

GML² 2014

13.–14. März

Grundfragen Multimedialen Lehrens und Lernens

Der Qualitätspakt E-Learning im Hochschulpakt 2020

Tagungsband

Nicolas Apostolopoulos, Harriet Hoffmann,
Ulrike Mußmann, Wolfgang Coy, Andreas Schwill (Hrsg.)

Impressum

Herausgeber

Nicolas Apostolopoulos, Freie Universität Berlin

Harriet Hoffmann, Freie Universität Berlin

Ulrike Mußmann, Freie Universität Berlin

Wolfgang Coy, Humboldt-Universität

Andreas Schwill, Universität Potsdam

Redaktion

Irina Baskow, Freie Universität Berlin

Harriet Hoffmann, Freie Universität Berlin

Layout & Satz

CeDiS, Freie Universität Berlin

Druck

Buch- und Offsetdruckerei H. Heenemann, Berlin

Vertrieb

Waxmann Verlag GmbH

Steinfurter Straße 555, 48159 Münster

www.waxmann.com

ISBN: 978-3-8309-3106-5

Learning Analytics aus hochschuldidaktischer Perspektive

Zusammenfassung

Der Begriff „Learning Analytics“ bezeichnet die Analyse großer Datenmengen, die durch die Nutzung von Informations- und Kommunikationstechnologien in Lernprozessen anfallen. Mit Hilfe dieser Datenanalysen sollen Nutzungsmuster gefunden werden, die Hinweise auf erfolgreiches oder nicht erfolgreiches Lehr- und Lernverhalten geben. Erkenntnisse aus Analyseprozessen können der Ausgangspunkt sowohl für Feedback an Studierende als auch für Veränderungen der Lehre sein. Die Debatte um Learning Analytics findet auf vielen Ebenen statt – eine große Rolle spielen dabei die Fragen, was technisch möglich und was datenschutzrechtlich und ethisch vertretbar ist. Wichtig erscheint uns aber auch die Frage danach, welche Erkenntnisse überhaupt gefunden werden können und was ihr didaktischer Mehrwert ist.

Der vorliegende Text führt zunächst allgemein in das Thema Learning Analytics ein, klärt Begriffe, und zeigt, wer von den Datenanalysen in welcher Weise profitiert. Er zeigt dann, in welchen hochschuldidaktisch relevanten Situationen Datenanalysen möglich sind. Am Ende steht ein kurzer Blick auf die Debatte um Learning Analytics sowie Thesen zum Umgang mit den zweifellos bestehenden Herausforderungen.

Kontext: Analyse großer Datenmengen

Ausgangspunkt des Themas „Learning Analytics“ ist das Vorhandensein großer, unstrukturierter Datenmengen („Big Data“), die durch die Nutzung von Informations- und Kommunikationstechnologien entstehen, sowie die Verfügbarkeit von Methoden und Werkzeugen zu ihrer Analyse. Nicht nur in staatlichen Geheimdiensten oder in der Kriminalistik, sondern auch in vielen anderen Lebensbereichen werden inzwischen derartige „Datenberge“ auf darin verborgene Muster hin analysiert und gewinnbringend „abgebaut“ („Data Mining“). Bekannte Beispiele sind die Web-2.0-Geschäftsmodelle großer Internetdienstleister, wie z. B. Google oder Amazon, die mit Hilfe ihrer Nutzungsdaten und Verarbeitungsalgorithmen einen direkten Mehrwert für die bereitgestellten Dienste erzeugen, indem z. B. die Relevanz von Suchergebnissen bestimmt wird oder angepasste Produktempfehlungen ermittelt werden. Auch in Finanzdaten werden mit Hilfe statistischer Analyse-

methoden Muster gefunden, deren Prognosen den Hochfrequenzhandel ermöglichen oder bei der Aufdeckung von Unregelmäßigkeiten und Insiderhandel helfen. Auch in der Klimaforschung und in den Lebenswissenschaften werden ebenso große Datenmengen verarbeitet.

Gemeinsam ist diesen Datenmengen nicht nur ein sehr großer (ständig zunehmender) Umfang, sondern auch eine große Heterogenität, die häufig einhergeht mit Unstrukturiertheit und variierender Datenqualität. Meist handelt es sich nicht um Daten, die für einen bestimmten Zweck erhoben werden, sondern die „gefunden“ werden und nicht nur aus Datenbanken stammen, sondern aus unterschiedlichen internen und externen Quellen wie Log-Dateien, Clickstreams und Protokollaufzeichnungen, Suchanfragen und -ergebnissen, Archiven von Foren- oder Blogbeiträgen, Metadaten verschiedenster Art usw.

