

Andrea Bertino*

Serendipität und Open Data. Richtlinien für die Implementierung von Empfehlungssystemen auf Entdeckungsplattformen

<https://doi.org/10.1515/bfp-2023-0059>

Zusammenfassung: Die ständig wachsende Zahl wissenschaftlicher Publikationen zwingt Forschende dazu, viel Zeit zu investieren, um die für ihre akademische Arbeit relevanten Ressourcen zu finden. Unterstützung bieten hier Entdeckungsplattformen (*discovery platforms*), die Forschungsdaten, Publikationen und andere Forschungsressourcen aggregieren und deren Auffindbarkeit durch sogenannte *recommender systems* (RS) unterstützen. Der Einsatz solcher Technologien kann jedoch zu gewissen Verzerrungen bei der Selektion der für die Forschung nützlichen Ressourcen führen und sich auf die Auswahl der zu bearbeitenden Themen, die verwendeten Argumente und letztlich auf das Innovationspotenzial der Forschung auswirken. Diese Auswirkungen sind noch nicht hinreichend geklärt und es fehlt an Empfehlungen und Best Practices für die Entwicklung von RS für wissenschaftliche Entdeckungsplattformen. In diesem Beitrag werden Richtlinien für die Anwendung von RS in Discovery-Plattformen für die Forschung formuliert, insbesondere im Hinblick auf eine mögliche Anwendung im *Open Data Navigator*, eine Discovery Plattform für Open Data, die im Rahmen des Schweizer *Connectome*-Projekts entwickelt wird. Als Prüfstein für die Nützbarkeit von RS wird das Konzept der Serendipität vorgeschlagen – das Phänomen, unerwartete, aber dennoch wertvolle Entdeckungen zu machen. Die empfohlenen Richtlinien zielen darauf ab, die Möglichkeit der Erfahrung von Serendipität in einer virtuellen Umgebung als eine der Voraussetzungen für innovative Forschung zu sichern.

Schlüsselwörter: Empfehlungssysteme; Entdeckungsplattformen; Auffindbarkeit; Serendipität; Open Data Navigator

Digital Serendipity. Ethical Challenges in the Implementation of Recommender Systems on Scientific Discovery Platforms

Abstract: The ever-growing number of scientific publications forces researchers to spend a lot of time finding

the resources relevant to their academic work. Discovery platforms provide support by aggregating research data, publications, and other research resources and supporting their discoverability through recommender systems (RS). However, the use of such technologies can lead to certain biases in the selection of resources that are useful for research and can affect the choice of topics to work on, the arguments used, and ultimately the innovation potential of research. These effects are not yet well understood, and there is a lack of concrete recommendations and best practices for the development of RS for scientific discovery platforms. In this paper, guidelines for the application of RS in scientific discovery platforms are formulated, about a possible application in the *Open Data Navigator*, an open data discovery platform being developed as part of the Swiss project *Connectome*. The concept of serendipity – the phenomenon of making unexpected but valuable discoveries – is proposed as a touchstone for the usefulness of RS. The recommended guidelines aim to ensure the possibility of experiencing serendipity in a virtual environment as one of the prerequisites for innovative research.

Keywords: Recommender systems; discovery platforms; discoverability; serendipity; open data navigator

1 Einleitung

Die Anzahl wissenschaftlicher Publikationen, Forschungsdaten und anderer Arten von Daten, die für Forschung und Lehre relevant sein können, nimmt ständig zu. Dies macht die Suche nach relevanten Informationen besonders komplex und zeitaufwändig. Verschiedene virtuelle Forschungsumgebungen und digitale Kataloge bieten daher unterschiedliche Lösungen an, um die Komplexität des Suchprozesses zu reduzieren. Insbesondere sogenannte *discovery platforms* bieten Lösungen an, um den Nutzer:innen potenziell relevante Ressourcen zu empfehlen. Ähnlich wie bei Plattformen für Online-Shopping oder Portalen für Unterhaltungsmedien werden solche Empfehlungen durch Technologien erzeugt, die darauf abzielen, den Nutzer:innen einen personalisierten Suchprozess zu

*Kontaktperson: Andrea Bertino, andrea.bertino@switch.ch.

<https://orcid.org/0000-0002-5080-036X>

ermöglichen. Solche Technologien, die als Recommender-Systeme (RS) bezeichnet werden, sind in jüngster Zeit mehrfach vorgeschlagen worden, um dieses Problem zu lösen.¹ Die Art und Weise, wie die Komplexität der Informationen reduziert wird, hängt stark von den Algorithmen der RS ab, wobei diese auch unerwünschte Effekte verstärken können.² Der wichtigste negative Effekt ist das Phänomen der *Filter Bubble*; bereits 2011 merkte Eli Pariser in *The Filter Bubble: What the Internet Is Hiding from You*, dass bestimmte Verhaltensweisen im Internet, wie z. B. die Suche nach Nachrichten oder das Betrachten von Nachrichten in einem algorithmusgesteuerten Feed, Filterblasen erzeugen können.³ Diese Blase ist auch mit der Sichtbarkeit verbunden: Man sieht vor allem das, was die *Drachen* des Internets einen sehen lassen. Bereits 2007 wurden in *Web Dragons, Inside the Myths of Search Engine Technology* die Suchmaschinen metaphorisch als moderne Drachen dargestellt,⁴ d. h. als die Hüter eines Schatzes (von Informationen). Das bedeutet, dass die meisten Nutzer:innen die Logik, aufgrund derer eine bestimmte Webseite bei einer Suchanfrage an erster Stelle erscheint, nicht wirklich nachvollziehen können. In dieser Sichtbarkeitsblase müssen diejenigen, die die Auffindbarkeit einer Webseite verbessern wollen, oft gegen die Heuristiken der beliebtesten Suchmaschinen ankämpfen, deren Details und Vorlieben streng gehütete Geschäftsgeheimnisse bleiben.⁵ Dies verstärkt wiederum die Neigung der Nutzer:innen zu personalisierten Filtern und erhöht damit erneut die Gefahr der *Filter Bubble*. Es entstehen individuelle Informationswelten, die an bereits bekannte Inhalte anknüpfen und damit bestehende Überzeugungen und Konzepte bestätigen.

Die Auswirkungen solcher Dynamiken auf das wissenschaftliche Arbeiten sind ebenso gravierend, werden aber weniger beachtet. Ähnlich wie bei den großen *Gatekeepers* des Internets erfolgt auch bei den auf wissenschaftlichen Rechercheplattformen eingesetzten RS die Auswahl der Inhalte nach Kriterien, die nicht immer vollständig transparent und nachvollziehbar sind. Dieser Mangel an Transparenz stellt zunächst eine Herausforderung für die Nutzer:innen dar, die nicht immer wissen können, in welchem Relevanzverhältnis die Ergebnisse zur Suchstrategie stehen und ob es sich lohnt, Zeit zu investieren, um diese Objekte für ihre Forschungszwecke zu berücksichtigen. Mangelnde Transparenz untergräbt das Vertrauen der Nutzer:innen in

die Empfehlungen.⁶ Und wenn die Empfehlungen unmittelbar relevant erscheinen, besteht die Gefahr, dass man sich so sehr auf die Ressourcen konzentriert, die man bereits nutzt, oder auf die spezifischen Themen, die die Nutzer:innen interessieren, dass man andere potenziell relevante Beiträge aus den Augen verliert.

In der Forschung können Filtersysteme insbesondere die Serendipität, d. h. die überraschende und ungeplante Entdeckung wertvoller Einsichten, verhindern und damit Kreativität und Innovation behindern. Darüber hinaus könnte ein äußerst effizientes und präzises Empfehlungssystem, wenn es unkritisch befolgt wird, die Tendenz zur Überspezialisierung,⁷ die in der heutigen wissenschaftlichen Arbeit bereits zu beobachten ist, noch verstärken. Extreme Spezialisierung scheint zwar angesichts der zunehmenden Komplexität der Probleme und der Menge an Daten und Ressourcen unvermeidlich, doch stellt sich die Frage, ob sie nicht auch Nachteile mit sich bringt. Die Rezeption kritischer Forschungsbeiträge, die weniger populäre Thesen vertreten oder weniger populäre Thesen oder Forschungsthemen mit geringerer Beachtung behandeln, kann durch Systeme benachteiligt werden, wenn RS nur Forschungsbeiträge empfehlen, die zu den populärsten Forschungsrichtungen gehören. Während dies sicherlich die Tatsache widerspiegelt, dass es so etwas wie zentrale Themen für verschiedene Epochen und Forschungsrichtungen gibt, könnte es auch einen verhängnisvollen intellektuellen Konformismus verstärken.

