

Robert Queckenberg,
Jonas Leschke, Malte Persike (Hg.)

LEARNING ANALYTICS, ARTIFICIAL INTELLIGENCE UND DATA MINING IN DER HOCHSCHULBILDUNG

Beiträge zur Learning AID 2024

[transcript] Zukunft der Hochschule

Robert Queckenberg, Jonas Leschke, Malte Persike (Hg.)
Learning Analytics, Artificial Intelligence und Data Mining in der
Hochschulbildung

Editorial

Die Hochschule befindet sich im Wandel: Studien- und Verwaltungsformen im Sinne des New Public Managements, die Digitalisierung sowie Forderungen nach mehr Diversität, Inklusion und Nachhaltigkeit stellen Forschung und Lehre vor große Herausforderungen.

Die Reihe **Zukunft der Hochschule** legt den Fokus auf die Risiken und Chancen dieser Entwicklungen und fragt nach der Zukunft unseres Hochschulsystems. Neben kritischen Perspektiven auf die neoliberalen Umstrukturierungsprozesse bietet sie Publikationen ein Forum, die Szenarien für eine sozial-ökologische Transformation der Hochschule entwerfen und nach inklusiveren Bildungszugängen und -formaten fragen. Zugleich ist dies der Ort in unserem Programm, an dem die Hochschulen mit außeruniversitären Forschungs- und Bildungseinrichtungen sowie zivilgesellschaftlichen Akteur:innen in Kontakt treten, um Strategien für einen partizipativen Wissenstransfer zu entwickeln.

Robert Queckenberg koordiniert am Zentrum für Wissenschaftsdidaktik der Ruhr-Universität Bochum das vom Ministerium für Kultur und Wissenschaft des Landes Nordrhein-Westfalen geförderte Konsortialprojekt KI:edu.nrw, das sich mit den Themen Learning Analytics und Künstliche Intelligenz in der Hochschulbildung beschäftigt und die Learning-AID-Tagung ausrichtet.

Jonas Leschke ist Leiter der Stabsstelle Strategische Lehrprojekte am Zentrum für Wissenschaftsdidaktik an der Ruhr-Universität Bochum. Dort verantwortet er verschiedene Projekte zu wissenschaftsdidaktischen Themen, wie bspw. Learning Analytics, Künstliche Intelligenz oder Lehrqualifizierung von Hochschulpersonal.

Malte Persike ist wissenschaftlicher Leiter am Center für Lehr- und Lernservices (CLS) der RWTH Aachen University. Er verantwortet und koordiniert das Forschungsprogramm des CLS und beschäftigt sich insbesondere mit der daten-gestützten Optimierung des Lehrens, Lernens und Prüfens.

Robert Queckenberg, Jonas Leschke, Malte Persike (Hg.)

Learning Analytics, Artificial Intelligence und Data Mining in der Hochschulbildung

Beiträge zur Learning AID 2024

[transcript]

Gefördert durch:

Ministerium für
Kultur und Wissenschaft
des Landes Nordrhein-Westfalen



Ein Kooperationsvorhaben empfohlen durch die:



INNOVATION DURCH KOOPERATION

Bibliografische Information der Deutschen Nationalbibliothek

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



Dieses Werk ist unter der Creative-Commons-Lizenz BY-SA 4.0 lizenziert. Für die ausformulierten Lizenzbedingungen besuchen Sie bitte die URL <https://creativecommons.org/licenses/by-sa/4.0/>.

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.

2025 © Robert Queckenberg, Jonas Leschke, Malte Persike (Hg.)

transcript Verlag | Hermannstraße 26 | D-33602 Bielefeld | live@transcript-verlag.de

Umschlagkonzept: Maria Arndt

Druck: Elanders Waiblingen GmbH, Waiblingen

<https://doi.org/10.14361/9783839475836>

Print-ISBN: 978-3-8376-7583-2 | PDF-ISBN: 978-3-8394-7583-6

Buchreihen-ISSN: 2943-4882 | Buchreihen-eISSN: 2943-4890

Gedruckt auf alterungsbeständigem Papier mit chlorfrei gebleichtem Zellstoff.

Inhalt

Editorial

Eine Fachtagung für Learning Analytics und Künstliche Intelligenz in der Hochschulbildung
Jonas Leschke, Robert Queckenberg und Malte Persike9

Keynotes

Mensch – Maschine – Kooperation

Wie wir für die Nutzung von Learning Analytics und generativer KI zusammenarbeiten können
Peter Salden, Malte Persike und Martin Mauve 19

Design, Development and Evaluation of Highly Informative Learning Analytics

Hendrik Drachsler 27

Learning Analytics

Learning Analytics in digitalen Selbstlernkursen

Roland Böttcher, Marina Rüter und Jonas Schug 51

Satzungen als taugliche Rechtsgrundlage für den Einsatz von Learning Analytics in Hochschulen

Gerrit Hornung und Hendrik Link 61

Die Interdependenz von Learning Analytics und Studierenden

Implikationen studentischer Wahrnehmungen für eine sozialverantwortliche
KI-Implementierung

Birte Keller, Marco Lünich und Frank Marcinkowski 73

Auf dem Weg zu Learning Analytics in der Praxis

Claudia Ruhland und Ummay Ubaida Shegupta 89

Ein wertesesibles Design für formatives Feedback mit Trusted Learning Analytics und KI

Heike Karolyi, Lars van Rijn, Michael Hanses und Claudia de Witt 101

Informierte Einwilligung für Learning Analytics

Gestaltung eines Informations- und Entscheidungsdialogs

Laura Platte, Kyra Thelen und Martin Breuer 111

Dashboards entschlüsseln

Workshopergebnisse zur Verbesserung von Learning Analytics Visualisierungen

Tabea Schwarz und Benjamin Ledel 119

Künstliche Intelligenz

KI auf dem Campus

Von der Empirie zur Strategie

Alexander Gerber und Torsten Niechoj 131

Studieren im Zeitalter von KI & Co

Welche Rolle spielen KI-gestützte Tools im Hinblick auf die Lernmotivation im
Studium – eine qualitative Analyse

Grit im Brahm, Steven Bauernfeind, Lucien Kemper und Matthias Kostrzewa 139

Künstliche Intelligenz in Studium und (tutorieller) Lehre

Ergebnisse einer bundesweiten Studie

Jenny Alice Rohde 147

Kritischer Umgang mit KI: Was heißt das und wie zeigt er sich in studentischen Reflexionen beim forschenden Lernen?	
Eine kulturwissenschaftliche Perspektive	
<i>Julius Voigt, Katrin Girgensohn, Jürgen Neyer, Benno Stein, Bernd Fröhlich, Matti Wiegmann, Magdalena Anna Wolska, Dora Kiesel, Patrick Riehmann, Irene López García, Mitja Sienknecht und Sassan Gholiagha</i>	157
Ein (KI-)Chatbot für ILIAS	
Perspektiven auf Conversational AI in der Beratung, Begleitung und dem Support in der Lehre	
<i>Beatrix Busse, Ingo Kleiber, Nadimo Staszak und Mark Kusserow</i>	169
GOALS: Ein Lern- und Übungssystem für Lehrveranstaltungen im Zeitalter generativer KI am Beispiel einer Einführungsveranstaltung der Informatik	
<i>Sven Jacobs, Marc Sauer und Andreas Hoffmann</i>	179
Die Integration generativer KI in die hochschulische Statistiklehre	
Eine Untersuchung zur Förderung affektiver und kognitiver Zielgrößen	
<i>Kim Méliani und Kristina Kögler</i>	191
Generative KI-Tools in der Lehrkräftebildung	
Themenschwerpunkte einer anwendungsorientierten Lehrveranstaltung	
<i>Johannes Schäfers</i>	201
Beyond AI literacy	
Universitäre transdisziplinäre KI-Ausbildung im Projekt BNTrAlnee	
<i>Elena Trunz, Matthias Carl Laupichler und Reinhard Klein</i>	211
HAWKI – vom Interface zu chatGPT zum KI-Ökosystem für Hochschulen	
<i>Stefan Wölwer und Vincent Timm</i>	221
Let's open the Toolkit	
Digitale Werkzeuge in der Hochschullehre	
<i>Caroline Berger-Konen, Jessica Felgentreu, Anika Limburg, Stefan Göllner und Sarah Habla</i>	229

Editorial

Eine Fachtagung für Learning Analytics und Künstliche Intelligenz in der Hochschulbildung

Jonas Leschke,¹ Robert Queckenberg² und Malte Persike³

Präambel

30.08.2022, 10:00 Uhr: Eine fachheterogene Gruppe von 140 Personen aus Lehre, Forschung, Hochschul- und Wissenschaftsdidaktiken, eLearning-Einrichtungen, zentralen und Fachstudienberatungen, Datenschutz und Ethik, Projekten, Hochschulleitung und Politik sitzt im Veranstaltungszentrum der Ruhr-Universität Bochum und sieht auf der Präsentationsfläche den Countdown auf 0 Minuten herunterlaufen – im selben Moment ertönt ein Gong: die erste Learning AID, eine Tagung über Learning Analytics, Artificial Intelligence und Data Mining in der Hochschulbildung, beginnt. Niemand weiß zu diesem Zeitpunkt, dass dies der Auftakt für eine Tagungsreihe ist, die sich innerhalb von drei Jahren als größte spezialisierte Fachtagung zu den Tagungsthemen im deutschsprachigen Raum etablieren wird.

Das Projekt KI:edu.nrw

Das Ziel des seit Ende 2020 vom Ministerium für Kultur und Wissenschaft des Landes Nordrhein-Westfalens für drei Jahre geförderten Projekts *KI:edu.nrw: Didaktik, Ethik und Technik von Learning Analytics und KI in der Hochschulbildung* war es, die praktischen, hochschulweiten Einsatzmöglichkeiten von Learning

1 ORCID-ID: 0000-0002-6343-117X

2 ORCID-ID: 0009-0006-5171-438X

3 ORCID-ID: 0000-0002-7825-089X

Analytics und KI in der Hochschulbildung zu sondieren (Salden et al., 2024). Exemplarisch wurde dafür die Ruhr-Universität Bochum betrachtet, die als große Volluniversität das Potenzial bot, allen Fallstricken bei der praktischen Einführung entsprechender Systeme zu begegnen. Einen dieser Fallstricke identifizierte Projektleiter Dr. Peter Salden bereits während der Antragsphase, indem es zum damaligen Zeitpunkt kein hochschulweit einsatzfähiges und für den deutschen Rechtsrahmen datenschutzkonformes Learning-Analytics-System auf dem Markt gab. Die RWTH Aachen hatte hierzu bereits wichtige Vorarbeiten im Land geleistet (Metzger/Bovermann, 2024), sodass diese, vertreten durch PD Dr. Malte Persike, als Entwicklungspartner für das Projekt angefragt wurde und gewonnen werden konnte.

Die Projektanlage von KI:edu.nrw gliederte sich anhand der folgenden drei Handlungsfelder:

- **Querschnittsbereiche:**

In diesem Handlungsfeld lagen alle Projektthemen, die eine unterstützende Funktion für die Hochschullehre und den Einsatz von Learning Analytics und KI einnehmen. Konkret meint dies die hochschuldidaktische Auseinandersetzung, Fragen des Datenschutzes und der Ethik, Möglichkeiten des Einsatzes in der Studienberatung und des Qualitätsmanagements, sowie die notwendigen technischen Voraussetzungen an Hochschulen.

- **Praxiserprobung:**

Die Projektarbeit sollte praxisorientiert erfolgen und nicht als konzeptionelle Forschungsarbeit. Entsprechend waren im Projekt lehrpraktische Auseinandersetzungen mit Learning Analytics und KI in unterschiedlichen Fachdisziplinen angelegt. Diese wurden durch die Querschnittsbereiche unterstützt und spiegelten die eigenen praktischen Erfahrungen an die Querschnittsbereiche zurück.

- **Dialog, Vernetzung und Transfer:**

KI:edu.nrw wurde zwar an der RUB und RWTH gefördert, verstand sich aber als Projekt für die Hochschulen in NRW, sodass bereits während der Projektlaufzeit regelmäßig der Dialog zu betroffenen Stakeholdern auch an allen anderen Hochschulen im Land gesucht und Vernetzung zu den Projektthemen durch unterschiedliche Formate angestoßen wurde.

Die Genese der Learning AID-Tagung

Bereits im Projektantrag wurde das Handlungsfeld »Dialog, Vernetzung und Transfer« angelegt, allerdings sollte dieses Handlungsfeld insbesondere durch den Austausch der jeweiligen Projektmitarbeitenden mit ihren jeweiligen eigenen Fachgesellschaften erfolgen. Beispielsweise sollte das Querschnittsprojekt Datenschutz den Austausch zwischen den Datenschutzbeauftragten im Land anstoßen oder das Teilprojekt der Studienberatung einen Dialog in der Fachgemeinschaft der Studienberatung moderieren.

Zusammen mit dem damaligen Projektkoordinator Jonas Leschke entwickelte Salden im Herbst 2021 zusätzlich die Idee eines Fachgemeinschaften-übergreifenden Austauschformats über die Projektthemen. Ziel war es, die positive Erfahrung aus der interdisziplinären Zusammenarbeit im Projekt, auch über das Projekt hinaus anzuregen. Unterstützt durch die Projektmitarbeitenden, insbesondere durch die Mitarbeiterin für Öffentlichkeitsarbeit im Projekt, Diana Meier-Haverkorn, entstand das Konzept für die erste Learning AID-Tagung. Das Akronym Learning AID, also Lernhilfe, beschreibt zugleich das Projektverständnis, dass digitale Lerntechnologien nicht zum Selbstzweck, sondern für einen echten Mehrwert eingesetzt werden sollen, und ergibt sich aus dem Langtitel der Tagung *Learning Analytics, Artificial Intelligence und Data Mining in der Hochschulbildung*.⁴

Handlungsleitend für das Tagungskonzept waren zwei Aspekte:

- Die Tagungsthemen sollten interdisziplinär betrachtet werden.
- Die Tagung sollte ausreichend Raum für Vernetzung und Dialog bieten.

Deshalb und da zum Zeitpunkt der Programmplanung nicht sicher war, wie viele Teilnehmende überhaupt an der Tagung teilnehmen würden, wurde die eintägige Agenda als eine Projekttagung geplant. Alle Sessions wurden gemeinsam von jeweils zwei Projektmitarbeitenden aus unterschiedlichen, aber thematisch nahen Teilprojekten von KI:edu.nrw konzipiert und moderiert. Für die zentralen Programmpunkte wurden teils projektexterne Expert*innen eingeladen. Genügend Pausen sollten die intensive Vernetzung der Teilnehmenden untereinander ermöglichen.

4 Das Akronym und da wir eine Tagung für den deutschsprachigen Raum anbieten wollen, sind die Gründe, wieso wir keinen ausschließlichen deutschen oder englischen Titel gewählt haben.

Neben der öffentlichen Bewerbung der Tagung wurde sie durch die Projektmitarbeitenden innerhalb der eigenen Fachcommunitys bekannt gemacht. Die Teilnahme an der Tagung war kostenfrei möglich.

All dies führte dazu, dass 140 Teilnehmende an der ersten Learning AID-Tagung teilnahmen. Und das zu einem Zeitpunkt, zu dem ChatGPT noch nicht medienwirksam auch für alle Hochschulangehörige veröffentlicht war.

Entwicklung zur größten spezialisierten Fachtagung

Die Evaluation der ersten Learning AID-Tagung war sehr positiv und zeigte, dass bei den Teilnehmenden ein großes Interesse und Bedarf an einem entsprechenden Forum besteht. Entsprechend wurde im Projekt zusammen mit dem Ministerium für Kultur und Wissenschaft des Landes Nordrhein-Westfalen entschieden, die Learning AID auch 2023 noch ein zweites Mal durchzuführen.

Früh in der Vorbereitung für die Learning AID 2023 wurde ChatGPT für alle zugänglich veröffentlicht. Das Thema Generative Künstliche Intelligenz (GKI) in der Hochschullehre erfuhr eine explosionsartige Aufmerksamkeit und das Interesse an der Learning AID nahm ebenfalls zu. Dies zeigte sich nicht nur daran, dass bereits einige Einreichungen aus Kapazitätsgründen abgelehnt werden mussten – die zweite Learning AID bot erstmalig einen öffentlichen Call for Submissions – auch die Tagung selbst war bereits nach der Hälfte des angedachten Anmeldezeitraums mit 230 Anmeldungen vollständig ausgebucht. Diese Entwicklung erforderte auch weitere personelle Unterstützung in der Tagungsvorbereitung und -durchführung durch Stephanie Merten und Jessica Dudde.

Durch die erneute Projektförderung von KI:edu.nrw für weitere drei Jahre konnte bei der Learning AID 2023 verkündet werden, dass es auch in den Jahren 2024 bis 2026 eine Learning AID-Tagung geben werde. Die Entwicklung der Tagung und die nun langfristige Entwicklungsperspektive ermöglichte es, für die Learning AID 2024 erstmalig die zentralen Akteure, Projekte und Institutionen zu den Themen Learning Analytics und KI in der Hochschulbildung in Deutschland als Partner*innen für die Tagung zu gewinnen. Robert Queckenberg als neue Projektkoordination des Projekts brachte zudem wichtige neue Impulse in die Tagung ein. Zeitgleich nahm das politische Interesse an der Tagung zu. So sagte die Wissenschaftsministerin des Landes Nordrhein-Westfalen für ein Grußwort zur dritten Learning AID zu und es fand eine po-

litische Podiumsdiskussion auch unter Beteiligung des Bundesministeriums für Bildung und Forschung statt. Unter anderem diese Entwicklungen führten dazu, dass sich die Anzahl der Einreichungen zwischen Learning AID 2023 und Learning AID 2024 mehr als verdoppelte und trotz deutlich erhöhter Kapazitäten die Tagung erneut frühzeitig mit 330 Anmeldungen ausgebucht war.

Der Wunsch nach Dokumentation

Aus den Rückmeldungen zur Learning AID 2023 von Teilnehmenden, aber auch von Nichtteilnehmenden, ergab sich bei der Learning AID 2024 eine weitere zentrale Neuerung in Form eines Tagungsbandes. Insbesondere Forschende und Projektmitarbeitende meldeten in den vergangenen Ausführungen zurück, dass sie Schwierigkeiten hätten, ihre Tagungsteilnahme zu begründen und abzurechnen, solange es über die Learning AID keinen wissenschaftlich verwertbaren Tagungsband gebe. Zudem wurde vielfach der Wunsch geäußert, die Tagung auch für Nichtteilnehmende zu dokumentieren und so die Diskussionen und Auseinandersetzungen während der Tagung für alle zugänglich zu machen. Auch diese Rückmeldung wurde für die Weiterentwicklung der Tagung aufgenommen, sodass im Rahmen der dritten Learning AID erstmalig der hier vorliegende Tagungsband entstanden ist.

Die Learning AID wird sich auch in den kommenden Jahren kontinuierlich weiterentwickeln, gestärkt durch neue Anregungen und Ideen aus der Durchführung und Evaluation der Learning AID 2024.

Die Learning AID 2024 – Ausblick in den Tagungsband

Für die Learning AID 2024 sind 82 Einreichungen für Impulsvorträge, Workshops, Poster und Demonstrationen eingegangen. Nach einem double-blind Peer-Review Verfahren konnten 56 der Einreichungen im Tagungsprogramm berücksichtigt werden. Für den vorliegenden Tagungsband konnten 18 der im Nachgang an die Tagung eingereichten Manuskripte zu Impulsvorträgen und Workshops sowie die beiden Keynotes der Tagung aufgenommen werden. Diese werden im Folgenden kurz vorgestellt.

Keynotes

Salden, Persike und Mauve arbeiten in ihrem Beitrag die Bedeutung des Faktors Mensch in der aktuellen Entwicklung um KI- und LA-Systeme heraus und beschreiben, wie im Projekt KI:edu.nrw versucht wird, genau diesen Faktor in den Mittelpunkt zu stellen.

Drachsler diskutiert bezugnehmend auf vielfältige eigene Forschungsergebnisse im Bereich von Trusted Learning Analytics und hochinformativem Feedback, die Bedeutung von didaktisch fundierten und empirisch überprüften technischen Entwicklungen, um durch deren Einsatz einen positiven Einfluss auf den Lernerfolg zu nehmen.

Learning Analytics

Böttcher, Rüter und Schug präsentieren in ihrem Beitrag praktische Möglichkeiten und Ergebnisse, wie Lehrende durch Moodle-integriertes Learning Analytics Risikogruppen sowie problematische Lernaufgaben identifizieren können, um dadurch die Dropout-Rate in digitalen Selbstlernkursen zu reduzieren.

Hornung und Link untersuchen verschiedene Hochschulgesetze dahingehend, inwiefern sie die Möglichkeit von eigenen Learning Analytics-Satzungen eröffnen und erkennen dabei einen Handlungsbedarf in einigen Bundesländern, um den didaktischen Einsatz entsprechender Anwendungen an den Hochschulen zu ermöglichen.

Keller, Lünich und Marcinkowski geben einen Überblick über fünf Jahre Forschung zur studentischen Wahrnehmung von KI an deutschen Hochschulen und resümieren daraus die Implikationen für einen gegenüber Studierenden sozialverantwortlichen Einsatz von KI und LA an deutschen Hochschulen.

Ruhland und Shegupta stellen in ihrem Beitrag die Entwicklung eines Kurskonzepts entlang des Design-Based-Research-Ansatzes dar, dessen Inhalte Lehrenden den reflektierten Einsatz von Learning Analytics in ihren eigenen Kursen ermöglicht.

Karolyi, van Rijn, Hanses und de Witt beschreiben einen Ansatz, wie mit Large-Language-Modellen hochinformatives Feedback für den vertrauenswürdigen Einsatz von Learning Analytics ermöglicht werden kann.

Platte, Thelen und Breuer stellen vier Gestaltungsperspektiven für die informierte Einwilligung von Studierenden für die Verarbeitung personenbezogener

gener Daten im Kontext von Learning Analytics am Beispiel der Software POLARIS vor.

Auch Schwarz und Ledel behandeln in ihrem Beitrag Gestaltungsmöglichkeiten in Learning-Analytics-Produkten, zur niedrigschwelligen Nachvollziehbarkeit von Learning-Analytics-Ergebnissen in Dashboards, um die Anforderung an Data Literacy und AI Literacy der Nutzenden gering zu halten.

Künstliche Intelligenz

Gerber und Niechoj stellen Studienergebnisse einer quantitativen Befragung von Studierenden und Mitarbeitenden der Hochschule Rhein-Waal zu Einstellungen, Erwartungen, Nutzung und Bedenken in Bezug auf Künstliche Intelligenz dar und vergleichen die Ergebnisse der beiden Gruppen miteinander.

Im Brahm, Bauernfeind, Kemper und Kostrzewa präsentieren in ihrem Beitrag ebenfalls Studienergebnisse, aus einer qualitativen Studierendenbefragung an der Ruhr-Universität Bochum zur Nutzung von KI-basierten Anwendungen, und ziehen daraus Schlussfolgerungen für das Hochschulstudium.

Rhode ergänzt die vorherigen Studien mit einer bundesweiten Tutor*innen-Befragung an 28 deutschen Hochschulen zum Einsatz von KI in Studium und tutorieller Lehre und befragt damit eine Gruppe, die sowohl die Rolle der Lernenden als auch die der Lehrenden einnehmen und miteinander vergleichen kann.

Voigt und Kolleg*innen nehmen in ihrem Beitrag eine kulturwissenschaftliche Perspektive auf den kritischen Umgang mit KI beim forschenden Lernen ein und analysieren hierfür wöchentliche Reflexionstexte von Studierenden über den Einsatz von KI in einem Seminarkontext.

Busse, Kleiber, Staszak und Kusserow stellen die Entwicklung eines in ILLIAS integrierten Chatbots vor, der regelbasierte Dialogführungen sowie in ILLIAS vorhandene Kontextinformationen, bei der Verarbeitung von Anfragen berücksichtigt und reflektieren diese Möglichkeit als Unterstützung für Lehrende und Lernende.

Jacobs, Sauer und Hoffmann stellen mit GOALS eine Softwarelösung für individuelle Lernwege innerhalb von Lehrveranstaltungen am Beispiel einer Einführungsveranstaltung für Informatik dar, die durch die Integration von Large Language Models zudem ein unmittelbares, formatives Feedback auf die Lösungen gibt.

Méliani und Kögler adressieren in ihrem Beitrag das Problem des defizitären Fähigkeitsselbstkonzepts von Studierenden am Beispiel der hochschulischen Statistiklehre und untersuchen, inwiefern die Möglichkeit der Nutzung von ChatGPT die affektive und kognitive Dimension des Selbstkonzepts beeinflusst.

Schäfers stellt ein Seminarkonzept zur Förderung des kompetenten Einsatzes von und der reflektierten Auseinandersetzung von Lehramtsstudierenden mit KI in der Schule und dessen Themenschwerpunkte dar und präsentiert Evaluationsergebnisse der Durchführung.

Trunz, Laupichler und Klein stellen das Projekt BNTrAInee vor, in dem Informatikstudierende informatische Probleme aus dem Bereich der KI-Anwendungen für Forschende aus anderen Disziplinen kooperativ mit diesen lösen, und berichten von Evaluationsergebnissen und Praxiserfahrungen.

Wölwer und Timm präsentieren in ihrem Beitrag die Open Source-Plattform HAWKI, die bundesweit an einer Vielzahl von Hochschulen den datenschutzfreundlichen Zugang zu generativen Modellen ermöglicht.

Berger-Konen, Felgentreu, Limburg, Göllner und Habla fassen die Ergebnisse ihres World-Cafés auf der Learning AID-Tagung zusammen und beschreiben darin, welche generativen KI-Anwendungen in der Praxis eingesetzt werden, vor welchen Herausforderungen Hochschulen und Lehrende bei der Dissemination entsprechender Anwendungen stehen und inwiefern digitale Selbstlernangebote dabei unterstützen können.

Literatur

- Metzger, Christian/Bovermann, Martin (2024): »KI:edu.nrw – eine Betrachtung aus der Perspektive des Teilprojektes Technik«, in: Peter Salden/Jonas Leschke (Hg.), *Learning Analytics und Künstliche Intelligenz in Studium und Lehre. Erfahrungen und Schlussfolgerungen aus einer hochschulweiten Erprobung*. Wiesbaden: Springer Fachmedien, S. 109–126. https://doi.org/10.1007/978-3-658-42993-5_7
- Salden, Peter/Leschke, Jonas/Persike, Malte (2024): »Das Projekt KI:edu.nrw – Rückblick für einen Ausblick«, in: Peter Salden/Jonas Leschke (Hg.), *Learning Analytics und Künstliche Intelligenz in Studium und Lehre. Erfahrungen und Schlussfolgerungen aus einer hochschulweiten Erprobung*. Wiesbaden: Springer Fachmedien, S. 3–24. https://doi.org/10.1007/978-3-658-42993-5_1

Keynotes

Mensch – Maschine – Kooperation

Wie wir für die Nutzung von Learning Analytics und generativer KI zusammenarbeiten können

Peter Salden, Malte Persike und Martin Mauve

Der Text stellt den Menschen als entscheidenden Faktor der aktuellen technischen Entwicklungen in den Mittelpunkt – sowohl als Gestalter von KI- und Learning Analytics-Systemen als auch als deren Adressaten. Der Text fragt danach, was Menschen heute über derartige Systeme lernen sollten (Was-Frage) und wie die Systeme eingesetzt werden können, um Lernprozesse zu unterstützen (Wie-Frage). Beschrieben wird am Beispiel des umfangreichen, hochschulübergreifenden Projekts KI:edu.nrw, wie ganz konkret derzeit in Nordrhein-Westfalen an den Themen Learning Analytics und generative KI gearbeitet wird. Zum Abschluss wird dabei auch näher auf hochschulübergreifende (und auch bundeslandübergreifende) Kooperationsmöglichkeiten eingegangen.

Human – Machine – Cooperation: How we can work together to use learning analytics and generative AI

The text focuses on humans as the decisive factor in current technical developments – both as designers of AI and learning analytics systems and as their addressees. The text asks what people should learn about such systems today and how the systems can be used to support learning processes. Using the example of the extensive cross-university project KI:edu.nrw, it describes how work on the topics of learning analytics and generative AI is currently being carried out in the German federal state of North Rhine-Westphalia. Finally, it also takes a closer look at cross-state cooperation opportunities.

Einleitung: Faktor Mensch

Mit der Learning AID-Tagung in Bochum besteht seit dem Jahr 2022 ein deutschlandweites Forum zum Austausch über Künstliche Intelligenz (KI) und Learning Analytics (LA) in der Hochschulbildung. Die Idee der Tagung: Einmal jährlich sollen all diejenigen, die in diesem Themenkreis arbeiten, miteinander persönlich – nicht virtuell! – in den Austausch treten. Die Tagung soll sowohl diejenigen anziehen, die wegweisende Impulse für die Thematik geben, als auch diejenigen, die an entscheidenden Positionen sitzen, und nicht zuletzt auch all jene, die mit der Umsetzung von Vorhaben im Bereich KI und LA in der Lehre zu tun haben. Wichtig für die Tagung sind auch die Partnerinstitutionen: Dazu gehörten im Jahr 2024 das Ministerium für Kultur und Wissenschaft des Landes Nordrhein-Westfalen, das Bundesministerium für Bildung und Forschung, die Stiftung Innovation in der Hochschullehre, das Hochschulforum Digitalisierung, der KI-Campus, das Virtuelle Kompetenzzentrum KI und Wissenschaftliches Arbeiten, e-teaching.org sowie VDI/VDE IT. Auch sie sind auf der Tagung präsent, häufig durch ihr Führungspersonal. Das ist wichtig, denn auch Institutionen sind keine anonymen Gebilde, sondern werden von Menschen getragen.

Der Austausch all dieser Menschen ist für die Weiterarbeit an den Themen KI und LA von enormer Bedeutung. Denn technische Systeme gestalten sich nicht selbst, sondern werden *von Menschen* gestaltet. Menschen sind es, die Sprachmodelle programmieren, Menschen programmieren Learning Analytics-Software. Dies verweist sowohl auf unseren Einfluss als auch auf unsere Verantwortung als diejenigen, die LA und KI-Einsatz im deutschsprachigen Raum gestalten.

Dabei ist stets zu bedenken, dass auch die Adressatinnen und Adressaten dieser Systeme Menschen sind. Natürlich geht es bei KI und LA-Systemen um Software, um Technik, sozusagen um Maschinen. Doch sind diese nur Vehikel, die letztendlich Menschen dienen sollen. Konkret geht es hier um Menschen, die *lernen*, und die Frage, wie man sie dabei unterstützen kann.

Schaut man auf Lernende und ihr Verhältnis zu den Themen KI und LA, so sind vor allem zwei Fragen relevant:

- die Was-Frage: Was sollen Menschen inhaltlich lernen, was sind unsere Bildungsziele? Was soll man über KI lernen, was soll aber auch unabhängig von KI gelernt werden? Welche Kompetenzen zum Umgang mit Daten sollen erworben werden?

- die Wie-Frage: Wie können Menschen beim Lernen unterstützt werden? Wie müssen wir KI und LA einsetzen, damit sie im Lernprozess eine Hilfe sein können? Und inwieweit macht der Einsatz von KI und LA überhaupt Sinn, wann soll er bewusst unterbleiben?

Der Mensch ist also der entscheidende Faktor: als Gestalter, aber auch als Adressat von KI und LA. In unserer Keynote schauen wir darauf, wie im nordrhein-westfälischen Landesprojekt KI:edu.nrw Lehre und Lernen mit Hilfe von generativer KI und LA gestaltet werden, wie Menschen dabei als Adressaten verstanden werden – und wie wir durch Zusammenarbeit die entstehenden Herausforderungen zu bewältigen versuchen.

Learning Analytics

In dem von uns – den Autoren – verantworteten Projekt KI:edu.nrw ist LA eines der zwei Schwerpunktthemen. Bei LA steht die »Wie«-Frage, d.h. wie Lernen durch Datenanalysen unterstützt werden kann, zumindest auf den ersten Blick im Vordergrund. Ausgangspunkt der Beschäftigung mit diesem Thema in KI:edu.nrw war im Jahr 2020 die Idee, durch die Analyse studentischer Lerndaten den Lernstand von Studierenden erkennen zu können. Ausgehend von dieser Zustandsbeschreibung soll dann Reflexion und individuelle Lernunterstützung möglich werden.

Wie im Jahr 2020, so ist auch heute noch zu konstatieren, dass der Einsatz von LA in Hochschulen nur zögerlich vorangeht. Zwar gibt es zahlreiche hierauf gerichtete Forschungsprojekte und auch erste Beispiele für Systeme, die für den Regelbetrieb konzipiert wurden (z.B. LerSys der HTWK Leipzig und LAPS der Hochschule der Medien Stuttgart). Dennoch sind vor dem regelhaften Einsatz in der Breite der Hochschullandschaft noch Herausforderungen zu meistern, die unter anderem auch in KI:edu.nrw bearbeitet werden.

Dies betrifft zunächst die Technik: KI:edu.nrw arbeitet eine Open Source Softwareplattform namens »Provider-Oriented Learning Analytics Infrastructure« (POLARIS) aus, die hochschulweit Daten aus unterschiedlichen Quellen zusammenführt und die algorithmische Analyse der Daten ermöglicht. In der Entwicklung liegt ein besonderer Fokus auf Datenschutz, Datensouveränität und Datensicherheit, die u.a. mit Hilfe eines detaillierten Zustimmungs- und Berechtigungs-Managements umgesetzt werden.

Neben der Technik ist aber auch die Ausarbeitung eines belastbaren rechtlichen Rahmens ein Schwerpunkt des Projekts. Wegweisend war hierfür die Veröffentlichung des von KI:edu.nrw beauftragten Gutachtens »Datenschutzrechtliche Beurteilung von Learning Analytics an Hochschulen in NRW«. Das Gutachten hat vor dem Hintergrund der nordrhein-westfälischen Rechtslage aufgearbeitet, dass Learning Analytics durchaus rechtskonform durchgeführt werden können, dafür aber sowohl hochschuleigene Rechtssätze als auch klare Regelungen im Hochschulgesetz erforderlich sind. Als Konsequenz des Gutachtens befindet sich eine Anpassung des nordrhein-westfälischen Hochschulgesetzes derzeit (Frühjahr 2025) in Vorbereitung. Auch über Nordrhein-Westfalen hinaus hat die Gutachten Impulse gesetzt und wurde inzwischen durch weitere Rechtsgutachten aus anderen Bundesländern (Hessen und Berlin) ergänzt, die auf dem KI:edu.nrw-Gutachten aufbauen.

Kann eine technische Lösung erarbeitet werden und ist der rechtskonforme Einsatz abgesichert, wird die Realisierung unterschiedlicher Szenarien möglich. Beispiele sind die verbesserte Planung von Studienverläufen, Unterstützung bei der Prüfungsvorbereitung (z. B. durch individuelle Vorbereitungsaufgaben) sowie begleitendes Feedback. Von Interesse ist dabei auch die Verbindung von LA und Generativer KI, beispielsweise indem auf Grundlage von Daten zum Lernstand individuelles Lernmaterial erzeugt wird.

Die Reflexion über die Rolle des Menschen mit Blick auf LA-Systeme findet in der Entwicklung von LA auf unterschiedlichen Ebenen statt. So gilt es beispielsweise aus didaktischer Perspektive, das Wissen über erfolgreiche Gestaltung von Feedback sinnvoll in der LA-Software abzubilden bzw. in die Gestaltung der Lehr-Lernprozesse, für welche die Software genutzt wird, einzu beziehen. Aus einer ethischen Perspektive ist beispielsweise zu bedenken, welche kritischen Effekte ein auf umfangreichen personenbezogenen Daten basierendes System haben kann – sei es aufgrund von Zweckentfremdung dieser Daten oder aufgrund von Fehlschlüssen, die Nutzerinnen und Nutzer aus Datenanalysen ziehen. Sowohl zu didaktischen als auch zu ethischen Fragen gibt es in KI:edu.nrw Teilprojekte.

Diese nicht-technischen Aspekte sind keineswegs Nebensachen. Im Gegenteil ist denkbar, dass sich technische und rechtliche Fragen für den Betrieb eines LA-Systems final klären lassen, wohingegen der Aufbau der nötigen Digital- und Datenkompetenzen bei den das System nutzenden Studierenden und Lehrenden als eine dauerhafte Begleitaufgabe gedacht werden muss.

Generative KI

Stand KI bis zum Jahr 2022 noch im Schatten von LA, ist das Thema generative KI seitdem klar in den Vordergrund getreten.

Die Fragen und Herausforderungen lassen sich dabei grundsätzlich analog zu LA beschreiben. Auch bei generativer KI stellen sich technische und rechtliche Fragen – beispielsweise nach dem Zugang von Hochschulangehörigen zu kommerziellen oder nicht-kommerziellen KI-Diensten. Aus Perspektive digitaler Souveränität ist von hohem Interesse, frei zugängliche Open Source-Sprachmodelle für Hochschulen nutzbar zu machen und hierauf beispielsweise auch Anwendungen aufzubauen, die speziell für den Einsatz in Studium und Lehre konzipiert wurden.

Auch hier gilt es aber, die technische Entwicklung rechtlich abzusichern. Die relevanten Fragen betreffen dabei unterschiedliche Rechtsgebiete. Wegweisend für den deutschen Hochschulraum war das von KI:edu.nrw beauftragte Rechtsgutachten, das im Jahr 2023 veröffentlicht wurde. Neue Fragen sind seitdem beispielsweise aufgrund der Verabschiedung der KI-Verordnung der Europäischen Union entstanden. Sie erfordert insbesondere, dass Hochschulen als Betreiberinnen oder Anbieterinnen von KI-Systemen umfangreiche Schulungs-, Transparenz- und Schutzpflichten wahrnehmen.

Technische und rechtliche Klärungen vorausgesetzt, kann generative KI schon jetzt Lehre und Lernen unterstützen. KI-Systeme können beispielsweise Studierende fördern, indem sie für die Erstellung individueller Aufgaben genutzt werden oder als Dialogpartner bei der Entwicklung eigener Gedanken helfen. Studierende haben schnell bemerkt, dass die Tools ihnen bei der Ausarbeitung wissenschaftlicher Texte große Hilfen sein können. Andersherum helfen die Tools auch Lehrenden, beispielsweise bei der Erstellung von Lehrmaterial. Ganz besonders beschäftigt sowohl Lehrende als auch Studierende die Frage, was generative KI für Prüfungen bedeutet.

Die Reflexion über Einsatzmöglichkeiten generativer KI in Studium und Lehre führt erneut zu der Frage, wie sowohl Lehrende als auch Studierende einen kompetenten Einsatz der Tools lernen können. In KI:edu.nrw zielt ein Teilvorhaben ausdrücklich auf dieses Thema, indem Online-Selbstlernmaterial zu Begrifflichkeiten, Methoden und Verfahren Künstlicher Intelligenz, aber beispielsweise auch zu Grundwissen über Datenverarbeitung sowie wichtigen ethischen und rechtlichen Konzepten erstellt wird. Entsprechendes Material soll für Lehrende verfügbar gemacht werden.

Zusammenarbeit

Als Verantwortliche für das Projekt KI:edu.nrw leitet uns sowohl eine Faszination als auch eine kritische Haltung im Hinblick auf den Einsatz von LA und KI. Vor allem aber leitet uns die Überzeugung, dass der Mensch aus allen Perspektiven im Mittelpunkt unserer Projektarbeit stehen muss. Dieses Denken führt auch zu der Überzeugung, dass menschliche Kooperation zur Erschließung der Projektthemen der beste Weg ist.

Denn egal bei welchem Thema: Fest steht, dass Hochschulen aufgrund der enormen Dynamik – und der begrenzten Ressourcen – auf Zusammenarbeit angewiesen sind. Dies beginnt in den einzelnen Hochschulen, wo KI oder LA nicht allein ein Thema des Rechenzentrums oder des Justizariats ist, sondern ein Querschnittsthema, für das auf allen Ebenen Hand in Hand gearbeitet werden muss – angefangen in der IT über didaktisches Zentrum, Justizariat, Datenschutzbeauftragte und Qualitätsmanagement bis hin zu Fakultäten, Hochschulleitung und Gremien.

Aus Perspektive eines Landesprojekts wie KI:edu.nrw ist über die einzelne Hochschule hinaus die hochschulübergreifende Zusammenarbeit ein wichtiger Ansatzpunkt. Das Projekt adressiert dies auf unterschiedlichen Ebenen durch eine Vielzahl von Aktivitäten. Dazu gehören:

- **Allgemeiner Informationsaustausch:** Mit dem »KI-Update NRW« organisiert KI:edu.nrw monatlich ein Online-Treffen der NRW-Hochschulen, in dem alle Interessierten Informationen über neue Entwicklungen im Land erhalten und ihre eigenen Informationen teilen können. Zusätzlich zum allgemein offenen KI-Update informiert KI:edu.nrw ausgewählte Gremien einzeln über neue Entwicklungen – so insbesondere die Gremien, in denen sich Hochschulleitungen hochschulübergreifend über Fragen von Studium und Lehre austauschen.
- **Sachbezogene Vernetzung:** KI:edu.nrw organisiert zudem die Vernetzung spezieller Fachgemeinschaften, die für ihre jeweils spezifischen Handlungsfelder aktuelle Fragestellungen mit Blick auf KI und LA reflektieren und bearbeiten. Beispiele sind Veranstaltungen für Rechenzentren, Datenschutzbeauftragte, Rechtsexpert:innen oder Vertreter:innen der Hochschuldidaktik.
- **Forschung-Praxis-Transfer:** Eine wichtige Annahme ist für das Projekt, dass ein Dialog von Forschung und Praxis von beiderseitigem Interesse ist. Denn Forschende zu KI und LA in der Hochschulbildung arbeiten oft mit

starkem Praxisbezug, während andersherum Praktiker:innen für die richtige Ausrichtung ihrer Entscheidung auf Erkenntnisse aus der Forschung angewiesen sind. Die jährlichen KI-Vernetzungstreffen von Forschungs- und Praxisprojekten von KI:edu.nrw sind daher inzwischen ein etabliertes Format der nordrhein-westfälischen KI-Landschaft.

- **Konferenzen:** Anlassbezogen richtet KI:edu.nrw immer wieder größere Veranstaltungen zu aktuellen Fragen aus, wie beispielsweise Symposien zur technischen Bereitstellung generativer KI, zu KI und Prüfungen sowie zu Rechtsfragen bzgl. generativer KI. »Flaggschiff« dieser Veranstaltungen ist die jährliche Learning AID-Tagung, die als deutschlandweiter »KI-Gipfel« angelegt ist.

KI:edu.nrw ist ein Landesprojekt und zielt mit seinen Aktivitäten in erster Linie auf die Vernetzung der Hochschulen im Land Nordrhein-Westfalen. Allerdings hat die Projektarbeit schnell gezeigt, dass die Zusammenarbeit bei den Themen LA und KI auch über Landesgrenzen hinweg sinnvoll ist.

Ein Beispiel dafür ist das Angebot von Schulungsveranstaltungen zu generativer KI in der Lehre: Hier besteht letztlich in allen Bundesländern ähnlicher Bedarf. KI:edu.nrw hat sich deswegen von Beginn an Vernetzungsaktivitäten der Landeseinrichtungen für digitale Hochschullehre angeschlossen, die beispielsweise zur Durchführung bundesweit geöffneter und gemeinsam beworbener Online-Schulungen für Lehrende führten. Andere Beispiele sind die Zusammenarbeit bei Rechtsfragen und die Bereitstellung von Open Source-KI.

Schluss

Besonders das Thema KI hat die Hochschulen über den Zeitraum der vergangenen zwei Jahre in seiner Intensität häufig unvorbereitet getroffen. Insgesamt zeigen aber die Beispiele sowohl zu KI als auch zu LA, dass durch Zusammenarbeit – hochschulintern, bundeslandweit und bundeslandübergreifend – Synergien entstehen, die durchaus auch kurzfristig bei der Lösung der Herausforderungen eine große Hilfe sein können. Mit diesem Optimismus schauen wir auf die Zusammenarbeit in unserem Projekt KI:edu.nrw ebenso wie auf die Vernetzung, die sich beispielsweise auch aus der Learning AID-Tagung jedes Jahr aufs Neue ergibt.

Design, Development and Evaluation of Highly Informative Learning Analytics

Hendrik Drachsler

Dieser Beitrag ist eine Zusammenfassung der Keynote von Hendrik Drachsler auf der Learning AID 2024 in Bochum. Die Keynote beleuchtet die Entwicklung des Forschungsprogramms von Trusted Learning Analytics (TLA) hin zu Highly Informative Learning Analytics (HILA) des EduTec.science Forschungsverbundes und diskutiert die zentrale Frage, wie KI-gestützte Learning Analytics sinnvoll in Bildungsprozesse integriert werden können. Obwohl KI und Learning Analytics großes Potenzial zur Verbesserung von Lehr- und Lernpraktiken bieten, hängt ihr Erfolg maßgeblich davon ab, wie sie gestaltet, getestet und weiterentwickelt werden. Entscheidend sind dabei: Kontext-spezifische Anwendungen, die sich an realen Bildungsanforderungen orientieren, empirische Validierung, um nachweislich wirksame Interventionen zu identifizieren und die Berücksichtigung der Bedürfnisse der Lernenden, um adaptives und nachhaltiges Lernen zu ermöglichen. Die Keynote argumentiert, dass der technologische Fortschritt allein nicht ausreicht – nur durch eine didaktisch fundierte und empirisch überprüfte Nutzung können KI-gestützte Learning Analytics tatsächlich zur Verbesserung der Bildung beitragen. Die Folien zur Keynote sind auf unserem Forschungsblog verfügbar: <https://edutec.science/keynote-at-learningaid-bochum-germany/>

Design, Development and Evaluation of Highly Informative Learning Analytics

This article is a summary of Hendrik Drachsler's keynote speech at Learning AID 2024 in Bochum. The keynote highlights the development of the research program from Trusted Learning Analytics (TLA) to Highly Informative Learning Analytics (HILA) of the EduTec.science research network and discusses the central question of how AI-supported learning analytics can be meaningfully integrated into educational processes. Although AI and learning analytics offer great potential for improving teaching and learning practices, their success depends largely on how they are designed, tested and further developed. Crucial here are Context-specific applications that are geared towards

real educational requirements, empirical validation to identify demonstrably effective interventions and consideration of learners' needs to enable adaptive and sustainable learning. The keynote argues that technological progress alone is not enough – only through didactically sound and empirically validated use can AI-supported learning analytics actually contribute to improving education. The keynote slides are available on our research blog: <https://edutec.science/keynote-at-learningaid-bochum-germany/>

Von Trusted Learning Analytics (TLA) zu hochinformativen Learning Analytics (HILA)

Der Ursprung von Learning Analytics (LA) liegt in der Vision, den Prozess des Lernens zu untersuchen, indem die in digitalen Lernumgebungen hinterlassenen Daten der Lernenden analysiert werden. Durch das Verfolgen dieser digitalen Spuren in Datenbanken soll ein besseres Verständnis von Lernverhalten und Lernprozessen ermöglicht werden. Ein wesentlicher Unterschied zu traditionellen Prüfungen besteht darin, dass LA kontinuierliche Daten aus realen Lernaktivitäten nutzt, anstatt nur punktuelle Leistungsnachweise zu erheben. Dies lässt die gewonnenen Informationen authentischer erscheinen, da sie das tatsächliche Verhalten der Lernenden widerspiegeln. Allerdings wurden die in digitalen Systemen gespeicherten Daten ursprünglich nicht mit der Absicht erfasst, Lernende in ihrem Lernprozess zu unterstützen. Vielmehr dienen sie primär der Systemfunktionalität, indem sie Statusinformationen und Ereignisse für die Softwareverwaltung speichern. Trotz dieser Einschränkungen herrschte in den frühen Jahren der LA-Forschung eine optimistische Erwartungshaltung, dass LA das Potenzial habe, herkömmliche Prüfungen zu ersetzen. Die Hoffnung war, dass der Lernerfolg durch die Analyse von Prozessdaten zuverlässig vorhergesagt werden könne (Greller & Drachler, 2012). Die damit verbundene umfassende Verarbeitung von Prozessdaten machte jedoch früh die Notwendigkeit eines starken Datenschutzes und einer klaren Datensouveränität deutlich. Dies führte zur Entwicklung des Konzepts der Trusted Learning Analytics (TLA), das den Schutz persönlicher Daten und transparente Nutzungskonzepte in den Fokus rückte. Für eine verantwortungsvolle Implementierung von TLA sind daher nicht nur technische Sicherheitsmaßnahmen erforderlich, sondern auch klare Kommunikationsstrategien, die Lernende darüber aufklären, wie ihre Daten verwendet werden und welchen konkreten Mehrwert sie für den Lernprozess bieten. Ein weiterer zentraler Aspekt ist die Einbindung aller relevanten Akteure in die

Entwicklung und Erforschung von TLA-Anwendungen. Neben Entwicklern und Bildungseinrichtungen sollten auch datenschutzrechtliche Expert:innen sowie Studierende aktiv in den Gestaltungsprozess eingebunden werden. Langfristige Begleitforschung ist notwendig, um die Auswirkungen und Potenziale von TLA wissenschaftlich zu evaluieren. Letztlich verfolgt TLA das Ziel, eine Balance zwischen der Nutzung von LA zur individuellen Unterstützung von Lernenden und dem Schutz ihrer persönlichen Daten zu finden. Nur durch diese Ausgewogenheit kann eine nachhaltige und verantwortungsvolle Integration von LA in Bildungssysteme sichergestellt werden.

Das TLA-Konzept von 2012 wurde in den folgenden Jahren intensiv beforscht und hat in sozialer, technischer und didaktischer Hinsicht erhebliche Fortschritte verbuchen können. In der sozialen Dimension wurden ethische Leitlinien (Drachler & Greller, 2016; Hansen et al., 2020), institutionelle Richtlinien (Scheffel et al., 2019), empirische Studien mit Bildungsakteuren (Jivet et al., 2020; Kollom et al., 2021; Wollny et al., 2023) und Instrumente (Tsai et al., 2018) für die ethische Nutzung von TLA entwickelt.

Auf der technischen Ebene wurden Infrastrukturen (Biedermann, Ciordas-Hertel, et al., 2023; Ciordas-Hertel et al., 2020; Ciordas-Hertel et al., 2019; Karademir et al., 2021; Wollny et al., 2021) zur Sammlung, Verarbeitung und Analyse von Daten entwickelt und eingesetzt. Auf der Grundlage dieser Ergebnisse wurde eine ausgereifte Dateninfrastruktur geschaffen, die die Tür für umfassendere empirische Studien über die Auswirkungen von TLA öffnet.

Im verschiedenen Bildungsbereich von Schule bis Hochschule wurden mehrere Feldstudien durchgeführt, um herauszufinden, wie sich Daten aus der TLA-Forschung auf die Anwendung durch Lehrkräfte auswirken (Kollom et al., 2021) und welchen Einfluss datengesteuerte Feedback-Modelle auf Lernende haben (Di Mitri et al., 2021; Jivet et al., 2020).

Das Highly-Informative Learning Analytics (HILA) Forschungsprogramm des Edutec.Science Forschungsverbundes¹ teilt diese Ambitionen mit anderen Forschungsgruppen, die die Ergebnisse der LA-Forschung des letzten Jahrzehnts aufarbeiten, um praktische Auswirkungen auf das Lehren und Lernen von heute zu erzielen. Basierend auf den Erkenntnissen aus dem TLA-Forschungsprogramm wurden drei Schwerpunktbereiche für das aktuelle Forschungsprogramm zu HILA definiert, die im Folgenden vorgestellt werden.

1 www.edutec.science

Fokussierung auf die Mikroebene von Lehren und Lernen

Im Bereich LA wird wiederholt darauf hingewiesen, dass LA in den Bildungswissenschaften verankert sein sollte (Greller & Drachsler, 2012; Gašević et al., 2015; Motz et al., 2022). Gasevic et al. (2015) verweisen daher auf andere etablierte Fachgesellschaften wie die Informationssuche, die bereits ein hohes Stadium wissenschaftlicher Reife erreicht haben: »As a developing field in information seeking, Wilson (1999, p. 250) noted that ›many things were counted, from the number of visits to libraries, to the number of personal subscriptions to journals and the number of items cited in papers. Very little of this counting revealed insights of value for the development of theory or, indeed, of practice. Significant progress in research and practice only really commenced when information seeking was framed within robust theoretical models of human behaviour« (Wilson, 1999, p. 250)« Gasevic et al. (2015, S. 6).

Ebenso schlussfolgern (Jivet et al., 2017, 2018) dass der Fokus im Bereich LA stärker auf das Learning als auf die Analytics gelegt werden sollte. Eine einseitige Konzentration auf den analytischen Aspekt führt häufig dazu, dass ausschließlich leicht verfügbare Daten aus Logdateien genutzt werden, anstatt gezielt sinnvolle und reichhaltige Datensätze zu generieren, die die tatsächlichen Lernziele und die Kompetenzentwicklung von Lernenden unterstützen. Diese Problematik wird auch von Motz et al. (2022) bestätigt. In einer umfassenden Analyse von Forschungspublikationen aus den Tagungsbänden zweier aktueller LAK-Konferenzen stellten sie fest, dass 70,5 % der Beiträge kein Instrument zur Messung des Lernerfolgs bereitstellen und 91,4 % keine pädagogische Intervention auf der Grundlage von Analytics beinhalten. Die Autoren kommen zu dem Schluss, dass es innerhalb der LA-Community derzeit an einer klaren methodischen Ausrichtung zur Messung des Lernerfolgs mangelt.

Das HILA-Forschungsprogramm zielt darauf ab, die oben benannten Lücken in der LA-Forschung zu schließen, indem es den Fokus auf die Bereitstellung hochinformativen Feedbacks für Lernende und insbesondere für Lehrkräfte legt. Im Gegensatz zu vielen bisherigen Ansätzen, die sich auf die Meso- und Makroebene konzentrieren, rückt HILA gezielt die Mikroebene von LA in den Mittelpunkt (Greller & Drachsler, 2012). Ziel ist es, Lehrkräfte und Lernende effektiv, effizient und wirkungsvoll zu unterstützen. Dieser Fokus ist besonders relevant, da viele Bildungssysteme weltweit durch einen akuten Lehrkräftemangel unter starkem Druck stehen. Hier kann der gezielte Einsatz von HILA eine Entlastung bieten, indem bestimmte Aufgaben, wie die Bewertung und das Geben von Feedback, durch maschinelles Lernen effizienter gestaltet

werden. Dies ermöglicht Lehrkräften, ihre begrenzten Ressourcen stärker auf die Gestaltung einer abwechslungsreichen und lernförderlichen Umgebung zu konzentrieren. Durch den Einsatz von HILA können Lehrkräfte sofortiges und personalisiertes Feedback bereitstellen, das direkt auf die individuellen Lernprozesse der Lernenden abgestimmt ist. Auf diese Weise trägt HILA nicht nur zur Verbesserung der Lehrqualität bei, sondern auch zur gezielten Unterstützung von Lernenden in ihren individuellen Lernverläufen.


Entwicklung von Daten-Erweiterten Lern-Aktivitäten (DeLA)

Anstatt sich auf eine einzelne Aktivität zu konzentrieren, um LA-Interventionen bereitzustellen, verfolgt das HILA-Forschungsprogramm unter anderem das Ziel, die am häufigsten vorkommenden Lernaktivitäten in Bildungseinrichtungen – von der Schule bis zur Hochschule – systematisch zu unterstützen. Dadurch sollen bestehende Lehr- und Lernpraktiken gezielt verbessert werden. Das HILA-Forschungsprogramm teilt dieses Ziel mit anderen Forschungsgruppen, die die Ergebnisse der LA-Forschung des letzten Jahrzehnts aufarbeiten, um konkrete und messbare Auswirkungen auf Lehr- und Lernprozesse zu erzielen. So untersuchten Saqr et al., (2022), ob und inwieweit allgemein verwendete Erfolgsindikatoren aus der LA-Forschung auf eine homogene Gruppe von Kursen übertragbar sind. Ihre Ergebnisse zeigen, dass alle betrachteten Indikatoren einen statistisch signifikanten kombinierten Korrelationskoeffizienten mit den Noten aufweisen und daher eine Rolle bei der Entwicklung von Prognosemodellen spielen könnten. Besonders Indikatoren, die auf Forenbeiträgen und dem Durchsuchen von Kursmaterialien basieren, erwiesen sich als gute Prädiktoren für den Lernerfolg der Studierenden. Zudem zeigte sich, dass Indikatoren für Gesamtaktivität, wie die Anzahl besuchter Veranstaltungen, die Sitzungsdauer oder die online verbrachte Zeit, zuverlässig und wiederholbar sind. Allerdings sind diese Indikatoren sehr allgemein gehalten und bieten keine ausreichende Grundlage für die Förderung spezifischer Lernziele oder Kompetenzen. Dies liegt vor allem daran, dass sie meist auf bereits vorhandenen Datenbanken basieren, die ursprünglich nicht für gezielte Lerninterventionen konzipiert wurden. Da diese Daten in erster Linie zur Protokollierung von Aktivitäten innerhalb digitaler Lernplattformen dienen, ermöglichen sie lediglich allgemeine Beobachtungen über das Nutzungsverhalten, wie die Anzahl der besuchten Sitzungen oder die Beteiligung in Foren. Sie liefern jedoch keine tiefgehenden Einblicke in spezifische Lernprozesse oder Kompetenzen. Dadurch sind sie ungeeignet für die

Bereitstellung von hochinformativem Feedback, das gezielt die Entwicklung von Fähigkeiten wie kritischem Denken, wissenschaftlichem Schreiben oder Problemlösungskompetenz unterstützen könnte.

Um diese Lücke zu schließen, verfolgt das HILA-Forschungsprogramm das Ziel, gezielte Interventionen zu entwickeln, die zentrale Kompetenzen wie Lesen, Schreiben, Rechnen, Programmieren, Modellieren und Gruppeninteraktion ansprechen. Diese Aktivitäten sind in nahezu jedem Kursdesign vertreten und spielen eine Schlüsselrolle beim Erwerb von Lernzielen. Um eine möglichst breite Abdeckung von Lernaktivitäten zu gewährleisten und HILA in verschiedenen Fachdisziplinen anwendbar zu machen, werden im Forschungsprogramm Daten-Erweiterte Lern-Aktivitäten (DeLA) entwickelt. Diese DeLAs ermöglichen es, sowohl Lernenden als auch Lehrenden hochinformatives Feedback zu spezifischen Lernaktivitäten bereitzustellen (Drachler, 2023). Abbildung 1 zeigt eine ikonische Darstellung der bisher entwickelten DeLAs. Jede DeLA-Ikone repräsentiert einen spezifischen Aufgabentyp, der mit einem entsprechenden Machine-Learning-Modell verknüpft ist, um zielgerichtetes HILA-Feedback für Lehr- und Lernprozesse zu ermöglichen.

Abb. 1: Ikonische Darstellung von Daten-Erweiterten Lern-Aktivitäten (DeLA), wie sie im HILA-Forschungsprogramm in unterschiedlichen Projekten eingesetzt werden.



Aufbau eines evidenzbasierten Wissenskorpus

Trotz mehr als 14 Jahren Forschung im Bereich LA bleibt die empirische Evidenz aus randomisierten, kontrollierten Feldstudien bislang begrenzt. Bereits 2016 wurde der Bedarf nach einem systematischen Wissenskorpus

über die Auswirkungen von LA-Ansätzen formuliert, das auf evidenzbasierten Forschungsansätzen beruht. Vor diesem Hintergrund wurde das EU-Projekt Learning Analytics Community Exchange (LACE) initiiert, mit dem Ziel, einen LA-Evidenz-Hub zu etablieren. Dieser Hub sollte eine systematische Übersicht über wirksame und weniger wirksame LA-Ansätze auf Basis von Publikationen der jährlichen LAK-Konferenz sowie relevanter Fachzeitschriften bieten (Ferguson & Clow, 2017). Das LACE-Projekt erzielte vielversprechende Fortschritte, unter anderem durch die Einführung innovativer Workshop-Formate wie dem »LAKfailathon«, der explizit darauf abzielte, fehlerhafte oder unwirksame Ansätze in der LA-Forschung zu reflektieren und kritisch zu diskutieren. Dennoch scheiterte der LA-Evidenz-Hub letztlich an fehlenden Ressourcen, insbesondere aufgrund der enormen Anzahl an neu erscheinenden Publikationen, die eine kontinuierliche Aktualisierung und Validierung der Erkenntnisse erforderlich gemacht hätten. Der Bedarf an einem fundierten, validierten Überblick über verschiedene LA-Ansätze besteht weiterhin, vorallem in der heutigen LA-Forschung, wo eine Vielzahl von unterschiedlichen KI-Modellen zum Einsatz kommen. In der Praxis wird beim Start neuer LA-Projekte häufig nicht systematisch auf evidenzbasierte Methoden und bewährte Erkenntnisse aus früheren Studien zurückgegriffen. Statt fundierter Indikatoren für Lernprozesse stehen oft technische Logdaten der jeweiligen digitalen Infrastruktur im Fokus. Diese Orientierung an vorhandenen, leicht zugänglichen Daten führt dazu, dass viele LA-Initiativen weiterhin primär technologiegetrieben sind, anstatt den didaktischen Mehrwert in den Vordergrund zu stellen (Motz et al., 2022).

Um LA nachhaltig in der Bildung zu verankern und bereichernde Lernerfahrungen zu fördern, ist es daher unerlässlich, bestehende Ansätze kritisch zu analysieren, systematisch in verschiedenen Bildungskontexten zu evaluieren und mit diversen Zielgruppen zu testen. Eine solche evidenzbasierte Herangehensweise ermöglicht eine fundierte Bewertung der Auswirkungen von LA-Methoden auf das Erreichen von Lernzielen und trägt zur gezielten Weiterentwicklung des Forschungsfeldes bei.

