

KI-Anwendungen im Engineering

Neue Technologien, neue Chancen?

Oliver Bleisinger* und
Martin Eigner

Machine Learning und Generative AI verändern die Art und Weise, wie technische Systeme entworfen, simuliert und optimiert werden. KI-gestützte Prozesse ermöglichen es, Entwicklungszeiten zu verkürzen und Kosten zu senken. Doch wie lassen sich KI-Anwendungen strukturiert in bestehende Entwicklungsprozesse integrieren sowie Nutzen und Erfolgchancen evaluieren? Dieser Beitrag skizziert einen Überblick über aktuelle KI-Anwendungen für die Verifikation & Validierung in der Produktentwicklung und bietet ein Vorgehen zur Umsetzung von KI-Anwendungsfällen.

Einleitung

Im Hinblick auf die Wertschöpfung von Generative AI zählt die Forschung und Entwicklung neuer Produkte zu den wichtigsten Anwendungsbereichen [1], aber auch weitere KI-Technologien finden im Engineering Anwendung. Daher etablieren sich zunehmend KI-Anwendungen zur Unterstützung kreativer, aber auch administrativer Engineering-Prozesse. Dies umfasst beispielsweise die Angebotserstellung in der RfQ-Phase (Request-for-Quotation), die Konzeptfindungsphase bei Systemarchitekturen (funktionale, logische und technische Architektursichten) [2] oder die Lösungsfindung bei der Softwareentwicklung sowie der mechanischen und elektronischen Detailkonstruktion [3]. Doch auch die Simulation sowie Verifikation & Validierung (V & V) [4], die Transformation funktional strukturierter E-BOMs zu montageorientierten M-BOMs, die Wiederholteilsuche zur Op-

timierung der Wiederverwendung (z. B. bei 3D-CAD) [5] oder die automatische Ableitung der Affected Items im Freigabe- und Änderungsprozess sind Anwendungsgebiete.

Technologien wie Large Language Models (LLMs), Active Learning und die neueste Generation Neuronaler Netze bieten nicht nur technische Herausforderungen, sondern auch erhebliche strategische Chancen und Potenziale für Führungskräfte und Entscheidungsträger. Dieser Beitrag bietet einen Überblick über KI-Anwendungen im Engineering und stellt an Beispielen aus dem Bereich der Simulation dar, wie KI nicht nur technische Prozesse automatisiert, sondern auch zur Effizienzsteigerung, Kostenreduktion und Innovationsförderung beiträgt. In der Mehrzahl der Unternehmen sind KI-Anwendungen noch nicht umgesetzt – so haben lediglich ca. 30 Prozent der Unternehmen für Generative AI erste Proof of Concepts durch-

geführt [6]. Daher wird abschließend ein systematischer Ansatz für die Pilotierung und Umsetzung von Nutzenpotenzialen vorgestellt, der durch einen Proof of Concept und ein Minimum Viable Product Unternehmen unterstützt, eigene KI-Lösungen zu entwickeln.

Ausgangslage im Engineering

Die zunehmende Verfügbarkeit leistungsfähiger Hardware und der steigende Grad der Digitalisierung befähigen vielfältige KI-Anwendungen im Engineering. Im letzten Jahrzehnt wurden in der Forschung vor allem signifikante Fortschritte beim Machine Learning (ML) in hochspezialisierten Anwendungsgebieten mittels Artificial Narrow Intelligence erzielt. Während bei den KI-Grundlagen praxisrelevante Fortschritte mit hoher Geschwindigkeit erzielt werden, bleibt die tatsächliche Anwendung im Engineering, insbesondere für frühe Phasen der Produktentwicklung, hinter ihrem Potenzial zurück [7]. Ähnlich wie die Einführung von 3D-CAD einen grundlegenden Wandel im Engineering ausgelöst hat, beginnt mit der breiten Verfügbarkeit und Nutzung von KI-Anwendungen ein Transformationsprozess im Engineering.

