

Garbage in, Gospel out?

Ein Diskussionsbeitrag zum Verhältnis von Aufgabenstellungen und Learning Analytics in der geographischen Bildung

Christian Dorsch

Geographiedidaktik

Universität Osnabrück

cdorsch@uni-osnabrueck.de

Luis Schäfer

Lessinggymnasium Frankfurt

luis.schaefer@t-online.de

Detlef Kanwischer

Geographiedidaktik

Goethe-Universität Frankfurt

kanwischer@geo.uni-frankfurt.de

angenommen nach doubleblind-Review-Verfahren

Abstract:

Learning Analytics (LA) provides insights into learning processes and promotes the development of applications that support teachers and learners as well as providing institutions with data for educational planning. This paper shows how algorithms mediate between the actors and thereby influence both the structure of the mediation and the actions themselves. Finally, it discusses what knowledge, skills and attitudes teachers and learners need to responsibly handle LA data in geographical education.

Keywords: learning analytics, data literacy, algorithms, digitality

Learning Analytics (LA) bietet Einblicke in Lernprozesse und fördert die Entwicklung von Anwendungen, die Lehrende und Lernende unterstützen sowie Institutionen Daten für die Bildungsplanung liefern. Der Beitrag zeigt, wie Algorithmen zwischen den Akteur*innen vermitteln und dabei sowohl die Struktur der Vermittlung als auch die Handlungen selbst beeinflussen. Abschließend wird diskutiert, welches Wissen, welche Fähigkeiten und Einstellungen Lehrende und Lernende für einen kritisch-reflexiven Umgang mit LA-Daten in der geographischen Bildung benötigen.

Stichwörter: Learning Analytics, Data Literacy, Algorithmen, Digitalität

1. Die Algorithmisierung der Bildung

Die Entwicklung von ChatGPT und anderen Multimodal Large Language Models reißen sich in eine Reihe von Innovationen ein, die in den letzten Jahren in den Bereichen der KI entwickelt wurden. Hierbei werden Kulturtechniken im Bildungsbereich algorithmisiert, was die Logik des Lernens grundlegend verändern kann. Ein anderes Beispiel, das schon seit über zehn Jahren im Bildungsbereich diskutiert wird und vielfältige Anwendungsszenarien offeriert, ist das Feld der Learning Analytics (LA). Im Kern geht es hierbei darum, dass Daten von Lernenden und ihren Lernkontexten erhoben, aggregiert, analysiert, ausgewertet und interpretiert werden. LA stützt sich unter anderem auf Theorien und Methoden der *data science* und des *machine learning*, der Bildungswissenschaft, der kognitiven Psychologie, der Statistik und Informatik (Joksimović, Kovanović & Dawson, 2019: 39). Ziel ist es, Lernprozesse besser zu verstehen und zu unterstützen (Wise, 2019: 119). Hierbei sind drei Interessengruppen für die Anwendung von LA zu nennen: Regierungen bzw. Bildungsträger, Lehrer*innen sowie Schüler*innen (Ferguson, 2012: 307). Für Regierungen bzw. Bildungsträger ist vor allem die Anwendbarkeit auf Herausforderungen im Bildungssystem von Interesse. Die wachsende Diversität der Schüler*innenschaft in Verbindung mit geringeren Bildungsausgaben steigern den Bedarf an kostenökonomischen Formen von Bildung, die gleichzeitig die Qualität des Unterrichts beibehalten, wenn nicht sogar erhöhen (Joksimović et al., 2019: 38). Dies führt zu größeren Klassen und der Anwendung neuer Technologien zur Wissensvermittlung. Learning Analytics greifen auf die in diesen Settings entstehenden Daten

zurück, um frühzeitige Indikatoren für den Lernerfolg der Schüler*innen zu generieren. Aus Sicht der Lehrenden kann durch Learning Analytics überprüft werden, ob Aufgaben wie geplant ablaufen und welche Gruppen von Lernenden besondere Unterstützung benötigen. Aus Sicht der Lernenden können Learning Analytics eine Grundlage bieten, um eigene Lernprozesse zu reflektieren und gegebenenfalls anzupassen (Wise, 2019: 119–120).

Die Daten werden insbesondere von Schul- bzw. Hochschulverwaltungssystemen auf der organisationalen Ebene und von Lernmanagementsystemen (LMS) auf der Ebene des Unterrichts bereitgestellt. Die digitalen Interaktionen und ‚Fußspuren‘, welche die Lernenden in diesen Systemen hinterlassen, sind die Basis für die algorithmische Auswertung. Dies reicht von simplen Messungen der Interaktionszeit mit Lernbausteinen bis hin zur Analyse der Aufgabenbearbeitung. Neben der Unterstützung von Lehrenden und Lernenden soll LA Bildungseinrichtungen aber auch umfangreiche Datenmengen zur Verfügung stellen, um deren Produktivität zu erhöhen. Hierbei vermitteln Algorithmen zwischen den verschiedenen Handlungsträger*innen und beeinflussen dabei sowohl die Struktur und Organisation der Vermittlung als auch die Handlungen selbst, zum Beispiel in der Art und Weise, wie Lerninhalte vermittelt werden oder Entscheidungen über Schul- und Studienverläufe getroffen werden.

Nach diesem allgemeinen Überblick über die Entwicklungen im Bereich der KI und speziell von LA, werden wir im weiteren Verlauf ein konkretes Anwendungsbeispiel aus dem weitreichenden Bereich der LA thematisieren. Anhand des Aufgabenbeispiels „Wheelmap“ aus den Bildungsstandards Geographie verfolgen wir das Ziel, die Implikationen des Einsatzes

von LA insbesondere für die Entwicklung von Aufgabenstellungen in der geographischen Bildung kritisch zu reflektieren. Hieraus leitet sich die Fragestellung ab, inwiefern der Einsatz von LA die Gestaltung von Aufgaben und Lernprozessen in der geographischen Bildung verändern könnte.

2. Modellierung von Learning analytics am Aufgabenbeispiel „Wheelmap“

Für einen Einsatz von Learning Analytics im Fach Geographie werden wir erste Überlegungen über eine mögliche Implementierung entlang eines Aufgabenbeispiels aus den Bildungsstandards der DGfG diskutieren. Unser Fokus liegt hierbei auf der Aufgabenstellung und den damit verknüpften Kompetenzziele. In den Bildungsstandards werden Aufgabenbeispiele formuliert, die zur gezielten Förderung der in den Standards enthaltenen Kompetenzen eingesetzt werden können. Stellvertretend für den Kompetenzbereich *Räumliche Orientierung* wird das Aufgabenbeispiel „Wheelmap – Inwiefern kann eine digitale Karte das Leben von Rollstuhlfahrerinnen und Rollstuhlfahrern

erleichtern?“ (Deutsche Gesellschaft für Geographie e. V. [DGfG], 2020: 67–72) ausgewählt und exemplarisch geprüft, wie ein auf LA basierendes System in diesem Kontext implementiert werden könnte. Dafür soll zunächst veranschaulicht werden, nach welcher Logik solche Systeme konzipiert werden. Eine etablierte Konzeption für die Entwicklung von LA Anwendungen ist der Learning Analytics Cycle von Clow (2012) (vgl. Abb. 1).

