

Fluch oder Segen?

ALINA KÖCHLING • SHIRIN RIAZY

Nicht nur in Online-Kursen werden immer mehr Daten über die und von den Teilnehmenden gesammelt. Diese Daten können mithilfe von Learning-Analytics-Programmen ausgewertet und verwendet werden, um Lernen zu personalisieren und Probleme in individuellen oder auch institutionellen Lernkontexten zu lösen.

Vermehrt nutzen Bildungseinrichtungen digitale Lernplattformen zur Erweiterung des Unterrichts. Bekannte Anbieter von komplexen webbasierten Infrastrukturen sind beispielsweise *Moodle*, *WebWeaverSchool*, *lo-net²* und *itslearning*. Diese Lernplattformen ermöglichen vor allem den Austausch der Lernenden untereinander und mit den Lehrenden, die Dateiablage und die Erstellung von Wikis und Arbeitsplänen. Häufig besteht auch die Möglichkeit der Einbindung von E-Content, der von Verlagen bereitgestellt wird. Einige Bildungseinrichtungen nutzen die digitalen Lernplattformen zum Teil auch, um Tests oder E-Klausuren online stellen zu lassen.

Durch die zunehmende Digitalisierung in Bildungseinrichtungen und die damit einhergehende Nutzung von digitalen Lernplattformen fallen Unmengen an Daten über den Lernprozess, den Lernfortschritt und das Lernergebnis sowie über die Lernenden selbst an. So dokumentiert bspw. die an vielen Schulen und Hochschulen genutzte Lernumgebung Moodle, welche Lernenden wann und wie oft auf einzelne Lehrmaterialien zugegriffen haben und mit welchem Erfolg elektronische Tests absolviert wurden. In ergänzenden Systemen, z. B. Verwaltungsdatenbanken, wird der Fortschritt in der Bildungslaufbahn von der Einschreibung über das Belegen und Bestehen von Lehrveranstaltungen bis hin zum Erreichen des Bildungsziels (Vergabe eines Abschlusses bzw. Titels) dokumentiert.

Systematische Analyse erhobener Daten: Vorteile von Learning Analytics

Die entstehende Datenfülle macht den Lehrenden eine individualisierte manuelle Auswertung sämtlicher Daten unmöglich. Durch den Einsatz moderner, computergestützter Verfahren – Learning Analytics, kurz: LA – besteht allerdings die Möglichkeit, diese Daten automatisiert auszuwerten. Unter Learning Analytics verstehen wir die systematische Analyse großer Datenmengen zu Lernenden, Lehrenden und Lernprozessen, mit dem Ziel, den Lernerfolg zu steigern und Lehre effektiver und effizienter zu gestalten. Bei LA wird der Fokus dabei auf die Lernenden und ihr Lernverhalten gelegt. Konkret finden dabei Gruppierungen der Lernenden statt, beispielsweise anhand von lernbezogenen Merkmalen oder Prognosen des Lernerfolgs. Darüber hinaus wird nach latenten Zusammenhängen zwischen dem Lernerfolg und anderen Variablen gesucht, um den Lernerfolg zu steigern und künftige Lernangebote zu verbessern (Baker & Inventado, 2014).

Bei den Analysen greifen Lehrende auf algorithmenbasierte Softwares zurück, die erhobene Daten zueinander ins Verhältnis setzen und Auswertungen vornehmen – und damit Voraussagen treffen. Daten, die algorithmisch ausgewertet werden, können den Lernprozess selbst betreffen (betrachtete Lernmaterialien, durchgeführte Übungen, benötigte Zeit,

Anzahl der Wiederholungen), es sind aber auch Kennzahlen, die den Lernerfolg (erzielte Punkte, richtige Lösungen, abgeschlossene Prüfungen) und die Lernenden an sich betreffen (demografische Merkmale, Lerntyp und Interaktionstyp; Rubel & Jones, 2016). Die Analyse dieser Daten ermöglicht die Individualisierung von Lernsettings und die Bewältigung von institutionellen Lehr- und Lernproblemen beispielsweise durch eine frühzeitige Identifizierung jener Lernenden, die Gefahr laufen, den Kurs oder das Studium abzubrechen, und die von gezielten Interventionen, wie z. B. persönlichen Gesprächen, Senkung des Aufgabenniveaus und individuelle Lernmaßnahmen, profitieren könnten (Gašević et al., 2016).