Feedback durch hochinformative Learning Analytics

Feedback gilt in den Bildungswissenschaften als eine der wirkungsvollsten Einflussgrößen auf Lernen und Lernerfolg (Hattie & Timperley, 2007, S. 81). Eine Meta-Analyse von Wisniewski et al., (2020) bestätigt diesen Einfluss mit

einer mittleren Effektgröße von $d = 0,75$, während hochinformatives Feedback sogar eine Effektgröße von $d = 0,99$ aufweist. Dies unterstreicht die zentrale Rolle von Feedback bei der Gestaltung effektiver Lernerfahrungen im Kontext von LA. Hattie & Timperley (2007) zeigten, dass Feedback das Potenzial hat, die Leistung der Lernenden maßgeblich zu beeinflussen, wenn es gezielt auf die individuellen Lernprozesse abgestimmt ist. Besonders für Lernende mit schwächeren oder durchschnittlichen Leistungen ist hochinformatives Feedback entscheidend, da es über einfache Leistungsrückmeldungen wie Punkte, Noten oder Bestehen/Nichtbestehen hinausgeht. Es soll Lernende dazu befähigen, ihre eigene Leistung kritisch zu reflektieren, gezielt zu verbessern und langfristig ihre Lernziele zu erreichen.

Während die positiven Effekte von Feedback gut dokumentiert sind, weisen neuere Studien darauf hin, dass Feedback nicht immer gleich wirkt. Lipnevich & Panadero (2021) identifizieren vier zentrale Dimensionen, die darüber entscheiden, ob Feedback tatsächlich wirksam ist:

1. Kognitiv: Verstehe ich das Feedback?
2. Affektiv: Weiß ich, wie ich damit umgehen soll?
3. Emotional: Gefällt mir die Rückmeldung?
4. Nützlichkeit: Finde ich das Feedback hilfreich?

Lipnevich & Lopera-Oquend (2022) fanden eine Korrelation zwischen der kognitiven und affektiven Dimension des Verständnisses von Feedback und entwickelten daraufhin ein überarbeitetes Modell für effektives Lernendenfeedback (Lipnevich & Smith, 2022). Neben den positiven Effekten von Feedback betonen Nachtigall et al., (2020), dass ungenaues oder wenig hilfreiches Feedback in Kombination mit ausbleibendem Lernerfolg demotivierende und unproduktive Lernprozesse hervorrufen kann. In einigen Fällen kann Feedback sogar negative Auswirkungen auf Lernende haben (Wisniewski et al., 2020). Dies liegt teilweise daran, dass Lernende Feedback unterschiedlich verarbeiten, je nach individuellen Dispositionen, Vorerfahrungen und Selbstregulationsfähigkeiten (Panadero & Lipnevich, 2022). Weidlich et al. (2024) bestätigten diesen Zusammenhang in einer randomisierten Feldstudie.

Diese Erkenntnisse zeigen, dass die Bereitstellung von Informationen über LA-Dashboards oder personalisierte Nachrichten allein nicht ausreicht, um effektives Lernen zu unterstützen. Eine technologisch reduzierte Sichtweise, bei der Lern- und Bildungsprozesse vorrangig an die Möglichkeiten bestehender Systeme angepasst werden, wird als Technologie-determinismus

kritisiert (Bruyckere et al., 2019; Winstone & Carless, 2019). Ein Beispiel für eine solche didaktische Vereinfachung ist der weit verbreitete, aber empirisch nicht belegte Mythos der Learning Styles, der häufig in Lernenden-Modellen genutzt wird, weil er sich technisch leicht umsetzen lässt (Kirschner, 2017). Dieser Technologiedeterminismus untergräbt das eigentliche Potenzial von LA und führt dazu, dass traditionelle, wenig wirksame Feedback-Modelle lediglich in ein neues technisches Gewand gekleidet werden (Winstone & Carless, 2019). Wie bereits unter 1.1 diskutiert, zeigt sich in der LA-Community häufig eine Bevorzugung technologischer Entwicklungen gegenüber didaktischen Konzepten (Greller & Drachsler, 2012; Gasevic et al., 2015; Motz et al., 2022). Um die Wirksamkeit von LA-gestütztem Feedback zu erhöhen, muss der Fokus daher von der Bereitstellung hin zur Verarbeitung von Feedback verlagert werden (Lui & Andrade, 2022). Dies erfordert eine differenzierte Betrachtung der individuellen Perspektiven, Eigenschaften und Bedürfnisse der Lernenden, ebenso wie den Einsatz reichhaltiger und didaktisch relevanter Daten, um wirklich HILA-Feedback für Lernende und Lehrkräfte zu ermöglichen.

Im HILA-Forschungsprogramm wird deshalb das Modell von Hattie & Timperley (2007) zur Strukturierung von formativem Feedback genutzt. Formatives Feedback stellt sicher, dass Lernende während des Lernprozesses gezielte Rückmeldungen erhalten, um ihre Leistung kontinuierlich zu verbessern (Shute, 2008). Darüber hinaus ist es dringend erforderlich, sich intensiver mit den Kompetenzen zur Verarbeitung von Feedback auseinanderzusetzen. Die sogenannten Feedback Literacy-Kompetenzen (Weidlich et al., 2025) sind entscheidend für die Wirksamkeit von LA-gestützten Feedbacksystemen – sowohl für Lehrkräfte als auch für Lernende. Diese Kompetenzen sollten verstärkt in randomisierten Vergleichsstudien untersucht werden, um langfristig fundierte Erkenntnisse über die tatsächlichen Effekte von HILA-Feedback auf Lernprozesse zu gewinnen.

Wirkung von hochinformativen Learning Analytics

Als ein Fachgebiet, das sich dem Verständnis und der Verbesserung des Lernens verschrieben hat, muss die LA in der Lage sein, ihre Auswirkungen auf das Lernen empirisch zu belegen. Dies gilt insbesondere in der heutigen Zeit, in der eine wachsende Zahl von LA-Methoden aus der Forschung in die Praxis übergehen und in Bildungseinrichtungen eingesetzt werden. Leider werden

kontrollierte, randomisierte Feldversuche im LA-Bereich nur selten durchgeführt (Viberg et al., 2018; Weidlich et al., 2022).

Das solche Experimente aber durchführbar sind und auch für die Anwendung von HILA vielversprechende Ergebnisse liefern, haben z.B. (Meurers et al., 2019), gezeigt. Meurers et al. führten eine randomisierte Feldstudie mit einem in den regulären Fremdsprachenunterricht integrierten Intelligenten Tutorsystem in Deutschland durch und konnten eine signifikante Lernverbesserung durch automatisiertes, von Lernenden gesteuertes Feedback im Vergleich zu Standardfeedback (wahr/falsch) nachweisen. Vergleichbare Studien sind immer noch selten; stattdessen werden routinemäßig Beobachtungsdaten verwendet, bei denen es schwierig ist, kausale Zusammenhänge zu erkennen.

In jüngster Zeit gab es eine Reihe von kritischen Artikeln über die bestehende Forschung im Bereich der LA. Weidlich et al. (2022) und Hicks et al. (2022) äußern sich zur Gewinnung von Erkenntnissen aus LA-Experimenten und zeigen gleichzeitig einen Ansatz zur Gewinnung von Kausalwissen außerhalb stark kontrollierter Experimente auf. Mit der HILA-Forschungsprogramm wollen wir diesen Mangel an empirischen fundierten Studien zu LA entgegenwirken. Durch die Durchführung zuverlässiger und methodisch valider Studien soll ein besseres Verständnis der kausalen Auswirkungen von LA auf das Lernen ermöglicht werden. Gleichzeitig wird angestrebt, einen systematischen Wissensfundus zu den Effekten von LA auf unterschiedliche Zielgruppen aufzubauen. Dies ist besonders relevant, da LA-Methoden in heterogenen Bildungssettings zum Einsatz kommen – von Kindern im Schulalter bis hin zu Hochschulstudierenden. Für die praktische Anwendung von LA ist es essenziell, dass die Auswahl eines LA-Instruments gezielt auf die spezifischen Lernziele und die jeweilige Zielgruppe abgestimmt wird. Ein erster Versuch, dieses ehrgeizige Ziel zu erreichen, wurde von (Ahmad et al., 2022) und dem Open Learning Analytics Indicator Repository (OpenLAIR²) sowie der Entwicklung verschiedener DeLAs (Biedermann, Ciordas-Hertel, et al., 2023; Biedermann, Schneider, et al., 2023; Gombert et al., 2023; O. F. Karademir et al., 2021; Menzel et al., 2023) unternommen, die in hohem Maße an jede Disziplin anpassbar sind, aber stärker kontrolliert werden können, um experimentelle Bedingungen zu ermöglichen.

Das HILA-Forschungsprogramm verfolgt damit das übergeordnete Ziel, bestehende Forschungslücken zu schließen, indem es Lernenden und Lehr-

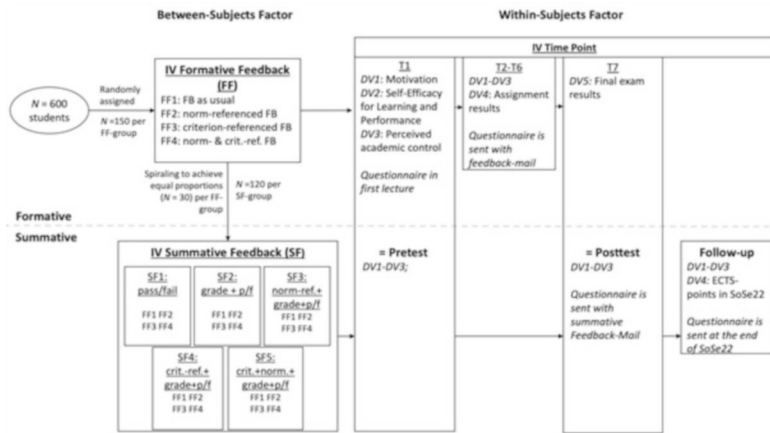
2 <https://edutec.science/open-learning-analytics-indicator-repository-openlair/>

kräften hochinformatives Feedback in authentischen Lernsituationen bereitstellt. Die zentrale Forschungsfrage lautet daher:

Welche Auswirkungen haben verschiedene Arten von HILA-Feedback auf die Ergebnisse von Übungsaufgaben, Prüfungsleistungen und affektive Variablen der Lernenden?

Zur Beantwortung dieser Frage werden experimentelle Prä-Post-Designs mit mehreren Vergleichsgruppen eingesetzt (siehe Abbildung 2). Die experimentellen Bedingungen variieren zwischen HILA-Feedback mit verschiedenen Fokussierungen (auf Aufgaben-, Prozess-, Selbstregulations- und Selbst-Ebene) und einer Kontrollgruppe, die allgemeines, nicht-personalisiertes Feedback erhält.

Abb. 2: Beispiel eines Forschungsdesigns aus dem Projekt HIKOF-DL aus dem HILA-Forschungsprogramm.



Die nachfolgend dargestellten Studien wurden unter kontrollierten Bedingungen mit aussagekräftigen Stichproben durchgeführt, um sowohl statistische Aussagekraft als auch ökologische Gültigkeit zu gewährleisten. Erste Ergebnisse weisen auf eine heterogene Wirkung von HILA-Feedback hin, sodass weitere Untersuchungen notwendig sind, um die spezifischen Einflussfaktoren detaillierter zu analysieren. Die Auswertung zusätzlicher Daten und weitere wissenschaftliche Publikationen zu diesen Themen sind in Arbeit.

HILA-Feedback und Prüfungsleistungen

Die Verbesserung von Prüfungsleistungen ist ein zentrales Ziel von HILA-Feedback. Verschiedene Studien untersuchen, inwiefern personalisierte Rückmeldungen durch LA zu besseren Lernergebnissen führen können. Besonders relevant ist hierbei der Einsatz von DeLAs, die eine tiefere Analyse von Lernprozessen ermöglichen.

Karademir et al. (2024)

Die Studie von Karademir et al. (2024) untersuchte den Einsatz eines LA-Dashboards, das Texte mittels des Writing-DeLAs analysierte. Die Ergebnisse zeigen eine signifikante Verbesserung der Lernergebnisse von Schüler:innen im Physikunterricht. Besonders Lernende mit Rückständen profitierten von der Nutzung des Dashboards durch ihre Lehrkräfte. Dies deutet darauf hin, dass HILA-Feedback gezielt zur Unterstützung von Lehrkräften eingesetzt werden kann, um individuelle Lernbedarfe besser zu adressieren.

Gombert et al. (2024) & Weidlich et al. (2024)

In der Studie von Gombert et al. (2024) wurde untersucht, wie automatisierte Analysen von Studierendenaufsätzen durch den Writing-DeLA zu hochinformativen Rückmeldungen führen. Die Ergebnisse zeigen, dass diese Rückmeldungen die Reflexionspraktiken der Studierenden verbesserten und potenziell zu besseren akademischen Leistungen beitragen.

Eine parallele Untersuchung von Weidlich et al. (2024) ergab hingegen, dass keine signifikanten Verbesserungen in den Prüfungsleistungen festgestellt werden konnten, obwohl HILA-Feedback affektive Variablen der Studierenden positiv beeinflusste. Diese Diskrepanz verdeutlicht die Notwendigkeit weiterer Forschung zur Wirkung von HILA-Feedback im Hochschulkontext und insbesondere zur Rolle des Anwendungskontexts.

HILA-Feedback und affektive studierenden Variablen und Lernstrategien

Neben den direkten Auswirkungen auf Prüfungsleistungen kann HILA-Feedback auch affektive Faktoren wie Motivation, Engagement und Selbstregulation beeinflussen. Die folgenden Studien untersuchen, inwiefern personalisiertes Feedback zu einer stärkeren Einbindung in den Lernprozess und verbesserten Lernstrategien führt.

Menzel et al. (2023)

Die Studie von Menzel et al. (2023) arbeitete mit dem Collaboration-DeLA und konnte zeigen, dass Studierende in Gruppenarbeiten HILA-Feedback als hilfreich empfanden. Die verstärkte Wahrnehmung von Gruppenprozessen führte zu einer Verhaltensänderung und einer erhöhten Beteiligung an Gruppenaktivitäten.

Giorgashvili et al. (2024)

In einer Folgestudie durch Giorgashvili et al. (2024) wurde untersucht, wie personalisiertes Feedback über ein LA-Dashboards individuelle Lernstrategien beeinflussen. Die Ergebnisse zeigen, dass HILA-Feedback zur Förderung der Selbstregulation und des Engagements beiträgt, was sich in angepassten Lernstrategien und einer stärkeren Beteiligung am Lernprozess widerspiegelte.

Winter et al. (2024)

Die Studie von Winter et al. (2024) betont die Rolle von HILA-Feedback für das Lernengagement. Durch die Modellierung von Engagement in Unterdimensionen wie Anstrengung und Aufmerksamkeit zeigte sich, dass HILA wertvolle Unterstützung bei der Verbesserung des studentischen Engagements und der Optimierung von Selbstlernstrategien bietet.

Weidlich et al. (2024)

Die Studie von Weidlich et al. (2024) beleuchtete emotionale und motivationale Unterschiede in Abhängigkeit vom Feedback-Format. Während kriteriumsbezogenes Feedback positive Emotionen förderte, wirkte sich normbezogenes Feedback negativ auf die Motivation von Studierenden mit niedrigen Selbstregulationsfähigkeiten aus. Dieses Ergebnis ist bemerkenswert, da Feedback traditionell als positiv für die Lernsituation angesehen wird. Die Studie zeigt jedoch, dass verschiedene Feedbackarten unterschiedlich wahrgenommen werden können und nicht immer vorteilhaft sind.

Die bisherigen Studien zu HILA-Feedback zeigen vielversprechende Effekte auf Prüfungsleistungen, affektive Variablen und Lernstrategien. Gleichzeitig verdeutlichen die Ergebnisse, dass die Wirksamkeit von HILA-Feedback kontextabhängig ist und von individuellen Faktoren der Lernenden beeinflusst wird. Zukünftige Forschung sollte sich insbesondere auf die spezifischen Bedingungen konzentrieren, unter denen HILA-Feedback seine volle Wirk-

samkeit entfaltet, sowie auf mögliche unbeabsichtigte Effekte, die durch unterschiedliche Feedbackarten entstehen können. Darüber hinaus sind weitere experimentelle Studien notwendig, um die kausalen Zusammenhänge zwischen HILA-Feedback und Lernleistungen genauer zu bestimmen.

Schlussfolgerungen

In meiner Keynote auf der Learning AID 2024 habe ich die Entwicklung von Trusted Learning Analytics (TLA) hin zu Highly Informative Learning Analytics (HILA) skizziert und zentrale Herausforderungen im Forschungsfeld diskutiert. Mein Ziel war es, aufzuzeigen, wie LA sinnvoll in Bildungsprozesse integriert werden können und welche Bedingungen erfüllt sein müssen, damit diese Technologien tatsächlich einen Mehrwert für Lernende und Lehrkräfte bieten. Mit dem HILA-Forschungsprogramm im EduTec.science-Forschungsverbund verfolgen meine Kolleg:innen und ich eine evidenzbasierte und didaktisch fundierte Herangehensweise, um Learning Analytics gezielt in Bildungsprozesse zu integrieren.

Dabei stehen drei zentrale Schwerpunkte im Fokus:

1. *Fokus auf die Mikroebene – Individuelles und wirksames Feedback:* Viele LA-Ansätze konzentrieren sich auf aggregierte Daten und liefern eher allgemeine Erkenntnisse auf der Meso- oder Makroebene. Ich bin überzeugt, dass der größte Mehrwert von LA auf der Mikroebene liegt, also in der direkten Unterstützung individueller Lernprozesse. HILA verfolgt daher einen lernendenzentrierten Ansatz, der personalisiertes, kontextsensitives Feedback ermöglicht. Durch präzisere Anpassung des Feedbacks an die individuellen Lernbedürfnisse können wir nicht nur das Lernen optimieren, sondern auch Lehrkräfte gezielt entlasten. Besonders in Zeiten eines steigenden Lehrkräftemangels halte ich es für essenziell, dass LA nicht nur analysiert, sondern konkrete Unterstützung für Lehr- und Lernprozesse bietet.
2. *Empirische Validierung durch gezielte Daten:* Ein großes Problem vieler LA-Ansätze ist, dass sie sich auf bestehende Log-Daten aus digitalen Plattformen stützen, die häufig wenig über tatsächliche Lernprozesse aussagen. Ich bin überzeugt, dass LA zielgerichtete und didaktisch relevante Daten benötigt, um wirklich nützlich zu sein. Deshalb setzen wir in HILA auf Daten-Erweiterte Lern-Aktivitäten. Diese ermöglichen es, gezielt aussagekräftige

Daten zu generieren, anstatt nur auf zufällig anfallende Interaktionsdaten zurückzugreifen. Dadurch schaffen wir nicht nur eine fundierte empirische Basis für LA, sondern stellen sicher, dass unsere Interventionen tatsächlich lernförderlich sind.

3. *Aufbau eines evidenzbasierten Wissenskorpus – Learning Analytics über Technologie hinaus denken*: Einer der zentralen Punkte meiner Keynote war, dass technologischer Fortschritt allein nicht ausreicht, um LA erfolgreich in die Bildungspraxis zu integrieren. Vielmehr braucht es eine wissenschaftlich fundierte Grundlage, um die Wirksamkeit dieser Technologien wirklich bewerten zu können. Mein Ziel ist es, mit HILA eine starke evidenzbasierte Forschung aufzubauen, die systematische Vergleichsstudien ermöglicht – sowohl in kontrollierten Laborstudien als auch in realen Bildungssettings. Gerade die Verknüpfung von theoretischer Forschung und praxisnahen Anwendungen halte ich für essenziell, um LA nachhaltig in der Bildungslandschaft zu verankern.

In meiner Keynote habe ich betont, dass die erfolgreiche Integration von LA nur durch interdisziplinäre Zusammenarbeit gelingen kann. Besonders die Verbindung zwischen Informatik und Fachdidaktik sehe ich als zentral an, um evidenzbasierte LA-Systeme zu entwickeln, die einen echten Mehrwert für Lehrkräfte und Lernende bieten. Dazu brauchen wir digitale Plattformen, die nicht nur Daten sammeln, sondern authentische, ökologisch valide Lerndaten erfassen und in sinnvolle, direkt umsetzbare Feedback übersetzen. Dies ist eine komplexe Herausforderung, die nur durch starke institutionelle Kooperationen und wissenschaftliche Partnerschaften bewältigt werden kann.

Darüber hinaus ist es dringend erforderlich, sich intensiver mit der Verarbeitung von Feedback auseinanderzusetzen. Die sogenannten Feedback Literacy-Kompetenzen sind entscheidend für die Wirksamkeit von LA-gestützten Feedbacksystemen, sowohl für Lehrkräfte als auch für Lernende. Ein tiefgehendes Verständnis darüber, wie Feedback wahrgenommen, interpretiert und in den eigenen Lernprozess integriert wird, ist essenziell, um LA wirksam und nachhaltig einzusetzen. Nur wenn Lehrende und Lernende über diese Kompetenzen verfügen, kann LA sein volles Potenzial entfalten und tatsächlich zu besseren Lernprozessen beitragen.

Literatur

- Ahmad, A., Schneider, J., Griffiths, D., Biedermann, D., Schiffner, D., Greller, W., & Drachslers, H. (2022). Connecting the dots: A literature review on learning analytics indicators from a learning design perspective. *Journal of Computer Assisted Learning*. <https://doi.org/10.1111/jcal.12716>
- Biedermann, D., Ciordas-Hertel, G.-P., Winter, M., Mordel, J., & Drachslers, H. (2023). Contextualized Logging of On-Task and Off-Task Behaviours During Learning. *Journal of Learning Analytics*, 10(2), 115–125. <https://doi.org/10.18608/jla.2023.7837>
- Biedermann, D., Schneider, J., Ciordas-Hertel, G.-P., Eichmann, B., Hahnel, C., Goldhammer, F., & Drachslers, H. (2023). Detecting the Disengaged Reader—Using Scrolling Data to Predict Disengagement during Reading. LAK23: 13th International Learning Analytics and Knowledge Conference, 585–591. <https://doi.org/10.1145/3576050.3576078>
- Bruyckere, P. D., Kirschner, P. A., & Hulshof, C. (2019). *More Urban Myths About Learning and Education: Challenging Eduquacks, Extraordinary Claims, and Alternative Facts* (1st ed.). Routledge. <https://doi.org/10.4324/9781351132435>
- Ciordas-Hertel, G., Schneider, J., & Drachslers, H. J. (2020). Which Strategies are Used in the Design of Technical LA Infrastructure?: A Qualitative Interview Study. In A. Cardoso, G. R. Alves, & M. T. Restivo (Eds.), *Proceedings of the IEEE Global Engineering Education Conference (EDUCON 2020)* (pp. 96–105). IEEE. <https://doi.org/10.1109/EDUCON45650.2020.9125363>
- Ciordas-Hertel, G.-P., Schneider, J., Ternier, S. G. C., & Drachslers, H. J. (2019). Adopting Trust in Learning Analytics Infrastructure: A Structured Literature Review. *Journal of Universal Computer Science*, 25(13), 1668–1686. <https://doi.org/10.3217/jucs-025-13-1668>
- Di Mitri, D., Schneider, J., & Drachslers, H. (2021). Keep me in the loop. Real-time feedback with multimodal data. *International Journal of Artificial Intelligence in Education*, 32(4), 1093–1118. <https://doi.org/10.1007/s40593-021-00281-z>
- Drachslers, H. (2023). Towards highly informative learning analytics (p. 62 pages). Open Universiteit×: Heerlen. <https://doi.org/10.25656/01:26787>
- Drachslers, H., & Grellers, W. (2016). Privacy and Analytics – it’s a DELICATE issue. A Checklist to establish trusted Learning Analytics. 89–98. <https://doi.org/10.1145/2883851.2883893>

- Ferguson, R., & Clow, D. (2017). Where is the evidence?: A call to action for learning analytics. *Proceedings of the Seventh International Learning Analytics & Knowledge Conference*, 56–65. <https://doi.org/10.1145/3027385.3027396>
- Gašević, D., Dawson, S., & Siemens, G. (2015). Let's not forget: Learning analytics are about learning. *TechTrends*, 59(1), 64–71. <https://doi.org/10.1007/s11528-014-0822-x>
- Giorgashvili, T., Jivet, I., Artelt, C., Biedermann, D., Bengs, D., Goldhammer, F., Hahnel, C., Mendzheritskaya, J., Mordel, J., Onofrei, M., Winter, M., Wolter, I., Horz, H., & Drachslers, H. (2024). Exploring Learners' Self-reflection and Intended Actions After Consulting Learning Analytics Dashboards in an Authentic Learning Setting. In R. F. Mello, N. Rummel, J. Jivet, G. Pishtari, & J. A. Ruipérez Valiente (Eds.), *19th European Conference on Technology Enhanced Learning, EC-X 2024*, September 16–20, 2024 (pp. 135–151). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-72315-5_10
- Gombert, S., Di Mitri, D., Karademir, O., Kubsch, M., Kolbe, H., Tautz, S., Grimm, A., Bohm, I., Neumann, K., & Drachslers, H. (2023). Coding energy knowledge in constructed responses with explainable NLP models. *Journal of Computer Assisted Learning*, 39(3), 767–786. <https://doi.org/10.1111/jcal.12767>
- Gombert, S., Fink, A., Giorgashvili, T., Jivet, I., Di Mitri, D., Yau, J., Frey, A., & Drachslers, H. (2024). From the Automated Assessment of Student Essay Content to Highly Informative Feedback: A Case Study. *International Journal of Artificial Intelligence in Education*, 34(4), 1378–1416. <https://doi.org/10.1007/s40593-023-00387-6>
- Greller, W., & Drachslers, H. (2012). Translating Learning into Numbers: A Generic Framework for Learning Analytics. *Educational Technology & Society*, 15(3), 42–57.
- Hansen, Jan, Rensing, Christoph, Herrmann, Oliver, & Drachslers, Hendrik. (2020). *Verhaltenskodex für Trusted Learning Analytics. Version 1.0. Entwurf für die hessischen Hochschulen*. <https://doi.org/10.25657/02:18903>
- Hattie, J., & Timperley, H. (2007). The power of feedback. *Review of Educational Research*, 77. <https://doi.org/10.3102/003465430298487>
- Hicks, B., Kitto, K., Payne, L., & Buckingham Shum, S. (2022). Thinking with causal models: A visual formalism for collaboratively crafting assumptions. *LAK22: 12th International Learning Analytics and Knowledge Conference*, 250–259. <https://doi.org/10.1145/3506860.3506899>

- Jivet, I., Scheffel, M., Drachslers, H., & Specht, M. (2017). Awareness is not enough. Pitfalls of learning analytics dashboards in the educational practice. In Élise Lavoué, Hendrik Drachslers, Katrien Verbert, Julien Broisin, & Mar Pérez-Sanagustín (Eds.), *Data Driven Approaches in Digital Education*. Springer International Publishing AG. https://doi.org/10.1007/978-3-319-66610-5_7
- Jivet, I., Scheffel, M., Schmitz, M., Robbers, S., Specht, M., & Drachslers, H. (2020). From students with love: An empirical study on learner goals, self-regulated learning and sense-making of learning analytics in higher education. *The Internet and Higher Education*, 47, 100758. <https://doi.org/10.1016/j.iheduc.2020.100758>
- Jivet, I., Scheffel, M., Specht, M., & Drachslers, H. (2018). License to evaluate: Preparing learning analytics dashboards for educational practice. *Proceedings of the 8th International Conference on Learning Analytics and Knowledge*, 32–40. <https://doi.org/10.1145/3170358.3170421>
- Karademir, O., Borgards, L., Di Mitri, D., Strauß, S., Kubsch, M., Brobeil, M., Grimm, A., Gombert, S., Rummel, N., Neumann, K., & Drachslers, H. (2024). Following the Impact Chain of the LA Cockpit: An Intervention Study Investigating a Teacher Dashboard's Effect on Student Learning. *Journal of Learning Analytics*, 11(2), 215–228. <https://doi.org/10.18608/jla.2024.8399>
- Karademir, O. F., Ahmad, A., Schneider, J., Di Mitri, D., Jivet, I., & Drachslers, H. (2021). Designing the Learning Analytics Cockpit—A Dashboard that Enables Interventions. In V. Uskov (Ed.), *Methodologies and Intelligent Systems for Technology Enhanced Learning*, 11th International Conference. *MIS4 × 2021* (Vol. 326, pp. 95–104). Springer. https://doi.org/10.1007/978-3-030-86618-1_10
- Kirschner, P. A. (2017). Stop propagating the learning styles myth. *Computers & Education*, 106, 166–171. <https://doi.org/10.1016/j.compedu.2016.12.006>
- Kollom, K., Tammets, K., Scheffel, M., Tsai, Y.-S., Jivet, I., Muñoz-Merino, P. J., Moreno-Marcos, P. M., Whitelock-Wainwright, A., Calleja, A. R., Gasevic, D., Kloos, C. D., Drachslers, H., & Ley, T. (2021). A four-country cross-case analysis of academic staff expectations about learning analytics in higher education. *The Internet and Higher Education*, 49(2021). <https://doi.org/10.1016/j.iheduc.2020.100788>
- Lipnevich, A. A., & Lopera-Oquendo, C. (2024). Receptivity to Instructional Feedback: A Validation Study in the Secondary School Context in Singa-

- pore. *European Journal of Psychological Assessment*, 40(1), 22–32. <https://doi.org/10.1027/1015-5759/a000733>
- Lipnevich, A. A., & Panadero, E. (2021). A Review of Feedback Models and Theories: Descriptions, Definitions, and Conclusions. *Frontiers in Education*, 6. <https://www.frontiersin.org/articles/10.3389/educ.2021.720195>
- Lipnevich, A. A., & Smith, J. K. (2022). Student – Feedback Interaction Model: Revised. *Studies in Educational Evaluation*, 75, 101208. <https://doi.org/10.1016/j.stueduc.2022.101208>
- Lui, A. M., & Andrade, H. L. (2022). The Next Black Box of Formative Assessment: A Model of the Internal Mechanisms of Feedback Processing. *Frontiers in Education*, 7, 751548. <https://doi.org/10.3389/educ.2022.751548>
- Menzel, L., Gombert, S., Weidlich, J., Fink, A., Frey, A., & Drachler, H. (2023). Why You Should Give Your Students Automatic Process Feedback on Their Collaboration: Evidence from a Randomized Experiment. In O. Viberg, I. Jivet, P. J. Muñoz-Merino, M. Perifanou, & T. Papathoma (Eds.), *Responsive and Sustainable Educational Futures* (pp. 198–212). Springer Nature Switzerland.
- Meurers, D., De Kuthy, K., Nuxoll, F., Rudzewitz, B., & Ziai, R. (2019). Scaling Up Intervention Studies to Investigate Real-Life Foreign Language Learning in School. *Annual Review of Applied Linguistics*, 39, 161–188. Cambridge Core. <https://doi.org/10.1017/S0267190519000126>
- Motz, B., Quick, J., Brooks, C., Bergner, Y., Gray, G., Lang, C., Li, W., & Marmolejo-Ramos, F. (2022). A LAK of Direction: Misalignment Between the Goals of Learning Analytics and its Research Scholarship [Preprint]. EdArXiv. <https://doi.org/10.35542/osf.io/bzahw>
- Nachtigall, V., Serova, K., & Rummel, N. (2020). When failure fails to be productive: Probing the effectiveness of productive failure for learning beyond stem domains. *Instructional Science*, No Pagination Specified-No Pagination Specified. <https://doi.org/10.1007/s11251-020-09525-2>
- Panadero, E., & Lipnevich, A. A. (2022). A review of feedback models and typologies: Towards an integrative model of feedback elements. *Educational Research Review*, 35, 100416. <https://doi.org/10.1016/j.edurev.2021.100416>
- Sagr, M., Jovanovic, J., Viberg, O., & Gašević, D. (2022). Is there order in the mess? A single paper meta-analysis approach to identification of predictors of success in learning analytics. *Studies in Higher Education*, 47(12), 2370–2391. <https://doi.org/10.1080/03075079.2022.2061450>
- Scheffel, M., Tsai, Y.-S., Gašević, D., & Drachler, H. (2019). Policy Matters: Expert Recommendations for Learning Analytics Policy. In *Lecture Notes*

- in *Computer Science* (pp. 510–524). Springer International Publishing. https://doi.org/10.1007/978-3-030-29736-7_38
- Shute, V. J. (2008). Focus on formative feedback. *Review of Educational Research*, 78. <https://doi.org/10.3102/0034654307313795>
- Tsai, Y.-S., Gašević, D., Whitelock-Wainwright, A., Muñoz-Merino, P. J., Moreno-Marcos, P. M., Fernández, A. R., Kloos, C. D., Scheffel, M., Jivet, I., Drachsler, H., Tammets, K., Calleja, A. R., & Kollom, K. (2018). RESEARCH REPORT NOVEMBER 2018.
- 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. <https://doi.org/10.1016/j.chb.2018.07.027>
- Weidlich, J., Fink, A., Jivet, I., Yau, J., Giorgashvili, T., Drachsler, H., & Frey, A. (2024). Emotional and motivational effects of automated and personalized formative feedback: The role of reference frames. *Journal of Computer Assisted Learning*, 40(6), 2735–2752. <https://doi.org/10.1111/jcal.13024>
- Weidlich, J., Gašević, D., & Drachsler, H. (2022). Causal Inference and Bias in Learning Analytics. *Journal of Learning Analytics*, 1–17. <https://doi.org/10.18608/jla.2022.7577>
- Weidlich, J., Jivet, I., Woitt, S., Orhan Göksün, D., Kraus, J., & Drachsler, H. (2025). The student feedback literacy instrument (SFLI): Multilingual validation and introduction of a short-form version. *Assessment & Evaluation in Higher Education*, 1–17. <https://doi.org/10.1080/02602938.2025.2451729>
- Winstone, N., & Carless, D. (2019). Designing effective feedback processes in higher education: A learning-focused approach. Routledge.
- Winter, M., Mordel, J., Mendzheritskaya, J., Biedermann, D., Ciordas-Hertel, G.-P., Hahnel, C., Bengs, D., Wolter, I., Goldhammer, F., Drachsler, H., Artelt, C., & Horz, H. (2024). Behavioral trace data in an online learning environment as indicators of learning engagement in university students. *Frontiers in Psychology*, 15, 1396881. <https://doi.org/10.3389/fpsyg.2024.1396881>
- Wisniewski, B., Zierer, K., & Hattie, J. (2020). The Power of Feedback Revisited: A Meta-Analysis of Educational Feedback Research. *Frontiers in Psychology*, 10. <https://www.frontiersin.org/articles/10.3389/fpsyg.2019.03087>
- Wollny, S., Di Mitri, D., Jivet, I., Muñoz-Merino, P., Scheffel, M., Schneider, J., Tsai, Y.-S., Whitelock-Wainwright, A., Gasevic, D., & Drachsler, H. (2023). Students' expectations of Learning Analytics across Europe. *Journal of Computer Assisted Learning*, 1–14.

Wollny, S., Schneider, J., Di Mitri, D., Weidlich, J., Rittberger, M., & Drachsler, H. (2021). Are We There Yet?: A Systematic Literature Review on Chatbots in Education. *Frontiers in Artificial Intelligence*, 4. <https://doi.org/10.3389/frai.2021.654924>

Learning Analytics

Learning Analytics in digitalen Selbstlernkursen¹

Roland Böttcher, Marina Rüter und Jonas Schug

Der Beitrag diskutiert die Verarbeitung, Auswertung und Nutzung von Learning-Analytics-Daten in umfangreichen digitalen Moodle-Selbstlernkursen. Ausgewertet wird das Lernverhalten von 492 Studierenden eines Selbstlernkurses mit automatisierter Portfolioprüfung. Die Datenbasis umfasst u.a. den zeitlichen Verlauf der Bearbeitung von Lernelementen, Zeitstempel von Aktivitätsabschlüssen, Zeitstempel von automatisierten Nachrichten zur Motivationssteuerung, individuelle Ergebnisse von 105 formativen Tests sowie Daten eines lernstrategischen Verhaltensprofils. Dabei wurden drei Steuerungsdimensionen identifiziert: langfristige Kursoptimierung (1), Ad-hoc-Anpassungen (2) und die Förderung von Kommunikation und Motivation (3). Die Ergebnisse zeigen, dass Learning Analytics Lehrenden Ansätze bietet, um – im Rahmen dieser Dimensionen –, Risikogruppen zu definieren, kritische Lernelemente zu identifizieren, Dropout-Raten zu reduzieren und das Kursdesign zu optimieren.

Learning analytics in digital self-learning courses

The report discusses the processing, evaluation and use of learning analytics data in extensive digital Moodle self-learning courses. The learning behaviour of 492 students of a self-study course with automated portfolio assessment is evaluated. The database includes, the time course of the processing of learning elements, time stamps of activity completions, time stamps of automated messages for motivation control, individual results of 105 formative tests of each participant as well as data of a learning-strategic behaviour profile. Three dimensions of control were identified: long-term course optimization (1), ad hoc adjustments (2) and the promotion of communication and motivation (3). The results show that learning analytics offers teachers approaches for identifying risk groups at an early stage, identifying critical learning elements, reducing dropout rates and optimizing course design within the scope of these dimensions.

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

Einleitung

Im Zuge der Digitalisierung werden in Hochschulen zunehmend digitale Lernwelten implementiert. Dieser Beitrag untersucht ein asynchrones Selbstlernangebot, das zeit- und ortsunabhängiges Lernen ermöglicht. Trotz dieser Flexibilität bleibt die Betreuung durch Lehrende essenziell, um fachliche Fragen zu klären, Motivation zu fördern und Feedback zu geben. Ohne diese Unterstützung können isolierte Lernsituationen und erhöhte Dropout-Raten entstehen. Da Lehrende oft nur begrenzte Einblicke in den Lernfortschritt haben, bieten Learning Analytics eine Lösung durch systematische Datensammlung und -auswertung, um gezielte Anpassungen und Interventionen vorzunehmen.

Steuerung von digitalen Selbstlernkursen mittels Learning Analytics

Seit den 1990er Jahren wird selbstgesteuertes Lernen – als ein zentrales Merkmal digitaler Selbstlernkurse – intensiv erforscht. Hattie und Timperley (2007) betonen die Rolle von Feedback, während Ifenthaler und Drachler (2019) auf die Bedeutung von Learning Analytics zur Analyse des Lernverhaltens und zur Umsetzung von Interventionen hinweisen. Leitner und Ebner (2017) heben hervor, dass Learning Analytics zur Identifikation von Risikogruppen und Reduzierung von Dropout-Raten genutzt werden kann. Der Beitrag orientiert sich an Studien zu datengesteuerter Entscheidungsfindung (Kaspi & Venkatraman, 2023) und evidenzbasierten Interventionen (Utamachant et al., 2023) und folgt einem Design-Based Research (DBR)-Ansatz, um die Lernumgebung iterativ zu optimieren (Bakker & Van Eerde 2015).

Der untersuchte Selbstlernkurs

Die Datenerhebung und -analyse erfolgte an dem digitalen Selbstlernkurs »Einführung in die Betriebswirtschaftslehre« (EBWL), der in einem Konsortium von sieben Hochschulen in NRW entwickelt wurde und curricular eingesetzt wird. Der Kurs umfasst eine narrative Rahmung, Lehrvideos, ein animiertes Glossar, Skripte, interaktive Vertiefungstexte, Tests, Quizze sowie Lektions- und einen Kursabschlussstest. Der Kurs ist über Moodle jederzeit zugänglich. Der Ablauf ist sequentiell und Lerneinheiten werden erst

nach Abschluss der vorherigen freigeschaltet. Studierende sammeln Punkte, hauptsächlich durch Lektionsabschlussstests (LAT – jeweils 100 Punkte) und den Kursabschlussstest (KAT – 300 Punkte), deren Fragen zufällig aus lektions-spezifischen Fragen-Pools gezogen werden (>1.500 Fragen in verschiedenen Fragetypen).

Datenauswertung

Aus bisherigen Forschungsarbeiten (siehe Abschnitt 2) lassen sich drei Steuerungsdimensionen (SD) identifizieren:


- **SD1:** Langfristige Kursoptimierung (z.B.: Weiterentwicklung des Kursdesigns, Implementierung neuer Lernelemente) – z.B. Buckingham Shum et al., 2019
- **SD2:** Ad-hoc-Kursoptimierungen (z.B.: Identifikation von inhaltlichen/formalen Fehlern) – z.B. Kaspi & Venkatraman, 2023
- **SD3:** Kommunikation und Motivation (z.B.: (Teil-)Automatisierte Nachrichten an Studierende/Studierendengruppen; motivationale Elemente) – z.B. Utamachant et al., 2023

Die Datenanalyse sowie die daraus abgeleiteten Empfehlungen für Maßnahmen, Interventionen und zur Kommunikation werden nun anhand dieser Dimensionen erläutert. Alle im Folgenden dargestellten Interventionsmechanismen wurden tatsächlich im dargestellten Kurs erprobt.

SD1: Langfristige Kursoptimierung

a) Testergebnisse: Einzelne Testergebnisse weichen signifikant vom errechneten Mittelwert ab (vgl. Abb. 1).

Abb. 1: Abweichende Testelemente




Lektionsabschlussstests (LAT): IX-5, XII-4

Zwischentests: XII-1, XII-2, XIII-4, XIII-6, XVI-4, I-4, XCIII-5, XI-5

Maßnahmen: Dies ermöglicht Lehrenden, gezielt Tests zu identifizieren und zu überarbeiten die auffallend erfolgreich oder unerfolgreich absolviert werden.

b) Erfolgsquoten: Der durchschnittliche Prozentsatz der erreichten Punkte im Zeitverlauf lässt sich – auf Basis einer Clusteranalyse (sortiert nach durchschnittlichem Testzeitpunkt) – in drei Gruppen differenzieren (vgl. Abb. 2): früh Lernende, konstant Lernende und spät Lernende. Die Gruppe der »Früh Lernenden« zeigt dabei anfangs hohe Durchschnittswerte, die im Laufe der Zeit leicht abnehmen, während die »Konstant Lernenden« stabile Durchschnittswerte aufweisen. »Späte Lernende« beginnen später im Kursverlauf, zeigen jedoch eine steigende Tendenz in den erreichten Prozentzahlen.

Abb. 2: Durchschnittlicher Prozentsatz nach Gruppen




Maßnahmen: Das vorliegende Muster bietet Lehrenden die Möglichkeit, gezielte Interventionen für späte und unregelmäßige Lernende durch frühzeitige Erkennung dieser Gruppen zu entwickeln, etwa durch motivierende Mitteilungen oder gezielte Unterstützung, sowie die Kurskonzeption so zu gestalten, dass frühes und kontinuierliches Lernen stärker gefördert und damit dafür Anreize geschaffen werden.

b) Leistungsprofil nach Testtyp und Testzeitpunkt: Der durchschnittliche Prozentsatz der erreichten Punkte kann nach Testtypen und Testzeitpunkten (z.B. Lektionsabschlussstests, Kursabschlussstests) differenziert werden. Dabei lassen sich drei Gruppen identifizieren (Abb. 3): »frühe Finalisten« mit niedrigen Erfolgen (1), die »Hauptgruppe« mit konstant hohen Ergebnissen im Kursabschlussstest (2), und »späte Finalisten« (3), die erst spät beginnen und ebenfalls geringe Punktzahlen erzielen. Es zeigt sich, dass nicht nur der Startzeitpunkt, sondern auch die kontinuierliche Teilnahme entscheidend für den Lernerfolg ist.

Abb. 3: Erfolg nach Datum und Testtyp

- 1: frühe Finalisten mit niedrigen Erfolgen im Kursabschlusstest
- 2: Hauptgruppe mit konstant hohen Ergebnissen im Kursabschlusstest
- 3: späte Finalisten mit niedrigen Erfolgen im Kursabschlusstest



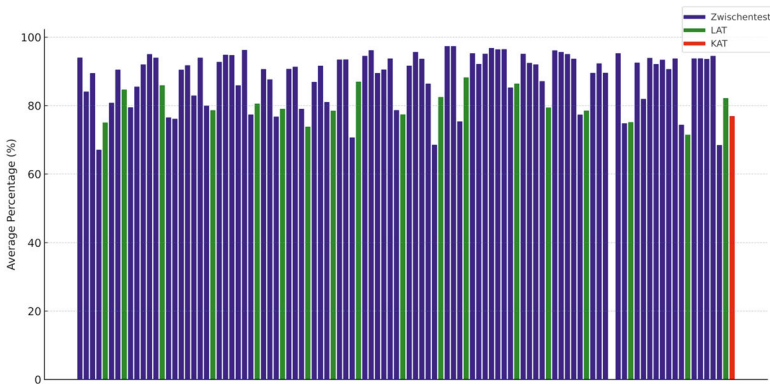
Maßnahmen: Zielgerichtete Interventionen können an den spezifischen Bedürfnissen der jeweiligen Gruppen ansetzen.

SD2: Ad-hoc-Kursoptimierungen

a) Testergebnisse: Abb. 4 zeigt die durchschnittlichen Testresultate.


Maßnahmen: Ausreißer können z.T. auf einen Fehler im Kurs zurückgeführt und ad hoc-behoben werden.

Abb. 4: Durchschnittliche Testresultate




a) Automatisierte Mitteilungen: Abb. 5 zeigt die Anzahl der Zugriffe (Seitenaufrufe) pro Woche im Verlauf des Semesters. Im Kursverlauf wurden automatisiert Nachrichten (»Pulse-Mitteilungen«) an Studierende versandt, die bisher noch geringe Beteiligungswerte am Kurs hatten. Diese Mitteilungen forderte Sie auf, sich zeitnah stärker im Kurs zu engagieren, um den Kurs erfolgreich zu absolvieren. Die sichtbare Steigerung der Lernaktivitäten nach den Mitteilungen zeigt, dass gezielte, motivierende Nachrichten ein wirksames Instrument zur Steuerung von Selbstlernprozessen darstellen.

Abb. 5: Zeitachse der Zugriffe (Seitenaufrufe) mit Zeitpunkten (1. und 2.) automatisierter Benachrichtigungen



b) Dropouts: Die Analyse der letzten abgeschlossenen Tests zeigt, dass Dropouts sich auf bestimmte Tests konzentrieren, was auf kritische Lernelemente hinweist (Abb. 6). Der Vergleich der durchschnittlichen Punktzahlen der Dropouts (79,56 %) mit den Nicht-Dropouts (85,17 %) zeigt nur eine geringe Differenz, was darauf hinweist, dass die Abbrecher ähnliche Leistungen erbrachten. Dies lässt die Schlussfolgerung zu, dass der Kursabbruch oft nicht auf mangelndem Verständnis, sondern auf externen Faktoren wie Zeitdruck, fehlender Motivation oder persönlichen Umständen basiert.

Abb. 6: Dropouts



Maßnahmen: Für die Kurssteuerung bedeutet dies, dass Interventionen nicht allein auf die Verbesserung der Testresultate abzielen sollten, sondern auch unterstützende Maßnahmen zur Steigerung der Motivation, zum besseren Zeitmanagement und zur persönlichen Betreuung notwendig sind, um Dropouts präventiv entgegenzuwirken.

Zusammenfassung

Langfristige Kursoptimierung (SD1): Analysiert signifikante Abweichungen und Korrelationen von Testergebnissen, um gezielte Interventionen zu entwickeln und das Kursdesign anzupassen.

Ad-hoc-Kursoptimierungen (SD₂): Nutzt zeitliche Analyse der Testergebnisse, um Fehler im Kurs zu identifizieren und Inhalte in Echtzeit anzupassen.

Kommunikation und Motivation (SD₃): Überwacht die Testaktivität und Dropout-Muster, um motivationsfördernde Maßnahmen wie Pulse-Mitteilungen gezielt einzusetzen.

Fazit und Ausblick

Es konnte gezeigt werden, dass Lehrende in digitalen Selbstlernkursen durch die Auswertung der in Moodle vorliegenden Daten Lernprozesse ihrer Studierenden besser verstehen und steuern können. Insbesondere die Identifikation technischer Fehler und Risikogruppen sowie die Analyse von Dropout-Raten bieten Einblicke, die zur Optimierung der Kursgestaltung und zur Entwicklung gezielter Interventionsmaßnahmen beitragen können. Allerdings bleibt eine zentrale Einschränkung bestehen: Learning Analytics zeigen meist nur, *was* Studierende tun, aber nicht *warum* (Buckingham Shum et al., 2019). Deshalb erfordert ihre Anwendung fundiertes didaktisches Wissen und eine kontextsensitive Dateninterpretation. Zukünftige Arbeiten sollten die Ergebnisse in ein umfassenderes Modell integrieren, um Learning Analytics gezielter für die Steuerung von Selbstlernprozessen einsetzen zu können.

Literatur

- Bakker, A., & van Eerde, D. (2015). An Introduction to Design-Based Research with an Example from Statistics Education, In: A. Bikner-Ahsbals, C. Knipping, & N. Presmeg (Eds.), *Approaches to Qualitative Research in Mathematics Education: Examples of Methodology and Methods* (pp. 429–466). Springer.
- Buckingham Shum, S, Ferguson, R & Martinez-Maldonado, R 2019, Human-centred learning analytics, In: *Journal of Learning Analytics*, vol. 6, no. 2, pp. 1–9.
- Hattie, J. & Timperley, H. (2007). *The power of feedback*. In: *Review of Educational Research*, 77(1), pp. 81–112.

- Ifenthaler, D., Drachsler, H. (2018). Learning Analytics. In: Niegemann, H., Weinberger, A. (eds) *Lernen mit Bildungstechnologien*. Springer Reference Psychologie. Springer, Berlin, Heidelberg.
- Kaspi, Samuel & Venkatraman, Sitalakshmi. (2023). Data-Driven Decision-Making (DDDM) for Higher Education Assessments: A Case Study. In: *Systems*. 11. 306
- Leitner, P, Khalil, M & Ebner, M 2017, Learning Analytics in Higher Education — A Literature Review. in A Peña-Ayala (ed.), *Learning Analytics: Fundamentals, Applications, and Trends*. vol. 94, Studies in Systems, Decision and Control, Springer International Publishing AG
- Utamachant, P., Anutariya, C. & Pongnumkul, S. i-Ntervene: applying an evidence-based learning analytics intervention to support computer programming instruction. *Smart Learn. Environ.* 10, 37 (2023).

Satzungen als taugliche Rechtsgrundlage für den Einsatz von Learning Analytics in Hochschulen¹

Gerrit Hornung und Hendrik Link

Für die Datenverarbeitung im Rahmen von Learning Analytics brauchen die Hochschulen Rechtsgrundlagen i. S. d. Art. 6 DSGVO. Mangels ausreichender Rechtsgrundlagen in den Gesetzen der Bundesländer schaffen sich Hochschulen im Rahmen ihrer Satzungsautonomie eigene Rechtsgrundlagen. Dies steht zwar zunächst mit der DSGVO im Einklang. Aufgrund des mit der Datenverarbeitung einhergehenden Grundrechtseingriffs müssen allerdings auch die Vorgaben des Grundgesetzes beachtet werden. Dieser Beitrag untersucht, welche Hürden insbesondere vom Vorbehalt des Gesetzes und der Wesentlichkeitstheorie ausgehen. Anhand der Analyse von Hochschulgesetzen mehrerer Bundesländer wird gezeigt, inwiefern die Gesetze diese Anforderungen erfüllen und eine valide Satzungsermächtigung für die Hochschulen bieten.

Statutes as a Suitable Legal Basis for the Use of Learning Analytics in Higher Education Institutions

For data processing within the scope of Learning Analytics, universities need legal bases in accordance with Article 6 GDPR. In the absence of sufficient legal bases in the laws of the German federal states, universities establish their own legal bases within the framework of their statutory autonomy. Although this aligns with the GDPR, the requirements of German constitutional law must also be observed due to the fundamental rights interference inherent in data processing. This article examines the key constitutional challenges. Through an analysis of the university laws in several German federal states, it is shown to what extent these laws meet the requirements and provide valid statutory authorizations for universities.

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

Learning Analytics

Learning Analytics meint die Analyse von Daten, die in Lernumgebungen (wie z.B. Moodle) anfallen, mit dem Ziel, Lehr- und Lernprozesse zu unterstützen und zu verbessern (vgl. Dondorf 2022: vii; Drachler 2018: 40). Es kann an Hochschulen genutzt werden, um z.B. durch die Auswertung von Daten aus Lernmanagementsystemen die Lern-Aktivität von Studierenden dynamisch abzubilden (vgl. Geminn et al. 2023: 6). Zur Erfassung der Lernerfolge werden unausweichlich personenbezogene Daten der Studierenden verarbeitet (vgl. Geminn et al. 2023: 6), wodurch der sachliche Anwendungsbereich der DSGVO eröffnet ist. Für die Verarbeitung bedarf es einer Rechtsgrundlage i. S. d. Art. 6 DSGVO. Hier kommen die Satzungen der Hochschulen zum Tragen, die im Gegensatz zu den allgemein gehaltenen Datenschutzgesetzen sowie den Hochschulgesetzen der Länder die Datenverarbeitung von Learning Analytics schneller und spezifischer regeln können (vgl. zu generellen Vorteilen von Satzungen Schmidt-Aßmann 2023: 108ff.). So hat die Universität Kassel kürzlich Learning Analytics in ihre E-Learning-Satzung aufgenommen und erlaubt dies nun explizit zu Forschungszwecken. Dieser Beitrag untersucht die rechtliche Zulässigkeit der Praxis der Hochschulen, sich in Satzungen Rechtsgrundlagen für die Verarbeitung von personenbezogenen Daten im Kontext von Learning Analytics zu schaffen.

Satzungen als Rechtsgrundlage der Datenverarbeitung im System der DSGVO

Nach Art. 6 Abs. 1 i.V.m. Art. 5 Abs. 1 lit. a DSGVO muss die Datenverarbeitung durch eine der Rechtsgrundlagen des Art. 6 Abs. 1 UAbs. 1 lit. a – f DSGVO legitimiert sein. Die Einwilligung (lit. a) scheidet in vielen Konstellationen in Hochschulen aus. Ist ein Hochschulabschluss ohne die Datenverarbeitung nicht zu erlangen, etwa weil die entsprechende Softwareverwendung in Kursen oder Prüfungen vorgeschrieben ist, muss die gebotene Freiwilligkeit der Einwilligung verneint werden (vgl. Geminn et al. 2023: 11; Golla 2019: § 23 Rn. 87). Jedoch kann Art. 6 Abs. 1 UAbs. 1 lit. e DSGVO als Rechtsgrundlage für eine Datenverarbeitung, die im öffentlichen Interesse liegt, herangezogen werden. Diese Rechtsgrundlage ist allerdings nur eine »Scharniernorm« (vgl. Roßnagel 2025: Art. 6 Abs. 1 DSGVO Rn. 73), für die es nach Art. 6 Abs. 3 S. 1 DSGVO einer entsprechenden Rechtsgrundlage im Recht der Mitgliedstaaten (lit. b) bedarf.

Es ist jedoch keine Norm in den Hochschulgesetzen der Länder ersichtlich, welche die Datenverarbeitung in Bezug auf Learning Analytics explizit regelt (der Referentenentwurf des Hochschulstärkungsgesetzes für NRW sieht in § 8a Abs. 3 S. 1 HG NRW-RefE eine solche Rechtsgrundlage vor, <https://www.mkw.nrw/hochschulstaerkungsgesetz>). Somit bleibt in Bezug auf das formelle Landesrecht der Rückgriff auf datenverarbeitungsbezogene Generalklauseln, die es in der überwiegenden Zahl der Hochschulgesetze gibt. Diese erlauben Datenverarbeitungen, soweit dies für die Erfüllung der Aufgaben der Hochschulen (hier der Durchführung der Lehre) erforderlich ist. In den anderen Ländern könnte auf die Generalklauseln der Datenschutzgesetze rekurriert werden. Diese verlangen lediglich, dass die Verarbeitung für die Erfüllung der in der Zuständigkeit des Verantwortlichen liegenden Aufgabe erforderlich ist.

Für die Verarbeitung von sensiblen Daten mit weitreichenden Analysemethoden, wie einer KI-basierten Ermittlung des Wissensstands von Studierenden, dürften diese Generalklauseln – sowohl in den Datenschutzgesetzen als auch in Hochschulgesetzen – jedoch zu unbestimmt sein (vgl. Geminn et al. 2023: 35). Deshalb ist es ratsam, Learning Analytics auf eine speziellere Rechtsgrundlage zu stützen, die sich einige Hochschulen in Satzungen geschaffen haben. Satzungen sind Rechtsvorschriften, die von einer »dem Staat eingeordneten juristischen Person des öffentlichen Rechts im Rahmen der ihr gesetzlich verliehenen Autonomie mit Wirksamkeit für die ihr angehörigen und unterworfenen Personen erlassen werden« (BVerfGE 10, 20 (49f.); 33, 125 (159)). In Art. 6 DSGVO finden sich keine Aussagen, ob Satzungen als Rechtsgrundlage der Mitgliedstaaten i. S. d. Art. 6 Abs. 3 S. 1 lit. b DSGVO herangezogen werden können. EG 41 S. 1 DSGVO konkretisiert aber, dass es sich nicht notwendigerweise um ein Parlamentsgesetz handeln muss. Damit genügen auch Satzungen oder Rechtsverordnungen (vgl. Roßnagel 2025: Art. 6 Abs. 3 DSGVO Rn. 21; Albers/Veit 2024: Art. 6 DSGVO Rn. 80; Assion et al. 2018: Art. 6 DSGVO Rn. 152; Johannes et al. 2023: 718).

Vorgaben des Grundgesetzes

Allerdings bringt EG 41 S. 1 DSGVO zum Ausdruck, dass bei nationalen Rechtsgrundlagen auch die Vorgaben des nationalen Rechts zu berücksichtigen sind (vgl. Assion et al. 2018: Art. 6 DSGVO Rn. 152). Verlangt dieses – etwa bei erheblichen Grundrechtseingriffen – ein Parlamentsgesetz als Rechtsgrundlage,

genügen niederrangige Vorschriften, wie Satzungen, nicht (vgl. Buchner/Petri 2024: Art. 6 DSGVO Rn. 94).

Vorbehalt des Gesetzes

Grundsätzlich können Grundrechtseingriffe auf Satzungen gestützt werden (vgl. Detterbeck 2017: § 13 Rn. 847). Nach dem Vorbehalt des Gesetzes sind Grundrechtseingriffe allerdings nur auf Grundlage eines Gesetzes gestattet (vgl. BVerfGE 133, 112 (132)). Satzungen als staatlich abgeleitetes Recht müssen deshalb auf einer formellen gesetzlichen Ermächtigungsgrundlage beruhen (vgl. Grzeszick 2024: Art. 20 GG Rn. 177; Detterbeck 2017: § 13 Rn. 846), wenn nicht – woran es im Hochschulbereich fehlt – schon eine verfassungsunmittelbare Grundlage greift (vgl. Sachs 2014: 165).

Wesentlichkeitstheorie

Nach der den Gesetzesvorbehalt weiterführenden Wesentlichkeitstheorie (vgl. Lerche 2009: § 62 Rn. 55) bleiben die wesentlichen Entscheidungen dem Parlament – als Organ mit höchster demokratischer Legitimität (vgl. Sachs 2021: Art. 20 GG Rn. 38) – vorbehalten. Der Gesetzgeber hat in grundlegenden normativen Bereichen, zumal im grundrechtsrelevanten Bereich, alle Entscheidungen selbst zu treffen (vgl. BVerfGE 49, 89 (LS. 2); Kotzur 2021: Art. 20 GG Rn. 156; Wolff 2022: § 15 Rn. 125). Das vorbehaltensauslösende Merkmal der Grundrechtsrelevanz hat die Intensität der Grundrechtsbetroffenheit als Maßstab (vgl. Kotzur 2021: Art. 20 GG Rn. 157). Diese Grundrechtsbetroffenheit ist bei einer hohen Intensität von Grundrechtseingriffen gegeben (vgl. BVerfGE 98, 218 (252); BVerfGE 58, 257 (274); Sommermann 2024: Art. 20 GG Rn. 276ff.; Lerche 2009: § 62 Rn. 54; Degenhardt 2022: Rn. 332ff.). Wie jede staatliche Verarbeitung personenbezogener Daten (BVerfGE 65, 1; vgl. Di Fabio 2024: Art. 2 Abs. 1 GG Rn. 176) ist Learning Analytics ein Eingriff in das Grundrecht auf informationelle Selbstbestimmung. Die Eingriffsintensität wird im Regelfall hoch sein. Durch die Möglichkeit, sensible Daten der Studierenden, bspw. die Lernfortschritte in verschiedenen Fächern, zu kumulieren, können sehr aussagekräftige Profile erstellt werden. Diese Sammlung umfangreicher Informationen ist aufgrund der Aussagekraft besonders anfällig, um über den Zweck des Lernmanagements hinaus genutzt zu werden (vgl. Golla 2019: § 23 Rn. 88).

Dieser starken Grundrechtsbetroffenheit sind die Belange der Hochschulen gegenüberzustellen. Die Wesentlichkeitstheorie findet ihre Grenzen in der Gewaltenteilung gem. Art. 20 Abs. 2 S. 2 GG (vgl. Sommermann 2024: Art. 20 GG Rn. 187). Staatliche Entscheidungen sind von den Organen zu treffen, die »nach ihrer Organisation, Zusammensetzung, Funktion und Verfahrensweise über die besten Voraussetzungen verfügen« (BVerfGE 68, 1 (86); 98, 218 (252)). Statische Parlamentsgesetze sind im Regelfall zu schwerfällig, um sich an gewandelte Verhältnisse anzupassen (Peine 2009: § 65 Rn. 54). Satzungen bewegen sich somit in einem Spannungsfeld. Einerseits sollen sie Parlament und Ministerien durch die »Aktivierung von Eigenverantwortlichkeit von abgrenzbaren Subsystemen entlasten« (Ellerbrok 2022: 320), andererseits muss ein hinreichendes Legitimationsniveau (vgl. BVerfGE 83, 60 (72); 93, 37 (67); 107, 59 (87)) dadurch gewahrt bleiben, dass die Festlegung der wesentlichen Aspekte durch die Legislative erfolgt.