Der Zyklus besteht aus vier Elementen und beginnt mit den Lernenden. Clow (2012: 134–135) beschreibt die Schritte wie folgt: Von den Lernenden ausgehend, ist der erste Schritt das Generieren und Sammeln von Daten, um eine entsprechende Datengrundlage zu schaffen. Darauf folgt das Prozessieren der Daten. Diese werden entweder in Metriken dargestellt oder durch Analyseverfahren weiterverarbeitet, um Erkenntnisse über das Lernen zu erlangen. Als Beispiele nennt Clow hierfür 1) Visualisierungen, 2) Anzeigen, 3) Listen von Lernenden, bei denen ein erhöhtes Risiko besteht, nicht zu bestehen, 4) Vergleich von Standards und erbrachten Leistungen sowie 5) Aggregationen. Vervollständigt wird der Zyklus durch die Ent-




Abb. 1: Der Learning Analytics Cycle (nach Clow, 2012: 134)

wicklung von Interventionen, welche sich wiederum auf die Lernenden auswirken.

Ziel des Aufgabenbeispiels „Wheelmap“ ist die Förderung von Kompetenzen insbesondere im Kompetenzbereich der Räumlichen Orientierung. Im Anschluss an Clow (2012) werden Szenarien entwickelt, wie LA eingesetzt werden kann, um Kompetenzen zu überprüfen. Die Aufgabe verlangt von den Schüler*innen sich in Menschen, die auf einen Rollstuhl angewiesen sind, hineinzusetzen. Dabei sollen sie sich mit der Online-Karte „Wheelmap“¹ (wheelmap.org) auseinandersetzen, die für zahlreiche Orte den Grad der Barrierefreiheit für Rollstuhlfahrer*innen anzeigt. Das Aufgabenbeispiel umfasst eine Situations- bzw. Problembeschreibung, fünf Aufgaben und einem tabellarischen Erwartungshorizont. Im Erwartungshorizont werden zusätzlich die Kompetenzen und Standards aufgelistet, die durch die Aufgaben gefördert werden sollen und in demselben Dokument definiert sind. Das Aufgabenbeispiel fördert den Erwerb dieser Kompetenzen. Dieser ist aber nicht nach Beendigung der Aufgabe abgeschlossen. Die Performanz beim Lösen der Aufgabe lässt aber Rückschlüsse darauf zu, wie erfolgreich der weitere Kompetenzerwerb der Lernenden sein wird. Für die Anwendung von LA in Bezug auf die Aufgabe und den damit verknüpften Kompetenzerwerb bietet sich daher ein Vorhersagemodell an, welches Aussagen darüber trifft, ob Schüler*innen die angestrebten Kompetenzen und Standards der Räumlichen Orientierung voraussichtlich erreichen. Zudem sind solche Vorhersagemodelle bereits an Hochschulen implementiert, weswegen wir uns in diesem Artikel auf sie

fokussieren. Als Datengrundlage, dienen die erhobenen Daten, die während der Bearbeitung der Aufgabe entstehen. Das Vorhersagemodell würde dabei noch weitere zur Verfügung stehenden allgemeine Daten und Daten von anderen Aufgaben der Lernenden berücksichtigen. Für die Diskussion von LA im Kontext von Aufgabenstellungen reicht es jedoch aus, wenn wir uns nur auf dieses Aufgabenbeispiel beziehen.

Im Folgenden werden beispielhaft drei unterschiedliche Modellvariationen umrissen, die getrennt oder im Verbund eingesetzt werden können. Diese unterscheiden sich hauptsächlich durch den Referenzrahmen, der als Grundlage genommen wird. Weitere Variationen wären daher denkbar. Für jedes dieser Modelle muss der Learning Analytics Cycle entsprechend angepasst werden.

Modell 1

Modell 1 nimmt als Referenzrahmen den bereitgestellten Erwartungshorizont. Die dahinterstehende Idee ist, dass durch einen qualitativen Abgleich der erarbeiteten Ergebnisse der Schüler*innen und den vorgegebenen Ergebnissen des Erwartungshorizonts, sich Aussagen treffen lassen über die Erfüllung der Standards und Kompetenzen. Dies lässt sich in Form von zwei Prämissen formulieren:

- Prämissen 1: Die Qualität der Ergebnisse der Schüler*innen kann mithilfe eines Vergleichs (durch LA) mit dem Erwartungshorizont bestimmt werden.
- Prämissen 2: Die Qualität der Ergebnisse sind ein Indiz dafür, dass die Kompetenzen und Standards erreicht werden.

¹ „Wheelmap“ ist eine Initiative des Sozialhelden e. V. Berlin und abrufbar unter www.wheelmap.org

Die bei der Bearbeitung der Aufgabe entstehenden Artefaktdaten umfassen alle erarbeitenden Ergebnisse, die von einer Metrik erfasst und mit dem Erwartungshorizont verglichen werden können. Im Fall von Aufgabe 1 wird als Lernprodukt eine Tabelle gefordert („Beschreibe und vergleiche die Unterschiede beider Darstellungen [auf den Plattformen „Google Maps“ und „Wheelmap“, Anmer. der Verf.] und stelle diese in einer Tabelle mit jeweils von dir gewählten Oberbegriffen dar“). Mit Blick auf den nächsten Schritt ergibt sich hier jedoch schon eine Herausforderung. Bei der Aufgabe handelt es sich um eine halboffene Aufgabe. Während die generelle Struktur (Tabellenform) vorgegeben ist, so sind die Oberbegriffe frei wählbar und die Beschreibung individuell. Die Aufgaben sind also nicht auf den ersten Blick als richtig oder falsch zu werten. Nur weil Schüler*innen einen anderen Oberbegriff als vom Erwartungshorizont vorgegeben wählen, bedeutet dies nicht, dass die Antwort dadurch weniger richtig ist. Ein stumpfer Abgleich wäre daher nicht zielführend.