»Anwendungen des maschinellen Lernens basieren zum Teil auf unausgewogenen Trainingsdaten.«

Vermehrt basieren LA-Systeme auf Methoden des maschinellen Lernens, sprich auf Berechnungsformeln, die autonom Voraussagen und Entscheidungen auf der Grundlage von vorher festgelegten Regeln und statistischen Modellen treffen. Dabei wird unter anderem Maschinelles Lernen angewendet, um mithilfe von statistischen Berechnungen effektiv Muster in den Daten zu erkennen und zu klassifizieren: Die Algorithmen lernen dabei, aus Beispielmustern, so genannten Trainingsdaten, bestimmte Schlüsse zu ziehen, die dann auf größere Datenmengen angewendet und verallgemeinert werden können. Aus Sicht der Anwender handelt es sich dabei häufig um so genannte Black-Box-Systeme, bei denen schwer nachvollziehbar ist, welche Verarbeitungsschritte die Daten durchlaufen und welche Konsequenzen das hat – d. h., es bleibt oftmals unklar, wie das System letztlich zu seiner Voraussage kommt.

Die Anwendung von LA ist sowohl für die Lehrperson als auch für die Lernenden mit vielen Vorteilen verbunden. Zum Beispiel ermöglichen LA-Systeme ein besseres Verständnis des Lernprozesses durch Informationen, z. B. wann gelernt wird und wie oft. Damit einher geht eine bessere Ausrichtung auf die individuellen Bedürfnisse der Lernenden (z. B. Lernstrategien, Leseempfehlungen, Tutorien), spezifisches Feedback sowie die Verbesserung der Lernumgebung, wie z. B. angepas-

tes Lernmaterial und spezifische Lernaufgaben (Schumacher & Ifenthaler, 2018). Durch die Vernetzung von Lernenden und Lehrenden bieten LA-Systeme darüber hinaus Möglichkeiten des Wissensaufbaus, der Selbstreflexion sowie der selbstregulierenden Lernprozesse (Knight, Shum & Littleton, 2014). Ein weiterer Vorteil von LA ist die schnelle Identifizierung von Lernschwächen und die damit einhergehende Erarbeitung von proaktiven Handlungsempfehlungen (Gašević et al., 2016). LA-Systeme ermöglichen ferner, Lernangebote individuell anzupassen und so den Lernerfolg wahrscheinlicher zu machen.

Risiken und Nachteile

Aktuelle Datenverarbeitungsmethoden bergen jedoch Risiken (Noble, 2018), denn Anwendungen der Methoden des maschinellen Lernens basieren zum Teil auf unausgewogenen Trainingsdaten, was wiederum zu unausgewogenen, möglicherweise diskriminierenden Vorhersagen führt (Dressel, 2018). Datensätze können zum Beispiel unausgewogen sein in Hinblick auf Alter, Geschlecht, Sexualität etc. Eine differenzierte Behandlung von Einzelpersonen auf Grundlage ihrer (z. B. ethnischen, geschlechtlichen oder altersspezifischen) Gruppenzugehörigkeit kann als Diskriminierung angesehen werden, wenn diese Einzelpersonen dadurch in irgendeiner Weise benachteiligt werden (Scholes, 2016). In einem unausgewogenen Trainingsdatensatz könnte es beispielsweise vorkommen, dass sämtliche weiblichen Lernenden schlechtere Noten haben als männliche Lernende. Der Algorithmus könnte darin eine Struktur erkennen und schlussfolgern, dass weibliche Lernende (aufgrund ihres Geschlechts!) grundsätzlich schlechtere Ergebnisse erzielen, und auf dieser Basis Prognosen treffen. Der Algorithmus unterscheidet nicht zwischen Korrelation und Kausalität, denn offensichtlich implizieren weder Geschlecht noch Alter oder Ethnizität notwendigerweise eine besonders gute oder schlechte Leistung.