Entwickelnde Unternehmen werden sich der Vielzahl der Herausforderungen

* Korrespondenzautor

Oliver Bleisinger, M. Sc.; :em engineering methods AG, Rheinstr. 97, 64295 Darmstadt, Tel.: +49 (0) 1511 6166-489, E-Mail: oliver.bleisinger@em.ag

Weiterer Autor

Prof. Dr.-Ing. Martin Eigner; EIGNER Engineering Consult, Baden-Baden

Hinweis

Bei diesem Beitrag handelt es sich um einen von den Advisory-Board-Mitgliedern des ZWF-Sonderheftes wissenschaftlich begutachteten Fachaufsatz (Peer-Review).

Kreativer Entwurfsprozess	Administration von Engineering Artefakten	
Automatisierte Codegenerierung	Nachweis der Normkonformität	Vorhersage des Projektfortschritts
Softwarecode Optimierung	Qualitätssicherung im Engineering	Fehlererkennung in Geschäftsprozessen
Genetischer Systementwurf	Datenbasierte Anforderungserhebung	Administration von Anforderungen
Generativer Produkt-/Modulentwurf	Generierung von Zulassungsdokumenten	Personalisierte Produktkonfiguration
Komponentenauswahl für Systementwürfe	Einflussanalyse im Änderungsmanagement	Analyse von Wiederverwendungspotenzial
Ressourceneffiziente 3D-Entwürfe	Erkennung projektbezogener Engpässe	Ableitung von Stücklisten
...	Bewertung mitgeltender Unterlagen	...

Bild 1. Auszug von Workshopergebnissen zu KI-Anwendungsfällen im Engineering

bei der Anwendung von ML und Generative AI (GenAI) zunehmend bewusster – sei dies durch die Konkretisierung der rechtlichen Situation durch die Gesetzgebung (z. B. EU AI Act), Hürden beim Datenschutz und der Datenverfügbarkeit oder den Ausbau notwendiger Kompetenzen von Mitarbeitenden [6, 8]. Auch das Thema der Anpassung von existierenden Rollen und Verantwortlichkeiten oder gar Vorgehensmodellen rückt zunehmend in den Fokus [8, 9], weshalb die Mehrzahl der Unternehmen eine Befähigung von Mitarbeitenden zum Thema KI für notwendig hält [6].

Häufig wird bei der Diskussion der Anwendung von KI im Engineering jedoch das klare Umreißen des anvisierten Anwendungsfalls (Use Case) zugunsten der antizipierten Nutzenpotenziale vernachlässigt. Use Cases, Potenziale und Herausforderungen variieren jedoch innerhalb eines Unternehmens stark und umfassen den kreativen Entwurfsprozess, die Verwaltung von Engineering-Artefakten (Bild 1) sowie die Simulation und V & V.

Für diesen Beitrag wird ein Fokus auf den Einsatz von ML im Sinne einer Artificial Narrow Intelligence für die frühe Simulation im V & V gelegt, d. h. auf 0D-Simulationen in der Konzeptphase. Hierfür werden exemplarisch drei Use Cases umrissen, die bei Industrieunternehmen umgesetzt wurden. Anhand der Vertiefung eines dieser Use Cases wird anschließend der Nutzen an einem konkreten Beispiel veranschaulicht. Die Ausführungen basieren dabei auf den Erfahrungen der Autoren aus Industrie- und Forschungsprojekten der letzten Jahre.

ML-basierte Simulation für Verifikation & Validierung

In diversen Forschungsprojekten, wie AMOSCO („AI-Based Vehicle Modelling for Simulation and Control Development“, 2021–2024), wurden acht Use Cases für das Engineering im Bereich Verifikation & Validierung identifiziert (Bild 2). Grundlage hierfür waren frühe Voruntersuchungen in den Jahren 2018 bis 2020 [10], inwiefern KI nutzbringend für die Simulation im Engineering eingesetzt werden kann, um die Wettbewerbsfähigkeit von Unternehmen zu fördern. Nachfolgend werden drei dieser Use Cases beschrieben.

Generierung von Simulationsmodellen

Dieser Use Case umfasst die Generierung von Simulationsmodellen und so-

mit die Vorhersage des Verhaltens von Systemen bzw. Produkten mittels KI. Nach einer definierten Dekomposition des Systems erfolgt die Festlegung des Inputs und Outputs der Simulation. Im Anschluss werden geeignete ML-Verfahren genutzt, um ein KI-basiertes Simulationsmodell zu trainieren. In einem Praxisbeispiel [11] haben sich unter anderem der Aufbau Neuronaler Netze und die Anpassung der Hyperparameter zur Optimierung der Simulationsgenauigkeit bewährt. Der Nutzen zeigt sich darin, dass das Modellieren durch das Training der KI-Modelle automatisiert wird. Es entsteht eine Kostenreduktion durch Einsparung von Personalressourcen für die Modellbereitstellung für anschließende Simulationen.