Eine Möglichkeit das Problem zu lösen, wäre die Aufgabe zu einer geschlossenen Aufgabe umzuwandeln. Denkbar wäre eine Tabelle mit vorgegebenen Oberbegriffen. Diese könnte möglicherweise in digitaler Form innerhalb eines LMS ausgefüllt werden, indem die Schüler*innen aus einer Reihe von Antwortmöglichkeiten, die richtigen Begriffe oder Beschreibungen auswählen. Dies würde die Messung vereinfachen, jedoch ist zu bezweifeln, ob auf Grundlage der Messung auf das gesetzte Kompetenzziel rückgeschlossen werden kann. Der Prämisse 2 nach besteht ein Zusammenhang zwischen der Qualität der Lösung der Aufgabe und dem Erreichen von Standards und Kompetenzen. Ändert sich nun die Aufgabe und somit

auch die Lösung, bleibt zu prüfen, ob dieser Zusammenhang noch besteht.

Eine andere Möglichkeit wäre zu versuchen durch den Einsatz von sogenannten *content analytics* der Individualität der potentiellen Antworten gerecht zu werden. Mit diesem analytischen Ansatz können Inhalte automatisiert erfasst, organisiert und klassifiziert werden (Kovanović, Joksimović, Gasevic, Hatala & Siemens, 2022: 79). Dafür könnte eine simple Metrik genutzt werden, die die Ergebnisse der Schüler*innen nach Stichworten untersucht. Der Erwartungshorizont müsste dabei entsprechend erweitert werden, um möglichst viele Schüler*innen Antworten abzudecken. Die eingesetzte Metrik könnte dadurch erkennen, welche Unterschiede in Form von Oberthemen aufgegriffen und ob diese richtig beschrieben wurden. Kritisch zu überprüfen ist dabei, ob Prämisse 1 bei dieser Option noch gültig ist. Erkennt die Metrik nun eine starke Abweichung zwischen den in der Aufgabe erzielten Ergebnissen und dem Erwartungshorizont kann daraus geschlossen werden, dass für die jeweiligen Schüler*innen die Gefahr besteht, die Kompetenzen und Standards im Kompetenzbereich *Räumliche Orientierung* nicht zu erreichen.

Während es für Aufgabe 1 plausibel erscheint durch den Einsatz von *content analytics* einen Vergleich zwischen Ergebnissen und Ergebnishorizont zu bewerkstelligen, so kann dies bei anderen offeneren Aufgaben komplizierter werden. So fordert Aufgabe 2b) („Beurteile, ob der von „Google Maps“ vorgeschlagene Weg rollstuhlgeeignet ist“) und 2c) („Finde mit Hilfe von „Wheelmap“ einen besser geeigneten Weg und zeichne ihn ein“) eine Beurteilung und eine Begründung von den Schüler*in-

nen auf Grundlage der individuell vorgefundenen Gegebenheiten. Neuere KI-Systeme, wie z. B. ChatGPT sind allerdings in der Lage Antworten von Schüler*innen auf offene Fragen zu kategorisieren und in ein Bewertungssystem zu überführen (Katz, Wei, Nanda, Brinton & Ohland, 2023). Eine Anpassung der Aufgaben zu einem geschlossenen Format ist hingegen nicht zielführend, da dieses der Komplexität der Forderungen an die Schüler*innen nicht gerecht würde.

Modell 2

Der Grundgedanke hinter Modell 2 ist, dass diejenigen Schüler*innen wahrscheinlich die Kompetenzen und Standards erfüllen werden, deren Ergebnisse Ähnlichkeiten aufweisen zu den Ergebnissen von Schüler*innen, die die Kompetenzen und Standards erreicht haben. Darauf aufbauend lassen sich folgende Prämissen formulieren:

- Prämissen 1: Die Ergebnisse von Schüler*innen lassen sich (durch LA) hinsichtlich ihrer Ähnlichkeit vergleichen.
- Prämissen 2a: Die Ergebnisse von Schüler*innen, die die Kompetenzen und Standards im Kompetenzbereich *Räumliche Orientierung* erreichen, weisen Ähnlichkeiten auf.
- Prämissen 2b: Die Ergebnisse von Schüler*innen, die die Kompetenzen und Standards im Kompetenzbereich *Räumliche Orientierung* nicht erreichen, weisen Ähnlichkeiten auf.

Bevor das eigentliche Modell implementiert wird, muss dem eine Phase vorangehen, in der der Referenzrahmen erhoben wird. Dies kann bewerkstelligt werden, indem Schüler*innen die Aufgaben regulär bearbeiten und ihre Ergebnisse erfasst und beurteilt werden. Die Ergeb-

nisse dieser Beurteilung werden als Daten mit den Ergebnissen der Aufgaben verknüpft. Als Referenzrahmen in Form von Artefaktdaten beziehungsweise Zugehörigkeitsdaten liegen nun die Aufgabenergebnisse von Schüler*innen zu Grunde, verbunden mit der Information, inwiefern sie die Kompetenzen und Standards erreicht haben.

Mithilfe des Referenzrahmens kann sich nun dem eigentlichen Modell gewidmet werden. Modell 2 nimmt wie Modell 1 Artefaktdaten als Datengrundlage. Nun ändert sich aber die Metrik. Zum Einsatz kommt das Analyseverfahren *structure discovery*, das nach Wise (2019: 125) dazu gebraucht wird, um hintergründige Verbindungen und Muster zwischen Variablen und Fällen zu erkennen. Übertragen auf das Beispiel bedeutet dies, dass bei Schüler*innen, deren Ergebnisse eine hohe Ähnlichkeit mit denen erfolgreicher Schüler*innen im Sinne des Kompetenzerwerbs aufweisen, eine höhere Wahrscheinlichkeit für Erfolg vorhergesagt wird als bei Schüler*innen, deren Ergebnisse eher denen weniger erfolgreicher Schüler*innen ähneln. Analog zu Modell 1 können dadurch Interventionen abgeleitet werden.

Modell 2 ist potentiell auf alle Aufgaben anzuwenden, die Artefaktdaten generieren. Im Gegensatz zu Modell 1 kann Modell 2 auch bei offenen Aufgaben wie 2b) und 2c) angewandt werden. Eine denkbare Schlussfolgerung beim Einsatz von *structure discovery* könnte sein, dass erfolgreiche Schüler*innen tendenziell längere Text als nicht erfolgreiche Schüler*innen schreiben. Daraus folgt, dass Schüler*innen, die längere Texte schreiben, mit höherer Wahrscheinlichkeit erfolgreich sind. Doch auch hier bleibt zu fragen, inwieweit *structure discovery* dazu in der Lage ist, wichtige Ähnlichkeiten aufzudecken, da beispielsweise Aufgabe 2b) und 2c) sich

auf individuelle Gegebenheiten in der Erfahrungswelt der Schüler*innen beziehen. Je nach Schulweg der Schüler*innen unterscheiden sich die Ergebnisse maßgeblich. Damit wäre in der Praxis von Fall zu Fall zu prüfen, ob Prämisse 1 zufriedenstellend erfüllt ist. Ein Vorteil von Modell 2 ist, dass es fortlaufend durch den Einsatz von maschinellem Lernen verbessert werden kann, indem der Referenzrahmen kontinuierlich durch die generierten Daten erweitert wird.