Das technische Design dieser RS hat also Implikationen, die über ihre rein technische Funktion hinausgehen. Die potenziellen Folgen sind ethisch relevant, weil sie nicht nur mit ihrer Fähigkeit zusammenhängen, relevante Empfehlungen zu geben und damit die Anwendungsfälle zu erfüllen, für die sie entwickelt wurden. Eine unbewusste Einschränkung oder Lenkung unseres Wissens und unserer Perspektive hat praktische Konsequenzen, die ethisch relevant sind, weil sie unsere Wertvorstellungen, Entscheidungen und Pläne grundlegend beeinflussen können. Ethisch relevant sind daher die Folgen dieser Anwendung für den Nutzer:innen *als Person* und nicht nur als Nutzer:innen einer bestimmten Anwendung. Ihre breitere gesellschaftliche Auswirkung geht über die reine Leistungsfähigkeit der Technologie hinaus. Zum Beispiel, auch wenn diese RS einer zeitgenössischen Tendenz zur Hyperspezialisierung⁸ ent-

6 Verbert et al. (2013).

7 Wissenschaftsrat (2020).

8 Für eine soziologische und erkenntnistheoretische Einordnung des Problems der übermäßigen Segmentierung und Spezialisierung der Wissenschaften bleibt Morin ein zentraler Bezugspunkt. Siehe insbesondere den ersten Band seines Werkes über die Methode, Morin (2010).

1 Kreutz und Schenkel (2022).

2 Elahi et al. (2021).

3 Pariser (2012).

4 Witten et al. (2007).

5 Gemmis et al. (2015).

sprechen und damit den Bedürfnissen ihrer Nutzer:innen gerecht werden, können sie den innovativen Charakter der Forschung und damit ihren Nutzen für die Gesellschaft im Allgemeinen einschränken.

In diesem Beitrag werden die Risiken des Einsatzes von RS in digitalen Plattformen für die Forschung dargestellt und die ethische Relevanz dieser Risiken im Hinblick auf die Stakeholder diskutiert, die von *biases* und *bubbles* in der Forschung betroffen sein können. Diese sind nicht nur Wissenschaftler:innen, sondern auch die Gesellschaft, die mit ihrem Steueraufkommen öffentliche Forschung finanziert, und die Privatwirtschaft, die auf der Grundlage dieser Forschungsergebnisse neue Produkte entwickeln. Im Hinblick auf die Anwendung von RS auf Entdeckungsplattformen (=EP) für die wissenschaftliche Arbeit soll dieser Artikel insbesondere zur Klärung der folgenden Fragen beitragen: Welche potenziell negativen Auswirkungen sollten bei der Entwicklung eines RS immer mitbedacht werden, um sicherzustellen, dass die ethischen Implikationen akzeptabel sind? Wie sollte ein RS für wissenschaftliche EP aussehen, das die ethischen Implikationen der Implementierung von RS berücksichtigt? Schließlich ist es das Ziel dieses Beitrags, Lösungsansätze vorzuschlagen, die auf dem Konzept der Serendipität basieren, der auch in der wissenschaftlichen Diskussion rund um RS eine wichtige Rolle spielt. Die hier vorgeschlagenen Leitlinien werden nicht abstrakt formuliert, sondern im Hinblick auf die zukünftige Entwicklung einer EP für die wissenschaftliche Entdeckung und Verwertung von Open Data, dem *Switch Open Data Navigator*⁹ entwickelt im Rahmen des Connectome Project.¹⁰ Diese Suchplattform richtet sich in erster Linie an Studierende und Forschende, die nach offenen Daten aus verschiedenen Quellen suchen, um insbesondere inter- und multidisziplinäre Projekte voranzutreiben. Der ODN aggregiert schrittweise Metadaten von Verwaltungen, Archiven, NGOs, Galerien, Bibliotheken, Museen und anderen Open-Data-Aggregatoren. Institutionelle Archive von Schweizer Hochschulen sind ebenfalls enthalten, um die Sichtbarkeit der nationalen Forschung zu erhöhen. Zudem sind relevante wissenschaftliche Publikationen aus nationalen und internationalen Forschungsprojekten mit den aggregierten Open Data verknüpft. Werkzeuge zur Visualisierung der Beziehungen zwischen den Ressourcen unterstützen die Benutzer:innen bei der Suche nach relevanten Informationen.

Die Empfehlungen verstehen sich daher als Leitfaden für eine Implementierung eines RS auf dieser Plattform.

⁹ <https://opendatanavigator.switch.ch/>.

¹⁰ <https://www.switch.ch/de/about/innovation#tab-1985>.

2 Sinn und Herausforderungen von Empfehlungssystemen

2.1 Arten von Empfehlungssysteme

Empfehlungssysteme (=RS) sind in der heutigen digitalen Ära weit verbreitet.¹¹ Sie beeinflussen nicht nur unsere täglichen Entscheidungen, sondern auch die Art und Weise, wie wissenschaftliche Forschung und Entdeckungen präsentiert und wahrgenommen werden. Die ethischen Herausforderungen, die mit ihrer Implementierung und Nutzung einhergehen, sind daher von großer Bedeutung, insbesondere im akademischen und wissenschaftlichen Kontext. Bevor wir uns den ethischen Implikationen der Anwendung von RS in EP für die wissenschaftliche Arbeit zuwenden, ist es notwendig, kurz einige der wichtigsten Ansätze zur Generierung von Empfehlungen vorzustellen.

Heutzutage werden RS zunehmend in einer Vielzahl von Anwendungen und für verschiedene Ziele eingesetzt, z. B. für E-Learning, Tourismus, Filme und Musik, E-Commerce, Nachrichten und in Fernsehprogrammen.¹² In all diesen unterschiedlichen Kontexten profitieren RS von verschiedenen Methoden des *text and data mining*, *natural language processing* (NLP) und des maschinellen Lernens, um interessante Objekte zu empfehlen. Es gibt im Wesentlichen zwei Hauptansätze zur Generierung von Empfehlungen: *objektbasierte* und *nutzerbasierte*. Die objektbasierte Methode bewertet die Eigenschaften und Ähnlichkeiten der vorhandenen Artikel in den Nutzerdatensätzen im Vergleich zu anderen Artikeln, um die ähnlichsten Artikel zu finden. Die nutzerbasierte Methode analysiert die Ähnlichkeit zwischen den Präferenzen einer Zielperson und denen anderer Nutzer:innen, um die Meinung der Zielperson zu einem bestimmten Artikel zu prognostizieren.¹³

Diese Differenzierung wird in der Forschung durch eine dritte Kategorie weiter verfeinert, und man spricht auch von *inhaltsbasierten, kollaborativen und wissensbasierten Filtertechniken*.¹⁴

Ein inhaltsbasierter Ansatz generiert passende Empfehlungen für die Nutzer:innen auf Basis ihres bisherigen Verhaltens. Er analysiert das bisherige Verhalten, erstellt für jede Nutzer:in ein Profil auf Basis der zuvor ausgewählten Objekte und empfiehlt Objekte mit ähnlichen Eigenschaften.

¹¹ Kreutz und Schenkel (2022).

¹² Roy und Dutta (2022).

¹³ Ziarani und Ravanmehr (2021).

¹⁴ Das et al. (2022).

ten. Mit einem solchen RS werden seine Präferenzen nicht mit denen anderer Benutzer:innen verglichen.¹⁵

Kollaborative Filtertechniken berücksichtigen stattdessen die Präferenzen mehrerer Nutzer:innen und erstellen eine Empfehlungsliste. Wenn die Präferenzen von Nutzer:in 1 und Nutzer:in 2 übereinstimmen, wird das Produkt, das Nutzer:in 2 empfohlen wird, auch Nutzer:in 1 empfohlen. Die Hypothese hinter diesem Ansatz ist, dass Personen, die in der Vergangenheit mit anderen Personen übereinstimmen, dies auch in der Zukunft tun werden.¹⁶

Der wissensbasierte Filteransatz wird in Fällen verwendet, in denen sowohl der kollaborative als auch der inhaltsbasierte Ansatz versagt haben oder nicht richtig funktionieren, wenn z. B. für einen bestimmten Artikel nicht genügend Bewertungen oder Rezensionen für den Empfehlungsprozess vorliegen. Dies ist bei Artikeln der Fall, die selten gekauft werden, wie Häuser, Autos oder Finanzdienstleistungen. Die Funktionsweise dieses Ansatzes besteht darin, das Wissen der Kund:innen über das Artikelsortiment zu nutzen, um die Artikel zu empfehlen, die ihren Bedürfnissen am besten entsprechen. Der Vorteil besteht darin, dass er keine vorherige Bewertung des Objekts erfordert und somit das sogenannte *Kaltstartproblem* überwindet, d. h. die Schwierigkeit, personalisierte Empfehlungen zu geben, wenn keine ausreichenden Daten über neue Nutzer:innen oder Objekte vorliegen, weil historische Informationen über Interaktionen oder Präferenzen fehlen. Der Nachteil ist jedoch, dass erfahrene Ingenieure benötigt werden, um die Aufgabe zufriedenstellend zu lösen,¹⁷ da solche Hybridsysteme die Integration verschiedener Filtermethoden erfordern, was die Komplexität des Prozesses erhöht. Wenn diese Filtersysteme dann die Sammlung personenbezogener Informationen erfordern – wie Mitgliedschaften, Kooperationen, Forschungsinteressen, Finanzierung, Zusammenarbeit, Präferenzen bei der Nutzung anderer Werkzeuge und alles, was zu potenziell nützlichen Empfehlungen beitragen kann – entstehen potenzielle Konflikte mit dem Schutz der Privatsphäre. Besonders problematisch ist dies bei den Discovery-Plattformen der großen Verlage, die zur besseren Vermarktung ihrer Produkte auch Research Tracking betreiben. Dies kann nicht nur die informationelle Selbstbestimmung beeinträchtigen, sondern auch den freien Wettbewerb im Bereich der Informationsversorgung behindern.¹⁸