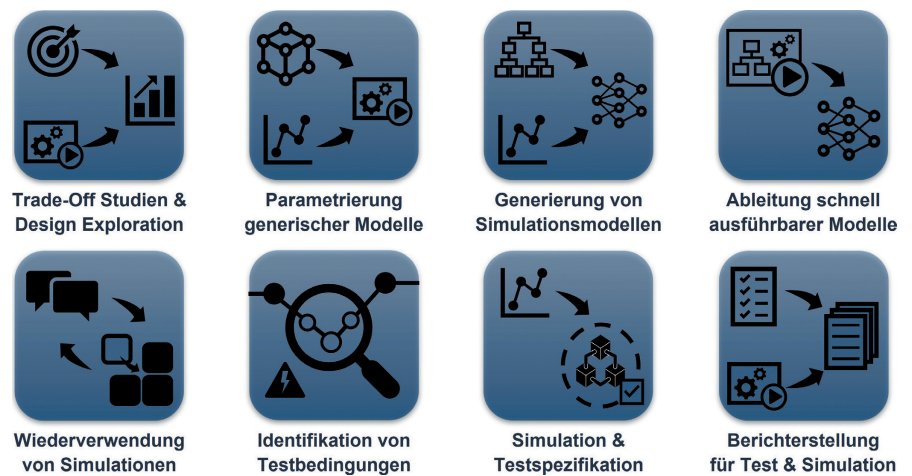


Bild 2. Eingrenzung ausgewählter KI-Anwendungsfälle für die Verifikation & Validierung

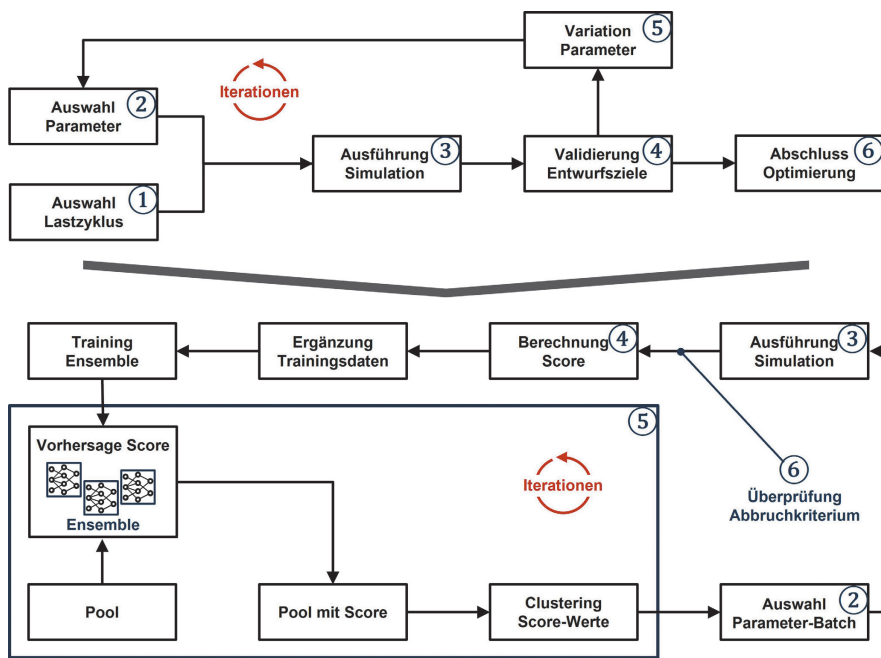


Bild 3. Basisarchitektur für die Automatisierung der Entwurfsoptimierung mit Active Learning