Auch der Bildungsbereich produziert inzwischen Unmengen verschiedenster Daten. Seien es Schulen, Hochschulen oder Institutionen der beruflichen Weiterqualifizierung: In Lehre, Verwaltung und universitärer Forschung wird eine Vielzahl von Prozessen durch Informations- und Kommunikationssysteme unterstützt oder überhaupt erst ermöglicht. Jede Transaktion und jede Interaktion im Lauf dieser Prozesse hinterlässt „Datenspuren“. Durch die zunehmende Nutzung von Campus- und Kurs-Managementsystemen, Lernplattformen, Social Media, Vorlesungsaufzeichnungen usw. werden fortwährend sehr große Datenmengen erzeugt.

Auch diese heterogenen Bildungsdaten lassen sich verknüpfen, analysieren und strukturieren; auch in ihnen lassen sich mit Hilfe induktiver Statistik Muster finden, die zuvor unbekannt waren und wichtige Zusammenhänge aufzeigen. Analog zum Begriff „Business Analytics“ für Datenanalysen im Unternehmenskontext spricht man dabei im Bildungsbereich von „Educational Analytics“. Dieser allgemeine Begriff bezieht als mögliche Datengrundlage sowohl Daten aus Verwaltung, Lehre und universitärer Forschung mit ein. Der Begriff „Learning Analytics“ bezeichnet aus dieser Gesamtmenge den Ausschnitt, der aus didaktischer Perspektive relevant ist: die Analyse von Daten, die Lehr- und Lernprozesse betreffen (zu definitiven Fragen s. Baker et al., 2012).

Nutzung bildungsbezogener Datenanalysen

Ergebnisse von Datenanalysen sind im Bildungsbereich für Akteure auf unterschiedlichen Ebenen von Bedeutung. Shum (2012, S. 3) unterscheidet hier eine Mikro-, eine Meso- und eine Makroebene. Diese Aufteilung ist auch mit Blick auf lehr- und lernbezogenen Daten sinnvoll und lässt sich dann wie folgt skizzieren:

- *Mikroebene:* Auf der Mikroebene als unterster Ebene werden Daten ausgewertet, die von einzelnen Lehrenden und Studierenden erzeugt worden

sind. So können Nutzungsdaten aus Lernplattformen oder von Videoportalen ausgewertet werden, um zu sehen, ob und wie bestimmte Angebote angenommen werden. Für Lehrende liefert dies unmittelbare Anhaltspunkte zum Lernstand von Studierenden und ermöglicht es ihnen, einzelne Studierende gezielt zu fördern oder auch den eigenen Unterricht anzupassen und auf erkannte Defizite einzugehen.

- *Mesoebene:* Auf der Mesoebene werden innerhalb einer Bildungsinstitution Daten aus unterschiedlichen Quellen der Mikroebene (und evtl. weiterer Quellen) aggregiert, so z. B. in einer Universität auf Fakultäts-ebene oder in der Präsidialverwaltung. Diese Daten können als Teil des „akademischen Controlling“ Aufschluss über wichtige Entwicklungen und Zusammenhänge geben. Nimmt man das Thema Studienabbruch als Beispiel, so kann eine Universität durch die Auswertung lehrbezogener Daten aus allen Fakultäten Anhaltspunkte dafür bekommen, was den Studienabbruch auslöst und welche der vielleicht schon ergriffenen Gegenmaßnahmen besonders hilfreich (oder nicht hilfreich) waren (vgl. Lauria et al., 2013).
- *Makroebene:* Die Makroebene stellt die höchste Aggregationsebene dar. Dort werden Daten aus unterschiedlichen Institutionen verknüpft und zentral ausgewertet. Dies kann z. B. in einer Behörde wie dem Wissenschaftsministerium oder in einem Institutionenverbund wie den TU9 (große Technische Universitäten) geschehen. Die Ergebnisse der Analysen können genutzt werden, um beispielsweise Empfehlungen zum Nutzen bestimmter Maßnahmen zu geben oder aber um eine Entscheidungsgrundlage für die Mittelverteilung zu haben. So kann z. B. die Analyse von Daten zum Studienerfolg und die Erkenntnis, dass Investitionen in die Lehrqualität Studienabbruchquoten senken, zur Einrichtung von Förderprogrammen wie dem „Qualitätspakt Lehre“ führen.