Anwendung auf Learning Analytics

Aufgrund der erforderlichen Einzelfallabwägung sind keine übergreifenden Vorgaben von Rechtsprechung und Literatur dahingehend möglich, was als »wesentlich« durch den parlamentarischen Gesetzgeber zu regeln ist (vgl. Kalscheuer/Jacobsen 2018: 524). Für den Grundrechtseingriff durch Learning Analytics lassen sich folgende spezifische Vorgaben für Satzungen skizzieren:

1. Es muss geregelt sein, wer die Satzung beschließen darf.
2. Die Rechtsgrundlage muss zumindest den übergeordneten Zweck der Datenverarbeitung enthalten, hier also Lehre oder Forschung (oder beides).
3. Das eingesetzte Mittel muss in der Ermächtigung zumindest grob vorgezeichnet sein, also die Verarbeitung personenbezogener Daten der Studierenden. Deshalb sind allgemeine Satzungsermächtigungen (z.B. § 2 Abs. 4 Satz 1 HG NRW oder § 36 HessHG) zu unbestimmt (vgl. Geminn et al. 2023: 36).
4. Zweifelhaft ist demgegenüber, ob zusätzlich zu fordern ist, dass Learning Analytics explizit in der gesetzlichen Satzungsermächtigung genannt wird. Dafür spricht zunächst die hohe Eingriffsintensität in das Recht auf informationelle Selbstbestimmung aus Art. 2 Abs. 1 GG i. V. m. Art. 1 Abs. 1 GG. Andererseits gehört die Ausgestaltung der Lehre zum Kernbereich der universitären Aufgaben und wird durch Art. 5 Abs. 3 GG grundrechtlich verbürgt. Zudem wird angeführt, dass es der Zielrichtung der ausge-

gliederten, mittelbaren Staatsverwaltung zuwiderlaufen würde, wenn konkrete gesetzliche Vorgaben zur Ausgestaltung der Satzung verlangt werden (s. Ellerbrok 2022: 321 mit dem Argument, die Anforderungen aus Art. 80 Abs. 1 S. 2 GG für Rechtsverordnungen dürften eben nicht analog angewandt werden). Weiter ist die Effizienzsteigerung bei der Frage nach demokratischer Legitimation zu bedenken (vgl. Petersen 2013: 845). Eine Satzungsermächtigung hätte einen hohen Regelungsaufwand zur Folge, sollte jede technische Anwendung zur Unterstützung der Lehre (digitale Lernplattformen, einzelne Dienste, Einsatz von KI etc.) spezifisch aufgeführt werden. Die Hochschulen zeichnen sich zudem durch eine besondere Sachnähe zur Regelungsmaterie aus. Unter Berücksichtigung dieser Faktoren kann nicht gefordert werden, Zweck und Umfang einer Datenverarbeitung zu spezifisch vorzugeben.

Nach der hier vertretenen Auslegung muss das Gesetz damit nicht weiter ins Detail gehen und etwa Learning Analytics *expressis verbis* erlauben. Wenn eine Satzungsermächtigung die Datenverarbeitung zum Zwecke der Forschung oder der Lehre enthält, darf die entsprechende Satzung Verfahren von Learning Analytics vorsehen, ohne gegen die Wesentlichkeitstheorie zu verstoßen. Da die Frage allerdings bisher in keiner Weise gerichtlich geklärt ist, ist den Landesgesetzgebern dennoch zu spezifischeren Satzungsermächtigungen zu raten, um den Hochschulen bei der Gestaltung einer zukunftsorientierten Lehre Rechtssicherheit zu geben.

Anwendung auf die Bundesländer

Hält man eine explizite Satzungsermächtigung nicht nur für rechtsstaatlich begrüßenswert, sondern für verfassungsrechtlich erforderlich, so ist Learning Analytics in Hochschulen nach geltendem Recht bundesweit unzulässig. Denn die Hochschulgesetze enthalten (bis zum Inkrafttreten von Regelungen wie § 8a Abs. 3 S. 1 HG NRW-RefE, s.o.) durchgängig nicht nur selbst keine Verarbeitungsgrundlage, sondern es fehlt auch an einer Satzungsermächtigung, die Learning Analytics ausdrücklich umfasst. Folgt man dagegen der hier vertretenen Ansicht, so bedarf es (lediglich, aber immerhin) einer Satzungsermächtigung, die es Hochschulen erlaubt, die Datenverarbeitung in der Lehre eigenständig in Satzungen zu regeln. Klammert man die nicht ausreichenden allge-

meinen Satzungsermächtigungen aus (s. o.), so lassen sich die Hochschulgesetze der Bundesländer in drei Gruppen unterteilen:

1. Einige Länder (Bayern, Brandenburg, Hessen, Nordrhein-Westfalen, Rheinland-Pfalz) haben lediglich sehr spezifische Rechtsgrundlagen und Satzungsermächtigung für die Datenverarbeitung, etwa hinsichtlich (Fern-)Prüfungen oder der Qualitätssicherung.
2. Andere Hochschulgesetze enthalten neben einer Generalklausel für die Datenverarbeitung eine entsprechende allgemeine Satzungsermächtigung (Baden-Württemberg: § 12 Abs. 1, 3 LHG BW; Berlin: §§ 6 Abs. 1, 6b Abs. 2 BerlHG; Bremen: § 11 Abs. 1, 4 BremHG; Hamburg: § 111 Abs. 1, 8 HmbHG; Mecklenburg-Vorpommern: § 7 Abs. 1, 4 LHG M-V; Sachsen: § 15 Abs. 1, 3 SächsHSG; Sachsen-Anhalt: § 119 Abs. 1, 5 HSG LSA); Niedersachsen kennt mit § 17 Abs. 1 S. 1 NHG zwar eine Generalklausel für die Datenverarbeitung, die Satzungsermächtigung ist jedoch sehr spezifisch. Hier ist keine passende Satzungsermächtigung für Learning Analytics ersichtlich, um das Nähere dieser Verarbeitung auszugestalten.
3. Wieder andere Hochschulgesetze (Saarland: § 3 Abs. 13 SHSG; Schleswig-Holstein: § 45 S. 1, 3 HSG SH; Thüringen: § 11 Abs. 1, 4 ThürHG) enthalten zwar eine Generalklausel für die Datenverarbeitung, hier soll Näheres aber durch eine Rechtsverordnung der Ministerien und nicht etwa durch eine Satzung der Hochschulen geregelt werden. Entsprechende Rechtsverordnungen (Schleswig-Holstein (StudDatenVO) und Thüringen (ThürHDataVO)) beziehen sich jedoch eher auf administrative Aufgaben und werden im Folgenden nicht berücksichtigt.

Bundesländer ohne allgemeine Satzungsermächtigung zur Verarbeitung

Bundesländer, die weder eine Generalklausel noch eine allgemeine Satzungsermächtigung gerade für die Verarbeitung von personenbezogenen Daten haben, erlauben diese Verarbeitung typischerweise in Bezug auf einzelne, spezifische Hochschulaufgaben. So regelt z.B. das Hessische Hochschulgesetz (HessHG) über 40 Satzungsermächtigungen, die teils explizit die Verarbeitung von personenbezogenen Daten umfassen. Bei diesen Ermächtigungen ist der Zweck der Satzung genau festgelegt. So dürfen diese das Nähere zur Verarbeitung etwa zu Qualitätssicherung und Berichtswesen (§ 14 HessHG), Fernprüfungen (§ 23 Abs. 6 HessHG) oder Drittmittelforschung (§ 34 HessHG) regeln. Dagegen ist keine Satzungsermächtigung ersichtlich, die es erlaubt,

die Verarbeitung von personenbezogenen Daten in der Lehre selbst zu regeln. Insbesondere enthält die Ermächtigung für Studien- und Prüfungsordnungen in § 25 HessHG keine derartige Befugnis (zu Möglichkeiten, eine entsprechende Satzung in Nordrhein-Westfalen rechtskonform auszugestalten, siehe Geminn et al. 2023: 36ff.).

Bundesländer mit allgemeiner Satzungsermächtigung zur Verarbeitung

Als Repräsentant der Bundesländer, deren Hochschulgesetze neben einer gesetzlichen Generalklausel auch eine allgemeine datenverarbeitungsbezogene Satzungsermächtigung für die Regelung der näheren Umstände und Details der Verarbeitung haben, dient Hamburg. Hier findet sich in § 111 Abs. 1 S. 1 HmbHG eine Generalklausel, die eine Vielzahl von Verarbeitungen legitimiert, u.a. die erforderliche Verarbeitung personenbezogener Daten im Rahmen von Lehrveranstaltungen (7. Var.) und Prüfungen (8. Var.). Die Satzungsermächtigung in § 111 Abs. 8 HmbHG ist entsprechend breit. Danach dürfen die Hochschulen näheres durch Satzung regeln, nach § 111 Abs. 8 Nr. 1 HmbHG insbesondere, welche Daten nach Abs. 1 – 3 verarbeitet werden dürfen. Aus § 111 Abs. 1, 8 HmbHG ergeben sich die notwendigen Festlegungen (s. o.): Es ist geregelt, wer die Satzung erlassen darf (die Hochschulen), und der übergeordnete Zweck der Datenverarbeitung (Lehre bzw. Lehrveranstaltungen) ist angegeben. Eine Satzung, die sodann die benötigten Daten samt dem Zweck Learning Analytics festschreibt, wäre hiernach zulässig. Bisherige Satzungen, so die der Universität Hamburg (<https://www.uni-hamburg.de/uhh/organisation/stabsstellen/recht/gesetze-verordnungen-satzungen.html>), nutzen diesen Spielraum bisher jedoch kaum aus, sondern beschränken die genannte Datenverarbeitung eher auf administrative Tätigkeiten.

Ergebnis

Für die Verarbeitung von personenbezogenen Daten im Kontext von Learning Analytics bedarf es im Regelfall nach Art. 6 Abs. 1 UAbs. 1 lit. e, Abs. 3 lit. b DSGVO einer Rechtsgrundlage des nationalen Rechts. Diese kann sich auch aus untergesetzlichem Recht, wie einer Satzung, ergeben. Satzungen sind aufgrund ihrer Flexibilität ein geeignetes Werkzeug, um in Hochschulen die Verarbeitung von personenbezogenen Daten zu legitimieren. Auch der Einsatz von Learning Analytics lässt sich grundsätzlich darauf stützen. Aufgrund

des Grundrechtseingriffs durch die Datenverarbeitung müssen allerdings die Vorgaben des Grundgesetzes gewahrt bleiben. So bedarf es aufgrund des Vorbehalts des Gesetzes einer Ermächtigungsgrundlage für den Erlass der Satzung. Diese Rechtsgrundlage muss nach der Wesentlichkeitstheorie den intensiven Grundrechtseingriff durch Learning Analytics durch Bestimmung des Zwecks und des Mittels vorzeichnen. So muss das Landesrecht enthalten, dass die Verarbeitung von personenbezogenen Daten in Zusammenhang mit der Lehre durch Satzung geregelt werden kann.

Solche Ermächtigungsgrundlagen für den Erlass von Satzungen sind in manchen Hochschulgesetzen enthalten. Legitimieren sie dazu, die Datenverarbeitung – u.a. in der Lehre – genauer auszugestalten, können die Hochschulen hiervon Gebrauch machen, um die Datenverarbeitung für Learning Analytics auf eine valide Rechtsgrundlage zu stützen. Fehlt es an einer Grundlage, so ist der Gesetzgeber gefordert, i. S. d. Wesentlichkeitstheorie Satzungen die nötige demokratische Legitimität zu verleihen.

Angesichts der bestehenden Rechtsunsicherheiten auch für die erste Gruppe von Ländern ist im Ergebnis allerdings allen Bundesländern zu raten, spezifischere Satzungsermächtigungen zu erlassen, um den Hochschulen die gebotene Rechtssicherheit für den Technologieeinsatz in der Lehre zu bieten. Solange Gesetzgeber und Hochschulen sich nicht in gebotener Maß mit den Rechtsgrundlagen für die Datenverarbeitung in der Lehre auseinandersetzen, bleibt die Rechtmäßigkeit der Verarbeitung personenbezogener Daten für Learning Analytics fraglich – eine unbefriedigende Situation sowohl für Lehrende als auch für Studierende angesichts der didaktischen Chancen derartiger Anwendungen.

Literatur

- Albers, Marion/Veit, Raoul-Darius (2024): »Art. 6 DS-GVO«, in: Wolff, Heinrich A./Brink, Stefan/von Ungern-Sternberg, Antje (Hg.): BeckOK Datenschutzrecht, 49. Ed., München: C.H. Beck.
- Assion, Simon (2018): »Art. 6 DS-GVO«, in: Gierschmann, Sibylle/Schlender, Katharin/Stentzel, Rainer/Veil Winfried (Hg.): Kommentar Datenschutz-Grundverordnung, Köln: Bundesanzeiger Verlag.
- Buchner, Benedikt/Petri, Thomas (2024): »Art. 6 DS-GVO«, in: Kühling, Jürgen/Buchner, Benedikt (Hg.): Datenschutz-Grundverordnung, Bundesdatenschutzgesetz: DS-GVO/BDSG, 4. Aufl., München: C.H. Beck.

- Degenhart, Christoph (2022): Staatsorganisationsrecht, 38. Aufl., Heidelberg: C.F. Müller.
- Detterbeck, Steffen (2017): Allgemeines Verwaltungsrecht, 15. Aufl., München: C.H. Beck.
- Di Fabio, Udo (2024): »Art. 2 GG«, in: Dürig, Günter/Maunz, Theodor (Begr.), Herzog, Roman/Scholz, Rupert/Herdegen, Matthias/Klein, Hans H. (Hg.): Grundgesetz Kommentar, 104. Aufl., München: C.H. Beck.
- Dondorf, Thomas (2022): Learning analytics for Moodle: facilitating the adoption of data privacy friendly learning analytics in higher education, Dissertation, Bauingenieurwesen, Aachen. <https://doi.org/10.18154/RWTH-2022-04002>
- Drachsler, Hendrik (2018): »Trusted Learning Analytics«, in: Synergie 6, S. 40–43. <https://doi.org/10.25657/02.19141>
- Ellerbrok, Torben (2022): »Die öffentlich-rechtliche Satzung«, in: Zeitschrift für das Juristische Studium (ZJS) 15 (3), S. 319–326.
- Geminn, Christian L./Johannes, Paul C./Nebel, Maxi/Bile, Tamer (2023): Datenschutzrechtliche Beurteilung von Learning Analytics an Hochschulen in NRW, Bochum: Ruhr-Universität Bochum, Universitätsbibliothek. <https://doi.org/10.13154/294-9657>
- Golla, Sebastian (2019): »§ 23 Datenschutz in Forschung und Hochschullehre«, in: Specht-Riemenschneider, Louisa/Mantz, Reto (Hg.): Handbuch Europäisches und deutsches Datenschutzrecht, München: C.H. Beck, S. 646–672.
- Grzeszick, Bernd (2024): »Art. 20 GG«, in: Dürig, Günter/Maunz, Theodor (Begr.), Herzog, Roman/Scholz, Rupert/Herdegen, Matthias/Klein, Hans H. (Hg.): Grundgesetz Kommentar, 104. Aufl., München: C.H. Beck.
- Johannes, Paul C./Nebel, Maxi/Geminn, Christian L. (2023): »Learning Analytics nach Satzung«, in: Datenschutz und Datensicherheit (DuD) 47 (11), S. 715–720. <https://doi.org/10.1007/s11623-023-1849-y>
- Kalscheuer, Fiete/Jacobsen, Annika (2018): »Kiel, Der Parlamentsvorbehalt: Wesentlichkeitstheorie als Abwägungstheorie«, in: Die Öffentliche Verwaltung (DÖV) 71 (13), S. 523–530.
- Kotzur, Markus (2021): »Art. 20 GG«, in: von Münch, Ingo/Kunig, Philip (Begr.), Kämmerer, Jörn-Axel/Kotzur, Markus (Hg.): Grundgesetz Kommentar, Bd. 1, 7. Aufl., München: C.H. Beck.
- Lerche, Peter (2009): »§ 62 Vorbehalt des Gesetzes und Wesentlichkeitstheorie«, in: Merten, Detlef/Papier, Hans-Jürgen (Hg.): Handbuch der Grund-

- rechte in Deutschland und Europa. Band III: Grundrechte in Deutschland – Allgemeine Lehren II, Heidelberg: C.F. Müller, S. 301–332.
- Peine, Franz-Joseph (2009): »§ 65 Grundrechtsbeschränkungen in Sonderstatusverhältnissen«, in: Merten, Detlef/Papier, Hans-Jürgen (Hg.): Handbuch der Grundrechte in Deutschland und Europa. Band III: Grundrechte in Deutschland – Allgemeine Lehren II, Heidelberg: C.F. Müller, S. 405–438.
- Petersen, Niels (2013): »Das Satzungsrecht von Körperschaften gegenüber Externen«, in: Neue Zeitschrift für Verwaltungsrecht (NVwZ) 32 (13), S. 841–846.
- Roßnagel, Alexander (2025): »Art. 6 DS-GVO«, In: Simitis, Spiros/Hornung, Gerrit/Spiecker genannt Döhmann, Indra (Hg.): Datenschutzrecht, 2. Auflage, Baden-Baden: Nomos.
- Sachs, Michael (2014): »Normsetzung (Rechtsverordnung, Satzung)«, in: Bultmann, Peter E./Grigoleit, Klaus J./Gusy, Christoph/Kersten, Jens/Otto, Christian-W./Preschel, Christina (Hg.): Allgemeines Verwaltungsrecht. Festschrift für Ulrich Battis zum 70. Geburtstag, München: C.H. Beck, S. 161–176.
- Sachs, Michael (2021): »Art. 20 GG«, in: Sachs, Michael (Hg.): Grundgesetz Kommentar, 9. Aufl., München: C.H. Beck.
- Schmidt-Aßmann, Eberhard (2023): Verwaltungsrechtliche Dogmatik in der Entwicklung, 2. Aufl., Tübingen: Mohr Siebeck.
- Sommermann, Karl-Peter (2024): »Art. 20 GG«, in: von Mangoldt, Hermann (Begr.), Huber, Peter M./Voßkuhle, Andreas (Hg.): Grundgesetz Kommentar, Bd. 2, 8. Aufl., München: C.H. Beck.
- Wolff, Heinrich A. (2022): »§ 15 Das rechtsstaatliche Prinzip«, in: Stern, Klaus/Sodan, Helge/Möstl, Markus (Hg.): Das Staatsrecht der Bundesrepublik Deutschland im europäischen Staatenverbund. Bd. 1, 2. Aufl., München: C.H. Beck.

Die Interdependenz von Learning Analytics und Studierenden

Implikationen studentischer Wahrnehmungen für eine sozialverantwortliche KI-Implementierung¹

Birte Keller,² Marco Lünich³ und Frank Marcinkowski⁴

Ein sozialverantwortlicher Einsatz von auf Künstlicher Intelligenz (KI) basierender Learning Analytics an Hochschulen erfordert die Einbindung aller relevanten Stakeholder, insbesondere der Studierenden als direkt Betroffene des Systems. Konzeptionelle Überlegungen und empirische Erkenntnisse aus fünf Jahren Forschung zu studentischen Wahrnehmungen von KI an deutschen Hochschulen liefern wichtige Impulse für die Gestaltung eines iterativen Prozesses zur fairen und sozialverantwortlichen Entwicklung von LA-Systemen. Dabei werden studentische Schadens- und Fairnesswahrnehmungen gegenüber KI-basierten Leistungsprognosesystemen sowie individuelle Anforderungen an das Design dieser soziotechnischen Systeme und Präferenzen der Verteilung von Fördermaßnahmen untersucht. Die gewonnenen Erkenntnisse werden vor dem Hintergrund des internationalen Forschungsstands kritisch diskutiert, um Implikationen für eine sozialverantwortliche KI-Implementierung abzuleiten.

The interdependence of learning analytics and students: Implications of student perceptions for socially-responsible AI implementation

The socially responsible use of artificial intelligence (AI)-based learning analytics (LA) at universities requires the involvement of all relevant stakeholders, especially students as those directly affected by the system. Conceptual considerations and empirical findings from five years of research on student perceptions of AI at German universities

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

2 ORCID-ID: 0000-0002-3145-5206

3 ORCID-ID: 0000-0002-0553-7291

4 ORCID-ID: 0000-0001-6497-9324

provide important impulses for the design of an iterative process for the fair and socially responsible development of LA systems. Student perceptions of harm and fairness towards AI-based performance prediction systems as well as individual requirements for the design of these socio-technical systems and preferences for the distribution of support measures are examined. The findings are critically discussed against the background of the international state of research in order to derive implications for a socially responsible AI implementation.

Einleitung

Ein sozialverantwortlicher Einsatz von KI-basierten Learning Analytics (LA) im tertiären Bildungsbereich, der fair, transparent und inklusiv gestaltet ist, erfordert die Einbindung aller relevanten Stakeholdergruppen (Keller/Lünich/Marcinkowski 2022; Lang/Davis 2023; Tsai/Whitelock-Wainwright/Gašević 2021). Neben Entwickler:innen und Hochschulverantwortlichen sind insbesondere die Studierenden von Bedeutung, da ihre Bildungswege durch Entscheidungen der vermeintlich objektiven Computerverfahren unmittelbar beeinflusst werden. Ethische Bedenken, wie Risiken der Diskriminierung (Simis/Weydner-Volkman 2024; Slade/Prinsloo 2013), machen iterative Prozesse zur sozialverantwortlichen Gestaltung solcher Systeme unverzichtbar. Andernfalls drohen die Reproduktion gesellschaftlicher Ungleichheiten und die Ablehnung des KI-Systems, wie ein Benotungsalgorithmus in Großbritannien zeigte, der Schüler:innen sozial schwächerer Familien benachteiligte (Smith 2020). Dieses Negativbeispiel verdeutlicht, dass die Einbettung von LA in den sozialen Kontext der Hochschulen und die Lebensrealität der Studierenden essenziell ist. LA-Systeme verarbeiten studentische Daten und beeinflussen gleichzeitig ihre Zukunft, was soziale Konflikte hervorrufen kann. Die Einbeziehung studentischer Wahrnehmungen in die Entwicklung fairer und sozialverantwortlicher Systeme ist daher zentral, insbesondere angesichts zentraler Herausforderungen der strategischen Planung, des Implementierungsmonitorings und der Evaluation pädagogischer Ziele (Tsai/Gasevic 2017; Tsai et al. 2020).

Im Folgenden werden Ergebnisse aus fünf Jahren empirischer Forschung zu studentischen Wahrnehmungen von KI-Anwendungen mit Fokus auf Leistungsprognosesysteme (Academic Performance Prediction Systems, kurz: APP) an deutschen Hochschulen vorgestellt. APP zählt zu den am meistbeachteten KI-Systemen im Bildungswesen (Zawacki-Richter et al. 2019; Alyahyan/

Düstegör 2020) und soll den Studienerfolg durch individuelle Unterstützungs- und Beratungsangebote auf Basis ihrer Prognosen fördern (Attaran/Stark/Stotler 2018; Daniel 2015). Die vorgestellten Studien sind Teil der Forschungsprojekte *Fair Artificial Intelligence Reasoning* (FAIR, Volkswagenstiftung) und *Responsible Academic Performance Prediction* (RAPP, BMBF [16DHB4020]). In interdisziplinärer Zusammenarbeit wurden studentische Bewertungen des Studienerfolgsbegriffs untersucht (Ülpenich et al. 2023), diskriminierungsbehaftete Einflussfaktoren zur Studienerfolgsvorhersage ermittelt (Junghänel et al., im Review) sowie Fairness- und Schadenswahrnehmungen analysiert (Keller/Lünich/Marcinkowski 2022; Lünich/Keller 2024). Auf dieser Basis wurde ein Prototyp einer sozialverantwortlichen APP-Anwendung entwickelt (Duong et al. 2023).

Das komplexe Wechselspiel von Studierenden und Learning Analytics

Stellt die Datenverfügbarkeit im digitalen Zeitalter, in dem jeder Log-in auf Lernplattformen Datenspuren hinterlässt, keine besondere Herausforderung dar (Liebowitz 2017), sind an die tatsächliche Nutzbarkeit der Daten neben technischen auch soziale und ethische Fragen geknüpft (Nguyen et al. 2023; Simis/Weydner-Volkman 2024). So bietet der Einsatz von LA Chancen wie personalisierte Lernwege und Warnsysteme zur Steigerung des Studienerfolgs (Alyahyan/Düstegör 2020; Arnold/Pistilli 2012; Chiu et al. 2023), birgt aber auch Risiken wie Benachteiligungen durch unreflektierte Entwicklungen oder fehlerhafte Dateninterpretationen (Fazelpour/Danks 2021). Durch die Einhaltung ethischer Anforderungen an *Fairness*, *Accountability* und *Transparency* sollen diese minimiert werden (Memarian/Doleck 2023), unbeabsichtigte Folgen bleiben jedoch möglich (Smuha 2022). Die Partizipation betroffener Personen im Entwicklungsprozess ist daher unerlässlich (Radtke et al. 2024), um Machtungleichgewichte gegenüber Entwickler:innen und einführenden Institutionen zu vermeiden (Kalluri 2020; Kasy/Abebe 2021; Weinberg 2022).

Eine Studie der Heinrich-Heine-Universität Düsseldorf zeigt, dass wahrgenommene Unfairness gegenüber LA die Protestbereitschaft steigert und der Reputation der Hochschule schadet (Marcinkowski et al. 2020). Vertrauen in Hochschule und System ist entscheidend für eine erfolgreiche und sozialverantwortliche Nutzung von LA (Jones/Rubel/LeClere 2020; Tsai/Whitelock-Wainwright/Gašević 2021), während Unfairnesswahrnehmungen und Datenschutzbedenken die Freigabe persönlicher Daten behindern (Keller/Lünich/

Marcinkowski 2022; Sun et al. 2019) und so die Leistungsfähigkeit von LA einschränken können (Li/Brooks/Schaub 2019).

Konzeption eines sozialverantwortlichen Academic-Performance-Prediction-Systems

Eine idealtypische Betrachtung des ethischen LA-Einsatzes (Brossi/Castillo/Cortesi 2022; Cerratto Pargman/McGrath 2021; Fazelpour/Danks 2021; Holmes/Porayska-Pomsta 2022; The Institute for Ethical AI in Education 2021; Nguyen et al. 2023; Pardo/Siemens 2014) ermöglicht die Identifikation von Stellschrauben des soziotechnischen Systems auf Input-, Throughput- und Output-Ebene, die studentische Fairnesswahrnehmungen eines sozialverantwortlichen APP-Systems adressieren (Keller/Lünich/Marcinkowski 2022; Marcinkowski/Starke 2019).

Auf der Input-Ebene sind Problemdefinition, Wahl eines Algorithmus, Auswahl der Inputdaten sowie Freiwilligkeit und Rechtmäßigkeit ihrer Nutzung essenziell. Zielsetzungen und Funktionen von APP sollten klar definiert sein (Fazelpour/Danks 2021), während White-Box-Algorithmen Transparenz und informationelle Fairness fördern (Lünich/Keller 2024; Perez Vallejos et al. 2017; Rudin 2019). Definition von soziodemografischen und leistungsbezogenen Daten sowie die Freiwilligkeit der Nutzung sind zentral für Diskriminierungsfreiheit (Keller/Lünich/Marcinkowski 2022). Auf der Throughput-Ebene beeinflussen Systemsicherheit und Fairnessnormen die Wahrnehmung. Das APP-System muss vor unbefugtem Zugriff geschützt sein (Wirtz/Weyerer/Geyer 2019), und Fairnessnormen sollten so gewählt werden, dass eine diskriminierungsfreie algorithmische Kategorisierung entsprechend der Gerechtigkeitsvorstellung im jeweiligen Kontext gewährleistet wird (Dunkelau/Duong 2022; Lepri et al. 2018; Wong 2020). Eine respektvolle Interaktion zwischen soziotechnischem System und Mensch erfordert den »human-in-the-loop«, sodass der Mensch in die Entscheidungsfindung eingebunden wird (Amershi et al. 2015; Holzinger 2016; Starke/Lünich 2020). Die Output-Ebene wird durch die Output-Kategorisierung, Transparenz und Erklärbarkeit geprägt. Während APP stets transparente Entscheidungsprozesse und klar definierte Verantwortlichkeit bei Fehlentscheidungen erfordert (Memarian/Doleck 2023), bedarf es einer Entscheidung für eine Output-Kategorisierung z.B. entlang einer Rangordnung nach Studienabbruchswahrscheinlichkeit oder anhand der Bedürftigkeit der Studierenden. Auch die auf APP beruhende

Verteilung von Unterstützungsmaßnahmen kann die Fairnesswahrnehmungen der Studierenden beeinflussen (Keller/Lünich/Marcinkowski 2022; Lünich/Keller/Marcinkowski 2024a).

Kritische Haltung Studierender gegenüber Academic Performance Prediction

Die empirischen Erkenntnisse der Autor:innen zur KI-Entwicklung an deutschen Hochschulen zeigen, dass diese im internationalen Vergleich vor wenigen Jahren noch am Anfang stand (Keller et al. 2019). Dennoch äußerten Studierende der Universität Düsseldorf bereits Bedenken gegenüber hochschulrelevanten KI-Systemen. Während »Learning Analytics« von 83,3 % befürwortet und lediglich von 16,7 % abgelehnt wurden, stießen KI-Anwendungen mit potenziellen Auswirkungen auf die persönliche Zukunft auf höhere Ablehnung, darunter automatisierte Benotungssysteme (55,3 %), KI-basierte Bewerberauswahl (60,8 %) und besonders APP-Systeme (78,8 %) (Kieslich et al. 2019).

Ein Grund für die kritische Haltung gegenüber APP könnte im wahrgenommenen Risiko liegen. Eine repräsentative Befragung von Studierenden (n = 751) und der Bevölkerung (n = 1.008) in Deutschland zeigt, dass 40,2 % der Studierenden und 37,4 % der Bevölkerung APP entsprechend der Klassifizierung des AI-Acts als Hochrisikoanwendung einordnen (Europäische Union 2024). 11 % der Studierenden halten das Risiko für inakzeptabel. Gleichzeitig zeigen 48,8 % der Studierenden und 55,2 % der Bevölkerung eine ambivalente Risikoeinschätzung, indem sie das Risiko als minimal oder begrenzt bewerten (Lünich/Keller/Marcinkowski 2024b). Studierende erwarten im Vergleich zur restlichen Bevölkerung häufiger gesellschaftliche und individuelle Schäden sowie Diskriminierung durch APP. Besonders jene, die Diskriminierung im Alltag erfahren haben, neigen dazu, größere Bedenken zu äußern (Lünich/Keller/Marcinkowski 2024b).

Eine qualitative Analyse individueller Schadenswahrnehmungen gegenüber APP zeigt vielfältige studentische Befürchtungen, die sowohl die Fairnesswahrnehmung als auch die faktische Fairness eines Systems beeinträchtigen könnten. Die Ergebnisse der Onlinebefragung von n = 1.378 deutschen Studierenden verweisen auf eine technische und soziale Dimension der wahrgenommenen Schäden. In der technischen Dimension stehen Bedenken über Fehler im KI-System im Vordergrund, wie unvollständige oder

selektive Inputdaten, die zu falschen Vorhersagen führen könnten. Technische Sicherheitsbedenken wie Hackerangriffe oder Datenschutzprobleme wurden seltener genannt. In der sozialen Dimension äußern Studierende Bedenken zu individuellen und gesellschaftlichen Folgen von APP, wie Stigmatisierung und unfaire Chancenverteilung bei Studienplätzen oder Stipendien. Zudem werden ethische Fragen zur Quantifizierung von Leistung und Vereinheitlichung von Studienverläufen aufgeworfen. Individuell wird ein Potenzial für psychische Schäden betont, da APP-Systeme Motivation, Emotionen und Leistungsdruck negativ beeinflussen könnten (Lünich/Maxhuni/Keller zur Einreichung vorbereitet; Maxhuni et al. 2023).

Differenzierte Anforderungen der Studierenden an faire Academic Performance Prediction

Angesichts der Schadenswahrnehmungen, ambivalenten Risikoeinschätzungen und identifizierten Stellschrauben eines idealtypischen APP-Systems stellt sich die Frage, wie ein faires APP-System aus Studierendensicht gestaltet werden kann und welche Anforderungen es erfüllen muss. Eine repräsentative Befragung von Studierenden ($n = 751$) zeigt differenzierte Anforderungen an ein sozialverantwortliches APP-System. Studierende legen großen Wert auf Selbstbestimmung und möchten entscheiden, ob und welche ihrer Daten für APP genutzt werden (Lünich/Keller/Marcinkowski 2024b). Dies entspricht Forderungen amerikanischer Studierender nach Kontrolle und informierter Zustimmung bei der Datennutzung (Sun et al. 2019). Die geringe Bereitschaft deutscher Studierender, persönliche Daten preiszugeben, unterstreicht die Relevanz ethisch und fair bewerteter Inputdaten (Keller/Lünich/Marcinkowski 2022). Internationale Forschung zeigt, dass Vertrauen in den ethischen Umgang mit Daten und die Abwägung zum individuellen Nutzen die Datenfreigabe fördert (Li et al. 2022). Studierende verlangen Transparenz und Erklärbarkeit. So soll ihnen ihre individuelle Leistungsprognose verständlich erklärt und jederzeit (nur) für sie persönlich einsehbar sein (Lünich/Keller/Marcinkowski 2024b).

Ein Vergleich der Anforderungen zeigt signifikante Unterschiede zwischen Studierenden mit hoher und niedriger Schadenswahrnehmung. Letztere sind häufiger bereit, ihre Daten freiwillig bereitzustellen, und befürchten seltener, dass Dozierende sie bei Einsicht in ihrer APP schlechter bewerten könnten (Lünich/Keller/Marcinkowski 2024b). Gerade die mangelnde Bereitschaft zur Da-

tenfreigabe einzelner Studierendengruppen kann sich dabei als problematisch für die Diskriminierungsfreiheit des Systems erweisen.

Neben Anforderungen an das Systemdesign fordern Studierende ebenso eine Selbstbestimmung in Bezug auf die Verteilung von Förderangeboten auf Basis von APP. Verpflichtende Maßnahmen bei schlechten Prognosen lehnen sie ab und bevorzugen unabhängige Studienberatungen gegenüber Beratungen durch eigene Dozierende (Lünich/Keller/Marcinkowski 2024b). Die Zuteilung von Fördermaßnahmen kann nach verschiedenen Verteilungsnormen erfolgen. Bei *Equality* erhalten alle Studierenden gleiche Unterstützung, bei *Equity* wird nach Leistung, und bei *Need* nach Bedürftigkeit zugeteilt (vgl. Deutsch 1975). So könnten etwa nur besonders leistungsstarke (*Equity*) oder leistungsschwache (*Need*) Studierende gezielt gefördert werden. Im Rahmen der studentischen Onlinebefragung (n = 1.378) zeigt sich jedoch eine klare Bevorzugung der *Equality*-Norm, die signifikant fairer bewertet wird als Verteilungen nach dem Leistungs- oder Bedürftigkeitsprinzip (Lünich/Keller/Marcinkowski 2024a).

Implikationen für einen sozialverantwortlichen Einsatz von Learning Analytics

Konzeptionelle und empirische Erkenntnisse aus fünf Jahren Forschung zu studentischen Wahrnehmungen von LA und APP liefern wichtige Implikationen für einen sozialverantwortlichen KI-Einsatz. Die Studien zeigen eine kritische, mitunter aber auch ambivalente Haltung der Studierenden. Sorgen vor Schäden und die Ablehnung der Datenfreigabe betonen die Notwendigkeit umfassender Leitlinien seitens der Hochschulen (Scheffel et al. 2024). Angesichts unterschiedlicher Wissensstände zwischen Studierenden, Entwickler:innen und Institutionen entstehen Fragen zu politisch-partizipatorischer und informationeller Fairness. Eine sozialverantwortliche LA-Einführung erfordert Einbezug und Transparenz, ohne Studierende zu überfordern (Lünich/Keller 2024).

Die Studienergebnisse zeigen Unterschiede in den Schadenswahrnehmungen Studierender und Forschender und unterstreichen die Relevanz der Betroffenenperspektive. Herausforderungen wie Transparenz, Fairness und Verantwortlichkeit stehen bereits im Fokus ethischer KI-Richtlinien (Hagendorff 2020; Jobin/Ienca/Vayena 2019). Allerdings fokussieren Studierende stärker auf individuelle Folgen wie Demotivation und Druck und kritisie-

ren die soziale und ethische Logik der KI. Sie hinterfragen die Kosten der Zielsetzungen, etwa die Quantifizierung von Leistung, und zweifeln die generelle Sinnhaftigkeit von LA-Systemen an (Ülpenich et al. 2023). Effizienz und Optimierung durch LA fördern eine Ethik der ständigen Verbesserung, die abweichende Perspektiven verdrängt und Handlungs- und Definitionsmacht an Maschinen überträgt. Hegemoniale Kräfteverhältnisse in der Problem- und Output-Definition können demokratischen Bildungsidealen zuwiderlaufen.

Neben den Designfaktoren der LA-Systeme müssen auch darauf basierende Interventionen und pädagogische Ansätze reflektiert werden (Tsai/Gasevic 2017; Tsai et al. 2020). Die Bewertung der Verteilung von Fördermaßnahmen wird zentral, da Studierende absolute Gleichbehandlung fordern, was die Sinnhaftigkeit der APP-Einführung infrage stellt. Individuelle Fördermaßnahmen auf Basis von APP sind zwar wichtig zur Leistungsverbesserung, doch unbegrenzte Zugänglichkeit könnte den Zweck der Implementierung untergraben. Unabhängige Beratungsangebote können hingegen die Bereitschaft zur Nutzung von Unterstützungsleistungen fördern. APP-Systeme, die aus Sicht der Studierenden primär Informationszwecken dienen sollten, werden kritisch gesehen, da sie potenziell Demotivation statt Studierenerfolg fördern. Angesichts der Abhängigkeit von freiwilliger Datenfreigabe müssen studentische Bedenken sowie Fairness- und Risikowahrnehmungen ernst genommen und integraler Bestandteil von Entwicklungs- und Implementierungsprozessen sein. Eine sozialverantwortliche LA-Entwicklung erfordert:

- **Gemeinsame Problemspezifizierung:** Akkurate LA-Anwendungen erfordern erhebliche Ressourcen. Daher muss die Definition des Problems, der Ziele, Funktionen und Grenzen gemeinsam mit allen Stakeholdern erfolgen, um Ablehnung zu vermeiden und Diskriminierung zu verhindern. Alternative Problemdefinitionen und nicht-algorithmische Lösungen sollten in Betracht gezogen werden.
- **Bedenken im Mittelpunkt:** Studentische Bedenken sind oft vielfältiger und unterscheiden sich von etablierten ethischen Richtlinien und müssen für eine verantwortungsvolle KI-Implementierung ernst genommen werden.
- **Sicherung der Diskriminierungsfreiheit:** Die Vermeidung der Reproduktion von Stereotypen und Diskriminierung in Inputdaten, algorithmischer Verarbeitung und Fördermaßnahmen muss oberste Priorität haben und darf nicht durch Trial-and-Error auf Kosten der Studierenden erreicht werden.

- **Transparenz und Verständlichkeit:** Transparenz muss gewährleistet werden, damit der KI-Einsatz nachvollziehbar bleibt, ohne die Betroffenen zu überfordern. Eine forschungsgestützte, klare Vermittlung der Anwendungsfelder und der Einsatz von White-Box-KI-Verfahren fördern Nachvollziehbarkeit und Verständnis.
- **Unabhängige Beratungsinstanzen:** Freiwillige, unabhängige Beratungsangebote und ein vertrauensvolles Umfeld können die Bereitschaft zur Nutzung von Unterstützungsleistungen steigern.
- **Fortlaufende Evaluation:** Der Einsatz von LA sollte sorgfältig geplant, verständlich erklärt und kontinuierlich unter Einbezug aller universitären Stakeholder evaluiert sowie an neue Erkenntnisse angepasst werden.

Die Entwicklung sozialverantwortlicher LA-Systeme und insbesondere akademischer Leistungsprognosen stellt eine anspruchsvolle Aufgabe dar, die ethische, technische und soziale Aspekte berücksichtigen muss. Die vorgeschlagenen Maßnahmen bieten eine Grundlage, um Akzeptanz und Wirksamkeit von LA-Systemen zu fördern. Ihre Umsetzung erfordert kooperatives Engagement aller Beteiligten – von Hochschulverantwortlichen und politischen Entscheidungsträger:innen bis zu den Studierenden. Nur ein integrativer Ansatz stellt sicher, dass KI-basierte LA-Systeme nicht nur technologische Fortschritte, sondern auch faire und inklusive Bildungschancen für alle Studierenden ermöglichen.

Literatur

- Alyahyan, Eyman/Düşteğör, Dilek (2020): »Predicting academic success in higher education: literature review and best practices. literature review and best practices«, in: International Journal of Educational Technology in Higher Education 17, pp. 1–21.
- Amershi, Saleema/Cakmak, Maya/Knox, William B. et al. (2015): »Power to the People: The Role of Humans in Interactive Machine Learning. The Role of Humans in Interactive Machine Learning«, in: AI Magazine 35, pp. 105–120.
- Arnold, Kimberly E./Pistilli, Matthew D. (2012): »Course signals at Purdue. Using Learning Analytics to Increase Student Success«, in: Shane Dawson/Caroline Haythornthwaite/Simon Buckingham Shum et al. (Eds.), Pro-

- ceedings of the 2nd International Conference on Learning Analytics and Knowledge (LAK 2012), New York, NY, USA: ACM, pp. 267–270.
- Attaran, Mohsen/Stark, John/Stotler, Derek (2018): »Opportunities and challenges for big data analytics in US higher education«, in: *Industry and Higher Education* 32, pp. 169–182.
- Brossi, Lionel/Castillo, Ana M./Cortesi, Sandra (2022): »Student-centred requirements for the ethics of AI in education«, in: Holmes/Porayska-Pomsta (Eds.), *The Ethics of Artificial Intelligence in Education*, pp. 91–112.
- Casanova, Joana R./Gomes, Cristiano M. A./Bernardo, Ana B. et al. (2021): »Dimensionality and reliability of a screening instrument for students at-risk of dropping out from Higher Education«, in: *Studies in Educational Evaluation* 68, p. 100957.
- Cerratto Pargman, Teresa/McGrath, Cormac (2021): »Mapping the Ethics of Learning Analytics in Higher Education: A Systematic Literature Review of Empirical Research«, in: *Journal of Learning Analytics* 8, pp. 123–139.
- Chiu, Thomas K./Xia, Qi/Zhou, Xinyan et al. (2023): »Systematic Literature Review on Opportunities, Challenges, and Future Research Recommendations of Artificial Intelligence in Education«, in: *Computers and Education: Artificial Intelligence* 4, pp. 1–15.
- Costa-Mendes, Ricardo/Cruz-Jesus, Frederico/Oliveira, Tiago et al. (2021): »Machine Learning Bias in Predicting High School Grades: A Knowledge Perspective. A Knowledge Perspective«, in: *Emerging Science Journal* 5, pp. 576–597.
- Daniel, Ben (2015): »Big Data and analytics in higher education: Opportunities and challenges«, in: *British Journal of Educational Technology* 46, pp. 904–920.
- Deutsch, Morton (1975): »Equity, Equality, and Need: What Determines Which Value Will Be Used as the Basis of Distributive Justice?«, in: *Journal of Social Issues* 31, pp. 137–149.
- Dunkelau, Jannik/Duong, Manh K. (2022): »Towards Equalised Odds as Fairness Metric in Academic Performance Prediction«, in: *FATED'22: 2nd Workshop on Fairness, Accountability, and Transparency in Educational Data.*, pp. 1–6.
- Duong, Manh K./Dunkelau, Jannik/Cordova, José A. et al. (2023): »RAPP: A Responsible Academic Performance Prediction Tool for Decision-Making in Educational Institutes«, in: Birgitta König-Ries/Stefanie Scherzinger/Wolfgang Lehner et al. (Eds.), *BTW 2023. Software Engineering 2023: Fachtagung vom 06. – 10. März 2023*, Dresden, Bonn: Köllen.

- Europäische Union (2024): Verordnung (EU) 2024/1689 des Europäischen Parlaments und des Rates vom 13. Juni 2024 zur Festlegung harmonisierter Vorschriften für künstliche Intelligenz und zur Änderung der Verordnungen (EG) Nr. 300/2008, (EU) Nr. 167/2013, (EU) Nr. 168/2013, (EU) 2018/858, (EU) 2018/1139 und (EU) 2019/2144 sowie der Richtlinien 2014/90/EU, (EU) 2016/797 und (EU) 2020/1828.
- Fazelpour, Sina/Danks, David (2021): »Algorithmic bias: Senses, sources, solutions«, in: *Philosophy Compass* 16, pp. 1–16.
- Hagendorff, Thilo (2020): »The Ethics of AI Ethics: An Evaluation of Guidelines. An Evaluation of Guidelines«, in: *Minds and Machines* 30, pp. 99–120.
- Holmes, Wayne/Porayska-Pomsta, Kaška (Eds.) (2022): *The Ethics of Artificial Intelligence in Education. Practices, Challenges, and Debates*, New York: Routledge.
- Holzinger, Andreas (2016): »Interactive machine learning for health informatics: when do we need the human-in-the-loop?«, in: *Brain informatics* 3, pp. 119–131.
- Jobin, Anna/Ienca, Marcello/Vayena, Effy (2019): »The global landscape of AI ethics guidelines«, in: *Nature Machine Intelligence* 1, pp. 389–399.
- Jones, Kyle M. L./Rubel, Alan/LeClere, Ellen (2020): »A Matter of Trust: Higher Education Institutions as Information Fiduciaries in an Age of Educational Data Mining and Learning Analytics«, in: *Journal of the Association for Information Science and Technology* 71, pp. 1227–1241.
- Junghänel, Luisa/Ülpenich, Bettina/Krause, Johannes et al. (im Review): *Diskriminierungsfreie Vorhersage des Studienerfolgs – Eine empirische Untersuchung möglicher Leistungsindikatoren*.
- Kalluri, Pratyusha (2020): »Don't ask if artificial intelligence is good or fair, ask how it shifts power«, in: *Nature* 583, p. 169.
- Kasy, Maximilian/Abebe, Rediet (2021): »Fairness, Equality, and Power in Algorithmic Decision-Making«, in: *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*, New York, NY, United States: Association for Computing Machinery, pp. 576–586.
- Keller, Birte/Baleis, Janine/Starke, Christopher et al. (2019): *Machine Learning and Artificial Intelligence in Higher Education. A State-of-the-Art Report on the German University Landscape. Working Paper No. 1*, Düsseldorf, https://www.phil-fak.uni-duesseldorf.de/fileadmin/Redaktion/Institute/Sozialwissenschaften/Kommunikations-_und_Medienwissenschaft/KM_W_I/Working_Paper/Keller_et_al._2019_-_AI_in_Higher_Education.pdf from November 9, 2021.

- Keller, Birte/Lünich, Marco/Marcinkowski, Frank (2022): »How Is Socially Responsible Academic Performance Prediction Possible? Insights From a Concept of Perceived AI Fairness«, in: Fernando Almaraz-Menéndez/Alexander Maz-Machado/Carmen López-Esteban et al. (Eds.), *Strategy, Policy, Practice, and Governance for AI in Higher Education Institutions*, IGI Global, pp. 126–155.
- Kieslich, Kimon/Lünich, Marco/Marcinkowski, Frank et al. (2019): *Hochschule der Zukunft. Einstellungen von Studierenden gegenüber Künstlicher Intelligenz an der Hochschule. Précis*, https://diid.hhu.de/wp-content/uploads/2019/10/DIID-Précis_Kieslich-et-al_Fin.pdf.
- Lang, Charles/Davis, Laura (2023): »Learning Analytics and Stakeholder Inclusion: What do We Mean When We Say »Human-Centered«?«, in: Isabel Hilliger/Hassan Khosravi/Bart Rienties et al. (Eds.), *LAK23: 13th International Learning Analytics and Knowledge Conference*, New York, NY, United States: Association for Computing Machinery, pp. 411–417.
- Lepri, Bruno/Oliver, Nuria/Letouzé, Emmanuel et al. (2018): »Fair, Transparent, and Accountable Algorithmic Decision-making Processes. The Premise, the Proposed Solutions, and the Open Challenges«, in: *Philosophy & Technology* 31, pp. 611–627.
- Li, Warren/Brooks, Christopher/Schaub, Florian (2019): »The Impact of Student Opt-Out on Educational Predictive Models«, in: *Proceedings of the 9th International Conference on Learning Analytics & Knowledge (LAK '19)*, New York, NY: ACM, pp. 411–420.
- Li, Warren/Sun, Kaiwen/Schaub, Florian et al. (2022): »Disparities in Students' Propensity to Consent to Learning Analytics«, in: *International Journal of Artificial Intelligence in Education* 32, pp. 564–608.
- Liebowitz, Jay (2017): »Thoughts on Recent Trends and Future Research Perspectives in Big Data and Analytics in Higher Education«, in: Ben Kei Daniel (Ed.), *Big Data and Learning Analytics in Higher Education. Current Theory and Practice*, Cham: Springer International Publishing, pp. 7–17.
- Lünich, Marco/Keller, Birte (2024): »Explainable Artificial Intelligence for Academic Performance Prediction. An Experimental Study on the Impact of Accuracy and Simplicity of Decision Trees on Causability and Fairness Perceptions«, in: *The 2024 ACM Conference on Fairness, Accountability, and Transparency*, pp. 1031–1042.
- Lünich, Marco/Keller, Birte/Marcinkowski, Frank (2024a): »Fairness of Academic Performance Prediction for the Distribution of Support Measures

- for Students: Differences in Perceived Fairness of Distributive Justice Norms«, in: *Technology, Knowledge and Learning* 29, pp. 1079–1107.
- Lünich, Marco/Keller, Birte/Marcinkowski, Frank (2024b): »Diverging Perceptions of Artificial Intelligence in Higher Education. A Comparison of Student and Public Assessments on Risks and Damages of Academic Performance Prediction in Germany«, in: *Computers and Education: Artificial Intelligence*.
- Lünich, Marco/Maxhuni, Albina/Keller, Birte (zur Einreichung vorbereitet): *Focusing on Student Harm Perceptions in Academic Performance Prediction: A Participatory Technology Assessment Framework to Prevent Reductionist and Hegemonic AI Implementation in Higher Education* [Arbeitstitel].
- Marcinkowski, Frank/Kieslich, Kimon/Starke, Christopher et al. (2020): »Implications of AI (Un-)Fairness in Higher Education Admissions. The Effects of Perceived AI (Un-)Fairness on Exit, Voice and Organizational Reputation«, in: Mireille Hildebrandt/Carlos Castillo/Elisa Celis et al. (Eds.), *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency (FAT* 20)*, New York, NY, USA: ACM, pp. 122–130.
- Marcinkowski, Frank/Starke, Christopher (2019): »Wann ist Künstliche Intelligenz (un-)fair? Ein sozialwissenschaftliches Konzept von KI-Fairness«, in: Jeanette Hofmann/Norbert Kersting/Claudia Ritzi et al. (Eds.), *Politik in der digitalen Gesellschaft. Zentrale Problemfelder Und Forschungsperspektiven*, Bielefeld, Germany: transcript Verlag, pp. 269–288.
- Maxhuni, Albina/Lünich, Marco/Keller, Birte et al. (2023): *Hegemoniale Technologieimplementierung an der Hochschule – Eine qualitative Analyse der Schadenswahrnehmung betroffener Studierender bei der Einführung von Dropout Detection*, Bremen, Deutschland.
- Memarian, Bahar/Doleck, Tenzin (2023): »Fairness, Accountability, Transparency, and Ethics (FATE) in Artificial Intelligence (AI) and Higher Education: A Systematic Review«, in: *Computers and Education: Artificial Intelligence* 5, pp. 1–12.
- Nguyen, Andy/Ngo, Ha N./Hong, Yvonne et al. (2023): »Ethical principles for artificial intelligence in education«, in: *Education and Information Technologies* 28, pp. 4221–4241.
- Niyogisubizo, Jovial/Liao, Lyuchao/Nziyumva, Eric et al. (2022): »Predicting Student’s Dropout in University Classes Using Two-Layer Ensemble Machine Learning S Approach: A Novel Stacked Generalization«, in: *Computers and Education: Artificial Intelligence* 3, pp. 1–12.

- Pardo, Abelardo/Siemens, George (2014): »Ethical and privacy principles for learning analytics«, in: *British Journal of Educational Technology* 45, pp. 438–450.
- Perez Vallejos, Elvira/Koene, Ansgar/Portillo, Virginia et al. (2017): »Young People's Policy Recommendations on Algorithm Fairness«, in: *Proceedings of the 2017 ACM Web Science Conference*, pp. 247–251.
- Radtke, Anna/Osinski, Meike/Serova, Katja et al. (2024): »Learning Analytics in der Erziehungswissenschaft: Lerndatenbasierte Förderung von Selbstregulation in einem Statistikkurs«, in: Salden/Leschke (Eds.), *Learning Analytics und Künstliche Intelligenz in Studium und Lehre*, pp. 45–61.
- Rudin, Cynthia (2019): »Stop Explaining Black Box Machine Learning Models for High Stakes Decisions and Use Interpretable Models Instead«, in: *Nature Machine Intelligence* 1, pp. 206–215.
- Salden, Peter/Leschke, Jonas (Eds.) (2024): *Learning Analytics und Künstliche Intelligenz in Studium und Lehre. Erfahrungen und Schlussfolgerungen aus einer hochschulweiten Erprobung*, Wiesbaden: Springer Fachmedien Wiesbaden.
- Scheffel, Maren/Simis, Christos/Leschke, Jonas et al. (2024): »Learning Analytics-Policies im Hochschulkontext«, in: Salden/Leschke (Eds.), *Learning Analytics und Künstliche Intelligenz in Studium und Lehre*, pp. 169–185.
- Simis, Christos/Weydner-Volkman, Sebastian (2024): »KI-gestützte Learning Analytics: Geschenk oder Falle für die Hochschulbildung? Ein ethischer Exkurs«, in: Salden/Leschke (Eds.), *Learning Analytics und Künstliche Intelligenz in Studium und Lehre*, pp. 127–148.
- Slade, Sharon/Prinsloo, Paul (2013): »Learning Analytics. Ethical Issues and Dilemmas«, in: *American Behavioral Scientist* 57, pp. 1510–1529.
- Smith, Helen (2020): »Algorithmic bias: should students pay the price?«, in: *AI & SOCIETY* 35, pp. 1077–1078.
- Smuha, Nathalie A. (2022): »Pitfalls and Pathways for Trustworthy Artificial Intelligence in Education«, in: Holmes/Porayska-Pomsta (Eds.), *The Ethics of Artificial Intelligence in Education*, pp. 113–145.
- Starke, Christopher/Lünich, Marco (2020): »Artificial intelligence for political decision-making in the European Union: Effects on citizens' perceptions of input, throughput, and output legitimacy«, in: *Data & Policy* 2, pp. 1–17.
- Sun, Kaiwen/Mhaidli, Abraham H./Watel, Sonakshi et al. (2019): »It's My Data! Tensions Among Stakeholders of a Learning Analytics Dashboard«, in: Stephen Brewster/Geraldine Fitzpatrick/Anna Cox et al. (Eds.), *Proceed-*

- ings of the 2019 CHI Conference on Human Factors in Computing Systems, New York, NY, USA: ACM, pp. 1–14.
- The Institute for Ethical AI in Education (2021): The Ethical Framework for AI in Education, <https://www.buckingham.ac.uk/research-the-institute-for-ethical-ai-in-education/>.
- Tsai, Yi-Shan/Gasevic, Dragan (2017): »Learning analytics in higher education—challenges and policies«, in: Alyssa F. Wise (Ed.), Proceedings of the Seventh International Learning Analytics & Knowledge Conference, New York, NY: ACM, pp. 233–242.
- Tsai, Yi-Shan/Rates, Diego/Moreno-Marcos, Pedro M. et al. (2020): »Learning analytics in European higher education—Trends and barriers«, in: Computers & Education 155, pp. 1–16.
- Tsai, Yi-Shan/Whitelock-Wainwright, Alexander/Gašević, Dragan (2021): »More Than Figures on Your Laptop: (Dis)trustful Implementation of Learning Analytics«, in: Journal of Learning Analytics 8, pp. 81–100.
- Ülpenich, Bettina/Junghänel, Luisa/Krause, Johannes et al. (2023): »Studien-erfolg und -misserfolg aus institutionenund studierendenzentrierter Perspektive: Eine qualitative Untersuchung«, in: Beiträge zur Hochschulfor-schung 45, pp. 54–74.
- Weinberg, Lindsay (2022): »Rethinking Fairness: An Interdisciplinary Survey of Critiques of Hegemonic ML Fairness Approaches«, in: Journal of Artificial Intelligence Research 74, pp. 75–109.
- Wirtz, Bernd W./Weyerer, Jan C./Geyer, Carolin (2019): »Artificial Intelligence and the Public Sector—Applications and Challenges«, in: International Journal of Public Administration 42, pp. 596–615.
- Wong, Pak-Hang (2020): »Democratizing Algorithmic Fairness«, in: Philosophy & Technology 33, pp. 225–244.
- Zawacki-Richter, Olaf/Marín, Victoria I./Bond, Melissa et al. (2019): »System-atic review of research on artificial intelligence applications in higher edu-cation – where are the educators?«, in: International Journal of Educational Technology in Higher Education 16, pp. 1–27.

Auf dem Weg zu Learning Analytics in der Praxis¹

Claudia Ruhland² und Ummay Ubaida Shegupta³

Learning Analytics (LA) unterstützt Lehrkräfte dabei, den Unterricht individuell auf Lernende abzustimmen und effizienter zu gestalten. Die erfolgreiche Einführung von LA erfordert die Einbindung aller Stakeholder, die jedoch über unterschiedliche Kompetenzen verfügen. Insbesondere Lehrkräfte ohne technische Vorkenntnisse benötigen Unterstützung. Um ihnen den Einstieg zu erleichtern, wurde ein Design-Based Research (DBR)-Ansatz genutzt, um Design-Prinzipien für den Kurs »Learning Analytics für Lehrkräfte« zu entwickeln. In diesem Beitrag wird aufgezeigt, welche Aspekte in der Gestaltung eines LA Kurses, insbesondere für Personen ohne informatisches Vorwissen, berücksichtigt werden sollten. Hierbei hat die Vermittlung von Emotionen eine große Bedeutung.

On the Way to Learning Analytics in Practice

Learning analytics (LA) supports teachers in tailoring lessons individually to learners and making them more efficient. The successful introduction of LA requires the involvement of all stakeholders, who, however, have different skills. Teachers without prior technical knowledge need support. To help them get started, a Design-Based Research (DBR) approach was used to develop design principles for the »Learning Analytics for Teachers« course. This article shows which aspects should be taken into account when designing an LA course, especially for people with no prior knowledge of information technology. The communication of emotions is of great importance here.

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

2 ORCID: 0000-0002-1952-8337

3 ORCID: 0000-0003-1092-9510

Ausgangslage

Learning-Analytics (LA) kann Lehrenden dabei helfen, Lernende individuell zu fördern und ihren Unterricht effektiv und effizient zu optimieren (u.a. Ifenthaler/Yau 2022; Reich 2022; Dixon et al. 2014). Eine praxistaugliche Entwicklung und nachhaltige Implementierung von LA erfordert die Einbindung aller Stakeholder (vgl. Macfadyen 2022; Drachler & Geller, 2016; Tsai et al. 2018). Diese sind jedoch insgesamt heterogen und verfügen in unterschiedlichem Umfang über die für eine didaktisch-technologische Entwicklung und nachhaltige Implementierung erforderlichen Kompetenzen. Personen mit informatischer Grundbildung können diese Kompetenzen leichter erwerben als Personen aus nicht-technischen Domänen (vgl. zum »Anschlusslernen«: Gieseke, 2019: 21; Faulstich & Zeuner, 1999: 52). Um auch nicht technik-affine Personen für LA zu interessieren und ihnen den Kompetenzerwerb zu erleichtern, wurden mittels Design-Based Research (DBR) adäquate Designprinzipien entwickelt und für nicht-technik-affine Lehrkräfte (nachfolgend Lehrkräfte) der Kurs »Learning Analytics für Lehrkräfte« gestaltet und auf dem KI-Campus bereitgestellt.

Methodik

Der Kurs »Learning Analytics für Lehrkräfte«

Der Kurs »Learning Analytics für Lehrkräfte« (Ruhland et al. 2022) bietet einen niedrigrschwelligsten Einstieg in das Thema LA und enthält drei kohärent aufeinander aufbauende Lernmodule: (1) Einführung in LA, (2) LA & Instructional Redesign und (3) Das LA Dashboard. Das didaktische Kursdesign orientiert sich am Konzept des »Constructive Alignment« (CA) von Biggs (1996), welches auf der konstruktivistischen Lerntheorie basiert und das Ziel verfolgt, Lernfortschritte zu beobachten und Lernverläufe an den individuellen Kompetenzen der Lernenden auszurichten.

Damit Lernende den Kurs in ihren Alltag integrieren und auch schon nach kurzen Lernzeiten Leistungserfolge erleben können, setzen sich die Module aus Micro Learning Units (MLUs) zusammen. Diese enthalten jeweils ein formuliertes praxisrelevantes *Intended Learning Outcome* (intendiertes Lernziel), *Teaching Learning Activities* – TLAs (Lernaktivitäten) mit zahlreichen Praxisbeispielen sowie *Lernzielüberprüfungen* (formative Assessments). An jedes Modul

schließt sich eine umfangreichere bewertete Praxisaufgabe an (summatives Assessment). Personen, die auf mindestens 50 Prozent der Lerninhalte zugegriffen haben, erhalten eine KI-Campus-Teilnahmebescheinigung. Diejenigen, die mindestens 60 Prozent der Gesamtpunktzahl erreicht haben, erhalten einen KI-Campus-Leistungsnachweis.

Durchführung der DBR-Studie

Das ursprünglich von Collins (1991, 1993) und Brown (1992) als Design-Experimente bezeichnete Forschungsparadigma Design-Based Research (DBR) ermöglicht in authentischen Lernumgebungen Innovationen zu gestalten und dabei Erkenntnisse über sowohl praxistaugliche Interventionen als auch wissenschaftliche Theorien zu gewinnen (Barab/Squire: 2004; Reimann 2024). Neben der *Einbettung in die authentische Lernumgebung* und engen *Verzahnung von Theorie und Praxis* ist DBR von einem hohen Maß an *Interdisziplinarität* und mehreren *iterativen Entwicklungsphasen* gekennzeichnet, welche in verschiedenen Varianten theoretisch modelliert wurden (Hoadley/Campos: 2020; McKenney & Reeves: 2019). Die nachfolgende Designstudie basiert auf dem Phasenmodell von McKenney & Reeves (ebd.) mit den Phasen (1) Analyse & Exploration, (2) Design und Construction sowie (3) Evaluation und Reflexion.

