sich wiederum Einsatzzwecke abstrakt ableiten und definieren. Chatbots bestehen hiernach aus den folgenden KI-Elementen:

Abbildung 1.1



Text Extraction [Te] bedeutet, dass dieses KI-Element das Analysieren von Texten beherrscht. Dies geschieht, indem es Entitäten (beispielsweise Personen, Organisationen, Städte, Produkte) und Begriffe (beispielsweise Kommunikation, Innovation, Produktion) in Texten zu unterscheiden lernt. Dadurch können Mehrdeutigkeiten in Namen und Wörtern aufgelöst werden. Ein ganz alltägliches Beispiel für die Ambiguität, auf deren Auflösung die KI abzielt, wäre der Name *Müller*, der je nach Kontext den Politiker Gerd Müller, den Fußballer Thomas Müller, aber auch die Drogeriekette Müller oder den Beruf Müller bezeichnen könnte.

Language Understanding [Lu] beschreibt das Verstehen der Information im Text, also die Zuordnung zur Bedeutung. Dieses KI-Element erfasst die in Texten gemeinten Beziehungen zwischen Entitäten und Konzepten und löst damit

zwei Probleme. Einerseits wird geklärt, welche Entitäten und Konzepte in Satzstrukturen überhaupt in einer Beziehung zueinanderstehen. Andererseits wird aber auch untersucht, welche Bedeutung diese Beziehung hat. Das Ergebnis von Language Understanding [Lu] – gemeinsam mit Text Extraction [Te] – ist die Übersetzung eines möglicherweise mehrdeutigen Textes in eine eindeutige maschinelle Repräsentation (Bitkom 2018).


Communication [Cm] als KI-Element kommt wiederum zum Einsatz, um große Mengen individueller oder wiederkehrender Fragen automatisiert zu beantworten. Dabei werden auf Basis konkreter Fallbeispiele sogenannte Modelle trainiert. Diese Modelle sind in der Lage, die Bedeutung eingehender Fragen zu verstehen, Antwortvorschläge zu geben und Dialoge zu führen. Im Fall von Chatbots bestehen diese Datensätze aus Sprachmodellen, die durch maschinelles Lernen (ML) trainiert werden.

Durch die Fragmentierung komplexer Anwendungen (wie Chatbots) lässt sich anhand des KI-Periodensystems nachvollziehen, auf welche Weise die unterschiedlichen Elemente der Künstlichen Intelligenz zusammenhängen und wirken. So trägt die Komplexitätsreduktion durch Aufgliederung in Bausteine mit unterschiedlichen Funktionen dazu bei, das weite Feld der Künstlichen Intelligenz operationalisierbarer zu machen.

Prozessbegleitung als Anwendungsfeld

Die Anwendungsgebiete von Chatbots sind vielfältig. Grundsätzlich ist festzustellen, dass Chatbots eingesetzt werden, um Menschen in Prozessen zu begleiten sowie Prozesse zu optimieren. Diese Anwendungsbereiche lassen sich in drei übergeordnete Einsatzszenarien einteilen: (a) Kommunikations-, (b) Entscheidungs- sowie (c) Lehr- und Lernprozesse (s. Abbildung 2), die im Folgenden eingehender betrachtet werden sollen.

Abbildung 2: Drei übergeordnete Einsatzbereiche von Chatbots (eigene Darstellung).



- a) Chatbots, die für Kommunikationsprozesse eingesetzt werden, finden sich vor allem im Kund:innenservice. Mithilfe dieser Chatbots können Flüge gebucht, Produkte bestellt oder Beschwerden (First-Level-Support) bearbeitet werden. Unternehmen können durch den Einsatz dieser Chatbots effizienter wirtschaften und eine bessere Kundenbetreuung gewährleisten.
- b) Der Einsatz von Chatbots in Entscheidungssituationen steht noch am Anfang. Diese spezialisierten Chatbots agieren als Assistenten für Menschen. Beispielsweise kann in einem Luft- und Raumfahrt-Szenario ein entscheidungsorientierter Chatbot in Gefahrensituationen bestimmte nächste (Prüf-)Schritte vorgeben oder Wahrscheinlichkeiten berechnen. Ein von den Studierenden in Zusammenarbeit mit der OHB AG entwickelter Chatbot namens *Alan, the Astro Aid* (s. Kapitel 4) unterstützt beispielsweise Astronauten beim Lösen im Umgang mit Schwierigkeiten in der Handhabung der von der OHB AG entwickelten European Physiology Modules (EPM).
- c) Auch in Lehr- und Lernprozessen können Chatbots als virtuelle Trainingspartner eingesetzt werden, die Studierenden dabei helfen, den Lernstoff zu festigen (de Witt et al. 2020, S. 19). Dabei lassen sich vier Anwendungsbereiche unterscheiden: (1) Die Betreuung von Lernenden, beispielsweise in einer Online-Community, (2) die Unterstützung bei Lernaktivitäten, (3) die Überprüfung von Wissen und die Bewertung von Leistungen sowie (4) die Lern- bzw. Karriereberatung (Satow 2018).

Modellierung und Training von Chatbots

Grundsätzlich ist die Technologie von Chatbots nicht neu. Erste Prototypen entstanden bereits in den 1960er Jahren, darunter auch ELIZA von Joseph Weizenbaum. ELIZA gilt als erster voll funktionaler Chatbot und wurde für die oberflächliche Simulation eines Psychotherapeuten bekannt. In der Psychotherapie werden gezielt offene Fragen gestellt – ein Prinzip, das Weizenbaum nutzte, indem er ein Programm entwickelte, das die non-direktiven Methoden der personenzentrierten Psychotherapie nach Carl Rogers anwendet (Höltgen/Baranovska 2018). ELIZA griff hierfür auf ein strukturiertes Wörterbuch zurück, d.h. das Programm durchsuchte die von User:innen eingegebenen Sätze nach Begriffen aus seinem Wörterbuch. Von diesem Wort ausgehend sucht der Chatbot nach Oberbegriffen oder Synonymen, auf die ELIZA das Gespräch lenken kann. Hier ein Beispiel:

Benutzer: »Ich habe ein Problem mit meiner Mutter.«

ELIZA: »Erzählen Sie mir mehr über Ihre Familie!«

Diese Form der Datenbankabfrage ist mit dem, was heute unter Künstliche Intelligenz (im Sinne von selbstlernenden Programmen) verstanden wird, allerdings nicht mehr vergleichbar. Seit ELIZA haben sich Chatbot-Technologien stetig weiterentwickelt und insbesondere die gesprächsorientierten KI (englisch: Conversational AI), die eine Mensch-Maschine-Interaktion durch natürliche Sprache ermöglichen, werden zunehmend effizienter (Lamprecht 2016). Beispielhaft stehen hierfür KI-gestützte Anwendungen wie GPT-3 von OpenAI, RASA, Google Dialogflow, Microsoft Luis, Amazon Lex und der IBM Watson Assistant. Ein besonderes Merkmal dieser Frameworks ist, dass sie es auch Laien ermöglichen, innerhalb weniger Stunden einen Chatbot zu entwickeln, ohne dass diese dafür eine Programmiersprache beherrschen müssten. Die Logik hinter dieser Technologie ist trivial: Chatbots werden auf bestimmte Inhalte trainiert, sogenannte *Intents*, die in das jeweilige System eingegeben werden. Damit können die Chatbots binnen Sekunden auf Anfragen reagieren und eine Interaktion in Echtzeit ermöglichen. Inwiefern die Interaktion *tatsächlich* gelingt, ist abhängig vom Zusammenspiel der Algorithmen der KI mit dem Sprachmodell. Ein wesentliches Qualitätsmerkmal ist dabei die Struktur des Gesprächsdesigns: Je umfassender die möglichen Intentionen der User:innen (in Form von Fragen, Befehlen und Smalltalk) bedient werden können, desto höher ist die Wahrscheinlichkeit, dass die Interaktion als gewinnbringend empfunden wird (McTear et al. 2016).

Chatbots als Einstieg in das maschinelle Lernen

Um einen interaktionsfähigen Chatbot zu gestalten, müssen die Studierenden ein Sprachmodell für die jeweilige Fallanwendung generieren, trainieren und dann anhand erster Testdaten optimieren. Auf diese Weise können Studierende lernen, wie maschinelles Lernen (ML), ein Teilgebiet der KI, funktioniert und wie sie diesen Lernprozess steuern und überwachen. Wesentlich dabei sind die Daten für das Sprachmodell. Diese Daten bestehen aus drei Hauptteilen: Intents, Entities und Dialog, die in eine Chatbot-Plattform eingegeben werden. ML nutzt die Technologie der sogenannten neuronalen Netzwerke. Dies sind Algorithmen, die ähnlich dem menschlichen Gehirn aufgebaut sind. Sie können wiederkehrende Muster erkennen und zuordnen, indem sie alle ihnen bekannten Informationen aus der realen Welt (Bilder, Texte, Zeitfolgen usw.) nutzen, um vertraute Muster in mathematische Vektoren zu übersetzen. Mit Hilfe der neuronalen Netzwerke kann das jeweilige System neue Informationen aufgrund von Ähnlichkeiten klassifizieren und in Gruppen (Entities) zusammenfassen. Diese Gruppen werden mit Labels wie beispielsweise Kund:innen, Kolleg:innen, Auftrag usw. benannt (Roßbach 2017, S. 13f.; Schikora et al. 2020, S. 268).