Noch vor jeder ethischen Bewertung ist die *Genauigkeit* des RS eine wichtige Voraussetzung für ihre Akzeptanz bei

den Nutzer:innen. Jedoch die Genauigkeit der Empfehlungen ist nicht der einzige Aspekt, der zur Zufriedenheit der Nutzer:innen führt: Diese können mit einer exakten Empfehlung unzufrieden sein, wenn sie dem Empfehlungssystem nicht vertrauen, wenn ihre Privatsphäre nicht gewahrt wird, wenn es lange dauert, bis sie eine Empfehlung erhalten, oder wenn sie die Benutzeroberfläche als unvorteilhaft empfinden.¹⁹ Generell ist es von Bedeutung, dass jedes Empfehlungssystem den Nutzer:innen immer den Kontext vermittelt, auf dem eine bestimmte Empfehlung beruht, und dass es die Möglichkeit bietet, mit dem System zu interagieren, um die Parameter, die zu solchen Empfehlungen führen, zumindest bis zu einem gewissen Grad zu verändern.²⁰ Die Transparenz und Nachvollziehbarkeit des Empfehlungsprozesses ist die Grundlage für jegliches Vertrauen der Nutzer:innen in ein RS und somit für die Akzeptanz seiner Outputs.

2.2 Risiken des Einsatzes von Empfehlungssystemen in digitalen Wissenschaftsplattformen

Im Allgemeinen ist die Empfehlung potenziell relevanter Objekte durch RS mit mehreren Risiken behaftet: wie z. B. Bereitstellung unangemessener Inhalte, Verletzung der Privatsphäre, Einschränkung der Autonomie, Intransparenz und mangelnde Fairness der Algorithmen.²¹ So wurden auch generische Empfehlungen für vertrauenswürdigen Anwendungen von RS schon formuliert:

1. Sicherheit & Robustheit: Entwicklung von robusten Empfehlungsalgorithmen, die gegen verschiedene Arten von Angriffen geschützt sind, und Einsatz von adversariellem Training²², Regularisierung und Daten-augmentation.
2. Nichtdiskriminierung & Fairness: Anwendung von Methoden zur Erkennung und Minderung von Diskriminierung in Empfehlungssystemen.
3. Erklärbarkeit: Einführung von post-hoc-Erklärungen, intrinsischen Erklärungen und hybriden Erklärungen, um die Transparenz von Empfehlungen zu erhöhen.
4. Datenschutz: Anwendung von Techniken wie differentieller Privatsphäre, föderiertem Lernen und Anonymisierung, um die Privatsphäre der Benutzer:innen zu schützen.

¹⁹ Witten et al. (2007).

²⁰ Adomavicius und Tuzhilin (2011).

²¹ Milano et al. (2020).

²² Technik des maschinellen Lernens, bei der ein Modell trainiert wird, um robuster zu werden, indem es absichtlich verschiedenen Arten von Angriffen oder schwierigen Szenarien ausgesetzt wird.

¹⁵ Ebd.

¹⁶ Ebd.

¹⁷ Das et al. (2022).

¹⁸ DFG-Committee On Scientific Library Services And Information Systems (2021).

5. Umweltwohlbefinden: Einsatz von Methoden zur Reduzierung des Speicher- und Energieverbrauchs von Empfehlungssystemen.
6. Rechenschaftspflicht & Überprüfbarkeit: Betonung der Bedeutung der Rechenschaftspflicht und Einführung von Mechanismen zur Überprüfung und Kontrolle von Empfehlungssystemen.²³

Wenn man jedoch die spezifische Anwendung von RS auf digitalen Plattformen für akademische Zwecke betrachtet, ist die ethische Diskussion über ihre Implikationen noch im Rückstand²⁴ und es wären spezifischere Kriterien und Richtlinien erforderlich. Obwohl ihr Einsatz im heutigen hyperspezialisierten akademischen Umfeld die Produktivität fördert, sollen vor allem die Auswirkungen auf Denkgewohnheiten und Verhaltensmuster der Akteure, die sie einsetzen, berücksichtigen werden. Sie können die Fähigkeit der Nutzer:innen schwächen, für unerwartete, aber potenziell nützliche Entdeckungen empfänglich zu bleiben, und damit ihre Fähigkeit, heterodoxes Denken und ungewohnte Sichtweisen zu akzeptieren.

In der Literatur werden vor allem zwei Formen von Verzerrungen, die die Anwendung von RS in wissenschaftlichen Kontext negativ beeinflussen können, nämlich, der *confirmation bias* und der *popularity bias*. Im ersten Fall besteht die Tendenz, nur und ausschließlich Empfehlungen zu erhalten, die die eigene Meinung bestätigen, und Beiträge mit „unbequemen“ Argumenten systematisch auszuschließen. Im zweiten Fall neigen die Nutzer:innen dazu, nur Beiträge auszuwählen, die bereits populär sind, und weniger bekannte, aber potenziell wichtige Quellen zu vernachlässigen. Dies begünstigt die Verbreitung von Beiträgen aus etablierten Forschungsbereichen und entmutigt die Entwicklung alternativer Themen und heterodoxer Beiträge. Diese Verzerrung tritt häufig auf, da sie in jedem Datensatz enthalten ist, der eine kleine Anzahl beliebter Artikel und eine große Anzahl unbeliebter Artikel enthält.²⁵ Diese Verzerrung zeigt sich häufig bereits auf der Ebene der bereitgestellten Filter und Facetten, die die Präferenzen von Nischennutzer:innen – wie Forschende, die an weniger populären Themen arbeiten – nicht berücksichtigen.²⁶ Diese Problematik von Voreingenommenheit wird auch bei Buchempfehlungssystemen offensichtlich.²⁷ Obwohl kollaborative Filteralgorithmen den Vorteil haben, keine sensiblen Benutzer- oder Artikelinformationen für Empfehlungen zu

benötigen, können sie dennoch unter dem Popularity-Bias leiden. Dieser Bias kann oft zu weiteren, nicht offensichtlicher Voreingenommenheit führen. Außerdem können Verzerrungen in den Empfehlungen auf bereits vorhandene *Verzerrungen in den Eingabedaten* zurückzuführen sein, die in der Regel auf methodische Ungenauigkeiten bei der Datenerhebung zurückzuführen sind. Solche Verzerrungen können durch den Algorithmus verstärkt werden, indem die Verzerrungen in den Eingabedaten jedes Mal weitergegeben werden, wenn neue Empfehlungen erstellt werden.²⁸

Ein weiterer problematischer Aspekt im Zusammenhang mit RS, der auch Auswirkungen auf digitale Suchdienste haben kann, ist das sogenannte *nudging*. Dabei handelt es sich um den Einsatz von Werkzeugen, die Menschen dazu bringen, bestimmte Entscheidungen zu treffen, ohne dass sie sich dessen bewusst sind und ohne, dass sie dazu gezwungen werden, weil die Entwickler oder Anbieter des Dienstes davon ausgehen, dass diese Entscheidungen im Interesse der Nutzer:innen sind. In einer Übersicht über die Literatur zu Nudging-Mechanismen in RS stellen Jesse und Jannach fest, dass von 87 Nudging-Mechanismen mindestens 69 Mechanismen in 18 verschiedenen RS eingesetzt wurden.²⁹ Es ist offensichtlich, dass das Konzept des Nudging mit der Vorstellung von guter wissenschaftlicher Praxis kollidiert: Die Idee, dass die Forschenden unbewusst von Dritten dazu gedrängt werden, Themen zu untersuchen oder Ressourcen zu nutzen, die andere für sie ausgewählt haben, steht in eklatantem Widerspruch zu der Vorstellung von Forschung als einer autonomen und kritischen Übung. Nudging ist in einem solchen Kontext ethisch unhaltbar.