Selbst wenn demografische Merkmale nicht erhoben werden, können sich in Daten Strukturen befinden, die die Lernenden implizit als Teil einer demografischen Gruppe identifizieren (Kamishima et al., 2012). Beispielsweise wurde gezeigt, dass Menschen je nach Alter Lernplattformen unterschiedlich nutzen und ein unterschiedliches Klickverhalten haben. Jemanden aufgrund der Geschwindigkeit seines Klickverhaltens als leistungsschwach einzuordnen, könnte eine versteckte Benachteiligung älterer Plattformnutzer sein.

Prognosen könnten weiterhin dahingehend ungenau sein, dass die Bewertung nicht allein auf (Prüfungs-)Ergebnissen (oder kompetenzbasierten Merkmalen) beruht, sondern auf dem gemessenen Prozess. In den gemessenen Daten fehlen jedoch wesentliche Merkmale, internale sowie externale Unterrichtsbedingungen, die nicht in algorithmischen Auswer-

tungen berücksichtigt werden können: Lernende, die hauptsächlich offline lernen, könnten z. B. benachteiligt werden, da LA-Systeme nicht analysieren können, welche Ressourcen und Lernaktivitäten offline genutzt worden sind, was wiederum eine Diskriminierung dieses Lerntyps ist (Jones & Salo, 2018). Prinzipiell werden womöglich Lernende, die nicht technologieaffin sind, benachteiligt, denn sie haben bereits von vornherein größere Probleme mit der Anwendung der digitalen Lernplattform. Darüber hinaus wird in den Daten wenig über das Instruktionsdesign, den sozialen Kontext der Lernenden, deren Lerngeschichte und mögliche Revisionen im Lehrinhalt festgehalten (Gašević, 2016) – was aber alles Auswirkungen auf den Lernerfolg haben kann.

All dies kann dazu führen, dass Lernende fehlerhaft klassifiziert werden – z. B. als falsche Lerntypen oder als mögliche Abbruchkandidaten. Falsche Klassifizierungen der Lernenden bergen in jedem Fall Gefahren, da sie zu einer Adaption des Lernmaterials oder zu Interventionen führen können, die unangemessen sind und den Lernenden unter- oder überfordern können. Damit würde LA sein Ziel nicht nur verfehlen, sondern zusätzlichen Schaden verursachen.

Die Prognosen und das Wissen um solche Prognosen beeinflussen zudem das Verhalten der Lernenden gegenüber anderen Lernenden und den Lehrenden. Jene, denen bewusst ist, dass ihr Verhalten überwacht wird, versuchen, ihren Fortschritt zu »beweisen«, z. B. indem sie sich vermehrt in das System einloggen, Lernmaterialien herunterladen oder sich verstärkt an Diskussionen im Diskussionsforum beteiligen (Knight, Shum & Littleton, 2014). Trotz dieser möglichen Fehlentwicklungen erfordert ein ethischer Umgang mit Lernenden, dass man sie stets als Mitentscheidende ansieht und in die Nutzung ihrer Daten einbezieht (Slade & Prinsloo, 2013).

Ethisch und pädagogisch sinnvoller Umgang mit Daten und Learning Analytics

Mit der Möglichkeit der algorithmischen Datenauswertung und dem damit einhergehenden Diskriminierungspotenzial ergeben sich auch ethische Fragen, nicht zuletzt im Umgang mit den erhobenen Daten. Um Bedenken frühzeitig entgegenzuwirken, sollte ein Fokus beim Einsatz von Learning Analytics auf der Datenschutzfrage liegen, die unter anderem Dateninterpretation, Dateneinwilligung, Datenschutzaufklärung, Datenidentifikation, Datenverwaltung und Datenspeicherung beinhaltet (Rubel & Jones, 2016; Schumacher & Ifenthaler, 2018; Slade & Prinsloo, 2013).