Modell 3

Modell 3 folgt einer ähnlichen Logik wie Modell 2. Anstatt der Ergebnisse soll dabei das Verhalten von Schüler*innen verglichen werden. Zugrunde liegt die Annahme, dass Schüler*innen wahrscheinlich die Kompetenzen und Standards des Kompetenzbereichs *Räumliche Orientierung* erfüllen werden, deren Verhalten Ähnlichkeit aufweist zu dem Verhalten von Schüler*innen, die die Kompetenzen und Standards erreicht haben. Bei der Datengrundlage handelt es sich um Aktivitätsdaten. Dadurch wird der Fokus erstmals auch auf Teile von Aufgaben gelenkt, die kein Ergebnis und dadurch auch keine Artefaktdaten generieren. Kurz gesagt, der Prozess steht hier im Mittelpunkt. So Tab. 1: Die drei LA-Modelle und ihre Parameter

kann bei Aufgabe 4 („Kartiere (...) die für Rollstuhlfahrerinnen und Rollstuhlfahrer wichtigen Orte/Gegebenheiten, die du in Aufgabe 2 identifiziert hast (...)“) der Prozess der Kartierung durch Modell 1 oder 2 aufgrund der angesprochenen Limitationen, wenn überhaupt, nur indirekt über die entstehende Karte erfasst werden. Denkbar wären hierbei Aufzeichnungen, die die Interaktionen mit Elementen und deren Dauer dokumentiert. Dies könnte besonders für Aufgabe 4 interessant sein, um das Kartieren nachzuverfolgen, aber auch für Aufgabe 2, wenn das Interagieren mit „Google Maps“ und „Wheelmap“ sowie das Bearbeiten der Karte im Fokus stehen.

Zu überprüfen bleibt, ob ein bestimmtes Verhalten, das durch LA mittels *structure discovery* erfasst werden kann, wie die Interaktionszeit mit Kartenelementen, mit dem Erreichen von Kompetenzen korreliert.

Die diskutierten drei Modellvarianten verdeutlichen, dass die Auswahl eines Modells ganz konkrete Auswirkungen auf den Referenzrahmen, die Datengrundlage, den Untersuchungsgegenstand und die Metrik hat, wie in der folgenden Tabelle verdeutlicht wird (vgl. Tabelle 1).

Insgesamt wird in der Tabelle deutlich,

	Referenzrahmen	Datengrundlage	Untersuchungsgegenstand	Metrik
Modell 1	Erwartungshorizont	Artefaktdaten	Ergebnis	Qualitativer Abgleich oder <i>content analysis</i>
Modell 2	Aufgabenergebnisse von Schüler*innen, die Kompetenzen erreicht haben	Artefaktdaten	Ergebnis	<i>structure discovery</i>
Modell 3	Verhalten von Schüler*innen, die Kompetenzen erreicht haben	Aktivitätsdaten	Prozess	<i>structure discovery</i>

wie weitreichend die didaktischen Entscheidungen sind, die während der Konzeption der Zyklen zu treffen sind, was wiederum ganz konkrete Auswirkungen auf den Lernprozess und die Kompetenzentwicklung hat, wie wir im Folgenden aufzeigen.

3. Implementierung der Zyklen und Implikationen für (geographische) Bildungsprozesse

Modell 1 kommt der Tätigkeit von Lehrkräften am nächsten, indem es Arbeitsergebnisse der Schüler*innen auf ihre Qualität bewertet. Gleichzeitig ist es in seinem Einsatz auf eine sehr spezifische Ausgangslage angewiesen, wie beispielsweise möglichst geschlossene Aufgabenformate. Modell 2 und 3 sind in ihrer Anwendung flexibler, da sie nicht auf kausale Erklärungen angewiesen sind, sondern rein nach Korrelation Vorhersagen treffen. Wenn von Vorhersagemodellen im Kontext der LA die Rede ist, dann sind meist auf Korrelation basierenden Systeme gemeint. Dabei kann Modell 2 und 3 kombiniert werden. Etablierte Modelle greifen sowohl auf Artefakt- und Aktivitätsdaten als auch auf zusätzlichen Informationen, wie biographische Angaben oder vergangene Leistungen, zurück (Arnold & Pistilli, 2012: 267). Mit ihnen können Lernende mit ihren Stärken und Schwächen modelliert und mit den Zielvorgaben abgeglichen werden (Gapski, 2021). Ein Beispiel für eine solche Anwendung ist die Software *Course Signals*, die entwickelt wurde, um den hohen Abbruchraten an den Universitäten in den ersten Semestern entgegenzuwirken (Arnold & Pistilli, 2012: 267).

Ob die drei Zyklen wie hier beschrieben implementiert werden könnten, ist letztlich ungewiss. Es bedarf einer ausführlichen Evaluation der Zyklen, ob die Prognosen zutreffend sind. Dies kann

durch Kontrollgruppen geschehen, die die gleichen Aufgaben durchführen, aber bei denen der Schritt der Intervention ausgelassen wird. Funktioniert das System, wird sich ein signifikanter Unterschied zeigen. Dabei ist allerdings eine Limitation des Systems zu beachten, die noch nicht angesprochen wurde: Alle drei Zyklen gehen von einem starren Unterricht aus, der immer gleich abläuft. Entscheidet die Lehrkraft aus pädagogischen Überlegungen heraus, Aufgaben zu verändern oder andere Anpassungen am Unterricht oder an den Lernprozessen durchzuführen, wirkt sich dies auf die Prognose des Vorhersagemodells aus. Hiermit stellt sich dann auch die Frage, wie sich die Struktur von Unterricht bei einem konsequenten Einsatz von LA ändern wird.