Auf Lernplattformen können zwar RS, die sich adaptiv an die Bedürfnisse und Anforderungen der Lernenden anpassen, selbstgesteuertes, exploratives und eigenverantwortliches Lernen erleichtern und Orientierung für Lernaktivitäten bieten.³⁰ Auf der anderen Seite kann es problematisch sein, dass diese RS nach Kriterien entwickelt werden, die normalerweise für die Entwicklung von RS in anderen Bereichen, wie z. B. E-Shopping und Unterhaltung, gelten. Während im E-Commerce der Schwerpunkt von RS auf der Personalisierung in Bezug auf den Geschmack liegt, liegt der Schwerpunkt in der Lernumgebung auf der kontextuellen Personalisierung in Bezug auf den Wissenserwerb. Und während im kommerziellen Kontext die Relevanz der abgegebenen Empfehlungen im Hinblick auf die erfolgreiche Vermarktung von Produkten im Vordergrund steht, sind Empfehlungen im pädagogischen Kontext vor allem als eine andere Art von Anregung für die Nutzer:in-

23 Fan et al. (2022).

24 Polonioli (2021).

25 Elahi et al. (2021), Gharahighehi et al. (2021).

26 Abdollahpouri et al. (2019).

27 Daniil et al. (2022).

28 Elahi et al. (2021).

29 Jesse und Jannach (2021).

30 Abdollahpouri et al. (2019).

nen ebenso zentral, sei es als Anregung zum kritischen Denken oder zur eigenständigen Aneignung des Lernstoffes im Hinblick auf das Erreichen der jeweiligen Lernziele. RS im Bildungskontext müssen vor allem kontextsensitiv sein, um das Wissen der Lernenden richtig zu interpretieren. Dies kann entweder durch hybride RS oder durch die Einbeziehung der Lernenden in den Empfehlungsprozess selbst erreicht werden.³¹

Auch Fairness im Sinne von Nichtdiskriminierung kann auch in diesem speziellen Bereich eine Herausforderung darstellen. Mangel an Fairness kann sowohl Endnutzer:innen betreffen, wenn Angehörige rechtlich geschützter Gruppen oder bestimmte Personengruppen systematisch schlechtere Empfehlungen erhalten, als auch Anbieter:innen von Inhalten, wenn Artikel von Angehörigen rechtlich geschützter Gruppen oder Personen von einem Algorithmus zu wenig empfohlen werden.³² Fairness bleibt dennoch ein schwer definierbarer Begriff, da es letztlich keinen formalen Rahmen gibt, der „alle möglichen Varianten von Fairness abdeckt“³³ und als ein sozial konstruiertes Konzept, das häufig die konkurrierenden Interessen der Stakeholder widerspiegelt, reicht eine Definitionen aus einer reinen technischen Perspektive nicht aus.³⁴ Somit scheint dieser Begriff allein nicht ausreichend klar zu sein, um die Definition von Richtlinien für die Anwendung von RS im akademischen Bereich zu ermöglichen und damit sicherzustellen, dass ein RS wissenschaftlichen Anforderungen gerecht wird. Betrachtet man die Anwendung von RS in diesem spezifischen Kontext, so müssen die Auswirkungen solcher Technologien auf die Werte und Erwartungen in diesem spezifischen Bereich berücksichtigt werden. Neben dem bereits erwähnten Wert der Autonomie, der jede Form von Nudging in diesem Bereich problematisch erscheinen lässt, steht hier zweifellos der Wert der Entdeckung neuen Wissens und der Stimulierung von Innovationsprozessen. Dann erscheint die Anwendung von RS im wissenschaftlichen Kontext vor allem als denkbar schädlich, da sie potenziell geeignet ist, Konformismus zu fördern und heterodoxe, aber möglicherweise wertvolle Forschungsvorhaben zu entmutigen. Um konkrete Richtlinien für die Anwendung von RS in einem akademischen Kontext zu formulieren, scheint es daher sinnvoller, sich auf eine andere Fähigkeit von RS zu konzentrieren, nämlich die, nicht nur sehr präzise und genaue, sondern auch überraschende, desorientierende, aber potenziell wertvolle Ressourcen zu präsentieren. Die folgenden Empfehlungen für die ethische Gestaltung einer

RS für wissenschaftliche Entdeckungsplattformen orientieren sich daher am Konzept der Serendipität.

3 Serendipität und ihre Förderung in digitalen Umgebungen

Um die Anforderungen an ein RS für akademische *discovery platforms* zu definieren, muss zunächst kurz geklärt werden, was unter dem Begriff Serendipität (*serendipity*) zu verstehen ist. Der 1754 von dem englischen Schriftsteller Horace Walpole geprägte Begriff bezeichnet die „Gabe, unerwartete, zufällige oder glückliche Entdeckungen zu machen“³⁵ und wurde als Metapher für die zufällige Informationsgewinnung bereits intensiv untersucht.³⁶ Das von McCay-Peet und Toms vorgeschlagene Schema fasst das Erlebnis der Serendipität gut zusammen:

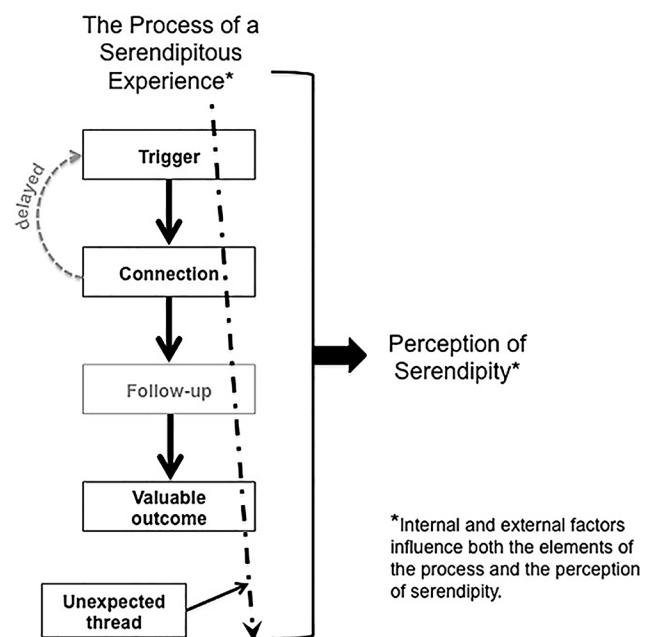


Abb. 1: Das Erlebnis der Serendipität³⁷

Es ist wichtig zu beobachten, dass Serendipität, obwohl sie per definitionem mit Zufall zu tun hat, durch verschiedene Wege unterstützt werden kann. Unter besonderer Berücksichtigung der Recherche von digitalen Texten scheinen dies die vier wichtigsten zu sein:³⁸

31 Buder und Schwind (2012).

32 Boratto et al. (2021), Zangerle und Bauer (2023).

33 Deldjoo et al. (2023).

34 Ferrara (2023).

35 Nutefall und Ryder (2010).

36 Erdelez (2004), Foster und Ford (2003), McCay-Peet und Toms (2018).

37 McCay-Peet und Toms (2015).

38 Toms (2000).

- Unterstützung des „blinden Zufalls“, z. B. durch einen *Zufallsgenerator für Informationsknoten*. Im Kontext von RS könnte diese Strategie durch die Bereitstellung von Zufallsvorschlägen umgesetzt werden.
- Unterstützung des *Pasteur-Prinzips* „Der Zufall begünstigt nur den vorbereiteten Geist“. Empfehlungssysteme könnten das Paradigma des „vorbereiteten Geistes“ umsetzen, indem sie Informationen über die Vorlieben der Nutzer:innen in verschiedenen Kontexten nutzen.
- *Anomalien und Ausnahmen*, umgesetzt durch Abstandsmaße, die in der Lage sind, Artikel zu identifizieren, die sich von denen unterscheiden, die den Nutzer:innen in der Vergangenheit gefallen haben.
- *Analogieschlüsse*, die einen Abstraktionsmechanismus erfordern, der es dem System ermöglicht, die Anwendbarkeit eines bestehenden Schemas auf eine neue Situation zu entdecken.

Eine weitere Strategie zum Verständnis und zur Ermöglichung von Serendipität in digitalen Umgebungen besteht darin, die Vorgehensweisen der Forschenden bei Entdeckungsprozessen, die nicht in digitalen Umgebungen stattfinden, zu berücksichtigen, um daraus zu lernen, welche Eigenschaften für digitale Plattformen ideal wären. Beispielsweise wurde die Arbeit von Historiker:innen untersucht und festgestellt, dass sie eine Art „heuristische Serendipität“ anwenden, d. h. einen Prozess der Informationssuche, bei dem durch Versuch und Irrtum neue und innovative Methoden entwickelt werden, um überraschende Ergebnisse zu finden.³⁹ Die Autoren leiten daraus mehrere mögliche Hinweise für die Gestaltung einer digitalen Plattform ab, von denen die folgenden für unser Ziel am relevantesten erscheinen:

- Die digitale Plattform sollte anregend, d. h. mit einer *Vielzahl von Informationen*, Ideen oder Ressourcen gefüllt sein, die für den Nutzer:innen interessant und nützlich sind.
- Sie muss *Verknüpfungen zwischen Ressourcen* ermöglichen, d. h. den Nutzer:innen Kombinationen von Informationen, Ideen oder Ressourcen aufzeigen und die Verbindungen zwischen Themen deutlich machen.
- Sie muss Exploration ermöglichen, d. h. die *ungehindernte Erkundung* von Informationen, Ideen oder Ressourcen erlauben.

Grundsätzlich ist das Herstellen von Verbindungen der Schlüssel zur erfolgreichen Integration von Serendipität in Empfehlungssysteme in Lernumgebungen.⁴⁰ Ähnliches

kann auch im Bereich der Forschung der Fall sein. Die Reflexion über traditionelle Forschungsprozesse, verbunden mit einem stärkeren Bewusstsein für die Grenzen der digitalen Forschungsumgebung und für die Notwendigkeit, diese kritisch an die eigenen disziplinären Bedürfnisse anzupassen, könnte Formen produktiver Serendipität begünstigen. Es stellt sich jedoch die Frage, wie die technischen Voraussetzungen geschaffen werden können, damit ein RS für offene und teilweise zufällige Entdeckungsprozesse geeignet ist.