Offensichtlich ist, dass die drei Ebenen aufeinander aufbauen bzw. voneinander abhängen: Je mehr Daten auf der Mikroebene eingespeist werden, desto belastbarer sind Analyseergebnisse auf der Makroebene; wenn umgekehrt eine Entscheidung auf der Mikroebene nicht nur auf Einzelphänomenen beruhen sollen, sondern durch breitere Erkenntnisse gestützt werden soll, hilft die Verknüpfung großer Datenmengen aus mehreren Quellen (Shum 2012, S. 3).

Betrachtet man Makro- und Mesoebene, so sind Datenanalysen dort offensichtlich Hilfestellungen für hochschulpolitische und verwaltungstechnische Steuerungsentscheidungen. Sie beeinflussen damit die didaktischen Vorgänge auf der Mikroebene und können auch Gegenstand hochschuldidaktischer Forschung sein. Im engeren Sinne didaktische Entscheidungen werden dort allerdings nicht getroffen. Aus der didaktischen Perspektive steht - so gesehen - die Mikroebene im Fokus.

Doch wie ist Didaktik gegenüber dem Thema „Learning Analytics“ überhaupt positioniert?

Learning Analytics aus hochschuldidaktischer Perspektive

Aus didaktischer Perspektive erscheinen Datenanalysen zunächst in gewisser Weise verdächtig. Wie es scheint, soll die Erkennung eines bestimmten Musters an eine bestimmte Folge geknüpft werden. Beispiel: Die Auswertung der Nutzungsdaten eines Studenten in einer Lernplattform zeigt, dass er bereitgestellte Texte regelmäßig nicht herunterlädt. Konsequenz: Der Student wird dazu aufgefordert, die Texte herunterzuladen.

Tatsächlich sind solche schematischen Ketten in einem lehrbezogenen Learning-Analytics-Einsatz denkbar. Sie erinnern damit an die behavioristische Didaktik, die mit ihren Reiz-Reaktion-Logiken inzwischen längst als überholt gilt. Wichtig ist insofern, auch das Thema Learning Analytics anders als in solchen simplen Anwendungen zu denken. Einen Ansatz hierfür liefert ein Modell von Greller und Drachsler (2012, S. 52 f.). In diesem Modell gibt es eine Abfolge von drei Schritten: 1.) eine didaktische Ausgangssituation, 2.) die Erhebung und Analyse von Daten sowie 3.) eine didaktische Konsequenz. Betrachtet man die Sache so, stellt eine Learning-Analytics-Datenanalyse lediglich ein Werkzeug dar, das in unterschiedlich modellierten didaktischen Settings zum Einsatz kommen kann, wobei das Entscheidende die Art und Weise der didaktischen Verarbeitung ist. So kann nach behavioristischem Prinzip auf ein bestimmtes Analyseergebnis eine fest definierte Konsequenz folgen. Denkbar ist aber auch, den Grundsätzen konstruktivistischer Didaktik Rechnung zu tragen und den Lernenden eine Information lediglich zur Verfügung zu stellen, damit sie selber daraus eine Konsequenz ziehen können.

Weniger auf der lerntheoretischen als auf der Umsetzungsebene liegt eine grundlegende Entscheidung, die noch vor der Datenanalyse liegt. So kann eine Datenanalyse in einer Unterrichtssituation sowohl hypothesengeleitet als auch ohne Hypothese eingeleitet werden (vgl. Baepler & Murdoch, 2010). Beispielsweise können Lehrende ohne ein bestimmtes Ziel die Daten, die in einer Vorlesung bei der Nutzung unterschiedlicher Online-Werkzeuge angefallenen sind, verknüpfen und auf Muster hin analysieren. Womöglich erhalten sie aus einer solchen Analyse Erkenntnisse, die sie vorher noch nicht angedacht hatten. Im Gegensatz dazu ist es aber auch möglich, dass eine Datenanalyse mit einer Hypothese begonnen und durchgeführt wird, d.h. ein Lehrender hat den Verdacht, dass ein ganz bestimmter Zusammenhang oder ein bestimmtes Phänomen besteht und prüft dies durch eine gezielte Analyse, um dann daraus didaktische Konsequenzen zu ziehen. Wichtig wäre nun die Frage, in welchen didaktischen Situationen Datenanalysen überhaupt Sinn machen können.