Ableitung schnell ausführbarer Modelle

Bei diesem Use Case werden analytische, d.h. gleichungsbasierte, Simulationsmodelle so in Neuronale Netze transformiert, dass Simulationen deutlich schneller ausgeführt werden. Die signifikante Beschleunigung der Simulation resultiert aus der hohen Ausführungsgeschwindigkeit bei der Inferenz Neuronaler Netze auf leistungsfähiger Hardware (z.B. High-End-Grafikkarten) und entspricht einem Vielfachen der Geschwindigkeit beim Lösen analytischer Modelle [12]. In Pilotprojekten [12, 13] waren höhere Anzahlen von Simulationsdurchläufen in einer vorgegebenen Zeit bei unwesentlich reduzierter Genauigkeit möglich. Die Folge ist eine deutliche Effizienzsteigerung bzw. ausgiebigere Produktoptimierung. Zudem wird bei Weitergabe der Modelle ein IP-Schutz (Intellectual Property) ermöglicht.

Trade-off-Studien & Design Space Exploration

Dieser Use Case zielt darauf ab, optimale Kompromisse bei Produkteigenschaften zu finden, z.B. im Spannungsfeld zwischen Nachhaltigkeit, Kosten und Qualität. Hierbei werden konkurrierende, d.h. im Zielkonflikt stehende, Entwurfsparameter sowie Randbedingungen, Entwurfsziele

und Metriken für Entwürfe festgelegt. Abhängig von der Parameteranzahl und der Komplexität der Randbedingungen können dann beispielsweise evolutionäre Algorithmen [14] oder Active-Learning-Verfahren [4] genutzt werden. Schritte im Optimierungsprozess, wie die Variation von Entwurfsparametern, werden automatisiert, um Pareto-Fronten zu identifizieren. Dies unterstützt die Nachvollziehbarkeit von Entwurfsentscheidungen, fördert aber auch Innovationen bzw. die Findung neuartiger Lösungen.

Design Space Exploration mit Active Learning

Nachfolgend wird eine Fallstudie zum Use Case „Trade-off-Studien und Design Space Exploration“ vorgestellt, um anhand des Beispiels einen konkreteren Einblick in Herausforderungen und Nutzen von KI-Lösungen zu vermitteln. Hierbei wird eine Active-Learning-Architektur für die Entwurfsoptimierung in der Fahrzeugkonzeption genutzt, welche Parameter von Hauptkomponenten des Systems in Hinblick auf die im Konflikt stehenden Entwurfsziele Energieverbrauch und Fahrleistung optimiert. Um genügend Trainingsdaten zu generieren, wurde ein Längsdynamikmodell des Fahrzeugs erstellt. Dieses bildet kom-

ponentenübergreifende Wirkketten in den Engineering-Domänen Mechanik, Elektrik und Software ab. Die Architektur des KI-Algorithmus mit der Einbindung des Simulationsmodells ist in Bild 3 skizziert.

Der Prozess der Entwurfsoptimierung (Bild 3 oben) besitzt durchnummerierte Aktivitäten, die durch die KI-Architektur (Bild 3 unten) automatisiert werden. Die Umsetzung der Nutzenpotenziale, wie etwa Zeitersparnis durch Automatisierung, basiert auf der Grundidee, dass ein sogenanntes Ensemble nach jeder Iteration des Algorithmus die Bewertung und Priorisierung der nächsten Simulationen übernimmt. Hierdurch werden nur die erkenntnisreichsten Fahrzeugentwürfe simuliert, d.h. durch den Algorithmus wird gezielt Feedback aus dem Simulationsmodell (d.h. synthetische Datenpunkte) abgerufen. Des Weiteren können neuartige Fahrzeugentwürfe entstehen, die den Zielkonflikt zwischen Fahrleistung und Verbrauch auf bisher unerwartete Weise ausbalancieren [4].

KI-Umsetzung für das Engineering

Da KI-Anwendungen immer mehr Einzug in Unternehmen halten, soll ein Vorgehen für eine nutzenorientierte Umsetzung konkreter Use Cases präsentiert werden. Das Vorgehen gliedert sich entsprechend Bild 4 in folgende Hauptbereiche:

- Scoping-Workshop,
- Proof-of-Concept (PoC),
- Minimum Viable Product (MVP) und
- Rollout.