Es werden drei Arten des ML unterschieden: supervised learning, unsupervised learning und reinforcement learning. Beim supervised learning wird einem

Programm ein Beispieldatensatz vorgegeben. Dieser enthält Daten, die bereits in bestimmte Kategorien (Cluster) eingeteilt und markiert (labeled data) sind. Auf diese Weise erkennt das Programm bestimmte Eingangs-Parameter und kann diese einem Ergebnis zuordnen. Stehen die Daten fest, werden diese durch Trainingsdurchläufe zu einem Modell. Wenn das Modell im Training zufriedenstellend abscheidet, können diesem auch unbekannte Daten geliefert werden und das Programm berechnet ein wahrscheinliches Ergebnis (Prediction). Beim unsupervised learning erzeugt das Programm ein eigenes Modell für eine gegebene Menge an Eingaben. Dieses Modell beschreibt die Eingaben und ermöglicht Vorhersagen. Hierfür werden die Input-Daten in einem Cluster-Verfahren in mehrere Kategorien eingeteilt, die sich durch charakteristische Muster voneinander unterscheiden. Das Programm ist in der Lage selbstständig Klassifikationen zu erstellen, nach denen es die Eingabemuster einteilt (Gomes et al. 2017, S. 23; Schikora et al. 2020, S. 270). Reinforcement Learning (bestärkendes Lernen) ermöglicht einem Programm eigenständig eine Strategie auf Basis einer Belohnungsfunktion zu erlernen. Die Belohnungs-Funktion (oder auch Nutzenfunktion) beschreibt, welchen Wert ein bestimmter Zustand oder Aktion hat. Anders als beim supervised learning und unsupervised learning sind bei reinforcement learning im Vorfeld keine Daten erforderlich. Stattdessen erfolgt die Bildung der Datenbasis durch Trial-and-Error-Abläufe innerhalb eines eigens angelegten Simulations-Szenarios. Während der Trainingsdurchläufe werden alle erforderlichen Daten generiert und markiert. Diese Lernform ist am ähnlichsten zu der natürlichen Lernform eines Menschen (Abdoos et al. 2015, S. 213). Bei den Chatbot-Projekten im Rahmen des HRL kommt das supervised learning zur Anwendung. Dadurch sollen die Studierenden lernen, wie für das Chatbot-Programm sinnvolle Funktionen aus Paaren von Ein- und Ausgaben erstellt und kombiniert werden können. Die Studierenden müssen hierfür, damit der maschinelle Lernprozess funktioniert, die korrekten Funktionswerte zu einer Eingabe bereitstellen. Auf diese Weise lernen die Studierenden die Entwicklung von kontextspezifischen (Sprach-)Modellen. Dieser Prozess verläuft iterativ und wird in der Regel ständig angepasst und überarbeitet bis ein Modell zufriedenstellend funktioniert.

2 Chatbot-Projekte im Reallabor

Die im Rahmen des HRL durchgeführten Chatbot-Projekte (siehe Kapitel 3) orientieren sich am Experimentieren in Reallaboren (Schneidewind 2018), d.h. sie schaffen einen Rahmen, um vom »Wissen zum Handeln zu kommen«. Der idealtypische Ablauf des Reallabors nach diesem Verständnis erfolgt ko-kreativ mit Praxispartner:innen, die (1) gemeinsam mit den Studierenden das Projekt gestalten, (2) die technische Modellierung bzw. Produktion des Chatbots umsetzen und (3) das Er-

gebnis interpretieren und evaluieren (Gibbons 1994; Singer-Brodowski 2016). In diesem Ablauf spiegelt sich das Konzept, das dem Reallabor-Ansatz zugrunde liegt: Eine transdisziplinäre Zusammenarbeit von Wissenschaftler:innen, Studierenden und Praxispartner:innen, soll forschendes Lernen ermöglichen. Die Kontextgebundenheit, die aus der Anwendung des Wissens resultiert, ermöglicht eine kontinuierliche (Selbst-)Reflexion und Evaluierung, um die Ergebnisse immer wieder infrage zu stellen und an neue Bedingungen anzupassen. Reallabore sind demnach Lern-Settings für eine transdisziplinäre Erkundungsforschung (Pijetlovic 2020; Müller-Christ/Pijetlovic 2018), die den üblichen Fokus der Entwicklung und Anwendung von KI-Technologien über die Integration und Synthese von Wissen zur potenziellen Anwendung hinaus erweitern.

Das HumanRoboLab-Konzept

Das HRL versucht, die Erprobung von KI-Technologien im Reallabor in wirtschaftswissenschaftliche und wirtschaftspsychologische Studiengänge zu integrieren. Es zielt darauf ab, realweltliche Lernumgebungen in bestehende Module der Lehre in diesen Fächern zu integrieren, die einerseits die Anwendung digitaler Technologien ermöglichen und andererseits die Entwicklung von Kompetenzen für deren sinnvollen Gestaltung und Reflexion fördern. Kern des HRL-Konzepts ist die Verzahnung von theoretisch-methodischem Fachwissen, Erfahrung und (Selbst-)Reflexion. Dabei wird sowohl grundlegendes Fachwissen zu den Themenkomplexen gesprächsorientierte Künstliche Intelligenz und Kommunikationstheorien vermittelt als auch die konkrete praktische Auseinandersetzung mit dem System-, Ziel- und Transformationswissen gefördert, das die Studierenden im jeweiligen Chatbot-Projekt anwenden. Dieses Konzept wird durch die methodologische Perspektive der systemischen Erkundungsforschung ergänzt, die sich aus Theorien der Möglichkeitswissenschaften (Pfriem 2017) und Zukunftsforschung (Kreibich 2007) zusammensetzt. Dieses Wechselspiel aus Theorie und Praxis wird von Übungen zur (Selbst-)Reflexion begleitet. Dies stärkt nicht nur die Lernerfahrung, sondern ermöglicht auch einen kritischen Blick auf die eigenen Kompetenzen und Einfluss der Technologie auf das menschliche Verhalten. In diesem Sinne zählt das HRL-Konzept besonders auf die sogenannte *Third Mission* der Hochschulaktivitäten ein. Die *Third Mission* bedeutet, dass neben den anderen beiden Missionen Lehre und Forschung, die Hochschule sich in wechselseitiger Interaktion mit der außerhochschulischen Umwelt befindet und sich hierfür gesellschaftsrelevanter, reflexiver Ansätze und Methoden transdisziplinärer Forschung bedient (Henke et al. 2016). Darüber hinaus bietet die Entwicklung von Chatbot-Prototypen sowohl den Studierenden als auch ihren Praxispartner:innen nicht nur die Möglichkeit, digitale Transformationsräume (Freiling et al. 2020) unternehmerisch zu erschließen, sondern auch in den gesellschaftspolitischen Kontext hineinzutragen.

Eine Auswahl der Chatbot-Projekte aus dem HRL

Das HRL-Konzept wurde in die Bachelor- und Masterstudiengängen BWL und Wirtschaftspsychologie an der Universität Bremen integriert. Insgesamt haben bislang 84 Studierende am HRL teilgenommen. Die Lehrveranstaltungen (sechs/neun Credit Points) werden für ein Semester angeboten und schließen mit einer öffentlichen Projektpräsentation der entwickelten Chatbot-Prototypen ab. Diese Abschlusspräsentationen halten die Studierenden im Rahmen der *Digital Assistant Conference*, an der auch interessierte Unternehmensvertreter:innen teilnehmen können. Dieses Format hat bereits dazu beigetragen, einigen Studierenden über ihre Projektarbeit den Karriereeinstieg zu ermöglichen. Als Praxispartner:innen der Studierenden waren bislang die Sparkasse Bremen AG, die auf Raum- und Luftfahrt spezialisierte Technologiegruppe OHB SE, die Techniker Krankenkasse, die Beiersdorf AG, die Universum GmbH, die Universität Bremen, die EWE AG, die auf Forderungsmanagement spezialisierte Seghorn AG sowie die Tourismusförderung der Stadt Bremen an den Projekten des HRL beteiligt. Die Studierenden konnten dabei frei entscheiden, mit welchen Praxispartner:innen zusammen sie ihre Projekte umsetzen wollen.