Anwendungsfelder innerhalb der Hochschuldidaktik

Ein weithin anerkanntes hochschuldidaktisches Modell unterrichtsbezogener Handlungssituationen liegt bislang nicht vor. Allerdings liegt hinter vielen hochschuldidaktischen Publikationen eine Vorstellung von Handlungsfeldern, die bei der Planung, Durchführung und Evaluation von Unterricht bestehen. Im Folgenden soll die Struktur aus Lüth, Tscheulin & Salden (2014) aufgenommen werden, die als Kategorien Veranstaltungsplanung, Aktives Lernen im Plenum, Lernen in Gruppen, Selbststudium, semesterbegleitendes Feedback und abschließendes Prüfen einführt. Zu ergänzen wäre der Bereich Evaluation. Auf all diese Bereiche kann die Analyse lehrbezogener Daten Auswirkungen haben, was im Folgenden jeweils kurz skizziert werden soll.

Semesterbegleitendes Feedback

Semesterbegleitendes Feedback ist aus Studierendensicht die offensichtlichste Anwendungsmöglichkeit für lernbezogene Datenanalysen. Hierbei können zwei Arten von Feedback unterschieden werden: zum einen Lernstandsbeschreibungen, zum anderen Erfolgsprognosen (vgl. in etwas anderem Kontext Greller & Drachsler, 2012, S. 47).

Bei Lernstandsbeschreibungen wird Studierenden anhand der von ihnen erzeugten Daten gespiegelt, wo sie im Lernprozess stehen – für sich genommen und im Vergleich mit anderen. So kann z. B. beim Einloggen in eine Lernplattform durch Visualisierungen in einer Übersicht („Dashboard“) dargestellt werden, wie häufig sich ein Student bereits in die Lernplattform eingeloggt hat (und wie häufig andere Studierende), wie viele Beiträge er in ein veranstaltungsbezogenes Forum eingestellt hat (und wie viele andere Studierende), wie viele der verfügbaren Texte er heruntergeladen hat (und wie viele andere Studierende). Den Studierenden wird es so möglich, ihre eigene Aktivität im Semester im Vergleich mit den Kommilitoninnen und Kommilitonen einzuschätzen. Denkbar ist auch die Messung dieser Aktivität an einem jeweils definierten Soll-Zustand.

Ausgehend von den Zustandsanalysen und verknüpft mit Werten aus den Vorjahren können den Studierenden dann auch Prognosen über ihr Bestehen am Semesterende gegeben werden. Wenn sich z. B. in den vorhergehenden Semestern abgezeichnet hat, dass alle Studierenden mit einem bestimmten Nutzungsverhalten eine abschließende Prüfung bestanden haben, so kann in einem laufenden Semester vom System in passenden Fällen eine positive Prognose ausgegeben werden. Wenn sich andererseits das Bestehen nur mit einer gewissen Wahrscheinlichkeit annehmen lässt, kann diese Wahrscheinlichkeit angezeigt werden (z. B. über ein Ampelsystem mit Rot – Gelb – Grün, vgl. Siemens et al., 2011, S. 15). Den Studierenden wird es so möglich, ihren eigenen Leistungsstand fortlaufend im Semester

einzuschätzen – und das selbst in Großveranstaltungen, in denen gewöhnlich kein personalisiertes Feedback gegeben werden kann.

Semesterbegleitendes Feedback, das auf Datenanalysen basiert, muss selbstverständlich nicht zwangsläufig in dieser unpersönlichen Form gegeben werden. Es ist denkbar, Daten personalisiert oder anonymisiert auch den Lehrenden einer Veranstaltung sichtbar zu machen. Sie können dann auf einzelne Studierende zugehen und sie auf eventuelle Lernschwierigkeiten ansprechen. Sie können darüber hinaus aber auch ihre eigene Lehre anpassen, wenn sie erkannt haben, dass bestimmter Stoff häufig nicht verstanden wurde. Semesterbegleitendes Feedback erhalten so nicht nur die Studierenden, sondern auch die Lehrenden, und das im Übrigen nicht nur zur Lernleistung der Studierenden, sondern auch zu ihrer eigenen Lehrleistung – denn womöglich fällt den Studierenden das Verständnis eines Inhalts auch deswegen schwer, weil er im Plenum nicht gut erklärt wurde. Ein klassisches Anwendungsbeispiel sind hier Datenanalysen von Vorlesungsaufzeichnungen, bei denen abgebildet werden kann, an welchen Stellen Studierende besonders häufig zurückgespult haben (vgl. Seidel, 2014, S. 100 f.). Dies kann entweder ein Hinweis auf besonders schwierigen Inhalt oder auf besonders unverständliche Erklärungen sein.