In der ersten Phase, dem Scoping, geht es um die Diskussion von geeigneten Use Cases und Best Practices mit Herausarbeitung existierender Probleme (Pain Points) sowie der Beschreibung der möglichen Use Cases, die diese Pain Points auflösen. Nach einer Priorisierung der Use Cases mit weiterem Input aus einer SWOT-Analyse und ggf. qualitativen Betrachtungen der wirtschaftlichen Potenziale wird ein Zielbild erarbeitet. Die erste Phase wird mit einer PoC-Roadmap und einem zeitlich strukturierten Umsetzungsplan abgeschlossen.

Der PoC, die zweite Phase, dient der Evaluierung und der Auswahl des für den Use Case geeigneten KI-Verfahrens.

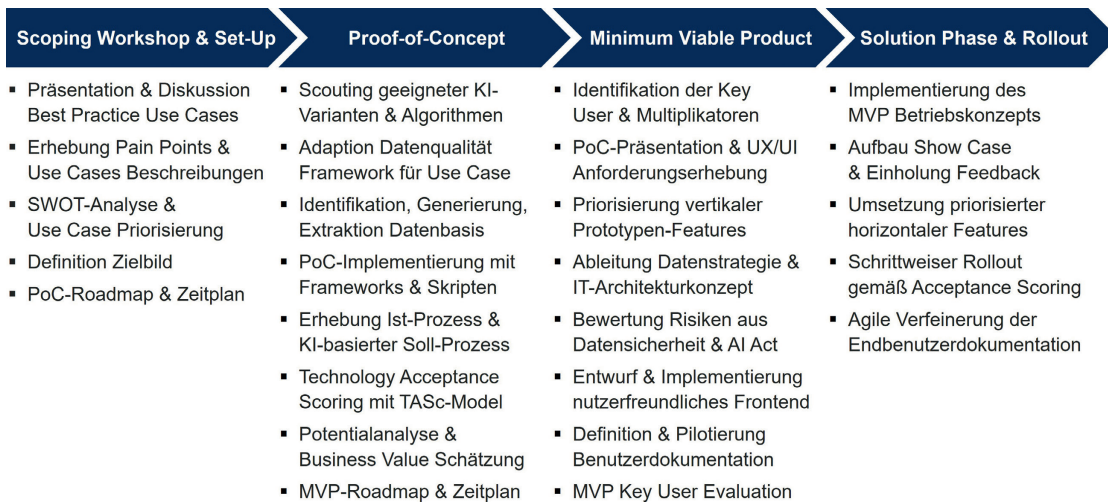


Bild 4. Vorgehen zur strukturierten Umsetzung von KI-Use-Cases im Engineering

Zur Sicherstellung der notwendigen Datenqualität wird zudem ein unternehmensspezifisches Framework mit Qualitätsattributen erarbeitet. Neben der Implementierung des PoC erfolgt eine Erhebung der Ist- und Soll-Prozesse, um eine Potenzialanalyse als quantitative Bewertung zu ermöglichen. Bei positiver Wirtschaftlichkeitsprognose endet die Phase mit einer MVP-Roadmap.

Die Phase der Umsetzung des MVPs legt den Fokus auf die Identifizierung der Hauptanwender sowie auf die Anforderungserhebung für die User Experience. Gemäß dem Technology Acceptance Scoring Model (TASC-Model) aus früheren Untersuchungen [15] wird dies als ein wesentlicher Erfolgsfaktor für die Akzeptanz neuer IT-Werkzeuge und Prozesse angesehen. Neben der prototypischen Erarbeitung einer User Experience findet eine strukturierte Evaluierung des MVPs statt.

Der Rollout bildet den Abschluss des Vorgehens und umfasst neben der Implementierung des Betriebskonzepts des MVPs (z.B. Integration in Legacy-IT, Datenschutzkonzept) auch den Aufbau von Show Cases zur Demonstration des Mehrwerts der KI-Anwendung sowie die Bereitstellung rudimentärer Dokumentation für Endanwender.

Herausforderungen, Risiken und Chancen

Der wachsende Einsatz von KI-Technologien im Engineering birgt enorme Chancen, aber auch Herausforderungen und Risiken. Der Einsatz von GenAI, wie z.B.