3.1. Strukturierende Wirkung von Learning Analytics

Bunz (2012) schreibt dem Einzug der Algorithmen in Arbeitsprozesse eine vergleichbare Wirkung zu wie dem Einzug der Maschinen während der Industriellen Revolution. Die grundlegende Logik, nach der bestimmte Arbeitsprozesse stattfinden, würde durch den Einzug der neuen Technologie verändert und strukturiert. Als Beispiel lässt sich hierfür die Einführung von Fließbändern nennen. Aus der Logik des Fließbandes ergibt sich, dass die Arbeiter*innen nun nur noch einen einzelnen Produktionsschritt beherrschen. Ihre Arbeitszeiten müssen in einem Schichtbetrieb aufeinander abgestimmt sein, Pausen sind nur nach Absprachen möglich und das Arbeitstempo ist von der Maschine bestimmt. Die Logik des Arbeitsprozesses hat sich grundlegend durch die Technologie verändert.

Der Logik folgend, dass tendenziell mehr Daten zu besseren Vorhersageergebnissen in der Anwendung von LA

führen (Brooks & Thompson, 2022: 31), könnten Lernumgebungen den Vorzug erhalten, die mehr Daten generieren. Hinzu kommt, dass die Daten in einer für die Metrik erfassbaren Form vorliegen müssen (Gapski, 2021). Beispielsweise generiert eine digitale Lernumgebung mehr Daten und wäre daher auch für den Einsatz von LA zu präferieren.

Wie bereits für Modell 1 diskutiert, würden geschlossene Aufgaben den Einsatz von bestimmten Techniken der LA vereinfachen oder überhaupt erst ermöglichen. Dies würde sich nicht unerheblich auf die Unterrichtsgestaltung auswirken. ChatGPT und ähnlich weit entwickelte KI-Systeme können zwar auch offene Aufgabenformate auswerten. Dennoch erfordern auch sie eine gewisse Strukturierung der Aufgaben und stehen innovativen Formaten des Assessments, die beispielsweise den Umgang der Schüler*innen mit Ungewissheit fördern oder zur gesellschaftlichen Partizipation auffordern, eher entgegen.

3.2. Regulierende Wirkung von Learning Analytics

Nach Greller und Drachsler (2012: 47–48) wird LA meist als Unterstützungstechnologie für den Entscheidungsprozess angesehen und ist pädagogisch neutral. LA könne in jeder pädagogischen Strategie zum Einsatz kommen und sie durch entsprechende Analysen bereichern. Dieser Auffassung widersprechen Allert und Richter (2020b: 16) und weisen darauf hin, dass immanente Annahmen der Technologie nur unzureichend thematisiert werden. Sie fordern daher, dass Ansätze und Prämissen von LA einer kritischen Prüfung unterzogen werden und die bildungstheoretischen Implikationen untersucht werden müssen.

Bereits die Rechtfertigung von LA enthält einige Annahmen über das Lernen:

Für Greller und Drachsler (2012: 42) ist eine der wichtigsten Vorteile von LA die Fähigkeit Lernen zu individualisieren. Es wird nämlich davon ausgegangen, dass Probleme auf der Ebene des Einzelnen gelöst werden können und folglich eine Hinwendung zum Einzelnen zu bestreben sei (Allert & Richter, 2020b: 24). Somit wird eher das Individuum als die Struktur adressiert. Hiermit werden einige didaktische Vorentscheidungen begründet, zum Beispiel hinsichtlich der Sozialform.

Besonders problematisch wird dabei das zugrundeliegende Menschenbild gesehen. Die Lernenden dienen den LA-Anwendungen als korrelierte Datensubjekte. Demnach sind sie durch ihre „objektiven“ Eigenschaften determiniert (Hildebrandt, 2006, zit. n. Allert & Richter, 2020b: 17). Gapski (2021) stellt in dem Zusammenhang die These auf, ob es sich bei der Herstellung dieser korrelierten Datensubjekte nicht um eine Individualisierung handelt, bei der die*der Lernende in Einzelteile im Sinne eines digitalen Nutzerprofils zerlegt wird, um die dabei generierten Daten verarbeiten zu können. Seine*ihre Eigenschaften werden dabei als bestimmbar, repräsentierbar und den Handlungen vorausgehend erachtet. Nach Allert und Richter (2020b) ist dies aber problematisch, da Situationen und ihre Akteure inhärent unbestimmt sind. Dies erklären sie wie folgt: Wissen und Deutungsschemata, die zur Bewältigung problematisierter Situationen gebraucht werden, sind nicht der Situation vorausgehend, sondern werden erst in der Auseinandersetzung mit der Situation erzeugt. Dies geschieht im Rahmen sozialer Konventionen, was der Bewältigung der Situation eine gewisse Erwartbarkeit verleiht. Algorithmen können als Form einer formalisierten Routine verstanden werden. Durch die Formalisierung werden die Situationen aber bereits im Vorhinein be-

stimmt und gedeutet. Als Beispiel können automatische Schreibkorrekturen dienen: Durch ihre inhärente Logik interpretieren sie jede Situation hinsichtlich der Zielsetzung des Richtig-Schreiben-Wollens, obwohl dieses Ziel nicht notwendigerweise immer verfolgt wird, da Autor*innen mitunter bewusst neue Begriffe konstruieren oder Wortspiele verwenden, um einem Gedankengang zu verdeutlichen. Durch die Formalisierung findet zwangsläufig eine Verallgemeinerung statt. Die Daten werden also so ausgewertet, als ob die Situation schon bestimmt wäre. Darin unterscheiden sich Algorithmen von uns. „Wir handeln in unbestimmten Situationen nicht, weil wir sie vollständig analysiert und erkannt haben, sondern weil wir sie durch das Handeln, durch das Ausloten von Handlungsoptionen zu erkennen suchen. Wir bestimmen die Situation durch Interaktion“ (Allert & Richter, 2020b: 22). Algorithmen, die bei LA zum Einsatz kommen, unterstellen, dass es eine Regelmäßigkeit von Lernprozessen gibt oder geben sollte, die vorausgesetzt werden kann. Dabei handelt es sich um eine standardisierende und regulierende Praktik, die Unvorhersehbarkeit ausklammert.

