



Lehrreiche Künstliche Intelligenz

Projekte und Perspektiven für Methoden der Künstlichen Intelligenz in der Physikdidaktik

Stefan Küchemann, Steffen Steinert und Jochen Kuhn

Die Digitalisierung in Schule und Hochschule hat nicht zuletzt durch die Corona-Pandemie einen großen Schub erhalten. Onlinebasierte Formate fanden größere Verbreitung; allein die Lernplattform Moodle umfasste im September 2023 über 46 Millionen Kurse und über 394 Millionen Nutzende weltweit [1]. Dies macht digitale Daten verfügbar und verarbeitbar, nicht zuletzt durch Methoden der Künstlichen Intelligenz. Insbesondere verdeutlicht das Sprachmodell ChatGPT von OpenAI, dass KI-basierte Anwendungen für Lernen und Lehren weit über den Rahmen von gängigen Lernplattformen hinausgehen [2].

Für den Einsatz von Künstlicher Intelligenz (KI) im Bildungskontext stellen sich weitreichende Fragen: Wie lassen sich Lernende durch solche Anwendungen effektiv begleiten und (frühzeitig) fördern? Auf welche Weise lassen sich personenbezogene Daten für das Training von KI-Algorithmen nutzen und gleichzeitig schützen? Genügen Menge und Qualität der anfallenden Datensätze überhaupt für eine sinnvolle Anwendung von Künstlicher Intelligenz?

KI-basierte Individualisierung durch Kurzaufgaben

Im Bildungsbereich hat man es in der Regel mit anderen Größenordnungen an Daten zu tun als beispielsweise bei ChatGPT, das auf einem sehr großen Textkorpus von mehreren hundert Milliarden Wörtern trainiert wurde. Auch im Hinblick auf die Physiklehre zielen KI-basierte Systeme darauf ab, Entscheidungs- und Lernprozesse, wie die Selektion oder die Vernetzung von Informationen, besser zu verstehen, um Fehler vorhersehen und vermeiden oder um vertiefende Hinweise geben zu können. Beispielsweise ließe sich der Schwierigkeitsgrad von Aufgaben an das individuelle physikalische Wissen oder die mathematischen Fähigkeiten von Lernenden anpassen, um eine Über- oder Unterforderung zu vermeiden.

Neben solchen Maßnahmen können KI-Systeme auch Lehrkräfte beim Unterrichten oder bei der Unterrichtsvorbereitung unterstützen [3, 4]. Dazu gehören die automatisierte Bewertung von Tests und Überprüfungen, die Analyse von Lernendendaten, die Diagnose von individuellem Förderbedarf (etwa durch eine geeignete Aufbereitung der Daten oder KI-basierte Hervorhebung in Daten-Dashboards) sowie die Klassenorganisation.

Diese Aspekte implementiert und erforscht das Projekt KI4S'Cool der LMU München für den Physikunterricht in der Schule. Die dafür entwickelte Anwendung ist über eine standardisierte Schnittstelle direkt in die jeweiligen Lernplattformen der Schulen eingebettet, sodass sie sich nahtlos als normales Seitenelement (vergleichbar mit einem YouTube-Video) einfügt. In der KI4S'Cool-App können Schülerinnen und Schüler sehr kurze, individualisierte kompetenz- und konzeptorientierte (Multiple-Choice-) Aufgaben lösen. Wöchentlich werden wenige solcher kurzen Aufgaben abgestimmt auf den Unterrichtsinhalt bereitgestellt, für die die insgesamt Bearbeitungszeit zehn Minuten nicht überschreitet. Die Aufgaben fördern individuell neben konzeptionellen Fähigkeiten gezielt mathematische Kompetenzen, die Repräsentationskompetenz, d. h. das Verständnis von Inhalten in verschiedenen Darstellungen wie etwa Graphen, und das Datenverständnis.

Die Schülerinnen und Schüler erhalten auf Basis ihrer Antworten und ihrer Wissens- und Verhaltensdaten personalisiertes Feedback und Hilfestellungen [4]. Das Feedback kann dabei unterschiedliche Formen annehmen: Erläuterungen auf Basis eines erklärenden Textes oder einer grafischen Darstellung sowie mithilfe von mathematischen Ausdrücken (Abb. 1). Diese erhalten die Schülerinnen und Schüler durch einen KI-Algorithmus je nach Lernstand individuell passend zugeteilt. Die Informationen über Lernverlauf, gelöste und fehlerhafte Aufgaben, mathematische Fähigkeiten, Repräsentations- und Datenkompetenz stehen

in Echtzeit sowohl den Lernenden personalisiert als auch den Lehrkräften kumuliert, gruppenbezogen oder individualisiert zur Verfügung. Die Lehrkräfte erhalten die Informationen auf Basis eines Dashboards in Echtzeit [5]. Im Vergleich zu einer normalen Lern-App lernt der KI-Algorithmus in der KI4S'Cool App von den Daten und Eingaben der Nutzenden und erkennt individuelle Lernverläufe. Dadurch bekommt jede Schülerin bzw. jeder Schüler auch individuelles Hilfsmaterial und Feedback bereitgestellt, das mit zunehmender Anzahl an Daten immer besser auf die persönlichen Lernverläufe abgestimmt wird und auch von der KI erkannte Fehlkonzepte beheben kann.