LLMs, erfreut sich als Hype-Thema aktuell großer Beliebtheit, doch existieren signifikante Risiken. So ist es einigen Unternehmen aufgrund geltender Sicherheitsvorschriften und Regelungen, wie z.B. TISAX, praktisch verboten, globale Chatbots wie ChatGPT zu nutzen. Ein Verstoß kann ein wirtschaftliches Risiko darstellen. Hinzu kommt, dass die Umsetzung der Gesetzgebung der letzten Monate noch nicht abschließend erfolgt ist. Unter Umständen müssen beim KI-Einsatz auch ethische Fragen geklärt werden oder soziotechnische Betrachtungen erfolgen, da insbesondere die Nutzerakzeptanz eine entscheidende Rolle für die erfolgreiche KI-Anwendung spielt. Die größte Herausforderung stellt jedoch für Unternehmen häufig die Bereitstellung und Sicherstellung der Qualität notwendiger Daten für ML dar.

Dies sind einige Herausforderungen, zu denen abschließend Thesen formuliert werden, die Chancen aufzeigen, wie Hürden überwunden und die Potenziale des KI-Einsatzes im Engineering genutzt werden können:

- Eine strukturierte Vorgehensweise mit stetiger Evaluation der Nutzenpotenziale von KI-Use-Cases während der Lösungsentwicklung reduziert Fehlinvestitionen.
- Aufgrund geltender Sicherheitsvorschriften, Geheimhaltung und Datenschutz werden sich unternehmensinterne KI-Lösungen (z.B. lokale LLMs) etablieren.
- Unternehmen, die trotz rechtlicher Unsicherheiten KI-Anwendungen ent-

wickeln, werden durch das Eingehen kalkulierter Risiken Wettbewerbsvorteile erzielen.

- Die Berücksichtigung soziotechnischer Faktoren beim Einsatz von KI, wie die frühzeitige Evaluation der Nutzerakzeptanz, wird ein zentraler Erfolgsfaktor.
- Der Fokus auf Use Cases, die möglichst vollständig auf synthetisch generierte Daten zurückgreifen, beschleunigt die initiale Umsetzung konkreter Lösungen.

Literatur

1. Chui, M.; Hazan, E.; Roberts, R. et al.: The Economic Potential of Generative AI – The Next Productivity Frontier. McKinsey & Company, 2023 (<https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/the-economic-potential-of-generative-ai-the-next-productivity-frontier#introduction>) [Abgerufen am 14.2.2025]]
2. Chami, M.; Zoghbi, C.; Bruehl, J.-M.: A First Step towards AI for MBSE: Generating a Part of SysML Models from Text Using AI. In: INCOSE Artificial Intelligence for Systems Engineering. 2019
3. Thompson, A.; Layzell, P.; Zebulum, R.S.: Explorations in Design Space: Unconventional Electronics Design Through Artificial Evolution. Transactions on Evolutionary Computation, IEEE 1999 DOI:10.1109/4235.78848
4. Bleisinger, O.; Keil, M.; Eigner, M.: Constrained Multi-Objective Design Optimization in Systems Engineering Using Active Learning. NordDesign 2024 DOI:10.35199/NORDDESIGN2024.38
5. Hanke, F.; Moallim, K.; Bernijazov, R. et al.: Intelligent Part Comparison in Computer-Aided Design. NordDesign 2024 DOI:10.35199/NORDDESIGN2024.16