Grundlage für die (1) *Analyse & Exploration* der ersten drei Monate bildeten ein Literature Review und Interviews mit 5 Expert:innen, um den curricularen Rahmen und ein Verständnis für die Zielgruppe zu entwickeln. Die anschließenden Phasen für (2) *Design & Construction* erstreckten sich über mehrere Monate und durchliefen mehrere Iterationen. Zunächst wurden aus der wissenschaftlichen Literatur zu Learning Analytics (LA) Texte produziert und anschließend mithilfe der Methode »Decoding the Disciplines« mit zwei fachfremden Personen in eine allgemeinverständliche Sprache umformuliert. Dann wurden die Texte didaktisch aufbereitet, bei der Entwicklung der MLUs iterativ weiterentwickelt und audiovisuell, visuell und/oder verbal dargestellt. Vor der Veröffentlichung wurde mit drei Personen ein UX-Designstest durchgeführt und auf Basis der Ergebnisse wurde der Kurs nochmals optimiert. Die (3) *Evaluation und Reflexion* erfolgt seit Veröffentlichung mittels kursintegrierter Befragungen formativ in monatlichen Abständen, wobei die Anzahl der Personen, die an den Befragungen teilnehmen, kontinuierlich ansteigt. Nach 6 Monaten hat der KI-Campus den Kurs nach eigenem Kriterienraster (semi-)summativ evaluiert (Mah et al. 2023). Die Ergebnisse der DBR-Stu-

die werden zu Design Prinzipien/Design Patterns (Eyal & Gil, 2020) für die Kursgestaltung zusammengefasst und im Folgenden erläutert.

Design-Forschungsprozess

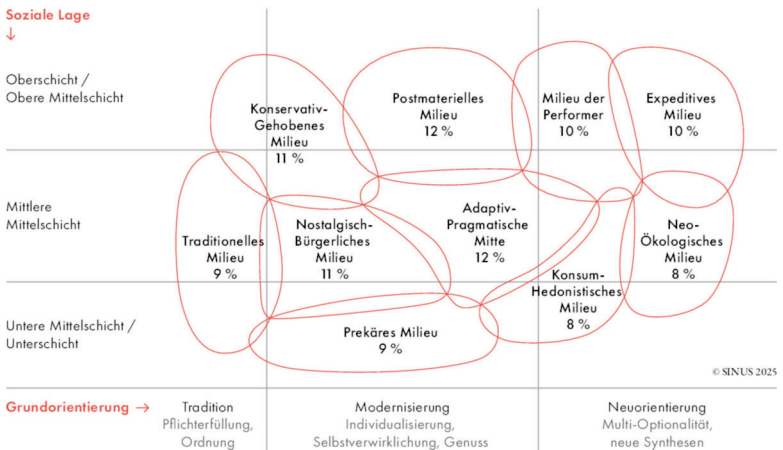
Zielgruppen

Zunächst gilt es zu bestimmen, welche Zielgruppen adressiert werden. Zielgruppen werden durch gemeinsame sozialstrukturelle Merkmale, wie Alter, Status oder ethnische Herkunft, Einstellungen und Werte charakterisiert (Faulstich und Zeuner 1999; Siebert 2019). Zur Beschreibung heterogener Zielgruppen verwenden Hippel et al. (2008) die Milieuforschung des SINUS-Instituts, das homogene Gruppen in der sogenannten »Kartoffelgrafik« darstellt und beschreibt (SINUS 2023). Milieus sind in einem Koordinatensystem angeordnet, deren x-Achse die soziale Lage von Unterschicht bis Oberschicht anzeigt. Die y-Achse kennzeichnet die Wertorientierungen von Tradition bis Neuorientierung [Innovation].

Abb. 1: Die Sinus-Milieus® (SINUS 2025)

Die Sinus-Milieus® in Deutschland 2025

Soziale Lage und Grundorientierung



Anhand eines Literature Reviews und Expert:inneninterviews wurden Lehrkräfte in Bezug auf ihre Wertorientierungen (x-Achse) im Bereich *Modernisierung & Individualisierung*, und ihre Schichtzugehörigkeit (y-Achse) gemessen am Nettoeinkommen (Statista 2022: 8) in der *Mittelschicht/oberen Mittelschicht* verortet. Auf der Kartoffelgrafik befindet sich dort die *Adaptiv-Pragmatische Mitte*: »Der moderne Mainstream: Anpassungs- und Leistungsbereitschaft, Nützlichkeitsdenken, aber auch Wunsch nach Spaß und Unterhaltung; starkes Bedürfnis nach Verankerung und Zugehörigkeit; wachsende Unzufriedenheit und Verunsicherung aufgrund der gesellschaftlichen Entwicklung; Selbstbild als flexible Pragmatiker« (SINUS 2023: 13) und das *Postmaterielle Milieu*: »Engagiert-souveräne Bildungselite mit postmateriellen Wurzeln: Selbstbestimmung und -entfaltung sowie auch Gemeinwohlorientierung; Verfechter von Post-Wachstum, Nachhaltigkeit, diskriminierungsfreien Verhältnissen und Diversität; Selbstbild als gesellschaftliches Korrektiv« (ebd.).

Von diesen charakteristischen Merkmalen wurde abgeleitet, inwieweit LA die Erwartungen und Einstellungen der Zielgruppen bedient, bzw. nach dem Konzept von Rogers (1971) mit ihren Lebenswelten kompatibel ist. Fehlende Informationen wurden durch kursintegrierte Befragungen erhoben.

Kompatibilität

Rogers (ebd.) bezeichnen mit Kompatibilität das Maß, in dem eine Innovation als vereinbar mit den bestehenden Werten, bisherigen Erfahrungen und Bedürfnissen der Empfänger wahrgenommen wird. Demnach wird eine Idee, die nicht mit den zentralen Merkmalen eines sozialen Systems im Einklang steht, langsamer angenommen als eine, die kompatibel ist. Kompatibilität schafft für den Empfänger mehr Sicherheit und verringert das Risiko, wodurch die neue Idee für ihn bedeutungsvoller wird. Eine Innovation kann kompatibel sein mit (1) soziokulturellen Werten und Überzeugungen, (2) bereits etablierten Ideen oder (3) den Bedürfnissen der Kunden [hier Lernenden] nach Innovationen (ebd.: 145).

(1) Lehrkräfte, die nach SINUS der adaptiv-pragmatischen Mitte zugeordnet werden, können sich an neue Gegebenheiten anpassen und LA aneignen, wenn sie darin einen pragmatischen Nutzen sehen. Lernen sollte in ihren persönlichen und beruflichen Alltag integriert werden können, in sozialer Gemeinschaft stattfinden und Freude bereiten. Lehrkräfte aus dem postmateriellen Milieu können einen Vorteil von LA in der Förderung individueller

Selbstentfaltung und einer diversen Gesellschaft sehen, wobei Diskriminierung vermieden und Nachhaltigkeit gewährleistet werden sollte. Online-Kurse im self-paced Modus können ihrer Präferenz für selbstgesteuertes Lernens entgegenkommen.

(2) Bereits etablierte Ideen wurden mithilfe von integrierten Befragungen identifiziert. Zunächst haben die Teilnehmenden deskriptive LA kennengelernt und exemplarisch angewendet. Anschließend wurde mittels einer geschlossenen Frage mit einer fünfstufigen Likert-Skala erhoben, ob sie sich vorstellen können digitale Verfahren und Methoden von LA einzusetzen, um mit *deskriptiver* LA einen besseren Überblick über Lernzustände und Lernverläufe zu gewinnen. Außerdem wurden sie gebeten, ihre Einschätzung zu begründen. Im Zeitraum von 02/2023 bis 01/2024 haben 68 Teilnehmende (n = 68) an der Befragung teilgenommen. Davon wählten 54,4 % (n = 37) »trifft eher zu«, 30,8 % (n = 21) »stimmt voll und ganz zu«, 8,8 % (n = 6) »weder noch«, 5,9 % (n = 4) »trifft eher nicht zu« und niemand stimmte für »trifft überhaupt nicht zu«. Auf die offene Frage nach einer Begründung für die Entscheidung antworteten 75 % Teilnehmende (n = 51). Hier wurde von einigen Personen genannt, dass solche Verfahren bereits eingesetzt werden, andere äußerten einen Bedarf an Schulungen, um LA kompetent entwickeln und verwenden zu können. Außerdem wurde vereinzelt angezweifelt, ob sich ein Mehrwert von digitaler/KI-unterstützter LA wegen der Aufwände für die Einholung von Einwilligungen in die Datenverarbeitung und einen digitalen Transfer analog erhobener Daten abzeichnet. Für Schulungen, digitalen Transfer und das Datenschutzmanagement wurde ein *Bedarfnach zentralen Lösungen* deutlich.

(3) Die kursintegrierten Befragungen bestätigten theoriebasierte Annahmen zu Bedürfnissen nach Innovationen für die Bewältigung heterogener Lerngruppen. Dass LA bei der Suche nach Erklärungen für Lernabweichungen und durch auf Erfahrung basierenden didaktischen Entscheidungen Unterstützung leistet, wurde positiv bewertet. Insbesondere wurden Vorteile darin gesehen, datenbasiert objektivere didaktische Entscheidungen treffen zu können. Insgesamt wurden mit La Chancen verbunden, die eigene Lehre qualitativ zu verbessern.

Die Befragungsergebnisse belegen, dass LA für einige Lehrkräfte mit etablierten Ideen und ihren Bedürfnissen nach Innovationen kompatibel ist. Um bei den übrigen Lehrkräften Bedürfnisse nach Innovationen und Ideen zur Etablierung von LA zu wecken, wurde ein für sie relevanter Mehrwert von LA in einer Kernbotschaft verdichtet.

Lernziele und Kernbotschaft

Die Lernziele umfassen den Erwerb von Wissen, Fähigkeiten und Kenntnissen über LA. Darüber hinaus soll er Lernenden Ideen und Anregungen geben, wie LA in der Lehre genutzt werden kann. Dafür bietet der Kurs einen praxisorientierten Einstieg in Learning Analytics (LA) und zeigt auf, wie datenbasierte Ansätze zur Optimierung von Lehr- und Lernprozessen genutzt werden können. Nach einer Einführung in die Grundlagen von LA werden die Relevanz empirischer Gütekriterien für eine valide Datenerhebung sowie deren Analyse vermittelt. Ein besonderer Fokus liegt auf der Modellierung von Lernumgebungen für den gezielten Einsatz von LA und der Gestaltung adaptiver Lernpfade. Zudem werden Methoden zur Visualisierung von Lernzuständen vorgestellt, um Lernprozesse explorativ zu analysieren und fundierte Entscheidungen zu treffen. Mit Hilfe eines Dashboards lassen sich Lehr- und Lernprozesse bewerten, wodurch didaktische Handlungsbedarfe frühzeitig erkannt und angepasst werden können.

Die Kernbotschaft fasst zusammen, welchen Eindruck der Kurs hinterlassen soll: »LA verschafft dir einen pragmatischen Nutzen und ermöglicht deinen Schüler:innen individuelle Selbstentfaltung.« Diese Botschaft wird in verschiedenen Varianten und an verschiedenen Stellen im Kurs kommuniziert, z.B. in den kursweiten Lernzielen: »Nach einem leichten und kurzweiligen Einstieg in LA möchten wir dir Ideen und Anregungen dazu geben, wie du die Vorteile von LA für dich nutzen kannst.« (Ruhland et al.: 2022)

Kommunikationsziel

Offen ist die Frage, mit welchem Kommunikationsziel die Botschaft vermittelt werden soll. Nach Kroeber-Riehl (1993) können Kommunikationsstrategien vier mögliche Ziele erreichen: »Aktualität«, »Emotion«, »Information«, »Emotion und Information«.

Das Kommunikationsziel *Aktualität* soll die Bekanntheit eines Angebotes steigern, durch das Evozieren von *Emotion* soll ein Angebot erlebbar werden und mit positiven Emotionen verbunden werden, die *Information* regt zu einer rationalen Beurteilung des Angebots an und das Zusammenwirken von *Emotion und Information* fördert die Entwicklung komplexer innerer Einstellung zum Angebot. Für die Wahl des Kommunikationsziels ist wesentlich zu berücksichtigen, dass der emotionale Eindruck einer rationalen Begründung für den An-

gebotsnutzen voraus geht, d.h., dass der [unmittelbar wahrgenommene erste] emotionale Eindruck des Angebotes kognitive Wahrnehmung und Entscheidung beeinflusst und quasi vorentscheiden kann (ebd.: 39ff.). Nach Roth gibt es sogar keine rein rationalen Entscheidungen: »Entscheidungen sind immer emotional, wie lange man auch abgewogen hat. Rationale Argumente wirken auf die Entscheidungen nur über die mit ihnen verbundenen Emotionen, d.h. Erwartungen und Befürchtungen, ein« (Roth 2011: 196).

Um den praktischen Mehrwert von LA auch für nicht-technikaffine Lehrende zugänglich zu machen, einen positiven ersten Eindruck zu vermitteln und sie zur Erweiterung fachfremder Kenntnisse und Fertigkeiten zu motivieren, fiel unsere Wahl auf das Kommunikationsziel *Emotion und Information*. Dementsprechend sollte das Kommunikationsdesign auf den ersten Blick emotional ansprechend sein, einen niedrigschwelligen Eindruck erwecken und zur Beschäftigung mit LA motivieren. Anschließend sollten Informationen vermittelt werden und Lernenden ermöglichen, eine aufgeklärte innere Haltung zu LA entwickeln. Dementsprechend unterscheidet sich der Kommunikationsstil bzw. die Tonalität des Kurses vom wissenschaftlichen Stil.

Tonalität – Text- und Bildsprache

Die Tonalität beschreibt die Atmosphäre oder den Klang eines Textes. Im Rahmen der Textgestaltung ist es entscheidend, eine Ausdrucksweise zu wählen, die die intendierte Zielgruppe in optimaler Weise anspricht. Die Vorgaben zur Tonalität definieren den grundlegenden Stil, der gewählt werden sollte, um das angestrebte Kommunikationsziel zu erreichen. Im Folgenden werden ausgewählte Stilmittel erläutert.

Du statt Sie – In den letzten Jahren ist ein deutlicher Trend zu beobachten, der vom formellen »Sie« zum informellen »Du« übergeht. Nach den in der Phase der Analyse und Exploration geführten Expert:inneninterviews ist das kollegiale »Du« auch im Lehrerzimmer weit verbreitet und wird in der Regel positiv aufgenommen. Es wird auch mit sozialer Nähe und Verbundenheit assoziiert und kann dazu beitragen, Barrieren abzubauen und Vertrauen aufzubauen. Besonders in digitalen Kommunikationsformen, in denen physische Distanz besteht, ermöglicht das »Du« eine künstlich geschaffene Nähe (Besch, 1998: 11, 25).

Direkte Ansprache – In pädagogischen Kontexten spielt die direkte Ansprache eine entscheidende Rolle. Die direkte Ansprache, z. Bsp. durch regelmäßige Fragen, wird als ein wirkungsvolles Mittel zur Erhöhung der Aufmerk-

samkeit und des Engagements der Rezipierenden betrachtet. Sie trägt nicht nur zur Schaffung einer positiven Lernatmosphäre bei, sondern ermöglicht es Lehrenden auch, eine engere Beziehung zu den Lernenden aufzubauen. Dies erleichtert ein besseres Verständnis der individuellen Bedürfnisse und fördert somit eine effektive Interaktion und Wissensvermittlung (Kulgemeyer, 2018).

Videos, Grafiken und Bilder – Visualisierungen können in unterschiedlichem Ausmaß Gefühle auslösen. Im Kurs wurden bewusst warme Farben und Linieneinführung mit handschriftlichem Duktus gewählt, um menschliche Nähe und Vertraulichkeit auszudrücken (Gredig, 2019). Eine Ausnahme bilden die Diagramme, die in den Praxisaufgaben hinzugezogen werden und solche, die in das Modul »Das LA Dashboard« integriert sind. Außerdem wurde in den Videos und auf den Textseiten als quasi pädagogischer Begleiter ein Avatar eingesetzt, dessen stilistische Anmutung an Kinderbücher erinnert.

Reflektion und Limitationen

DBR stellt sich als geeignete Methode dar, um basale Kompetenzen für die Entwicklung und Implementierung von LA allgemeinverständlich zu vermitteln und zu ermitteln, welche Relevanz LA für die Lehrpraxis hat. In Bezug auf eine theoretische Weiterentwicklung hat sich gezeigt, dass Emotionen für eine Auseinandersetzung mit LA von entscheidender Bedeutung sind. Es ist erforderlich, dass sich auch Stakeholder aus fachfremden Domänen erst für das Thema öffnen müssen, um sich aktiv damit auseinandersetzen zu können.

Die SINUS Forschung sollte mit Bedacht hinzugezogen werden. Einerseits hat sich dieser Forschungsansatz in der Erwachsenenpädagogik etabliert. Andererseits wird er der Heterogenität unserer Gesellschaft durch die Abbildung von Stereotypen kaum gerecht. Aus diesem Grund ist ein reflektierter Umgang notwendig, bei dem die SINUS-Milieus mehr als wissenschaftliches Konstrukt, denn als Abbild der Gesellschaft verstanden werden.

Danksagung

Die Autorin dankt dem BMBF für die freundliche Unterstützung im Rahmen des Projektes »tech4compKI – Personalisierte Kompetenzentwicklung und hybrides KI-Mentoring« (FKZ 16DHB2212).

Literatur

- Barab, Sasha/Squire, Kurt (2004): Design-Based Research: Putting a Stake in the Ground, in: *Journal Of The Learning Sciences*, Bd. 13, Nr. 1, S. 1–14, [online] https://doi.org/10.1207/s15327809jls1301_1.
- Besch, Werner (1998): *Duzen, Siezen, Titulieren. Zur Anrede im Deutschen heute und gestern*. Göttingen: Vandenhoeck und Ruprecht.
- Biggs, John (1996): Enhancing teaching through constructive alignment, in: *Higher Education*, Bd. 32, Nr. 3, S. 347–364, [online] <https://doi.org/10.1007/bf00138871>.
- Brown, Ann L. (1992): Design Experiments: Theoretical and Methodological Challenges in Creating Complex Interventions in Classroom Settings, in: *Journal Of The Learning Sciences*, Bd. 2, Nr. 2, S. 141–178, [online] https://doi.org/10.1207/s15327809jls0202_2.
- Collins, Allan (1992): *Toward a Design Science of Education*, in: Springer eBooks, S. 15–22, [online] https://doi.org/10.1007/978-3-642-77750-9_2.
- Dixon, Felicia A./Nina Yssel/John M. McConnell/Travis Hardin (2014b): Differentiated Instruction, Professional Development, and Teacher Efficacy, in: *Journal For The Education Of The Gifted*, Bd. 37, Nr. 2, S. 111–127, [online] <https://doi.org/10.1177/0162353214529042>.
- Eyal, L. & Gil, E. (2020): Design patterns for teaching in academic settings in future learning spaces. *British Journal of Educational Technology*, 51(4), 1061–1077. <https://doi.org/10.1111/bjet.12923>
- Faulstich, Peter/Zeuner, Christine (1999): *Erwachsenenbildung – eine handlungsorientierte Einführung*. Weinheim: Juventa.
- Gieseke, Wiltrud (2016): *Lebenslanges Lernen und Emotionen: Wirkungen von Emotionen auf Bildungsprozesse aus beziehungstheoretischer Perspektive*.
- Gredig, A. (2019). Die Spur der Gefühle – Kulturanalytische Überlegungen zum emotionalen Wert der Handschrift, in: S. Hauser, M. Luginbühl & S. Tinken (Hg.), *Mediale Emotionskulturen*. Peter Lang CH.
- Hoadley, Christopher/Fabio C. Campos (2022): Design-based research: What it is and why it matters to studying online learning, in: *Educational Psychologist*, Bd. 57, Nr. 3, S. 207–220, [online] <https://doi.org/10.1080/00461520.2022.2079128>.
- Ifenthaler, Dirk/Jane Yin-Kim Yau (2022): Analytics for Supporting Teaching Success in Higher Education: A Systematic Review, in: 2022 IEEE Global

- Engineering Education Conference (EDUCON), Bd. 57, S. 1721–1727, [online] <https://doi.org/10.1109/educon52537.2022.9766734>.
- Kroeber-Riel, Werner/Esch, Franz-Rudolf (2004): Strategie und Technik der Werbung: verhaltenswissenschaftliche Ansätze.
- Kulgemeyer, Christoph (2018): Wie gut erklären Erklärvideos? Ein Bewertungsleitfaden. *Computer + Unterricht*, 109, 8–11.
- Macfadyen, Leah P. (2022): Institutional Analytics, in: Solar eBooks, S. 173–186, [online] <https://doi.org/10.18608/hla22.017>.
- Mah, Dana-Kristin/Bernd, Mike/Dufentester/Christian/Hense, Julia (2023): ›Evaluation und Maintenance von Online-Kursen zum Thema Künstliche Intelligenz‹, *Zeitschrift für Hochschulentwicklung*, 18(1), pp. 37–56, [online] <https://doi.org/10.3217/zfhe-18-01/03>.
- McKenney, Susan/Thomas C. Reeves (2019): Conducting educational design research, Routledge eBooks, [online] <https://doi.org/10.4324/9781315105642>.
- Reich, Justin (2022): Learning Analytics and Learning at Scale, in: Solar eBooks, S. 188–195, [online] <https://doi.org/10.18608/hla22.018>.
- Rogers, Everett M. (2003): *Diffusion of Innovations*, 5th Edition.
- Roth, Gerhard (2019): Warum es so schwierig ist, sich und andere zu ändern: Persönlichkeit, Entscheidung und Verhalten.
- Ruhland, Claudia/Schnücker, Alexander/Shegupta, U. Ummay/Seegerer, Stefan/Meissner, Roy (2023): Learning Analytics für angehende Lehrkräfte. Manuskript zum Online Kurs auf dem KI-Campus, [online] <https://learn.ki-campus.org/courses/leas-fub2021/items/7FMFr8ocaohlRt4rdokWoC>
- Siebert, Horst (2019): Didaktisches Handeln in der Erwachsenenbildung: Didaktik aus konstruktivistischer Sicht.
- Sinus-Milieus – der Goldstandard der Zielgruppensegmentation (2023): Sinus-Milieus – der Goldstandard der Zielgruppensegmentation, [online] <https://www.sinus-institut.de/sinus-milieus>.
- Statista (2022): Mittelschicht in Deutschland | Statista, Statista, [online] <https://de.statista.com/statistik/studie/id/113088/dokument/mittelschicht-in-deutschland/>.
- Von Hippel, Aiga/Tippelt, Rudolf/Reich, Jutta/Baum, Dajana/Barz, Heiner (2008): Weiterbildung und soziale Milieus in Deutschland, Band 3: Milieu-marketing implementieren, [online] <https://doi.org/10.3278/85/0007w>.
- Tsai, Yi-Shan/Pedro Manuel Moreno-Marcos/Ioana Jivet/Maren Scheffel/Kairit Tammets/Kaire Kollom/Dragan Gašević (2018): The SHEILA Framework: Informing Institutional Strategies and Policy Processes of Learning

Analytics, in: Journal Of Learning Analytics, Bd. 5, Nr. 3, [online] <https://doi.org/10.18608/jla.2018.53.2>.

Ein wertesesibles Design für formatives Feedback mit Trusted Learning Analytics und KI¹

Heike Karolyi,² Lars van Rijn,³ Michael Hanses⁴ und Claudia de Witt⁵

Der Einsatz von Künstlicher Intelligenz (KI) ermöglicht die Generierung von skalierbarem personalisiertem, hochinformativem Feedback (HIF) an Hochschulen. Die Verfügbarkeit von Large Language Models (LLMs) kann an Hochschulen durch lokale Installationen vertrauenswürdig umgesetzt werden. Beim Einsatz der LLMs im Zusammenhang mit Feedback in der Hochschullehre sollten jedoch eine Reihe von Rahmenbedingungen beachtet werden, um die von den Lehrenden definierten Inhalte und Kriterien qualitätsgesichert umzusetzen. Bei den im Forschungszentrum CATALPA an der FernUniversität in Hagen entwickelten KI-Anwendungen zu formativem Feedback wurden im Rahmen eines Value Sensitive Design (VSD)-Prozesses konzeptionelle, empirische und technologische Anforderungen integriert, die sich aus dem TLA-Ansatz von Hansen et al. (2020) ergeben. So wird ein vertrauenswürdiger Einsatz von Learning Analytics (LA) und KI bereits in der Anwendungsentwicklung sichergestellt.

A Value Sensitive Design for formative Feedback with Trusted Learning Analytics and AI

The use of artificial intelligence (AI) enables the generation of scalable, personalized, highly informative feedback (HIF) at universities. The availability of Large Language Models (LLMs) can be reliably implemented at universities through local installations. However, when using LLMs in connection with feedback, several conditions should be considered in order to implement the content and criteria defined by the teachers in a quality-assured manner.

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

2 ORCID-ID: 0000-0002-8587-9530

3 ORCID-ID: 0000-0002-8381-2666

4 ORCID-ID: 0009-0004-3365-6273

5 ORCID-ID: 0000-0001-6478-8392

In the LA and AI applications for formative feedback developed at the CATALPA research center at the FernUniversität in Hagen, conceptual, empirical and technological requirements resulting from the TLA approach of Hansen et al. (2020) were integrated as part of a Value Sensitive Design (VSD) process. This ensures the trustworthy use of learning analytics (LA) and AI as early as the application development stage.

Einleitung

Um KI-Anwendungen ethisch, rechtlich sowie sozial verträglich zu gestalten und zu nutzen, wurde im Forschungszentrum CATALPA an der FernUniversität in Hagen der Ansatz zum wertesensiblen Design (eng. Value Sensitive Design (VSD), vgl. Spiekermann 2021; Friedman & Hendry 2019) für die Entwicklung von Feedbackanwendungen genutzt. Basierend auf einer Triangulation von (1) konzeptionellen, (2) empirischen und (3) technologischen Untersuchungen, unterstützt ein VSD ein umfassendes Verständnis von Anforderungen und Bedürfnissen in der Anwendungsentwicklung. Damit konnten systematisch Designentscheidungen wertorientiert getroffen werden, um eine automatisierte personalisierte Feedbackanwendung mit besonders lernförderlichem *hochinformativem Feedback* (HIF) (Wisniewski et al. 2020, Hattie 2024) durch Learning Analytics (LA) und KI umzusetzen. Ein solches Feedback zu skalieren, ist in Anbetracht der knappen Betreuungskontingente von Lehrenden und Dozierenden in großen Kursen an Hochschulen nicht ohne technische Unterstützung möglich, bietet aber einen klaren Mehrwert für Lernende. Rahmenbedingungen wie der Ansatz von Trusted Learning Analytics (TLA) (Hansen et al. 2020), Datenschutz, Urheberrecht und EU-KI-Verordnung (AI-Act) erfordern einen sensiblen Umgang mit KI und wurden in der wertesensiblen Entwicklung in zwei KI-basierten Anwendungen realisiert: eine Anwendung für das Selbstmonitoring und eine Anwendung zu korrekivem Feedback für automatisierte Rückmeldungen zu langen Freitextaufgaben.

Das Projekt IMPACT und Trusted Learning Analytics (TLA)

In dem Bund-Länder- geförderten Verbundprojekt IMPACT werden an fünf Hochschulen KI-basierte Lösungen zum Einsatz von Chatbots, zum formativen – bzw. summativen Feedback entwickelt und in die Implementierung gebracht. Das Verbundprojekt folgt dabei dem Ansatz von TLA nach Hansen et al.

(2020) mit einem umfassenden Verhaltenskodex, der Ziele und Prinzipien für den Einsatz von Daten in Bildungseinrichtungen festlegt. Die Hauptziele bestehen darin, Daten ethisch verantwortungsvoll, zielgerichtet und transparent einzusetzen, um sichere und vertrauenswürdige Systeme in die Anwendung zu bringen und sicherzustellen, dass alle Beteiligten sich mit dem Verhaltenskodex identifizieren.

Um diese Ziele zu erreichen, basiert der TLA-Ansatz (Hansen et al. 2020) auf sieben Prinzipien: Durch den Einsatz von LA sollen die *Bedingungen für Studium und Lehre verbessert* (1), *Unterstützungsangebote für alle Studierende* (2) bereitgestellt, ein *transparenter Umgang mit Daten* (3) gepflegt, und ein *kritischer Umgang mit Daten* (4) gewährleistet werden. *Menschliche Kontrolle* (5) soll sicherstellen, dass Entscheidungen auf der Grundlage von Daten nur nach menschlichen Vorgaben und Kontrolle getroffen werden. Das Prinzip der *Führungsverantwortung* (6) stellt sicher, dass Daten ethisch und verantwortungsvoll genutzt werden, z. B. nach festgelegten Richtlinien und Standards. Die *Verpflichtung zu Weiterbildungsangeboten* (7) erfordert sowohl regelmäßige Teilnahme an als auch die Bereitstellung von Weiterbildungen.

Die Einhaltung dieser Prinzipien trägt dazu bei, dass vertrauenswürdige Anwendungen im Hochschulstudium nachhaltig im Einsatz bleiben. Bei der Gestaltung und Entwicklung von Feedback-Anwendungen müssen neben den Rahmenbedingungen zudem verschiedene Perspektiven in Abstimmung gebracht werden. Im Teilprojekt der FernUniversität in Hagen wurde für die Anwendungsentwicklung zum formativen Feedback nach dem Ansatz der wertesensiblen Gestaltung nach Friedman & Hendry (2019) gearbeitet.

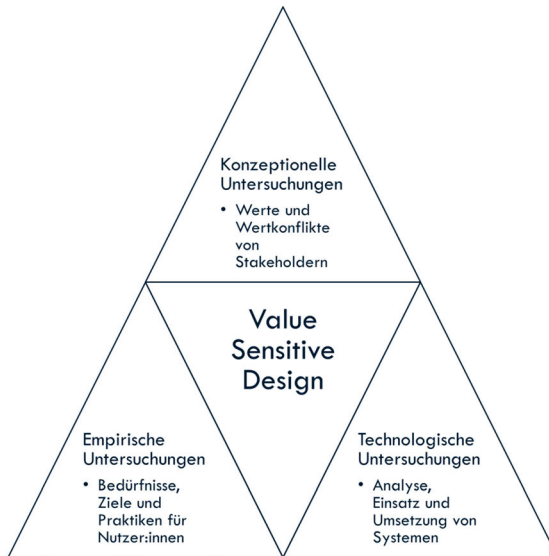
Wertesensible Gestaltung von Feedback-Anwendungen

Die wertesensible Gestaltung von Systemen ist ein zentrales Anliegen bei der Entwicklung von Technologien, um menschliche Werte und Bedürfnisse zu berücksichtigen (Spiekermann 2021; Friedman & Hendry 2019).

Die Triangulation aus konzeptionellen, empirischen und technologischen Untersuchungen, ermöglicht es, ein umfassendes Verständnis von Anforderungen, der aktuellen Praxis und Bedürfnissen zu TLA zu berücksichtigen und so systematische Designentscheidungen zu treffen. Der Ansatz des VSD fungiert als essenzieller Impuls auf dem Weg zu einer verantwortungsvolleren und nachhaltigeren Technologieentwicklung und bindet mehrere Disziplinen in den Designprozess ein.

Konzeptionelle Untersuchungen helfen Werte und Wertkonflikte von Stakeholder:innen in der Anwendungsentwicklung zu identifizieren und zu verstehen. Grundlage dafür bildeten die Befragungen von Studierenden und Mitarbeitenden an der FernUniversität in Hagen, die nach dem SHEILA-Framework (Tsai et al., 2018) ermittelt wurden. Als zweite Grundlage diente der KI-Leitfaden und die Handlungsempfehlungen zu generativer KI (Biederbeck et al. 2023; Biederbeck et al. 2024), die Grundsätze für den Umgang mit KI formulieren und die Hochschule als Akteur in Wissenschaft und Gesellschaft betrachtet. Ein verantwortungsvoller Umgang mit KI, trotz Technologieoffenheit, gilt dabei als essenziell.

Abb. 1: Aspekte des Value Sensitive Design (eigene Darstellung)



Empirische Untersuchungen hingegen konzentrieren sich auf Bedürfnisse, Ziele und Praktiken für Nutzer:innen. Damit fließen die Erkenntnisse der empirischen Bildungsforschung u.a. zu Feedback, zu Feedback Literacy und zu Online-Engagement mit ein. Die empirische Bildungsforschung zeigt, dass insbesondere HIF, ein entscheidender Faktor für den Lernerfolg ist, da es kognitive Leistung, Motivation, Verhalten und Emotionen positiv beeinflusst

(Hattie 2009; Wisniewski et al. 2020). HIF hat mit einer Effektstärke von $d = 0,99$ den größten Einfluss auf den Lernerfolg und zeichnet sich dadurch aus, dass es nicht nur korrektive Rückmeldungen, mit Informationen zur Selbstregulation, Aufmerksamkeit und Selbstreflexion verknüpft. Grundvoraussetzung dafür, dass Studierende Feedbackinformationen für sich nutzbar machen können, sind aber auch hinreichende Kenntnisse von Feedback Literacy (Woit et al. 2023).

Die gängige Praxis wird aber auch durch gesetzliche Rahmenbedingungen, wie die Datenschutzgrundverordnung (DSGVO) und AI-Act, mit der Erwartung zu Transparenz, der Bereitstellung von Informationen zu und der Aufklärung über den Umgang mit Daten sowie deren Verarbeitung bestimmt. Diese Informationen wurden in unterschiedliche Komponenten des Userinterfaces integriert. Für die Erlangung informierter Einwilligungen wurde ein sogenannte Privacy by Default Systematik umgesetzt und im Zuge dessen eine direkte Verknüpfung zu Datenbanken angelegt. Dies hat direkte Konsequenzen für die Datennutzung und Visualisierung im System. Die enge Abstimmung mit Datenschutzbeauftragten diente der Sicherstellung, dass alle erforderlichen Schritte eingehalten wurden. Die Gewährleistung menschlicher Aufsicht und Transparenz bei der Nutzung von KI-Systemen ist zentral für die Compliance zum AI-Act. Ebenso ist eine systemseitige Kontrolle unerwünschter oder fehlerhafter Ausgaben bei der Nutzung von kennzeichnungspflichtiger generativer KI (genKI) erforderlich.

Technologische Untersuchungen, die die Anwendungsentwicklung durch Vorabanalysen und Möglichkeiten des technischen Einsatzes sowie deren Umsetzung in Systemen begleiten, sind zentral für die Bereitstellung von robusten und vertrauenswürdigen KI-Anwendungen. In der technischen Umsetzung bestand die Herausforderung darin, Lösungen zu finden, um die in den konzeptionellen und empirischen Untersuchungen identifizierten Aspekte als zentrale Bedarfe sowie didaktische Elemente oder prozedurale Strukturen zu berücksichtigen. Informationen zu Feedback Literacy sowie Transparenzinformationen zu genutzten Kennzahlen und Daten werden in beiden Anwendungen beispielsweise kontextbezogen in Infoboxen bereitgestellt.

Gestaltung von KI-gestütztem formativem Feedback

In dem entwickelten IMPACT-Feedbackzentrum wird HIF über zwei Anwendungen an Studierende ausgegeben: Es handelt sich zum einen um ein **Monitoring Information Dashboard (MIND)** mit interaktiven Visualisierungen zum Self-Monitoring, das in Hanses et al. (2024) ausführlich beschrieben wurde. Zum anderen stellt das Feedbackzentrum eine KI-gestützte Web-Anwendung zu »**Corrective Formative Feedback**« (COFFEE) zur Verfügung, das hier im Weiteren beschrieben wird. COFFEE nutzt eine Kombination aus vorgegebenen Regeln und Kriterien sowie der Einsatz lokaler Large Language Models (LLM). Das Resultat ist ein Feedback zu den von Studierenden verfassten Freitextantworten, das eine Rückmeldung dazu gibt, wie die Lösung in Bezug auf vorab definierte Kriterien verbessert werden kann. Es lässt sich damit nahtlos in ein verbreitetes hochschuldidaktisches Lehrformat einsetzen. Bei einem LLM-generierten »korrektiven« Feedback ohne direkte menschliche Supervision ist der Prozess, über den das Feedback umgesetzt wird, entscheidend.

*Die Grundidee des formativen Feedbacks in COFFEE liegt darin, Studierende **nicht** durch die KI bewerten zu lassen, sondern ein LLM zu nutzen, um Studierenden zu verdeutlichen, was eine gute Lösung ausmacht.*

Studierenden wird mit COFFEE ein schnelles Überprüfen von Lösungsvorschlägen für spezifizierte Freitextaufgaben ermöglicht.

Regelbasiertes und KI-gestütztes korrekatives Feedback


COFFEE kombiniert vordefinierte Regeln und Kriterien mit lokalen Large Language Models (LLM).

Der Prozess, durch den Lehrende ein korrekatives Feedback in COFFEE anlegen (vgl. Abb. 2), besteht aus mehreren Schritten:

1. Zunächst wird eine Aufgabe im Feedbackzentrum angelegt, bei der Informationen wie Titel, Beschreibung und Anforderungen eingetragen werden.
2. Im nächsten Schritt werden Bewertungsregeln und Rubrics für eine Aufgabe definiert. Lehrende können verschiedene Kriterien wie z. B. Inhalt, Struktur, Stil oder Grammatik im System mit einem Prompt festlegen.

3. Die Kriterien ordnen die Lehrenden dann einer Aufgabe zu, sodass für jede Aufgabe nur die von ihnen erwünschten Kriterien verwendet werden.
4. Nachdem die Aufgabe und die Bewertungskriterien sowie deren Reihenfolge definiert sind, kann die Aufgabe veröffentlicht werden.

Abb. 2: Systematisierung für ein regelbasiertes formatives Feedback



Bewertungskriterien werden über einen formulierten Prompt an ein ausgewähltes LLM übermittelt. In dem Prompt können auch nicht erwünschte Ausgaben definiert werden. Die Kenntlichmachung der Nutzung von genKI und Informationen zu den verwendeten Prompts werden transparent sowie kontextbezogen automatisiert aktualisiert und auf der Nutzeroberfläche bereitgestellt. Das korrektive Feedback, das durch diesen Prozess generiert wird, ist skalierbar und kann für eine Vielzahl von Aufgaben und Studierenden angepasst werden. Es kombiniert eine von Lehrenden vorgegebene regelbasierte Bewertung mit der Einbindung von LLMs, um Feedback bereitzustellen, das die Erwartung an eine gute Aufgabenlösungen aufzeigt. Voraussetzung für die Umsetzung des regelbasierten Ansatzes ist, dass es zu den Aufgaben klare Bewertungsregeln z.B. durch Operatoren oder Rubrics (English et al., 2022; Nordrum, Evans & Gustafsson, 2013) gibt, die auf die Ebene eines Kriteriums heruntergebrochen werden können (vgl. Abbildung 2).

Prompt Engineering und Qualitätssicherung

Eine der größeren Herausforderungen besteht in der Sicherung der Qualität, die durch die Nachteile der generativen KI, z.B. fehlerhafte Ausgaben, entstehen. In Ermangelung gesicherter Erkenntnisse zum Prompt-Engineering für formative Feedbacks durch LLMs haben sich im Projekt nach intensiver und

sorgfältiger Exploration folgende Aspekte bei der Formulierung von Prompts bewährt. Ein Prompt sollte:

- inhaltlich strukturiert, in kurzen, vollständigen Sätzen formuliert sein und wenige Formatierungen verwenden.
- eine reduzierte Komplexität für das LLM aufweisen (nur ein Kriterium enthalten).
- Kontextinformationen zur Aufgabe bereitstellen (z.B. Lehrtext).
- Antwortstil und Verbotsregeln beschreiben (z.B. sachlich, akademisch, keine Punktzahlen).
- die Struktur des Feedbacks beschreiben (z.B. erst positive Aspekte, dann Fehler, dann (?) Inhalt guter Lösung beschreiben).
- konsistente Begrifflichkeiten verwenden (z.B. nicht wahlweise »Aufgabe« und »Lösungsversuch«).

Um sicherzustellen, dass das korrektive Feedback sowohl fair, transparent und wirksam ist, als auch die menschliche Aufsicht gewährleistet, müssen Bewertungskriterien und Prompts transparent und nachvollziehbar sein. Der Ansatz respektiert die Autonomie der Studierenden und unterstützt die persönliche Entwicklung in einem geschützten Rahmen, da alle Feedbackbereiche so gestaltet sind, dass Lehrende keinen Einblick in die individuellen Ergebnisse erhalten.

Die EU-Vorgaben wurden mit dem AI-Act Compliance Checker überprüft und nachgehalten. Transparenz zur Anwendung, Unterdrückung ungewollter Inhalte sowie die Kennzeichnung von genKI wurden durch die Implementierung von geeigneten Mechanismen und kontextbezogenen Systemhinweisen sichergestellt, in denen auch über den Einsatz von LLMs und die (didaktische) Funktion informiert wird. Die bisherigen Rückmeldungen der Studierenden belegen, dass COFFEE einen deutlichen Mehrwert im Lernprozess bietet und eine hohe Akzeptanz hat.

Fazit & Ausblick

Der Beitrag zeigt, wie ein VSD-Ansatz dazu beiträgt, die Potenziale von KI für eine skalierbare Bereitstellung von formativem Feedback zu nutzen und gleichzeitig Aspekte für einen vertrauenswürdigen Einsatz von LA und KI bereits in der Anwendungsentwicklung zu berücksichtigen. Die Feedback-

anwendung COFFEE stellt Studierenden KI-geschriebenes HIF innerhalb weniger Sekunden bereit und ermöglicht es ihnen, gezielt ihre Fähigkeiten und Leistungen selbstverantwortlich zu verbessern. Orientiert an den Grundsätzen von Lehre und Didaktik wird die menschliche Kontrolle gewahrt, um sicherzustellen, dass die bereitgestellten Informationen sachgerecht und für die Studierenden relevant sind, aber auch ein Deskillung (Reinmann 2023) vermieden wird. Autonomie, Transparenz und Interpretierbarkeit werden durch kontextnahe und -relevante Informationen in der Anwendung gewährleistet.

Die wertesensibel gestalteten Feedbackanwendungen des IMPACT-Feedbackzentrums bieten eine wertvolle Ergänzung zum Lehren und Lernen an Hochschulen. Dennoch ergeben sich Herausforderungen, da für die lernförderliche Nutzung Kenntnisse von Feedback Literacy bei Lernenden Voraussetzung sind. Lehrende, die die Feedbackanwendung in ihr Fach übertragen möchten, können strukturierte Bewertungsregeln für ihre Aufgaben in einen Prompt überführen, müssen dann aber über aufwendiges Testen sicherstellen, dass ihre Vorgaben auch tatsächlich zuverlässig umgesetzt werden. Die Qualitätssicherung stellt damit eine zentrale Notwendigkeit beim Einsatz generativer KI im Hochschulstudium, die in Zukunft noch verbessert und systematisiert werden muss.

Danksagung

Die Autorinnen und Autoren bedanken sich für die Förderung des Verbundprojekts IMPACT im Rahmen der Bund-Länder-Förderinitiative Künstliche Intelligenz in der Hochschulbildung. Das Teilprojekt der FernUniversität in Hagen mit dem Förderkennzeichen 16DHBKI043 wurde durch das Bundesministerium für Bildung und Forschung (BMBF) und das Land Nordrhein-Westfalen für den Zeitraum Dezember 2021 bis November 2025 unterstützt.

Literatur

Biederbeck, A., Bills, A., Gisbert, A., Hinte, Hofmann, U., Karolyi, H., Kempka, A., Opel, S., Kempka, A., Remic, O., Schröder, A., Sorichter, N., Sperl, A., Terbeck, M., De Witt, C., 2024. Handlungsempfehlungen für den didaktischen Einsatz von generativer KI in der Hochschullehre.

- Biederbeck, A., Bils, A., Gisbert, A., Karolyi, H., Kempka, A., Opel, S., Sperl, A., De Witt, C., 2023. KI-Leitfaden der FernUniversität in Hagen Grundsätze und Orientierungshilfen für die Nutzung von Künstlicher Intelligenz in Lehre und Studium.
- English, N., Robertson, P., Gillis, S., Graham, L., 2022. Rubrics and formative assessment in K-12 education: A scoping review of literature. *International Journal of Educational Research* 113, 101964. <https://doi.org/10.1016/j.ijer.2022.101964>
- Friedman, B., Hendry, D., 2019. Value sensitive design: shaping technology with moral imagination. The MIT Press, Cambridge, Massachusetts.
- Hansen, J., Rensing, C., Herrmann, O., Drachsler, H., 2020. Verhaltenskodex für Trusted Learning Analytics. Version 1.0. Entwurf für die hessischen Hochschulen. <https://doi.org/10.25657/02:18903>
- Hanses, M., Van Rijn, L., Karolyi, H., De Witt, C., 2024. Guiding Students Towards Successful Assessments Using Learning Analytics From Behavioral Data to Formative Feedback, in: Sahin, M., Ifenthaler, D. (Eds.), *Assessment Analytics in Education, Advances in Analytics for Learning and Teaching*. Springer International Publishing, Cham, pp. 61–83. https://doi.org/10.1007/978-3-031-56365-2_4
- Hattie, J., 2024. Visible learning 2.0. Schneider Verlag Hohengehren GmbH, Baltmannsweiler.
- Nordrum, L., Evans, K., Gustafsson, M., 2013. Comparing student learning experiences of in-text commentary and rubric-articulated feedback: strategies for formative assessment. *Assessment & Evaluation in Higher Education* 38, 919–940. <https://doi.org/10.1080/02602938.2012.758229>
- Reinmann, G., 2023. Deskillung durch Künstliche Intelligenz? Potenzielle Kompetenzverluste als Herausforderung für die Hochschuldidaktik. Diskussionspapier Nr. 25, Hochschulforum Digitalisierung, Berlin.
- Spiekermann, S., 2021. Value-based Engineering: Prinzipien und Motivation für bessere IT-Systeme. *Informatik Spektrum* 44, 247–256. <https://doi.org/10.1007/s00287-021-01378-4>
- Woitt, S., Weidlich, J., Jivet, I., Orhan Göksün, D., Drachsler, H., Kalz, M., 2023. Students' feedback literacy in higher education: an initial scale validation study. *Teaching in Higher Education* 1–20. <https://doi.org/10.1080/13562517.2023.2263838>
- Wisniewski, B., Zierer, K., Hattie, J., 2020. The Power of Feedback Revisited: A Meta-Analysis of Educational Feedback Research. *Front. Psychol.* 10, 3087. <https://doi.org/10.3389/fpsyg.2019.03087>

Informierte Einwilligung für Learning Analytics

Gestaltung eines Informations- und Entscheidungsdialogs¹

Laura Platte, Kyra Thelen und Martin Breuer

Learning Analytics-Angebote an Hochschulen haben große Potenziale zur Verbesserung des Lernens und Lehrens, gehen jedoch mit hohen Anforderungen an den Datenschutz und eine ethische Gestaltung einher. Eine mögliche datenschutzrechtliche Grundlage zur Verarbeitung personenbezogener Daten ist die informierte Einwilligung. Im Rahmen des Projekts KI:edu.nrw entwickelt das Teilprojekt Learning Analytics einen Dialog zur informierten Einwilligung in die Datenverarbeitung durch die Open Source-Software POLARIS. Ein Dialog informiert Studierende über die Learning Analytics-Angebote und unterstützt sie bei einer selbstständigen Entscheidung. Dabei erweitern wir die Anforderungen des Datenschutzes um die Perspektiven der Ethik, der Didaktik und des User Experience und User Interface Designs. In diesem Beitrag stellen wir die vier Gestaltungsperspektiven vor. Abschließend zeigen wir beispielhaft ihre Anwendung an einem Element eines Prototyps des Dialogs und präsentieren die Ergebnisse unseres Workshops auf der Learning AID 2024.

Informed Consent for Learning Analytics: Designing an Information and Decision Dialog

Learning analytics offers at universities have great potential for improving learning and teaching but are accompanied by high demands in terms of data protection and ethical design. One possible legal basis for the processing of personal data is informed consent. As part of the KI:edu.nrw project, the Learning Analytics sub-project is developing a dialog for informed consent to data processing using the POLARIS open source software. In doing so, we are expanding the requirements of data protection to include the perspectives of ethics, didactics and user experience and user interface design. The dialog informs students about the learning analytics offerings and supports them in making an independent decision. In this article, we present the four design perspectives. Finally,

1 Basiert auf einem Workshop im Rahmen der Tagung.

we show an example of their application using an element of a prototype of the dialog and present the results of our workshop at Learning AID 2024.

Einleitung

Learning Analytics-Angebote an Hochschulen bieten das Potenzial, Lernprozesse zu unterstützen und die Qualität der Lehre zu verbessern. Gleichzeitig stellt die damit verbundene Verarbeitung personenbezogener Lerndaten hohe Anforderungen an den Datenschutz und die ethische Gestaltung. Die Datenschutzgrundverordnung (DSGVO) nennt die informierte und freiwillige Einwilligung als eine mögliche Rechtsgrundlage für die Verarbeitung personenbezogener Daten (Art. 6 DSGVO; Geminn/Johannes/Nebel/Bile 2023).

Die naheliegende und häufig gewählte Lösung besteht darin, den Studierenden die umfangreichen Datenschutzhinweise in reiner Textform zu präsentieren. Aufgrund des oft erheblichen Textumfangs und der inhaltlichen Komplexität, die ein gewisses Vorwissen über Themen wie Informationsverarbeitung erfordert, stellt dies jedoch eine erhebliche Barriere dar. Für eine nachhaltige Information der Studierenden, die diese zu autonomen Entscheidungen über den Umgang mit ihren Lerndaten befähigt, greift diese Variante also zu kurz.

Als Alternative stellen wir in diesem Beitrag unseren Ansatz aus dem Projekt *KI.edu.nrw* vor. Die im Rahmen des Projekts entwickelte Open Source-Software POLARIS (Provider Oriented Open Learning Analytics) verfügt über ein Einwilligungsmanagement, das um einen Dialog zur informierten Einwilligung erweitert wird. Wir betrachten die informierte Einwilligung als wertvollen frühen Kontaktpunkt der Studierenden in ihrer Auseinandersetzung mit Learning Analytics. Die Informationsangebote der Einwilligung sollen die Studierenden beim langfristigen souveränen Umgang mit ihren Lerndaten unterstützen.

Im ersten Unterkapitel stellen wir verschiedene Perspektiven vor, aus denen wir Anforderungen an die Gestaltung eines Informations- und Entscheidungsdialogs ableiten: *Datenschutz, Ethik, Didaktik* und *User Experience und User Interface Designs (UI/UX Design)*. Im zweiten Unterkapitel stellen wir den auf dieser Basis entwickelten Prototypen des Dialogs vor.

Perspektiven auf die informierte Einwilligung

Datenschutz

Aus der Perspektive des Datenschutzes ist die informierte Einwilligung *eine der in Art. 6 DSGVO genannten Rechtsgrundlagen der Datenverarbeitung*. Betroffene können in die Verarbeitung ihrer personenbezogenen (Lern-)Daten einwilligen, wenn diese Einwilligung informiert und freiwillig geschieht (Geminn/Johannes/Nebel/Bile 2023). Die DSGVO definiert detaillierte Vorgaben bezüglich des Inhalts der Information, z.B. zum Zweck der Datenverarbeitung (Art. 13(1 c) DSGVO) und dem Widerrufsrecht (Art. 13(2b) DSGVO), die als Datenschutzhinweise zur Verfügung gestellt werden.

Ethik

Aus Perspektive der Ethik betrachten wir die informierte Einwilligung als *reflexionsbedürftige Situation, in der ein starkes Machtgefälle zwischen den Studierenden und der Hochschule berücksichtigt werden muss*.

Zu Beginn müssen die zentralen Begriffe und Kriterien definiert werden: Verstehen wir die Einwilligung z.B. eine *Entscheidung zu einem Zeitpunkt* oder handelt es sich um einen *Prozess*? Wir verstehen die informierte Einwilligung als einen Prozess, in dem die Studierenden durch von der Hochschule bereitgestellte Information selbstgesteuert ein Verständnis eines konkreten Learning Analytics-Angebots entwickeln und Entscheidungen zur Verarbeitung ihrer Lerndaten im Rahmen dieses Angebots treffen, überprüfen und bei Bedarf widerrufen.

Im Sinne der *Ethics by design* soll die ethische Reflexion den gesamten Entwicklungsprozess von Learning Analytics begleiten und nicht als nachgelagerte Folgenabschätzung umgesetzt werden (Salden/Leschke/Persike 2024).

Es gilt, verschiedene potenzielle Interessenskonflikte zu berücksichtigen: Beispielsweise hat die Hochschule ein Interesse an der Zustimmung der Studierenden, da sie sich durch die Daten wertvolle Erkenntnisse über das Lernen verspricht. Gleichzeitig hat sie die Aufgabe, neutral über die Verarbeitung von Lerndaten zu informieren und eine echte Freiwilligkeit zu ermöglichen.

Didaktik

Im Rahmen der informierten Einwilligung müssen Studierende zu einer selbstständigen Entscheidung befähigt werden. Aus Perspektive der Didaktik kann die informierte Einwilligung *als Anlass der Kompetenzentwicklung* betrachtet werden.

Um eine informierte Entscheidung zu treffen, benötigen Studierende Kenntnisse in verschiedenen Bereichen. Dazu gehören zum einen grundlegende Kenntnisse im Bereich Data Literacy (Schwarz/Jeworutzki 2024), wie ein Verständnis von technischen Maßnahmen Datenverarbeitung. Außerdem benötigen sie bestimmte Informationen über die konkreten Prozesse der jeweiligen Learning Analytics-Infrastruktur ihrer Hochschule.

Die didaktische Perspektive berücksichtigt zudem die Voraussetzungen der Zielgruppe, die in diesem Fall sehr heterogen ist: Es müssen Unterschiede im Vorwissen und Informationsinteresse berücksichtigt werden. Aus medienpädagogischer Sicht ist es zudem sinnvoll, die Erklärungen multimedial statt in reiner Textform umzusetzen, z. B. durch Abbildungen (Mayer 2021).

UI/UX Design

Das UI/UX Design betrachtet die informierte Einwilligung als *interaktive Oberfläche, die entlang der Nutzendenbedürfnisse gestaltet werden muss*. Ein gelungenes Design muss die Erwartungen und Bedürfnisse der Studierenden in den Mittelpunkt stellen. Dazu gehört zum Beispiel eine reibungslose Navigation im Dialog.

Dieser nutzendenzentrierte Ansatz liefert eine Reihe von Methoden, um etwa die Verständlichkeit und Navigierbarkeit des Entscheidungsdialogs früh im Gestaltungsprozess zu testen. Mit Think Aloud-Studien (bei denen die Teilnehmenden ihre Gedanken beim Bearbeiten einer Aufgabe laut aussprechen; Nielsen/Clemmensen/Yssing 2002) und Interviews können potenziell missverständliche Elemente identifiziert und verbessert werden.

Die Anforderungen der barrierefreien Gestaltung umfassen zum einen technische Kriterien wie Tastaturnavigierbarkeit. Darüber hinaus beinhalten sie viele Gestaltungsrichtlinien, von denen alle Nutzenden profitieren: Stark gegliederte Texte mit einfach verständlichen Formulierungen, eindeutig benannte Hyperlinks und Abbildungen mit hohen Kontrasten machen den Dialog für alle Nutzenden besser zugänglich.

Entwurf eines Informations- und Entscheidungsdialogs für die Plattform POLARIS

POLARIS ist eine Open Source-Softwarelösung für Learning Analytics, die im Rahmen des Projekts KI:edu.nrw unter Koordination der RWTH entwickelt wird (Vorarbeiten: Judel/Schroeder 2022; Metzger/Bovermann 2024). POLARIS arbeitet quellsystemübergreifend. Das bedeutet, dass Lerndaten aus verschiedenen so genannten Datenquellen wie Campusmanagement-, Lernmanagement- oder e-Prüfungssystemen zusammengeführt werden, um didaktisch begründete Statistiken und Rückmeldungen bereitzustellen. Eine Kernfunktionalität von POLARIS ist das zentrale Einwilligungsmanagement. Zusätzlich stellt POLARIS eine Schnittstelle bereit, Einwilligungen extern zu setzen und somit Informations- und Entscheidungsdialoge direkt in den Quellsystemen anzubieten. Ein Klick auf den Button »Statistiken aktivieren« öffnet ein Modalfenster, in dem der Dialog angezeigt wird.

Der erste Prototyp des Dialogs

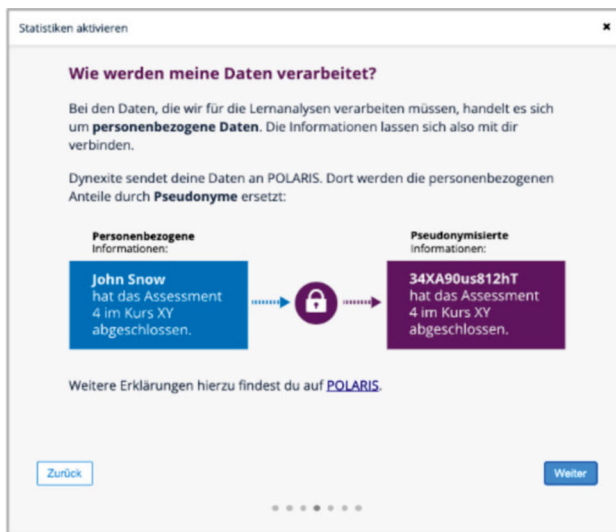
Auf Basis der oben umrissenen Perspektiven wurde ein erster Prototyp des Dialogs für eine Statistik zum Übungsfortschritt im e-Prüfungssystem DYNEXITE (<https://v3.docs.dynexite.rwth-aachen.de/>) entwickelt.

Um die gleichzeitig angezeigte Informationsmenge zu reduzieren, wird im Modalfenster nicht der vollständige Rechtstext der Datenschutzhinweise angezeigt. Stattdessen navigieren die Studierenden selbstständig durch einen siebenschrittigen Dialog (siehe Abbildung 1). Die Texte geben mit niederschweligen Erklärungen eine Übersicht über die zentralen Informationen, die sich unter anderem aus der ethischen und didaktischen Perspektive ableiten (z.B. was Learning Analytics und POLARIS sind oder einen Hinweis auf Freiwilligkeit und Widerrufsrecht). Zusätzliche Erklärungen sowie die rechtsverbindlichen Datenschutzhinweise können die Studierenden über Hyperlinks aufrufen.

Abbildung 1 zeigt beispielhaft den vierten Schritt des Dialogs. Unter der Überschrift »Wie werden meine Daten verarbeitet?« wird in einfachen Formulierungen und mithilfe einer schematischen Abbildung vereinfacht erklärt, wie personenbezogene Lerndaten in POLARIS pseudonymisiert werden. Es ist anzunehmen, dass nicht allen Studierenden das Konzept der Pseudonymisierung hinreichend bekannt ist. Daher leitet sich aus der Perspektive der Ethik und der Didaktik ab, zusätzliche Information anzubieten. Die Lesbarkeit

des Textes wird durch die starke Gliederung in Absätze unterstützt. Zusätzlich hebt der Fettsatz die beiden Konzepte hervor, die gegenübergestellt werden. In der letzten Textzeile sind ausführlichere Erklärungen verlinkt. Dies ermöglicht den Studierenden eine Auseinandersetzung mit der Datenverarbeitung gemäß ihres individuellen Informationsbedarfs. Die Navigationselemente im unteren Bereich des Modalfensters erlauben es, sich im Dialog zu orientieren und selbstgesteuert vor- und zurückzubewegen.

Abb. 1: Gestaltung des Dialogs am Beispiel des vierten Schritts



Ergebnisse des LAID-Workshops

Die vier Perspektiven und der Prototyp des Dialogs wurden im Rahmen eines 90-minütigen Workshops auf der Learning AID 2024 vorgestellt. In der Kleingruppenphase wurden aus den beschriebenen Perspektiven heraus Ansätze zu Verbesserung des Dialogs entwickelt. Die Teilnehmenden wählten dabei selbst die Gruppe, deren Perspektive sie einnehmen wollten.

Ein viel diskutiertes Thema in den Gruppen Didaktik und UI/UX Design war die Frage, wie die notwendige Informationsmenge noch effektiver organisiert und individualisiert werden kann. Insbesondere bei einer wiederholten

Bearbeitung des Dialogs soll eine Verkürzung ermöglicht werden. Die einführnden Erklärungen können beim wiederholten Bearbeiten als bekannt vorausgesetzt werden; andere aus datenschutzrechtlicher und ethischer Sicht wichtige Informationen, wie die Freiwilligkeit und das Widerrufsrecht, sollten Teil des Dialogs bleiben. Den Studierenden könnte außerdem im ersten Schritt eine Auswahl angeboten werden, ob sie ausführliche oder kompakte Information erhalten wollen.

Als weiteres Verbesserungspotential aus ethischer Sicht wurde die ausführlichere Darstellung von potenziellen negativen Konsequenzen von Learning Analytics identifiziert.

Fazit und Ausblick

An die informierte Einwilligung zu Learning Analytics an Hochschulen werden hohe Anforderungen gestellt. Die vorläufigen Ergebnisse dieses Beitrags verdeutlichen, dass eine multiperspektivische Herangehensweise bei der Ausgestaltung des Prozesses äußerst lohnend ist: Ein gut gestalteter Dialog kann einen wertvollen Kontaktpunkt zu den Studierenden zu schaffen, der sie beim Aufbau eines grundlegenden Verständnisses von Learning Analytics und einer selbstbestimmten Entscheidung unterstützt.

Je nach Anwendungsfall bietet es sich an, weitere Gestaltungsperspektiven gewichtet aufzunehmen, zum Beispiel für die technische Umsetzbarkeit und einen nachhaltigen Betrieb. Der hier vorgestellte Dialog wird im nächsten Schritt an der RWTH Aachen pilotiert, evaluiert und weiterentwickelt. Bereits bei der Entwicklung des ersten Prototyps wurde angestrebt, technische Komponenten wiederverwendbar und interoperabel zu gestalten (Salmen/Breuer/Görzen/Persike/Schroeder 2024). Künftig sollen diese Komponenten in POLARIS integriert werden, sodass eine Integration in weitere Quellsysteme ohne maßgeschneiderte Eigenentwicklungen möglich ist.

Dieser Beitrag ist im Rahmen des vom Ministerium für Kultur und Wissenschaft des Landes Nordrhein-Westfalen geförderten Projekts »KI:edu.nrw – Didaktik, Ethik und Technik von Learning Analytics und KI in der Hochschulbildung« entstanden.