Im Nachfolgenden wird eine kleine Auswahl der Projekte aus dem HRL vorgestellt, um einen Eindruck davon zu vermitteln, für welche Praxiskontexte die Studierenden bereits voll funktionsfähige Chatbots entwickelt haben:

TiKay-Bot (Techniker Krankenkasse)

Der TiKay-Bot optimiert die Suche nach einem Pflegeplatz. Durch gezieltes Abfragen der notwendigen Informationen über Pflegeart, Pflegeschwerpunkt, Pflegegrad und Ort des Pflegeheims im Verlauf eines Chat-Gesprächs kann TiKay auf Grundlage einer Datenbank eine Liste mit geeigneten Pflegeheimen zusammenstellen. Durch diese Vorauswahl erhalten Suchende einen informativen Überblick über potenziell passende Einrichtungen und können sich auf die Kontaktaufnahme zu den ausgewählten Pflegeheimen konzentrieren. Darüber hinaus ist der TiKay-Bot in der Lage, allgemeine Fragen zu Themen wie Kosten, Leistungen oder Betreuung in der Pflege zu beantworten oder den direkten Kontakt zur Informationsquelle herzustellen.

Museums-Bot XT-9U (Universum GmbH)

XT-9U ist ein Chatbot für den Bereich »Digitale Welten« im Erlebnismuseum Universum in Bremen. XT-9U besitzt Wissen über KI und Robotik. Die Besucher:innen des Museums sollen durch den Chatbot erfahren, welche Art von KI ihm selbst zugrundeliegt und welche Sensoren beispielsweise die von SoftBank Robotics entwickelten Roboter PEPPER und NAO nutzen, um eine Unterhaltung führen zu können. XT-9U ist nach dem Vorbild eines interessierten Wissenschaftlers gestaltet, der

Neues entdecken möchte und gerne auch die Antworten der Besucher:innen hinterfragt. Der Name des digitalen Assistenten ist inspiriert durch die Star-Wars-Roboter R2D2 und C3PO. Bei XT-9U steht das XT für eXtending Technology, die 9 für sein Entwicklungsjahr 2019 und das U für Universum – den Namen des Erlebnis-museums.

Design Thinking bot (Universität Bremen)

Der Design Thinking Bot hat die Aufgabe, Teilnehmer:innen einer nach den Regeln des Design Thinking gestalteten Design Challenge durch den Entwicklungsprozess ihrer Produkte zu begleiten. Der Chatbot kennt die einzelnen Prozessschritte des Design Thinking und kann die Teilnehmer:innen durch die Phasen leiten, Fragen zum Prozess beantworten und nützliche Hinweise für Bearbeitungsschritte geben. Die besondere Herausforderung dieses Projekts bestand darin, einen Chatbot zu entwickeln, der keine Vorgaben macht, sondern nützliche Anregungen liefert und das kreative Denken der Nutzer:innen fördert.

Alan (OHB SE)

Alan ist ein Chatbot, der in Zusammenarbeit mit der OHB Gruppe entwickelt wurde. Alan soll Astronaut:innen im All dabei unterstützen, Probleme und Fehler schnell und effizient zu lösen. Da er – im Gegensatz zu Expert:innen auf der Erde – eventuelle Fragen ohne Verzögerung durch die Übertragung des Gesprächs geben kann, ermöglicht er Echtzeit-Support. Im Mittelpunkt dieses Bot-Projektes steht das von OHB gefertigte Serviceelement, das International Standard Payload Rack auf Basis des European Physiology Module (kurz: EPM). Das EPM ist für Experimente konstruiert und stellt eine wichtige Forschungseinrichtung des Columbus-Raumlabors auf der internationalen Raumstation ISS dar. Der von den Studierenden entwickelte digitale Assistent Alan soll im ersten Anwendungsszenario Astronaut:innen dabei helfen, einen Fehler im Stromkreislauf zu beheben, der bereits im Jahr 2010 auf der ISS auftrat und sich dadurch äußerte, dass die Stromverteilungseinheit nicht mehr ordnungsgemäß funktionierte.

Gelernte Kompetenzen und Fähigkeiten

Im Rahmen der Chatbot-Projekte im Reallabor konnten sich die Studierenden Kompetenzen (s. Tabelle 1) aneignen, die es ihnen u.a. ermöglichen, die Relevanz der Auseinandersetzung mit Chatbots in verschiedenen Anwendungsbereichen besser einzuschätzen, Missverständnisse in der Debatte über KI und Chatbots auszuräumen sowie die mediale Berichterstattung über KI-Entwicklungen besser zu verstehen und anhand ihrer neu erworbenen Kenntnisse korrekt einzuordnen. Bei allen Chatbot-Projekten waren dabei zwei zentrale Schlüsselkompetenzbereiche allgegenwärtig: (1.) Das Generieren von Datensätzen, um ein geeignetes Sprachmo-

dell aufzusetzen und anschließend trainieren zu können. Diese Datensätze können auf Grundlage strukturierter oder unstrukturierter Daten zusammengestellt werden. Die Studierenden im Reallabor haben vorrangig unstrukturierte Daten erzeugt, die sie dann in Wenn-Dann-Beziehungen zueinander gesetzt haben, um klare Abfolgen von Intents (Input) und Dialog (Response) zu ermöglichen. Dieser Prozess der Datenstrukturierung ist notwendig, weil dem Chatbot-Programm simple Hintergrundinformationen fehlen, die menschliche User:innen ganz selbstverständlich in jede Kommunikation einbringen. So wissen die User:innen etwa, dass man sich beispielsweise bei der ersten Begegnung begrüßt und erst danach tiefer in die Interaktion einsteigt – doch einem Chatbot muss diese soziokulturell begründete Konvention erst durch entsprechende Abfolgen von Intents und Dialog beigebracht werden. Die Herausforderung für die Studierenden besteht darin, sich Selbstverständlichkeiten wie diese bewusst zu machen und die Daten dann so aufzubereiten, dass eine sinnvolle Interaktion für einen bestimmten Zweck gelingen kann. (2.) Für das jeweilige Fallbeispiel, das der Chatbot durch zweckmäßige Interaktion beherrschen soll, muss die KI auch in der Lage sein, die Zielsetzung der jeweiligen User:innen zu identifizieren und mit einem entsprechenden Prozess des lösungsorientierten Handelns übereinzubringen: Nur so kann die Interaktion zu einem Ziel führen, das am Ende den Nutzer:innen auch wirklich dienlich ist. Die Studierenden erarbeiten daher zunächst einen Algorithmus, also eine Vorschrift, die beschreibt, wie sich bestimmte Ziele Schritt für Schritt erreichen lassen. In der KI ist ein Algorithmus eine Vorschrift zum Lösen eines (mathematischen) Problems, die in eine Programmiersprache übersetzt wurde. Um einerseits die Prozesse, die der Chatbot unterstützen soll, besser zu verstehen und andererseits passende Datensätze für ein auf ebendiese Prozesse zugeschnittenes Sprachmodell zu generieren, haben die Teilnehmer:innen des Reallabors Experteninterviews durchgeführt. Auf diese Weise konnten die Studierendenteams erste Erfahrungen in Prozessanalyse und Modellierung von Sprachmodellen sammeln – zwei Schlüsselkompetenzen für den souveränen Umgang mit KI.

Tabelle 1: Kompetenzbereiche der Studierenden im HRL-Kontext (eigene Darstellung).

BEREICH	KOMPETENZ
Methodisch	• Maschinelles Lernen (Supervised Learning) • Datenbeschaffungsmanagement • Dialogmanagement
Fachlich	• Wissen über Funktionsweise digitaler Dialogsysteme (Chatbots) • Praktisches Handlungswissen in Bezug auf Modellierungsstrategien • Systemische Perspektive auf KI
Persönlich	• Entwicklung einer forschenden Haltung zu KI-Anwendungen • Selbsterkenntnis durch die Auseinandersetzung mit KI • Überführung praxisrelevanter Ideen in digitale Anwendungen

Darüber hinaus konnten die Studierenden durch die Teilnahme am HRL erfahren, ob eine Tätigkeit im Bereich der Chatbot-Entwicklung – oder auch ganz allgemein in der Arbeit mit KI-Anwendungen – ihrer eigenen Persönlichkeit entspricht und sie sich auch nach Abschluss ihres Chatbot-Projekts in Richtung Maschinelles Lernen, User Interaction Design oder Conversational User Experience Design fachlich weiterentwickeln möchten. Gleichzeitig konnten aber auch die Praxispartner:innen dank der Arbeit an den Chatbot-Projekten eigene Lerneffekte verzeichnen. Der transdisziplinäre Ansatz des Reallabors hat dazu beitragen, dass a) eine Kultur der Kreativität und Innovation entstehen konnte, die den Wissensaustausch zwischen Hochschullehre und Wirtschaftspraxis angeregt hat, b) die Praxispartner:innen ein besseres Verständnis für Chatbot-Technologie entwickelt sowie Transformationswissen für ihr Arbeits- und Unternehmensfeld erworben haben und alle Beteiligten praktische c) Erfahrung in kollaborativer Agilität sammeln konnten.

3 Quo vadis, Chatbot-Reallabor?


In dieser abschließenden Reflexion werden erste Gedanken aufgeworfen, die im HRL-Konzept berücksichtigt und vertieft werden sollen. Diese Reflexionen entstanden durch Gespräche im Team der Lehrenden, durch die Evaluierungen der Lernerfahrungen mit den Studierenden und Praxispartner:innen und durch weitergehende Chatbot-Projekte in anderen Kontexten.