6. Höck, B.; Behr, J.; Fachinger, A. et al.: Generative KI in der deutschen Wirtschaft 2024 – Wo stehen Unternehmen bei der Implementierung? KPMG AG, 2024, S. 5–11
7. Shabestari, S.; Herzog, M.; Bender, B.: A Survey on the Applications of Machine Learning in the Early Phases of Product Development. ICED 2019
DOI:10.1017/dsi.2019.250
8. Keil, M.; Bleisinger, O.: KI-intensive Systeme: Herausforderungen und Perspektiven für das Systems Engineering. Tag des Systems Engineering 2024: Tagungsband Leipzig, 13.–15. November 2024
9. Hasterok, C.; Stompe, J.; Pfrommer, J. et al.: PAISE – Das Vorgehensmodell für KI-Engineering. Fraunhofer IOSB, Karlsruhe 2021
DOI:10.24406/publica-fhg-301357
10. Bleisinger, O.; Kuhn, T.; Eigner, M.: Auto-generation of Simulation Models From Usage Data Using Learning AI Procedures. Product Data Journal (2020) 1 (https://prostep.epaper-pro.org/pdj_1-2020_english/#46 [Abgerufen am 14.2.2025])
11. Bleisinger, O.; Casarejos Cobra, J. P.: Machine Learning Based Simulation for Wear Estimation in Commercial Vehicle Applications. In: Commercial Vehicle Technology. 2022, S. 81–92
DOI:10.1007/978-3-658-40783-4_6
12. Feldmann, J.; Kraft, K.; Steiner, L. et al.: Fast and Accurate DRAM Simulation – Can We Further Accelerate It? In: Proceedings of Conference: Design, Automation & Test in Europe Conference & Exhibition (DATE), 2022
DOI:10.23919/DATE48585.2020.9116275
13. Bleisinger, O.; Malek, C.; Holbach, S.: Machine Learning Based Simulation for Design Space Exploration. Proceedings of the Design Society (2020) 2, S. 1521–1530
DOI:10.1017/pds.2022.154
14. Müller, C.; Ochsendorf, J.: Combining Structural Performance and Designer Preferences in Evolutionary Design Space Exploration. Automation in Construction 51 (2015)
DOI:10.1016/j.autcon.2015.02.011
15. Heinrich, J.; Bleisinger, O.; Avdejuk, K. et al.: Das Technology Acceptance Scoring Model (TASc-Model) für die Einführung von Model-Based Systems Engineering. In: Willke, D.; Koch, W.; Kaffenberger, R.; Dreiseitl, S. (Hrsg.): Tag des Systems Engineering 2024: Tagungsband Leipzig, 13.–15. November 2024. Gesellschaft für Systems Engineering 2024, ISBN:391064905X

Die Autoren dieses Beitrags

Oliver Bleisinger, M. Sc., arbeitet aktuell am Abschluss seiner Dissertation an der RPTU Kaiserslautern-Landau mit dem Schwerpunkt Machine Learning im Systems Engineering. Hauptberuflich ist er als Teamleiter für Model-Based Systems Engineering bei der :em engineering methods AG tätig. Zudem ist er Dozent für Software Engineering am Institut für Informatik der JGU Mainz. Zuvor forschte er als Business Area Manager beim Fraunhofer-Institut für Experimentelles Software Engineering im Bereich Machine Learning für Systems Engineering. Er ist an über 50 Veröffentlichungen und Konferenzvorträgen beteiligt.

Prof. Dr.-Ing. Martin Eigner leitete von 2004 bis 2017 den Lehrstuhl für Virtuelle Produktentwicklung an der RPTU Kaiserslautern-Landau. Seine Schwerpunkte liegen in den Bereichen Product Lifecycle Management, System Lifecycle Management, Model-Based Systems Engineering und Product Line Engineering. Er beschäftigt sich jüngst mit der Einbindung von KI im Engineering. Im Jahr 2001 gründete er das Beratungsunternehmen EIGNER Engineering

Consult. Er ist Autor und Co-Autor von 17 Fachbüchern sowie von zahlreichen Konferenzbeiträgen und betreute bisher beinahe 100 Doktorarbeiten.

Abstract

AI Applications in Engineering – New Technologies, New Opportunities? Machine Learning and Generative AI are transforming the way technical systems are designed, simulated, and optimized. AI-driven processes enable the reduction of development time and costs. But how can AI applications be systematically integrated into existing development processes, and how can their benefits and success potential be evaluated? This paper provides an overview of current AI applications for verification and validation in product development and outlines an approach for implementing AI use cases.


Schlüsselwörter

Künstliche Intelligenz, Produktentwicklung, Anwendungsfälle, Verifikation und Validierung, Simulation

Keywords

Artificial Intelligence, Product Development, Use Cases, Verification and Validation, Simulation

Bibliography

DOI:10.1515/zwf-2024-0173
ZWF 120 (2025) Special Issue; page 39 – 43
Open Access. © 2025 bei den Autoren, publiziert von De Gruyter. 
Dieses Werk ist lizenziert unter der Creative Commons Namensnennung 4.0 International Lizenz.
ISSN 0947-0085 · e-ISSN 2511-0896