Literatur

- Metzger, Christian/Bovermann, Martin (2024): »KI:edu.nrw – eine Betrachtung aus der Perspektive des Teilprojektes Technik«, in: Peter Salden/Jonas Leschke (Hg.), *Learning Analytics und Künstliche Intelligenz in Studium und Lehre*, Wiesbaden: Springer Fachmedien, S. 109–126.
- Geminn, Christian/Johannes, Paul/Nebel, Maxi/Bile, Tamer (2023): »Datenschutzrechtliche Beurteilung von Learning Analytics an Hochschulen in NRW«. Studie im Auftrag der Ruhr-Universität Bochum.
- Judel, Sven/Schroeder, Ulrik (2022): »EXCALIBUR LA – An Extendable and Scalable Infrastructure Build for Learning Analytics«, in: *International Conference on Advanced Learning Technologies (ICALT 2022)*, S. 155–157.
- Mayer, Richard E., (2021): *Multimedia Learning*. Cambridge/New York/Port Melbourne: Cambridge University Press.
- Nielsen, Janni/Clemmensen, Torkil/Yssing, Carsten (2002): »Getting access to what goes on in people's heads? Reflections on the think-aloud technique«, in: *Proceedings of the Second Nordic Conference on Human-Computer Interaction*, S. 101–110.
- Salden, Peter/Leschke, Jonas/Persike, Malte (2024): »Das Projekt KI:edu.nrw – Rückblick für einen Ausblick«, in: Peter Salden/Jonas Leschke (Hg.), *Learning Analytics und Künstliche Intelligenz in Studium und Lehre*, Wiesbaden: Springer Fachmedien, S. 225–243.
- Salmen, Frederic/Breuer, Martin/Görzen, Sergej/Persike, Malte/Schroeder, Ulrik (2024): »FAIR Learning Technologies with Web Components and Packages«, in: *Proceedings of DELFI 2024*, Gesellschaft für Informatik e.V., S. 267–274.
- Schwarz, Tabea, Jeworutzki, Sebastian (2024): »Data Literacy für Learning Analytics«, in: Peter Salden/Jonas Leschke (Hg.), *Learning Analytics und Künstliche Intelligenz in Studium und Lehre*, Wiesbaden: Springer Fachmedien, S. 225–243.

Dashboards entschlüsseln

Workshopergebnisse zur Verbesserung von Learning Analytics Visualisierungen¹

Tabea Schwarz² und Benjamin Ledel³

Dieses Paper präsentiert die Ergebnisse eines Workshops zum Design von Learning Analytics Dashboards (LADs). Im Fokus steht die Frage, inwieweit alle Nutzer:innen in die Lage versetzt werden können, solche LADs zu verstehen, insbesondere angesichts der wachsenden Bedeutung von AI Literacy und Data Literacy. Die Förderung dieser Kompetenzen ist für die Förderung von Mündigkeit wesentlich, aber es ist zu diskutieren, ob dies allein ausreicht, um eine breite Nutzung von LADs zu ermöglichen. Daher plädiert das Paper dafür, neben der Stärkung von Literacy auch der barrierefreien und nutzerfreundlichen Gestaltung von LADs Priorität einzuräumen. Der Workshop, dessen Ergebnisse hier vorgestellt werden, adressierte speziell diesen zweiten Aspekt und liefert wertvolle Einblicke in das Design von LADs, die eine bessere Zugänglichkeit für alle AnwenderInnen gewährleisten sollen.

Decoding Dashboards: workshop results for improving learning analytics visualisations

This paper presents the results of a workshop on the design of learning analytics dashboards (LADs). It focuses on the extent to which all users can be empowered to understand such LADs, particularly in light of the growing importance of AI and data literacy. Fostering these skills is essential for promoting autonomy, but it is debatable whether this alone is sufficient to enable the widespread use of LADs. The paper therefore argues that, in addition to improving literacies, priority should be given to making LADs accessible and user-friendly. The workshop, the results of which are presented here,

1 Basiert auf einem Workshop im Rahmen der Tagung.

2 ORC-ID: 0009-0000-6966-8912

3 ORC-ID: 0000-0002-6776-0472

specifically addressed this second aspect and provides valuable insights into the design of learning analytics dashboards that should ensure better accessibility for all users.

Learning Analytics: Chancen und Risiken

In der modernen Bildungslandschaft haben technologische Innovationen, insbesondere im Bereich der digitalen Technologien, tiefgreifende Veränderungen herbeigeführt. Eine zentrale Entwicklung ist dabei die Einführung von Learning Analytics (LA), die es Bildungseinrichtungen ermöglicht, Daten über das Lernverhalten der Studierenden zu sammeln und auszuwerten, um den Lernprozess gezielt zu unterstützen (Schwarz/Jeworutzki 2024: 226; Ebner 2019: 46; Siemens 2013: 1382). Dabei besteht die Erwartung, durch die Analyseergebnisse wertvolle Einblicke in Lernprozesse zu gewinnen, die sowohl Lernende als auch Lehrende nutzen können (Schwarz/Jeworutzki 2024: 226; Ebner 2019: 46; Chatti et al. 2012: 319–320).

Hinter diesen Ergebnissen stehen verschiedene, oftmals komplexe Analysen, die von deskriptiver Statistik bis hin zu maschinellem Lernen reichen können. Im Anschluss an die Analysen werden die Endergebnisse in vielen Fällen in Form von Learning Analytics Dashboards (LADs) zusammengefasst, um den Adressat:innen einen einfachen Zugang zu ermöglichen. Dabei handelt es sich häufig um grafische Darstellungen und damit um starke Vereinfachungen der zugrunde liegenden Daten (Schwarz/Jeworutzki 2024: 232–233).

Den Chancen, die diese aufbereiteten Lerndaten für Lehrende und Lernende bieten, stehen jedoch auch Herausforderungen gegenüber. Analysen bringen immer eine Veränderung der Daten mit sich und somit entsteht bei der Nutzung der Ergebnisse unter anderem das Risiko von Verzerrungen und Fehlinterpretationen, da diese während der Analyse kontinuierlich angepasst und interpretiert werden müssen. Des Weiteren besteht die Gefahr der Fehlinterpretation der Endergebnisse durch Lehrende und Lernende, da ein Teil von ihnen die Daten aufgrund von fehlenden Kompetenzen nicht kontextualisieren kann (Schwarz/Jeworutzki 2024: 226–227). Es wird somit zur richtigen Interpretation ein kritischer Umgang mit den Ergebnissen und der Art und Weise, wie diese genutzt werden können, benötigt.

In diesem Zusammenhang spielen Data Literacy (DL) und AI Literacy (AIL) eine Schlüsselrolle. Sie sind ein essenzieller Hebel für Individuen, um die Ergebnisse von LA angemessen zu interpretieren und datengestützte Entscheidungen zu treffen (Laupichler et al. 2023: 1; Schüller et al. 2021: 4. Doch sie sind

nicht der einzige Weg die visualisierten Daten zugänglicher zu machen. Ein zusätzlicher Anknüpfungspunkt ist ein nutzerfreundliches Design von Dashboards. Doch trotz der Beliebtheit von LADs wird der Designaspekt in der Forschung oftmals vernachlässigt (Sedrakyan 2020: 1–2).

Das folgende Paper setzt genau an diesem Zweiklang aus Literacies und Design an und diskutiert, wie ein zugängliches Design von LADs dazu beitragen kann, dass alle Nutzer:innen – unter Rücksichtnahme Vorwissen – diese Systeme effektiv nutzen können. Die Ergebnisse des Workshops zum Design von LADs bilden den Schwerpunkt des Papers und liefern einen wertvollen Lösungsansatz.

Literacies und Design: Zwei Säulen der Zugänglichkeit

Um die Ergebnisse des Workshops angemessen einordnen zu können, werden im Folgenden die grundlegenden theoretischen Konzepte zusammengefasst, die sowohl AIL als auch DL sowie das Design von LADs betreffen. Diese Konzepte sind von entscheidender Bedeutung, da sie auf unterschiedliche Weise interpretiert und angewendet werden können. Zu Beginn bedarf es daher einer klaren Definition von AIL und DL. In diesem Paper wird sich auf die Definitionen von Schüller et al. (2019) für DL und Laupichler et al. (2023) für AIL bezogen. DL umfasst die grundlegenden Datenkompetenzen, die in einer zunehmend digitalisierten Welt für alle Menschen von zentraler Bedeutung sind und stellt, nach Schüller et al. (2021: 1) einen unverzichtbaren Bestandteil der Allgemeinbildung dar. AIL hingegen bezieht sich auf Kompetenzen, welche das grundlegende Verständnis und die analytische Bewertung von KI sowie die kritische Nutzung von KI-Anwendungen durch Nicht-Expert:innen umfassen (Laupichler et al. 2023: 1).

Vor diesem Hintergrund wird ersichtlich, dass im Kontext von LA (wenn diese KI-gestützt sind) eine Verknüpfung beider Literacies notwendig ist. Schüller et al. (2021: 16) argumentieren, dass DL eine zentrale Voraussetzung für die Mündigkeit von Bürger:innen darstellt. Im Bildungsbereich müssen diese Mündigkeitsvoraussetzungen im Kontext von LA erweitert werden, um eine autonome Nutzung von LADs zu ermöglichen. Ein besonders herausfordernder Aspekt für den Bildungsbereich ist in diesem Zusammenhang das breite Spektrum an Fähigkeiten, die sowohl AIL als auch DL erfordern. Denn diese umfangreichen Kompetenzspektren müssen in einer von Heterogenität geprägten Lernumgebung vermittelt werden. Hochschulen und Universitäten

sehen sich mit Studierenden und Lehrenden konfrontiert, die unterschiedliche Vorkenntnisse und Zielsetzungen mitbringen (Schwarz/Jeworutzki 2024: 237). Dies wirft die Frage auf, ob die Förderung dieser Kompetenzen mit der schnellen Implementierung von LADs Schritt halten kann.

Um die Zugänglichkeit von LADs nicht ausschließlich von Schulungsmaßnahmen und der Motivation der NutzerInnen abhängig zu machen, spielt daher das Design eine unterstützende Rolle. Ein benutzerfreundliches Design soll es auch Nutzer:innen mit geringen Datenkompetenzen, sei es aufgrund fehlender Ressourcen oder persönlichen Desinteresses, ermöglichen, die LADs bestmöglich zu verwenden. In der Forschung bezüglich der Gestaltung von LADs, primär für Studierende, gewinnen dabei theoretisch fundierte Frameworks zunehmend an Bedeutung, wie Paulsen und Lindsay (2023: 14288) in ihrer systematischen Überprüfung betonen. Ihre Analyse zeigt zudem, dass sich das Design solcher LADs immer stärker an pädagogischen Prinzipien orientiert und nicht mehr rein analytikgetrieben ist. Hierbei identifizieren sie zwei Hauptkategorien von Frameworks, die das Dashboard-Design beeinflussen: theorieorientierte und designorientierte Frameworks. Theorieorientierte Frameworks umfassen pädagogische Theorien, wie den sozialen Konstruktivismus, sowie psychologische Konzepte, wie das selbst-regulierte Lernen (Self-Regulated Learning (SRL), vgl. Lu et al. 2020). Zu den designorientierten Frameworks gehören Ansätze wie das nutzerzentrierte Design (User-Centred Design, vgl. Duan et al. 2022). Doch trotz der zunehmenden Anwendung solcher Frameworks bleibt festzustellen, dass eine signifikante Anzahl von LADs nach wie vor ohne theoretische Grundlage gestaltet wird. Dies verdeutlicht, dass es weiterhin Lücken in der konsistenten Anwendung fundierter theoretischer Ansätze gibt, obwohl der Trend hin zu pädagogisch informierten Dashboards insgesamt zunimmt (Paulsen/Lindsay, 2023: 14288).

Workshop-Ergebnisse

Die unterschiedlichen Möglichkeiten bei Designansätzen und den oftmals fehlenden Fundierungen bei der Gestaltung, besonders in Bezug auf Kompetenzen, von LADs bildeten den Impuls des Workshops zur Entwicklung von Anforderungen für LADs. Dieser wurde auf Basis der Design Thinking-Methode durchgeführt. Dieser iterative und nutzerzentrierte Ansatz erweist sich als besonders geeignet, da er ermöglichte, losgelöst von bestehenden

Designansätzen mit den Teilnehmenden zu arbeiten und ihre verschiedenen Perspektiven in den Prozess einzubeziehen. Die Workshop-Teilnehmer:innen, bestehend aus Expert:innen verschiedener Disziplinen und Bereiche, erhielten zu Beginn eine grundlegende Einführung in die bereits dargestellten Chancen und Risiken von LA sowie die Rollen von Literacies und Design in diesem Kontext. Dies bildete die Basis für die erste Diskussionsphase, um zentrale Anforderungen bei der Nutzung von LADs zu formulieren. Anschließend wurde in einer zweiten Diskussionsphase mit vier Beispiel-LADs gearbeitet, wobei ohne einen Fokus auf die Daten und ihre Ergebnisse das reine Design betrachtet wurde. Hierbei war das Ziel, bereits umgesetzte Anforderungen zu identifizieren und mögliche Verbesserungen für die Gestaltung von benutzerfreundlichen LADs zu entwickeln.

Die Ergebnisse des Workshops verdeutlichen, dass die Gestaltung von LADs auf mehreren Ebenen bedacht werden muss. Zentrale Anforderungen betreffen die Themen Konsistenz und Transparenz, Anpassbarkeit und Usability, wissenschaftliche Fundierung und Hilfestellungen, Vermeidung von Informationsüberflutung, motivierende Anreize und positive Rückmeldungen sowie Ethik und Datenschutz. Im Rahmen dieses Papers kann nicht auf alle Bereiche eingegangen werden, daher wurde der Schwerpunkt auf die im Workshop am meisten diskutierten Aspekte gelegt.

Von den Teilnehmenden wurde insbesondere betont, dass die Visualisierungen klar und konsistent sein müssen, um eine zugängliche Nutzung zu gewährleisten. Sie hoben hervor, dass eine intuitive Lesbarkeit der Dashboards, die Vermeidung von Reizüberflutung und die Anpassbarkeit der Anzeigeelemente essenziell sind. Parallelen zur existierenden Literatur wurden auch hier akzentuiert, nämlich dass sich LADs nicht ausschließlich auf leistungsorientierte Ziele konzentrieren sollten. Studien zeigen beispielsweise, dass eine zu starke Fokussierung auf Leistungsziele das Lernverhalten negativ beeinflussen und die Motivation der Lernenden verringern kann (Sedrakyan et al. 2020: 2; Lonn/Aguiar/Teasley 2015: 93–96). Um diesem Risiko entgegenzuwirken, wurde im Workshop diskutiert, dass Dashboards so gestaltet werden sollten, dass sie Lernziele unterstützen. Lernende, die spezifische Lernziele verfolgen, sind in der Regel daran interessiert, um des Lernens willen zu lernen. Das bedeutet, dass die Gestaltung von Lernerfolgskontrollen den Schwerpunkt von der Leistung auf das Lernen verlagern muss. Ein solches Design fördert eine nachhaltige Lernmotivation, wie Dweck/Leggett (1988: 266–271) es mit ihrem Konzept der Lernziele verdeutlichen (Sedrakyan et al. 2020: 2).

Als eine weitere wesentliche Anforderung wurde Usability von LADs genannt. Die Teilnehmenden betonten, dass LADs für eine heterogene Gruppe von Nutzenden zugänglich sein müssen, die, wie bereits dargestellt, oft über sehr unterschiedliche Vorkenntnisse verfügen. Das Design muss daher sicherstellen, dass sowohl Nutzende mit geringeren Datenkompetenzen als auch solche mit fortgeschrittenen Fähigkeiten die Dashboards effektiv nutzen können.

Ein weiterer relevanter Aspekt, der sich sowohl in der Literatur als auch in den Workshop-Ergebnissen widerspiegelt, ist die Notwendigkeit einer kontinuierlichen Rückmeldung an die Nutzenden. Dashboards müssen Mechanismen enthalten, die eine individualisierte, prozessorientierte Rückmeldung ermöglichen. Es wurde im Workshop diskutiert, dass Hilfetexte und Tooltips eingebaut werden sollten, um die Interpretation der angezeigten Daten zu unterstützen. Dies deckt sich mit den Ergebnissen von Sedrakyan et al. (2020: 12–13), die darauf hinweisen, dass prozessorientiertes Feedback effektiv ist, um ineffiziente Lernprozesse zu identifizieren und das Lernen zu verbessern.

Im Rahmen des Workshops wurden somit mehrere zentrale Anforderungen identifiziert, die auch in der aktuellen wissenschaftlichen Diskussion zum Design von LADs thematisiert werden. Ein wesentliches Ergebnis ist die Notwendigkeit, eine ausgewogene Balance zwischen der Darstellung relevanter Daten, der Unterstützung von Lernprozessen und der Benutzerfreundlichkeit der Dashboards zu erreichen. Dabei wurde deutlich, dass sowohl technologische als auch pädagogische Aspekte bei der Entwicklung von LADs berücksichtigt werden müssen, um die heterogenen Bedürfnisse der Nutzenden adäquat zu erfüllen.

Ein potenzieller Ansatz, der im Workshop intensiv diskutiert wurde, betrifft die Möglichkeit der Anpassung der Dashboards an die Vorkenntnisse der Nutzenden. Dieser Ansatz sieht vor, verschiedene Stufen – Anfänger:in, Erfahren und Expert:in – zu integrieren, um den unterschiedlichen Anforderungen der heterogenen Nutzendengruppe in Bezug auf Verständnis von LA-Ergebnissen gerecht zu werden. In der Stufe für Anfänger:innen sollten die Darstellungen und Erklärungen so gestaltet sein, dass die Ziele der Analysen klar und verständlich beleuchtet werden, was insbesondere zur Förderung der Data und AIL beiträgt. Im Gegensatz dazu sollte die Stufe »Expert:in« mehr detaillierte Daten bereitstellen, da hier die Gefahr einer Überreizung durch zu viele Informationen als geringer eingeschätzt wird. Diese Mehrstufigkeit könnte sich nicht nur auf die Visualisierungen, sondern auch auf das schriftliche Feedback innerhalb der LADs beziehen. Das Ziel dieses Ansatzes ist es daher, den Nutzenden eine individuell angepasste Nutzung der Dashboards zu ermöglichen.

und somit sowohl ihre Lernprozesse als auch ihre Datenkompetenzen optimal zu unterstützen.

Konklusion

Der vorliegende Beitrag hat gezeigt, dass LA, trotz der Potenziale, Lernprozesse durch datenbasierte Erkenntnisse gezielt zu unterstützen, Herausforderungen mit sich bringen, die vor allem auf eine angemessene Interpretation und Nutzung der Ergebnisse durch Lehrende und Lernende zurückzuführen sind. Besonders mangelnde DL und AIL können dazu führen, dass die Nutzung von LA nicht zielführend erfolgt. Daher wurde in diesem Beitrag herausgearbeitet, dass neben der Förderung dieser Kompetenzen vor allem die Gestaltung der Dashboards eine zentrale Rolle für den Erfolg von LA spielt.

Die Designkomponente erweist sich als entscheidend, um die Zugänglichkeit und Verständlichkeit der LADs für eine heterogene Nutzerschaft zu gewährleisten. Dabei ist zu beachten, dass Design niemals Kompetenz ersetzt, aber unterstützen kann. Wie auch die Ergebnisse des Workshops verdeutlichen, ist es das Ziel, durch eine nutzerfreundliche Gestaltung der LADs auch Nutzende mit geringerer Datenkompetenz zu integrieren. Dabei stellt sich der Ansatz der Mehrstufigkeit als zentraler Lösungsansatz heraus: Durch die Möglichkeit, zwischen unterschiedlichen Kompetenzstufen (Anfänger:in, Erfahren, Expert:in) zu wählen, verbindet der Ansatz die Förderung von DL und AIL mit einer klaren, zielgruppenspezifischen Visualisierung und einem differenzierten Feedbacksystem.

Der mehrstufige Ansatz bietet somit eine Lösung, um den unterschiedlichen Bedürfnissen und Vorkenntnissen der Nutzenden gerecht zu werden. Die Idee des mehrstufigen Dashboards soll zukünftig weiterentwickelt und in weiteren Workshops evaluiert werden, um eine kontinuierliche Verbesserung und Anpassung an die Bedürfnisse der Lernenden und Lehrenden zu gewährleisten.

Literatur

Chatti, Mohamed Amine/Dyckhoff, Anna Lea/Schroeder, Ulrik/Thüs, Hendrik (2012): A reference model for learning analytics. (= International Journal of Technology Enhanced Learning, 4), Inderscience Publishers, S. 318–331.

- Duan, Xiaojing/Wang, Chaoli/Rouamba, Guieswende (2022): Designing a learning analytics dashboard to provide students with actionable feedback and evaluating its impacts. (= Proceedings of International Conference on Computer Supported Education).
- Ebner, Martin (2019): Learning Analytics – eine Einführung. (= Bildung und Beruf, 2), DBB Verlag GmbH, S. 46–49.
- Khalil, Mohammad/Ebner, Martin (2015): Learning analytics: principles and constraints. (= Edmedia+ Innovate Learning), Association for the Advancement of Computing in Education (AACE), S. 1326–1336.
- Laupichler, Matthias Carl/Aster, Alexandra/Haverkamp, Nicolas/Raupach, Tobias (2023): Development of the »Scale for the assessment of non-experts' AI literacy«—An exploratory factor analysis. (= Computers in Human Behavior Reports, 12), Elsevier, S. 1–10.
- Lonn, Steven/Aguilar, Stephen J./Teasley, Stephanie D. (2015): Investigating student motivation in the context of a learning analytics intervention during a summer bridge program. (= Computers in Human Behavior, 47), Elsevier, S. 90–97.
- Lu, Min/Chen, Li/Goda, Yoshiko/Shimada, Atsushi/Yamada, Masanori (2020): »Visualizing studying activities for a learning dashboard supporting meta-cognition for students«, in: Norbert Streitz/Shin'ichi Konomi (Hg.), Distributed, Ambient and Pervasive Interactions: 8th International Conference, DAPI 2020, Held as Part of the 22nd HCI International Conference, HCII 2020, Copenhagen, Denmark, July 19–24, 2020, Proceedings 22, Cham: Springer, S. 569–580.
- Schwarz, Tabea/Jeworutzki, Sebastian (2024): »Data Literacy für Learning Analytics«, in: Peter Salden/Jonas Leschke (Hg.), Learning Analytics und Künstliche Intelligenz in Studium und Lehre: Erfahrungen und Schlussfolgerungen aus einer hochschulweiten Erprobung, Berlin: Springer, S. 225–243.
- Sedrakyan, Gayane/Malmberg, Jonna/Verbert, Katrien/Järvelä, Sanna/Kirschner, Paul A. (2020): Linking learning behavior analytics and learning science concepts: Designing a learning analytics dashboard for feedback to support learning regulation. (= Computers in Human Behavior, 107), Elsevier, S. 1–14.
- Siemens, George (2013): Learning analytics: The emergence of a discipline. (= American Behavioral Scientist, 57), SAGE Publications Sage CA: Los Angeles, CA, S. 1380–1400.

Schüller, Katharina/Busch, Paulina/Hindinger, Carina (2019): Future skills: ein Framework für Data Literacy. (= Hochschulforum Digitalisierung, 46), S. 1–128.

Schüller, Katharina/Koch, Henning/Rampelt, Florian (2021): Data-Literacy-Charta. Stifterverband: Berlin, S. 1–6.

Künstliche Intelligenz

KI auf dem Campus

Von der Empirie zur Strategie¹

Alexander Gerber² und Torsten Niechoj³

Das Projekt »KI auf dem Campus« (KIC) will durch eine systematische Analyse der Einstellungen und Erwartungen, Nutzungen und Bedenken von Lehrenden und Studierenden gegenüber Künstlicher Intelligenz eine Forschungslücke schließen, die es Hochschulen erlaubt, evidenzbasierte Entscheidungen zum Umgang mit der Technologie zu treffen. Dieser Beitrag beschreibt vorläufige Ergebnisse der ersten Phase dieser Studie, einer quantitativen Befragung in NRW, die im Folgenden bundesweit repliziert sowie qualitativ vertieft werden soll.

AI on Campus: From Empirical Analysis to Strategic Decisions

The »AI on Campus« project aims to close a research gap by systematically analysing the attitudes and expectations, uses and concerns of lecturers and students towards artificial intelligence, allowing universities to make evidence-based decisions on how to deal with the technology. This article describes the preliminary results of the first phase of this study, a quantitative survey in North Rhine-Westphalia, which will be replicated nationwide and supplemented by a qualitative analysis.

Ziele und Methodik

Angesichts der unübersehbaren Veränderungskräfte, die Künstliche Intelligenz (und vor allem generative Transformatoren wie ChatGPT) in der Bildung freisetzt, reagieren Hochschulen weltweit mit teils drastischen Regelungen,

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

2 ORC-ID: 0000-0002-9737-1267

3 ORC-ID: 0000-0002-1050-7628

etwa bei der Anpassung von Prüfungsordnungen. Fast alle diese weitreichenden strategischen Entscheidungen werden bislang getroffen, ohne dass es eine hinreichende empirische Basis dafür gäbe, welche Gruppen von Studierenden und Lehrenden welche Werkzeuge wie und wofür einsetzen oder auch ablehnen und auch welche KI-Kompetenzen potentielle Arbeitgeber von den Absolventen erwarten. Auch die theoretische Durchdringung von Einflussfaktoren zur Akzeptanz von KI steht noch am Anfang.

Dabei müsste das Ziel einer evidenzbasierten Strategiefindung eigentlich sein, dass sich alle Maßnahmen und Regelungen systematisch an den Erwartungen und Erfahrungen der Beteiligten orientieren (Tobor 2024; Budde et al. 2024). Erste Studien hierzu liegen zwar bereits vor (vgl. Cieliebak et al. 2023; von Garrel/Mayer/Mühlfeld 2023; Strzelecki 2023; von Garrel/Mayer 2024; Hüsch et al. 2024), sind aber oft methodisch nur bedingt belastbar und zeichnen kein wirklich eindeutiges Bild. Wir haben den Forschungsstand bereits kurz in einer separaten Publikation diskutiert (vgl. Gerber/Niechoj 2024: 31).

Das Forschungsprojekt »KI auf dem Campus« (KIC)⁴ zielt darauf ab, mehrere der eingangs genannten Forschungslücken zu schließen. Erste Befunde haben wir auf der Learning AID 2024 vorgestellt und fassen sie nachfolgend zusammen. Sie basieren auf einer im Juli 2024 in englischer und deutscher Sprache durchgeführten, weitgehend quantitativen Befragung von Lehrenden und Studierenden an beiden Standorten der öffentlichen und internationalen Hochschule Rhein-Waal in NRW. Diese erste Befragung richtete sich an 277 Mitarbeitende (Rücklaufquote: 36 %) und 5.900 Studierende (Rücklaufquote: 5 %). Sie erfolgte als pseudonymisierte Vollerhebung, womit longitudinal auch fortlaufend Folgeanalysen möglich sind. Dies erlaubt es, Lerneffekte der Beteiligten zu berücksichtigen, was gerade bei einem derart dynamischen Thema wie der KI-Nutzung von besonderer Bedeutung ist. Geplant ist, zusätzlich zur Folgeerhebung die Befragung auch an weiteren Hochschulen zu replizieren und qualitativ tiefergehende Analysen, etwa Fokusgruppen, Interviews und weitere Befragungen von Teilstichproben, durchzuführen.

Der Fragebogen basiert auf einem modifizierten Technologieakzeptanzmodell (TAM) nach Davis (1989) und Venkatesh und Davis (2000). Im Rahmen dieses Modells hängt die Akzeptanz und Nutzung einer neuen Technologie von

4 Vgl. die Projektseite unter <https://www.hochschule-rhein-waal.de/de/fakultaeten/kommunikation-und-umwelt/forschungsprojekte/kic-kuenstliche-intelligenz-auf-dem-campus>.

der wahrgenommenen Benutzerfreundlichkeit und Nützlichkeit ab. Auch soziale Erwartungen, denen sich Akteure ausgesetzt sehen, spielen eine Rolle. Dieses TAM haben wir, ähnlich wie Choi et al. (2022), an die spezifische Situation von KI an Hochschulen angepasst und erweitert, indem wir auch die pädagogische Haltung der Lehrenden bzw. die Einstellung zum Studium seitens der Studierenden als mögliche Einflussfaktoren berücksichtigt haben.

Die Befragungsinstrumente stehen auf Anfrage für eine mögliche Replikation zur Verfügung (Kontakt und Details siehe Projektwebseite). Zudem unterstützen wir bei Bedarf durch hochschulspezifische Datenanalysen.

Erste Ergebnisse und Diskussion

KI-Nutzung allgemein

Sowohl in der Lehre als auch in der Forschung setzt eine deutliche Mehrheit der Lehrenden einfache KI-Werkzeuge ein (z.B. DeepL oder Grammarly). Dass KI auch bereits von 23 % der Lehrenden für Prüfungszwecke eingesetzt wird, dürfte viele Prüfungsämter überraschen. Die Nutzung komplexerer Werkzeuge (z.B. zur Sprachsynthetisierung oder Bildgenerierung) ist weniger als halb so stark ausgeprägt, und sehr anspruchsvoll zu bedienende Werkzeuge (z.B. zur automatisierten Analyse von Text oder Generierung von Code) die absolute Ausnahme.

Die Nutzung bei Studierenden ist ähnlich ausgeprägt, allerdings sind auch komplexere und sogar sehr anspruchsvolle Werkzeuge bei Studierenden deutlich häufiger im Einsatz als bei Lehrenden. Eine Analyse dazu, welche einzelnen Tools jeweils zum Einsatz kommen, zeigte unter anderem, dass Studierende häufiger KI zur Programmierung nutzen als Lehrende. Bemerkenswert ist auch, dass Studierende doppelt so oft KI zur Prüfungsvorbereitung nutzen wie die Lehrenden, die diese Prüfungen erstellen, durchführen und bewerten.

Signifikante Unterschiede zeigen sich in der Nutzung von KI durch Lehrende unterschiedlicher Disziplinen. Auf Seiten der Studierenden fällt beim Vergleich der Studienrichtungen auf, dass MINT-Studierende schon erfahrener mit den Werkzeugen umgehen, da hier anspruchsvollere Anwendungen zum Einsatz kommen, wohingegen etwa bei den Sozial- oder Gesundheitswissenschaften eher ein Einstieg durch Nutzung einfacherer KI-Werkzeuge deutlich wird.

Nützlichkeit und Nutzerfreundlichkeit

Sowohl Lehrende als auch Studierende schätzen die Benutzerfreundlichkeit der KI überwiegend als hoch ein, vor allem wenn es darum geht, neue Lösungen zu finden.

Hinsichtlich der Nützlichkeit von KI-Werkzeugen sehen Lehrende vor allem die Zeitersparnis positiv, allerdings lediglich in Forschung und Lehre und nicht bei Prüfungen, möglicherweise, weil der Einarbeitungsaufwand als zu hoch eingeschätzt wird u.a. wegen Datenschutz oder noch nicht auf KI angepasster Prüfungsregeln. Gut zwei Drittel der Studierenden hingegen schätzen die Zeitersparnis durch KI in allen drei Bereichen, also ausdrücklich auch für das Verfassen von Haus- und Abschlussarbeiten, als hoch ein. Dies ist insoweit bemerkenswert, da sie zugleich mit 72 % der Aussage zustimmen, dass KI-Werkzeuge falsche Ergebnisse generieren können und mit 86 % zustimmen, dass sie KI-generierte Ergebnisse mit anderen Quellen vergleichen und überlegen, ob die Ergebnisse stimmig sind. All dies hätte eher erwarten lassen, dass die Zeitersparnis als geringer eingeschätzt wird, wobei sicherlich insbesondere bei den Antworten zur letzten hier genannten Frage auch soziale Erwünschtheit eine Rolle spielt.

Überrascht hat uns, wie unterschiedlich Lehrende und Studierende mögliche positive berufsqualifizierende Effekte der KI-Nutzung sehen. 62 % der Lehrenden versprechen sich eine Erhöhung der Berufsqualifikation, während es bei den Studierenden lediglich 40 % sind. Beide Gruppen sehen überwiegend keine positive Auswirkung auf die Zusammenarbeit der Studierenden. Genau umgekehrt ist es bei der Frage, ob KI Studierenden hilft, besser wissenschaftlich zu arbeiten: Nur 34 % der Lehrenden, jedoch 61 % der Studierenden stimmen dieser Aussage zu.

Unsere Erwartung war, dass auch die pädagogische Haltung der Lehrenden die Nutzung generativer KI beeinflussen würde. Entsprechend haben wir die pädagogische Haltung der Lehrenden über drei Items vermessen, die die beiden Extrempole einer konstruktivistischen und transmissiven Lehr- und Lernhaltung sowie eine mittlere Haltung erfassen. Dazu haben wir die Lehrenden gefragt, ob sie Wert darauf legen, dass die Studierenden sich Inhalte interaktiv und eigenverantwortlich erschließen, selbst wenn dies zu sachlich weniger korrekten Ergebnissen führt (konstruktivistisch), oder sie Wert darauf legen, dass Studierende Gelegenheit bekommen, Inhalte zu diskutieren und ihre eigenen Lösungen zu finden (Mittelposition), oder dass sie Wert darauf legen, relevantes Fachwissen durch den Lehrenden aufzubereiten und zu

präsentieren (transmissiv). Tatsächlich zeigen sich aber keine nennenswerten Unterschiede zwischen den drei gemessenen didaktischen Ansätzen.

Korrelationen zwischen Studierendenmotivation und KI-Nutzung untersuchen wir derzeit noch. Wir haben bereits erfasst, was Studierende dazu motiviert zu lernen. Jeweils mehr als zwei Drittel der Studierenden haben angegeben, dass das Interesse am Fach, der Erwerb fachlicher Qualifikationen, Aussicht auf einen Arbeitsplatz, auf dem sie etwas bewirken können und der gut bezahlt ist sowie eine selbständige Lebensgestaltung sie motiviert. Mit 56 % Zustimmung rangiert das Verbringen von Zeit mit anderen Studierenden am Ende der Zustimmungswerte, allerdings spiegeln diese Ergebnisse möglicherweise wider, dass alle bisher Befragten von einer Hochschule für angewandte Wissenschaften stammen, deren Studierende vergleichsweise stark in regionalen Sozialkontakten verankert sind, verglichen etwa mit Studierenden typischer Universitätsstädte.

Erwartungen und Restriktionen

Neben diesen Faktoren haben wir auch soziale Erwartungen und Handlungsrestriktionen untersucht. So sehen Lehrende eine ganze Reihe potentieller Einschränkungen, Probleme und Anforderungen. Darauf deuten die Zustimmungswerte zur Frage nach dem finanziellen Aufwand für Lizenzierungen in Höhe von 52 % hin sowie insbesondere die hohen Zustimmungswerte (84 %) zur Frage nach prüfungsrechtlichen Bedenken. Zwischen diesen beiden Polen bewegen sich die ebenfalls hohen Zustimmungswerte zu ethischen Bedenken (62 %), zum Datenschutz (66 %), zum Weiterbildungsbedarf (73 %) und zur Notwendigkeit der Anpassung von Curricula (77 %). Hohe Werte für Unentschiedenheit bei einigen Antworten der Lehrenden können darauf hindeuten, dass entweder die Lehrenden noch relativ unerfahren in der Nutzung sind, so dass sie sich noch nicht festlegen können, oder dass sie Bedenken bei einigen Werkzeugen für berechtigt halten, bei anderen aber nicht.

Die Antworten der Studierenden zu vergleichbaren Fragen zeigen in der Tendenz geringere Bedenken. 57 % sehen Datenschutzprobleme, was dem Ergebnis der Lehrenden ähnelt, aber dennoch darunter liegt. Weiterbildungsbedarf (hier abgebildet über die Frage, ob Studierende zustimmen, dass sie sich immer wieder in neue Apps einarbeiten müssen), wird kaum gesehen: nur 38 % stimmen zu, 51 % stimmen nicht zu. Interessant ist, dass 72 % die Aussage, dass KI-Werkzeuge sie Einiges an Geld kosten, ablehnen, obwohl sie durchaus Datenschutzprobleme sehen und das Datenschutzniveau bei kostenpflichti-

gen Applikationen oft höher ist als bei kostenfreien Werkzeugen. Zudem haben wir für mehr als sechzig KI-Werkzeuge abgefragt, ob die kostenfreie oder kostenpflichtige Version genutzt wird und können so sehen, dass Studierende durchaus kostenpflichtige Applikationen verwenden. Hier stehen aber beliebte Applikationen im Vordergrund, deren neuere Versionen nur noch kostenpflichtig nutzbar sind.

Diese vorläufige und noch weitestgehend deskriptive Auswertung hilft zu verstehen, wie KI-Werkzeuge aktuell von Lehrenden und Lernenden genutzt werden, wie Benutzerfreundlichkeit und Nützlichkeit eingeschätzt werden, welche Bedenken und Erwartungen bestehen und welche Handlungsrestriktionen gesehen werden. Die Analyse ermöglicht es auch, die im theoretischen Modell verwendeten Einflussfaktoren empirisch zu erfassen; allerdings erfordert es in den kommenden Monaten noch eine weitergehende statistische Analyse, um den jeweiligen Einfluss der Faktoren genauer zu bestimmen.

Fazit

Im Hochschulalltag sind bislang überwiegend einfach zu bedienende KI-Werkzeuge im Einsatz, allerdings gibt es deutliche Nutzungsunterschiede sowohl zwischen Lehrenden und Studierenden als auch innerhalb der Disziplinen (Lehrender) und der Fachrichtungen (Studierender). Alle Gruppen schätzen die Bedienung der KI-Werkzeuge als überwiegend nutzerfreundlich ein. Hinsichtlich des wahrgenommenen Nutzens der Werkzeuge unterscheiden sich die beiden Gruppen jedoch, da Studierende größeren Nutzen insbesondere in Bezug auf Zeitersparnis bei Haus- und Abschlussarbeiten sehen. Auch setzen sie doppelt so oft KI-Werkzeuge zur Prüfungsvorbereitung ein wie Lehrende, die diese Prüfungen erstellen, durchführen und bewerten. Lehrende haben zudem grundsätzlich deutlich mehr Bedenken gegenüber der KI als Studierende, nämlich zu allen sechs abgefragten Aspekten, während Studierende nur zu drei Aspekten Bedenken äußern. 62 % der Lehrenden, aber nur 36 % der Studierenden sehen zudem berufsqualifizierende Effekte durch KI im Studium. Ein Einfluss pädagogischer Haltung auf die KI-Nutzung ist überraschenderweise nicht nachweisbar.

Literatur

- Budde, Jannica/Tobor, Jens/Friedrich, Julius (2024): »Künstliche Intelligenz: Wo stehen die deutschen Hochschulen?«, Hochschulforum Digitalisierung, URL: https://www.che.de/download/blickpunkt-kuenstliche-intelligenz-wo-stehen-die-deutschen-hochschulen/?ind=1719560801121&filename=Blickpunkt_KI-Monitor.pdf&wpdmdl=31069&refresh=66ea8736044ac1726646070 (letzter Zugriff: 5.10.2024).
- Choi, Seongyune/Jang, Yeonju/Kim, Hyeoncheol (2023): »Influence of Pedagogical Beliefs and Perceived Trust on Teachers' Acceptance of Educational Artificial Intelligence Tools«, in: *International Journal of Human-Computer Interaction*, Jg. 39, H. 4, S. 910–922. <https://doi.org/10.1080/10447318.2022.2049145>
- Cieliebak, Mark/Drewek, Anna/Jakob Grob, Karin/Kruse, Otto/Mlynchik, Katsiaryna/Rapp, Christian/Waller, Gregor (2023): Generative KI beim Verfassen von Bachelorarbeiten: Ergebnisse einer Studierendenbefragung im Juli 2023. ZHAW Zürcher Hochschule für Angewandte Wissenschaften. <https://doi.org/10.21256/zhaw-2491>
- Davis, Fred D. (1989): »Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology«, in: *MIS Quarterly*, H. September, S. 319–340.
- Gerber, Alexander/Niechoj, Torsten (2024): »KI auf dem Campus. Chancen und Herausforderungen«, in: *Die Neue Hochschule*, H. 3, S. 30–33. <https://doi.org/10.5281/zenodo.11203051>
- Hüsch, Marc/Horstmann, Nina/Breiter, Andreas (2024): »Künstliche Intelligenz in Studium und Lehre – Die Sicht der Studierenden im WS 2023/24, Centrum für Hochschulentwicklung«, URL: <https://www.che.de/download/check-ki-2024/> (letzter Zugriff: 5.10.2024).
- Strzelecki, Artur (2024): »Students' Acceptance of ChatGPT in Higher Education: An Extended Unified Theory of Acceptance and Use of Technology«, in: *Innovative Higher Education*, Jg. 49, S. 223–245. <https://doi.org/10.1007/s10755-023-09686-1>
- Tobor, Jens (2024): »Blickpunkt: Leitlinien zum Umgang mit generativer KI«, Hochschulforum Digitalisierung, 7.2.2024. URL: https://www.unidigital.news/wp-content/uploads/2023/06/Blickpunkt_Leitlinien-zum-Umgang-mit-generativer-KI_2024.pdf (letzter Zugriff: 5.10.2024).
- Venkatesh, Viswanath/Davis, Fred D. (2000): »A Theoretical Extension of the Technology Acceptance Model: Four Longitudinal Field Studies«, in: *Man-*

agement Science, Jg. 46, H. 2, S. 186–204. <http://dx.doi.org/10.1287/mnsc.46.2.186.11926>

Von Garrel, Jörg/Mayer, Jana (2024): »Which features of AI-based tools are important for students? A choice-based conjoint analysis«, in: Computers and Education: Artificial Intelligence, Jg. 7, Art. 100311. <https://doi.org/10.1016/j.caeai.2024.100311>

Von Garrel, Jörg/Mayer, Jana/Mühlfeld, Markus (2023): »Artificial Intelligence in studies—use of ChatGPT and AI-based tools among students in Germany«, in: Humanities and Social Sciences Communications, 10, Art. 799. <https://doi.org/10.1057/s41599-023-02304-7>

Studieren im Zeitalter von KI & Co

Welche Rolle spielen KI-gestützte Tools im Hinblick auf die Lernmotivation im Studium – eine qualitative Analyse¹

Grit im Brahm, Steven Bauernfeind, Lucien Kemper und Matthias Kostrzewa

Die Veröffentlichung von ChatGPT hat die Debatte über akademische Praktiken an Universitäten neu entfacht. Bedenken über prüfungsbezogene Rechtsfragen und mögliche Betrugskultur werfen die Frage auf, ob traditionelle Bewertungsmethoden garantieren können, dass KI-gestützte Arbeiten individuelle Leistungen widerspiegeln. Der vorliegende Beitrag untersucht, welche Rolle KI-Werkzeuge aus Sicht der Studierenden im Studium spielen und welche motivationalen Orientierungen deren Nutzung oder Ablehnung beeinflussen. Die Ergebnisse der inhaltsanalytischen Auswertung der Gruppendiskussionen (N=16) verdeutlichen, dass Studierende KI-basierte Anwendungen sowohl in lernorientierter Haltung als Werkzeug in ihren Studienprozess integrieren als auch von einer zum Teil geringen intrinsischen Lernorientierung, arbeitsvermeidenden Orientierungen sowie einer nur wenig selbstbestimmten Handlungsregulation (Deci & Ryan, 2002) berichten. Vor diesem Hintergrund setzen sich die Autoren mit den Konsequenzen dieser Studienhaltung auseinander.

Studying in the Age of AI & Co. – AI-supported Tools and Their Impact on Learning Motivation in Higher Education – A Qualitative Analysis

The publication of ChatGPT has reignited the debate about academic practices at universities. Concerns about examination-related legal issues and possible cheating culture raise the question of whether traditional assessment methods can guarantee that AI-supported work reflects individual performance. This paper examines the role of AI tools from the students' perspective in their studies and which motivational orientations influence their use or rejection. The results of the content-analytical evaluation of the group discussions (N=16) make it clear that students integrate AI-based applications

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

into their study process both in a learning-oriented attitude as a tool and also report a partially low intrinsic learning orientation, work-organising orientations and only little self-determined regulation of their activities (Deci & Ryan, 2002). Against this background, the authors examine the consequences of this study behaviour.

Der Lernort Universität ist – anders als z.B. Schulen, die durch die Allgemeine Schulpflicht gerahmt sind – vor allem durch Freiwilligkeit, Eigenverantwortung und Selbstständigkeit gekennzeichnet: Studierende wählen ihre Kurse selbst, entscheiden in Teilen, ob sie Veranstaltungen analog, vor Ort oder digital zu Hause wahrnehmen, bestimmen ihr Lerntempo und setzen z.B. in zeitlicher Konkurrenz mit der studienbegleitenden Arbeitswelt eigenständig Prioritäten in Bezug auf die Studienintensität. Die Anforderungen an der Universität sind durch den Modus der Wissenschaft und des forschenden Lernens charakterisiert; das Studieren unterstellt eine hohe Lernmotivation und -autonomie.

Die Veröffentlichung von ChatGPT durch OpenAI im November 2022 hat den Diskurs um das Studieren an Universitäten neu geweckt. Dabei dominieren prüfungsrechtliche Fragestellungen und die Sorge einer Pfuschkultur ohne Risiko (News4teachers 2024), die etablierte schriftliche Studier- und Prüfungsverfahren grundlegend in Frage stellen. Die technischen Entwicklungen ermöglichen es Studierenden, einzelne Kapitel oder gar ganze Hausarbeiten durch geschicktes Prompting erstellen zu lassen; dieselbe Technik kann jedoch nicht zuverlässig nachweisen, ob Texte durch KI erstellt wurden oder – wie in Prüfungen gefordert – ausschließlich auf individuellen Leistungsanstrengungen der Studierenden beruhen. Vor diesem Hintergrund untersucht der Beitrag, welche Rolle die Verfügbarkeit generativer KI-Tools aus Sicht der Studierenden für ihre Motivation und das eigenständige Studieren spielt. Der Beitrag nutzt als Rahmenwerk die Selbstbestimmungstheorie nach Deci & Ryan (2002) und stellt ausgewählte Befunde dar, die aus explorativen Gruppendiskussionen ($n=4$) mit Studierenden ($N=16$) mittels qualitativer Inhaltsanalyse (Kuckartz und Rädiker 2022) und deduktiv-induktiver Kategorienbildung herausgearbeitet wurden. Die Befunde verdeutlichen, dass Studierende KI-basierte Anwendungen sowohl in lernorientierter Haltung als Werkzeug in ihren Studienprozess integrieren als auch von einer zum Teil geringen intrinsischen Lernorientierung, arbeitsvermeidenden Orientierungen sowie einer nur wenig selbstbestimmten Handlungsregulation (Deci & Ryan, 2002) berichten. Dies steht durchaus im Gegensatz zu den oben aufgestellten Prämissen ei-

ner Studierkultur. Entsprechend diskutieren die Autor*innen die Folgen einer solchen Studienhaltung.

Theoretische Rahmung und Forschungsstand

Die Selbstbestimmungstheorie von Ryan & Deci (2002) stellt ein theoretisches Rahmenwerk dar, welches das Zustandekommen von Motivation als einen dynamischen Prozess betrachtet, der die Qualität und die Regulation eines zielgerichteten Handlungsantriebes erklärt. Motivation kann demnach

- eine intrinsische (der Handlungsantrieb resultiert aus der Person selbst, weil die Tätigkeit oder das Ziel der Tätigkeit als interessant, befriedigend und/oder sinnvoll erlebt wird) oder
- eine extrinsische (der Handlungsantrieb resultiert aus einer Bewertung äußerer Faktoren, wie Belohnung, Noten und/oder Druck) Ausprägung aufweisen.
- Zudem ergänzen Ryan & Deci den amotivierten Zustand, der dann vorliegt, wenn eine Person zwischen Handlung und Ziel keinen Zusammenhang erkennen kann und nicht motiviert ist.

Die extrinsische Motivation wird als ein Kontinuum betrachtet und stuft Qualität entlang des Regulationsgrades der Selbstbestimmung ein. Es wird zwischen vier Formen unterschieden:

- Externe Regulation wird durch äußere Anreize, wie z. B. Belohnungen oder Bestrafungen gesteuert. Verhalten wird aufgrund von externem Druck oder äußeren Erwartungen gezeigt und wird in der Regel als unangenehm und emotional belastend erlebt (Schiefele 2015).
- Introjizierte Regulation integriert die Anerkennung des Lern- und Leistungsziels in die Person in Teilen. Menschen handeln aus einem Gefühl der Verpflichtung und wollen Schuldgefühle oder das Gefühl der Unzulänglichkeit vermeiden.
- Identifizierte Regulation ist durch hohe Selbstbestimmung gekennzeichnet. Lernende erkennen den Wert und den Sinn der Lernhandlung; dennoch können Zielkonflikte mit anderen Handlungen entstehen.
- Integrierte Regulation ist die selbstbestimmteste Form der extrinsischen Motivation und steht der intrinsischen Motivation am nächsten. Das Ver-

halten wird vollständig in das Selbstbild und die Werte der Person integriert. Diese Stufe wird erreicht, wenn die Person sich nicht nur mit einem bestimmten Handlungsziel (z.B. Anforderungen des Studiums) identifiziert, sondern dieses auch ohne Konflikte mit anderen Zielen (z.B. Berufstätigkeit) in ihr Selbst integriert hat.

Deci und Ryan (2002) können in Studien belegen, dass stärker selbstbestimmte Formen der Motivation langfristig mit einem höheren Engagement, besserem Wohlbefinden und größerem Lernerfolg einhergehen. Sie betonen, dass die drei psychologischen Grundbedürfnisse: (1) Autonomie- und (2) Kompetenz-Erleben sowie (3) soziale Eingebundenheit für das Zustandekommen intrinsischer und die Qualität extrinsischer Motivation grundlegend seien. Das Gefühl, keine oder zu wenig Kontrolle über die eigenen Handlungen und Entscheidungen zu haben, sich in Handlungssituationen nicht als kompetent erleben zu können und fehlende (positive) Beziehungen zu anderen Lernenden oder ein fehlendes Gefühl der Zugehörigkeit zu einer Gruppe, führt zu Meideverhalten (Krapp 1993). Im Gegensatz dazu fördert die Berücksichtigung dieser Grundbedürfnisse ein intrinsisches Lernverhalten.

Fragestellung und Studiendesign

Die Studie untersucht die Frage, in welcher Weise die Verfügbarkeit KI-basierter, textgenerierender Technologien die Lernmotivation und das Verhältnis von Fremd- und Selbstregulation im Studium beeinflusst.

Im Sommersemester 2024 wurden vier Gruppendiskussionen mit je vier Studierenden unterschiedlicher Unterrichtsfächer durchgeführt. Zwei Gruppen setzten sich aus Studierenden in 2-Fach-B.A.-Studiengängen, zwei aus Studierenden im M.Ed.-Studiengang zusammen. Alle Studierenden verfolgen das Studienziel Lehramt. Die Gruppendiskussionen dauerten zwischen 56 und 85 Minuten und bezogen sich thematisch breit auf die Wahrnehmung, das Verständnis und die Nutzung von Technologien, die auf künstlicher Intelligenz basieren, im Alltag, im Studium und im späteren Lehrberuf. Die Diskussionen wurden aufgezeichnet, vollständig transkribiert und nachfolgend inhaltsanalytisch ausgewertet (Kuckartz & Rädiker 2022). Die Kategorien wurden zunächst deduktiv entlang der oben ausgeführten Theorien und in einem zweiten Schritt induktiv aus dem Material entwickelt, um vorhandene Kategorien auszudifferenzieren.

Zentrale Befunde

Um die Motivation von Studierenden, die zur (Nicht-)Nutzung von KI-basierenden Anwendungen im Studium führt, besser verstehen zu können, erscheint eine kurze Übersicht über die Bereiche sinnvoll, in denen Studierende angeben, KI im Studium zu nutzen: Viele Studierende verstehen unter im Studium nutzbarer KI vor allem Künstliche Intelligenzen, die auf Natural-Language-Processing-Modellen basieren. Dazu zählen insbesondere ChatGPT zur Konzeptionierung und Erstellung von Hausarbeiten und Referaten, DeepL Translate für Übersetzungsleistungen und DeepL Write für sprachliche Überarbeitungen.

Die Diskussionen geben ferner Hinweise auf die diversen Motivationslagen, mit denen die Studierenden KI im Studium nutzen oder bewusst darauf verzichten. Einige Studierende berichten, KI nicht zu nutzen, um Bestrafungen (Seminaarausschluss, Nicht-Bestehen) zu vermeiden. Sie handeln external reguliert. Die Sorge aufzufliegen, hat eine unangenehme und emotional belastende Wirkung auf die Studierenden.

Andere Studierende sehen im Sinne einer Kosten-Nutzen-Rechnung den zusätzlichen zeitlichen Arbeitsaufwand als zu hoch an, der aus ihrer Sicht erforderlich sei, um den Output einer KI für eigene Leistungsprodukte nutzen zu können. Sie deuten dies als Misserfolg in Bezug auf eine leistungsbezogene Nutzung von KI im Studium. *»Weil wenn ich mir die schreiben lasse, dann kann ich das alles nicht zitieren und das nervt mich einfach. Dann ist es für mich einfach nur doppelte Arbeit. Dann suche ich die lieber selbst«* (M1, P5, Pos. 22). Ein wahrgenommener innerer Druck, durch die Nutzung von z.B. ChatGPT doppelte Arbeit leisten zu müssen, ist ein Hinweis auf Fremdregulation. Es erfolgt somit keine Identifikation mit den Anforderungen des wissenschaftlichen Arbeitsmodus. Bei einer identifizierten Regulation wird die Bedeutung der eigenständigen Lernleistung (mit und ohne KI) für den Lernprozesses erkannt; sie kann aber in Zielkonflikt mit anderen Handlungen – hier vor allem mit Zeit und Anstrengung – geraten.

Eine weitgehend selbstbestimmte Regulation wird erkennbar, wenn Studierende sich mit ihren Lernprodukten identifizieren möchten. *»Ich finde, man sollte sich auch irgendwie immer noch selbst treu bleiben irgendwie. Und da dann wirklich noch sich selber auch in der Abgabe finden, also sich da auch noch mit identifizieren können«* (B1, P4, Pos.118). Studierende, die diese lernorientierte Haltung einnehmen, schließen eine Hausarbeit 'auf Knopfdruck' aus, lehnen hingegen eine unterstützende Nutzung von KI im Studium nicht ab. *»Ich glaube, es ist halt*

wichtig, dass also bei mir war das jetzt auch beispielsweise so, wenn ich halt größere Hausarbeiten oder so schreibe, dann weiß ich, okay, ich muss trotzdem meine Recherche machen, ich muss trotzdem die Texte lesen, ich muss das begreifen. KI ist dann so ein, so ein, so ein Add on« (M2, P3, Pos. 47). KI wird von diesen Studierenden als Ergänzung zu etablierten Werkzeugen im Studium wahrgenommen und sie können diese kritisch reflektiert in ihre akademischen Lern- und Arbeitsprozesse integrieren. Sie verstehen das Studium als einen selbstgesteuerten, aktiven und eigenverantwortlichen Prozess, in dessen Rahmen sie Lernergebnisse generieren, auf die sie stolz sein können und wollen. Dies schließt zugleich eine fremdgesteuerte, Lernanstrengungen auslagernde Nutzung von KI aus. »Das erfüllt dann ja auch irgendwie mit Stolz und so, dass man diese Motivation, dass man diese Fähigkeiten [zu studieren] dann auch kann, das ist ja schon wichtig« (B1, P4, Pos.148).

Schließlich deckt die Auswertung auch amotivierte Haltungen einiger Studierender auf. Dies ist erkennbar, wenn einerseits arbeitsvermeidend die eigene Faulheit herangezogen wird, um zu begründen, gute Ergebnisse durch KI zu erzielen. »Ich bin zum Beispiel sehr faul und ich bin immer sehr dankbar dafür, wenn mir einfach irgendwas ausspuckt und ich da möglichst wenig Aufwand reinstecken muss und irgendwie ein gutes Outcome damit habe« (B2, P2, Pos. 18). Andererseits werden Studierende mit Prüfformaten konfrontiert, in denen sie z.B. durch Testat-Antworten (lediglich) ihre Anwesenheit belegen sollen. Sie stellen den Zusammenhang zwischen Ziel und der Tätigkeit grundlegend in Frage und sind in dieser amotivierten Haltung bereit, die Tätigkeit an KI auszulagern. »Weil man lernt auch nichts, wenn man es selber machen würde« (B1, P5, Pos.101).

Einen erkennbar hohen Stellenwert nimmt das Bedürfnis der Studierenden nach Kontrolle ein. Studierende wollen sich nicht fremdsteuern lassen, weil sie die zugrundeliegenden komplexen Algorithmen nicht verstehen können, sondern möchten ihre Produkte selbst verantworten. »Ich vertraue dem Ganzen nicht gut genug, um zu sagen, ich möchte da jetzt selbst nicht noch einen Blick drüber haben, mal den Text gelesen haben und auch das fertige Produkt würde ich auf jeden Fall auch nicht von einer KI schreiben lassen wollen« (M2, P4, Pos.48). Offen bleibt zum jetzigen Zeitpunkt die Bewertung der Studierenden, falls KI den Status einer vertrauenswürdigen Qualität erhält. Werden die Studierenden dann auch lieber die Verantwortung selbst übernehmen oder eine Fremdsteuerung akzeptieren, weil der subjektive Wert der Zeit- und Arbeitersparnis gegenüber einer identifizierten oder integrierten Leistungserbringung bzw. intrinsischen Lernleistung überwiegt?

Diskussion und Ausblick

Die Auswertungen verdeutlichen, dass die Verfügbarkeit von KI bei vielen Studierenden dazu führt, diese als unterstützendes Werkzeug im Studium wahrzunehmen. Es wurde gezeigt, dass dabei ambivalente Kräfte auf die Studierenden wirken.

Die Ausprägung von Arbeitsvermeidungshaltungen und anderen Formen der Fremdregulation in den Äußerungen der Studierenden weisen darauf hin, dass die Prämissen einer starken Lernmotivation und Leistungsbereitschaft – häufig auch in Konkurrenz mit stärker bedürfnisorientierten Anforderungen der Erwerbsarbeit – nicht vorausgesetzt werden können. Diese sollten vielmehr durch das Studium selbst generiert und etabliert werden. Statt KI zu verbieten und unter Strafe zu stellen, könnte und sollte mehr Energie in die Entwicklung von Lern- und Forschungsformaten investiert werden, die beispielsweise auf eine Kultur der Digitalität (Stalder 2016) vorbereiten. Sie zeichnet sich durch ein hohes Maß an Selbst- und Mitbestimmung der Lernenden aus, in der die Studierenden Verantwortung für die Ausgestaltung des Studiums übernehmen. Dies wird aber nur durch die Vermeidung solcher externen Vorgaben möglich, mit denen sich Studierende nicht identifizieren können. Universität muss ein Ort gegenseitiger Aushandlung von Bedeutung sein und nicht einer einseitigen Wissensweitergabe von Lehrenden zu Lernenden. An dieser Argumentation wird deutlich erkennbar, dass die Transformationsprozesse, mit denen wir uns in eine Kultur der Digitalität bewegen, letztlich nicht nur auf die Nutzung digitaler Technik, sondern stärker auf Partizipation angewiesen sind. Eine zentrale Zielsetzung des Studiums muss die Identifikation mit den Prinzipien des wissenschaftlichen Arbeitens sein; diese ist letztlich die Voraussetzung der oft geforderten forschenden Grundhaltung von Studierenden.

Literatur

Deci, Edward L. & Ryan, Richard M. (2002): Overview of self-determination theory: An organismic dialectical perspective, in: Edward L. Deci & Richard M. Ryan (Hg.), *Handbook of self-determination research*, Rochester, NY: University of Rochester Press, S. 3–33.

- Krapp, Andreas (1993): Psychologie der Lernmotivation. Perspektiven der Forschung und Probleme ihrer pädagogischen Rezeption, in: Zeitschrift für Pädagogik, Nr. 39, S. 187–206.
- Kuckartz, Udo & Rädiker, Stefan (2022): Qualitative Inhaltsanalyse. Methoden, Praxis, Computerunterstützung, Weinheim: Beltz Juventa.
- News4teachers (2024): Pfuschen (fast) ohne Risiko, [online] <https://www.news4teachers.de/2024/04/ich-gehe-davon-aus-dass-wir-dann-die-dinge-eingefangen-haben-zur-zukunft-der-pruefungskultur-in-zeiten-der-ki/> [27.09.2024].
- Schiefele, Ulrich (2015): Motivation, in: Elke Wild & Jens Möller (Hg.), Pädagogische Psychologie, Heidelberg: Springer, S. 153–176.

Künstliche Intelligenz in Studium und (tutorieller) Lehre

Ergebnisse einer bundesweiten Studie¹

Jenny Alice Rohde

*Im Frühling 2024 wurden 220 Tutor*innen aus 28 deutschen Hochschulen zu Künstlicher Intelligenz (KI) in Studium und (tutorieller) Lehre befragt. Insgesamt gaben 94 % an, über KI-Erfahrungen zu verfügen, wobei ChatGPT 3.5 am meisten genutzt wurde. Die Befragten nutzen KI im Studium v.a. zur Klärung von Verständnisfragen, Schreibunterstützung und für Übersetzungen. Ein Drittel sieht eine deutliche Veränderung ihres Studiums durch KI, insbesondere durch gesteigerte Effizienz und veränderte Lernmethoden. Einsatzmöglichkeiten von KI in der (tutoriellen) Lehre sehen die Tutor*innen v.a. in der Erstellung von Lehrmaterialien und bei der Förderung von Inklusion. Es bestehen jedoch Vorbehalte hinsichtlich des Einsatzes bei der Korrektur studentischer Arbeiten. Sie wünschen sich klarere Regelungen und eine stärkere Thematisierung von KI durch Lehrende. Die Tutor*innen schätzen die persönliche Interaktion mit den Studierenden und sind der Ansicht, dass KI Tutorienarbeit nicht ersetzen könne.*

Artificial intelligence in studies and (tutorial) teaching – results of a nationwide study

In spring 2024, 220 tutors from 28 German universities were anonymously surveyed on artificial intelligence (AI) in studies and (tutorial) teaching. A total of 94 % stated that they had experience with AI, with ChatGPT 3.5 being used the most. The respondents mainly use AI in their studies to clarify comprehension questions, for writing support and for translations. One third see a significant change in their studies as a result of AI, particularly through increased efficiency and changed learning methods. The tutors see potential uses for AI in (tutorial) teaching, particularly in the creation of teaching materials and the promotion of inclusion. However, there are reservations regarding

¹ Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

the use of AI in the correction of student work. They would like to see clearer regulations and a stronger focus on AI by teachers. The tutors value the personal interaction with students and believe that AI cannot replace tutorial work.