Aktives Lernen

Datenanalysen befördern aktives Lernen nicht unmittelbar. Allerdings können sie Ausgangspunkt für aktivierende Szenarien sein, wenn das im vorstehenden Unterkapitel beschriebene semesterbegleitende Feedback genutzt wird, um entsprechende Sequenzen in den Unterricht einzubauen. So kann ein Lehrender beispielsweise aufgrund von Lösungsstatistiken von Online-Lernmodulen zu der Einschätzung gelangen, dass bestimmte Aufgaben und die hinter ihnen liegenden Konzepte nicht verstanden wurden. Entsprechend kann er in den Unterricht kleine Übungseinheiten einbauen, in denen die Studierenden an den Schwierigkeiten arbeiten sollen.

Richtet sich der Blick auf den Lehrenden, so können Datenanalysen auf Defizite beim Grad der Aktivierung in einer Veranstaltung aufmerksam machen. So können z. B. in Veranstaltungen mit einer Backchannel-Kommunikation Studierende parallel zum Lehrendenvortrag Fragen zum Stoff über ihre mobilen Geräte an die vortragende Person kommunizieren. Das Frageaufkommen zu bestimmten Zeiten der Vorlesung kann dabei ein Anhaltspunkt für die Schwierigkeit oder die Verständlichkeit eines Vortrags sein, aber auch für die Aufmerksamkeit der Studierenden. So ist in Forschungen mehrfach belegt worden, dass die Aufmerksamkeit in Vorlesungen nach ca. 20 Minuten kontinuierlich abnimmt (z. B. Stuart, 1978, S. 515). Spiegelt sich dies in der Datenanalyse einer stetig nachlassenden Backchannel-Kommunikation, wird für einen Lehrenden deutlich, dass er aktivierende Elemente in seine Veranstaltung einbauen sollte.

Lernen in Gruppen

Die vorstehend erwähnten Zustandsbeschreibungen und Bestehensprognosen können auch für Gruppen erstellt werden. Wenn beispielsweise für eine Veranstaltung Projektgruppen eingerichtet sind, können die Daten der Gruppenmitglieder verknüpft werden und aggregiert z. B. die Aktivität der Gruppe im Vergleich zu anderen anzeigen.

Soziale Zusammenhänge können mit Blick auf den Lernerfolg aber auch dann analysiert werden, wenn zu einer Veranstaltung formal keine fixen Gruppen bestehen. So ist denkbar, dass innerhalb veranstaltungsbezogener Chats und Foren einzelne Studierende intensiv miteinander im Austausch stehen und sich darauf verlassen, durch den Informationsaustausch sinnvoll auf das Bestehen der Abschlussprüfung hinzuarbeiten. Allerdings können alle Teilnehmer einer solchen Gruppe negative Bestehensprognosen haben. Würden solche Beziehungen durch eine Netzwerkanalyse sichtbar gemacht, könnte den Beteiligten in ihrem „Dashboard“ eine entsprechend kritische Bewertung ihres Lernnetzwerks gespiegelt werden. Die Studierenden können dann selbst entscheiden, ob sich die Qualität des Netzwerks verbessern lässt oder ob sie neue Netzwerke aufbauen sollten.

Selbststudium

Die Möglichkeit, Selbststudium durch die Bereitstellung von Lernstandsbeschreibungen und Prognosen anzuregen, ist im Unterkapitel „Semesterbegleitendes Feedback“ bereits aufgezeigt worden. Datenanalysen können darüber hinaus in konkreten Selbststudiensituationen aber auch dabei helfen, dieses zu steuern. So können adaptive Lernsysteme erkennen, welche Aufgaben Studierende bereits lösen können bzw. welche für die Lösung von Aufgaben notwendigen Konzepte Studierende bereits verstehen. Auf Grundlage dieser Erkenntnis können dann beispielsweise in Lernplattformen automatisch Aufgaben ausgewählt werden, die dem Lernstand des Bearbeiters entsprechen. Ist ein Konzept noch nicht verstanden, so können zusätzliche Aufgaben und Erklärungen bereitgestellt werden, bevor der Zugang zu weiterführenden Aufgaben freigegeben wird, mit denen ein Student oder eine Studentin sonst noch überfordert wäre.

Prüfen

Auch das Prüfen im engeren (summativen) Sinne kann durch den Einbezug von Datenanalysen verändert werden. Dies gilt zum einen in der Prüfungsvorbereitung, in der Lehrende einen genaueren Einblick in den Lernstand ihrer Studierenden haben. Möglich ist darüber hinaus der Einbezug der personenbezogenen Daten in die Notengebung. So können ein aktives Nutzungsverhalten auf einer Lernplattform, die erfolgreiche Bearbeitung von Online-Modulen und die aktive und er-

folgreiche Beantwortung von Clickerfragen in der Vorlesung (sofern die Clicker personalisiert sind) zusammen zu einer mündlichen Mitarbeitsnote verbunden oder als Bonus auf eine Note angerechnet werden. Eine solche Nutzung von Daten dürfte freilich aus guten Gründen, auf die im weiteren Verlauf dieses Textes noch eingegangen wird, recht umstritten sein, wie im übrigen auch die inzwischen nicht mehr utopische Möglichkeit, Prüfungsergebnisse von Studierenden computerbasiert bewerten zu lassen (Stichwort „Diskursanalyse“).