Darüber hinaus haben LA im Bildungsgeschehen in mehrfacher Hinsicht weitere performative Auswirkungen: Für den Einsatz von KI an Schulen und Hochschulen müssen zunächst die einzelnen Fächer Wissensbasen formulieren, welche aus kodifizierbaren und repräsentationalen Wissen bestehen, damit sie von den KI-Systemen erfasst werden können (Allert & Richter, 2020a: 1–2). Dies wirkt sich performativ sowohl auf Lernprozesse als auch auf die Fächer- und Lehrkultur aus. In Modell 1 muss beispielsweise der Referenzrahmen in Form des Erwartungshorizonts in solcher Weise vorliegen, dass die

Aufgaben durch den Einsatz von LA automatisch überprüfbar werden. Dadurch wird festgelegt, was als ‚richtige‘ und was als ‚falsche‘ Antwort gilt und somit auch wie die Qualität von Antworten eingeschätzt wird. Je nach Feedback, welches den Lernenden durch LA zurückgespielt wird, ziehen diese daraus entsprechende Schlüsse: Zum Beispiel könnten sie die Art und Weise, wie sie Antworten formulieren, an die technischen Bedürfnisse von LA anpassen. Ähnliches lässt sich auch für Modell 2 und 3 formulieren. Durch LA und die dabei verwendeten Algorithmen wird bestimmt, welches Verhalten und welche Ergebnisse als förderlich zum Erreichen der Lernziele gelten. Indem das LA-System die oberflächliche Erscheinung erfolgreicher Lernprozesse zu beschreiben versucht, um dies mit gemessenen Daten abzugleichen, wirkt es sich performativ auf die tatsächlich stattfindenden Lernprozesse aus. Sich auf den Vergleich berufende Interventionen fördern oder sanktionieren entsprechend Ergebnisse oder Verhalten. Dies wird besonders dann zum Problem, wenn die Metrik oder der Referenzrahmen nicht das widerspiegelt, was gelernt werden soll (Clow, 2012: 137). Dann optimiert sich das System nicht hinsichtlich der Lernziele, sondern hinsichtlich der ‚fehlerhaften‘ Metrik bzw. des Referenzrahmens.

Zudem sind die Lernenden noch durch eine weitere performative Wirkung von LA betroffen: Mit LA findet eine Positionierung von Lernenden durch Algorithmen statt (Dorsch, 2023). Schüler*innen entwerfen ihr eigenes Bild auf Grundlage dieser Positionierung. So können sie zu dem Schluss kommen, dass sie beispielsweise in Mathematik unbegabt sind. In der Folge richten sie ihr Handeln danach aus, indem sie beispielsweise den Mathematikunterricht „schwänzen“. Allert und

Richter (2020b: 18–19) setzen in ihrer Kritik daran an, dass hinter LA-Systemen die Vorstellung steht, dass Eigenschaften, vorgegeben sind. Dabei sei die Verortung seitens der Lernenden, beispielsweise zu der Gruppe der Mathematikunbegabten, nicht der Handlungen vorausgehend, sondern wird erst durch diese Handlungen erzeugt.

Auf der Grundlage der vorgestellten Überlegungen kann das Bild von LA als „a support technology for decision making processes“ (Greller & Drachsler, 2012: 47) relativiert werden. LA unterstützt nicht nur beim Verstehen von Lernprozessen, um darauf aufbauend Interventionen abzuleiten, sondern wirkt sich performativ auf diese aus. Die algorithmischen Prozesse beschreiben also nicht nur die Realität, sondern bringen sie auch selbst hervor (Allert, 2020: 27). Die geschilderten Wirkungen von LA müssen sich Lehrende und Lernende bewusst machen, wenn sie LA reflektiert nutzen möchten. Welche Kompetenzen dabei behilflich sein können, soll nun diskutiert werden.

4. Kompetenzen für einen mündigen Einsatz von Learning Analytics

Aus der Informatik ist der Begriff ‚Garbage in, garbage out‘ bekannt, der sich darauf bezieht, dass die Ergebnisse von Computermodellen nur so gut sind, wie die Daten, die in das System eingespeist werden. Eine Abwandlung ist der Begriff ‚Garbage in, Gospel out‘, der zum einen das blinde Vertrauen in Software bezeichnet, wenn Ergebnisse der Informationsverarbeitung als unbestreitbare Tatsachen behandelt werden, ohne sie richtig zu verstehen. Andererseits umschreibt er die Fehlannahme, dass, wenn nur ausreichend Daten vorliegen, die Modelle schon brauchbare Ergebnisse liefern würden

und diesen vertraut werden könne. Beides ist trügerisch: Vielmehr müssen sowohl die Eingangsdaten kritisch überprüft als auch die Ergebnisse reflektiert und dekonstruiert werden. In Bezug auf den Einsatz von LA in der geographischen Bildung rückt hiermit die Frage nach der Datenkompetenz der Lehrkräfte in den Mittelpunkt: Welches Wissen, welche Fähigkeiten und welche Einstellungen brauchen Lehrer*innen für einen effektiven, reflektierten, kritischen und verantwortungsvollen Umgang mit Daten im Kontext von LA in der geographischen Bildung?

Bereits Greller und Drachsler (2012: 51–52) stellen Kompetenzen zusammen, die von den Lehrenden für die zukünftige Entwicklung von LA erworben werden müssen. Darunter finden sich vor allem Kompetenzen, die zur Interpretation der angezeigten Ergebnisse nötig sind. Ansonsten könnten die Ergebnisse, die LA-Systeme Lehrenden liefern, dazu einladen, diese unreflektiert, beispielsweise zur Benotung, zu verwenden. Mandinach und Abrams (2022) heben diesbezüglich die Wichtigkeit von *data literacy* hervor. Darunter verstehen sie die Fähigkeit Informationen in anwendbares Wissen für die Gestaltung von Lehrprozesse umzuwandeln, indem verschiedene Arten von Daten gesammelt, analysiert und interpretiert werden können (Mandinach & Abrams, 2022: 196). Derartige Fähigkeiten können im Geographieunterricht in unterschiedlichsten Themenfeldern erworben werden, z. B. bei kleineren empirischen Forschungsprojekten, bei der Weiterverarbeitung und Visualisierung der Daten mittels GIS oder bei der Auseinandersetzung mit sozialen Medien.

Zweifelsohne handelt es sich hierbei um wichtige Fähigkeiten für den Einsatz von LA. Sie sind jedoch angesichts der strukturierenden und regulierenden Wir-