HRL 2.0

Für alle Beteiligten ist die Tatsache frustrierend, dass die Chatbot-Projekte es bislang nicht über die Prototypphase hinaus geschafft haben in eine dauerhafte Umsetzung und Implementierung in der Praxis zu gelangen. Daher ist auch naheliegend, dass sowohl die Studierenden als auch die Praxispartner:innen den Wunsch äußerten, ein weiteres Semester »geschenkt« haben zu wollen, um ihr Chatbot-Projekt in die Verstetigung zu überführen. Daher sollen im Rahmen des HRL die Chatbot-Projekte zukünftig konsequenter in die Umsetzung geführt werden, um dadurch einen Beitrag zur Erneuerung der Wirtschaft und Stärkung der digitalen Transformation zu leisten. Dies erfordert Anschlussformate nach einer ersten Stufe der Zusammenarbeit im Rahmen der Chatbot-Projektarbeiten während des ersten Semesters. Das HRL könnte dies in unterschiedlicher Weise umsetzen:

- a) Die Semesterprojekte (ca. 100 Tage) werden um ein weiteres Semester (ca. 100 Tage) verlängert.
- b) Chatbot-Projekte, an denen bereits über ein Jahr in Form von Lehrveranstaltungen gearbeitet worden ist, werden in extramurale Formate überführt oder in die Innovations- bzw. Neugeschäftstätigkeit des projektgebenden Betriebs integriert. Jenseits von HRL und den projektgebenden Betrieben könnten standortbezogene Inkubatoren und Akzeleratoren diese Übernahmeformate darstellen. Das HRL muss seinerseits dafür Voraussetzungen schaffen, dass die Projekte rechtzeitig auf solche Formate vorbereitet werden und Abstimmungen erfolgen, die ein »Handover« ermöglichen. Es deckt dabei idealtypisch und wie in Abbildung 3 dargestellt die ersten beiden Stufen einer vierstufigen Chatbot-Projektentwicklung bis zur erfolgreichen Implementierung ab.

Abbildung 3: Chatbot-Projekte als Frühstufe digitaler Geschäftsentwicklung (eigene Darstellung).



Zusatzangebote

Nach wie vor ist das HRL-Konzept darauf ausgelegt, die technologischen Möglichkeiten von Chatbots auszuschöpfen, ohne dass die Studierenden dabei Programmiersprachen anwenden müssen. Das erleichtert zwar einerseits den Einstieg in die Materie, beschränkt jedoch auch das Potenzial der daraus resultierenden Anwendungen: Der Einsatz von Programmieranwendung würde deutlich mehr Möglichkeiten für die Gestaltung der Chatbots eröffnen. Beispielsweise könnten mit Hilfe von Programmiersprachen wie JavaScript Anwendungsschnittstellen (API) zu Datenbanken programmiert oder der Chatbot in eine Webpage integriert werden. Darüber hinaus bleibt auch der Bereich des maschinellen Lernens, also die Frage, auf welche Arten Maschinen lernen können, im Rahmen des Projekts derzeit noch größtenteils in der Anwendung unberührt.

Weitere Wissens- und Lernbausteine zu Maschinellern, Algorithmen und Programmierung wären daher sinnvolle Ergänzungen, um den Studierenden einen größeren Handlungsspielraum in Bezug auf ihre eigenen Chatbots zu ermöglichen. So könnte es für die Studierenden beispielsweise nützlich sein, zukünftig auf ein ergänzendes Lehrangebot zurückzugreifen, dass sich mit der Erstellung eigener Algorithmen für die Projekte im Reallabor beschäftigt. Hierfür haben die Studierenden sich Workshop-Formate gewünscht, die neben der Lehrveranstaltung besucht werden können. So können die Studierenden eine zusätzliche digitale Schlüsselkompetenz erwerben und zugleich die Interaktionsfähigkeit ihrer Chatbots gezielt erhöhen. Alternativ ließen sich die genannten technischen Limitationen auch durch eine interdisziplinäre Einbindung von Fachgebieten wie

Informatik und Digitale Medien ein Stück weit nivellieren, indem beispielsweise ein*e Studierende*r der Informatik in jeder Projektgruppe angehört.

Die Herausforderung: Chatbots als Lernbegleiter

Blicke in die Literatur und Besuche auf den entsprechenden Plattformen im Internet zeigen, dass Chatbots im Hochschulbereich explosionsartig zunehmen, gleichwohl hinterlassen viele Beispiele den Eindruck, als wenn die Technologie zumeist dazu genutzt wird, um sehr einfache Dialoge und regelbasierte Aufgaben zu bewältigen. So gibt es Chatbots im Hochschulbereich, die eingesetzt werden, um Studierende bei der Bewältigung von Aufgaben mit vordefinierten Regeln zu unterstützen. Beispielsweise bei Mathematik-Aufgaben oder für das Erlernen einer neuen Fremdsprache. Für Fremdsprachen werden die Chatbots als Dialogpartner eingesetzt, um Gesprächssituationen zu trainieren oder den Wortschatz zu erhöhen. Die Arbeit von Bao (2019) gibt hier einen Einblick in diesen Bereich, in der es darum geht, die Angst vor Fremdsprachen durch Chatbot-Interaktionen zu verringern. Es gibt auch Chatbots im Hochschulbereich, die bei administrativen Aufgaben unterstützen. Ein Beispiel hierfür findet man in der Studie von Galko et al., (2018), wo der Einschreibungsprozess für Studierende vollständig in einen Dialog mit einem Chatbot verlagert wurde. Allerdings sind diese Arten von Chatbots vordefinierte Anwendungen, die User:innen zwar nutzen aber nicht selber für ihren individuellen Lernprozess gestalten können. Für die Hochschulbildung sind daher diese einfachen Anwendungsfälle erste Schritte, die das KI-Potenzial allerdings noch nicht vollständig ausreizen. Der vermutlich lange Weg zu einer gelingenden (Prozess-/Lern-)Begleitung durch Chatbot-Systeme soll perspektivisch dazu beitragen, dass Lernende ihren Lernprozess stärker reflektieren und selbstgesteuert vertiefen können. Wir glauben, dass diese Aufgabe niemand besser lösen kann als die Studierenden und die Lernenden selbst. Was sie hierfür allerdings benötigen, sind Kenntnisse und Fähigkeiten einen solchen Chatbot als Lern-Begleiter für sich zu entwickeln, um eigenständig festzulegen, welche Lernziele über welchen Weg erreicht werden sollen. Die Vermutung und Hoffnung ist, dass auf diesem Wege das KI-Potenzial von Chatbots zu einer Lern- und Bewusstseinsentwicklung bei Menschen beitragen kann.

Denis Pijetlovic: Universität Bremen, Postdoctoral Researcher im Fachgebiet Nachhaltiges Management; denis.pijetlovic@uni-bremen.de

Literatur

- Abdoos, M., Mozayani, N., & Bazzan, A. (2015). Towards reinforcement learning for holonic multi-agent systems. *Intelligent Data Analysis*, 19(2), 211–232. Amsterdam: IOS Press.
- Bao, M. (2019). Can Home Use of Speech-Enabled Artificial Intelligence Mitigate Foreign Language Anxiety – Investigation of a Concept. *Awej* 5, 28–40.
- Bendel, O. (2020). Serviceroboter aus Sicht der Ethik. In M. Lindau & M. Meier Kresling (Hg.), *Schöne neue Welt? Zwischen technischen Möglichkeiten und ethischen Herausforderungen* (S. 57–76). Bielefeld: transcript.
- Bitkom e.V. (2018). *Digitalisierung gestalten mit dem Periodensystem der Künstlichen Intelligenz – Ein Navigationssystem für Entscheider*. https://www.bitkom.org/sites/default/files/201812/181204_LF_Periodensystem_online_o.pdf Zugegriffen: 18. Dezember 2020.
- de Witt, C., Rampelt, F., Pinkwart, N. (Hg.). (2020). *Künstliche Intelligenz in der Hochschulbildung*.-Whitepaper. Berlin: KI-Campus.
- Feine, J., Morana, S. & Maedche, A. (2019). Designing a Chatbot Social Cue Configuration System. In *Proceedings of the 40th International Conference on Information Systems (ICIS)* (S. 5–6). München: AISel.
- Freiling, J., Holli, M. & Stührenberg, K. (2020). *Exploration durch digitale Transformationsräume. Das Beispiel »future concepts bremen«*. Austrian Management Review Vol. 10 (1) (S. 47–59). Hg.: Wolfgang H. Güttel, Baden-Baden: Rainer Hampp Verlag.
- Galko, L., Porubán, J., and Senko, J. (2018). »Improving the User Experience of Electronic University Enrollment,« in 16th IEEE International Conference on Emerging eLearning Technologies and Applications, ICETA 2018, Sary Smokovec, Slovakia, Nov 15–16, 2018. Editors F. Jakab, (Piscataway, NJ: IEEE), (S. 179–184).
- Gibbons, M., Limoges, C., Nowotny, H., Schwartzman, S., Peter, S., & Trow, M. (1994). *The new production of knowledge: The dynamics of science and research in contemporary societies*. London: Sage Publications Ltd.
- Gomes, H., Barddal, J., Enembreck, F., & Bifet, A. (2017). A survey on ensemble learning for data stream classification. *ACM Computing Surveys*, 50(2), 23:1–23:36.
- Hammond, K. (2017). *Here and now: Bringing AI into the enterprise*. <https://conferences.oreilly.com/artificial-intelligence/ai-ny-2017/public/schedule/detail/59188> Zugegriffen: 18. Dezember 2020.
- Henke, J., Pasternack, P. & Schmid, C. J. (2016): Third Mission von Hochschulen. Eine Definition. In *Das Hochschulwesen* 64 (1/2) (S. 16–22). Bielefeld: UniversitätsVerlagWebler.
- Höltgen, S. & Baranovska, M. (Hg.). (2018). *Hello, I'm Eliza. 50 Jahre Gespräche mit Computern*. Bochum/Freiburg: Projekt Verlag.