Evaluation

Die Evaluation von Veranstaltungen basiert an Hochschulen momentan überwiegend auf den subjektiven Einschätzungen, die Studierende nach Abschluss einer Veranstaltung abgeben. Denkbar ist, diese Evaluationen um ein Set von Daten zu ergänzen, die bei den Online-Aktivitäten während einer Veranstaltung angefallen sind. Lehrende haben so die Möglichkeit, die von ihnen gewählten Lehrstrategien auf einer breiteren Grundlage zu hinterfragen. So kann sich herausstellen, dass mit viel Aufwand bereitgestellte Zusatzmaterialien von den Studierenden nicht genutzt worden sind, was entweder gegen die Materialien an sich sprechen kann oder dafür, dass sie noch besser in die Gesamtveranstaltung integriert werden müssen.

Veranstaltungsplanung

Liegen bereits aus mehreren vergangenen Durchläufen einer Veranstaltung Daten vor, werden diese auch zu einer wichtigen Grundlage der Veranstaltungsplanung. Schließlich kann ein Lehrender auf Grundlage von Daten dann schon absehen, wie seine Studierenden lernen, welche Angebote sie akzeptieren und wann sie diese brauchen. Die Inhalte können sowohl im Semestervorlauf gezielter ausgewählt als auch während eines laufenden Semesters angepasst werden.

Diskussion um Learning Analytics

Die kurzen Ausführungen des vorstehenden Kapitels zeigen somit eine ganze Bandbreite an Möglichkeiten auf, die aus didaktischer Perspektive sinnvolle Nutzungen von Datenanalysen darstellen. Neben den verlockenden Potentialen gibt es aber auch Einschränkungen, derer man sich bewusst sein muss. Dies sind zunächst vor allem datenschutzrechtliche und ethische Fragen (Slade & Galpin, 2012). Schließlich geht es nicht nur um den Umgang mit personenbezogenen Daten, sondern auch um das Eindringen in die Privatsphäre der Lernenden (und Lehrenden). Learning Analytics erlaubt die Beobachtung von Prozessen, die von den Betroffenen als sehr persönlich angesehen werden können.

Hier ist zum einen ein großes Maß an Transparenz erforderlich; zum anderen sollte es für die Betroffenen die Möglichkeit geben, bestimmte Formen der Daten-

speicherung und -analyse auszuschließen. Lernende und Lehrende müssen wissen, was mit den gesammelten Daten geschieht, und sich gegen bestimmte Nutzungen entscheiden können – vor allem gegen Personalisierungen. Dies widerspricht dem Data Mining-Ansatz allerdings insofern, als dass bei „gefundenen“ Daten die „Urheber“ in der Regel nicht mehr gefragt werden können. Auch die Belastbarkeit der Analyseergebnisse wird eingeschränkt, wenn bestimmte Nutzungstypen nicht erfasst werden. Brown (2011, S. 3) weist in diesem Zusammenhang darauf hin, dass Verbesserungsvorschläge, die auf Learning Analytics beruhen, zutreffender sind, wenn (1) die Zahl der beobachtbaren Personen erhöht wird und (2) die Datenmenge, die zur Analyse verfügbar ist, maximiert werden kann.

Die Datenmenge wird beispielsweise dadurch eingeschränkt, dass viele Lernende die bereitgestellten Kommunikations- und Kooperationsmöglichkeiten nicht nutzen, auf alternative reale oder virtuelle Lernräume ausweichen. Dies kann vermehrt vorkommen, wenn Lernende und Lehrende das Gefühl haben, in den bereitgestellten Umgebungen unter Beobachtung zu stehen.

Die Akzeptanz der bereitgestellten Systeme und von Learning Analytics mag indes dann verbessert werden, wenn sie Lernenden und Lehrenden einen unmittelbaren Mehrwert bieten, z. B. in Form von angepassten Lernpfadempfehlungen oder durch die schon erwähnten „Dashboards“, in denen für die Nutzer die erfassten Daten transparent werden. Durch eine gute begleitende Moderation kann immer wieder verdeutlicht werden, was mit den Daten getan wird und wie die Lehrenden auf ihrer Grundlage didaktische Entscheidungen treffen.

