

Nutzungsmuster bei digitalen Medien

1. Hintergrund und Motivation

Der Autor dieses Beitrages erstellt seit 2014 kurze, komikartig gehaltene Videos zur Erläuterung der Grundideen statistischer Verfahren; die Videos sind auf dem YouTube-Kanal „Kurzes Tutorium Statistik“ frei verfügbar (eine Beschreibung von Konzept und Ansatz findet sich in Bärthl, 2018). 85% der Zugriffe erfolgen aus Deutschland und weisen ein deutliches „Auf- und Ab“-Muster auf, welches ohne Zweifel die typischen Prüfungsphasen reflektiert. Die Zugriffszahlen suggerieren, dass die Videos primär kurz vor Klausuren, statt kontinuierlich über das Semester verteilt, geschaut werden.

Dieser Artikel liefert einen kurzen Abriss über existierende Forschungsarbeiten zu den Fragen „Wie wichtig ist kontinuierliches Lernen?“ und „Wodurch wird Kontinuität gefördert?“. In einem Kurzbeitrag wie diesem ist es natürlich nicht möglich, den Stand der Forschung umfassend abzubilden; bei der Darstellung handelt es sich um eine Auswahl interessanter Artikel zur schlaglichtartigen Charakterisierung der Thematik. Insbesondere wurde der Fokus auf Arbeiten gelegt, welche auf automatisch erhobene Nutzungsdaten digitaler Lernunterstützungsinstrumente zurückgreifen.

2. Relevanz kontinuierlicher Nutzung digitaler Lernmedien

Zur Unterstützung der Entwicklung eines Monitoring-Systems für Lehrende werten Macfadyen und Dawson (2010) die Logdaten eines über Black Board Vista komplett online gehaltenen Biologiekurses aus (118 Studierende der University of British Columbia aus dem Jahr 2008). Neben weiteren Untersuchungen zu Lernnetzwerken stellen sie ein Regressionsmodell über 22 Variablen (wie etwa Zahl der online-Sitzungen, gesamte online-Zeit, Anzahl gelesener Kurs-E-mails) auf. Sie versuchen so, die wesentlichen Vorhersagegrößen für die Abschlussnote sowie den Teilnahmeerfolg (bestanden/nicht bestanden) zu ermitteln und gelangen zu dem Ergebnis, dass die absolute Anzahl der abgesetzten Diskussionsbeiträge ($\beta = 0,44$), die Zahl der abgeschlossenen (freiwilligen, unbenoteten) Selbsttests ($\beta = 0,18$) sowie die Anzahl der gesendeten Kurs-E-mails ($\beta = 0,17$) die stärkste Vorhersagekraft in Bezug auf die Abschlussnote besitzen (Aufklärung von über 30% der Varianz der Abschlussnote; alle Größen sind signifikant mit $p < 0,05$). Zwar kann man spekulieren, dass ein höheres Maß an Gesamtaktivität über kontinuierliche Arbeit erreicht wird, allerdings ist dies nicht zwingend. Eine in der Studie in dieser Hinsicht nicht thematisierte Grafik suggeriert vielmehr, dass

alle Leistungscluster tatsächlich starke Aktivitätsfluktuationen über den Verlauf des Kurses aufweisen.

Hershkovitz und Nachmias (2011) widmen sich speziell der Frage, welches Durchhaltevermögen und Verhalten Studierende bei der Nutzung digitaler Lernsysteme im Laufe eines Semesters zeigen. Sie kumulieren hierzu alle Moodle-Aktivitäten wie etwa das Anschauen, Hinzufügen oder Aktualisieren von Materialien jedes Teilnehmers (1189 Studierende der Tel Aviv University aus dem Semester 2008/09) in einer tagesgenauen Betrachtung. Aus den so erhobenen Aktivitätsverläufen bilden sie Cluster von Nutzern und identifizieren fünf Typen: Low-extent users (155 der 1189 Teilnehmer, generell niedriges Aktivitätsniveau), Late users (149 Teilnehmer, primär gegen Ende des Semesters aktiv), Online quitters (151 Teilnehmer, nach kurzer Zeit der Kursteilnahme inaktiv), Accelerating users (341 Teilnehmer, hauptsächlich zu Beginn und am Ende des Kurses aktiv) und Decelerating users (393 Teilnehmer, gegen Ende des Kurses inaktiv). Prinzipiell ist das Wissen um die Verschiedenartigkeit der Nutzungsmuster zwar informativ, allerdings stellen die Autoren keinen Bezug zum Lernerfolg her.

Thematisiert wird der Zusammenhang zwischen Regelmäßigkeit der Nutzung elektronischer Materialien und dem Studienerfolg bei You (2016), der das Nutzungsverhalten der Teilnehmer eines online gehaltenen Kurses „Introduction to Color“ untersucht (530 Studierenden einer Südkoreanischen Universität), indem er erhebt, ob und in welchem Umfang ein zu Beginn jeder Woche aktiv gestelltes Video innerhalb der vorgegebenen Zeitspanne angesehen wird. Die so identifizierte Nutzungsregelmäßigkeit, sowie weitere aus Logdaten ersichtliche Kenngrößen, setzt er in Bezug zu den Punktzahlen, die in zwei offline abgehaltenen Prüfungen erreicht wurden. Auf Basis einer hierarchischen Regressionsanalyse identifiziert You die Regelmäßigkeit des Studierens ($\beta = 0,35$; $p < 0,001$) als die wichtigste Vorhersagegröße für den Studienerfolg, gefolgt von der Zahl abgehaltener Sitzungen ($\beta = 0,18$; $p < 0,001$), verspäteten Abgaben von Kursaufgaben ($\beta = -0,18$; $p < 0,001$) und gelesenen Kursinstruktionen ($\beta = 0,11$; $p < 0,01$). Da es sich beim untersuchten Objekt um einen ausschließlich online gehaltenen Kurs handelt, sind die Ergebnisse nicht vorbehaltlos auf primär unterstützende elektronische Materialien übertragbar. Generell weisen sie jedoch auf die Wichtigkeit einer kontinuierlichen Kursteilnahme hin.