Falls LA-Systeme breitere Anwendung in einer Bildungseinrichtung finden, sollte darauf geachtet werden, dass der Umgang mit den Informationstechnologien bedacht und transparent erfolgt, denn LA nutzt hochsensible Daten, um ef-

fizient zu funktionieren. Hilfreich dabei sind klar formulierte Grundsätze und die höchsten Datenschutzstandards (Drachler & Greller, 2016). Für eine ethische vertretbare Umsetzung existieren Verhaltenskodizes, wie beispielsweise die DELICATE-Checkliste von Drachler und Greller (2016) oder Jisc (2015)¹. Wesentliche Punkte beinhalten hier die ausschließliche Nutzung der Daten für autorisierte Bildungszwecke und strenge Richtlinien für die Datenspeicherung (Knight, Shum & Littleton, 2014; Sclater, 2017). Zudem ist es förderlich, die Lernenden mit in den Prozess einzubeziehen und sie über die Erfassung ihrer Daten sowie die angewendeten Algorithmen zu informieren und ihnen Wahlmöglichkeiten bei der Erhebung und Verwendung der Daten zu geben (Rubel & Jones, 2016).

Auf die Gefahr der Verstärkung und Verschleierung von bestehenden Verzerrungen und impliziter Benachteiligung wird in den Verhaltenskodizes zwar aufmerksam gemacht, allerdings fehlt es bislang an Methoden und konkreten Handlungsanweisungen zur Überprüfung genutzter Daten auf ihre Eignung für Vorhersagemodelle (Slade & Prinsloo, 2013; Kamishima et al., 2012). Es ist wichtig, dass vor der Implementierung ausreichend geprüft wird, in welcher Form Daten ausgewertet werden sollen, welche Daten mit in die Auswertung einfließen und inwiefern diese Daten als Bewertungshilfe dienen sollen.

Bei der Implementierung von digitalen Lernplattformen sowie bei der Anwendung sollte bedacht werden, dass Technologien allein nicht die Praxis bestimmen sollten. Nachteile und Risiken maschineller Auswertungen und Vorhersagen sollten daher von Bildungsinstitutionen bei der Implementierung und Anwendung bedacht werden, denn nicht alles, was effektiv ist, ist auch moralisch vertretbar.² Zusätzlich zu algorithmischen Bewertungen sollten zudem bei Unsicherheit andere Beratungsquellen hinzugezogen werden – beispielsweise die Lehrkräfte.

Fazit

Durch den Informationsgewinn, den Learning Analytics bieten, ist es möglich, den Unterricht auf die Lernenden maßzuschneidern und frühzeitig einzugreifen, wenn der Lernerfolg gefährdet ist. Somit können Fluktuationen verhindert und Bildungsziele gefördert werden (Rubel & Jones, 2016). Durch die Erhebung und Nutzung z. T. hochsensibler Daten besteht jedoch auch die Gefahr der Diskriminierung, beispielsweise in Bezug auf das Geschlecht, Ethnizität, Alter, Behinderung

¹ www.jisc.ac.uk/guides/code-of-practice-for-learning-analytics

² Hier ist zum Beispiel an den Einsatz von Gesichtserkennung im Klassenzimmer zu denken, wie es in China z. T. eingesetzt wird: Kameras überwachen die Schülerinnen und Schüler und bewerten anhand ihrer Mimik, ob sie z. B. unaufmerksam oder abgelenkt sind (www.telegraph.co.uk/news/2018/05/17/chinese-school-uses-facial-recognition-monitor-student-attention/).



oder auch Lerntyp. Die Diskriminierung durch Daten kann deshalb besonders folgenreich sein, weil KI-basierte Systeme vermeintlich objektiv entscheiden, die Diskriminierung damit unerwartet und weniger transparent ist und potenziell tausende Lernende in gleicher Art treffen würde.