Wiederum aus der didaktischen Perspektive gibt es darüber hinaus allerdings weitere Fragen an die vorgestellten Analysemethoden. So bergen sie die Gefahr, dass statt der Qualität die Quantität von Daten positive Bewertungen auslösen. So darf z. B. eine große Zahl unqualifizierter Beiträge in einem Lernforum (z. B. Smileys) keine positivere Bewertung der Analysesoftware auslösen als eine einzelne, aber dafür sehr durchdachte Eintragung. Letztlich bleibt aber auch bei ausreichend intelligenten Softwarelösungen die Frage, inwieweit sie über die in Datenform erfassbaren Äußerungen hinaus auch angestrebte Zustände wie Kompetenz erfassen können. Auch hierfür mögen sich Indikatoren finden lassen, die Erfassung persönlicher Kompetenz in einem umfassenden Sinne – verstanden als Handlungsfähigkeit in komplexen Situationen – dürfte aber doch für Datenanalyse-Tools eine ernste Herausforderung bleiben.

Abschluss und Ausblick

Die vorstehenden Ausführungen haben gezeigt, dass lehr- und lernbezogene Datenanalysen aus didaktischer Perspektive durchaus ein großes Potential bieten. Für die Umsetzung sind aber die nötigen Rahmenbedingungen zu schaffen. Folgende Punkte seien dafür abschließend herausgehoben:

- *Bewusstsein:* Um Verständnis und Unterstützung für den Einsatz von Learning Analytics zu bekommen, muss man sich innerhalb einer Hochschule zunächst der Datenmengen und ihrer Potentiale für die didaktische und institutionelle Weiterentwicklung überhaupt bewusst werden. An vielen Hochschulen in Deutschland scheint dies so noch nicht gegeben zu sein.
- *Regulierung:* Da die Daten aus allen Bereichen einer Hochschule stammen können und auch sensible personenbezogene Daten umfassen, wird eine Strategie zum Umgang mit diesen Daten benötigt. Der Zugriff auf viele Datenquellen unterliegt gesetzlichen und institutionellen Regelungen, die Verknüpfung von Datenquellen und ihre zulässige Nutzung muss reguliert und ein ethischer Konsens hergestellt werden.
- *Transparenz:* Es muss für alle Beteiligten transparent sein, welche Daten erhoben werden und was mit ihnen geschieht. Es muss klar sein, wer welche Informationen in welcher Form bekommt und welche Vorkehrungen zur Einschränkung auch der zukünftigen Nutzung oder von Datenmissbrauch getroffen werden.
- *Didaktischer Mehrwert:* Es sollte eine möglichst genaue Vorstellung von der vorgesehenen Nutzung von Daten bestehen und diese Nutzung den Beteiligten – vor allem auch den „Datenverursachern“ – einen echten Mehrwert bringen.

Der aktuelle NMC Horizon Report (The New Media Consortium, 2014) sieht in Learning Analytics ein für die Zukunft der Lehre höchst relevantes Thema. Die Eingabe des Suchbegriffs bei Google Trends zeigt jedoch auch, dass das allgemeine Interesse sich zurzeit noch im Wesentlichen auf die USA beschränkt, gefolgt von Indien und Großbritannien.

In Deutschland scheint der Trend noch nicht angekommen zu sein. Dies zeigt sich auch daran, dass viele der an deutschen Hochschulen üblichen Lernplattformen die in diesem Text beschriebenen Nutzungen noch gar nicht ermöglichen. Die allgemeine Verfügbarkeit besser geeigneter Technologie wird aber auch hierzulande früher oder später zur Verbreitung lehr- und lernbezogener Datenanalysen führen. Unserer Auffassung nach ist es weniger eine Frage, ob Bildungsdaten mit Hilfe von Learning Analytics und Educational Data Mining ausgewertet werden, sondern unter welchen Bedingungen dies geschieht. Die Einführung entsprechender Me-

thoden und Technologien sollte daher durch eine entsprechende Diskussion über rechtliche, ethische und didaktische Implikationen begleitet werden.