Die detaillierte Untersuchung aller Algorithmen und Methoden, die für diesen Zweck verwendet werden können, würde den Rahmen dieses Beitrags sprengen. Dennoch ist es sinnvoll, einen generischen Ansatz vorzustellen, der für wissenschaftliche Forschungsplattformen besonders nützlich erscheint. Dieser Ansatz konzentriert sich darauf, die zu entdeckenden Ressourcen anzureichern, um neue Schlüsselwörter zu generieren und sie über verschiedene Suchwege auffindbar zu machen.

Ein vielversprechender Ansatz scheint es zu sein, Ressourcen der *künstlichen Intelligenz*, insbesondere des *Natural Language Processing* zu kombinieren, um Wissen aus Ressourcen zu extrahieren und den Nutzer:innen neue digitale Objekte zu empfehlen.

Named Entities wie Orte, Organisationen, Personen etc. können zu diesem Zweck extrahiert werden, ebenso wie Topics und Keywords. Die extrahierten Entitäten können dann gegen bekannte Vokabulare disambiguiert und referenziert werden, um „kognitive Entitäten“ in maschinenlesbarer Form zu generieren, z. B. basierend auf Konzepten wie Wikidata.⁴¹ Sogenannte *Knowlets*, die Kernaussagen zu einem bestimmten Konzept enthalten, können ebenfalls als maschinenlesbare Nanopublikationen verwendet werden,⁴² um Ähnlichkeiten zwischen Texten oder anderen Arten von digitalen Objekten zu erkennen und so Objektvorschläge zu machen. Bei Publikationen und anderen Arten von Daten können beispielsweise der Titel, das Abstract und der Volltext eines Artikels durch verschiedene Techniken wie Tokenisierung, Stopworteliminierung, Lemmatisierung und Named Entity Recognition and Disambiguation (NERD) verarbeitet werden. Mithilfe von Heuristiken werden dann weniger wichtige Wörter herausgefiltert. Die relevanten kognitiven Einheiten werden separat gespeichert und mit den Metadaten der durchsuchbaren Ressourcen verknüpft. Besonders wertvoll ist die Möglichkeit, diese Informationen mithilfe eines Vektorraummodells darzustellen. Dieses Modell basiert auf der Häufigkeit von Wörtern oder Phrasen im Dokument und ermöglicht es, die mit verschiedenen Keywords verbundenen kognitiven Einheiten

³⁹ Martin und Quan-Haase (2017).

⁴⁰ Afzadi (2019).

⁴¹ Gemmis et al. (2015).

⁴² Mons (2019).

einfach und schnell zu finden, indem die Repositorien der kognitiven Einheiten abgefragt werden. Ihre Relevanz wird berechnet und auf dieser Grundlage werden Empfehlungen formuliert. Gemmis schlägt spezifisch vor, dass eine Phase der Wissensextraktion und -harmonisierung erfolgt, bei der die Keywords aus den Dokumenten identifiziert werden, um Abfragen an die Repositorien der kognitiven Einheiten zu formulieren und die am besten geeigneten Wissensinhalte zu finden. Durch das Erstellen von Listen verwandter Keywords ist es möglich, eher zufällige, aber dennoch potenziell relevante Empfehlungen zu generieren. Sowohl die Empfehlungen als auch die abgerufenen kognitiven Einheiten erzeugen immer wieder neue Listen verwandter Keywords, die verwendet werden können, um verwandte Artikel vorzuschlagen oder zu suchen.⁴³

4 Serendipität auf einer Open-Data-Entdeckungsplattform

Open Data sind Daten, auf die jedermann ohne Einschränkungen durch Urheberrechte, Patente oder andere Kontrollmechanismen zugreifen und die er/sie nutzen, verändern und mit anderen teilen darf.⁴⁴ Sie werden von einer Vielzahl von Institutionen und Datenanbietern erzeugt, kuratiert, verarbeitet, archiviert und zur Verfügung gestellt: öffentliche Verwaltungen, NGOs, Museen, Galerien, Bibliotheken, lokale und nationale Archive und natürlich institutionelle Repositorien und Fördereinrichtungen. Sie sind für Forschung und Lehre von höchster Relevanz, weil sie mehrere Themen und Forschungsfragen abdecken. Die Befruchtung verschiedener Wissensgebiete durch den Austausch von Methoden und Erkenntnissen aus anderen Bereichen setzt immer voraus, dass Daten und Informationen auch aus Bereichen außerhalb des eigenen Spezialgebietes auffindbar sind. Aber gerade weil sie nicht ausschließlich auf die akademischen Diskurse beschränkt sind, sind ihre Standards und die Metadaten, die sie beschreiben, sehr heterogen und oft nicht vertraut für diejenigen, die es gewohnt sind, mit anderen Arten von wissenschaftlichen Daten zu arbeiten. Das macht es auch schwierig, sie über ein RS zu entdecken. Dies ist in diesem Fall umso wichtiger, als diese Daten für verschiedene Arten von Interessengruppen aus sehr unterschiedlichen Disziplinen von Nutzen sind. Daher

ist es vorteilhaft, über eine Umgebung zu verfügen, die all diese Daten zusammenführt und eine digitale Plattform, die gezielt die Entdeckung von Open Data für Forschung und Lehre unterstützen soll, muss das Ziel ernst nehmen, die Bedingungen der Möglichkeit für zufällige und glückliche Entdeckungen zu schaffen. Herkömmliche Suchmaschinen bieten zwar bereits Zugang zu vielen dieser offenen Datensätze, aber keinen dienen den Wissenschaftler:innen, die aus unterschiedlichen Disziplinen kommen und Daten aus verschiedenen Bereichen benötigen.

4.1 Der Open Data Navigator

Mit dem Open Data Navigator⁴⁵ hat die Stiftung Switch⁴⁶ den Prototyp einer Plattform für Open Data aus verschiedenen, heterogenen Domänen lanciert. Das Hauptziel der Plattform besteht darin, die Entdeckung und Nutzung von Open Data aus einer inter- und multidisziplinären Perspektive zu fördern. Sie umfasst Anwendungsfälle, in denen z. B. Daten aus der öffentlichen Verwaltung mit Daten aus dem Bereich des kulturellen Erbes und mit wissenschaftlichen Publikationen kombiniert werden, oder Anwendungsfälle, in denen Berichte einer NGO mit Statistiken der öffentlichen Verwaltung und/oder sozialwissenschaftlichen Veröffentlichungen interpretiert werden sollen. Stakeholder einer solchen Plattform sind in erster Linie Individuen, die in verschiedenen Wissensbereichen forschen und lehren und Unterstützung in Bezug auf offene Daten außerhalb des akademischen Datenkreislaufs benötigen. Eine bessere Integration dieser nicht-akademischen offenen Daten in den wissenschaftlichen Prozess ist das Hauptziel dieser Initiative.

Die Plattform sammelt in erster Linie Metadaten von Open-Data-Repositorien, die für Lehre und Forschung relevant sein können. Diese werden als *Linked Open Data* aggregiert, um eine Art Metadatenkatalog nach einem gemeinsamen Metadatenschema⁴⁷ zu erstellen, einer Auswahl von schema.org⁴⁸ basierend auf dem Feedback von Vertretern der Stakeholder-Community. Auf diese Weise werden Verbindungen zwischen Datensätzen hergestellt, die nicht nur für Menschen, sondern auch für Maschinen lesbar sind. Dadurch ist es möglich, verschiedene Arten von RS zu implementieren und Empfehlungen zu generieren. Aber selbst wenn die Metadaten als *Linked Data* gespeichert und indexiert werden, wird dies ohne ein geeignetes Such- und

43 Gemmis et al. (2015).

44 Nach der Definition des Open Data Handbook: „Open data is data that can be freely used, re-used and redistributed by anyone – subject only, at most, to the requirement to attribute and share alike.“, <https://opendatahandbook.org/guide/en/what-is-open-data/>.

45 <https://opendatanavigator.switch.ch/>.

46 <https://www.switch.ch/>.

47 <https://rescs.org/dev/index.html>.

48 <https://schema.org/>.

Empfehlungssystem nicht unbedingt zu zufälligen, aber glücklichen Entdeckungen führen. Es ist in erster Linie für Suchprozesse ausgelegt, die sehr genaue, aber nicht überraschende Ergebnisse erfordern. Der Aufbau einer RS, die Serendipität in Entdeckungsprozessen ermöglicht, erfordert daher wiederum die Integration verschiedener Lösungen, die die ursprünglichen Daten anreichern, um neue Arten von Empfehlungen zu generieren. Aber auch hier gibt es spezifische Schwierigkeiten, die besondere Aufmerksamkeit verdienen, auch im Hinblick auf ihre langfristigen Auswirkungen.