Um dies zu verhindern, tragen die Nutzerinnen und Nutzer der Software – seien es Mitarbeiterinnen und Mitarbeiter in Verwaltung und Studienberatung, sei es planendes Personal oder seien es Lehrende – eine besondere Verantwortung: Sie müssen bestrebt sein, eigene Vorurteile zu hinterfragen, chancengerechte Lernumgebungen zu schaffen und objektiv Bewertungen zu vergeben. Wenn LA-Systeme Anwendung finden, sollten ihre Vorteile genutzt werden, sie sollten jedoch nur zur Beratung herangezogen werden und nicht alleine Prognosen treffen.

»Die Nutzer von Learning-Analytics-Software tragen eine besondere Verantwortung.«



ALINA KÖCHLING

ist wissenschaftliche Mitarbeiterin an der Heinrich-Heine-Universität Düsseldorf an der Juniorprofessur für Unternehmensführung und Mitarbeiterin des Forschungsprojekts LADI (Learning Analytics und Diskriminierung).

Alina.Koechling@hhu.de



SHIRIN RIAZZY

ist wissenschaftliche Mitarbeiterin an der Hochschule für Technik und Wirtschaft Berlin im Fachbereich Informatik, Kommunikation und Wirtschaft und Mitarbeiterin des Forschungsprojekts LADI (Learning Analytics und Diskriminierung).

Shirin.Riazzy@HTW-Berlin.de

Baker, R.S. & Inventado, P.S. (2014). Educational data mining and learning analytics. In J. A. Larusson & B. White (Hrsg.), *Learning Analytics: from Research to Practice* (S. 61–75). New York, NY: Springer.

Drachler, H. & Greller, W. (2016, April). Privacy and analytics: it's a DELICATE issue. A checklist for trusted learning analytics. In *Proceedings of the sixth international conference on learning analytics & knowledge* (S. 89–98). ACM.

Dressel, J. & Farid, H. (2018). The accuracy, fairness, and limits of predicting recidivism. *Science advances*, 4(1), eaa05580.

Gašević, D., Dawson, S., Rogers, T. & Gasevic, D. (2016). Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. *The Internet and Higher Education*, 28, 68–84.

Jisc (2015). *Code of Practice for Learning Analytics*. www.jisc.ac.uk/guides/code-of-practice-for-learning-analytics.

Jones, K.M. & Salo, D. (2018). Learning analytics and the academic library: Professional ethics commitments at a crossroads. *College & Research Libraries*, 79(3), 304–323.

Kamishima, T., Akaho, S., Asoh, H. & Sakuma, J. (2012). Fairness-aware classifier with prejudice remover regularizer. In *Joint European Conference on Machine Learning and Knowledge Discovery in Databases* (S. 35–50). Berlin, Heidelberg: Springer.

Knight, S., Shum, S.B. & Littleton, K. (2014). Epistemology, assessment, pedagogy: where learning meets analytics in the middle space. *Journal of Learning Analytics*, 1(2), 23–47.

Noble, S.U. (2018). *Algorithms of oppression: How search engines reinforce racism*. New York, NY: nyu Press.

Rubel, A. & Jones, K.M. (2016). Student privacy in learning analytics: An information ethics perspective. *The Information Society*, 32(2), 143–159.

Scholes, V. (2016). The ethics of using learning analytics to categorize students on risk. *Educational Technology Research and Development*, 64(5), 939–955.

Schumacher, C. & Ifenthaler, D. (2018). Features students really expect from learning analytics. *Computers in Human Behavior*, 78, 397–407.

Sclater, N. (2017). *Learning Analytics Explained*. London: Routledge.

Slade, S. & Prinsloo, P. (2013). Learning analytics: Ethical issues and dilemmas. *American Behavioral Scientist*, 57(10), 1510–1529.