Was ethische Fragen betrifft, so könnte ein Blick auf einen anderen Bereich helfen, der bereits umfangreiche Erfahrung im Umgang mit großen sensiblen Datenmengen hat: die Lebenswissenschaften. Analog zum Fünf-Säulen-Konzept des Deutschen Ethikrates für den Umgang mit Humanbiobanken (Deutscher Ethikrat, 2010) könnten zukünftig, wenn immer größere Bildungsdatenbestände immer größere Risiken des Missbrauchs in sich bergen, ähnliche Maßstäbe an den Umgang mit diesen Daten angelegt werden. Neben der bereits geforderten Transparenz und der Festlegung der zulässigen Nutzung von Bildungsdaten könnten auch die Etablierung eines „Bildungsbankgeheimnisses“, die Einbeziehung von Ethikkommissionen und insbesondere die Einhaltung und Prüfung von Qualitätsstandards eine Grundlage für die Vereinbarkeit von Persönlichkeitsrechten und dem berechtigten Erkenntnisinteresse bilden.

Was letztlich die didaktische Nutzung betrifft, so zeichnet sich mit Blick auf die kritischen Aspekte wie das Thema „Kompetenzmessung“ ab, dass Learning Analytics zwar ein wichtiges Element didaktischer Szenarien werden dürften, letztlich dabei aber auch nur ein Werkzeug unter anderen in einem großen didaktischen Werkzeugkasten sein werden.

Referenzen

Baepler, P. & Murdoch, C. J. (2010): Academic Analytics and Data Mining in Higher Education. In: *International Journal for the Scholarship of Teaching and Learning* 4, Nr. 2.

Baker, R. S. et al. (2012): Educational Data Mining meets Learning Analytics. In: *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*.

Brown, M. (2011): *Learning Analytics: The Coming Third Wave*. Verfügbar unter: <http://net.educause.edu/ir/library/pdf/ELIB1101.pdf> [17.04.2014].

Deutscher Ethikrat (Hrsg., 2010): *Humanbiobanken für die Forschung. Stellungnahme*. Verfügbar unter: <http://www.ethikrat.org/dateien/pdf/stellungnahme-humanbiobanken-fuer-die-forschung.pdf> [17.04.2014].

Greller, W. & Drachslers, H. (2012): Translating Learning into Numbers: A Generic Framework for Learning Analytics. In: *Educational Technology & Society*, Vol. 15, Nr. 3, S. 42–57.

Lauria, Eitel J.M. et al. (2013): Open Academic Analytics Initiative: Initial Research Findings. In: *Proceedings of the Third International Conference on Learning Analytics and Knowledge*, S. 150-154.

Lüth, T., Tscheulin, A. & Salden, P. (2014): *Die Masse in Bewegung bringen. Aktives Lernen in Großveranstaltungen*. Hamburg.

Verfügbar unter: <http://doku.b.tu-harburg.de/volltexte/2014/1262/> [17.04.2014].

Seidel, N. (2014): Analyse von Nutzeraktivitäten in linearen und nicht-linearen Lernvideos. In: *Zeitschrift für Hochschulentwicklung* 9, Nr. 3, S. 94-108.

Shum, S. B. (2012): *Learning Analytics*, UNESCO Institute for Information Technologies in Education. Policy Brief, November 2012. Verfügbar unter: <http://iite.unesco.org/pics/publications/en/files/3214711.pdf> [17.04.2014].

Siemens, G. et al. (2011): *Open Learning Analytics: an integrated & modularized platform*, Society for Learning Analytics Research.

Verfügbar unter: <http://www.solaresearch.org/OpenLearningAnalytics.pdf> [17.04.2014].

Slade, S. & Galpin, F. (2012): Learning Analytics and Higher Education: Ethical Perspectives. In: *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*, S. 16-17.

Stuart, J. & Rutherford, J.R.D. (1978): Medical Student Concentration During Lectures. In: *Lancet*, Nr. 2, S. 514-516.

The New Media Consortium (Hrsg., 2014): *NMC Horizon Report, 2014 Higher Education Edition*.

Verfügbar unter: <http://cdn.nmc.org/media/2014-nmc-horizon-report-HE-DE.pdf> [17.04.2014].

Vita

Dr. Peter Salden ist stellv. Geschäftsführender Koordinator des Zentrums für Lehre und Lernen der Technischen Universität Hamburg-Harburg.

Detlef Rick, Diplominformatiker und Master of Higher Education, ist Fachreferent für die Studieneingangsphase am Zentrum für Lehre und Lernen der Technischen Universität Hamburg-Harburg und Lehrbeauftragter im Bereich der Lehrerbildung Informatik an der Universität Hamburg.

Alexander Tscheulin, Dipl.-Päd., ist Referent für Mediengestütztes Lehren und Lernen am Zentrum für Lehre und Lernen der Technischen Universität Hamburg-Harburg.

Weitere Informationen: <http://cgi.tu-harburg.de/~zllwww/>