- Human-Robo-Lab (2020). *Studentische Bot-Projekte*. <https://www.uni-bremen.de/nm/transfer/human-robo-lab/studentische-bot-projekte> Zugegriffen: 19. Dezember 2020.
- Kreibich, R. (2017). *Wissenschaftsverständnis und Methodik der Zukunftsforschung*. In *Zukunftszeichen: Semiotik und Futurologie*, Zeitschrift für Semiotik, Bd. 29, Heft 2–3/2007 (S. 318).
- Lamprecht, S. (2016). *Digitale Quasselstrippe – Interessante Chatbot-Gründungen*. eTailment vom 26. September 2016. <https://etailment.de/news/stories/Digitale-Quasselstrippen---interessante-Chatbot-Gruendungen-4377> Zugegriffen: 20. Dezember 2020.
- McTear, M., Callejas, Z., & Grigol, D. (2016). *The Conversational Interface. Talking to Smart Devices*. Cham: Springer International Publishing.
- Michiels, E. (2017). *Modelling Chatbots with a Cognitive System Allows for a Differentiating User Experience*. Doctoral Consortium and Industry Track Papers, 2017, 70–78.
- Müller-Christ, G. & Pijetlovic, D. (2018). *Komplexe Systeme lesen. Das Potential von Systemaufstellung für Wissenschaft und Praxis*. Wiesbaden: Springer Gabler.
- Pijetlovic, D. (2020). *Das Potential der Pflege-Robotik. Eine systemische Erkundungsforschung*. Wiesbaden: Springer Gabler.
- Roßbach, P. (2017). Machine Learning, Modern Data Analytics and Artificial Intelligence – What’s New? BIT. Banking & Information Technology, 18(3), (S. 13–19). Regensburg: Ibi Research GmbH.
- Satow, L. (2018). Lernen mit Chatbots und digitalen Assistenten. In K. Wilbers (Hg.), *Handbuch E-Learning* (S. 1–14). Köln: Wolters Kluwer.
- Schikora C., Galster S. & Högerl, D. (2020) Digitalisierung im Recruiting: Chatbots. In M. Harwardt, P.J. Niemann, A. Schmutte & A. Steuernagel (Hg.), *Führen und Managen in der digitalen Transformation* (S. 266–281). Wiesbaden: Springer Gabler.
- Schneidewind, U. (2018). *Die große Transformation: eine Einführung in die Kunst gesellschaftlichen Wandels*. Frankfurt a.M.: Fischer Taschenbuch.
- Singer-Brodowski, M. (2016). Transformative Bildung durch transformatives Lernen. Zur Notwendigkeit der erziehungswissenschaftlichen Fundierung einer neuen Idee. ZEP: Zeitschrift für internationale Bildungsforschung und Entwicklungspädagogik, 39(1), (S. 13–17).

Wie wollen wir leben?

Ulf-Daniel Ehlers

Die Entwicklung von Künstlicher Intelligenz (KI) scheint unser Menschenbild infrage zu stellen. Denn was ist die Bedeutung von *Intelligenz*, wenn Maschinen *intelligent* werden? Fangen die ungeheuren Entwicklungen im Bereich der Digitalisierung an, den fundamentalen Unterschied zwischen *Mensch*-lichem Denken und *Maschine*-ller Informationsverarbeitung zu verwischen?

Zeit, weiterzudenken!

Zunächst: KI ist die Nutzung von algorithmischer Entscheidungsunterstützung. Diese schreitet in so unaufhaltsamer Weise voran, dass Ray Kurzweil, Leiter der technischen Entwicklung bei Google, den Zeitpunkt, an dem eine künstliche Superintelligenz die biologische Intelligenz der Menschheit überflügelt, auf das Jahr 2045 terminiert (vgl. Kurzweil, 2005, Bostrom, 2014). Technikpioniere wie Stephen Hawking, Elon Musk und Bill Gates pflichten bei – warnend (vgl. Musk, 2014, Kerkmann, 2017). Laut Allan Dafoe, Direktor des Centre for the Governance of AI at the Future of Humanity an der Universität Oxford, wird KI den Menschen schon bald in vielen Gebieten überholen: beim Übersetzen von Sprachen (2024), Schreiben von Schulaufsätzen (2026), Fahren eines Lkws (2027), Arbeiten im Einzelhandel (2031), Verfassen eines Bestsellers (2049) oder bei chirurgischen Operationen (2053) (vgl. Grace et al., 2018). Noch viel dramatischer ist es, dass bereits heute, im Jahr 2020, nicht mehr zu übersehen ist, welchen enorm verzerrenden Einfluss KI auf die Filterbubbles politischer Kommunikation – und damit das Herz demokratischer Gesellschaften haben kann.

KI als neue Weltlenkerin? Nein! Zumindest für absehbare Zeit ist ein solches Horrorszenario nicht zu befürchten. Zwar werden die Änderungen im Alltagsleben durch KI stärker als bisher erkennbar – aber trotzdem: Bei KI-Systemen handelt es sich bei weitem nicht um eine dem Menschen vergleichbare Intelligenz, sondern eher um sehr spezifische Nischenfähigkeiten, die bei eng definierten Aufgaben überlegen sind, aber außerhalb ihres Daseinszwecks oft bei den einfachsten Tätigkeiten scheitern. Sie können viel, haben aber klare Limitationen. Während Alpha

Zero, eine Schach-KI, zwar den Schachweltmeister besiegen kann, fehlt Computern eigener Antrieb, Willensfreiheit, Bewusstsein, Fähigkeit zur Selbstreflexion und Verständnis unserer Welt. Sinn, Verstehen und Verantwortung sind Konzepte, die für KI schon kategorial unpassend sind. KI kann damit auch weder böswillige noch heimtückische Intentionen verfolgen und auch keine Verantwortung für ihr Tun übernehmen – verantwortlich ist und bleibt der Mensch.

»KI« als ein Kategorienfehler

Maschinen können helfen, schneller Datenoperationen auszuführen – aber helfen sie auch, bessere Entscheidungen zu treffen? Maschinen helfen logischer zu folgern – aber helfen sie auch, skeptisch zu zweifeln? Maschinen können Daten vereinen aber können sie auch Widerstand organisieren? Maschinen können Informationen aufbereiten aber können sie auch Unbestimmtheit zulassen?

Im Begriff der *Künstlichen Intelligenz* liegt das, was Niklas Luhmann einen Kategorienfehler nannte. Ein Kategorienfehler ist es, wenn eine Bäckerin versucht *belegte Brötchen* zu backen oder ein Bauer, *Bratkartoffeln* zu pflanzen. Im Wortspiel *Künstliche Intelligenz* werden zwei fundamental verschiedene Kategorien verwechselt: das Lösen strategischer (und formalisierbarer) Probleme, das in der KI als Intelligenz interpretiert wird einerseits und das Bewusstsein, das in der Fähigkeit besteht, auf die Komplexität der Welt durch Kreativität und Gefühl zu antworten andererseits. Kann KI letzteres? Nein, denn dazu müssen soziale, emotionale und Künstliche Intelligenz zusammenwirken.

Bildung. Entwickeln Computer eine umfassendere Unterstützung im Lebensvollzug von Menschen, so hat dies auch Auswirkungen auf Ziele, Methoden und Anforderungen von Bildung. Bildung im Zeitalter der künstlichen Intelligenz muss Menschen primär in der Entwicklung von Handlungsfähigkeit für eine Welt unterstützen, die durch ständig emergente Zustände geprägt ist, in der sich also die Zukunft nicht mehr durch die Kenntnis der Vergangenheit bewältigen lässt. Ein so verstandenes Bildungsziel geht weit über bisherige wissensorientierte Vermittlungsansätze hinaus. Bildung kann nicht die Aufgabe haben, Menschen in Bezug auf die Datenverarbeitungsgeschwindigkeit konkurrenzfähig mit Maschinen zu machen, sondern muss sie künftig vielmehr im Entscheiden, im Zweifeln und im Widerständigen fördern.