kung von LA nicht ausreichend. Es wird zwar dem Aspekt Rechnung getragen, dass LA Anwendungen nur unterstützend tätig werden können und es daher Kompetenzen seitens der Lehrkraft braucht, um diese sinnvoll einzusetzen, jedoch muss ein Ansatz für den Einsatz von LA tiefer greifen. Werden LA als eine wechselseitige Beziehung aus Akteur*innen und Struktur verstanden, dann müssen sowohl Lehrkräfte als auch Schüler*innen als Akteur*innen anerkannt werden, die spezifische Kompetenzen im mündigen Umgang mit der Struktur brauchen. Die Fähigkeit zur Reflexion ist nötig, um die Systeme und dahinterstehenden Algorithmen zu dekonstruieren. Auf Ebene der Lehrkraft bedeutet dies, LA nicht als ein reines Werkzeug im Geographieunterricht zu sehen, sondern sich der strukturierenden und regulierenden Wirkung von LA bewusst zu sein und diese im pädagogischen Handeln zu berücksichtigen. Kanwischer und Schulze (2021, S. 160–161) weisen im Kontext digitaler Anwendungen für die Hochschullehre darauf hin, dass diese meist ein bestimmtes Lernparadigma implizieren, aber nicht automatisch auch unterstützen. Es sei bei dem Einsatz der Anwendungen daher entscheidend, wie sie von der Lehrkraft eingesetzt werden. Für eine Nutzung, die das Potential der Anwendungen hinsichtlich angestrebter Ziele ausschöpft, bedürfe es einer Reflexion. Dabei müssen die Bedürfnisse der Lernenden sowie Lehrenden und die Möglichkeiten der Technologie hinsichtlich einer didaktischen Umsetzung abgeglichen werden (Kanwischer & Schulze, 2021, S. 163). Ein ebensolcher Abgleich muss von Lehrer*innen geleistet werden, der die Bedürfnisse der Schüler*innen in durch LA gestalteten Lernumgebungen berücksichtigt.

Eine weitere Aufgabe von Lehrkräf-

ten ist hierbei, einen selbstreflexiven Umgang mit LA Systemen seitens der Schüler*innen zu fördern. Durch die performative Wirkung von Algorithmen, die Subjekte hervorbringen (Introna, 2017), ist es wichtig, dass Schüler*innen ihre eigenen Interessen kennen und in Relation zur Gemeinschaft setzen können (Dorsch & Kanwischer, 2020, S. 30–32). Dies bedeutet, dass sie einen eigenen Handlungsspielraum entwickeln, mit dem sie sich mit der Positionierung durch Algorithmen innerhalb eines LA-Systems in Relation setzen. Dies umfasst auch, dass sie lernen, sich außerhalb des technischen Rahmens zu artikulieren und sich in ein kritisches Verhältnis zu dem System zu setzen (Allert & Richter, 2020b: 26). Besonders vor dem Hintergrund, dass Lernenden kaum ersichtlich ist, wie sich ihr Input auf das System auswirkt, bedarf es Kompetenzen der Schüler*innen, sich autonome Handlungsspielräume innerhalb des LA Systems zu schaffen (ebd.).

Zuletzt sollten Schüler*innen und Lehrkräfte dazu befähigt werden, lernbezogene Daten und Mittel der Weiterverarbeitung für ihre Zwecke hinsichtlich von Lernprozessen zu nutzen. Einen Anhaltspunkt, wie dies gedacht werden kann, liefern Allert und Richter (2020b: 27): Die der LA zugrundeliegende Vorstellung von Bildung wird als gestaltbar angesehen. Es gibt festgeschriebene Strukturen und Modelle, anhand derer das Lernen stattfindet und die dem Lernprozess vorausgehen. Dadurch wird versucht, Unbestimmtheiten zu minimieren und planbar zu machen. Dies widerspricht jedoch, wie oben aufgezeigt, der Idee sozialer Praktiken, nach der die Logik und die Regeln des Lernens erst kontinuierlich durch die Interaktionen entstehen und daher im Vorhinein nicht bestimmbar sind. Diesem Gedanken

könnte gerecht werden, indem Technologien anders gedacht werden, nämlich als epistemische Artefakte. Datenbasierte Systeme, die als epistemische Artefakte konzipiert sind, stellen kein bestehendes Wissen dar, sondern erlauben es, aus den Daten Fragen herauszuarbeiten. Werkzeuge könnten dabei genutzt werden, eigene Praktiken des Lernens zu entwickeln und zu unterstützen. In einer solchen Art von Bildung würde ein Hinterfragen des Gegebenen durch das Erarbeiten von Alternativen ermöglicht (Allert & Richter, 2020b: 28–32). Kompetenzen, die einen solchen Einsatz und Umgang mit LA ermöglichen und fördern, verleihen den Akteur*innen mehr Autonomie, da die Entwicklung des individuellen Lernprozesses im Vordergrund steht.

5. Ausblick

Es steht außer Frage, dass angesichts der enormen Entwicklungspotentiale im Bereich des maschinellen Lernens und der künstlichen Intelligenz, LA auch im Graphieunterricht zukünftig eine größere Rolle spielen werden. Zu verlockend ist die Aussicht für Lehrende, mittels automatisierter Auswertungsverfahren dabei unterstützt zu werden, ihren Schüler*innen individuelles Feedback zu geben oder über den exakten Lernstand der eigenen Klasse informiert zu werden. Genauso wird die Bildungspolitik angesichts des Lehrkräftemangels nicht auf die Stärken automatisierter Wissensvermittlung und KI-gestützter Unterstützungsangebote für Lernende verzichten. Angesichts der zahlreichen Initiativen, die sich für einen ethischen und datenschutzkonformen Einsatz von Learning Analytics einsetzen (vgl. z. B. den Verhaltenskodex für Trusted Learning Analytics nach Hansen, Rensing, Herrmann & Drachler, 2020), wird die Pro-

blematik dabei weniger in einem verantwortungslosen Umgang mit den Daten der Lernenden liegen als vielmehr in der Vernachlässigung der strukturierenden und regulierenden Wirkungen von LA. Wie am Aufgabenbeispiel zur „Wheelmap“ dargestellt, müssen sich die Unterrichtspraktiken ändern. Es müssen Wissensbestände definiert und Kompetenzen modelliert werden, damit sie von den entsprechenden Systemen möglichst effizient erfasst werden können. Eine weitere Herausforderung wird darin liegen, die dabei produzierten Lernstandsanalysen und Empfehlungen zu hinterfragen und dabei nicht den*die individuelle*n Schüler*in aus dem Blick zu verlieren und den eigenen Handlungs- und Ermessenspielraum nicht zu Gunsten einer automechanischen ‘Gospelgläubigkeit’ aufzugeben.