4.2 Herausforderungen bei der Umsetzung eines RS auf dem Open Data Navigator

Aufgrund der wissenschaftlichen und gesellschaftlichen Relevanz der Open Data sind die Schwierigkeiten bei der Erstellung einer geeigneten RS für eine solche Plattform nicht nur technischer, sondern auch ethischer Natur. Unzureichende Empfehlungen können sowohl die wissenschaftliche Forschung und ihre gesellschaftlichen Auswirkungen als auch die Aktivitäten der Bürger:innen beeinträchtigen, die diese Daten nutzen wollen, um informierte Entscheidungen zu treffen – man denke z. B. an die soziale Relevanz von Verwaltungsdaten oder NGO-Daten und die Bedeutung, die sie durch geeignete wissenschaftliche Informationen besser interpretieren zu können.

Die prototypische Entwicklung des Open Data Navigator konzentrierte sich bisher auf semantische Empfehlungen auf Basis des Knowledge Graph, der auf einer bewusst generischen Ontologie basiert. Für eine Entdeckungsplattform, die die Auffindbarkeit von Open Data für Forschung und Lehre fördern und gleichzeitig die Bedingungen der Serendipität im Entdeckungsprozess gewährleisten soll, scheinen jedoch andere Lösungen notwendig zu sein. Eine klare Identifizierung der spezifischen Herausforderungen des RS für das ODN wird uns helfen, eine allgemeine Richtlinie zu definieren. Am Ende des Papiers werden dann geplante und mögliche nächste Schritte für die Entwicklung des Open Data Navigator vorgestellt, die diesen Richtlinien entsprechen sollten.

Zusätzlich zu den schon genannten Verzerrungen gibt es nämlich spezifische Biases, die ein Problem für den Entdeckungsprozess und die Implementierung eines RS auf einer solchen Plattform darstellen können.

- *Metadata Quality Bias.* Wir bezeichnen diesen Bias als Metadata Quality Bias, um ihn von anderen Biases, die bereits in der Forschung erwähnt wurden, zu unterscheiden und seine Besonderheit hervorzuheben. In vielen Fällen ist die Qualität der aggregierten Meta-

daten nicht ausreichend, um signifikante Verbindungen zwischen verschiedenen Daten herzustellen; Metadaten können fehlen oder fehlerhaft sein, so dass sie keine direkte Entdeckung oder Empfehlung einer RS ermöglichen.

- *Mangel an gemeinsamen Standards und Best Practices.* Die Tatsache, dass auf der Plattform Daten von sehr unterschiedlichen Anbietern und aus sehr unterschiedlichen Bereichen aggregiert werden, bedeutet, dass man es mit einer Vielzahl von Metadatenstandards zu tun hat, insbesondere was die Verschlagwortung von Datensätzen und Publikationen betrifft. Diese spielen, wie wir gesehen haben, eine Schlüsselrolle bei der Formulierung von RS und bei der Unterstützung von Serendipität. Ohne kontrollierte Vokabulare und Ressourcen, um diese auf aggregierte Metadaten anzuwenden, bleiben viele Daten, die potenziell stärker miteinander verknüpft und daher leicht auffindbar wären, unverbunden und schwer auffindbar.
- *Personalisierung der Empfehlungen vs. Datenschutz.* Ein RS-System würde, wie bereits erwähnt, auch hier stark von nutzerbasierten Informationen und Feedbacks profitieren. Das RS könnte z. B. Informationen über die Suchhistorie, persönliche Vorlieben bezüglich Disziplinen und Interessen sammeln. Es könnte die Forschungsbeiträge der Nutzer:innen als Grundlage für Empfehlungen berücksichtigen oder Informationen, die sie auf anderen ähnlichen Portalen gespeichert haben: Es könnte sogar die Möglichkeit geben, die Relevanz und Nützlichkeit von Ressourcen und Empfehlungen zu bewerten und diese Bewertungen anderen mitzuteilen. Dies setzt natürlich voraus, dass es eine geeignete Rechtsgrundlage für die Einwilligung in die Nutzung personenbezogener Daten gibt und die Nutzer:innen entsprechend informiert werden. Inwieweit dies der Personalisierung von Empfehlungsprozessen Grenzen setzt kann, muss im Einzelfall geklärt werden.⁴⁹
- *Unzulängliche Modellierung der antizipierten Anwendungsszenarien.* Schließlich gibt es besondere Schwierigkeiten im Zusammenhang mit der Art der Nutzererfahrung, die auf einer solchen Plattform stattfinden muss. Da sie sich nicht an Spezialist:innen einer einzigen Disziplin richtet, sondern potenziell an alle Forscher:innen, die mit offenen Daten aus verschiedenen Bereichen und möglicherweise aus einer interdisziplinären Perspektive arbeiten, wird sie mit sehr unterschiedlichen Erwartungen konfrontiert, wie Daten und Informationen visualisiert werden sollen und wie das gesamte Nutzererlebnis auf der Plattform aus-

49 S. z. B. Friedman et al. (2015).

sehen soll. Dies kann das Vertrauen der Nutzer:innen einschränken und sie sogar dazu bringen, der Relevanz der vorgeschlagenen Empfehlungen zu misstrauen. Eine ungewöhnliche und seltsame Nutzererfahrung kann die Vertrauenswürdigkeit der RS untergraben.

4.3 Empfehlungen

Die Nutzung von RS auf digitalen Plattformen für Studien- und Forschungszwecke hat ethische Relevanz für viele Stakeholder, nämlich für Forschende, Studierende und Citizen Scientists, aber auch indirekt für alle Institutionen und Personen, die akademische Forschung finanzieren. Nur wenn es gelingt, Serendipität zu fördern, kann das Risiko eines Verlustes an Innovationskraft im Prozess der Generierung von Empfehlungen für potenziell relevante digitale Objekte minimiert werden. Wir möchten nun konkrete Empfehlungen für die Entwicklung solcher digitaler Discovery-Plattformen geben, insbesondere für den Open Data Navigator, wie er derzeit von Switch im Connectome Project entwickelt wird und der sich in erster Linie an Studierende und Forschende aus verschiedenen Fachgebieten und an Citizen Scientists richtet.

1. *Ein Gleichgewicht zwischen Genauigkeit und Zufälligkeit herstellen.* Generell sollte das implementierte RS-System so gestaltet sein, dass ein Gleichgewicht zwischen Genauigkeit und *Überraschungseffekt* der Empfehlungen erreicht wird. Um dies zu erreichen, scheinen hybride RS, d. h. Empfehlungen, die sowohl auf dem Inhalt der Metadaten (*content based*) als auch auf den von den Nutzer:innen bereitgestellten Informationen basieren (*user based*), nach dem derzeitigen Stand der Forschung am besten geeignet zu sein.
2. *Metadatenanreicherungen zugunsten von inhaltbasierten Empfehlungen durchführen.* Für inhaltsbasierte Empfehlungen sollten Metadaten mit geeigneten NLP-Techniken angereichert werden. Eine einfache Korrelation von Ressourcen basierend auf gemeinsamen Begriffen ohne angemessene Normalisierung oder Standardisierung der verwendeten Begriffe führt zu spezifischen Empfehlungen und schließt viele Fälle von Empfehlungen basierend auf Synonymen und ähnlichen Begriffen aus, die für Serendipität entscheidend sind. Um dies zu vermeiden, scheinen vektorbasierte NLP-Techniken am besten geeignet. Auf dieser Basis können kognitive Einheiten und Begriffscluster generiert werden, die mehrere synonome Begriffe enthalten und so Beziehungen zwischen digitalen Objekten herstellen, die sonst nicht miteinander in Verbindung stehen und daher nicht empfohlen werden würden.

3. *Nutzerbasierte Empfehlungen und Personalisierung unter Berücksichtigung von Datenschutz und Privatsphäre gewährleisten.* Die Nutzer:innen sollen die Möglichkeit haben, einige Parameter des Empfehlungssystems direkt zu beeinflussen, und das Empfehlungssystem soll die Profile der Nutzer:innen berücksichtigen, um personalisierte Empfehlungen zu generieren. Dazu sind zwei verschiedene Verfahren denkbar. Zum einen muss die Suchhistorie analysiert werden, um wiederkehrende Interessen zu identifizieren. Zum anderen muss den Nutzer:innen die Möglichkeit gegeben werden, persönliche Profile mit persönlichen Präferenzen und Informationen anzulegen. Beides stellt eine ethische Herausforderung für den Datenschutz dar. Diese Informationen sollten auf nationalen und sicheren Servern gespeichert werden und nicht für andere Zwecke verwendet werden können. Generell ist es wichtig, dass die Umsetzung von Maßnahmen zur Personalisierung von Empfehlungsprozessen immer sorgfältig von Datenschutzexperten auf ihre rechtliche und ethische Relevanz hin überprüft wird.
4. *Transparenz und Nachvollziehbarkeit der Algorithmen ermöglichen.* Nudging auf wissenschaftlichen Wissensplattformen schafft Misstrauen und sollte daher vermieden werden, auch wenn es im Interesse der Stakeholder gut gemeint sein mag. Es ist daher wichtig, die vollständige Transparenz der RS zu gewährleisten, indem der Prozess, der zu bestimmten Empfehlungen führt, nachvollziehbar gemacht wird. Es muss jedoch geklärt werden, wie viele technische Details wirklich verständlich und hilfreich sind, um die Logik der Empfehlungen zu verstehen. Es liegt auf der Hand, dass Beispiele besser geeignet sind, um die Filter-, Facettierungs- und Empfehlungsprozesse zu veranschaulichen. Ohne die Nutzung der Plattform zu erschweren, sollte jeder Abschnitt, der Empfehlungen enthält, kurze und benutzerfreundliche Erklärungen enthalten.
5. *Open-Source-Tools und Sprachmodelle verwenden.* Besonders wichtig ist die Darstellung des NLP-Modells, das für die Datenanreicherung und die kognitive Cluster- und Themengenerierung verwendet wird. Es sollten geeignete Open-Source-Modelle verwendet werden, die jeder mit ausreichender Kompetenz verstehen kann und die als Grundlage für die Trainingsdaten dienen. Darüber hinaus lässt die Verwendung von Open-Source-Modellen die Möglichkeit offen, die Modelle durch kooperative Ansätze (*crowd sourcing*) zu verbessern, die, wenn sie von den Entwicklern der Plattform berücksichtigt werden, zu einer Verbesserung der implementierten RS führen können.

