

KI-basierte Erstellung individualisierter Mathematikaufgaben für MINT-Fächer

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

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

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

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

1 Einleitung

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

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

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

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

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

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

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

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

2 Konzept

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

2.1 Aufgaben

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

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

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

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

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

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

2.2 KI zur Aufgabenerstellung

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

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

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

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

2.3 Learning Analytics

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

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

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

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

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

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

3 Diskussion

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

Literatur

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

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