Ähnlich dem Projekt KI4S'Cool verfolgen die beiden Kooperationsprojekte im Rahmen der Learning Progression Analytics (LPA AFLEK und LPA ALICE) zwischen dem Leibniz-Institut für die Pädagogik der Naturwissenschaften und Mathematik in Kiel, dem Leibniz-Institut für Bildungsforschung und Bildungsinformation in Frankfurt, der Ruhr-Universität Bochum und dem Leibniz-Institut für Wissensmedien in Tübingen ein Monitoring von Lernverläufen von Schülerinnen und Schülern, die ebenfalls für die Lehrkräfte aufbereitet werden [6].

Blicke für Durchblick

Neben der Analyse und einer Verbesserung von Lernverläufen in KI4S'Cool und den Projekten im Rahmen des LPA wurde im Projekt HyperMind ein intelligentes




Abb. 1 Die KI4S'Cool App gibt Schüler:innen ein individuelles Feedback in drei verschiedenen Formaten: eine verbale, eine grafische und eine mathematische Erläuterung. Zusätzlich informiert es die Lernenden über ihre Lernentwicklung.




Abb. 2 Das intelligente Schulbuch HyperMind nutzt den Verlauf des Blickes einer Schülerin oder eines Schülers beim Lernen (a) und liefert Diagramme von aufbereiteten Blickdaten (b) für Lehrkräfte.

Schulbuch entwickelt, das Blickdaten von Schülerinnen und Schülern beim Lernen aufzeichnet, d. h. die Blicke von Lernenden mit sogenannten Eye-Tracking-Geräten verfolgt. Im Vergleich zu Punktzahlen in Leistungstests erreicht die Nutzung von Blickdaten eine deutlich höhere Vorhersagegenauigkeit des Verständnisses [7, 8]. Dadurch können Schülerinnen und Schüler bereits direkt während des Lernens Hilfestellungen durch Visualisierungen oder zusätzliche Erklärungen erhalten (Abb. 2).

Am Puls der Lernenden

Ähnliche Systeme wie die KI4S'Cool App kommen auch in der universitären Lehre zum Einsatz. Durch diese lässt sich bei Studierenden die Gefahr eines Studienabbruchs feststellen und den Betroffenen individuelle Hilfe anbieten, um den Lernerfolg zu erhöhen und damit die Abbruchquote zu verringern. Dies soll beispielsweise im Rahmen des Projekts KI4TUK durch das wöchentliche Lösen kompetenz- und konzeptspezifischer Kurztests geschehen [9]. Die Kurztests sind auf den Vorlesungsverlauf abgestimmt und fördern neben Mathematik- und Repräsentationskompetenz auch das Datenverständnis. Die dafür entwickelte webbasierte Plattform (RATsApp) arbeitet derzeit wie ein klassisches System, da sie zunächst optimal eingestellt (trainiert) werden muss. In dieser Trainingsphase stellt das System MINT-Studierenden in der Studieneingangsphase ein Feedback auf Basis ihrer Antworten in den Kurztests und Hilfsmaterial auf Basis der Auswahl der Studierenden ohne zugrundeliegenden KI-Algorithmus bereit. Dabei sammelt es Daten und kann – sobald eine hinreichende Güte in der Klassifikation vorliegt – eigenständig individualisierte Vorschläge für Hilfsmaterial und Feedback geben sowie die Aufgaben an die Kompetenzen der Lernenden anpassen. Im Verlauf eines Semesters können die Studierenden – ähnlich wie bei KI4S'Cool – ihre Lernentwicklung beobachten.