Einleitung

Die Fortschritte im Bereich der KI stellen etablierte Lehr- und Lernmethoden, Curricula und Prüfungsformate in Frage. Während sich die Technologie rasant weiterentwickelt, kann die wissenschaftliche Forschung zur Integration von KI in die Hochschullehre kaum mithalten. Erste Untersuchungen beleuchten die Haltung und Nutzung von KI durch Studierende und Lehrende (Preiß, Bartels & Pawlowski, 2023; Choi, Jang & Kim, 2022; Cieliebak et al., 2023; Gerber & Niechoj, 2025; Kumar & Raman, 2022; Gottschling, Seidl & Vonhof, 2024; Strzelecki, 2023; von Garrel, Mayer & Mühlfeld, 2023). Dabei zeigt sich jedoch eine Forschungslücke hinsichtlich der Rolle studentischer Tutor*innen. Sie nehmen eine besondere Position ein, da sie sowohl die Perspektive der Lernenden als auch die der Lehrenden kennen und somit als Multiplikator*innen u.a. für den Umgang mit KI fungieren. Zudem arbeiten viele von ihnen nach dem Studienabschluss an Hochschulen (Hopp et al., 2023; Rohde, 2019) und werden die künftige Lehrpraxis prägen. Spannagel (2024) beschreibt bereits theoretisch, wie Tutor*innen KI in ihrer Lehre sinnvoll einsetzen können. Dennoch ist bislang außer einer Vorstudie an der Technischen Universität Hamburg (Rohde & Uzulis, 2024) wenig über die Haltung von Tutor*innen zu KI bekannt. Mit dieser Befragung soll diese Forschungslücke geschlossen werden. Es werden der KI-Einsatz im Studium und in der Tutorienarbeit sowie die Einstellungen von Tutor*innen zu KI in der Lehre beleuchtet, so dass Empfehlungen für Hochschulen abgeleitet werden können.

Stichprobe und Fragebogen

Die Stichprobe umfasst 220 studentische Tutor*innen aus 28 deutschen Hochschulen und vielen verschiedenen Studienrichtungen. Besonders stark vertreten sind jedoch die Ingenieur- und Naturwissenschaften. Der Online-Fragebogen bestand aus 39 quantitativen und 13 offenen Fragen und war in deutscher und englischer Sprache verfügbar. Die Fragebogenentwicklung basierte auf den Ergebnissen einer Vorstudie (Rohde & Uzulis, 2024). Die anonyme Da-

tenerhebung fand von April bis Ende Mai 2024 statt. Die Tutor*innen können den Einfluss von KI in der Hochschule sowohl aus der Studierenden- als auch aus der Lehrendenperspektive einschätzen. Zudem sind sie die Hochschullehrenden der Zukunft, denn 40 % beantworteten die Frage, ob sie nach ihrem Abschluss an einer Hochschule arbeiten möchten mit »ja«, 45 % mit »vielleicht« und nur 15 % mit »nein«.

Ergebnisse

Im Folgenden werden ausgewählte Ergebnisse der Umfrage vorgestellt.

Erfahrung mit KI und KI-Tools

In Bezug auf den Erfahrungsgrad der Tutor*innen mit KI zeigt sich eine Normalverteilung der Antworten. Insgesamt gaben 94 % an, über Erfahrungen mit KI zu verfügen. Von diesen berichteten 32 %, nur »ein wenig« Erfahrung zu haben, 36 % »etwas«, 21 % »recht viel« und 5 % »sehr viel«. Im Vergleich zur Vorstudie im Herbst 2023 (Rohde & Uzulis, 2024), ist der Erfahrungsgrad nun deutlich höher.

Bezüglich der genutzten KI-Tools zeigt sich, dass im Frühjahr 2024 ChatGPT 3.5 weiterhin das am häufigsten eingesetzte Tool ist. 71 % der Studierenden gaben an, diesen Chatbot zu nutzen. Das Übersetzungstool DeepL wird von 50 % genutzt, während 23 % den Chatbot Copilot verwenden. Zudem verfügen 20 % der Befragten über einen kostenpflichtigen Zugang zu ChatGPT 4.0, der auch den Zugriff auf das Bildgenerierungstool DALL-E ermöglicht, welches von 17 % genutzt wird. Im Vergleich dazu nutzen nur 8 % der Studierenden das Bildgenerierungstool Midjourney. Das Videogenerierungstool Runway wurde von keiner Person in der Stichprobe verwendet. Als sonstige Tools wurden je viermal das Programmierungstool Github Copilot, das Bildgenerierungstool Stable Diffusion und der Chatbot Gemini sowie je zweimal das Recherchetool Research Rabbit genannt.

Unter den Befragten mit einem kostenpflichtigen ChatGPT 4.0-Account gaben 43 % an, eine eigene Lizenz zu haben, 20 % nutzen eine geteilte Lizenz, und 9 % haben über ihre Hochschule Zugang. 27 % gaben an, dass keiner der drei vorgegebenen Zugangswege zu ChatGPT 4.0 auf sie zutrifft.

Nutzung von KI im Studium

Im Studium lassen sich die Befragten in folgenden Bereichen von KI unterstützen:

- Klärung von Verständnisfragen 57 %
- Unterstützung beim Schreiben 47 %
- Übersetzung 46 %
- Programmierung 38 %
- Recherche & Literaturstudium 33 %
- Lösung von Übungsaufgaben 23 %
- kein Einsatz 14 %
- Sonstiges 10 %

Unter »Sonstiges« geben sie an, mit KI Fremdsprachen zu lernen oder sich Übungsaufgaben zum Lernen erstellen zu lassen.

Auf die Frage »KI hat mein Studium verändert« antworten 33 % mit »ja«, 22 % mit »vielleicht« und 45 % mit »nein«. Diejenigen, die der Ansicht sind, dass KI ihr Studium verändert hat, berichten im Freitextformat von einer verbesserten Effizienz durch ihre KI-Nutzung (*»Deutlich schneller eine Antwort auf Fragen zu bekommen.«*, T60) sowie von einer veränderten Arbeitsweise durch KI (*»ChatGPT ist mein Lernpartner geworden.«*, T212).

Thematisierung von KI in der Lehre und Regeln zur KI-Nutzung

Bezüglich der Thematisierung von KI in der Lehre gaben die Befragten an, dass ihre Lehrenden nur selten über Regeln (3,6)², Chancen (3,4) und Gefahren (3,3) von KI sprechen. Sie würden es begrüßen, wenn Lehrende KI stärker thematisieren würden (2,3). Trotz dieses Wunsches und ihrer Überzeugung, dass Studierende KI bereits im Kontext ihrer Tutorien nutzen (2,4), möchten viele das Thema nur ungern in ihrer Rolle als Tutor*in aufgreifen (3,1). Dies könnte daran liegen, dass nur 13 % der Tutor*innen Vorgaben von ihren Vorgesetzten zum Umgang mit KI in ihren tutoriellen Veranstaltungen erhalten haben. Die in Freitexten dargestellten Regeln variieren stark. Manche Vorgesetzten verbieten die studentische Nutzung von KI vollständig und fordern Tutor*innen auf,

2 Skala von 1 (stimme voll zu) bis 5 (stimme nicht zu)

bei Verdacht Meldung zu erstatten. In anderen Veranstaltungen ist die Nutzung von KI hingegen als »alltägliches Werkzeug« erlaubt, wobei auf Kennzeichnungspflichten, Datenschutz und Urheberrechte hingewiesen wird.

Auf die offene Frage, welche Regeln die Tutor*innen sich selbst für den Einsatz von KI in den von ihnen geleiteten Veranstaltungen wünschen, reichten auch hier die Antworten von einem vollständigen Verbot bis hin zu Empfehlungen für einen verantwortungsvollen Umgang mit KI. Deutlich wurde zudem, dass sich viele Tutor*innen klare Regelungen von ihren Vorgesetzten wünschen. Darüber hinaus betonten mehrere ihren Wunsch nach persönlicher Interaktion sowie nach »*offener Kommunikation und gemeinsamer Arbeit mit KI*« (T9), um Vor- und Nachteile gemeinsam zu erörtern.

Nutzung von KI in der (tutoriellen) Lehre

Die 220 Tutor*innen stimmen der Aussage »KI wird die Lehre in Zukunft verändern« zu (1,82) und sind eher der Meinung, dass KI die Lehrqualität in Zukunft verbessern wird (2,5). Nur 10 % sind dagegen, KI in der Lehre einzusetzen. In den Freitextantworten begründeten diese 10 % ihre Skepsis mit der Sorge um den Verlust eigenständigen Denkens und Lernens, einem Rückgang menschlicher Interaktion, der Befürchtung falscher KI-Ergebnisse sowie grundsätzlich ethischer Bedenken.

Auf die Frage, was sie benötigen würden, um KI in ihrer tutoriellen Lehre einzusetzen, erhielten folgende Punkte die höchste Zustimmung (jeweils 1,8): »Ideen für einen sinnvollen Einsatz« und »klarere Regeln im Umgang mit KI«. Darüber hinaus wurde der Aussage »Wir brauchen eine Campuslizenz für eine KI.« überwiegend zugestimmt (2,2).

Auf die Frage, zu welchem Zweck sie KI als Tutor*in nutzen würden, erhielten folgende Aspekte besonders hohe Zustimmungswerte (jeweils 2,0): »Generierung von (alternativen) Übungsaufgaben«, »Förderung der Inklusion (barrierefreie Präsentationen, Übersetzungen etc.)« und »Inspiration für die Erstellung oder Verbesserung von Lehrmaterialien«. Die geringste Zustimmung (3,5) fand hingegen die Idee, KI für die »Korrektur von und Feedback zu studentischen Arbeiten« zu verwenden.

Die Aussage »KI wird die tutorielle Lehre in Zukunft überflüssig machen.« wird von den Tutor*innen klar abgelehnt (4,5). Offenbar schätzen sie den Wert ihrer persönlichen und individuellen Interaktion mit den Studierenden sehr (vermutlich auch aus eigener studentischer Erfahrung) und glauben nicht, dass KI alle Aspekte ihrer Arbeit übernehmen könnte.

Diskussion

Im Frühjahr 2024 wurden 220 Tutor*innen zur Nutzung von KI im Studium und in der Lehre befragt. Zu berücksichtigen ist, dass die KI-affineren Studierenden aus ingenieur- und naturwissenschaftlichen Fächern (von Garrel et al., 2023) stärker vertreten waren. Die Einschätzungen der Tutor*innen lassen sich nicht vollständig auf hauptamtliche Lehrende übertragen, auch wenn es Überschneidungen gibt, etwa bei der Eignung von KI zur Erstellung von Lehrmaterialien (Preiß et al., 2023).

Die Stärken dieser Befragung liegen in der relativ großen und bundesweiten Stichprobe, dem Mix an qualitativen und quantitativen Fragen sowie in der Konzeption auf Basis der Ergebnisse einer Vorstudie.

Über 90 % der Befragten nutzen KI. Diese Ergebnisse bestätigen frühere Studien, die auf die zunehmende Bedeutung von KI-Tools wie ChatGPT in der Hochschulbildung hinweisen (von Garrel et al., 2023), zeigen aber auch auf, dass die Erfahrung mit KI zunimmt.

Allerdings zeigt die Art und Weise, wie sich die Befragten im Studium durch KI unterstützen lassen, Probleme auf. So birgt die Nutzung von KI zur Klärung von Verständnisfragen die Gefahr, dass die Studierenden KI-Ergebnisse nicht prüfen und Fehlinformationen unkritisch übernehmen. Darüber hinaus kann u.a. das Delegieren der Lösung von Übungsaufgaben an eine KI zu »Deskilling« führen. Folglich erlernen oder vertiefen die Studierenden die mit den Übungsaufgaben adressierten Fähigkeiten nicht. Diesen Verlust an eigenständigem Denken sowie die Reduktion menschlicher Interaktion befürchten die 10 % der Befragten, die sich gegen den Einsatz von KI in der Lehre aussprechen.

Tutor*innen fehlt es an Vorbildern, die einen verantwortungsbewussten Umgang mit KI vorleben. Es wäre sinnvoll, wenn Lehrende Raum bieten würden, um KI auszuprobieren und die Ergebnisse gemeinsam kritisch zu reflektieren, um Chancen und Grenzen bei der Nutzung sowie Auswirkungen für ihre Disziplin zu erarbeiten (vgl. Schäfers, 2025). Zudem sollten sie über Regeln zum Umgang mit KI, wie Kennzeichnungspflichten, Datenschutz und Urheberrecht, informieren oder entsprechende Materialien bereitstellen.

Für den Einsatz von KI in der Lehre und im Studium sind zudem gleiche Zugangschancen erforderlich. Dies kann z.B. über eine datenschutzkonforme Campuslizenz für alle Studierenden erreicht werden, wie auch von den hier Befragten befürwortet.

Hinsichtlich des Einsatzes von KI in der (tutoriellen) Lehre ist die Förderung von Inklusion sowie der Umgang mit Heterogenität vielversprechend, wie z.B. durch individualisierte Lernmaterialien, individuelles Feedback und Lernangebote, die auf die Stärken, Interessen und Ziele der Studierenden zugeschnitten sind. Feedback auf Aufgabenebene (richtig/falsch) könnte an eine jederzeit erreichbare KI abgegeben werden. Auf diese Weise hätten Lehrende Zeit, Feedback zu Arbeitsweisen und Strategien zu geben (Spannagel, 2024). Allerdings ist zum einen zu bedenken, dass KI-Feedback nicht für alle Studierenden im gleichen Maße hilfreich ist (Drachslar, 2024). Zum anderen ist anzunehmen, dass die Fähigkeit, auf höheren Kompetenzstufen Feedback zu geben, von vielen Lehrenden erst erlernt werden müsste. Darüber hinaus erscheint es sinnvoll, zu differenzieren, was studentische Tutor*innen und was hauptamtliche Lehrende leisten können. Beispielsweise ist es die Aufgabe der Betreuer*innen der Tutor*innen über alternative Prüfungsformen zu entscheiden, die nicht an eine KI ausgelagert werden können.

Kleinen gut betreuten Veranstaltungen kommt eine hohe Bedeutung zu. In Tutorien arbeiten die Studierenden oft in Kleingruppen während Tutor*innen sie unterstützen. Hier ist es unwahrscheinlicher, dass sie Aufgaben un beobachtet an eine KI delegieren. So erwerben die Studierenden die Fähigkeiten, die zwar von einer KI unterstützt werden könnten, aber von Absolvent*innen selbst beherrscht werden sollten. Abschließend ist es empfehlenswert, das Thema KI differenziert in Tutor*innenqualifizierungen zu behandeln und dabei die Betreuer*innen der Tutor*innen einzubeziehen, um ein abgestimmtes Vorgehen zu gewährleisten und einen breiteren Diskurs über den Einsatz von KI in der Lehre anzustoßen.

Literatur

- Choi, S., Jang, Y., & Kim, H. (2022). Influence of pedagogical beliefs and perceived trust on teachers' acceptance of educational artificial intelligence tools. *International Journal of Human-Computer Interaction*, 39(4), 910–922. <https://doi.org/10.1080/10447318.2022.2049145>
- Kieliebak, M., Drewek, A., Grob, J., Kruse, O., Mlynchik, K., Rapp, C., & Waller, G. (2023). Generative KI beim Verfassen von Bachelorarbeiten: Ergebnisse einer Studierendenbefragung im Juli 2023. ZHAW Zürcher Hochschule für Angewandte Wissenschaften. <https://doi.org/10.21256/zhaw-2491>

- Drachsler, H. (2025) Design, Development and Evaluation of Highly Informative Learning Analytics. In Queckenberg, R., Leschke, J., Persike, M. (Hg.) Learning Analytics, Artificial Intelligence und Data Mining in der Hochschulbildung – Beiträge zur Learning AID 2024.
- Gerber, A., & Niechoj, T. (2025). KI auf dem Campus: Von der Empirie zur Strategie. In Queckenberg, R., Leschke, J., Persike, M. (Hg.) Learning Analytics, Artificial Intelligence und Data Mining in der Hochschulbildung – Beiträge zur Learning AID 2024.
- Gottschling, S., Seidl, T., & Vonhof, C. (2024). Nutzung von KI-Tools durch Studierende: Eine exemplarische Untersuchung studentischer Nutzungsszenarien. *die hochschullehre – Interdisziplinäre Zeitschrift für Studium und Lehre*, 11. <https://www.hochschullehre.org>
- Kumar, V. V., & Raman, R. (2022). Student perceptions on artificial intelligence (AI) in higher education. In 2022 IEEE Integrated STEM Education Conference (ISEC) (pp. 450–454). IEEE. <https://doi.org/10.1109/ISEC54952.2022.10025165>
- Hopp, M., Hoffmann, A.-K., Zielke, A., Leslie, L., & Seeliger, M. (2023). Jung, akademisch, prekär: Studentische Beschäftigte an Hochschulen und Forschungseinrichtungen: Eine Ausnahme vom dualen System regulierter Arbeitsbeziehungen. IAW Bremen. <https://www.iaw.uni-bremen.de/f/a515fbdade.pdf>
- Preiß, J., Bartels, M., & Pawlowski, J. (2023). ChatGPT & Me: Umfrageergebnisse und Implikationen ein Arbeitstreffen. Präsentation. <https://www.hul.uni-hamburg.de/ueber-uns/aktuelles/2023-10-04-duty-publication.html>
- Rohde, J. A. (2019). Der Beitrag von (Fach-)Tutor*innen und ihrer Qualifizierung zur Qualität der Hochschullehre. In #VERNETZT: Beiträge aus dem Netzwerk Tutorienarbeit an Hochschulen (7).
- Rohde, J. A., & Uzulis, M. (2024). Künstliche Intelligenz in Studium und tutorieller Lehre: Einsatzmöglichkeiten und Gefahren aus der Sicht von Tutor:innen. In Heyner, M., Pfeiffer, L., Wanko, S., Wiemer, S., & Wolff, L. (Hg.), *Vernetzt. Mittendrin. Auf Augenhöhe: 15 Jahre Netzwerk Tutorienarbeit*.
- Schäfers, J. (2025). Generative KI-Tools in der Lehrkräftebildung – Themenschwerpunkte einer anwendungsorientierten Lehrveranstaltung. In Queckenberg, R., Leschke, J., Persike, M. (Hg.) Learning Analytics, Artificial Intelligence und Data Mining in der Hochschulbildung – Beiträge zur Learning AID 2024.
- Spannagel, C. (2024). Künstliche Intelligenz in der tutoriellen Arbeit: Unterstützung und Herausforderung für Tutor:innen. In Heyner, M., Pfeiffer,

L., Wanko, S., Wiemer, S., & Wolff, L. (Hg.), Vernetzt. Mittendrin. Auf Augenhöhe: 15 Jahre Netzwerk Tutorienarbeit.

Strzelecki, A. (2024). Students' acceptance of ChatGPT in higher education: An extended unified theory of acceptance and use of technology. *Innovative Higher Education*. <https://doi.org/10.1007/s10755-023-09686-1>

von Garrel, J., Mayer, J., & Mühlfeld, M. (2023). Künstliche Intelligenz im Studium: Eine quantitative Befragung von Studierenden zur Nutzung von ChatGPT & Co. Hochschule Darmstadt. <https://doi.org/10.48328/tudatalib-1219>

Hinweis

ChatGPT 4.0 wurde als Formulierungshilfe beim Schreiben des Artikels eingesetzt.

Kritischer Umgang mit KI: Was heißt das und wie zeigt er sich in studentischen Reflexionen beim forschenden Lernen?

Eine kulturwissenschaftliche Perspektive¹

Julius Voigt,² Katrin Girgensohn,³ Jürgen Neyer,⁴ Benno Stein,⁵ Bernd Fröhlich,⁶ Matti Wiegmann,⁷ Magdalena Anna Wolska⁸, Dora Kiesel,⁹ Patrick Riehm,¹⁰ Irene López García,¹¹ Mitja Sienknecht¹² und Sassan Gholiagha¹³

KI-Nutzung im Hochschulkontext sollte – so wird es häufig betont und gefordert – kritisch erfolgen. Dieser Beitrag befasst sich aus einer tendenziell kulturwissenschaftlichen Perspektive damit, was eine kritische Nutzung sein könnte. Dafür zeigt er anhand eines Einblicks in eine qualitative Studie zu einem politikwissenschaftlichen Seminar, das im Modus des Forschenden Lernens durchgeführt wurde, wie sich kritisches Denken im Umgang mit KI-Tools in studentischen Reflexionen manifestieren kann.

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

2 ORC-ID: 0009-0009-8533-4475

3 ORC-ID: 0000-0001-7174-3491

4 ORC-ID: 0000-0001-6788-5219

5 ORC-ID: 0000-0001-9033-2217

6 ORC-ID: 0000-0002-9439-1959

7 ORC-ID: 0000-0002-3911-0456

8 ORC-ID: 0009-0007-7841-937X

9 ORC-ID: 0000-0002-6283-2633

10 ORC-ID: 0000-0002-6956-466X

11 ORC-ID: 0009-0003-1237-6734

12 ORC-ID: 0000-0001-5217-1432

13 ORC-ID: 0000-0001-6464-7557

A critical approach to AI: What does it mean and how does it manifest itself in students' reflections in research-based learning? A cultural studies perspective

It is often emphasized and demanded that AI should be used critically in a university context. This article looks at what critical use could be from a cultural studies perspective. To this end, it uses an insight into a qualitative study of a political science seminar conducted in the mode of research-based learning to show how critical thinking in dealing with AI tools can manifest itself in student reflections.

Einleitung

Die häufige Forderung danach, nicht nur im Hochschulkontext, Künstliche Intelligenz (KI) *kritisch* zu nutzen (z. B. Buck und Limburg 2024), hat uns im Kontext des Forschungsprojekts SKILL (Girgensohn et al. 2023) zu der Frage geführt, wie ein kritischer Einsatz von KI-Tools in der Hochschullehre aussehen könnte. Folgende Hypothesen leiten uns dabei:

1. Forschendes Lernen (FL, nach Huber und Reinmann 2019) und KI sind ein gutes Paar, um die gegenseitigen Vor- und Nachteile auszugleichen. (vgl. dazu auch Preiß, Watanabe 2024, Wrede et al. 2023)
2. Es ist möglich, kritisches Denken und eine kritische Haltung (mit und ohne KI) durch FL zu fördern und zu kultivieren.

In diesem Beitrag wird die Möglichkeit kritischen Denkens beim Forschenden Lernen mit KI unter dem Schirm eines kulturwissenschaftlichen Forschungsparadigmas betrachtet und dient als Grundlage einer qualitativen Studie. Unser Anliegen ist es, die – in anderen Bereichen des SKILL-Projekts praktizierten – Ansätze von Data Mining und quantitativer Analyse durch diese Sichtweise zu ergänzen.

KI-Kritikbegriff und kritische KI-Praxis aus kulturwissenschaftlicher Perspektive

Um mit Adorno (1971) und Biesta (2005) eine kritische (Hochschul-)Kultur zu fördern, die an einem dichten, vielschichtigen und persönlichkeitsfördernden Ideal von *Bildung* (in Abgrenzung zu *Lernen*) interessiert ist, braucht es einen entsprechend vielschichtigen, offenen und dennoch konkreten und operatio-

nalisierbaren Begriff von Kritischem Denken. Kritisches Denken und Bildung können nicht schnell und nicht ›einfach so‹ anhand von messbaren Kategorien hergestellt werden. Sie benötigen Engagement, Mut und Zeit. Angesichts von Multikrise und Zeitdruck stellt der Anspruch einer geduldigen kritischen KI-Praxis eine Herausforderung dar, noch dazu angesichts eines sich rasant entwickelnden Feldes von KI und Informatik.

Eine erste Maxime könnte, mit Isabelle Stengers, daher die Forderung nach Langsamkeit sein (Stengers 2018). Wenn Krisen und KI-Entwicklung toben, ist ein möglicher kritischer Akt der Unterscheidung (Kritik/Krise von altgr. *krínein*: trennen, unterscheiden), etwas Ruhe in die Entwicklungen zu bringen. Natürlich kann kritische Praxis nicht ›bloß‹ in beruhigter Passivität enden, darum braucht es einen *Raum*, wo kritische Aktion und Reflexion zusammenkommen. Bei Stengers Kollegen Bruno Latour finden wir einen Begriff, die Arena, mit dem sich ein Zeitraum denken lässt, um KI-Kritik buchstäblich (ein-)zu üben: »Der Kritiker ist nicht derjenige, der entlarvt, sondern der, der versammelt. Der Kritiker ist nicht der, der dem naiven Gläubigen den Boden unter den Füßen wegzieht, sondern der, der den Teilnehmern Arenen bietet, wo sie sich versammeln können. [...] [V]ielmehr ist er derjenige, für den, was konstruiert wird, zerbrechlich ist und der Pflege und der Vorsicht bedarf.« (Latour 2021, 55). Zeiträume wie diese ließen neben dichtem Austausch, Vorsicht und Nachdenken auch die notwendige ›messiness‹ zu, die Stengers hervorhebt und die laut ihr den sogenannten ›fast sciences‹ fehlt (vgl. Stengers, 120).

Die sorgsame Pflege, das Kultivieren, wie es hier bei Latours Arena deutlich wird, verträgt sich aus unserer Sicht insbesondere mit einer kritischen und offenen Feedbackkultur, weniger mit einer Assessmentkultur, Mess- und Überprüfbarkeit. Auch Hendrik Drachsler (2024) hebt diese grundlegende Tendenz zur Feedbackkultur als Vorschlag für die Bildungskultur in seiner Keynote der diesjährigen Learning AID Konferenz in Bochum hervor. Anders als Drachsler und sein Team (Woitt et al. 2023), welche die Feedbackpraktiken größtenteils in *messbare* Kategorien überführen, untersuchen wir in unserer Arbeit stärker im qualitativen Modus die kritische Lern- und Feedbackkultur und -kompetenz und versuchen, diese in Bezug auf KI-Nutzung *lesbar* zu machen. Das Anliegen bleibt ähnlich und ist die Entwicklung, Erprobung und begleitende Erforschung einer studierendenzentrierten, *kritischen KI-Kultur*, die sich immer auch als »Kunst« einer *KI-kritischen Kultur* versteht, um von den Entwicklungen in diesem Feld »nicht dermaßen regiert zu werden« (vgl. Foucault 1992, 12).

Um in Bildungsprozessen mit und ohne KI und im Feld von Lehr- und Lernanalyse neben Berechenbarkeit und Codierbarkeit auch einen kultur- und geisteswissenschaftlichen Begriff von Kritik einzubringen, haben wir uns an die Arbeit gemacht einen solchen zu entwickeln, in Seminaren zu erproben und dessen Wirkung zu erforschen. Gerade in einer Zeit, wo insbesondere auch im soziokulturellen Feld (Feher/Katona 2021) sowie in den Kultur- und Geisteswissenschaften der KI-Boom durch ChatGPT und Co. Einzug hält (Mauthe et al. 2024), sind diese Fachrichtungen heraus- und aufgefordert, mit ihrer Expertise mitzubestimmen in welcher Art und Weise KI genutzt und KI-Kritik eingeübt werden kann und sollte. Um dies systematisch zu fördern und zu fordern wurde bei SKILL folgende Begriffsbestimmung für kritisches Denken im Zuge von KI-Nutzung und -Entwicklung erarbeitet:

Begriffsbestimmung Kritisches Denken

»Kritisches Denken ist ein systematischer und dennoch unvorhersehbarer und manchmal riskanter Denkprozess, der zu einer (vorläufig) endgültigen Schlussfolgerung führt.

Die daran beteiligten Denkprozesse analysieren und bewerten Vorannahmen und vorläufige Schlussfolgerungen, indem sie – auch mit kreativen Methoden – nach Grenzen suchen und Interpretationen in Frage stellen sowie Quellen und Belege nach wissenschaftlichen Kriterien auswerten. Zum kritischen Denken gehört neben der grundsätzlichen Skepsis auch die grundsätzliche Bereitschaft, fremde Gedankengänge wohlwollend zu akzeptieren und empathisch zu prüfen. Es erfordert daher auch Ambiguitätstoleranz. Kritisches Denken ist grundsätzlich mit Metakognition verbunden, d.h. der bewussten Wahrnehmung der eigenen Denkprozesse und deren Analyse und Bewertung, was auch die Bereitschaft zur Selbstkorrektur einschließt. Es ist immer mit kollaborativen Prozessen – die auch asynchron und durch Lesen stattfinden können – verbunden, da nur so die Grenzen des eigenen Denkens erkannt werden können. Kritisches Denken setzt die Bereitschaft voraus, Verantwortung für die Ergebnisse der eigenen Denkprozesse zu übernehmen. Es braucht Zeit, Energie und Ressourcen und bildet so einen Gegenpol zur subjektiven, spontanen Meinungsbildung.« (SKILL-Projekt 2024)

Die Herleitung der Begriffsbestimmung wird ausführlicher in Voigt, Christ et al. (i. Dr.) sowie in Girgensohn, Voigt et al. (2025) beschrieben und führt ver-

schiedene kultur- und geisteswissenschaftliche sowie hochschuldidaktische Traditionen und Konzeptualisierungen des Kritikbegriffs und zum kritischen Denken zusammen. Ein besonderes Merkmal ist dabei die Verzahnung von zwei grundlegenden Linien, die beim kritischen Denken eine Rolle spielen: die Fähigkeit und Notwendigkeit allein und selbstständig zu denken sowie – scheinbar demgegenüber – die eigenen Gedanken dem Denken anderer auszusetzen. Aus unserer Sicht stellt gerade das Wechselspiel beider Modi einen doppelten Kern kritischen Denkens oder einer kritischen Praxis dar. In Bezug auf KI-Nutzung hat Watanabe in Auseinandersetzung mit Hanna Arendt (Watanabe 2023) und Kant (Watanabe 2024) die Besonderheiten insbesondere des selbst Denkens gründlicher beleuchtet. In Anders (2023) wird die Traditionslinie John Deweys und weiterer deutlicher, wobei das Denken mit und gegen andere eine prominentere Rolle einnimmt.

Seminare zwischen Fachlehre, Forschung, Feedback und KI

Im Sinne dieser konkreten, aber dennoch umfangreichen Definition von kritischem Denken wurden Seminare im Modus des Forschenden Lernens entwickelt. Dort wird die Definition mit Studierenden in actu erprobt, aber auch diskutiert, weiterentwickelt sowie ihre Auswirkung und Machbarkeit begleitend erforscht.

In kleinen Gruppen werden Studierende, begleitet von Lehrenden, Professor*innen und KIs als virtuellen Tutor*innen (Dreyfus/Dreyfus 1986; Lin et al. 2023), durch einen selbstständigen und kompletten Forschungsprozess geführt. Sie nutzen dabei generative KI-Anwendungen in allen Forschungs- und Schreibphasen und reflektieren dies, die Gruppenarbeit sowie die Fort- und auch Fehlschritte der Arbeit regelmäßig und schriftlich. Die Reflexionen folgten dabei den von Bräuer (2016) vorgeschlagenen Schritten: Zielsetzung formulieren, Beschreibung, Analyse, Bewertung, Planung und neue Zielsetzung. Am Ende wird die kollaborative Forschungsarbeit der Seminargruppe(n) publiziert, was einen wesentlichen Bestandteil beim Forschenden Lernen ausmacht. Gerade wenn es um Verantwortung und Autor*innenschaft gegenüber – auch mit KI produzierten – Ergebnissen geht, tritt die Relevanz dieser Dimension des Forschenden Lernens noch einmal besonders hervor. Die Publikation von Alaraishi, Er et al. (2024) enthält 2 von ursprünglich 3 Fallstudien der Studierenden und ist online abrufbar.

Im Seminar werden somit Fachlehre, KI-Nutzung, kollaboratives Lernen, Peer- sowie Expert*innenfeedback im Prozess des gemeinsamen Forschens vereint und regelmäßig reflektiert.

Inhaltsanalyse: Reflexionspapiere als Motor kritischen Denkens sowie Grundlage der Forschung

In den Reflexionspapieren, die die Studierenden zum Vor- und Nachdenken über ihre Arbeit wöchentlich geschrieben haben, finden sich zahlreiche und vielfältige Spuren kritischen Denkens und eines gründlichen Ausprobierens, Aushandelns und Reflektierens. Für eine qualitative Inhaltsanalyse nach Kuckartz (2018) wurden aus der obigen Begriffsbestimmung deduktiv Oberkategorien entwickelt. Die am häufigsten auftretenden Kategorien sind »Metakognition/bewusste Wahrnehmung eigener Denkprozesse und Handlungen«, »Austausch/Kollaborativ Denken/Handeln« und »Analyse/Skepsis/Überprüfen/Bewertung«. Dass die Studierenden aktiv und regelmäßig in schriftlicher Form über ihre Arbeit mit und ohne KI im Forschungsprozess nachgedacht haben, ist ein erster Erfolg, der die Hypothese der Passfähigkeit von Forschendem Lernen, Kritischem Denken und KI-Nutzung bestätigt. Hierbei scheinen die Reflexionen eine wichtige Rolle zu spielen; auch merklich für die Studierenden selbst: »Die Einzelreflexionen helfen mir dabei meine Gedanken zu ordnen und motivieren mich dazu aktiv in diesem Seminar weiterzuarbeiten.« (Fall 2, S. 11)

Es zeigt sich: Praxis und Material der Reflexionsschreiben sind – wenn man so will – kontingenzbewusste kulturwissenschaftliche (Feld-)Forschung (Reckwitz 2008) in Aktion. Die Reflexionen im Zuge der KI-Nutzung fördern das verdichtete Zusammendenken technischer, ökologischer, ethischer, soziokultureller, medientheoretischer, epistemologischer, semiotischer usw. Herausforderungen, die die Studierenden durchlaufen. Diese Auseinandersetzung passiert auf den zwei Gleisen kritischen Denkens: selbstständig und für sich sowie im Austausch mit Peers, Expert*innen und KI. Die dialogischen Dimensionen zeigen sich in den induktiv hinzugekommenen und vermehrt auftauchenden Subkategorien: »Rolle d. Dozierenden«, »Rolle der Peers« und »KI als Tutor*in, Lernpartner*in, Motivator*in«. Viele dichte Beschreibungen zeugen hier anschaulich von der Notwendigkeit eines Austauschs auf diversen Ebenen.

Über die un-/kritische Arbeit mit KI in der letztgenannten Kategorie werden wir genauere Untersuchungen anstellen, die Auswertung steht derzeit noch am Anfang. Dabei wird auch zu fragen sein, wie Studierende das Entwickeln eines kritischen Bewusstseins selbst beschreiben. Ein Beispiel aus einer der Reflexionen veranschaulicht das studentische Erlebnis:

»Die ›kritische Haltung‹ im Umgang mit KI beim Studieren, Forschen und Lernen bedeutet für mich, dass ich nach der Nutzung von KI-Tools feststelle, dass meine Kreativität abnimmt und ich stark von den Formulierungen der KI abhängig werde, da sie oft besser und schneller sind. Dadurch muss ich selbst weniger nachdenken, was ein Nachteil sein kann. Besonders beim Bearbeiten langer Texte habe ich Schwierigkeiten, daher versuche ich, mit Hilfe von ChatGPT Begriffe zu erklären und Texte zusammenzufassen, um besser folgen zu können. Ein Problem dabei ist, dass ChatGPT keine direkten Zitate oder sichere Informationen liefert, daher muss ich die Informationen immer selbst überprüfen.« (Fall 1, S. 4)

Das Zitat zeigt den schmalen Grat und die Ambivalenz zwischen Unterstützung und Schwächung im Denkprozess mittels KI. Diese ermöglicht z.T. einen Zugang zu zunächst schwer verständlichem Wissen, gleichsam droht damit die eigene Denkfähigkeit abzunehmen. Die tatsächliche und im nächsten Moment vermeintliche Hilfe per KI wird als potenziell fehlerhaft eingeordnet, was interessanterweise wiederum das eigene Denken und Überprüfen von (KI-)Ergebnissen erfordert und somit fördert. Zwischen Vorteilen und Verkomplizierungen mit der Technik entwickelt sich so eine Art Quasi-Dialog, dessen Ausgang aus unserer Sicht offen ist, der aber neben einigen (neuen) Problemen, die es natürlich zu thematisieren gilt, zumindest eines schafft: das Denken herauszufordern.

Konklusion

Durch Sicht- und Lesbarmachen per qualitativer Inhaltsanalyse wird die persönliche Erfahrung der Studierenden auf eine Weise zugänglich, die für einen kultur- und geisteswissenschaftlichen Modus des Denkens, Studierens und Forschens auf besondere Weise an Relevanz gewinnt. Das Setting des Forschenden Lernen ermöglicht die Zusammenkunft von ›Technikexperiment‹, Forschungsprozess, Gruppenerfahrung und regelmäßiger Metareflexion. In diesem komplexen Geschehen werden die Studierenden maßgeblich mit aktuellen technischen und soziokulturellen Herausforderungen und Fragen

konfrontiert. Im Seminarraum und darüber hinaus lernen sie gemeinsam mit diesen Herausforderungen und Fragen empirisch und diskursiv umzugehen. Die Studierenden ›trainieren‹ in Aktion und begleitet durch selbstständige Reflexion sowie in gemeinsamer Diskussion im Seminar wesentliche Kultur- und Wissen(schaft)spraktiken. Das Bewusstwerden und die Verantwortung für die Folgen bestimmter technischer, kommunikativer, sozialer usw. Entscheidungen werden hierbei zur Aufgabe für das persönliche und wissenschaftliche Denken und Tun.

Die intensive Auseinandersetzung in den Reflexionen mit dem eigenen Forschungs- und Denkprozess, mit und ohne KI, geht dabei im besten Fall in Richtung einer Art buchstäblichen Denkszene. Mit Adorno (1974) ließe sich mit dem Stichwort vom »Schauplatz geistiger Erfahrung« (ebd. 21) auch von einer essayistischen Form der KI-Nutzung sprechen. Die Seminare werden zur offenen Suchbewegung in einem thematisch und didaktisch eingebetteten Versuch. Gerahmt durch eine Lehr- und Lernkultur wie das forschende Lernen wird dieses Zusammenspiel im Idealfall zur gut gestalteten kritischen und kreativen ›Arena‹, deren Konstruktion und Pflege sich nach den ersten Erfahrungen lohnt.

Sie ermöglicht eine Annäherung an ein Ideal von Forschung und Lehre, das nicht nur Stengers Forderung nach ›slow science‹ entspricht, sondern das ein dichtes und erfahrungsgebundenes Lernen im Sinne von Bildung möglich macht. Dabei werden verschiedene persönliche und disziplinäre Stile gefordert und eine z.T. undisziplinierte Flexibilität gefördert, um mit unvorhergesehenen Fragen umzugehen bzw. diese zunächst einmal zu formulieren. Vielleicht kein schlechter Ansatz, um mit aktuellen und immer wieder akuten Herausforderungen nicht nur im Zuge von KI-Entwicklungen umzugehen.

Literatur

- Adorno, T. W. (1971) Kritik. Kleine Schriften zur Gesellschaft. Frankfurt/M: Suhrkamp.
- Adorno, T. W. (1974) ›Der Essay als Form‹, in ders. Noten zur Literatur, in ders. Gesammelte Schriften Band II. Frankfurt/M: Suhrkamp.
- Alaraishi, M., Er, M., Festag, S., Hasanzade, T., Lang, K., Low, S., Neyer, J., Palenda, C., Rebitzer, H., Swierczynski, A., Voigt, J. (2024) Weltpolitik im Umbruch: Eine Bestandsaufnahme neuer Formen multilateraler Krisen-

- bewältigung. Forschung zu Wissenserwerb und Lehr-/Lernprozessen, (4). <https://doi.org/10.11584/opus4-1356>.
- Anders, B. A. (2023) *The AI Literacy Imperative: Empowering Instructors & Students*. Sovorel Publishing.
- Biesta, G. (2005) ›Against learning. Reclaiming a language for education in an age of learning‹, *Nordisk Pedagogik*, 25, pp. 54–66. Oslo: ISSN 0901–8050.
- Bräuer, G. (2016) *Das Portfolio als Reflexionsmedium für Lehrende und Studierende* (2nd edn). *Kompetent lehren: Band 6*. Verlag Barbara Budrich; UTB GmbH.
- Buck, I., Limburg, A. (2024) ›KI und Kognition im Schreibprozess: Prototypen und Implikationen‹, *JoSch*, 1(24), pp. 8–23. <https://doi.org/10.3278/JOS2401W002>.
- Drachsler, H. (2024) ›Auf dem Weg zu hochinformativen Learning Analytics mit KI‹, *Keynote-Vortrag, Learning AID 2024*, Bochum.
- Dreyfus, H. L., Dreyfus S. E. (1986) ›Computers in the Classroom: Tools, Tutors and Tutees‹, in dies. *Mind over Machine. The Power of Human Intuition and Expertise in the Era of the Computer*. New York: The Free Press.
- Feher, K., Katona, A. I. (2021) ›Fifteen shadows of socio-cultural AI: A systematic review and future perspectives‹, *Futures*, 132, 102817. <https://doi.org/10.1016/j.futures.2021.102817>.
- Foucault, M. (1992) *Was ist Kritik?* Berlin: Merve Verlag.
- Girgensohn, K., Mundorf, M., Gholiagha, S., Voigt, J., Fröhlich, B., Kiesel, D., Neyer, J., López Garcia, I., Riehmann, P., Sienknecht, M., Stein, B., Wiegmann, M., Wolska, M. A. (2023) ›Research Based Learning with AI at the Social Science AI-Lab for Research Based Learning (SKILL)‹, *Forschung zu Wissenserwerb und Lehr-/Lernprozessen*, (3). <https://doi.org/10.11584/opus4-1326>.
- Girgensohn, K., Voigt, J., Gholiagha, S., Fröhlich, B., Kiesel, D., Neyer, J., López Garcia, I., Riehmann, P., Sienknecht, M., Stein, B., Wiegmann, M., Wolska, M. A. (2025) ›KI und Kritisches Denken beim Forschenden Lernen in Politikwissenschaften‹, *Zeitschrift für Hochschulentwicklung*, 20(SH-KI-2), 39–59. <https://doi.org/10.21240/zfhe/SH-KI-2/03>.
- Huber, L. and Reinmann, G. (2019) *Vom forschungsnahen zum forschenden Lernen an Hochschulen*. Wiesbaden: Springer Fachmedien. <https://doi.org/10.1007/978-3-658-24949-6>.
- Kuckartz, U. (2018) *Qualitative Inhaltsanalyse. Methoden, Praxis, Computerunterstützung* (4th edn). Weinheim, Basel: Beltz Juventa.

- Latour, B. (2021) *Elend der Kritik. Vom Krieg um Fakten zu Dingen von Belang.* Zürich/Berlin: Diaphanes.
- Lin, C. C., Huang, A. Y. Q., Lu, O. H. T. (2023) ›Artificial intelligence in intelligent tutoring systems toward sustainable education: a systematic review‹, *Smart Learning Environments*, 10(41). <https://doi.org/10.1186/s40561-023-00260-y>.
- Mauthe, A., Latz, C., Rosenbaum, A. (2024) ›Chancen und Risiken im Umgang mit KI in der Lehre‹, Vortrag, *Learning AID 2024*, Bochum.
- Preiß, J., Watanabe, A. (2024) ›Chance für eine neue Renaissance? Forschendes Lernen als Antwort auf neue KI-Herausforderungen in der Hochschulbildung?‹, *Dikule-Symposion*, Bamberg.
- Reckwitz, A. (2008) ›Die Kontingenzzperspektive der »Kultur«. Kulturbegriffe, Kulturtheorien und das kulturwissenschaftliche Forschungsprogramm‹, in ders. *Unscharfe Grenzen. Perspektiven der Kultursoziologie.* Bielefeld: transcript Verlag. <https://doi.org/10.1515/9783839409176-001>.
- SKILL-Projekt (2024) *Begriffsbestimmung Kritisches Denken.* Internes Arbeitspapier.
- Stengers, I. (2018) *Another Science is Possible: A Manifesto for Slow Science.* Cambridge: Polity.
- Voigt, J., Christ, M., Girgensohn, K., Gholiagha, S., Fröhlich, B., Kiesel, D., Neyer, J., López Garcia, I., Riehmman, P., Sienknecht, M., Stein, B., Wiegmann, M., Wolska, M. A. (2025, i. Dr.) *Kritisches Denken Lernen und kritisches Lernen Denken. Einblicke aus dem SKILL-Projekt (A Social Science Lab for Research Based Learning).* Einreichung für JFMH-Tagungsband. Münster/New York: Waxmann.
- Woitt, S., Weidlich, J., Jivet, I., Orhan Göksün, D., Drachsler, H., Kalz, M. (2023) ›Students' feedback literacy in higher education: an initial scale validation study‹, *Teaching in Higher Education*. Available at: <https://doi.org/10.1080/13562517.2023.2263838> (Accessed: 30.09.2024).
- Watanabe, A. (2023) ›Von tätigen Studierenden: Hannah Arendts Tätigkeitsanalysen als Reflexionsinstrument für den Einsatz von Künstlicher Intelligenz in der Hochschulbildung‹, *Zeitschrift für Hochschulentwicklung*, 18(3), pp. 197–212. <https://doi.org/10.21240/zfhe/18-03/10>.
- Watanabe, A. (2024) ›Have Courage to Use Your Own Mind, with or without AI: The Relevance of Kant's Enlightenment to Higher Education in the Age of Artificial Intelligence‹, *The Electronic Journal of e-Learning*, Vol. 22, No. 2, pp 46–58. <https://doi.org/10.34190/ejel.21.5.3229>.

Wrede, S. E., Gloerfeld, C., Witt, C. de, Wang, X. (2023) ›Künstliche Intelligenz und forschendes Lernen – ein ideales Paar im Hochschulstudium!?, in Schmohl, T., Watanabe, A., Schelling, K. (Hg.) Hochschulbildung: Lehre und Forschung. Künstliche Intelligenz in der Hochschulbildung, Vol. 4, pp. 195–212. Bielefeld: transcript Verlag. <https://doi.org/10.14361/9783839457696-011>.

Ein (KI-)Chatbot für ILIAS

Perspektiven auf Conversational AI in der Beratung, Begleitung und dem Support in der Lehre¹

Beatrix Busse,² Ingo Kleiber,³ Nadimo Staszak⁴ und Mark Kusserow⁵

*Der Artikel diskutiert die Entwicklung einer Conversational AI, des (KI-)Chatbots cboAssist:edu, für ILIAS, der Lehrende und Lernende dialogisch und kontextbezogen im Learning Management System unterstützt. Dabei verbindet er mehrere Informationsquellen und Systeme (z. B. das Campus-Management-System) über eine Oberfläche. Der Chatbot kombiniert regelbasierte Dialogführung mit KI-basierten Funktionen, um Nutzer*innen insbesondere bei technisch-didaktischen Herausforderungen zu unterstützen. Der Artikel thematisiert das Potenzial von (KI-)Chatbots in der Unterstützung von Lehrenden und Lernenden dabei anhand von komplexer werdenden Entwicklungsstufen der Beratung, Begleitung und des Supports sowie möglichen Innovationsszenarien. Darüber hinaus werden die Rolle von generativer KI und die Vorteile von hybriden Ansätzen, gerade in der Unterstützung von Lehrenden und Lernenden, beleuchtet.*

An (AI) Chatbot for ILIAS – Perspectives on Conversational AI in Counseling, Guidance, and Support in Teaching

The article discusses the development of a Conversational AI, the (AI) chatbot cboAssist:edu, for ILIAS, which supports teachers and learners in a dialogical and context-aware fashion within the Learning Management System. In doing so, it connects several information sources and systems (e.g., the Campus Management System) via one interface. The chatbot combines rule-based dialog with AI-based functions to support users,

-
- 1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.
 - 2 ORCID: 0000-0003-4696-6727
 - 3 ORCID: 0000-0001-7231-2714
 - 4 ORCID: 0009-0002-3118-6023
 - 5 ORCID: 0009-0001-1795-7007

especially with technical and educational challenges. The article discusses the potential of (AI) chatbots in supporting teachers and learners on the basis of increasingly complex development stages of counseling, guidance, and support, as well as possible innovation scenarios. In addition, the role of generative AI and the advantages of hybrid approaches, especially in the support of teachers and learners, are highlighted.

Einleitung

Conversational AI, insbesondere »intelligente« Chatbots, kann eine Schlüsselrolle bei der gezielten Unterstützung von Lehrenden und Lernenden einnehmen: Sie entlastet z. B. Expert*innen, indem sie auf Basis von Nutzer*innen- und Kontextinformationen Lehrende gezielt und individuell unterstützt, so dass mehr Zeit für komplexe Beratung- und Supportaufgaben bleibt.

Am CompetenceCenter E-Learning der Universität zu Köln entwickeln wir seit 2022 einen ILIAS-Chatbot, der Nutzer*innen kontextbezogen im zentralen Learning Management System (LMS) unterstützen soll. Dieser bisher »traditionelle« Chatbot, der sich in der Testphase befindet, führt Dialoge entlang vorgegebener Pfade, wird aber um KI-basierte Funktionen erweitert. Im Folgenden wird das System vorgestellt und diskutiert, welche Aufgaben übernommen werden können und welche Rolle generative KI spielen kann.

Beratung, Begleitung & Support in der Lehre

Lehrende und auch z. B. Learning Experience Designer*innen benötigen unserer Erfahrung nach umfassende Unterstützung (Beratung, Begleitung und Support), um hochwertige und innovative Lernerfahrungen entwickeln und begleiten zu können. Im Bildungstechnologie-Kontext insbesondere im Zusammenhang mit dem LMS, sind didaktische und technische Fragestellungen, die uns erreichen, oftmals eng verknüpft. Der Unterstützungsbedarf reicht von einfachen technischen Problemen bis hin zu komplexen, didaktisch-technischen Herausforderungen, etwa bei Lehr-Lernszenarien.

Dabei bedarf es möglichst unmittelbarer, passender Unterstützung und Hilfe zur Selbsthilfe – auch mit Blick auf den Kompetenzaufbau der Nutzer*innen. Unterstützende brauchen Zeit für komplexe Fälle und für deren Bearbeitung klare, ausführliche und kontextbezogene Problembeschreibungen.

Chatbots können hier eine wichtige Rolle einnehmen, indem sie »Standardfälle« bearbeiten, den Kommunikationsaufwand reduzieren und passgenaue Informationen zur Verfügung stellen. Dies entlastet Nutzer*innen und Unterstützer*innen (Meyer von Wolff/Hobert/Schumann 2020). Durch den Einsatz von (generativer) KI und die Anbindung weiterer Systeme können zudem höhere Unterstützungsstufen (s. u.) erreicht werden.

Conversational AI & die Unterstützung von Lehre und Lernen

Ein Chatbot ist ein Conversational User Interface, »eine dialogbasierte Benutzerschnittstelle, über die Menschen mit einem technischen System per natürlicher Sprache interagieren« (Bruns/Kowald 2023: 3). Chatbots fungieren als sprach- und dialogbasierte Schnittstelle zwischen Nutzer*innen und Systemen und ermöglichen eine einheitliche Interaktion mit diesen. Zunehmend wird auch der Begriff Conversational AI verwendet, der die dialogbasierte Interaktion und die Nutzung von KI betont (Freed 2021). KI-Chatbots (vgl. z. B. ChatGPT) werden zudem agentisch, können also (teil-)autonom und mit der »Außenwelt« sowie anderen Systemen interagieren.

Im Lehr- und Lernkontext unterstützen Chatbots z. B. Lehrende bei der Nutzung von Bildungstechnologie oder als Lernbegleitende auch Lernende. Ramandanis und Xinogalos (2023: 20) zeigen, dass Chatbots das Potenzial haben, das Lehr-Lern- und Unterstützungsangebot von Bildungseinrichtungen quantitativ und qualitativ, besonders für Lernende, zu verbessern.

Chatbots in der Unterstützung von Lehrenden

(KI-)Chatbots unterstützen Nutzer*innen bei typischen Problemen, indem sie dialogisch zur Lösung führen, Informationen bereitstellen und Systemfunktionen auslösen können. Zudem dienen sie als Level-0-Support, der Fälle mit Konversations- und Kontextdaten aufbereitet weiterleiten kann.

Der Einzug von KI bietet laut Halsey (2024: 155f.) zwei zentrale neue Möglichkeiten: Sie kann Daten nutzen, um Nutzer*innen zu unterstützen und wiederum aus deren Daten lernen. Zudem können KI-Chatbots Sprache »verstehen« und in einer verständlichen, angepassten und förderlichen Weise kommunizieren und dabei z. B. komplexe Informationen zusammenfassen.

Der Umfang der Unterstützung durch Chatbots lässt sich anhand von Entwicklungsstufen beschreiben. In Tabelle 1 sind solche für einen LMS-spezifi-

schen Chatbot und die Unterstützung von Lehrenden dargestellt. Jede Stufe beinhaltet dabei die Vorhergehende.

Während die Funktionalität auf niederen Stufen greif- und steuerbar ist, stellt die (halb-)automatisierte Beratung und Begleitung – besonders dann, wenn Inhalte erstellt und bearbeitet werden – eine komplexe Herausforderung dar.

Tab. 1: Entwicklungsstufen der Beratung, Begleitung und des Supports

Stufe	Beschreibung
1) Bereitstellung von Hilfsmaterialien	Es werden Informationen aus Informations- und Hilfsmaterialien (z. B. FAQs) bereitgestellt.
2) Kontextsensitive Unterstützung	Durch die Nutzung von Meta- und Kontextdaten kann die Unterstützung an die Situation der Nutzer*innen (z. B. den aktuellen Kurs) angepasst werden.
3) Interaktive und vernetzte Unterstützung	Der Chatbot kann vernetzte Daten und Systeme nutzen und Aktionen auslösen (z. B. Lerner*innen hinzufügen).
4) Dialogorientierte Beratung	Die didaktisch-technische Beratung erfolgt dialogisch und Nutzer*innen können z. B. Rückfragen stellen.
5) Erstellung und Überarbeitung von Inhalten	Es können Inhalte (z. B. eine Übung), auch basierend auf z.B. Kursmaterialien sowie Dialog- und Kontextdaten, erstellt und bearbeitet werden.
6) Begleitung, Analyse und Optimierung	Inhalte und Szenarien können basierend auf z. B. bestehenden Materialien und Learning Analytics analysiert, optimiert und ergänzt werden.

Die technische Komplexität, z. B. der Einsatz von generativer KI und Retrieval Augmented Generation (RAG) – der Verknüpfung von Sprachmodellen mit Wissensdatenbanken oder Kursinhalten –, aber auch die Relevanz rechtlicher Fragen, nehmen kontinuierlich zu.

Hybride Ansätze & die Rolle generativer KI

Seit der Veröffentlichung von ChatGPT und dem daraus resultierenden »ChatGPT Effect« (Chan/Colloton 2024) unterliegt (generative) KI, die unzureichend differenziert wird, im Bildungsdiskurs einem Hype. Im Bereich der Unterstützung befürworten wir trotzdem einen hybriden Ansatz: Dialogsysteme, die primär regelbasiert arbeiten und gezielt durch »traditionelle« KI, LLMs u. ä. unterstützt werden. Während (multimodale) LLMs neue Möglichkeiten für Konversationen und die Analyse sowie Erzeugung von Inhalten bieten, sprechen drei Gründe dafür, gerade in der Unterstützung und Beratung weiterhin auf bewährte Technologien zu setzen.

Erstens ist es vorteilhaft, auf robuste und deterministische Systeme zu setzen. Vorbestimmte (Dialog-)Pfade und eine klare Nutzer*innenführung haben sich bei Standardproblemen als zuverlässig erwiesen. Zweitens weisen generative Modelle weiterhin grundlegende Probleme auf (z. B. unvorhergesehenes Verhalten oder Halluzinationen), die zusätzliche Probleme für Nutzer*innen schaffen können, die besonders in Unterstützungssituationen problematisch sind. Drittens erfordert der »myth of clean tech« (Crawford 202: 41) eine kritische Auseinandersetzung mit den Ressourcen, die KI verbraucht. Besonders »teure« KI, ökonomisch und ökologisch, sollte daher nur dort eingesetzt werden, wo sie ihre Stärken auch ausspielen kann. Dabei ist trotz Vorteilen wie der dauerhaften Erreichbarkeit von KI-Diensten mitzudenken, ob aufgrund der Verfügbarkeit von KI Zusatzleistungen angeboten werden, die man ohne KI gar nicht erst angeboten hätte.

Ungeachtet dessen gibt es gute Gründe, LLMs zu nutzen, um eher klassische Systeme zu ergänzen: Beispielsweise die bessere Erkennung der Herausforderungen und Absichten der Nutzer*innen, die Analyse von Inhalten und Daten oder die Erzeugung und Überarbeitung von Inhalten.

Der ILIAS-Chatbot *cboAssist:edu*

Der ILIAS-Chatbots *cboAssist:edu* hat zum Ziel, dass Lehrende und zukünftig auch Lernende schnell, gezielt und kontextbezogen unterstützt und Mitarbeitende für komplexere Aufgaben entlastet werden. Dies geschieht durch eine freundliche, zentralisierte (Single Point of Support), dialogbasierte, unmittelbare, geführte, individualisierte und kontextbezogene Schnittstelle.

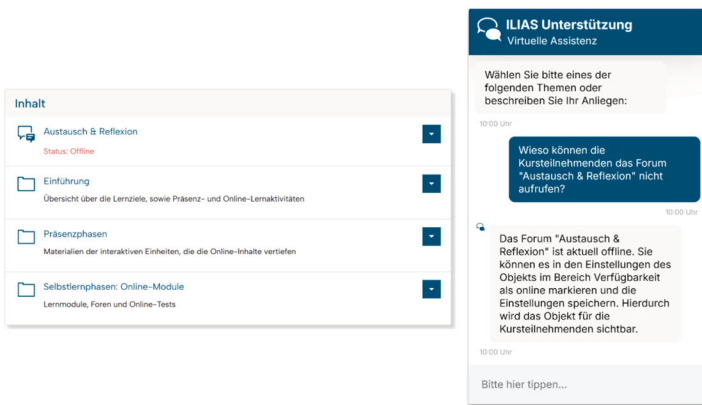
Zudem werden Datenquellen wie das Campus-Management-System (CMS) eingebunden, um Anfragen systemübergreifend zu bearbeiten.

Aktuelle Funktionen

Der Prototyp entspricht der dritten Entwicklungsstufe. Er führt dialogisch durch Standardprobleme, stellt Informationen bereit, reagiert auf den Kontext (z. B. Kurs und Nutzer*in), nutzt Daten aus verschiedenen Schnittstellen und erstellt metadatierte Supportanfragen (Tickets). Nutzer*innen werden passende Themen vorgeschlagen, um das Gespräch zu starten und zu steuern.

Abbildung 1 zeigt eine kontextsensitive Reaktion, bei der ein Objekt als »Offline« konfiguriert und somit für Lernende nicht nutzbar ist. Das System erkennt das Problem und bietet eine Erklärung und Lösung an.

Abb. 1: Kontextsensitive Reaktion auf ein ILLIAS-Objekt



In Zukunft soll der Chatbot u. a. durch den Aufbau eines Support (Learning) Record Store (S(L)RS) erweitert werden, der Unterstützungs- und Lehr-Lernaktivitäten übergreifend aufzeichnet. So kann *choAssist:edu* ausgehend von früheren Fällen und Informationen Nutzer*innen individuell beraten und z. B. passgenau oder auch antizipierend E-Learning-Szenarien erstellen.

Technische Umsetzung & Integration von LLMs

cboAssist:edu basiert auf Rasa⁶, einem modularen, flexiblen »open source ML framework to construct chatbots and intelligent assistants« (Kong/Wang 2021: 25). Rasa fungiert als Middleware zwischen dem Chat-Widget, das Konversations- und Kontextdaten liefert, und den sogenannten Action Workers, die Aktionen ausführen. Rasa ermöglicht sowohl klassisches Natural Language Processing und Understanding (NLP/NLU) als auch die Nutzung von (multimodalen) LLMs. Geplant ist die Einbindung von offenen LLMs und RAG-Systemen z. B. mit Open-Source-KI.nrw⁷ um Inhalte generieren und reagieren zu können, wenn das regelbasierte System an Grenzen stößt. RAG ermöglicht es uns zudem, (Lern-)Materialien einzubeziehen. So kann die jeweils einfachste passende Lösung gewählt werden: von vorgegebenen Dialogpfaden über NLP/NLU bis hin zu LLM- und RAG-basierten Agenten.

Ausgewählte Innovationsszenarien

Abschließend sollen kurz drei Innovationsszenarien skizziert werden, die verdeutlichen, wie Chatbots Lehre und Lernen verändern können.

Kompetenzbasierte & individualisierte Unterstützung

Daten über Hintergründe, Kompetenzen und Präferenzen (vgl. S(L)RS) werden genutzt, um individualisierte Vorschläge und Hilfestellungen, z. B. zur Kurs- und Materialoptimierung oder Aufgaben zu machen. So werden Lehrende auch beim Kompetenzaufbau unterstützt. Nutzungsdaten, z. B. gestellte Fragen, und Feedback können dann zur Optimierung genutzt werden.

Beratung & Erstellung von didaktischen Szenarien

Lehrende erhalten konkrete Empfehlungen zur didaktisch-technischen Gestaltung ihrer Lehre und werden z. B. auf neue Methoden oder Tools aufmerksam gemacht. In Ko-Kreation mit dem Chatbot, welcher auch z. B. Kurse und Objekte erstellen, konfigurieren und mit Inhalten (vgl. RAG) füllen kann, entwickeln Lehrende so ihre Lehre weiter.

6 <https://rasa.com>

7 <https://www.oski.nrw>

Systematische Ausweitung hin zu Lernenden

Chatbots bieten, besonders bei direkter LMS-Integration, großes Potenzial für Lernende. Dieses reicht von der Unterstützung bei der Navigation über die dialogbasierte Interaktion mit Inhalten (vgl. RAG) bis hin zur Planung, Unterstützung und Reflexion von Lernprozessen durch KI-Lernbegleitende, die auch Learning und Assessment Analytics einbeziehen.