Weltaneignung. Aber worum geht es bei der Bildung eigentlich? Bildung ist ein individueller Prozess des Subjektes. Er besteht in der Ausbildung eines Verhältnisses zu sich selbst, zu den Gegenständen der Welt und zur Gesellschaft. Bildung ist Weltaneignung. Ihr institutionelles Pendant ist das Lernen. Als System hat sie ein *Techno-*

logiedefizit (vgl. Luhmann & Schorr, 1982). Das bedeutet, sie kann nicht auf dieselbe zweckrationale Weise wie etwa ein Produktionsprozess optimiert werden. Sie zielt darauf ab, die Partizipationsfähigkeit von Menschen in der Gesellschaft zu fördern oder dort, wo diese abhandengekommen ist, wieder herzustellen. Damit ist Bildung die Bühne für die Förderung der Handlungsfähigkeit von Menschen im Zeitalter von KI. Wie müssen die Konturen einer solchen Bildung aber aussehen?

Zweifel, Unsicherheit, Widerstand

Zweifel. Bildung muss vor allem das Zweifeln lehren. Denn: Konsens wird nur durch Zweifel möglich und erreicht. Grenzen schaffen erst den Wunsch zur Grenzenlosigkeit. Widerständigkeit ermöglicht erst das Lernen. Krisen bewirken das Suchen von Innovationen und das Gehen neuer Wege. Der Wert des Zweifels, das Gewicht der Unsicherheit, die Weite des Widerstands und die Kraft des Unbestimmten sind für unsere Gesellschaft konstituierend, für Demokratie, für das Zusammenleben. Freiheit entsteht erst dort, wo immer beide Pole einer Relation wirken können: Zweifel und Gewissheit, Wahrheit und Erkenntnis. Nicht nur das Korrelat ist das Entscheidende, sondern die Relation ist es, auf die es ankommt. Nicht Balance ist der natürliche Zustand, sondern das oszillierende Spiel zwischen beiden Polen im Wettbewerb und im Ringen um Stabilität. Bestimmt die Spieltheorie dieses Ringen als rationales Tun, so gerät sie dort, wo irrational entschieden wird, ins Dilemma. In diesem Sinne muss Bildung also nicht Gewissheit vermitteln, sondern genauso die Fähigkeit zum Zweifel, zum Einnehmen und Verwerfen von Positionen und zur Reflexion der eigenen Position im Spielraum der Möglichkeiten.

Will die KI mit der Unsicherheit der Welt umgehen, muss sie noch viel vom Menschen dazu lernen. Allerdings geht es dabei nicht um graduelles »mehr« Lernen, sondern um das Erlernen eines prinzipiell anderen Weltzugangs: Nämlich des Erlernens, Verantwortung zu übernehmen.

Widerständigkeit. Die Zukunft der Gesellschaft spannt sich wie ein Horizont, der sich aus Erwartungen ihrer Mitglieder bestimmt. Sie wird nicht rational entworfen. Der Bielefelder Soziologe Niklas Luhmann beschreibt, dass soziale Systeme sich auf Basis der Erwartungen ihrer Mitglieder auf die Zukunft ausrichten (vgl. Luhmann, 1990). Die Selbstreferenz des einzelnen Systems lernt dabei im Wettstreit mit anderen.

Es sind die unterschiedlichen Perspektiven gesellschaftlicher Gruppen, verschiedener kultureller Territorien, des Gewebes aus kleinsten kulturellen, subkulturellen und individuellen Milieus, welche die Voraussetzung für den Zweifel, für die Ungewissheit, für die Krise und den Widerstand bilden. Und nur so können Lernen, Innovation, Konsens in die Welt kommen.

Wir unterscheiden zukünftige Gegenwart und gegenwärtige Zukunft voneinander. Im Wettbewerb von gegenwärtigen Zukünften – also Projektionen in Gestalt von Utopien – und den zukünftigen Gegenwarten, die wir versuchen durch technologische, kausale oder stochastische Verbindungen zukünftiger Ereignisse vorherzusagen, zu formen und anzustreben, ist es das Unbehagen, dem eine entscheidende Rolle zufällt. Und es ist die Ungewissheit, die ein hohes Gewicht hat, es sind gerade die Ungereimtheiten, die als Kompassnadel fungieren. Denn sie stellen infrage, welche Wege eingeschlagen werden, welche technologischen Orientierungen angemessen sind und wie Entwicklung und Abläufe kausal miteinander zusammenhängen. Der Zweifel ist für die Wissenschaft, für die Gesellschaft und für die Zukunft konstituierend.

Wahrheit schließt lernen aus

Lernen. Algorithmische Gewissheit und absolute Wahrheit als Kategorien schließen Lernen (im widerständigen und ganzheitlichen Sinne) zunächst aus. Gewissheit und Wahrheit schließen Widerständigkeit aus. Zweifel und Widerständigkeit aber fördern Erkenntnis. Zwischen Erkenntnis und Wahrheit liegt daher ein Spannungsfeld, im unabdingbaren stetig voranschreitenden Ringen. In einem gegenseitigen Bedingen von erreichtem Verstehen und unbekannter Zukunft. In dieser polaren Dialektik entsteht die Identität menschlichen Zusammenlebens. Gerade die Kunst, Kultur und die Geisteswissenschaften beschäftigen sich damit, was gedeihlich und was hinderlich für das Zusammenleben der Menschen ist – oftmals allerdings erst im Nachhinein. Dafür sind sicher nicht nur die großen gesellschaftlichen Herausforderungen gute Beispiele, also Themen wie der Klimawandel, die Digitalisierung, Bekämpfung des Hungers in der Welt, die Herausforderungen der Globalisierung und des globalen Finanzsystems.

Kunst. Kunst als Instanz der Reflexion der Verhältnisse stellt Fragen und stellt infrage, bestätigt und unterstreicht, intensiviert und übertreibt. Sie dient dem gesellschaftlichen System dazu, aus seiner begrenzenden Selbstreferentialität auszubrechen und zu lernen. Sie dient dem Lebensblick als Erweiterung, der zukünftigen Gegenwart als Orientierung und der gegenwärtigen Zukunft als Kritik. Die Beschäftigung mit der KI in der Kunst ist insofern eine *conditio sine qua non*.

Zukünftige Gegenwart oder Gegenwärtige Zukunft

Kritikpunkt. KI steht prototypisch für die Entwicklung einer zukünftigen Gegenwart. Doch in welcher Weise und aus welcher Perspektive ist sie zu kritisieren? Es

gibt nur diesen einen Weg, Fragen zu stellen: Wie gut ist sie geeignet für das Oszillieren zwischen den Polen der Entwicklung. Jede gesellschaftliche Bewegung, jede wissenschaftliche Erkenntnis, jede künstlerische und kulturelle Entwicklung entsteht (zunächst) als ungewisser Versuch im Oszillieren zwischen den Polen der zukünftigen Gegenwart eine Position einzunehmen. Versagt man diese suchende Unsicherheit, so entsteht Populismus, Diktatur und Monokausalität. Weitert man aber den Blick, so wird deutlich, dass Wahrheit als Konzept auf Erkenntnis angewiesen ist und erst im Spannungsfeld beider Pole Entwicklung stattfinden kann. So öffnet man sich der stetigen konstanten Suche um die Balance des menschlichen und technischen Miteinanders.

Paradoxien. Mit Wittgenstein können wir formulieren, dass Sprache Position bildet, dass Sprache Bewusstsein und Struktur schafft (vgl. Wittgenstein, 1921). *Künstlich* und *kunstvoll* könnten hier im Begriff der KI keine größeren Gegenpole darstellen. Die Kunst ist der Gegenpol zur künstlichen Intelligenz. Während die eine im Modus der Unsicherheit agiert (Kunst als Suche zukünftiger Gegenwarten), agiert die andere im Modus sicherer Bestimmung und schließt Unsicherheit aus (Künstliche Intelligenz als Suche nach gegenwärtigen Zukünften). Die Kunstaussstellung MENSCH MASCHINE – Sophia lernt Zeichnen von Markus Jäger ist in diesem Sinne provokativ. Sie ist früh dran. Sie polarisiert insofern, als dass sie in kunstvoller Weise für die KI die Fähigkeit des Perspektiveinnehmens vor- sieht (wie sieht KI die Welt?). Sie provoziert, in- dem sie damit genau derjenigen Instanz die Fähigkeit zuschreibt sich zukünftige Gegenwarten auszumalen, die eigentlich auf das Kreieren gegenwärtiger Zukünfte fokussiert ist. In diesem Paradox ist MENSCH MASCHINE Zukunftskunst.

Die Paradoxie fragt: Kann KI überhaupt so etwas wie eine *Sichtweise* einnehmen? Können Künstliche Intelligenzen überhaupt verschiedene, konkurrierende Perspektiven gegeneinander abwägen? Kann sichere, digitale Kalkulation auch Unsicherheit erzeugen? Können Algorithmen Zweifel kultivieren? Können wir mit *machine learning* Krisenerfahrung und Irritation erzeugen? Für Bildung sind diese Fragen wichtig – denn gerade hier, im Erstaunen oder um mit Karl Jaspers zu sprechen, in der Grenzsituation, im Zweifel und in der Widerständigkeit werden wir ja zum Mensch (Jaspers, 1956). Gerade hier, im Ringen um Erstaunen, Zweifel und Widerständigkeit, formt sich die Gesellschaft. Die Kunstaussstellung MENSCH MASCHINE verweist die KI daher auf ihren Platz.