6. *Maßnahmen zur Verbesserung der Metadata Quality Bias ergreifen.* Wie wir gesehen haben, kann eine schlechte Qualität der Metadaten den Empfehlungsprozess beeinträchtigen. Um diese Situation zu verbessern, werden drei Strategien vorgeschlagen.
 - 6.1. *Techniken zur Datenanreicherung, Disambiguierung und Deduplizierung einzusetzen*, um sicherzustellen, dass die für die Empfehlungen verwendeten Metadaten und insbesondere ihre Schlagwörter ausreichen, um Verbindungen zwischen den Ressourcen herzustellen und so die Entdeckung neuer Ressourcen für die Nutzer:innen auf produktive Weise zu erleichtern.
 - 6.2. *Best Practices für Data Management fördern.* Es ist notwendig, Best Practices für das Datenmanagement zu erarbeiten und deren Anwendung durch die Anbieter offener Daten und Data Stewards zu fördern, um bestimmte Qualitätsstandards zu gewährleisten. Dies kann durch die Erstellung geeigneter Richtlinien, in denen die erforderlichen Standards beschrieben werden, und durch eine bessere Koordination zwischen den Datenprovidern einerseits und den Serviceprovidern andererseits erreicht werden.
 - 6.3. *Benutzergesteuerte Eingabe von Metadaten ermöglichen.* Ein weiterer vielversprechender Ansatz besteht darin, den Endnutzer:innen direkt in die Verbesserung der Metadaten einzubeziehen, indem ihm geeignete Verfahren zur Verfügung gestellt werden, mit denen er fehlende Informationen ergänzen oder fehlerhafte Informationen korrigieren kann. Über eine entsprechende Funktion in der Benutzeroberfläche könnten die Nutzer:innen eigene Informationen hinzufügen. Dabei ist zu berücksichtigen, dass dies wiederum Herausforderungen an die Sicherung der Datenqualität stellt. Dies erfordert redaktionelle Prozesse, um die Gültigkeit der von den Nutzer:innen hinzugefügten Informationen zu überprüfen.
7. *Stakeholder in die Mitgestaltung der Plattform einzubeziehen.* Das Vertrauen in ein digitales Werkzeug ist offenbar größer, wenn es von Stakeholdern mitgestaltet wird. Damit die Nutzer:innen Vertrauen in die Eignung der Plattform im Allgemeinen und damit auch in die Darstellung und Empfehlung potenziell relevanter Objekte haben, müssen sie durch geeignete Verfahren die Möglichkeit haben, an der Gestaltung der Plattform mitzuwirken.
 - 7.1. *Nutzer:innen-Fokusgruppen.* Die konkrete Ausgestaltung der Plattform muss zunächst unter möglichst intensiver und häufiger Beteiligung der

Betroffenen entwickelt werden. Endnutzer:innen sollen in die Mitgestaltung der Plattform einbezogen werden und könnten zur Qualität der Metadaten und somit des RS beitragen; die Sicherstellung einer Mindestdatenqualität zur Generierung geeigneter Empfehlungen erfordert eine stärkere Koordination zwischen Service- und Data Provider.

7.2. *Scientific Advisory Boards mit ethischen Kompetenzen.* Zum anderen muss die Administration die Einrichtung von Scientific Advisory Boards ermöglichen, die in der Lage sind, die Zweckmäßigkeit der erhobenen Informationen und der entwickelten Funktionalitäten und insbesondere die langfristigen Auswirkungen des Einsatzes eines bestimmten RS auf Wissenschaft und Gesellschaft zu beurteilen. Die Einbindung von Personen mit Kompetenzen im Bereich der digitalen Ethik in ein solches Board erscheint daher angebracht. Die Bewertung der datenschutzrechtlichen Aspekte der Personalisierung der RS erfordert ebenfalls die Expertise von Rechtsexpert:innen.

5 Fazit: Nächste Umsetzungsschritte in Connectome Project und Outlook

Werkzeuge zur Entdeckung von Informationen und Daten, die für die Forschung nützlich sein können, haben ethisch relevante Implikationen, da sie zu Verzerrungen führen können, die für die wissenschaftliche Forschung und somit für die Gesellschaft, die auf wissenschaftliche Innovation angewiesen ist, schädlich sind. Bei der Entwicklung digitaler Plattformen zur Entdeckung von Daten, müssen Maßnahmen ergriffen werden, um eine gewisse Serendipität zu gewährleisten, d. h. die Möglichkeit, dass Empfehlungssysteme überraschende, aber dennoch nachvollziehbare und damit nützliche Empfehlungen generieren. Dies ist keine leichte Aufgabe, da das Konzept der Serendipität sehr weit und facettenreich ist und je nach Anwendungsbereich immer wieder neu spezifiziert werden muss.

Die wichtigsten nächsten Umsetzungsschritte im Rahmen des Connectome Projects in Bezug auf den Open Data Navigator werden nun darin bestehen, die Entwicklung der RS für den Open Data Navigator so zu gestalten, dass zumindest einige dieser Anforderungen berücksichtigt werden können. Die prototypische Entwicklung des Open Data Navigator konzentrierte sich bisher auf Empfehlun-

gen, die auf einer Kombination von Knowledge Graph und Elastic Search basieren. Um jedoch die Bedingungen der Serendipität im Entdeckungsprozess und gleichzeitig die Transparenz zu wahren, schienen weitere Lösungen notwendig. Dafür wird der Einsatz von hybriden Suchformen von großer Bedeutung sein. Diese kombinieren ein semantisches, d. h. vektor- und kontextbasiertes Konzept der Ähnlichkeit zwischen Objekten mit einem präzisen Keyword Matching, was die Entdeckung relevanter Ressourcen erheblich verbessern kann. Die hybride Suche kombiniert verschiedene Suchalgorithmen, um die Genauigkeit und Relevanz von Suchergebnissen zu verbessern, indem die besten Eigenschaften von keyword- und vektorbasierten Suchtechniken genutzt werden. Diese Methode verwendet verschiedene Arten von Vektoren, um die semantische Bedeutung und den Kontext von Suchanfragen und Dokumenten darzustellen. Die hybride Suche eignet sich daher besonders für Systeme, die die Vorteile der semantischen Suche nutzen wollen, aber auch auf exakte Schlagworttreffer angewiesen sind.

Elasticsearch⁵⁰ hatte die Open-Source-Optionen für Elasticsearch und Kibana eingestellt und sie unter der Elastic-Lizenz veröffentlicht, wobei der Quellcode unter der Elastic-Lizenz oder SSPL verfügbar ist. Anforderungen an Transparenz und Flexibilität haben daher den Einsatz von OpenSearch⁵¹ für die Implementierung der hybriden Suche in dem Open Data Navigator. Dieses Tool ist Open Source ist und verfügt über eine starke Community-Unterstützung. Somit ermöglicht OpenSearch den Entwicklern, den Code zu überprüfen, anzupassen und zu erweitern, um spezifische Anforderungen zu erfüllen.

Der weitere zentrale Schritt in der Optimierung des RS für die Open Data Navigator wäre dann die Implementierung personalisierter Empfehlungen durch die Integration von Nutzerprofilen in den hybriden Suchprozess von OpenSearch. Dieser Ansatz ermöglicht es, die Suchergebnisse noch genauer auf die individuellen Präferenzen und Bedürfnisse der Nutzer:innen abzustimmen. Durch die Analyse der in den Nutzerprofilen gespeicherten Informationen – wie z. B. bisherige Suchanfragen, Interaktionen mit Suchergebnissen und persönliche Präferenzen – kann die Relevanz der Empfehlungen deutlich gesteigert werden. Die Herausforderung wird darin bestehen, einen effizienten Mechanismus zu entwickeln, der diese Nutzerdaten in Echtzeit mit den Ergebnissen der hybriden Suche kombiniert. Dies erfordert eine sorgfältige Abwägung zwischen der Personalisierung von Inhalten und dem Schutz der Privatsphäre der Nutzer:innen. Durch die Nutzung der flexiblen

Architektur und der erweiterbaren Plugins von OpenSearch könnte man einen maßgeschneiderten Suchpipeline-Prozess erstellen, der sowohl semantische Relevanz als auch persönliche Präferenzen berücksichtigt, um ein hochgradig personalisiertes und effektives Empfehlungssystem zu realisieren.