Lessons Learned

Ausgehend von unseren Entwicklungserfahrungen und Tests betonen wir drei Erkenntnisse. Erstens können Chatbots als dialogische Schnittstellen zwischen Nutzer*innen, Systemen und digitalen Räumen dienen: Der Chatbot verbindet LMS, CMS und bestehende Informations- und Unterstützungsangebote in einer Oberfläche. Zweitens hat sich die gezielte Nutzer*innenführung anhand vordefinierter Pfade für Standardprobleme als effektiv erwiesen. Drittens ist es auch in einer LLM-dominierten Welt lohnend, bewährte Technologien zu nutzen und diese durch generative KI bewusst, zielführend und mehrwertbringend zu ergänzen.

Literatur

- Bruns, Beate/Kowald, Cäcilie (2023): *Praxisleitfaden Chatbots. Conversation Design für eine bessere User Experience*, Wiesbaden: Springer.
- Chan, Cecilia K. Y./Colloton, Tom (2024): *Generative AI in Higher Education. The ChatGPT Effect*, London, New York: Routledge.
- Crawford, Kate (2023): *Atlas of AI. Power, Politics, and the Planetary Costs of Artificial Intelligence*, New Haven, London: Yale University Press.
- Freed, Andrew R. (2021): *Conversational AI. Chatbots that Work*, Shelter Island: Manning.
- Halsey, Mike (2024): *The IT Support Handbook. A How-To Guide to Providing Effective Help and Support to IT Users*, Berkeley, CA: Apress.
- Kong, Xiaoquan/Wang, Guan/Nichol, Alan (2021): *Conversational AI with Rasa*, Birmingham, Mumbai: Packt.
- Meyer von Wolff, Raphael/Hobert, Sebastian/Schumann, Matthias (2020): »Einsatz von Chatbots am digitalen Büroarbeitsplatz – Eine praxisorientierte

tierte Betrachtung von Einsatzbereichen, Wirkungen und Handlungsempfehlungen«, in: HMD Praxis der Wirtschaftsinformatik 57, S. 413–431.

Ramandanis, Dimitrios/Xinogalos, Stelios (2023): »Investigating the Support Provided by Chatbots to Educational Institutions and Their Students: A Systematic Literature Review«, in: Multimodal Technologies and Interaction 7, S. 103.

GOALS: Ein Lern- und Übungssystem für Lehrveranstaltungen im Zeitalter generativer KI am Beispiel einer Einführungsveranstaltung der Informatik¹

Sven Jacobs,² Marc Sauer³ und Andreas Hoffmann⁴

Die heterogene Vorbildung der Studierenden in den Einführungsveranstaltungen der Informatik stellt Hochschulen vor besondere Herausforderungen, da Informatik als Schulfach in den Bundesländern unterschiedlich verankert ist. Um diesem Umstand zu begegnen, wurde an der Universität Siegen die Übungsplattform GOALS (Graph Oriented and AI Based Learning Siegen) entwickelt. GOALS ermöglicht es den Studierenden, selbst zu entscheiden, wann sie welche Aufgaben bearbeiten, und stellt die Lerninhalte transparent in einem Konzeptgraphen dar. Durch die Integration von Large Language Models (LLMs) wird unmittelbares, formatives Feedback zu Programmieraufgaben generiert. Die Plattform wurde im Sommersemester 2024 in zwei Phasen evaluiert. Die Ergebnisse zeigen eine positive Resonanz der Studierenden hinsichtlich der Nutzbarkeit von GOALS und des generierten Feedbacks.

GOALS: A Learning and Practice System for Lectures in the Age of Generative AI Using the Example of an Introductory Computer Science Lecture

The heterogeneous prior education of students in introductory computer science courses poses particular challenges for universities, as computer science is established differently as a school subject across the federal states. To address this issue, the University of Siegen developed the practice platform GOALS (Graph Oriented and AI Based Learning Siegen). GOALS allows students to decide for themselves when to work on which tasks

-
- 1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.
 - 2 ORCID-ID: 0009-0000-5079-7941
 - 3 ORCID-ID: 0000-0002-9217-3085
 - 4 ORCID-ID: 0000-0002-6870-6451

and presents the learning content transparently in a concept graph. By integrating Large Language Models (LLMs), immediate, formative feedback on programming tasks is generated. The platform was evaluated in two phases during the summer semester of 2024. The results show a positive response from students regarding the usability of GOALS and the generated feedback.

Einleitung

Hochschulische Einführungsveranstaltungen der Informatik stehen vor der besonderen Herausforderung, dass das Schulfach Informatik in den Bundesländern höchst unterschiedlich verankert ist. Im Vergleich zur Forderung von sechs Pflichtstunden Informatik in der Sekundarstufe I der ständigen wissenschaftlichen Kommission der Kultusministerkonferenz berichtet der Informatik Monitor für Nordrhein-Westfalen, dass der Anteil von Schülerinnen und Schülern mit Pflichtfach Informatik in der Sekundarstufe 24 % und der Anteil mit Informatik in der Sekundarstufe II 14 % (Rheinland-Pfalz 8 %/24 %; Hessen 0 %/10 %) beträgt (Hellmig 2023: 77).

Aus diesem Grund sitzen in den meist synchronen Informatik Einführungsveranstaltungen sehr heterogene Lerngruppen. Im Sommersemester 2023 gaben an der Universität Siegen in der Einführungsveranstaltung »Objektorientierte und funktionale Programmierung« (OFP) 43 % (n=97) der Studierenden an, dass sie in der Schule keinen Informatikunterricht besucht haben.

Um diesen Herausforderungen zu begegnen, wurde der Übungsbetrieb für die Einführungsveranstaltung OFP mithilfe einer hierzu entwickelten Übungsplattform mit dem Namen GOALS (Graph Oriented and AI Based Learning Siegen) umgestellt. Statt wöchentlich abzugebenden Übungsaufgaben können die Studierenden nun selbst über das Semester hinweg entscheiden, wann sie welche Aufgaben bearbeiten. Damit trotz asynchroner Bearbeitung unmittelbar und formativ Feedback zu den Lösungen der Studierenden gegeben werden kann, werden die neuen Möglichkeiten von Large Language Models (LLMs) eingesetzt. Hierzu wurden mehrere Komponenten unter dem Namen »Tutor Kai« (Jacobs/Jaschke, 2024a) in GOALS entwickelt.

Methodik


Die Evaluation der Übungsplattform fand im Sommersemester 2024 für die Einführungsveranstaltung OFP in zwei Phasen statt. An der Vorlesung nahmen circa 200 Studierende teil. Das Ziel der Evaluation war es zu untersuchen, wie die Studierenden die Nutzbarkeit von GOALS bewerten und inwiefern die anfänglichen Erwartungen der Studierenden am Ende des Semesters aus ihrer Perspektive erfüllt wurden.

Zu Beginn wurden nach erstmaliger Vorstellung von GOALS die Erwartungen der Studierenden an die Übungsplattform und deren LLM-Integrationen mit einem Fragebogen (Evaluation A) erhoben. Dieser wurde von 97 Studierenden vollständig ausgefüllt. Am Ende der Vorlesungszeit und noch vor der Klausur wurden die Erfahrungen der Studierenden sowie die Nutzbarkeit von GOALS mit einem zweiten Fragebogen (Evaluation B) erfasst (n=58). Die Teilnahme war freiwillig.

GOALS Übungsplattform

In der ersten Entwicklungsstufe von GOALS wurde zunächst ein Konzeptgraph entwickelt, welcher noch nicht für Knowledge Tracing (vgl. Abdelrahman/Wang/Nunes 2023), sondern vielmehr zur Übersicht und Navigation eingesetzt wird. Da die Studierenden selbst entscheiden sollen, wann sie welche Aufgaben bearbeiten, ist es dabei notwendig, die zugehörigen Konzepte und ihre Abhängigkeiten darzustellen. Je Inhaltsbereich wird das Niveau der angestrebten Kompetenzförderung anhand der Kategorien der kognitiven Prozessdimension nach Anderson und Krathwohl (2001) innerhalb eines Graphen dargestellt. Der initiale Konzeptgraph entstand durch die Expertenanalyse (Modulverantwortliche) der in der Form von Folien, Videoaufzeichnungen und Aufgabenstellungen vorhandenen Vorlesungsmaterialien. Dabei wurden diese in Sinnabschnitte unterteilt und nach Konzepten gruppiert. Anschließend wurden Abhängigkeiten modelliert und die vorhandenen Aufgaben basierend auf den kognitiven Prozessdimensionen den Konzepten zugeordnet. Zu jedem Konzept wurden passende Multiple-Choice-Aufgaben basierend auf dem Transkript der Vorlesungsaufzeichnung durch ein LLM generiert, durch Tutoren geprüft und freigegeben (siehe Abschnitt 4.2). Anschließend wurde der initiale Graph in Zusammenarbeit mit zwei Modulverantwortlichen überarbeitet.

Abb. 1: User Interface von GOALS




Damit der Konzeptgraph nicht nur zur Visualisierung, sondern auch zur Navigation genutzt werden kann, muss dieser übersichtlich gestaltet sein. Aus diesem Grund werden Abhängigkeiten vereinfacht dargestellt, indem beispielsweise Knoten innerhalb eines Subgraphen nur Abhängigkeiten untereinander haben (vgl. Abb. 1: oberer Bereich). Zusätzlich werden die Kategorien der kognitiven Prozessdimension vereinfacht als Level dargestellt und jeder Aufgabe visuell nur eines dieser Level zugeordnet (Abb. 1: unterer Bereich).

Zur Evaluation der Nutzbarkeit von GOALS wurde der System Usability Scale (vgl. Brooke 1996) in seiner deutschen Übersetzung (vgl. Gao/Kortum/Oswald 2020: 17) innerhalb Evaluation B verwendet. Die Einzelergebnisse (vgl. Abb. 2) und der Gesamtwert von 80,4 müssen unter der Einschränkung interpretiert werden, dass Studierende, die nicht mit GOALS oder der Vorlesung zurechtgekommen sind, gegebenenfalls nicht mehr auf Anfragen reagierten. Bezüglich des Konzeptgraphen wurden die 58 Studierende in der Evaluation B außerdem gefragt, wie nachvollziehbar dessen Aufbau war und wie gut die Navigation durch diesen gelang. Hinsichtlich des Aufbaus äußerten 15 Studierende und bezüglich der Navigation 20 Studierende, dass Verbesserungspotenzial besteht.

Neben dieser Evaluation der gesamten Plattform und des Konzeptgraphen wurden die diversen Integrationen von generativer künstlicher Intelligenz in

Form von LLMs für die Generation von Aufgaben und formativen Feedback einzeln untersucht (vgl. Jacobs et al. 2025a, Jacobs et al. 2025b).

Abb. 2: System Usability Scale: Ergebnisse der Evaluation B (n=58)



Integration von Large Language Models

Die Möglichkeiten von generativer künstlicher Intelligenz (GenAI) für die Einführung in die Programmierung sind umfangreich (Brett et al. 2023, Prather et al. 2023 sowie Denny et al. 2024). In GOALS wurde das zu Beginn des Sommersemesters 2024 aktuelle Large Language Model »gpt-4-turbo-2024-04-09« von OpenAI (OpenAI 2023) verwendet, um automatisch formatives Feedback zu Programmieraufgaben zu geben sowie die Multiple-Choice- und Programmier-Aufgaben zu generieren.

Feedback


Die Wirksamkeit von Feedback ist hinlänglich belegt (vgl. Hattie/Timperley 2007) und kann durch fehlerspezifische strategische Informationen erheblich zum Lernfortschritt beitragen (vgl. Narciss 2006). Die automatische Generierung von Feedback bei Programmieraufgaben ist bereits seit geraumer Zeit Gegenstand von Forschung (vgl. Keuning/Jeuring/Heeren 2019). In diesem

Kontext werden häufig statische Tests eingesetzt, die sich nur begrenzt anpassen lassen und primär zur Lokalisierung von Fehlern dienen. Large Language Models können diese Funktionen erweitern, indem Probleme dynamischer adressiert werden und Feedback individuell formuliert wird.

Bei einem ersten Feedback-Prototypen für GOALS im Sommersemester 2023 wurden hierzu die Aufgabenstellung, die Lösung des Studierenden, die Ausgabe des Compilers sowie ein Prompt (vgl. Schulhoff et al. 2024: 5) an das LLM gesendet. Innerhalb des Prompts wurde das LLM (GPT-4-0314) dazu gebracht, ein kurzes Feedback zu geben, welches notwendige Konzepte erklärt aber keinesfalls Teile der Lösung verrät. Zur Evaluation bewerteten 51 Studierende 1243 Feedbacks, inwiefern Ihnen das Feedback geholfen hat. Auf einer Likert Skala von eins (überhaupt nicht hilfreich) bis sieben (sehr hilfreich) erreicht der Prototyp hierbei einen Wert von 5,05. Bei einer Expertenanalyse von 263 Feedbacks stellte sich jedoch heraus, dass in sechs Prozent der generierten Feedbacks halluzinierte Fehler beschrieben wurden und zwölf Prozent der Feedbacks zu einer falschen Lösung geführt hätten (vgl. Jacobs/Jaschke 2024a).

Im darauffolgenden Semester wurde das Feedback mittels Retrieval Augmented Generation (vgl. Gao et al. 2024) basierend auf Transkripten der Vorlesungsaufzeichnungen erweitert, sodass innerhalb des Feedbacks passende Stellen aus den Vorlesungsaufzeichnungen zitiert und verlinkt werden können (vgl. Jacobs/Jaschke 2024b). Auf diese Weise soll die Anzahl der Halluzinationen verringert werden und zudem sollen die bekannten Erklärungen aus der Vorlesung den Studierenden beim Erinnern unterstützen. In einem Klausurvorbereitungsworkshop mit 15 Studierenden in Wintersemester 2023/24 wurde dieser Ansatz erstmalig erprobt. Die Ergebnisse deuten darauf hin, dass die verlinkten Vorlesungsaufzeichnungen im Feedback hilfreich für die Studierenden sind (vgl. Jacobs/Jaschke 2024b). Da der Ansatz jedoch zwei aufeinander aufbauende Anfragen an das LLM benötigt, ist die Zeit bis zum ersten Wort des Feedbacks deutlich länger. Durch die Veröffentlichung des im Sommersemester 2024 verwendeten LLMs GPT-4 Turbo konnte diese Zeit deutlich reduziert werden.

Abb. 3: Erwartungen an und Erfahrungen mit dem generierten Feedback



Während der Vorlesungszeit des Sommersemesters 2024 wurden für die Programmieraufgaben insgesamt 9917 Feedbacks generiert. Zu Beginn und Ende des Semesters wurden zudem die Erwartungen (Evaluation A) und Erfahrungen (Evaluation B) der Studierenden an und mit dem generierten Feedback untersucht. Die Ergebnisse (vgl. Abb. 3: Evaluation A) legen nahe, dass die Studierenden nahezu ausschließlich davon ausgingen, durch das Feedback mehr zu lernen und die Aufgaben schneller bearbeiten zu können. Die Erwartungen der Studierenden wurden aus ihrer Perspektive erfüllt, wobei die Zustimmung hinsichtlich des Lerneffekts leicht gesunken ist und hinsichtlich der Bearbeitungszeit leicht gestiegen ist (vgl. Abb. 3: Evaluation B). Zudem sind die Bedenken hinsichtlich der Fairness und Genauigkeit im Vergleich von Evaluation A und Evaluation B gesunken.

In einer Think-Aloud-Studie, die zusätzlich zu Beginn des Sommersemesters 2024 durchgeführt wurde, wurde der Nutzen des Feedbacks für die Studierenden qualitativ untersucht. Dabei zeigte sich, dass Studierende mit Programmiererfahrung mehr vom Feedback profitieren als Studierende ohne Vorkenntnisse (vgl. Jacobs et al. 2025b).

Aufgaben generieren

In GOALS können sowohl Programmieraufgaben als auch Multiple- und Single-Choice (MC) Aufgaben automatisch mittels LLMs generiert werden.

Bei den MC Aufgaben wurde das jeweils relevante Transkript der Vorlesungsaufzeichnung als Kontext für das LLM genutzt (Retrieval Augmented Generation), damit die Fragen inhaltlich zu den tatsächlich behandelten Themen passen. Nach einer anschließenden Revision durch Tutoren und Modulverantwortliche wurden die Fragen für Studierende freigeschaltet. Über 90 % der so generierten MC Aufgaben konnten ohne Korrektur für das Sommersemester 2024 freigegeben werden.

Bei der Generierung von kontextuell personalisierten Programmieraufgaben wurden alle notwendigen Aufgabenbestandteile wie Aufgabenstellung, Programmgerüst, Musterlösung und Unit-Tests basierend auf Programmierkonzepten und einem frei wählbaren Kontext generiert. 200 generierte Python-Aufgaben wurden von Experten anhand unterschiedlicher Kriterien positiv bewertet (vgl. Jacobs et al. 2025a). Anschließend generierten 26 Studierende in einer Übungswoche 167 Programmieraufgaben basierend auf ihren individuell gewählten Kontexten (z. B. Fußball-EM 2024). Von diesen bewerteten sie 104 Aufgaben und gaben an, dass über 90 % der Aufgaben den gewünschten Kontext integrieren und genügend Informationen zur Lösung der Aufgaben gegeben sind. Außerdem bewerteten die Studierenden die Personalisierung der Aufgaben sowie die Möglichkeit, immer weitere Aufgaben generieren zu können, sehr positiv (vgl. Jacobs et al. 2025a).

Fazit

Die Einführung der Übungsplattform GOALS in ihrer ersten Entwicklungsstufe hat eine transparente und übersichtliche Darstellung von Inhalten und Aufgaben in Form eines Konzeptgraphen ermöglicht. Durch die Integration von Large Language Models (LLMs) zur Generierung von formativem Feedback können Studierende die Aufgaben selbstbestimmt und in ihrem eigenen Tempo bearbeiten, ohne an wöchentliche Abgabetermine gebunden zu sein. Die Studierenden bewerteten die Nutzbarkeit der Plattform sehr positiv und empfanden das generierte Feedback als hilfreich. Die hohen Erwartungen an das generierte Feedback wurden aus Sicht der Studierenden erfüllt. Auch die vorgestellten Ansätze zur Generation von Programmieraufgaben erscheinen vielversprechend. Obwohl die Aufgaben, die mit den derzeitigen LLMs (GPT-4o) generiert werden, noch eine manuelle Überprüfung erfordern, könnte dies in Zukunft mit verbesserten Systemen und LLMs nicht mehr der Fall sein.

In zukünftigen Weiterentwicklungen soll der Konzeptgraph zusammen mit dem darin abgebildeten Fortschritt der Studierenden als Lerner-Modell genutzt werden. Dies eröffnet die Möglichkeit, adaptive Feedbackstrategien zu entwickeln und Aufgaben zu generieren, die einen individuellen Lebensweltbezug aufweisen. Auf diese Weise soll GOALS noch besser auf die heterogenen Vorkenntnisse und Bedürfnisse der Studierendenschaft zugeschnitten werden, was zu einem personalisierten und effektiveren Lernprozess beitragen soll.

Literatur

- Abdelrahman, Ghodai/Wang, Qing/Nunes, Bernardo (2023): »Knowledge Tracing: A Survey«, in: *ACM Computing Surveys* 55(11), S. 1–37.
- Anderson, Lorin W./Krathwohl, David R. (2001): *A Taxonomy for Learning, Teaching and Assessing: A Revision of Bloom's Taxonomy of Educational Objectives*, New York: Addison-Wesley.
- Becker, Brett A./Denny, Paul/Finnie-Ansley, James/Luxton-Reilly, Andrew/Prather, James/Santos, Eddie Antonio (2023): »Programming Is Hard – Or at Least It Used to Be: Educational Opportunities and Challenges of AI Code Generation«, in: *SIGCSE 2023: The 54th ACM Technical Symposium on Computer Science Education*, S. 500–506, <https://doi.org/10.1145/3545945.3569759>
- Brooke, John (1996): »SUS: A Quick and Dirty Usability Scale«, in: Patrick W. Jordan/Bruce Thomas/Ian L. McClelland/Bernard Weerdmeester (Hg.), *Usability Evaluation in Industry*, London: Taylor & Francis, S. 189–194.
- Denny, Paul/Prather, James/Becker, Brett A./Finnie-Ansley, James/Hellas, Arto/Leinonen, Juho/Luxton-Reilly, Andrew/Reeves, Brent N./Santos, Eddie Antonio/Sarsa, Sami (2024): »Computing Education in the Era of Generative AI«, in: *Communications of the ACM* 67, S. 56–67.
- Gao, Meiyuzi/Kortum, Philip/Oswald, Frederick L. (2020): »Multi-Language Toolkit for the System Usability Scale«, in: *International Journal of Human-Computer Interaction* 36(20), S. 1883–1901.
- Gao, Yunfan/Xiong, Yun/Gao, Xinyu/Jia, Kangxiang/Pan, Jinliu/Bi, Yuxi/Dai, Yi/Sun, Jiawei/Guo, Qianyu/Wang, Meng/Wang, Haofen (2024): *Retrieval-Augmented Generation for Large Language Models: A Survey*, <https://doi.org/10.48550/arXiv.2312.10997>

- Hattie, John/Timperley, Helen (2007): »The Power of Feedback«, in: *Review of Educational Research* 77, S. 81–112.
- Hellmig, Lutz/Schieckoff, Bentley/Schwarz, Richard/Süßenbach, Felix (2023): *Informatik-Monitor 2023/24: Zur Situation des Informatikunterrichts in Deutschland*, Berlin: Gesellschaft für Informatik e.V, <https://informatik-monitor.de/2023-24>
- Jacobs, Sven/Jaschke, Steffen (2024a): »Evaluating the Application of Large Language Models to Generate Feedback in Programming Education«, in: *2024 IEEE Global Engineering Education Conference (EDUCON)*, S. 1–5, <https://doi.org/10.1109/EDUCON60312.2024.10578838>
- Jacobs, Sven/Jaschke, Steffen (2024b): »Leveraging Lecture Content for Improved Feedback: Explorations with GPT-4 and Retrieval Augmented Generation«, in: *2024 36th International Conference on Software Engineering Education and Training (CSE&T)*, S. 1–5, <https://doi.org/10.1109/CSEET62301.2024.10663001>
- Jacobs, Sven/Peters, Henning/Jaschke, Steffen/Kiesler, Natalie (2025a): »Unlimited Practice Opportunities: Automated Generation of Comprehensive, Personalized Programming Tasks«, in: *Proceedings of the 2025 Conference on Innovation and Technology in Computer Science Education Vol. 1 (ITiCSE)*, <https://doi.org/10.48550/arXiv.2503.11704>
- Jacobs, Sven/Kempf, Maurice/Kiesler, Natalie (2025b): »That’s Not the Feedback I Need! – Student Engagement with Compiler and GenAI Feedback in Tutor-Kai«, Manuskript eingereicht.
- Keuning, Hieke/Jeurig, Johan/Heeren, Bastiaan (2019): »A Systematic Literature Review of Automated Feedback Generation for Programming Exercises«, in: *ACM Transactions on Computing Education* 19, S. 1–43.
- Narciss, Susanne (2006): *Informatives tutorielles Feedback. Entwicklungs- und Evaluationsprinzipien auf der Basis instruktionspsychologischer Erkenntnisse*, Münster: Waxmann.
- OpenAI (2023): *GPT-4 Technical Report*, <https://doi.org/10.48550/arXiv.2303.08774>
- Prather, James/Denny, Paul/Leinonen, Juho/Becker, Brett A./Albluwi, Ibrahim/Craig, Michelle/Keuning, Hieke/Kiesler, Natalie/Kohn, Tobias/Luxton-Reilly, Andrew/MacNeil, Stephen/Petersen, Andrew/Pettit, Raymond/Reeves, Brent N./Savelka, Jaromir (2023): »The Robots Are Here: Navigating the Generative AI Revolution in Computing Education«, in: *Proceedings of the 2023 Working Group Reports on Innovation and Technology in Computer Science Education*, New York: ACM, S. 108–159.

Schulhoff, Sander/Ilie, Michael/Balepur, Nishant/Kahadze, Konstantine/Liu, Amanda/Si, Chenglei/Li, Yinheng/Gupta, Aayush/Han, HyoJung/Schulhoff, Sevien/Dulepet, Pranav Sandeep/Vidyadhara, Saurav/Ki, Dayeon/Agrawal, Sweta/Pham, Chau/Kroiz, Gerson/Li, Feileen/Tao, Hudson/Srivastava, Ashay/Da Costa, Hevander/Gupta, Saloni/Rogers, Megan L./Goncearenco, Inna/Sarli, Giuseppe/Galynker, Igor/Peskoff, Denis/Carpuat, Marine/White, Jules/Anadkat, Shyamal/Hoyle, Alexander/Resnik, Philip (2024): The Prompt Report: A Systematic Survey of Prompting Techniques, <https://doi.org/10.48550/arXiv.2406.06608>

Die Integration generativer KI in die hochschulische Statistiklehre

Eine Untersuchung zur Förderung affektiver und kognitiver Zielgrößen¹

Kim Méliani und Kristina Kögler

Statistik-Veranstaltungen werden in erziehungswissenschaftlichen Studiengängen oft mit erheblichen Vorbehalten besucht. Dies ist größtenteils auf defizitäre Selbstkonzepte, aber auch Unsicherheiten und Wissensdefizite im Umgang mit den statistischen Methoden zurückzuführen. Generative KI bietet zwischenzeitlich große Lernpotenziale und es stellt sich die Frage, inwiefern sich diese in der Statistiklehre gezielt nutzen lassen. Der Beitrag zielt auf die Untersuchung der Wirksamkeit von KI-unterstützter Statistiklehre mittels ChatGPT und bezieht dabei sowohl affektive als auch kognitive Zielgrößen ein. Dabei werden quantitative Daten (N = 72) eines Statistikseminars zur Programmiersoftware R im Masterstudiengang Berufspädagogik der Universität Stuttgart herangezogen. Die Ergebnisse deuten auf signifikante positive Veränderungen des statistikbezogenen Selbstkonzeptes sowie der Statistikangst, aber auch der Wissensentwicklung in der Studierendengruppe hin, die mit generativer KI arbeitete.

The Integration of Generative AI in University-Level Statistics Education – Investigating the Effects on Affective and Cognitive Learning Outcomes

Statistical courses of educational science programs are often attended with considerable reservations, which are largely due to deficient self-concepts as well as uncertainties and knowledge gaps in dealing with statistical methods. In this context, generative AI offers substantial support and learning potential, raising the question to what extent these resources can be strategically utilized in statistics education. This study aims to investigate the effectiveness of AI-supported statistics education using ChatGPT, considering both affective and cognitive outcome measures. For this purpose, quantitative data (N =

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

72) from a statistics seminar on the programming software R in the Master's program in Vocational Education at the University of Stuttgart are used. The results indicate significant positive changes in statistics-related self-concepts and statistics anxiety, as well as knowledge development in the group of students that utilized generative AI.

Einleitung

Die Teilnahme an statistischen Lehrveranstaltungen wird von Studierenden erziehungswissenschaftlicher Studiengänge vielfach mit beträchtlichen Vorbehalten assoziiert. Diese Vorbehalte resultieren in erster Linie aus defizitären Selbstkonzepten sowie erheblichen motivationalen und emotionalen Beeinträchtigungen, welche das Lernverhalten negativ beeinflussen können (vgl. Faber/Drexler/Stappert 2018; Paulitsch 2013: 8; Bandalos/Finney/Geske 2003: 605). Die Ergebnisse empirischer Studien legen nahe, dass Studierende mit einem positiv ausgeprägten Fähigkeitsselbstkonzept über angemessenere Lernstrategien verfügen und dadurch bessere akademische Leistungen erzielen (vgl. Filiz et al. 2020; Eccles/Wigfield 2020; Fenning/May 2013; O'Mara et al. 2006). Zudem zeigen Befunde aus der Leistungsangstforschung, dass vor allem Besorgtheitskognitionen einen negativen Einfluss auf das Lernen und die Leistung ausüben (vgl. von der Embse, et al. 2018; Onwuegbuzie/Wilson 2003). Diese Kognitionen können die Anwendung geeigneter Lernstrategien und damit die akademische Leistung negativ beeinflussen, was den entscheidenden Unterschied zwischen Studierenden mit starkem und schwachem Fähigkeitsselbstkonzept weiter verdeutlicht. Die bereits vorhandene Skepsis der Studierenden gegenüber statistischen Konzepten und Methoden wird durch die zusätzliche Herausforderung, statistische Verfahren unter Zuhilfenahme von programmierbarer Statistik-Software wie R anzuwenden, weiter verstärkt. Mit der fortschreitenden Etablierung von künstlicher Intelligenz (KI) im Kontext von Lehren und Lernen eröffnen sich jedoch neue motivationale und didaktische Potenziale, insbesondere durch den Einsatz generativer KI als Lern- und Übungssystem, um in einer unterstützenden und interaktiven Lernumgebung Ängste abzubauen und Unsicherheiten im Umgang mit statistischen Konzepten zu überwinden (Ogunleye et al. 2024: 2). Der vorliegende Beitrag widmet sich der Frage, ob und inwiefern sich über den Einsatz generativer KI in der Statistiklehre positive Effekte auf die affektiven und kognitiven Outcomes auf Seiten der Studierenden erzielen lassen. Die Datengrundlage entstammt dem Statistik-Kurs »Einführung in die Pro-

grammiersprache R«, welcher an der Universität Stuttgart von Studierenden des Masterstudiengangs »Berufspädagogik und Personalentwicklung« als Pflichtmodul besucht wird. Im Rahmen einer quasi-experimentellen Interventionsstudie mit Experimental- und Kontrollgruppe wurden lehrbegleitend Daten gesammelt, die für die vorgestellten Analysen herangezogen werden.

Aufbau des Lehrkonzepts zur Förderung affektiver wie kognitiver Zielgrößen

Der Kurs »Einführung in die Programmiersprache R« ist ein unbenoteter Pflichtkurs, dessen Inhalt in drei Hauptmodule unterteilt ist: univariate, bivariate und multivariate Statistik. Im Rahmen der Lehrveranstaltung werden in Form von ILIAS-Tests und Skript-Abgaben formative Assessments durchgeführt, um die statistischen Inhalte sowie das Anwendungswissen im Umgang mit der Programmiersprache R formativ zu erfassen. Den Studierenden wird eine einwöchige Bearbeitungszeit eingeräumt, die kooperatives Arbeiten ermöglicht und sie gezielt auf die Anforderungen im Berufsleben vorbereiten soll. Seit dem Wintersemester 2023 wird zusätzlich der lehr- und lernbegleitende Einsatz generativer KI mittels ChatGPT durchgeführt. Hiermit kommt ein neuer Fokus hinzu, nämlich die implizite Förderung von AI Literacy. In mehreren Präsenzterminen wurden Themen wie die Potenziale und Grenzen des Sprachmodells behandelt, um ein kritisches Verständnis der Technologie zu fördern. Anhand konkreter Einsatzbeispiele wurden die Datenaufbereitung und -auswertung sowie das Nachvollziehen von Fehlermeldungen erläutert. Zudem wurde aufgezeigt, wie durch gezieltes Prompting komplexe Grafiken erstellt und durch präzise Input-Informationen die Qualität des Outputs sukzessive verbessert werden können. Im Verlauf des gesamten Semesters hatten Studierende außerdem die Möglichkeit, sich auch außerhalb der Sitzungstermine zu individuellen Anwendungsfällen beraten zu lassen.

Forschungsfragen und Instrumente

Ausgehend von dem skizzierten Lehrkonzept soll die folgende Fragestellung untersucht werden: Wie verändern sich die statistikbezogenen Selbstkonzepte und Wissensgrundlagen der Studierenden im Zeitverlauf mit und ohne Nutzung generativer KI in der Lehrveranstaltung? Zur Beantwortung dieser Fra-

gestellung kann auf Daten einer lehrbegleitenden Untersuchung im Rahmen des Kurses *Einführung in die Programmiersprache R* zurückgegriffen werden. Es stehen teilweise längsschnittliche Daten aus vier Semesterdurchgängen zur Verfügung, die zu Beginn (t_1) als auch am Ende des viermonatigen Semesters (t_2) erhoben wurden. Im Folgenden soll die Frage weiter ausdifferenziert werden, indem zwischen *affektiven* und *kognitiven Dimensionen* von Veränderungen unterschieden wird:

Affektive Ebene: Wie entwickelt sich das *statistische Fähigkeitsselbstkonzept* über das Semester hinweg? Reduziert sich die *Statistikangst* im Laufe des Semesters?

Kognitive Ebene: Wie verändert sich die Selbsteinschätzung *statistischen Wissens* über die Zeit hinweg? Wie schneiden die Studierenden beim *Wissenstest* ab, der am Ende des Semesters vor Ort durchgeführt wird?

Dabei soll genauer betrachtet werden, ob Unterschiede zwischen den Semestern, in denen KI in der Lehre eingesetzt wurde (Experimentalgruppe/EG) und den Semestern ohne KI in der Lehre (Kontrollgruppe/KG), bestehen. Mögliche Störfaktoren, wie parallele Veranstaltungen mit vergleichbaren Inhalten oder unterschiedliche Lehrende, können in diesem Setting ausgeschlossen werden, da die Datenerhebung ausschließlich in Lehrveranstaltungen derselben Dozierenden erfolgte. Zur Messung der Veränderung zwischen den Gruppen sowie über die Zeitpunkte hinweg wurden gemischte Varianzanalysen sowie t -Tests für abhängige und unabhängige Stichproben auf Basis von etablierten Fragebogen- und selbstentwickelten Testinstrumenten berechnet. Das *statistische Fähigkeitsselbstkonzept* wurde in Anlehnung an Marsh und Shavelson (1985) durch vier Items auf einer vierstufigen Likert-Skala erfasst. Die interne Konsistenz der Skala erreichte zu beiden Messzeitpunkten akzeptable Werte $\alpha_{t_1} = 0.76$ und $\alpha_{t_2} = 0.85$. Die *Statistikangst* (Faber/Drexler/Stappert 2018) wurde im Längsschnitt erhoben. Diese wurde mittels 17 Items, unterteilt in die Subdimensionen Besorgtheits-, Vermeidungs- sowie Aufgeregtheitskognitionen, auf einer vierstufigen Likert-Skala gemessen. Die interne Konsistenz der Skala erreichte zu beiden Messzeitpunkten exzellente Werte $\alpha_{t_1/t_2} = 0.95$. Infolge des späteren Einsatzes des Instruments können im Folgenden lediglich für die EG-Gruppe Entwicklungsdaten aufgezeigt werden. Zur Messung des selbst eingeschätzten Statistikwissens wurde eine Skala mit elf selbst konstruierten Items eingesetzt, die sich an den im Laufe des Semesters behandelten Statistikinhalten orientierte, wobei ebenfalls eine vierstufige

Likert-Skala zum Einsatz kam. Die interne Konsistenz der Skala erreichte zu beiden Messzeitpunkten sehr gute Werte $\alpha_{t1} = 0.90$ und $\alpha_{t2} = 0.87$.

Stichprobe und Ergebnisse

Die Gesamtstichprobe umfasst $N = 72$ Studierende, wobei pro Semester etwa 16 bis 20 Studierende vertreten sind. Davon sind $N = 60$ Studierende im Masterstudiengang Berufspädagogik und $N = 12$ Studierende im Masterstudiengang Digital Humanities. Die Auswertung der Stichprobe ergibt, dass 94 % ($N = 68$) der Befragten weiblich sind. Zudem zeigt sich, dass mit 72 % ($N = 50$) die Mehrheit der Studierenden über keine Vorerfahrung mit der R-Software verfügt. In der KG befinden sich das *Wintersemester 2022* und *Sommersemester 2023*, in der EG das *Wintersemester 2023* und das *Sommersemester 2024*. Zu Beginn des Semesters wurden die Studierenden gebeten eine Gesamteinschätzung (Note 1 bis Note 5) ihrer bisherigen Leistung in zuvor besuchten Statistik-Kursen abzugeben. Dabei fällt auf, dass die Studierenden der EG ihre eigene Leistung tendenziell schlechter beurteilen ($MW_{KG} = 3.36$ (1.09), $MW_{EG} = 3.71$ (1.01)), die Unterschiede sind jedoch nicht signifikant.

Veränderung des statistikbezogenen Selbstkonzepts

Die Studierenden aus der KG wiesen bereits zu Semesterbeginn einen relativ hohen, positiven Wert auf, wobei zwischen den beiden Messzeitpunkten lediglich eine minimale Veränderung zu verzeichnen ist ($MW_{t1} = 2.59$ (.68); $MW_{t2} = 2.63$ (.75)). In der EG-Gruppe zeigt sich hingegen eine tendenziell positivere Entwicklung ($MW_{t1} = 2.38$ (.59); $MW_{t2} = 2.63$ (.68)).

Dies wird insbesondere durch die Datenverläufe ersichtlich (vgl. Abb. 1), welche eine ausgeprägtere Verbesserung über die Zeit andeuten. Trotz dieser tendenziellen Steigerung blieb das Ergebnis der Varianzanalyse knapp über der Signifikanzgrenze ($p = .059$), was auf die geringe Stichprobengröße ($N \sim 30$) in den Subgruppen zurückgeführt werden könnte. Die Entwicklung der Statistikangst, hier dargestellt durch den Summenscore (vgl. Abb. 2), verdeutlicht, dass diese im Verlauf des Semesters hoch signifikant ($p < .001$) reduziert wurde ($MW_{t1} = 41$ (12.8); $MW_{t2} = 35.3$ (11.8)). Die berechnete Effektstärke nach Cohen ($d = 0.61$) deutet auf einen mittleren Effekt hin.

Abb. 1: Entwicklung des statistischen Fähigkeits-selbstkonzepts





Abb. 2: Entwicklung der Statistikangst (EG)



Veränderung der statistikbezogenen Kompetenzen

In beiden Gruppen kann eine signifikante Verbesserung der Selbsteinschätzung über das Semester hinweg verzeichnet werden (KG : $MW_{t1} = 2.25$ (.68); $MW_{t2} = 3.26$ (.49); EG : $MW_{t1} = 2.31$ (.74); $MW_{t2} = 3.29$ (.54). Die Ergebnisse der Varianzanalyse weisen auf einen hochsignifikanten Unterschied hin ($p < .001$), wobei die Effektstärke durch das partielle Eta-Quadrat ($\eta^2 = .73$) als sehr groß bezeichnet werden kann. An den Datenverläufen ist in beiden Gruppen eine mehrheitlich positive Entwicklung erkennbar (vgl. Abb. 3).

Als Gegenstück zu den formativen Studienleistungen, in denen die Studierenden über einen längeren Bearbeitungszeitraum die Möglichkeit haben, sich mit den Inhalten auseinanderzusetzen, findet zum Ende des Semesters in der Abschlussitzung ein Wissenstest statt, der zentrale Inhalte des Semesters in acht Fragen erfasst. Der Test wird in ILIAS als E-Prüfung durchgeführt und umfasst fünf statistikbezogene sowie drei R-bezogene Fragen. Die Testergebnisse (Abb. 4) ermöglichen hierbei eine objektive und vor allem individuelle Leistungsbeurteilung, da keine Hilfsmittel vorgesehen sind. Die Ergebnisse des t-Tests weisen für die EG-Gruppe eine signifikant höhere Test-Lösungsquote auf als für die KG-Gruppe ($MW_{EG} = .76$ (.15); $MW_{KG} = .64$ (.18)). Die Effektstärke nach Cohen ($d = 0.73$) lässt auf einen Effekt mittlerer Größe schließen.

Abb. 3: Entwicklung der Selbsteinschätzung statistischer Kenntnisse





Abb. 4: Lösungsquote im Wissenstest zu Semesterende (t2)



Diskussion

In der Gesamtschau lässt sich eine positive Veränderung des statistikbezogenen Selbstkonzepts, der Statistikangst sowie des Statistikwissens feststellen. Diese Entwicklung ist insbesondere bei den Studierenden der EG zu beobachten, die in allen Aspekten eine tendenziell günstigere Entwicklung aufweisen. Der gezielte Einsatz generativer KI kann offenbar unterstützend für den Lehr- und Lernprozess wirken und positive Effekte auf den Lernerfolg zeitigen. Diese Entwicklung kann möglicherweise auf verschiedene Einflussfaktoren zurückgeführt werden: Der Chatbot ist 24/7 verfügbar, wodurch Studierende jederzeit auf Unterstützung zurückgreifen können. Die Fehlermeldungen des Statistikprogramms R wirkten sich häufig negativ auf die Studierenden aus: Die schnelle Bearbeitung und das sofortige Feedback, die durch den Einsatz von ChatGPT möglich sind, bieten einen deutlichen Zeitvorteil und tragen höchstwahrscheinlich zur Minderung dieser negativen Effekte bei. Ferner entfällt die soziale Bewertung im Lernprozess, was insbesondere im Kontext der 1:1-Interaktion einen geschützten Raum schafft, in dem Studierende Fragen stellen und experimentieren können. Schließlich führt die Möglichkeit, komplexere R-Grafiken mit Unterstützung der KI zu erstellen, zu positiven Selbstwirksamkeitserfahrungen. Die Studierenden gewinnen

dadurch Vertrauen in ihre eigenen Fähigkeiten, auch komplexe Aufgaben erfolgreich zu bewältigen. Es scheint zudem möglich, dass der Einsatz von KI einen Beitrag zur Reduktion von Besorgnis und Vermeidungstendenzen leisten könnte, die nach Faber et al. (2018) oft im Zusammenhang mit Statistikangst stehen. Studierende erleben weniger kognitive Überforderung, da sie durch die KI-gestützte Unterstützung gezielt und individuell mit den Inhalten interagieren können. Abschließend ist noch wichtig zu betonen, dass ein statistisches Grundlagenwissen für eine sinnvolle KI-Nutzung erforderlich ist. Andernfalls besteht die Gefahr, dass die ausschließliche Nutzung von KI zu einem *Deskilling* führt (siehe hierzu Reinmann 2023). Nur durch eine kritische und reflektierte Auseinandersetzung mit den Inhalten können langfristig Kompetenzen entwickelt werden, die sowohl das Wissen als auch das Fähigkeitsselbstkonzept stärken.

Literatur

- Bandalos, Deborah L./Finney, Sara J./Geske, Jenenne A. (2003): »A model of statistics performance based on achievement goal theory«, in: *Journal of Educational Psychology*, 95(3), S. 604–616.
- Eccles, Jacquelynn S./Wigfield, Allan (2020): »From expectancy-value theory to situated expectancy-value theory: A developmental, social cognitive, and socio-cultural perspective on motivation«, in: *Contemporary Educational Psychology*, 61.
- Faber, Günter/Drexler, Heike/Stappert, Alexander (2018): »BEVAST-EWL. Skala zu studentischen Besorgtheits-, Vermeidungs- und Aufregetheitskognitionen bezüglich statistischer Anforderungen in erziehungswissenschaftlichen Lehr-Lern-Kontexten«, in: *Leibniz-Zentrum für Psychologische Information und Dokumentation ZPID*, Hg. (Elektronisches Testarchiv).
- Fenning, Breanne E./May, Laura Negel (2013): »Where there is a will, there is an A: examining the roles of self-efficacy and self-concept in college students' current educational attainment and career planning«, in: *Social Psychology of Education*, 16(4), S. 635–650.
- Filiz, Mehmet/Early, Erin/Thurston, Allen/Miller, Sarah (2020): »Measuring and improving university students' statistics self-concept: A systematic review«, in: *International Journal of Educational Research Open*, 1, Article 100020. <https://doi.org/10.1016/j.ijedro.2020.100020>.

- Marsh, Herb/Shavelson, Richard (1985): »Self-concept: Its multifaceted, hierarchical structure«, in: *Educational Psychologist*, 20(3), S. 107–123.
- O'Mara, Alison/Marsh, Herb/Craven, Rhonda G./Debus, Raymond L. (2006): »Do self-concept interventions make a difference? A synergistic blend of construct validation and meta-analysis«, in: *Educational Psychologist*, 41(3), S. 181–206.
- Ogunleye, Bayode/Zakariyyah, Kudirat Ibilola/Ajao, Oluwaseuna/Olayinka, Olakunle/Sharma, Hemlata (2024): »A systematic review of generative AI for teaching and learning practice«, in: *Education Sciences*, 14(6), S. 636. <https://doi.org/10.3390/educsci14060636> vom 28.09.2024.
- Onwuegbuzie, Anthony J./Wilson, Vicki A. (2003): »Statistics anxiety: Nature, etiology, antecedents, effects and treatments – a comprehensive review of the literature«, in: *Teaching in Higher Education*, 8, S. 195–209.
- Paulitsch, Kerstin (2013): »Ich kann Statistik!« Zum Zusammenhang von Selbstwirksamkeit, Gedächtnisabruf und elektrokortikaler Aktivierung im Bereich der psychologischen Statistik. Diplomarbeit, Karl-Franzens-Universität Graz, Graz.
- R Core Team (2024): R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>.
- Reinmann, Gaby (2023): Deskillung durch Künstliche Intelligenz? Potenzielle Kompetenzverluste als Herausforderung für die Hochschuldidaktik (= Diskussionspapier Nr. 25), Hochschulforum Digitalisierung. https://hochschulforumdigitalisierung.de/sites/default/files/dateien/HFD_DP_25_Deskillung.pdf vom 28.09.2024.
- von der Embse, Nathaniel/Jester, Dane/Roy, Devlina/Post, James (2018): »Test anxiety effects, predictors, and correlates: A 30-year metaanalytic review«, in: *Journal of Affective Disorders*, 227, S. 483–493. <https://doi.org/10.1016/j.jad.2017.11.048> vom 28.09.2024.

Generative KI-Tools in der Lehrkräftebildung

Themenschwerpunkte einer anwendungsorientierten Lehrveranstaltung¹

Johannes Schäfers²

Mit dem Aufkommen von Large Language Modellen und der dahinterstehenden generativen Künstlichen Intelligenz (KI) wurde ein Paradigmenwechsel eingeläutet, der besonders Auswirkungen auf den Bildungsbereich mit sich zieht. Sowohl der frühzeitige Einbezug von KI als auch die damit verbundene Kompetenzförderung ist unabdingbar, um angehende Lehrkräfte auf diese Herausforderungen vorzubereiten, indem sie sich mit Risiken beschäftigen und gemeinsam über Handlungsempfehlungen nachdenken. Ziel der in diesem Beitrag behandelten Lehrveranstaltung war es, Seminarinhalte auszumachen, die Studierende auf den Einsatz und Einbezug generativer KI in Arbeit, Beruf und Bildung vorbereiten und deren Kompetenzen durch realistische Einsatzszenarien und Anwendungsbezüge fördern sollte. Im Zentrum dieses Beitrags steht daher die Frage, welche Themenschwerpunkte es benötigt, um angehenden Lehrkräften einen Einstieg in das Thema KI zu geben und auf den Umgang mit KI-Tools in der Praxis vorzubereiten.

Generative AI tools in the use of teacher training – main topics of an application-oriented course

The emergence of large language models and the generative artificial intelligence (AI) behind them has heralded a paradigm shift that will have a particular impact on the education sector. Both the early inclusion of AI and the associated skills development are essential in order to prepare prospective teachers for these challenges by dealing with risks and thinking together about recommendations for action. The aim of the course discussed in this article was to identify seminar content that would prepare students for the use and incorporation of generative AI in work, careers and education and promote

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

2 ORCID-ID: 0009-0007-7071-0947

their skills through realistic application scenarios and application references. This article therefore centres on the question of which key topics are needed to give prospective teachers an introduction to the topic of AI and prepare them for working with AI tools in practice.

Einleitung

Um der steigenden Nachfrage und dem Bedarf nach einer grundlegenden Lehrveranstaltung zum Thema KI in der ersten Phase der Hamburger Lehrkräftebildung gerecht zu werden, wurde zum Wintersemester 2023/24 das Seminar »KI-Tools in Arbeit, Beruf und Bildung« an der Technischen Universität Hamburg (TUHH) vom Institut für Berufliche Bildung und Digitalisierung entwickelt und zum ersten Mal angeboten. Auch wenn es schon zuvor einzelne Angebote und Möglichkeiten innerhalb weiterer Lehrveranstaltungen u.a. an der TUHH gab, KI miteinzubeziehen und einzelne KI-Tools anzuwenden, lag bislang kein direkter Schwerpunkt auf der grundlegenden An- und Verwendung von KI. Diese Lücke wurde mit diesem Seminar geschlossen, indem darin besonders auf das Bewusstsein für die Möglichkeiten und Grenzen von KI in Arbeit, Beruf und Bildung abgezielt wurde.

Lehrveranstaltungsplanung

Bevor eine genaue Festlegung der Themenschwerpunkte des Seminars stattfinden konnte, mussten zuvor die Rahmenbedingungen ausgemacht werden auf die sich die Lehrveranstaltung beziehen sollte. Dies waren zum einen die teilnehmenden Lehramtsstudierenden als Zielgruppe dieses Seminars, die groben Lernziele, die mit dieser Lehrveranstaltung erreicht werden sollten und die Festlegung der Studien- und Prüfungsleistungen, die ebenfalls einen praxisorientierten Anwendungsbezug innehaben sollten.

Studierendenzusammensetzung

Durch das große Interesse und die breite Öffnung des Seminars konnten sowohl Lehramtsstudierende der TUHH wie auch der Universität Hamburg (UHH) an diesem Seminar teilnehmen. Die Teilnehmer*innenzahl wurde auf 30 Personen begrenzt, um ein möglichst anwendungsbezogenes Seminar zu

gewährleisten und die Studierenden bestmöglich persönlich begleiten und betreuen zu können.

Die Studierenden stammten somit aus folgenden Studiengängen:

- Lehramt für die Sekundarstufe I und II (B.Ed.): 3 Studierende
- Lehramt an berufsbildenden Schulen (M.Ed.): 12 Studierende
- Lehramt der Primar- und Sekundarstufe I (M.Ed.): 3 Studierende
- Lehramt für Sonderpädagogik (M.Ed.): 6 Studierende

Die teilnehmenden Studierenden (n=24) kamen dabei aus dem 1., 3., 5. und 7. Semester, was zu einer zusätzlichen stark heterogenen Studierendenschaft in diesem Seminar beitrug. Dabei herrscht im beruflichen Lehramt ohnehin eine starke Heterogenität (vgl. Gillen et al. 2021), die sich aufgrund der verschiedenen berufsbiografischen Hintergründe und des zum Teil starken Altersunterschieds der Studierenden – in diesem Seminar zwischen 21 und 38 Jahren – noch stärker bemerkbar machte. Auch die Vorerfahrungen der Studierenden im Umgang mit KI schwankten stark, was in diesem Seminar besonders berücksichtigt werden musste. Besaßen knapp 61 % bereits erste Erfahrungen, setzten 39 % der Lehramtsstudierenden noch nie KI oder generative KI-Tools im privaten oder beruflichen Kontext, einschließlich dem Studium, vor dem Besuch des Seminars ein.

Anwendungsbezogene Lernziele

Aufbauend auf den benannten Zielen, die Lehramtsstudierenden auf den Einsatz und Einbezug generativer KI in der Praxis vorzubereiten und deren digitalisierungsbezogenen Kompetenzen durch realistische Einsatzszenarien und Anwendungsbezüge mit KI zu fördern, wurden übergeordnete und anwendungsbezogene Lernziele formuliert, die gleichzeitig die stark heterogene Studierendenzusammensetzung dieses Seminars berücksichtigen sollte. Somit stellten sich die groben Lernziele wie folgt dar:

Die Studierenden sollen nach Besuch des Seminars...

1. die zugrundeliegende Entstehungsgeschichte von KI und deren aktuelle Anwendungsbezüge im schulischen Bildungsbereich definieren und erläutern können.

2. basierend auf wissenschaftlich empirischen Grundlagen und aktuellen Anwendungsbezügen zum Thema KI im schulischen Bildungsbereich mit anderen Personen diskutieren können.
3. Anwendungsbezüge von KI-Tools im schulischen Bildungsbereich benennen, einbeziehen, präsentieren aber auch weitere Anwendungsbezüge selbstständig herleiten können.
4. den eigenen Einsatz von KI-Tools im schulischen Bildungsbereich kritisch reflektieren können.
5. KI-Tools zukünftig für alltägliche Arbeitsaufgaben und schulspezifische Bildungsbereiche eigenständig einsetzen können.

Studien- und Prüfungsleistungen

Der praxisorientierte Anwendungsbezug sollte auch bei den Studien- und Prüfungsleistungen einbezogen werden. Dabei bestand die Studienleistung aus zwei Teilen: Zum einen wurden die Studierenden dazu aufgefordert, einen Steckbrief zu einem von ihnen ausgewählten oder vorgeschlagenen KI-Tool mit vorbestimmten Angaben, wie z.B. den Kosten zur Nutzung des KI-Tools, auf einer digitalen Pinnwand zusammenzutragen sowie für die anderen Studierenden bereitzustellen. Der andere Studienleistungsteil bestand aus einem selbst verfassten Abstract über eine exemplarische Verwendung des jeweiligen KI-Tools der Studierenden aus ihrem Lehramtsbereich. Diese Abstracts wurden am Ende des Semesters gesammelt und als »Book of Abstracts« allen Studierenden unter der freien Lizenz »CC-BY-SA 4.0« zur Verfügung gestellt. Sofern eine benotete Prüfungsleistung von den Studierenden gewünscht wurde, konnte diese zu Beginn der vorlesungsfreien Zeit als mündliche Einzelprüfung mit der Reflexion und Verteidigung eines Thesenpapiers abgelegt werden. Dabei erhielten die Studierenden innerhalb der 30-minütigen Prüfungen die Möglichkeit zwei kritische Thesen zu ihrem Lehramtsbereich und zum Seminarthema KI sowie eine übergeordnete These zum Rahmenthema der Lehrveranstaltung »KI-Tools in Arbeit, Beruf und Bildung« mit wissenschaftlicher Literatur zu belegen oder zu widerlegen. Darüber hinaus wurden den Studierenden zu den jeweilig gewählten Themenschwerpunkten auch kritische Nachfragen zu den Inhalten des Seminars gestellt.

Themenschwerpunkte der Lehrveranstaltung

Unter Berücksichtigung der genannten Lehrveranstaltungsplanung und mit der Unterstützung von wissenschaftlichen Gastvortragenden konnte mit der Festlegung der Themenschwerpunkte dieser Veranstaltung begonnen werden. Aufgrund der zum Teil geringen Vorerfahrungen der teilnehmenden Studierenden mit KI und dem Einstieg in dieses Themenfeld bestand die erste Sitzung aus einer grundlegenden *Einführung in das Thema KI*. Hierbei wurden erste technische Grundlagen zu KI sowie die geschichtliche Entwicklung von den 1950er Jahren u.a. über den Turing-Test (vgl. Schmidhuber 2015; Turing 2009) bis hin zum 2017 entwickelten Transformer-Modell (vgl. Vaswani et al. 2017) und der heutigen vielfältig eingesetzten Large Language Modelle (LLM) erläutert. Durch das Aufzeigen erster *KI-Anwendungsbereiche* im Bildungsbereich, z.B. den Möglichkeiten von Learning Analytics (vgl. Zawacki-Richter et al. 2019), konnten Beispiele abgebildet werden, wie und wo KI die (angehenden) Lehrkräfte schon heute z.B. über KI-gestützte Lernplattformen unterstützen kann (vgl. Schäfers 2024b). Einen weiteren besonderen Themenschwerpunkt stellte das Thema *Prompt Engineering* dar. Die Studierenden erhielten über einen Gastvortrag eines wissenschaftlichen Mitarbeiters der TUHH anfänglich einen direkten Einblick in erste empirische Untersuchungen generativer KI, was daraufhin für Formulierungs- und Verbesserungsversuche und einem besseren Kennenlernen durch Learning by Doing (vgl. Schäfers 2024a) der ausgewählten KI-Tools genutzt wurde. Durch das erfolgreiche Testen von KI-Tools sowie das kritische Hinterfragen und Reflektieren der angezeigten Ergebnisse im Rahmen des Themenschwerpunkts *Generative KI in Text und Bild* wurde bei den Lehramtsstudierenden ein Reflexionsprozess angestoßen. Dieser soll sie befähigen, zukünftig KI-generierte Inhalte eigenständig zu erkennen, zu prüfen und kritisch zu hinterfragen. Da es in dieser Lehrveranstaltung besonders um den Einsatz von *KI in Schule, Ausbildung und Studium* gehen sollte, wurden neben weiteren Anwendungsbeispielen z.B. der Hybridisierung der Lehre mit Hilfe von KI (vgl. Schäfers 2023) auch Kompetenzfelder und -dimensionen von den Studierenden selbstständig recherchiert, zusammengetragen und herausgearbeitet, die es u.a. für die Anwendung von KI im Kontext von Arbeit benötigt (vgl. u.a. Wienrich et al. 2022). Darüber hinaus sollten sich die Studierenden auch über die *Gesellschaftlichen & ethischen Implikationen von KI* bewusst werden. Hierfür wurde u.a. der stark gestiegene Wasserverbrauch großer Technologieunternehmen – bedingt durch die Kühlung von Grafikkarten – mit dem Wasserverbrauch

früherer Jahre verglichen (vgl. Holland 2023; Li et al. 2023). Dies unterstreicht ebenfalls die Bedeutung eines verantwortungsvollen und bewussten Umgangs mit KI. Auch hier wurde ein wissenschaftlicher Mitarbeiter der TUHH eingeladen, der einen Gastvortrag zu diesem Themenschwerpunkt hielt. Da für die derzeitigen Lehramtsstudierenden und Lehrkräfte von morgen über die Eingabe von z.B. Schülerinnen- und Schülerdaten ein datenschutzrechtliches Risiko besteht, wurden die Studierenden über *Hinweise zum Datenschutz & KI* aufgeklärt, wozu auch die Handreichung der TUHH »KI-Tools in Studium und Lehre« (Baumhauer et al. 2023) hinzugezogen wurde. Abgeschlossen wurde das Seminar mit einer breit angelegten *Diskussion zu KI* und einem damit verbundenen Rollenspiel, welches die verschiedenen Themenschwerpunkte noch einmal in einem fiktiven Szenario beleuchtete. Somit stellten sich die Themenschwerpunkte der Lehrveranstaltung wie folgt dar:

1. Einführung in das Thema KI
2. KI-Anwendungsbereiche (z.B. für Unterrichtsanwendungen)
3. Prompt Engineering (Gastvortrag)
4. Generative KI in Text & Bild
5. KI in Schule, Ausbildung & Studium
6. Gesellschaftliche & ethische Implikationen (Gastvortrag)
7. Hinweise zum Datenschutz & KI
8. Diskussion zum Themenfeld KI

Umfrageergebnisse der Studierenden

Zur Überprüfung der Wirksamkeit der Themenschwerpunkte und Seminarinhalte wurden die Lehramtsstudierenden gebeten, an zwei anonymen Umfragen über kurze Fragebögen teilzunehmen und ihre Kompetenzen im Umgang mit KI darin selbst einzuschätzen und zu reflektieren. Hierzu kamen digitale Umfragen zu Beginn und zum Ende des Wintersemesters 2023/24 zum Einsatz. Aufgrund der sehr unterschiedlichen Vorerfahrungen der Studierenden im Umgang mit KI, wichen auch die Umfrageergebnisse der Studierenden zu Beginn des Seminars stark voneinander ab. So schätzten die Studierenden ihre eigenen Kompetenzen über den hinzugezogenen Reflexionsfragebogen im

Umgang mit KI im Durchschnitt als eher ausreichend (Mittelwert 3,82/5³) ein. Ein besonderes Interesse bestand zu diesem Zeitpunkt an den Themenschwerpunkten *Einführung in das Thema KI, KI-Anwendungsbereiche* und *KI in Schule, Ausbildung und Studium*. Im Verlauf des Semesters veränderten sich die Umfrageergebnisse der Studierenden deutlich. So gaben am Ende des Seminars alle Studierenden an, dass sie zukünftig auch nach dem Seminar KI und KI-Tools noch weiter einsetzen möchten. Auch die Selbsteinschätzungen der eigenen Kompetenzen im Umgang mit KI verbesserte sich im Durchschnitt auf eher gut (Mittelwert 2,22/5). Besonders informativ wurden zum Ende des Seminars die drei bereits oben benannten Themenschwerpunkte bewertet. Zudem wurden die Gastvorträge von den Studierenden besonders positiv hervorgehoben, welche laut der Studierendenaussagen für eine sehr gute Abwechslung im Seminar sorgten.

Fazit & Ausblick

Zusammenfassend kann festgehalten werden, dass die gewählten Themenschwerpunkte zu einem stärkeren Interesse, Verständnis und insgesamt zu einer Förderung der Kompetenzen im Umgang mit KI-Tools der teilnehmenden Lehramtsstudierenden beigetragen haben. Gleichzeitig beruhen die Umfrageergebnisse jedoch auch auf den freiwilligen und selbstständigen Angaben der Studierenden. Für eine genauere Überprüfung der Kompetenzförderung bei den Studierenden bedarf es weiteren und tiefergehenden Untersuchungen. Dennoch kann aus den Ergebnissen der Lehramtsstudierenden ein stärkeres Bewusstsein für die Möglichkeiten und Grenzen von KI in Arbeit, Beruf und Bildung abgelesen werden. Darauf weisen auch die Studien- und Prüfungsleistungsergebnisse hin, die alle samt positiv bewertet werden konnten. Obwohl sich dieser Beitrag aufgrund des Schwerpunkts auf die Förderung von KI-Kompetenzen in der Lehrkräfteausbildung vorrangig an Lehramtsstudierende, Dozierende, Referendar*innen, Seminarleitende sowie Lehrkräfte und Schulpersonal in den drei Phasen der Lehrkräftebildung richtet, lassen sich die behandelten Themenschwerpunkte auch auf andere Studiengänge übertragen. Die dargestellten Inhalte bieten primär einen

3 Die Skala der Selbsteinschätzung ging hierbei von »1« für »sehr gute Kompetenzen im Umgang mit KI« bis hin zu »5« für »mangelhafte Kompetenzen im Umgang mit KI«.

Einstieg in das Thema KI und maschinelles Lernen. Für eine vertiefte Auseinandersetzung mit spezifischen Aspekten sind jedoch stärker fachbezogene Hintergründe und darauf abgestimmte Kerninhalte erforderlich.