Die während des ersten Semesters in KI4TUK generierten Daten werden in RATsApp perspektivisch auch für die darauffolgenden Laborpraktika in den MINT-Fächern bereitgestellt. Um Kompetenzen im reflexiven Umgang mit Daten oder bei Interpretation und Transfer von Repräsentationen

einzuschätzen sowie Lern- und Problemlösestrategien mittels KI zu erkennen, werden dabei physiologische (Herzratenvariabilität, Hautleitwert, EEG) oder verhaltensbasierte Daten (Blickdaten) genutzt. Eine erfolgreiche Vorhersage des Lernerfolgs in den universitären Laborpraktika erlaubt es anschließend, die Hilfsmaterialien als Augmented Reality-Visualisierungen KI-basiert anzupassen. Bringen Studierende geringeres Vorwissen mit und betrachten während eines Experiments längere Zeit ein Gerät, so lässt sich eine zusätzliche Erklärung, etwa über die Funktion des Geräts, unmittelbar über die Augmented Reality-Brille in das Blickfeld einblenden. Ebenso wäre es möglich, relevante Komponenten, welche die Lernenden beim Experimentieren eventuell vernachlässigt haben, farblich hervorzuheben.

Aktuelle Herausforderungen

Neben allgemeinen Problemen von KI ergeben sich bei ihrem Einsatz für Lehren und Lernen spezifische Herausforderungen: Im Vergleich zu Anwendungen wie der Bilderkennung werden KI-Algorithmen in der Lehr-Lern-Forschung meist mit personenbezogenen (eventuell sogar physiologischen und somit medizinisch relevanten) Daten trainiert und fällen auf dieser Basis Entscheidungen. Dadurch kommen grundlegende rechtliche und ethische Aspekte ins Spiel. Nicht zuletzt ist es notwendig, die Vorgaben der Datenschutzgrundverordnung (DSGVO) vor und nach der Datenerhebung einzuhalten. Hier gilt es, die Zustimmung der Teilnehmenden zur Datenerhebung, -analyse und -speicherung sowie anonymisierten Veröffentlichung einzuholen. Zudem haben die Datenspende:innen das Recht, die Grundlage einer algorithmischen Entscheidung, die sie stark beeinträchtigt, zu erfahren [10]. Die Regelung fordert somit eine erhöhte Transparenz bei algorithmischen Entscheidungen, um eine „black-box society“ oder eine Diskriminierung durch Algorithmen zu vermeiden [10]. KI-basierte Systeme sind somit mit einer größtmöglichen Transparenz zu entwickeln, um eine gute Verständlichkeit zu gewährleisten.

In der empirischen Bildungsforschung sind Daten unmittelbar an Lernende und Lehrende geknüpft, d. h. in der

Regel „erzeugt“ eine Person einen Datenpunkt, da von einer Person allein oft nicht auf andere geschlossen werden kann. Durch den bereits oben beschriebenen Umstand der Datenaufnahme steigt der Aufwand entsprechend deutlich mit zunehmender Anzahl an Datenpunkten, die notwendig für eine gute Performanz von KI-Algorithmen sind. Häufig kommen in der Lehr-Lern-Forschung solche Algorithmen auch bei unzureichend großen Datensätzen zum Einsatz. Das kann zu einer zufällig hohen Abschätzung der Vorhersagegenauigkeit führen, selbst wenn kein Zusammenhang zwischen Eingabegrößen und Zielgröße gegeben ist. Gleichzeitig mangelt es noch an etablierten Verfahren, welche die notwendige Anzahl an Trainingsdaten etwa für eine gültige Klassifikation vorab bestimmen. Es ließ sich zeigen, dass neuronale Netze bei kleinen Datenmengen schlechter abschneiden als weniger komplexe Algorithmen (z. B. „Support Vector Machine“ oder „Random Forest“), da diese weniger Parameter haben und dadurch weniger Daten zur optimalen Einstellung benötigen [8].

Der Einsatz von KI-Algorithmen findet häufig explorativ statt, d. h. Messdaten sind zwar so eingebunden, dass die Vorhersage des Lernerfolgs oder die Anpassung an Lernende maximiert wird, aber lerntheoretische Rahmenmodelle (wie die Theorie des multimedialen Lernens) unbeachtet bleiben. Eine wesentliche Vorgehensweise physikdidaktischer Bildungsforschung ist allerdings, theoriebasiert Hypothesen zu generieren, die sich anschließend in Studien testen lassen. Wenn etwa mehrere unabhängige Studien eine theoretische Vorhersage bestätigen, ist es möglich, mehrere Arbeiten eines Themas im Rahmen von Meta-Analysen quantitativ zu vergleichen und übergreifende Aussagen zu identifizieren. Damit sind KI-Methoden allerdings teilweise schwer vereinbar, weil hier der Algorithmus selbstständig Schwellenwerte bei Parametern festlegt und oft eine Reihe von Datentypen zur Optimierung der Vorhersage integriert. Damit bleibt die Vorgehensweise bei Lehren und Lernen auf KI-Basis weitgehend explorativ. Sobald jedoch ein adaptives Lernsystem trainiert ist, d. h. die prädiktiven Parameter unverändert bleiben, ist eine hypothesenbasierte Vorgehensweise einfacher umsetzbar.