Literaturverzeichnis

Abdollahpouri, H.; Mansouri, M.; Burke, R.; Mobasher, B. (2019): The Impact of Popularity Bias on Fairness and Calibration in Recommendation. DOI:10.48550/ARXIV.1910.05755

Adomavicius, G.; Tuzhilin, A. (2011): Context-Aware Recommender Systems. In: *Recommender Systems Handbook*, hg. von F. Ricci, L. Rokach, B. Shapira und P. B. Kantor, 217–53. Springer US. DOI:10.1007/978-0-387-85820-3_7.

Afridi, A. H. (2019): Transparency for Beyond-Accuracy Experiences. In: *Procedia Computer Science*, 151, 335–44. DOI:10.1016/j.procs.2019.04.047.

Boratto, L.; Faralli, S.; Marras, M.; Stilo, G. (Hrsg.) (2021): Advances in Bias and Fairness in Information Retrieval: Second International Workshop on Algorithmic Bias in Search and Recommendation, BIAS 2021, Lucca, Italy, April 1, 2021, Proceedings. Heidelberg: Springer.

Buder, J.; Schwind, C. (2012): Learning with personalized recommender systems: A psychological view. In: *Computers in Human Behavior*, 28 (1), 207–16. DOI:10.1016/j.chb.2011.09.002.

Daniil, S.; Cuper, M.; Liem, C. C. S.; van Ossenbruggen, J.; Hollink, L. (2022): Hidden Author Bias in Book Recommendation (arXiv:2209.00371). arXiv. <http://arxiv.org/abs/2209.00371>.

Das, C.; Sahoo, A. K.; Pradhan, C. (2022): Multicriteria recommender system using different approaches. In: *Cognitive Big Data Intelligence with a Metaheuristic Approach*, 259–77. Elsevier. DOI:10.1016/B978-0-323-85117-6.00011-X.

Deldjoo, Y.; Jannach, D.; Bellogin, A.; Difonzo, A.; Zanzonelli, D. (2023): Fairness in Recommender Systems: Research Landscape and Future Directions. In: *User Modeling and User-Adapted Interaction*. DOI:10.1007/s11257-023-09364-z.

DFG-Committee On Scientific Library Services And Information Systems (2021): Data tracking in research: Aggregation and use or sale of usage data by academic publishers. A briefing paper of the Committee on Scientific Library Services and Information Systems of the Deutsche Forschungsgemeinschaft (DFG, German Research Foundation). Zenodo. DOI:10.5281/ZENODO.5937995.

Elahi, M.; Kholgh, D. K.; Kiarostami, M. S.; Saghari, S.; Rad, S. P.; Tkalčič, M. (2021): Investigating the impact of recommender systems on user-based and item-based popularity bias. In: *Information Processing & Management*, 58 (5), 102655. DOI:10.1016/j.ipm.2021.102655.

Erdelez, S. (2004): Investigation of information encountering in the controlled research environment. In: *Information Processing & Management*, 40 (6), 1013–25. DOI:10.1016/j.ipm.2004.02.002.

Fan, W.; Zhao, X.; Chen, X.; Su, J. et al. (2022): A Comprehensive Survey on Trustworthy Recommender Systems (arXiv:2209.10117). arXiv. <http://arxiv.org/abs/2209.10117>.

50 <https://www.elastic.co/de/elasticsearch>.

51 <https://opensearch.org/>.

Ferrara, E. (2023): Fairness And Bias in Artificial Intelligence: A Brief Survey of Sources, Impacts, And Mitigation Strategies. arXiv. <http://arxiv.org/abs/2304.07683>.

Foster, A.; Ford, N. (2003): Serendipity and information seeking: An empirical study. In: *Journal of Documentation*, 59 (3), 321–40. DOI:10.1108/00220410310472518.

Friedman, A.; Knijnenburg, B. P.; Vanhecke, K.; Martens, L.; Berkovsky, S. (2015): Privacy Aspects of Recommender Systems. In: *Recommender Systems Handbook*, hg. von F. Ricci, L. Rokach, B. Shapira, 649–88. Springer US. DOI:10.1007/978-1-4899-7637-6_19.

Gemmis, M. de; Lops, P.; Semeraro, G.; Musto, C. (2015): An investigation on the serendipity problem in recommender systems. In: *Information Processing & Management*, 51 (5), 695–717. DOI:10.1016/j.ipm.2015.06.008.

Jesse, M.; Jannach, D. (2021): Digital nudging with recommender systems: Survey and future directions. In: *Computers in Human Behavior Reports*, 3, 100052. DOI:10.1016/j.chbr.2020.100052.

Kreutz, C. K.; Schenkel, R. (2022): Scientific paper recommendation systems: A literature review of recent publications. In: *International Journal on Digital Libraries*, 23 (4), 335–69. DOI:10.1007/s00799-022-00339-w.

Martin, K.; Quan-Haase, A. (2017): “A process of controlled serendipity”: An exploratory study of historians’ and digital historians’ experiences of serendipity in digital environments. In: *Proceedings of the Association for Information Science and Technology*, 54 (1), 289–97. DOI:10.1002/pra2.2017.14505401032.

McCay-Peet, L.; Toms, E. G. (2015): Investigating serendipity: How it unfolds and what may influence it. In: *Journal of the Association for Information Science and Technology*, 66 (7), 1463–76. DOI:10.1002/asi.23273.

McCay-Peet, L.; Toms, E. G. (2018): Facilitating Serendipity. In: *Researching Serendipity in Digital Information Environments*, hg. von L. McCay-Peet E. G. Toms, 33–45. Springer International Publishing. DOI:10.1007/978-3-031-02312-5_4.

Milano, S.; Taddeo, M.; Floridi, L. (2020): Recommender systems and their ethical challenges. In: *AI SOCIETY*, 35 (4), 957–67. DOI:10.1007/s00146-020-00950-y.

Mons, B. (2019): FAIR Science for Social Machines: Let’s Share Metadata Knowlets in the Internet of FAIR Data and Services. In: *Data Intelligence*, 1 (1), 22–42. DOI:10.1162/dint_a_00002.

Morin, E. (2010): Die Methode: Die Natur der Natur (R. E. Zimmermann, W. Hofkirchner, Hrsg.). Turia + Kant.

Nutefall, J. E.; Ryder, P. M. (2010): The Serendipitous Research Process. In: *The Journal of Academic Librarianship*, 36 (3), 228–34. DOI:10.1016/j.acalib.2010.03.005.

Pariser, E. (2012): The filter bubble: How the new personalized web is changing what we read and how we think (2nd pr): London: Penguin Books.

Polonioli, A. (2021): The ethics of scientific recommender systems. In: *Scientometrics*, 126 (2), 1841–48. DOI:10.1007/s11192-020-03766-1.

Roy, D.; Dutta, M. (2022): A systematic review and research perspective on recommender systems. In: *Journal of Big Data*, 9 (1), 59. DOI:10.1186/s40537-022-00592-5.

Toms, E. G. (2000): Understanding and facilitating the browsing of electronic text. In: *International Journal of Human-Computer Studies*, 52 (3), 423–52. DOI:10.1006/ijhc.1999.0345.

Verbert, K.; Parra, D.; Brusilovsky, P.; Duval, E. (2013): Visualizing recommendations to support exploration, transparency and controllability. In: *Proceedings of the 2013 International Conference on Intelligent User Interfaces*, 351–62. DOI:10.1145/2449396.2449442.

Wissenschaftsrat (2020): Wissenschaft im Spannungsfeld von Disziplinarität und Interdisziplinarität | Positionspapier (Drs. 8694-20). Verfügbar unter https://www.wissenschaftsrat.de/download/2020/8694-20.pdf?__blob=publicationFile&v=5.

Witten, I. H.; Gori, M.; Numerico, T. (2007): Web dragons: Inside the myths of search engine technology. Morgan Kaufmann.

Zangerle, E.; Bauer, C. (2023): Evaluating Recommender Systems: Survey and Framework. In: *ACM Computing Surveys*, 55 (8), 1–38. DOI:10.1145/3556536.

Ziarani, R. J.; Ravanmehr, R. (2021): Serendipity in Recommender Systems: A Systematic Literature Review. In: *Journal of Computer Science and Technology*, 36 (2), 375–96. DOI:10.1007/s11390-020-0135-9.

**Andrea Bertino**

SWITCH
Data & insights
Werdstraße 2
CH-8321 Zürich
Switzerland
andrea.bertino@switch.ch
<https://orcid.org/0000-0002-5080-036X>