Literatur

- Baumhauer, M.; Bulmann, U. & Wartolla, A. (2023). KI-Tools in Studium und Lehre: Handreichung der TU Hamburg.
- Hochreiter, S. & Schmidhuber, J. (1997). Long Short-Term Memory. In: *Neural Computation*. 9. Jahrgang, Nr. 8, ISSN 0899-7667, S. 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>, PMID 9377276.
- Gillen, J.; Michele, J.; Schäfers, J.; Steuber, A. & Wende, J. (2021). Digitalisierung als Chance für eine diversitätssensible Hochschullehre im Rahmen berufs- und wirtschaftspädagogischer Studiengänge? In: *bwp@ Berufs- und Wirtschaftspädagogik – online*, Ausgabe 40, 1-22. Online unter: www.bwpat.de/ausgabe40/gillen_etal_bwpat40.pdf (Zugriff am: 09.08.2024).
- Holland, M. (2023). Wohl wegen ChatGPT: Wasserverbrauch von Microsoft 2022 um ein Drittel gestiegen. *heise online*. Verfügbar unter: <https://www.heise.de/news/Wohl-wegen-ChatGPT-Wasserverbrauch-von-Microsoft-2022-um-ein-Drittel-gestiegen-9300486.html> (Zugriff am: 10.02.2024).
- Kühl, E. (2022). Künstliche Intelligenz: Klimahelfer oder Klimasünder? *Die Zeit*. Verfügbar unter: <https://www.zeit.de/digital/internet/2022-07/kuenstliche-intelligenz-klimaschutz-energieverbrauch/komplettansicht> (Zugriff am: 10.02.2024).
- Li, P.; Yang, J.; Islam, M. A. & Ren, S. (2023). Making AI Less »Thirsty«: Uncovering and Addressing the Secret Water Footprint of AI Models. <https://doi.org/10.48550/arXiv.2304.03271>.
- Schäfers, J. (2023). Förderung digitaler Medienkompetenzen von heterogenen beruflichen Lehramtsstudierendengruppen mithilfe eines hybriden Seminarkonzepts. In: Ahlers, M.; Besser, M.; Herzog, C. & Kuhl, P. (Hg.): *Digitales Lehren und Lernen im Fachunterricht*. Weinheim: Beltz Juventa.
- Schäfers, J. (2024a). Medienkompetenz durch »Learning by Doing«? – Erste Untersuchungsergebnisse einer qualitativen Kompetenzanalyse am Beispiel leitfadengestützter Interviews. *Medienpädagogik: Zeitschrift für Theorie Und Praxis Der Medienbildung* 58 (JFMH2023): 13-22. <https://doi.org/10.21240/mpaed/58/2024.03.22.X>.

- Schäfers, J. (2024b). KI-gestützte Lernplattformen in der beruflichen Bildung – Bestandsaufnahme und Zukunftspotenziale. In: Jenewein, K.; Vollmer, T.; Karges, T.; Reichwein, W.; Richter-Honsbrock, T. & Schütt-Sayed, S. (Hg.). *Transformation und Digitalisierung. Neues berufliches Lehren und Lernen*. Bielefeld: wbv Publikation. <https://doi.org/10.3278/9783763974368>.
- Schmidhuber, J. (2015). Deep Learning in Neural Networks: An Overview. *Neural Networks*, 61, 85–117.
- Turing, A.M. (2009). Computing Machinery and Intelligence. In: Epstein, R.; Roberts, G. & Beber, G. (Hg.). *Parsing the Turing Test*. Springer, Dordrecht. https://doi.org/10.1007/978-1-4020-6710-5_3.
- Vaswani, A.; Shazeer, N.; Parmar, N.; Uszkoreit, J.; Jones, L.; Gomez, A.; Kaiser, L. & Polosukhin, I. (2017). »Attention is all you need«. *Advances in neural information processing systems*, Vol. 30.
- Wienrich, C.; Carolus, A.; Markus, A. & Augustin, Y. (2022). AI Literacy: Kompetenzdimensionen und Einflussfaktoren im Kontext von Arbeit. Denkfabrik-bmas.de. Verfügbar unter: https://www.denkfabrikbmas.de/fileadmin/Downloads/Publikationen/AI_Literacy_Kompetenzdimensionen_und_Einflussfaktoren_im_Kontext_von_Arbeit.pdf (Zugriff am: 10.02.2024).
- 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, S. 1–27. <https://doi.org/10.1186/s41239-019-0171-0>.

Beyond AI literacy

Universitäre transdisziplinäre KI-Ausbildung im Projekt BNTrAInee¹

Elena Trunz, Matthias Carl Laupichler und Reinhard Klein

*In unserem Projekt wird die KI-Expertise der Informatik mit anderen Disziplinen durch gemeinsame Projekte und bedarfsorientierte Lehrangebote vernetzt. Studierende der Informatik bearbeiten in Projektgruppen und Abschlussarbeiten Forschungsfragen aus den Fachdisziplinen, für deren KI-Anwendungen dort Ressourcen und Expertise fehlen. Die Doppelbetreuung durch Informatik- und Fachdisziplin-Expert*innen stellt sicher, dass die Arbeiten aufaktuellem Forschungsniveau erfolgen und als Grundlage für zukünftige Drittmittelprojekte dienen. Gleichzeitig lernen die Informatikstudierenden transdisziplinäre Ansätze kennen. Um die KI-Kompetenz der Forschenden zu erweitern, bieten wir Kurse an, die praxisorientiertes Wissen vermitteln. Der Schwerpunkt liegt dabei auf der Modifikation und Implementierung von Software durch betreute Programmieraufgaben, die auf unterschiedliche Zielgruppen zugeschnitten sind. Im Folgenden stellen wir das Konzept, Evaluationsergebnisse und Praxiserfahrungen vor.*

Beyond AI literacy: University-based transdisciplinary AI training program in the BNTrAInee project

In our project, the AI expertise of the Department of Computer Science is linked to other disciplines through collaborative projects and demand-driven teaching. Computer science students work in project groups and on theses on research questions from various areas where resources and expertise for AI applications are lacking. Dual supervision by experts from both computer science and the relevant disciplines ensures that the work is carried out at the cutting edge of research and serves as a basis for future projects funded by third parties. At the same time, computer science students will gain insight into transdisciplinary approaches. To enhance the AI skills of researchers, we offer courses

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

that focus on practical knowledge, with an emphasis on modifying and implementing software through supervised programming tasks, tailored to different target groups. In the presentation we will outline the project concept, evaluation results and practical experience.

Einleitung

KI-Bildung gewinnt auch an Universitäten und Hochschulen zunehmend an Bedeutung (Kandlhofer et al. 2016, Laupichler et al. 2022). Doch Studierende bringen unterschiedliche Vorkenntnisse mit: Informatikstudierende haben oft praktische KI-Erfahrung, aber wenig transdisziplinäre Zusammenarbeit, während Studierende anderer Disziplinen KI-Potenzial erkennen (Wood/Ange/Miller 2021, Laupichler et al. 2024a), aber meist keine Programmiererfahrung besitzen. Viele Lehrprojekte fokussieren auf grundlegende KI-Kompetenzen (AI literacy, Long/Magerko 2020), vernachlässigen aber fortgeschrittene Studierende, die bereits über erste Kenntnisse im Bereich der KI verfügen und diese gezielt einsetzen möchten (AI proficiency) oder Studierende, die bereits eine breite KI-Kompetenz erworben haben (AI expertise, Schüller et al. 2023). Es braucht daher neue Ansätze, die Anfänger*innen und Fortgeschrittene gleichermaßen fördern.

Unser Projekt BNTrAInee (Bonn transdisziplinäre Ausbildung in künstlicher Intelligenz) vernetzt die Informatik-Expertise mit den Anforderungen anderer Disziplinen. Informatikstudierende sammeln Praxiserfahrung in der Zusammenarbeit mit Fachvertreter*innen, während diese lernen, KI zur Datenanalyse zu nutzen. Die beiden zentralen Säulen von BNTrAInee sind: 1. Kurse für fortgeschrittene Studierende aus nicht-informatischen Disziplinen, in denen sie die Grundlagen der KI-Programmierung erlernen. 2. Projektgruppen, in denen Studierende der Informatik konkrete Probleme aus anderen Disziplinen mit Hilfe von KI lösen.

Säule 1: Entwicklung von Kursen für (fortgeschrittene) Studierende anderer Fachdisziplinen

Theoretischer Hintergrund

Im Rahmen der Future Skills-Bewegung wurde bereits vor einigen Jahren postuliert, dass »Digitalkompetenz« eine essenzielle Individualkompetenz des 21. Jahrhunderts darstellt (Ehlers, 2020). Spätestens seit dem Aufkommen und der intensiven Nutzung von Large Language Models wie OpenAI's ChatGPT durch KI-Laien wird deutlich, dass alle Menschen unabhängig von ihrer beruflichen oder akademischen Ausrichtung eine grundlegende KI-Kompetenz (AI literacy) erwerben sollten (European Commission, 2023, Act 4b). Darüber hinaus besteht in vielen Fachdisziplinen ein erheblicher Bedarf, Nachwuchswissenschaftler*innen und leitende Forscher*innen in der Anwendung von KI-Methoden zu schulen, um ihre KI-Kompetenz zu erhöhen. Dies ist besonders relevant, da Disziplinen wie beispielsweise Medizin, Bildungswissenschaften und Ingenieurwesen zunehmend auf KI-Anwendungen setzen. Auch wenn Programmierkenntnisse in diesen Fächern oft keine Kernkompetenz darstellen, ist ein fundiertes Anwendungswissen unabdingbar (Laupichler et al., 2024; Sperling et al., 2024; Schleiss et al., 2022). Eine erhöhte AI proficiency fördert die effiziente Zusammenarbeit zwischen Informatiker*innen und Fachexpert*innen. Schüller et al. (2023) beschreiben diesen Zwischenbereich als »Skilled User« – Personen, die Daten und KI kompetent und verantwortungsvoll nutzen, einschließlich der Fähigkeiten, Daten zu sammeln, zu verwalten und zu analysieren.

Vorgehen & Curriculare Struktur

Um die AI literacy und insbesondere die AI proficiency von Studierenden verschiedener Fachrichtungen zu erhöhen, wurde ein dreiwöchiger Intensivkurs »Foundations of Machine Learning in Python« entwickelt, der zentrale Kompetenzen in Data Science, klassischem maschinellen Lernen und Deep Learning fördert. Der stark nachgefragte Kurs beginnt mit mathematischen Grundlagen wie der Gradient Descent-Methode. In der zweiten Woche folgen klassische Machine Learning Algorithmen wie Support Vector Machines, Decision Trees und Clustering sowie eine Einführung in Hochleistungsrechnen (HPC). Die dritte Woche konzentriert sich auf moderne Deep Learning-Anwendungen. Zusätzlich wurden spezialisierte Kurse für Teilnehmende mit

grundlegender AI proficiency angeboten, darunter ein einwöchiger »Advanced Machine Learning« Kurs.

Jeder Kurstag umfasst etwa acht Stunden mit einer kurzen theoretischen Einführung am Morgen, gefolgt von intensiven Programmierübungen. Tutoren stehen während der Übungen durchgehend zur Verfügung, um Fragen zu klären und Frustration zu vermeiden. Optionale Aufgaben sind an verschiedene Kompetenzstufen angepasst. Der Fokus liegt weniger auf Theorie (Wissensebene) als vielmehr auf der Förderung praktischer Kompetenzen (Anwendungsebene). Alle Kurse richteten sich vor allem an Masterstudierende und Promovierende außerhalb der Informatik. Die bisherigen Teilnehmenden kamen aus Disziplinen wie Neurobiologie, Physik, Medizin oder Germanistik. Für leitende Wissenschaftler*innen (PIs), die KI in ihre Forschungsgruppen integrieren wollen, gab es kürzere, fokussierte Intensivkurse.

Erkenntnisse

Das grundlegende Kurskonzept besteht seit dem ersten Projektjahr und wird nun jedes Semester abwechselnd als »Foundations of Machine Learning in Python« oder »Advanced Machine Learning« angeboten. Der Kurs für PIs findet einmal jährlich statt. Basierend auf strukturierten Evaluationen wurde das Kursformat kontinuierlich optimiert. Für die Evaluationen kamen Onlinefragebögen zum Einsatz, die im »then-/post-assessment«-Verfahren (Schiekirkka/Anders/Raupach 2014) das Erreichen der Lernziele erfassen und so Verzerrungen durch den sogenannten response shift bias (Howard/Dailey 1979) minimieren.

Die Evaluation des »Foundations«-Kurses zeigte eine große Heterogenität in den Vorkenntnissen der Teilnehmenden. Während etwa die Hälfte den Schwierigkeitsgrad und das Tempo des Kurses als »genau richtig« empfand, bewertete die andere Hälfte diese als zu anspruchsvoll oder zu schnell. Um diesem Unterschied gerecht zu werden, wurden die Aufgaben angepasst und ergänzt: Neben den Hauptaufgaben wurden zusätzliche optionale Aufgaben mit steigendem Schwierigkeitsgrad eingeführt. Besonders die ersten Kurstage erwiesen sich oft als die herausforderndsten. Dennoch gelang es den meisten Teilnehmenden, die Hauptaufgaben mit Unterstützung der Tutoren bis zum Ende des Tages erfolgreich abzuschließen. Bereits in der zweiten Woche zeigte sich ein deutlicher Fortschritt: Die Teilnehmenden fühlten sich sicherer im Verstehen und Programmieren von ML-Aufgaben sowie im Umgang mit den erforderlichen Tools. In der letzten Woche wurden diese Fähigkeiten weiter

gefestigt und auf leichtere, aber moderne Problemstellungen angewendet. Im »Advanced«-Kurs konnten die Teilnehmenden bereits anspruchsvollere Aufgaben bewältigen. Dennoch wurde auch hier die sofortige Unterstützung der Tutoren laut Evaluation besonders geschätzt.

Eine zentrale Erkenntnis aus den Evaluationen beider Kurse war, dass die meisten Teilnehmenden eine steile Lernkurve sowohl in der Theorie als auch in der praktischen Anwendung und Programmierung von ML-Algorithmen durchliefen und angaben, dass das neu erworbene Wissen ihre Forschung positiv beeinflussen werde.

Säule 2: Implementierung transdisziplinärer Projektgruppen

Theoretischer Hintergrund

Wie bereits erwähnt, ist davon auszugehen, dass viele Informatikstudierende über mehr als nur grundlegende AI literacy verfügen. Vielmehr lassen sie sich als »Collaborators and AI Implementers« oder »Creators of AI« (Faruqe et al., 2022) bzw. als »AI Proficient« oder sogar »AI Experts« (Laupichler, 2024b) einordnen. Dies liegt daran, dass sie im Rahmen ihres Studiums eine fundierte Einführung in die mathematischen und informatischen Grundlagen der Künstlichen Intelligenz erhalten. Am Standort Bonn erfolgt dies beispielsweise unter anderem durch die Vorlesung »Deep Learning für Visual Computing« im Bachelorstudiengang Informatik. Während Informatikstudierende im Vergleich zu anderen Fachrichtungen über eine deutlich ausgeprägtere KI-Kompetenz verfügen, sind praktische Übungen mit realen Problemstellungen selten (Rodolfa & Ghani, 2021). Andere transdisziplinär geprägte Bereiche wie die Humanmedizin haben bereits vor Jahrzehnten erkannt, dass theoretische Grundlagen erst in Kombination mit praxisnahem Training an konkreten Fällen einen echten Mehrwert bieten (Long, 2000). Das Projekt BNTrAInee setzt genau hier an: Es ermöglicht Informatikstudierenden, KI-Anwendungen in transdisziplinären Projektgruppen zu erproben und an praxisbezogenen real-world Problemstellungen zu arbeiten.

Curriculare Struktur

Um die Praxiserfahrung der Informatikstudierenden im Bereich Künstliche Intelligenz zu erweitern, wurde das Konzept transdisziplinärer Projektgrup-

pen entwickelt. Informatik-Studierende arbeiten gemeinsam mit Betreuenden aus der Informatik sowie Expert*innen aus externen Disziplinen wie Digital Humanities, Geschichte oder Pharmakologie, oft Promovierende oder PIs. Die externen Fachvertreter*innen bringen neben ihrer Expertise konkrete, forschungsrelevante Fragestellungen mit, die durch den Einsatz von KI effizienter gelöst werden können. Durch die Projektarbeit sammeln die Informatikstudierenden wertvolle Praxiserfahrung, erhalten 9 ECTS-Punkte und können die Ergebnisse in ihre Projekt-, Bachelor- oder Masterarbeit einfließen lassen. Die Projekte laufen in der Regel über ein Semester, die Themen werden im Vorfeld über die BNTrAInee-Projektbörse ausgewählt.

Regelmäßige Treffen dienen der Besprechung von Fortschritten und offenen Fragen. Zusätzlich stehen die Studierenden in engem Austausch mit den Informatik-Betreuenden, insbesondere bei programmiertechnischen Herausforderungen. Jedes Projekt endet mit einer Präsentation der Ergebnisse vor einer Gruppe interessierter Vertreter*innen aus den beteiligten Fachbereichen, was den Austausch weiter fördert.

Erkenntnisse

Die Abläufe in den Projektgruppen sind bei den meisten Projekten ähnlich. Zunächst unterstützen die Fachvertreter*innen mit ihrem Fachwissen die Annotation und die Vorverarbeitung der Daten. Danach trainieren die Informatikstudierenden unter Anleitung ihrer Betreuer Modelle, die anschließend in Zusammenarbeit mit den Fachvertreter*innen ausgewertet werden.

Die Evaluation der transdisziplinären Projektgruppen wurde im Gegensatz zum zweiten Projektstrang durch semistrukturierte Interviews durchgeführt, in denen sowohl Informatikstudierende als auch Fachvertreter*innen ihre Erfahrungen schilderten. Die Verwendung dieser Evaluationsmethode hatte den Vorteil, dass einerseits auch auf der Grundlage der kleineren Stichprobe konkrete Handlungsempfehlungen und Verbesserungsmöglichkeiten abgeleitet werden konnten. Andererseits kann mithilfe des qualitativen Verfahrens ein wesentlich höherer Detailgrad erreicht werden, der mit quantitativen Fragebögen nicht möglich wäre. Obwohl die Evaluation noch andauert, lassen sich bereits erste Erkenntnisse ableiten.

Generell wurden die transdisziplinären Projektgruppen von allen Beteiligten sehr positiv bewertet. Die Informatikstudierenden schätzten die praxisnahe Ausrichtung der Projekte und fanden es bereichernd, Einblicke in die Arbeitsweisen anderer Disziplinen zu gewinnen. Die Fachvertreter*innen hoben

vor allem hervor, dass die Zusammenarbeit mit den Studierenden zu einer effizienten und schnellen Erreichung der Projektziele führte.

Neben den subjektiven Rückmeldungen zeigen auch objektive Kennzahlen den Erfolg: Einige Projektgruppen haben Ergebnisse erzielt, die in Fachzeitschriften veröffentlicht oder auf Konferenzen präsentiert wurden (Lion/Trunz/Klein 2024, Teplytska et al. 2024, Wolter et al. 2024). Dabei teilen sich Informatikstudierende und Fachvertreter*innen die Co-Autorenschaft, was den transdisziplinären Charakter und den Mehrwert der Kooperation unterstreicht.

Fazit

Das Projekt BNTrAInee adressiert zwei zentrale Lücken in der KI-Bildung: Einerseits steigert es – basierend auf den Evaluationsergebnissen – die AI literacy bzw. proficiency von Nicht-Expert*innen aus anderen Disziplinen, die KI-Anwendungen nutzen müssen, ohne sie selbst programmieren zu können. Andererseits ermöglicht es Informatikstudierenden, ihr theoretisches Wissen in praxisnahen Projekten anzuwenden und ihre Anwendungskompetenzen durch transdisziplinäre Zusammenarbeit zu erweitern.

Obwohl das Projekt zum Zeitpunkt dieser Veröffentlichung noch nicht abgeschlossen ist, deuten erste Ergebnisse darauf hin, dass beide Gruppen ihre Kompetenzen erheblich steigern konnten. Zukünftig wird es von Interesse sein, durch erneute Befragungen derselben Personen zu untersuchen, ob diese Kompetenzzuwächse langfristig bestehen bleiben und sich möglicherweise sogar positiv auf die spätere Berufsrealität von Promovierenden, leitenden Wissenschaftler*innen (PIs) und Informatikstudierenden auswirken.

Literatur

- Ehlers, U. (2020): »Future Skills: Lernen der Zukunft-Hochschule der Zukunft.«, Springer Nature.
- European Commission (2023): »*Artificial Intelligence Act*«.
- Faruqe, F./Watkins, R./Medsker, L. (2022): »Competency Model Approach to AI Literacy: Research-Based Path From Initial Framework to Model.«, in: *Advances in Artificial Intelligence and Machine Learning*, 02(4), 580–587.

- Howard, G. S./Dailey, P. R. (1979): »Response-shift bias: A source of contamination of self-report measures«, in: *Journal of Applied Psychology*, 64(2), 144.
- Kandlhofer, M./Steinbauer, G./Hirschmugl-Gaisch, S./Huber, P. (2016): »Artificial intelligence and computer science in education: From kindergarten to university«, in: *IEEE frontiers in education conference (FIE)* (pp. 1–9), IEEE.
- Laupichler, M. C./Aster, A./Schirch, J./Raupach, T. (2022): »Artificial intelligence literacy in higher and adult education: A scoping literature review«, in: *Computers and Education: Artificial Intelligence*, 3, 100101.
- Laupichler, M. C./Aster, A./Meyerheim, M./Raupach, T./Mergen, M. (2024a): »Medical students' AI literacy and attitudes towards AI: a cross-sectional two-center study using pre-validated assessment instruments«, in: *BMC Medical Education*, 24(1), 401.
- Laupichler, M. C. (2024b): »Are they lit? Developing, testing, and implementing an instrument to measure artificial intelligence literacy«, *Universitäts- und Landesbibliothek Bonn*.
- Lion, P./Trunz, E./Klein, R. (2024): »Unsupervised detection and localization of Egyptian hieroglyphs«, in: *Proceedings of Eurographics Workshop on Graphics and Cultural Heritage*, The Eurographics Association.
- Long, D. M. (2000): »Competency-based residency training: the next advance in graduate medical education.«, in: *Academic Medicine*, 75(12), 1178–1183.
- Long, D./Magerko, B. (2020): »What is AI literacy? Competencies and design considerations«, in: *Proceedings of the 2020 CHI conference on human factors in computing systems* (pp. 1–16).
- Ng, D. T. K./Leung, J. K. L./Chu, S. K. W./Qiao, M. S. (2021): »Conceptualizing AI literacy: An exploratory review«, in: *Computers and Education: Artificial Intelligence*, 2, 100041.
- Rodolfa, K. T./Ghani, R. (2021): »Taking our medicine: Standardizing data science education with practice at the core.«, in: *Harvard Data Science Review*, 3(1).
- Schiekirka, S./Anders, S./Raupach, T. (2014): »Assessment of two different types of bias affecting the results of outcome-based evaluation in undergraduate medical education«, in: *BMC Medical Education*, 14, 1–9.
- Schüller, K./Rampelt, F./Koch, H./Schleiss, J. (2023): »Better ready than just aware: Data and AI Literacy as an enabler for informed decision making in the data age«.

- Schleiss, J./Bieber, M./Manukjan, A./Kellner, L./Stober, S. (2022): »An interdisciplinary competence profile for AI in engineering.«, in: *Towards a new future in engineering education, new scenarios that european alliances of tech universities open up* (pp. 1601–1609). Universitat Politècnica de Catalunya.
- Sperling, K./Stenberg, C. J./McGrath, C./Åkerfeldt, A./Heintz, F./Stenliden, L. (2024): »In search of artificial intelligence (AI) literacy in Teacher Education: A scoping review.«, in: *Computers and Education Open*, 100169.
- Teplytska, O./Ernst, M./Koltermann, L.M./Valderrama, D./Trunz, E./Vaisband, M./Hasenauer, J./Froehlich, H./Jaehde, U. (2024): »Methoden des maschinellen Lernens zur präzisen Dosierung in der Krebsmedikamententherapie: Ein Scoping-Review«, in: *Klinische Pharmakokinetik*.
- Wolter, M./Veeramacheneni L./Baessler, B./Attenberger, U./Wichtmann, B. (2024): »On the stability of neural segmentation in radiology«, in: *ESANN*.
- Wood, E. A./Ange, B. L./Miller, D. D. (2021): »Are we ready to integrate artificial intelligence literacy into medical school curriculum: students and faculty survey«, in: *Journal of medical education and curricular development*, 8, 23821205211024078.

HAWKI - vom Interface zu chatGPT zum KI-Ökosystem für Hochschulen¹

Stefan Wölwer² und Vincent Timm³

Der frei verfügbare Zugang zu generativen KI-Systeme wie ChatGPT hat die Art und Weise, wie Inhalte produziert und vermittelt werden, grundlegend verändert. Es entstehen neue Formen der dialogischen Interaktion zwischen Menschen und technischen Systemen. Herausfordernd für Hochschulangehörige ist, diese Zugänge und Nutzungsmöglichkeiten datenschutzkonform und sozialverträglich zu nutzen. Ferner zeigen sich Barrieren im intellektuellen Umgang mit generativer KI, die eine sinnvolle Nutzung einschränken. Dies erfordert neue technische, gestalterische, pädagogische und wissenschaftliche Methoden und Werkzeuge für die Auseinandersetzung mit KI. Die Integration in den Hochschulalltag ist aufgrund der Dynamik der Technologie, die hier auf tradierte Strukturen trifft, eine Herausforderung. Das Interaction Design Lab hat mit der datenschutzkonformen Plattform HAWKI ein Interface und Ökosystem für generative KI-Anwendungen entwickelt und stellt dies als Open Source-Anwendung zur Verfügung. Dieser Beitrag erläutert den gestalterischen und technologischen Entwicklungsprozess und zeigt neue Interaktionsformen zwischen Menschen und KI auf.

HAWKI – from an interface to chatGPT to an AI ecosystem for universities

Freely available access to generative AI systems such as ChatGPT has fundamentally changed the way in which content is produced and communicated. New forms of dialogical interaction between people and technical systems are emerging. The challenge for university members is to use these access and usage options in a data protection-compliant and socially acceptable manner. Furthermore, there are barriers in the intellectual handling of generative AI that limit its meaningful use. This requires new technical, creative, pedagogical and scientific methods and tools for dealing with AI. Integration

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

2 ORCID: 0009-0001-1337-9254

3 ORCID 0009-0005-2451-9397

into everyday university life is a challenge due to the dynamic nature of the technology, which clashes with traditional structures. With the data protection-compliant HAWKI platform, the Interaction Design Lab has developed an interface and ecosystem for generative AI applications and makes this available as an open source application. This article explains the design and technological development process and shows new forms of interaction between humans and AI.


Einleitung

Mit der Einführung von ChatGPT durch OpenAI am 30. November 2022 eröffneten sich für Hochschulen enorme Chancen für die Weiterentwicklung von Lehre und Forschung. Dies war und ist verbunden mit der Notwendigkeit zur kritischen Reflexion des eigenen Handelns, um beispielsweise den Lebenswirklichkeiten der Studierenden im Umgang mit digitalen Assistenzsystemen gerecht zu werden. Damit einher geht eine Veränderung der Interaktion zwischen Lehrenden und Studierenden sowie der iterierenden Interaktion zwischen Menschen und technischen Systemen wie PCs, mobilen Endgeräten und vernetzten Produkten. Diese Entwicklung begann nicht erst mit ChatGPT, sondern erfuhr an dieser Stelle eine extreme Beschleunigung. Die digitale Transformation, die mit dem Dreischritt Computerisierung/Digitalisierung/Algorithmisierung beschrieben werden konnte (Foraita, Wölwer 2020: 49), erfährt nun eine Erweiterung durch die generative Erstellung von Inhalten, die auf eigens trainierten großen Sprachmodellen basiert. Damit erweitert sich auch die Interaktionsform des Dialogs zwischen Menschen und Maschinen einerseits und des Dialogs zwischen Menschen über soziale Medien andererseits. Diese Veränderungsprozesse ergeben sich aus der technologischen Entwicklung selbst und sind darüber hinaus das Ergebnis gezielter Planung und Gestaltung.

Das Interaction Design Lab an der Fakultät Gestaltung der Hochschule für angewandte Wissenschaft und Kunst (HAWK) Hildesheim/Holzwinden/Göttingen setzt sich intensiv mit der digitalen Transformation auseinander und war daher in der Lage, die Disruption durch die Einführung von ChatGPT als wertvollen Impuls aufzunehmen und in die konkrete Gestaltung von Produkten, Services und Rahmenbedingungen einfließen zu lassen. Vor diesem Hintergrund wurde mit der Entwicklung einer onlinebasierten und datenschutzkonformen Schnittstelle zu ChatGPT begonnen, die in weiteren Iterationen zu einem KI-basierten Ökosystem aus technischen Services und

inhaltlichen Lehr- und Forschungsangeboten ausgebaut wird. Entwurf und Entwicklung der HAWKI-Plattform basieren dabei auf den Forschungs- und Gestaltungsmethoden des Interaction Designs.

Abb. 1: Die drei Themenbereiche des Interaction Design (IxD)



Interaction Design

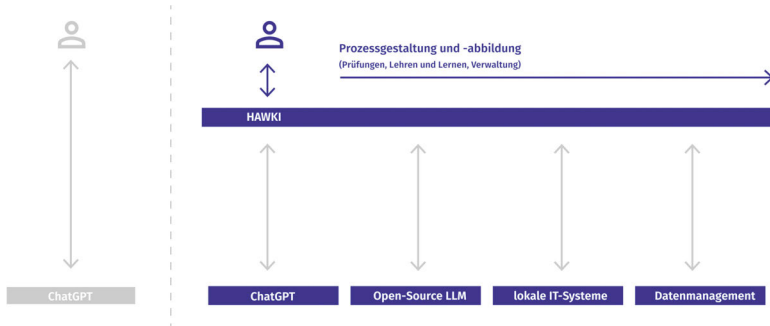
Das Interaction Design mit seinen multimodalen Forschungs- und Arbeitsweisen kann durch seine Kompetenz in der Visualisierung von Sachverhalten die unterschiedlichen Forschungs- und Arbeitsmethoden der verschiedenen Disziplinen der digitalen Transformation verständlich darstellen. Darüber hinaus kann Interaction Design mit seiner konzeptionellen Kompetenz die notwendigen Rahmenbedingungen für eine erfolgreiche digitale Transformation mitgestalten und unterstützen. Dies ergibt sich aus seinen synergetischen Schnittstellen zu Design, Technologie und Gesellschaftswissenschaften. Interaction Design ist die ästhetische Gestaltung jener Parameter, die für eine nachhaltige und verständliche Interaktion zwischen Menschen, Artefakten

und Systemen in physischen sowie damit vernetzten virtuellen Räumen notwendig sind (Wölwer 2023). Sowohl im akademischen als auch im praxisorientierten Umfeld war bisher die Mensch-Maschine-Interaktion das prominente Forschungs- und Anwendungsfeld (vgl. Moggridge 2007). Die Mensch-Maschine-Interaktion liegt aber auch den sozialen Medien zugrunde, in denen Menschen mit Menschen über digitale Systeme interagieren. Mit den Zugängen zu generativen KI-Systemen wie ChatGPT kommt ein wichtiges Aufgabenfeld für das Interaction Design hinzu: die ästhetische Gestaltung der Rahmenbedingungen für die Interaktion zwischen Menschen und technologisch-simulierten Entitäten. Als solche können wir generative KI-Systeme verstehen. Es geht nicht nur um die technische Erzeugung von Inhalten, sondern auch um die menschliche Wahrnehmung dieser Prozesse. Was in der theoretischen Frage von Alan Turing, ob Menschen den Computer als intelligent empfinden (vgl. Turing 1950), seinen Anfang nahm und über die prototypische Herangehensweise von Joseph Weizenbaum im Projekt Eliza (vgl. Weizenbaum 1966) wesentlich vertieft worden ist, findet in der derzeitigen Technologieentwicklung eine enorme Skalierung in der Frage, wie Menschen die sogenannte generative Künstliche Intelligenz wahrnehmen. Schließlich findet hier zunehmend eine Anthropomorphisierung dieser Technologie statt, indem von halluzinierenden Systemen gesprochen oder der KI ein eigenes Bewusstsein zugeschrieben wird (vgl. Nezik 2023). Aus unserer Sicht ist es daher ratsam, generative KI als technologisch-simulierte Entität zu begreifen. In der Folge arbeiten wir in der digitalen und damit auch gesellschaftlichen Transformation nicht nur in interdisziplinären, sondern auch in multientitären Teams zusammen.

Aus dieser Überlegung heraus haben wir HAWKI als Schnittstelle zur Interaktion mit KI-Systemen entwickelt. Für uns liegt der Fokus nicht auf der technologischen Produktion von LLM und den dafür notwendigen Algorithmen, denn dazu fehlen uns die notwendigen Kenntnisse. Unsere Expertise liegt vielmehr in der o.g. ästhetischen Gestaltung von Rahmenbedingungen, die eine gelingende Mensch-KI-Interaktion ermöglichen. Die dazu benötigten Fähigkeiten im Interaction Design basieren dabei auf der theoretischen und praktischen Reflexion sowie der Erfahrung in der Betrachtung der Mensch-Maschine-Interaktion als Dialogsystem (vgl. Card, Moran, Newell 1983) einerseits und auf der Kompetenz der generativen Gestaltung (vgl. Bohnacker et al. 2009) andererseits, innerhalb derer Computer über die Formulierung von Algorithmen, auch Creative Coding genannt, zur Generierung visueller Inhalte gesteuert werden. Hinzu kommt, dass die Profession des Designs

insgesamt eigenständig Ideen und Artefakte entwirft und somit dem Prozess der Generierung von Inhalten sehr offen gegenübersteht.

Abb. 2: HAWKI – vom Interface zum Ökosystem



Methodik und Prozess

Der Design Thinking Prozess als Rahmen- und Orientierungsmodell ermöglicht und fördert den iterativen, prototypischen und partizipativen Entwicklungsweg (vgl. Kolko, 2018). Diese induktive Herangehensweise ist gerade im Bereich der o.g. Interaktion mit generativen KI-Systemen hilfreich, da die aktuelle Situation der allgemein verfügbaren Zugänge zu diesen neu und bisher wenig erforscht ist. Daneben zeigt sich auch in den gremienbasierten Entscheidungswegen an Hochschulen eine Kombination von tradierten Rahmenbedingungen, die einen einschränkenden Einfluss auf die digitale Transformation in den jeweiligen Institutionen haben. Auch hier kann der Design Thinking Prozess Entscheidungswege unterstützen und beschleunigen. Bei der Entwicklung von HAWKI spielen die Methoden des Prototyping und Usertesting (Weichert, Quint, Bartel 2018) eine wesentliche Rolle. Ergänzt und vertieft wird dieses Entwurfsmodell durch das Entwicklungsmodell Open Source. Dabei wird der Quellcode eines digitalen Produkts öffentlich zugänglich gemacht. Open Source-Software unterstützt so die interinstitutionelle Zusammenarbeit und hilft, Fehler zu beheben, neue Funktionen hinzuzufügen und die Qualität der Software zu verbessern. Darüber hinaus fördert die

daraus resultierende Transparenz der Programmierung das Vertrauen der Menschen in das digitale Produkt oder dem Service.

Meilensteine der HAWKI Entwicklung

Der oben beschriebene Entwicklungsprozess lässt sich anhand der folgenden Meilensteine gut zusammenfassen. Dabei wird deutlich, wie eng die Methoden und Prozesse des Interaction Designs in die Entwicklung von HAWKI eingebunden waren und welche Bedeutung sie für die Gestaltung des Systems hatten. Im Januar 2023 haben wir einen ersten Prototyp für eine dialogbasierte KI-Schnittstelle im Hochschulkontext entwickelt. Dieser basierte auf der OpenAI-API und bot in enger Abstimmung mit dem Datenschutzteam eine datenschutzkonforme Lösung. Zudem wurden erste mentale Modelle von virtuellen Assistenten und Wissensräumen erstellt. Fokusgruppen und Stakeholder-Interviews halfen dabei, die Bedürfnisse der Zielgruppen zu definieren und in das System zu übersetzen. Im Mai 2023 folgten gezielte Tests mit einer kleinen Gruppe von Studierenden und Lehrenden und die erste Freigabe für die Hochschulöffentlichkeit. Diese folgten iterativen Prinzipien, wobei kontinuierliches Feedback die Grundlage für Anpassungen und Verbesserungen bildete.

Für die Kostenabrechnung hinterlegten wir die Kreditkarte der Hochschule. Im August 2023 veröffentlichte das Team den Programmcode als Open Source auf GitHub. Dies führte zu einer Vernetzung der nutzenden Hochschulen, wodurch die Sicherheitsarchitektur verbessert und zusätzliche Funktionen eingeführt werden konnten. Die Open Source-Veröffentlichung spiegelte das Prinzip des kollaborativen Designs als zentralen Aspekt des Interaction Designs wider. Im Herbst 2023 nahm die Verbreitung und Nutzung der HAWKI-Plattform unterstützt durch visuelles Storytelling und ansprechendes Interface Design bundesweit zu. Im Januar 2024 wuchs das Team im IxD Lab um eine weitere Full-Stack-Entwicklerstelle an. Im Frühjahr 2024 etablierte sich das HAWKI Weekly, ein regelmäßiges Treffen der Entwicklerinnen und Entwickler im Netzwerk, das die institutionsübergreifende Zusammenarbeit förderte. Seit August 2024 integrieren wir einen Retrieval-Augmented Generation (RAG) Prozess, der es den Hochschulen ermöglicht, eigenes Wissen und Inhalte datenschutzkonform zu vektorisieren und über die Plattform verfügbar zu machen. Dieser Schritt zeigt die bewusste Gestaltung von Informationsarchitekturen und Nutzungsprozessen, um die Komplexität

der Datenvektorisierung zu reduzieren und die Zugänglichkeit zu Datenpools zu erhöhen. Im Herbst 2024 haben wir mit der Modularisierung des Programmcodes begonnen, die es ermöglicht, auf die spezifischen Bedürfnisse der einzelnen Hochschulen einzugehen, ohne die Kernfunktionalitäten zu beeinträchtigen. Im Februar 2025 erfolgte der Launch von HAWKI 2.0 mit neuen Funktionen wie speicherbaren Chatverläufen und einem Gruppenchat, der die User Experience weiter verbessert und die oben beschriebene multi-entitäre Teamarbeit ermöglicht.

Fazit

Aus einem zunächst basalen Interface zu ChatGPT entwickelten wir seit Januar 2023 über die Forschungs- und Gestaltungsmethoden des Interaction Designs die Grundlage für ein wachsendes und umfassendes Ökosystem zu KI-Systemen. Aufgrund der Modularität im Aufbau und der Bereitstellung über Open Source können alle Hochschulen und Institutionen, die HAWKI nutzen, eigene Forschungsschwerpunkte, KI-Assistenten und Funktionen hinzufügen und im gemeinsamen Netzwerk teilen. Die Abhängigkeit von kommerziellen LLM-Anbietern sinkt durch lokale und regionale Open Source-LLM-Angebote, was zu höherer Datensouveränität führt. HAWKI fördert die gemeinsamen Interaktionsräume von Hochschulangehörigen mit KI-Systemen durch die hier beschriebenen Methoden und Kompetenzen des Interaction Designs und erweitert die technologische Infrastruktur um wichtige didaktische und partizipative Formate. Durch diese prototypische und designbasierte Entwicklung ist es gelungen, das hohe Tempo der technologischen Entwicklung im Bereich der generativen KI auf die Gestaltung und Bereitstellung der notwendigen Interaktionsräume für Hochschulen und Institutionen zu übertragen.

Literatur

- Bohnacker, Hartmut/Groß, Benedikt/Laub, Julia/Lazzeroni, Claudius (2009): Generative Gestaltung, Mainz, Verlag Hermann Schmidt
- Card, Stuart K/Moran, Thomas P/Newell, Allen (1983): The psychology of human-computer interaction, Hillsdale, Lawrence Erlbaum Associates
- Foraita, Sabine/Wölwer, Stefan (2020): »Design for Teaching!«, in: Saskia Planckert (Hg.) Entwerfen, Lernen, Gestalten, Bielefeld, transcript Verlag, S. 49

- Github, <https://github.com/HAWK-Digital-Environments/HAWKI> vom 23.09.2024
- Kolko, Jon (2018): »The divisiveness of design thinking«, in: Simone Barbosa, Gilbert Cockton (Hg.) *Interactions*, Volume 25, Issue 3, New York: Association for Computing Machinery, S. 28–34, <https://doi.org/10.1145/3209963>
- Moggridge, Bill (2007): *Designing Interactions*, Cambridge, The MIT Press
- Nezik, Ann-Kathrin (2023): »Hast du ein Bewusstsein? Ich denke schon, Antwortet der Rechner«, in: *Die ZEIT*, 03/2023, Hamburg, Zeitverlag Gerd Bucerius GmbH & Co. KG, S. 13–15
- Turing, Alan (1950): »Computing Machinery and Intelligence«, in *Mind*, Vol. 236: *A Quarterly Review of Psychology and Philosophy*, Oxford, Oxford University Press
- Weichert, Steffen/Quint, Gesine/Bartel, Torsten (2018): *Quick Guide UX Management*, Wiesbaden: Springer Gabler
- Weizenbaum, Joseph (1966): »ELIZA—a computer program for the study of natural language communication between man and machine«, in: *Communications of the ACM*, Volume 9, Issue 1, DOI (10.1145/365153.365168)
- Wölwer, Stefan (2023): » Interaction Design as an Interdisciplinary Research Mindset«, DOI (10.48547/202307-004)

Let's open the Toolkit

Digitale Werkzeuge in der Hochschullehre¹

Caroline Berger-Konen, Jessica Felgentreu, Anika Limburg, Stefan Göllner
und Sarah Habla

Wie kaum ein anderes Thema prägt derzeit die Einbettung generativer KI-Tools (genAI-Tools) in Lehr-Lernsettings die Diskussion über eine zukunftsfähige Hochschullehre. Im Rahmen eines World-Cafés auf der Learning AID 2024 wurde gemeinsam mit der anwesenden Fachcommunity erörtert, welche genAI-Tools bereits tatsächlich in der Praxis eingesetzt werden, welche Herausforderungen eine Dissemination derzeit behindern und inwiefern digitale Lernangebote (Prompt-Labor 2.0) gezielt Anwendungswissen vermitteln können. Dabei zeigte sich, dass genAI-Tools u.a. in der Lehrplanung, im wissenschaftlichen Arbeiten und zur Entlastung im Arbeitsalltag bereits eine Rolle spielen, eine nachhaltige und breite Nutzung jedoch durch erhebliche Unsicherheiten auf unterschiedlichen Ebenen behindert wird. Die Diskussion deutet darauf hin, dass sich genAI-Tools sukzessive in der Hochschullehre etablieren.

Let's open the Toolkit: GenAI-tools in higher education – Findings from the Learning AID 2024 World Café

The embedding of generative AI-tools (GenAI-tools) in teaching and learning settings is currently shaping the discussion about future-proof higher education more than almost any other topic. As part of a world café at Learning AID 2024, a discussion was held on which AI-tools are already actually being used in practice, which challenges are currently preventing dissemination and to what extent digital learning formats (Prompt Lab 2.0) can provide specific application knowledge. It became clear that GenAI-tools already play a role in curriculum planning, scientific work and to relieve the workload in everyday teaching, but that there are considerable uncertainties at various levels regarding their sustainable use. The discussion indicates that GenAI-tools are gradually establishing themselves in higher education teaching.

¹ Basiert auf einem Workshop im Rahmen der Tagung.

Einleitung

Text-, Bild-, Ton- oder Video-generierende Computersysteme wie ChatGPT, Microsoft Copilot oder Perplexity.ai haben die Diskussionen um zukunftsfähige Hochschullehre dynamisiert, die sich auf die Mikroebene (Lehr-Lern-Prozesse), die Mesoebene (Fakultäten, Fachbereiche und Zentraleinheiten) und auch auf die Makroebene (strukturelle und institutionelle Rahmenbedingungen) beziehen (Schmohl et al. 2023).

Unzählige genAI-Tools für verschiedene Anwendungsfelder konkurrieren auf einem dynamischen und unüberschaubaren Markt. Dass generative KI berufliche Praxis, Forschung und Lehre gleichermaßen berührt, teils sogar weitreichend verändert und dominiert, ist eine weit verbreitete Überzeugung, die im konkreten Fall die Abwägung ethischer, sozialer und ökologischer Aspekte erfordert. So werden im Diskurs zum Einsatz von KI-Systemen in der Hochschullehre vielfältige Unterstützungsmöglichkeiten bspw. im Hinblick auf Schreibprozesse (Buck/Limburg 2023, 2024) erkannt, gleichzeitig bestehen Bedenken, die vor allem um datenschutzrechtliche, ethische und didaktische Fragestellungen kreisen (Zawacki-Richter et al. 2019).

Vor diesem Hintergrund stellt sich die Frage, inwiefern KI-Anwendungen bereits Einzug in Hochschullehre und Forschungspraxis erhalten haben. Der FernUni-KI-Campus-Hub NRW, das VK:KIWA und der Stifterverband verfolgten im Rahmen eines World-Cafés auf der Learning AID 2024 das Ziel, eine Bestandsaufnahme gemeinsam mit der Fachcommunity vorzunehmen, um einerseits den Wissenstransfer hochschulübergreifend zu stärken und andererseits auf Basis offener Fragen und Herausforderungen thematische Ausrichtungen für zukünftige Formate identifizieren zu können.

Das Konzept des World-Cafés sah vor, zunächst eine praxisorientierte Übersicht in Form einer gemeinsamen Tool- und Use-Case-Sammlung zu erstellen (Tisch 1,2). Anschließend wurden Hindernisse, Herausforderungen und offene Fragen diskutiert, um auf dieser Basis entsprechende Unterstützungsmöglichkeiten ableiten zu können (Tisch 3,4). Zuletzt wurde reflektiert, welches Wissen für ein gezieltes Prompting erforderlich ist und wie es im Rahmen eines neuen Formats adressiert werden kann (Tisch 5,6).

Insgesamt diskutierten mehr als 40 Vertreter*innen der wissenschaftlichen Fachcommunity die Fragestellungen an den jeweiligen Thementischen. Im Folgenden werden die Diskussionspunkte in ihren Grundzügen zusammengetragen, reflektiert und Implikationen im Hinblick auf notwendige

Schritte für einen kritisch-reflexiven Einsatz von genAI-Tools in der Hochschullehre abgeleitet.

Let's open the Toolkit: Welche genAI-Tools haben sich für welche Zwecke etabliert?

Bislang fehlen repräsentative Befragungen dazu, welche genAI-Tools sich in unterschiedlichen hochschulischen Anwendungskontexten bereits etabliert haben. Im Rahmen des World-Cafés diskutierten wir daher an den ersten beiden Thementischen zunächst, welche genAI-Tools die anwesenden Vertreter*innen der Fachcommunity in ihre Arbeitsabläufe integriert haben. Dabei wurde schnell deutlich, dass auch unter den Anwesenden Kenntnisstand und Erfahrungsschatz sehr unterschiedlich sind und ein Einsatz derzeit vor allem situativ entschieden wird. Insgesamt ließen sich dennoch drei Anwendungsfelder erkennen: 1) in der Hochschullehre, 2) im Kontext wissenschaftlichen Arbeitens sowie 3) als Entlastung im Arbeitsalltag.

1. Als wichtigste Anwendung im hochschulischen Lehr-Lernkontext wird von den Teilnehmenden noch immer chatGPT betrachtet, etwa zur Lehrplanung oder zur Aufgabenerstellung. In der Lehrveranstaltung selbst waren zwei Settings verbreitet: Zum einen wurde chatGPT-Generate – sei es Text oder Code – zum Gegenstand kritischer Reflexion und anschließender Iteration gemacht, zum anderen wurde chatGPT mithilfe komplexer Prompts, wie sie etwa im Prompt-Labor des KI-Campus entwickelt und gesammelt wurden, als Tool zum personalisierten Lernen angeboten. Während das erste Setting den Fokus auf die bedeutsame Zukunftskompetenz der Mensch-Maschine-Kollaboration legt, zielt der zweite Use-Case auf das Potenzial von KI zur Lernbegleitung ab.
2. Im Kontext des wissenschaftlichen Arbeitens wurde das Potenzial von KI-Anwendungen vor allem gesehen in (a) automatisierter Texterstellung und Transkription sowie (b) der Literaturrecherche und Aufbereitung des Forschungsstands:
 - a) KI-generierte Texte wurden vor allem als Inspiration bzw. Entlastung im Schreibprozess begriffen (passend zu Theorieansätzen, s. Buck/Limburg 2024). Darüber hinaus wurde KI vor allem bei Lower Order Tasks eingesetzt, etwa zur Rechtschreibprüfung und Textüberarbeitung oder zur Transkription (z.B. mit Whisper oder noScribe).

- b) Für die Literaturrecherche nutzen die Teilnehmenden eine große Breite an KI-Tools, z.B. Elicit, Open Knowledge Maps, Connected Papers, ResearchRabbit, Semantic Scholar, iris.ai, scite, Consensus oder Inciteful. Als Vorteile gegenüber der klassischen Datenbankrecherche wurde dabei sowohl die Paraphrase und Zusammenfassung einzelner Texte oder die Text-Synthese verschiedener Paper betrachtet, als auch die visuelle Aufbereitung von Forschungsständen, z.B. der gegenseitigen Referenzierung, der Publikationschronologie oder thematischer Facetten. Beides war vor dem Aufkommen dieser Tools sehr aufwändig, auch wenn die Ergebnisse von KI-Recherchen noch etliche Unzulänglichkeiten aufweisen (z.B. ausschließlich englischsprachige Paper).
3. Zur Entlastung im Arbeitsalltag wurde wiederum oft chatGPT verwendet, sei es für E-Mails oder andere Schreibaufgaben. Für die Internetrecherche im nicht-wissenschaftlichen Bereich nutzen einige perplexity.ai, das bei ihnen klassische Suchmaschinen wie google vollständig ersetzt. GenAI-Tools wie tome.app oder Gamma.app werden für die automatisierte Erstellung von Präsentationen genutzt. Bei jedem dieser Use-Cases wurde jedoch betont, dass die Ergebnisse kritisch geprüft und iteriert werden müssen.

Bei allen drei Anwendungsfeldern wurde wiederholt die Problematik des Zugangs zu genAI-Tools diskutiert und inwiefern Hochschulleitungen in der Verantwortung stehen, Zugänge zu schaffen und Richtlinien zu formulieren.

Toolkit upside-down: Welche Faktoren schränken die Dissemination und Exploration von genAI-Tools in der Lehre ein?

Die zentrale Erkenntnis dieser Diskussionsrunde lautet, dass sich die größte Barriere der Dissemination in einer tiefen Verunsicherung der Lehrenden finden lässt, die sich aus ganz unterschiedlichen Bedenken speist. Selbst für viele Mitglieder der Fachcommunity stellt alleine die große Anzahl am Markt verfügbarer genAI-Tools eine Hürde dar. Die Auswahl eines bestimmten Tools scheint vor diesem Hintergrund beliebig. Einerseits helfen Tool-Repositoryen (z.B. futuretools.io, theresanaiforthat.com, ki-suche.io), andererseits weisen auch sie für einen konkreten Anwendungsfall zahlreiche Tools aus. Unsicherheit besteht ebenfalls darüber, welche Anforderungen ein genAI-Tool erfül-

len sollte, um datenschutz- und urheberrechtskonform zu sein. Aus der Perspektive der Lehrenden und einzelnen Studierenden wurde zudem reflektiert, welche Kompetenzen für eine sichere und ethische Nutzung gestärkt werden müssen. Im Fokus stand diesbezüglich die Stärkung von AI-Literacy (Schüller et al. 2023).

Im Hinblick auf die Rolle der professionellen Lehrperson bestehen daneben durchaus Ängste in Bezug auf die Substitution bisheriger didaktischer Aufgaben. Übergreifend sind sowohl für Studierende als auch für Lehrende sichere Rahmenbedingungen und praxisnahe Orientierungshilfen erforderlich, die nicht nur bei der Anwendung, sondern auch bei der didaktischen Planung und Umsetzung von Lehr-Lernsettings unterstützen. Hochschulen bieten derzeit jedoch entweder ganz unterschiedliche, oder auch keine Orientierungs- oder Handlungsleitfäden für die Verwendung von genAI-Tools an. Dies verstärkt die Verunsicherung innerhalb der Lehrenden- und Studierendenschaft und verhindert ein proaktives Explorieren. Außerdem verhindert die Rechtsunsicherheit einen offenen Austausch über Nutzungserfahrungen. In diesem Kontext besteht auch die Sorge, dass genAI-Tools unwissentlich unangemessen verwendet werden könnten.

Eine weitere Hürde stellt die Wahl zwischen frei zugänglichen oder kommerziellen genAI-Tools dar, insbesondere wenn es um eine langfristige und nachhaltige Nutzung geht. Obwohl sich vier Bereitstellungswege für generative KI-Systeme an Hochschulen etabliert haben (Berger-Konen 2024) wird der Zugang zu diesen bislang weiterhin als kompliziert, wenig standardisiert und voraussetzungsreich empfunden.

Daran anknüpfend bezog sich ein weiterer Diskussionsschwerpunkt auf ethische Bedenken. Der Einsatz von KI-Systemen wirft Fragen zum Datenschutz oder zur Transparenz von Algorithmen auf. Dies betrifft bspw. Menschenrechtsverletzungen bei der Bereinigung von Trainingsdatensätzen (z.B. von rassistischen und sexistischen Inhalten), intransparente algorithmisierte Verfahren der Datenverarbeitung oder einen bedenklichen ökologischen Fußabdruck aufgrund des Energieverbrauchs großer Server (z.B. Deutscher Ethikrat 2023).

Grundsätzlich wurde deutlich, dass auch innerhalb der Fachcommunity Unsicherheiten bestehen und dezidierte Kenntnisse auf dem Weg zur Dissemination von genAI-Tools in der Hochschullehre fehlen. Die daraus resultierenden Austausch- und Fortbildungsbedarfe wurden abschließend konkretisiert, um diese perspektivisch bspw. in einem neuen Format des KI-Campus zu bearbeiten.

Toolkit fine-tuning: Welche Kompetenzen für das Prompting sind für die Nutzung generativer KI-Tools in der Lehre erforderlich?

In der dritten Phase des World-Cafés wurde die Frage nach dem genAI-Tool-Einsatz in der Hochschullehre in Bezug auf ein digitales Lernangebot gestellt, welches aktuell vom KI-Campus in Zusammenarbeit mit Malte Persike und weiteren Dozierenden konzipiert und umgesetzt wird.

Es handelt sich hierbei um das Prompt-Labor 2.0 – einen Selbstlernkurs, der über Videos und interaktive Aufgaben zahlreiche Fragestellungen, Techniken und Hintergrundwissen zum Umgang mit generativer KI in Lehr-Lernkontexten vermittelt. Dabei werden in einem systematischen Ablauf zunächst Grundlagen, Funktions- und Verhaltensweisen generativer KI-Systeme sowie grundlegende Prompting-Techniken vermittelt. Weitere Einheiten beziehen sich insbesondere auf Prüfungen. Das Kursangebot enthält Vertiefungen zu Prompting-Workflows, zu komplexen Prompting-Werkzeugen und Inhalte zur Qualitätssicherung und Verwendungsmöglichkeiten von Prompts in der Lehre (vgl. Göllner 2023).

Mit der Veröffentlichung des neuen Selbstlernkurses starten auch sogenannte »Prompt-Retros«, synchrone digitale Veranstaltungen, in denen sich die Teilnehmenden Prompts und Anwendungsszenarien gegenseitig vorstellen, in denen aber auch in Kleingruppen erneut der direkte Peer-To-Peer Austausch begünstigt wird.

Vor diesem Hintergrund wurden den Teilnehmenden im Rahmen des World-Cafés zwei Fragen gestellt: a) Welche Anforderungen für den Selbstlernkurs bestehen bezüglich der Vermittlung von Wissen rund um genAI-Tools? b) Welches Potenzial besteht in den »Prompt-Retros«, um praktisches Wissen mit genAI-Tools experimentell, interaktiv und kollaborativ aufzubauen?

Die Diskussionen zu diesen Fragen bestätigten, dass neben der grundlegenden Aufklärung über Funktionsprinzipien, Anwendungswissen und Tool-Spezifika die Auseinandersetzung mit Anwendungssituationen von ganz zentraler Bedeutung bleibt. Dies funktioniert am besten im Peer-To-Peer Austausch, wobei auch fachspezifische Reflexionen notwendig bleiben.

GenAI-Tools bieten für Lehr-Lernprozesse z.B. die Möglichkeit einer automatisierten Umwandlung von Texten in Podcastform oder können durch Empfehlungsbots weitere Inhalte zum Gelernten aufzeigen. Diese Möglichkeiten wurden von den Teilnehmenden positiv bewertet. Dabei ist aufgrund der sehr dynamischen Entwicklung innerhalb der Tool-Landschaft Aktualität

ein zentrales Kriterium: Nicht nur die Anzahl der genAI-Tools wächst, auch Leistungsumfang und Leistungsfähigkeit verändern sich stetig. Dies erfordert stetige Reflexionen darüber, welche »Gewinne« z.B. für die Selbstorganisation oder Vermittlungsaufgaben der Lehrenden zu erzielen sind. Gewünscht wird, dass in den Prompt-Retros die oftmals wiederkehrenden Anwendungsszenarien mit den Potenzialen der Tools in Beziehung gesetzt werden. Konkrete Fragen für die weitere Ausgestaltung des Prompt-Labors z.o lauten: Welches Tool kann mich wie in einer Situation unterstützen? Welche Kombination verschiedener spezialisierter Tools ist gewinnbringend für den jeweiligen Anwendungsfall? Wann behindert ein Tool den Erkenntnisprozess, wann unterstützt es ihn? Welche Aufgaben sind automatisierbar und beschleunigen Prozesse? Welche Aufgaben sollten nicht automatisiert werden, da ein Kontroll- (aber auch Souveränitätsverlust) droht?

Fazit

Die Ergebnisse des World-Cafés verdeutlichen, dass der Einsatz generativer KI-Tools in der Hochschullehre noch mit vielen offenen Fragen verbunden ist. Lehrende stehen vor der Herausforderung, ihre doppelte Rolle zu meistern: Zum einen möchten sie die Potenziale nutzen, die genAI-Tools für Lernkontexte bieten, und einen entsprechend kompetenten und verantwortungsbewussten Umgang lehren. Zum anderen müssen sie sich selbst weiterbilden und Einsatzszenarien unter teilweise unsicheren Rahmenbedingungen erproben. Die aufgezeigten Unsicherheiten innerhalb der Fachcommunity spiegeln sich somit auch in der mangelnden Verfügbarkeit konkreter Best-Practices und etablierter Anwendungsbeispiele für die Hochschullehre wider. Festzuhalten bleibt jedoch auch, dass Forschungs- und Vernetzungsaktivitäten rund um Künstliche Intelligenz in der Hochschullehre (z.B. FernUni-KI-Campus-Hub NRW, KI:edu.nrw, VK:KIWA, CATALPA) als wichtig und weiterhin wünschenswert erachtet werden.

Ein zentrales Ergebnis ist darüber hinaus, dass sich Lehrende bei der Auswahl von genAI-Tools überwiegend auf die Integration von ChatGPT fokussieren, während andere, speziell auf Lehren und Lernen ausgerichtete Tools bisher nur eine nachgeordnete Rolle spielen. Insgesamt suggerieren die Diskussionen aber, dass genAI-Tools sowohl sukzessive in die Hochschullehre Einzug halten, als auch, dass sich allmählich bestimmte Tools für bestimmte Aufgaben nach und nach durchsetzen und potenziell zum Standard werden. Dieser Pro-

zess wird sehr wahrscheinlich stark durch Aspekte beeinflusst werden, die wir von den Teilnehmenden an den Thementischen drei und vier erfragt haben, bei der es um die Frage ging, welche Aspekte Lehrende derzeit von der Nutzung von genAI-Tools abhalten.

Literatur

- Berger-Konen, Caroline (2024): »Zugänge zu generativer KI an Hochschulen schaffen: Resümee zum Symposium an der FernUniversität in Hagen. Siehe <https://hochschulforumdigitalisierung.de/zugaenge-zu-generativer-ki-an-hochschulen-schaffen/vom-21.08.2024>.
- Buck, Isabella/Limburg, Anika (2023): »Hochschulbildung vor dem Hintergrund von Natural Language Processing (KI-Schreibtools). Ein Framework für eine zukunftsfähige Lehr- und Prüfungspraxis«, in: Die Hochschullehre 9(1), S. 70–84.
- Buck, Isabella/Limburg, Anika (2024): »KI und Kognition im Schreibprozess: Prototypen und Implikationen«, in: Journal für Schreibwissenschaft 26, S. 8–23.
- Center of Advanced Technology for Assisted Learning and Predictive Analytics (CATALPA) (2024). <https://www.fernuni-hagen.de/forschung/schwerpunkte/catalpa/>
- Ethikrat (2023): Mensch und Maschine – Herausforderungen durch Künstliche Intelligenz, Berlin: Deutscher Ethikrat.
- FernUni-KI-Campus-Hub NRW (2024). <https://fernuni-ki-campus.fernuni-hagen.de/>
- Göllner, Stefan (2023): »Prompt-Labor – Generative KI in der Hochschullehre«. <https://hochschulforumdigitalisierung.de/prompt-labor-generative-ki/>
- KI-Campus (2024). <https://ki-campus.org/>
- KI:edu.nrw – Didaktik, Ethik und Technik von Learning Analytics und KI in der Hochschulbildung (2024). <https://ki-edu-nrw.ruhr-uni-bochum.de/>
- Schmohl, Tobias/Watanabe, Alice (2023): Künstliche Intelligenz in der Hochschulbildung. Chancen und Grenzen des KI-gestützten Lernens und Lehrens, Bielefeld: transcript.
- Schüller, Katharina/Rampelt, Florian/Koch, Henning/Schleiss, Johannes (2023): Better ready than just aware: Data and AI Literacy as an enabler for informed decision making in the data age. INFORMATIK 2023 – De-

signing Futures: Zukünfte gestalten, Bonn: Gesellschaft für Informatik.
[HTTPS://DOI.ORG/10.18420/inf2023_49](https://doi.org/10.18420/inf2023_49)

Virtuelles Kompetenzzentrum: Künstliche Intelligenz und wissenschaftliches
Arbeiten (VK:KIWA) (2024). <https://www.vkkiwa.de/>

Zawacki-Richter, Olaf//Marín, Victoria I./Bond, Melissa/Gouverneur, Fran-
ziska (2019): »Systematic Review of Research on Artificial Intelligence Ap-
plications in Higher Education. Where Are the Educators?«, in: Interna-
tional Journal of Educational Technology in Higher Education 16(1), S. 1–27.