Digitale Souveränität. Was bedeutet diese Bildkunst für die Bildung der Zukunft und für Zukunftsbildung? Bildung zielt auf Handlungsfähigkeit des Subjekts ab. Und zwar in Souveränität mit sich als Subjekt, mit der gegenständlichen Objektwelt und mit der Gesellschaft. In Bezug auf KI und Bildung stellt sich die Frage, wie eine solche digitale Souveränität aussieht. Und da wird es kompliziert. Denn es gilt nun

genau denjenigen Punkt zu bestimmen, an dem Digitalisierung unsere Souveränität als Menschen vielleicht bereits in Frage gestellt hat. Der kanadischen Medientheoretiker Marshall McLuhan formuliert: Wir formen unsere Werkzeuge, danach formen unsere Werkzeuge uns.

Was folgt daraus für die Frage nach der Bildung der Zukunft: Zunächst einmal müssen zukünftige Bildungserfahrungen mehr Fragen behandeln, für die es keine richtigen und falschen Antworten gibt. Denn einer Zukunft im Zustand der Emergenz, sich stetig wandelnd und ungewiss, kann nicht mit gewissem Wissen begegnet werden, nur im Training und der Analyse, in der Kritik und Gestaltung von Ungewissheit.

Dann: Wenn wir als Menschen Maschinen erschaffen, die Aufgaben mit Sicherheit und Gewissheit schneller, besser und überdauernder erledigen, so entstehen ganz neue Möglichkeitsräume für unser menschliches Handeln und auch für unser Bildungsbemühen. Sie weiten sich, erlauben Neues zuzulassen, wie die Konzentration darauf, das Gewicht der Ungewissheit zu erfahren, die Weite und Bedeutung des Zweifels und die Tiefe und die Wichtigkeit der Widerständigkeit. Erstaunen, Ethik, Perspektivwechsel, Verantwortung und Ambiguität, Sinnstiftung und Visionsfähigkeit stellen sich dann als Bildungsinhalte gleichwertig neben den bisherigen Kanon.

Bildung in diesem Sinne muss die Frage stellen, wie wir in die Haltung des *sowohl als auch* kommen. In diejenige Haltung in Bezug auf die Welt, das Klima, Digitalisierung, Globalisierung oder globale Finanzmärkte in der wir eben nicht die Pole, sondern die Zwischenräume, die Relationen in den Blick nehmen. In der wir nicht populistisch handeln, denken und wahrnehmen, sondern in der wir emphatisch und ethisch Haltung einnehmen. Future Skills – zukünftige Bildung muss Umgang mit Ambiguität fördern. Sich in die Perspektive des Anderen hineinzuversetzen, Position beziehen zu können, Verantwortung zu übernehmen, Entscheidungen zu treffen, im zweifelnden Erkennen um Polarisierung.

Die KI ändert nichts daran, dass der Mensch verantwortlich ist für sein Tun und Lassen – und auch für seine Maschinen. Die Technologie ist weder gut noch schlecht noch neutral. Sie ist nicht deterministisch. Die Folgen der Technologie sind abhängig davon, was wir als Gesellschaft daraus machen.

Wo wir im Bildungssystem bisher vielfach auf Wissen und Wissensvermittlung gebaut haben, muss künftig ein neuer Modus des Wissens gefunden werden. Ein Modus, der darauf zielt, Lernende in die Lage zu versetzen in neuen, unbekannten, komplexen Situationen erfolgreich im humanistischen Sinne zu handeln.

KI – neue Fragen nach der Freiheit

Tatsächlich bietet KI eine Verstärkungsmöglichkeit für Herrschaftsstrategien aller Art: Politische Kontrolle und mediale Tyrannei erhalten neue, mächtige Möglichkeiten. Aber was im Sinne der Kontrolle nutzbar ist, eignet sich auch zur Rebellion. Freiheit – als Fähigkeit, der Welt Eigenes hinzuzufügen – wird durch KI ebenfalls verstärkt. Im Spannungsverhältnis zwischen dem Digitalen und dem Humanen entwickeln sich der menschliche Geist und menschliche Fähigkeiten weiter. Es entstehen neue Machtverhältnisse, neue Konflikte. Aber auch ein neues Selbstbewusstsein.

Bildung im Zeitalter von KI ruft auf: Wir haben nichts zu verlieren als unser inneres Maschine-Sein. Wir haben eine neue, humane Welt zu gewinnen (Horx, 2020). Ethische Kompetenz? Ja! Ambiguität meistern? Ja! Kritisch und reflexiv sein? Ja! Es ist das Zusammenspiel verschiedener Future Skills, das die Zukunft des Bildungssystems bestimmt. Wenn wir KI ernst nehmen.

Und damit erzwingt Künstliche Intelligenz einen Aufstieg menschlicher Intelligenz und Empathie. Indem die KI uns verbesserte Prognosen liefert, fordert sie uns gleichzeitig heraus, unsere Zukunftsfähigkeit zu verbessern. Künstliche Intelligenz kann nur wahrhaft *intelligent* sein, wenn sie durch humane Ziele gestaltet und mit menschlicher Bedeutung imprägniert ist. Was produziert werden soll, welche Mobilitäts- und Kommunikationsformen für die Zukunft sinnvoll sind, das hängt immer von den Kontexten menschlicher Erfahrungen ab. Diese Ziele liegen jenseits maschineller Logik. Sie sind Hervorbringungen der menschlichen Kultur, Ausdrucksformen der Empathie und des Bewusstseins.

Die Zukunft der Digitalisierung ist aber die Verbindung von emotionaler, sozialer und künstlicher Intelligenz. KI fordert uns heraus, unsere Werte neu zu definieren und zu verstehen, was Erfahrung, Bedeutung, Wissen und Bildung wirklich bedeuten.

Ulf-Daniel Ehlers: Duale Hochschule Baden-Württemberg, Professor für Bildungsmanagement und lebenslanges Lernen; ehlers@dhbw-karlsruhe.de

Literatur

- Bostrom, N. (2014). Superintelligence. Paths, Dangers, Strategies. Oxford University Press, Band(72),32-35.
- Grace, K., Salvatier, J., Dafoe, A., Zhang, B., & Evans, O. (2018). When will AI exceed human performance? Evidence from AI experts. Journal of Artificial Intelligence Research, Band(62),729-754.
- Horx, M. (2020). Zukunftsinstitut. Erscheinungsort: Verlag.

- Jaspers, K. (1956). Philosophie I. Erscheinungsort: Springer Verlag.
- Kerkmann, C. (2017, 17. Juli). Wer hat Angst vor denkenden Maschinen? Handelsblatt.com. <http://www.handelsblatt.com/20069992.html>.
- Kurzweil, R. (2005). The Singularity Is Near: When Humans Transcend Biology. New York: Penguin Group.
- Luhmann, N. (1990). Ökologische Kommunikation: Kann die moderne Gesellschaft sich auf ökologische Gefährdungen einstellen? Opladen: Westdeutscher Verlag.
- Luhmann, N., Schorr, K. E. (1982). Das Technologiedefizit der Erziehung und die Pädagogik. In N. Luhmann, K. E. Schorr (Hg.): Zwischen Technologie und Selbstreferenz. Fragen an die Pädagogik (S. 11–41). Stuttgart: Surkamp Verlag.
- Musk, E. (2014, 3. August). Worth reading Superintelligence by Bostrom. We need to be super careful with AI. Potentially more dangerous than nukes. Twitter.com. <https://twitter.com/elonmusk/status/495759307346952192>.
- Wittgenstein, L. (1921). Tractatus Logico-Philosophicus. In W. Ostwald: Annalen der Naturphilosophie (S. 185–262). Erscheinungsort: Verlag.