6. Literatur

- Allert, H. (2020). Algorithmen und Ungleichheit. *Medien + Erziehung*, 64(3), S. 26–32.
- Allert, H. & Richter, C. (2020a). Künstliche Intelligenz (KI) und Rechtfertigungslogiken in der Hochschulbildung. Verfügbar unter: [343971153_Kunstliche_Intelligenz_KI_und_Rechtfertigungslogiken_in_der_Hochschulbildung](https://doi.org/10.1007/978-3-658-28398-8_2)
- Allert, H. & Richter, C. (2020b). Learning Analytics: subversive, regulierende und transaktionale Praktiken. In Iske, S., Fromme, J., Verständig, D. & Wilde, K. (Hrsg.). *Big Data, Datafizierung und digitale Artefakte*. Wiesbaden: Springer Fachmedien, S. 15–35. https://doi.org/10.1007/978-3-658-28398-8_2
- Arnold, K. E. & Pistilli, M. D. (2012). Course signals at Purdue. In Dawson, S. (Hrsg.). *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*. New York, NY: ACM, S. 267–270
- Brooks, C. & Thompson, C. (2022). Predictive Modelling in Teaching and Learning. In Lang, C., Siemens, G., Wise, A. F., Gašević, D. & Merceron, A. (Hrsg.). *The Handbook of Learning Analytics SOLAR*, S. 29–37. <https://doi.org/10.18608/hla22.003>

- Bunz, M. (2012). *Die stille Revolution. Wie Algorithmen Wissen, Arbeit, Öffentlichkeit und Politik verändern, ohne dabei viel Lärm zu machen* (1. Aufl., neue Ausg.). Berlin: Suhrkamp.
- Clow, D. (2012). The learning analytics cycle. In Buckingham Shum, S. J., Dawson, E. S., Haythornthwaite, C. A. & Dawson, S. (Hrsg.). *LAK 2012. Proceedings of the 2nd International Conference on Learning Analytics and Knowledge* : April 29-May 2, 2012, Vancouver, British Columbia, Canada: ACM, S. 134–138. <https://doi.org/10.1145/2330601.2330636>
- Deutsche Gesellschaft für Geographie e. V. (2020). *Bildungsstandards im Fach Geographie für den Mittleren Schulabschluss* (10., aktualisierte und überarbeitete Auflage).
- Dorsch, C. (2023). „Kunden wie du kauften auch ...“. In Pettig, F. & Gryl, I. (Hrsg.). *Geographische Bildung in digitalen Kulturen. Perspektiven für Forschung und Lehre*, Berlin: Springer, S. 291–298. https://doi.org/10.1007/978-3-662-66486-5_23
- Dorsch, C. & Kanwischer, D. (2020). Mündigkeit in einer Kultur der Digitalität. *Geographische Bildung und „Spatial Citizenship“*. *Zeitschrift für Didaktik der Gesellschaftswissenschaften (ZDG)*, 11(1), S. 23–40.
- Ferguson, R. (2012). Learning analytics: drivers, developments and challenges. *International Journal of Technology Enhanced Learning*, 4(5/6), S. 304–317. <https://doi.org/10.1504/IJTEL.2012.051816>
- Gapski, H. (2021). Künstliche Intelligenz (KI) und kritische Medienbildung: Reflexionen aus kommunikationswissenschaftlicher Perspektive, JFF - Institut für Medienpädagogik in Forschung und Praxis. Verfügbar unter: <https://digid.jff.de/kuenstliche-intelligenz-und-kritische-medienbildung-harald-gapski/>
- Greller, W. & Drachsler, H. (2012). Translating Learning into Numbers: A Generic Framework for Learning Analytics. *Educational Technology & Society*, 15(3), S. 42–57.
- Hansen, J., Rensing, C., Herrmann, O. & Drachsler, H. (2020). *Verhaltenskodex für Trusted Learning Analytics. Version 1.0. Entwurf für die hessischen Hochschulen*. *Innovationsforum Trusted Learning Analytics*. <https://doi.org/10.25657/02:18903>
- Hildebrandt, M. (2006). Privacy and Identity. In Claes, E., Duff, A. & Gutwirth, S. (Hrsg.). *Privacy and the criminal law* (. Antwerpen: Intersentia, S. 61–104)
- Introna, L. D. (2017). Die algorithmische Choreographie des beeindruckbaren Subjekts. In Seyfert R. (Hrsg.). *Algorithmenkulturen. Über die rechnerische Konstruktion der Wirklichkeit*. Bielefeld: Transcript, S. 41-74.
- Joksimović, Kovanović, V. & Dawson: (2019). The Journey of Learning Analytics. *HERDSA Review of Higher Education*, 6, S. 37–63.
- Kanwischer, D. & Schulze, U. (2021). Geographische Hochschulbildung in einer Kultur der Digitalität. In Wintzer, J., Moßig, I. & Hof, A. (Hrsg.). *Prinzipien, Strukturen und Praktiken geographischer Hochschullehre*. Bern: Haupt Verlag, S. 153–166.
- Katz, A., Wei, Nanda, G., Brinton, C. & Ohland, M. (2023, 9. Mai). Exploring the Efficacy of ChatGPT in Analyzing Student Teamwork Feedback with an Existing Taxonomy. Verfügbar unter: <http://arxiv.org/pdf/2305.11882.pdf>
- Kovanović, V., Joksimović, S., Gasevic, D., Hatala, M. & Siemens, G. (2022). Content Analytics: The Definition, Scope, and an Overview of Published Research. In Lang, C., Siemens, G. Wise, A. F., Gašević D. & Merceon, A. (Hrsg.). *The Handbook of Learning Analytics*. SOLAR, S. 77–92.
- Mandinach, E. B. & Abrams, L. M. (2022). Data Literacy and Learning Analytics. In Lang, C., Siemens, G., Wise, A. F., Gašević, D. & Merceon, A. (Hrsg.). *The Handbook of Learning Analytics* SOLAR, S. 29–37. <https://doi.org/10.18608/hla22.019>
- Siemens, G. & Baker, R. S. J. d. (2012). Learning analytics and educational data mining. In Dawson, S. (Hrsg.). *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*. New York, NY: ACM, S. 252-254.
- Wise, A. F. (2019). Learning Analytics: Using Data-Informed Decision-Making to Improve Teaching and Learning. In Adesope, O. O. & Rud, A. G. (Hrsg.). *Contemporary Technologies in Education. Maximizing Student Engagement, Motivation, and Learning*. Cham: Palgrave Macmillan US, S. 119–143. https://doi.org/10.1007/978-3-319-89680-9_7

DuEPublico

Duisburg-Essen Publications online

UNIVERSITÄT
DUISBURG
ESSEN

Offen im Denken

ub | universitäts
bibliothek

Dieser Text wird via DuEPublico, dem Dokumenten- und Publikationsserver der Universität Duisburg-Essen, zur Verfügung gestellt. Die hier veröffentlichte Version der E-Publikation kann von einer eventuell ebenfalls veröffentlichten Verlagsversion abweichen.

DOI: 10.17185/duepublico/83359

URN: urn:nbn:de:hbz:465-20250408-152539-9

Erschienen in: Wie(so)? Geographische Bildungsprozesse im Zeitalter der Digitalität
(OpenSpaces Sonderausgabe 2025, Heft1, S. 46-59)



Dieses Werk kann unter einer Creative Commons Namensnennung 4.0 Lizenz (CC BY 4.0) genutzt werden.