Lakes statt Leakes

In den letzten Jahren haben sich mehrere vielversprechende Ansätze entwickelt, KI-Methoden beim Lehren und Lernen von Physik und perspektivisch in der (hoch-)schulischen Lehre zu integrieren. In der schulischen Bildung zeigen Beispielprojekte wie KI4S'Cool oder LPA, wie sich KI-Methoden erfolgreich in der Schule einsetzen lassen. In der universitären Lehre existieren bereits KI-basierte Systeme wie RATsApp, die den Schwerpunkt darauf legen, potenzielle Studienabbruchsgruppen zu identifizieren und zu unterstützen sowie die disziplinspezifische Problemlösekompetenz zu fördern. Auch wenn sich diese Systeme bereits im Einsatz befinden, sind sie noch in einem frühen Stadium der Entwicklung. Daher ist eine kontinuierliche Begleitforschung erforderlich, um Optimierungsbedarfe zu erkennen und umzusetzen, da sie die bereits angesprochenen generellen Herausforderungen bei der Implemen-

tierung meistern müssen. Diese ist generell bei KI-Algorithmen aufwändig und komplex, allerdings stellen sich im Bildungsbereich durch die Erhebung personalisierter Daten, den zumeist kleinen Datensätzen und der explorativen Vorgehensweise zusätzliche Herausforderungen, teilweise bereits vor einer Implementation bzw. Datenerhebung. Eine mögliche Erleichterung bei der Datenerhebung ist beispielsweise die Einrichtung von sogenannten Data-Lakes. Dabei handelt es sich um Lehrveranstaltungen oder ganze Einrichtungen, in denen regelmäßige und systematische Datenerhebungen zum Training von KI-Systemen stattfinden – bei gleichzeitiger Beachtung datenschutzrechtlicher und ethischer Grundsätze. Dies könnte den Aufwand beim Gewinnen der Daten reduzieren. Abgesehen davon sollten Lehrkräfte und Dozierende für eine erfolgreiche Implementation von Co-Teaching- und Assisted-Learning-Ansätzen in der Schule entsprechend geschult werden [11].

Literatur

- [1] Statistiken von Moodle finden sich auf <https://stats.moodle.org>
- [2] E. Kasneci et al., Learn. Individ. Differ. **103**, 102274 (2023)
- [3] Deutsche Telekomstiftung (Hrsg.), Schlussbericht – KI@Bildung, <https://bit.ly/45OKBrB>
- [4] S. Küchemann et al., Phys. Rev. Phys. Educ. Res. **19**, 020128 (2023)
- [5] www.ki4scool.com
- [6] Projekte zu Learning Progression Analytics: www.ipn.uni-kiel.de/de/forschung/projekte/learning-progression-analytics
- [7] S. Becker et al., Phys. Rev. Phys. Educ. Res. **18**, 020107 (2022)
- [8] S. Küchemann et al., Proc. CSEDU, **1**, 6 (2020), <https://doi.org/10.5220/0009359400360046>
- [9] <https://ki4tuk.eit.uni-kl.de>
- [10] B. Goodman und S. Flaxman, AI Magazine **38**, 50 (2017)
- [11] S. Küchemann, A. Dengel und J. Kuhn, Bildung und Erziehung **74**, 313 (2021)

Die Autoren



Stefan Küchemann ist seit 2022 akademischer Rat am Lehrstuhl Didaktik der Physik der LMU München. In seiner Nachwuchsgruppe entwickelt und erforscht er KI-basierte Lernumgebungen und Prinzipien der Personalisierung auf Basis von Charakteristika von Lernenden und Eyetracking-Daten.

Steffen Steinert ist wissenschaftlicher Mitarbeiter



und Doktorand am Lehrstuhl für Didaktik der Physik der LMU München. Seine Forschungsinteressen sind die Anwendung von Methoden des maschinellen Lernens in der Bildungsforschung und die Nutzung von Augmented Reality in physikalischen Experimenten zu Lehr- und Lernzwecken.

Jochen Kuhn (FV Didaktik der Physik) ist Universitätsprofessor (W3) und Leiter des Lehrstuhls für Didaktik der Physik der LMU München. Seine Forschungsschwerpunkte sind multiple Repräsentationen beim Lernen mit Multimedia (Augmented und Virtual Reality), Lehren und Lernen mit und über Künstliche Intelligenz und Eyetracking-Analysen.



Dr. Stefan Küchemann, Steffen Steinert, Prof. Dr. Jochen Kuhn, Fakultät für Physik, Lehrstuhl für Didaktik der Physik, Geschwister-Scholl-Platz 1, 80539 München