Peer Review

Durch kritische Begutachtung der eingegangenen Beiträge im Zuge des Double-Blind-Review-Verfahrens haben die folgenden Kolleg*innen wesentlich zur Sicherstellung der wissenschaftlichen Qualität dieser Publikation beigetragen:

Thomas Bröker	Jakob Lindner
Claudia de Witt	Maren Lübcke
Martin Ebner	Eike Meyer
Ulf-Daniel Ehlers	Norbert Pengel
Maria Flück	Denis Pijetlovic
Nadine Fröhlich	Jessica Rubart
Stephanie Gaaw	Sandra Schön
Christina Gloerfeld	Johannes Schrumpf
Anja Gottburgsen	Astrid Schulz
Hauke Hasenknopf	Katharina Schulz
Stefan Heiss	Funda Seyfeli-Özhizalan
Anne-Kathrin Helten	Cathleen M. Stützer
Sabrina Herbst	Thomas Voit
Dominikus Herzberg	Xia Wang
Christine Hoffmann	Klaus Wannemacher
Yvette E. Hofmann	Doris Weißels
Dirk Ifenthaler	Uwe Wienkop
Heike Jochims	Janka Willige
Wulf Kellerwessel	Diana Wolff-Grosser
Markus Lange-Hegermann	Silke E. Wrede
Philipp Leitner	Benjamin Zinger

Verzeichnis der Videos

Nr. 1) Einführung: KI in der Hochschullehre

Urheber*in: Tobias Schmohl

Entstehungsdatum: 24.09.2022

Kurzbeschreibung: In diesem Video führt Prof. Dr. Tobias Schmohl, einer der Herausgeber von »Künstliche Intelligenz in der Hochschulbildung. Chancen und Grenzen des KI-gestützten Lernens und Lehrens«, in das Thema des Sammelbandes ein. Er erklärt, wie Künstliche Intelligenz (KI) auf institutioneller, curricularer und individueller Ebene in die Hochschulbildung eingebunden werden kann, und zeigt die Diskrepanz zwischen dem (hochschul-)politischen Wunsch nach mehr KI-Anwendungen und dem aktuellen Stand der Forschung und Entwicklung auf. Vor diesem Hintergrund gibt er einen Überblick über die Entstehung des Sammelbandes und die darin versammelten Beiträge.

Keywords: Künstliche Intelligenz, Hochschulbildung, Hochschuldidaktik, Digitalisierung, Student Lifecycle

Sprache: Deutsch

Creative-Commons-Lizenz: CC-BY-SA 4.0

URL: <https://link.transcript-open.de/5769/video/001>

Nr. 2) Learning Analytics in Hochschulen und Künstliche Intelligenz

Urheber*in: Martin Ebner

Entstehungsdatum: 24.11.2021

Kurzbeschreibung: Dieses Video bietet einen Einblick in das Thema des Beitrags »Learning Analytics in Hochschulen und Künstliche Intelligenz«. Stellvertretend für das Autor*innenteam gibt Dr. Martin Ebner eine kompakte Definition von Learning Analytics. Er skizziert, welche Vorteile der Einsatz KI-basierter Analyse-Tools für die Hochschulbildung bietet und welche Herausforderungen es dabei aus technischer und hochschuldidaktischer Perspektive zu adressieren gilt.

Keywords: Learning Analytics, Künstliche Intelligenz, Hochschullehre

Sprache: Deutsch

Creative-Commons-Lizenz: CC-BY-SA 4.0

URL: <https://link.transcript-open.de/5769/video/002>

Nr. 3) Ethische Perspektiven auf Künstliche Intelligenz im Kontext der Hochschule

Urheber*in: Dirk Ifenthaler

Entstehungsdatum: 21.12.2021

Kurzbeschreibung: Dieses Video bietet eine kompakte Einführung in Prof. Dr. Dirk Ifenthalers Beitrag »Ethische Perspektiven auf Künstliche Intelligenz im Kontext der Hochschule«. In diesem Video skizziert der Autor das Spannungsfeld zwischen Hochschuldidaktik und Ethik, das aus dem Einsatz von Künstlicher Intelligenz (KI) und insbesondere Learning Analytics in der Hochschulbildung erwächst. Neben möglichen Vorteilen KI-basierter Anwendungen für Organisation und Lehre thematisiert er dabei vor allem offene Fragen, die es mit Blick auf die Anwendung disruptiver Technologien im Hochschulalltag zu beantworten gilt: Welche Daten benötigt eine Hochschule wirklich, um optimale Bedingungen für Lehre und Lernen zu schaffen – und wie kann ein ethischer Umgang mit diesen teils sensiblen Informationen aussehen?

Keywords: Hochschule, Ethik, Künstliche Intelligenz, Learning Analytics

Sprache: Deutsch

Creative-Commons-Lizenz: CC-BY-SA 4.0

URL: <https://link.transcript-open.de/5769/video/003>

Nr. 4) Studierende im KI-Diskurs

Urheber*in: Alice Watanabe, Tobias Schmohl, Larissa Jablotschkin, Clarissa Gora, Conrad Dreyer, Laura Zuckschwerdt

Entstehungsdatum: 13.08.2021

Kurzbeschreibung: Dieses animierte Lernvideo entstand im Rahmen des Forschungsprojektes »KI in der Hochschullehre« an der Technischen Hochschule Ostwestfalen-Lippe. Ausgehend von den Erlebnissen der fiktiven Studierenden Dan und Daria soll es Workshop-Teilnehmende dazu anregen, über mögliche Auswirkungen KI-basierter Tools auf den Hochschulalltag nachzudenken. In ihrem Beitrag »Studierende im KI-Diskurs« präsentiert Alice Watanabe, die an der Entwicklung des Lernvideos federführend beteiligt war, ein Workshop-Konzept, das dieses Video nutzt, um Studierende über Chancen und Risiken von KI in der Hochschulbildung zu informieren und sie zur eigenständigen Auseinandersetzung mit der Thematik anzuregen.

Keywords: KI-gestütztes Lernen und Lehren, Akzeptanzforschung, explorative Interviewstudie, Lernvideo, KI-Diskurs, Partizipation

Sprache: Deutsch

Creative-Commons-Lizenz: CC-BY-SA 4.0

URL: Video eins: <https://link.transcript-open.de/5769/video/004>

Video zwei: <https://link.transcript-open.de/5769/video/005>

Video drei: <https://link.transcript-open.de/5769/video/006>

Nr. 5) Künstliche Intelligenz und forschendes Lernen – ein ideales Paar im Hochschulstudium!?

Urheber*in: Silke Wrede, Christina Gloerfeld, Claudia de Witt, Xia Wang

Entstehungsdatum: 24.11.2021

Kurzbeschreibung: Dieses Video führt in den Beitrag »Künstliche Intelligenz und forschendes Lernen – ein ideales Paar im Hochschulstudium!?« ein. Die Autorinnen Silke Wrede, Dr. Christina Gloerfeld, Prof. Dr. Claudia de Witt und Dr. Xia Wang stellen hier das AI.EDU Research Lab vor, ein Forschungsprojekt an der FernUniversität Hagen, an dessen Beispiel sie in ihrem Artikel aufzeigen, wie KI-basierte Anwendungen das forschende Lernen an der Hochschule unterstützen und fördern können.


Keywords: Künstliche Intelligenz, forschendes Lernen, Hochschulstudium

Sprache: Deutsch

Creative-Commons-Lizenz: CC-BY-SA 4.0

URL: <https://link.transcript-open.de/5769/video/007>

Pädagogik



Tobias Schmohl, Thorsten Philipp (Hg.)

Handbuch Transdisziplinäre Didaktik

2021, 472 S., kart., 7 Farabbildungen

39,00 € (DE), 978-3-8376-5565-0

E-Book: kostenlos erhältlich als Open-Access-Publikation

PDF: ISBN 978-3-8394-5565-4

ISBN 978-3-7328-5565-0



Andreas Germershausen, Wilfried Kruse

Ausbildung statt Ausgrenzung


**Wie interkulturelle Öffnung und Diversity-Orientierung
in Berlins Öffentlichem Dienst und in Landesbetrieben
gelingen können**

2021, 222 S., kart., 8 Farabbildungen

25,00 € (DE), 978-3-8376-5567-4

E-Book: kostenlos erhältlich als Open-Access-Publikation

PDF: ISBN 978-3-8394-5567-8



Andreas de Bruin

Mindfulness and Meditation at University

10 Years of the Munich Model

2021, 216 p., pb.


25,00 € (DE), 978-3-8376-5696-1

E-Book: available as free open access publication

PDF: ISBN 978-3-8394-5696-5

**Leseproben, weitere Informationen und Bestellmöglichkeiten
finden Sie unter www.transcript-verlag.de**

Pädagogik



Andreas de Bruin


Achtsamkeit und Meditation im Hochschulkontext 10 Jahre Münchner Modell

2021, 216 S., kart., durchgängig vierfarbig

20,00 € (DE), 978-3-8376-5638-1

E-Book: kostenlos erhältlich als Open-Access-Publikation

PDF: ISBN 978-3-8394-5638-5



Holger Angenent, Jörg Petri, Tatiana Zimenkova (Hg.)


Hochschulen in der Pandemie Impulse für eine nachhaltige Entwicklung von Studium und Lehre

Mai 2022, 448 S., kart., 52 SW-Abbildungen

45,00 € (DE), 978-3-8376-5984-9

E-Book: kostenlos erhältlich als Open-Access-Publikation

PDF: ISBN 978-3-8394-5984-3



Ivana Pilic, Anne Wiederhold-Daryanavard (eds.)

Art Practices in the Migration Society Transcultural Strategies in Action at Brunnenpassage in Vienna

2021, 244 p., pb.

29,00 € (DE), 978-3-8376-5620-6

E-Book:

PDF: 25,99 € (DE), ISBN 978-3-8394-5620-0

**Leseproben, weitere Informationen und Bestellmöglichkeiten
finden Sie unter www.transcript-verlag.de**