3. Kontinuitätsfördernde Elemente

Hohe Abbruchquoten bei online-Kursen sind als Problem bekannt, weswegen sich verschiedene Untersuchungen mit möglichen Einflussgrößen auf Abbruch- bzw. Fortsetzungsentscheidungen befassen. So identifiziert Lee

(2010) bei der Untersuchung eines web-basierten Lernsystems (363 Rückläufer einer Befragung, National Pingtung University, Taiwan) mithilfe eines Strukturgleichungsansatzes, welcher Elemente des expectation-confirmation models, des technology acceptance models, der theory of planned behavior sowie der flow theory verbindet, dass Zufriedenheit mit den Materialien (0,518; $p < 0,001$) den stärksten Einfluss auf die Fortsetzungsabsicht ausübt, gefolgt von der empfundenen Nützlichkeit (0,208; $p < 0,05$) und der Einstellung zu elektronischen Materialien (0,164; $p < 0,05$). Vergleichbare Ansätze, welche zusätzlich eine Beziehung zum Lernerfolg herstellen, existieren, bleiben aber ähnlich vage (z.B. Lee, Wong & Fung, 2010).

Guo, Kim und Rubin (2014) befassen sich gesondert mit Videos, um den Einfluss von Video-Produktionsstilen auf die Zuschauerbindung zu ermitteln; hierzu werten Sie die Daten aus über 6,9 Mio. Videobetrachtungen auf der MOOC-Plattform edX aus dem Herbst 2012 aus. Sie erfassen unter anderem, nach wie vielen Minuten Lehrvideos abgebrochen wurden und setzen dies in Verbindung mit videospezifischen Merkmalen wie Produktionsstil (unterschieden in kommentierte Folien, Programmiercode, Tablet-Freihandzeichnung, Vorlesungsaufnahme, Studioaufnahme und Schreibtischaufnahme), Gesamtdauer des Videos, Sprechgeschwindigkeit und weiteren Merkmalen. Sie gelangen zu dem Ergebnis, dass kürzere Videos stärker binden, dass Aufzeichnungen mit direktem Blickkontakt des Vortragenden (Schreibtischaufnahme) vorteilhafter sind als Vorlesungsaufzeichnungen, dass Tablet-Freihandzeichnungen stärker binden als Folien oder die Aufzeichnung getippten Programmiercodes, und dass Studierende unterschiedlich mit Vorlesungsaufzeichnungen und Tutorials umgehen sowie durchschnittlich länger schauen, wenn der Vortragende schneller spricht. Die Untersuchung greift zwar auf eine hohe Zahl von Videositzungen zurück, die Videovergleiche sind jedoch auf insgesamt vier Kurse beschränkt. Ferner konzentriert sich die Studie auf die Zuschauerbindung innerhalb eines Videos und trifft keine Aussage über das Nutzungsverhalten im Verlaufe des Kurses. Die Resultate der Auswertung können daher nur als Anregung zur Entwicklung von Maßnahmen dienen, die Studierende zu einer zeitlich gleichmäßiger verteilten Nutzung von Lernvideos motivieren könnten.

4. Fazit

Die mittlerweile starke Einbindung digitaler Medien in den Lehrbetrieb ermöglicht neue Formen der Erhebung und Analyse des Verhaltens von Lernenden. Die vorgestellten Untersuchungen deuten darauf hin, dass Studierende elektronische Materialien sehr unterschiedlich nutzen, dass sich eine kontinuierliche Nutzung positiv auf den Lernerfolg auswirkt, dass aber auch

bei stark fluktuierender Nutzung gute Noten erzielt werden können. Eine abschließende Antwort auf die Frage nach der optimalen Gestaltung und Einbindung kann trotz einer Vielzahl existierender Untersuchungen (für einen Überblick vgl. z.B. Peña-Ayala, 2014) bislang jedoch nicht gegeben werden. Ein sinnvoller Weg zur Systematisierung unterschiedlicher Ansätze könnte die Durchführung von Metastudien sein; Beispiele hierfür existieren für Computerspiele und Simulationen in der Lehre (vgl. z.B. Clark, Tanner-Smith & Killingsworth, 2016 oder Merchant, Goetz, Cifuentes, Keeney-Kennicutt & Davis, 2014).

Literatur

- Bärtl, M. (2018). Kurzes Tutorium Statistik – YouTube Videos zur beschreibenden Statistik. In A. Salle, S. Schumacher & M. Hattermann (Hrsg.), *Mathematiklernen mit digitalen Medien – Ergebnisse des mamdim-Projekts*. Berlin, Heidelberg: Springer.
- Clark, D., Tanner-Smith, E. & Killingsworth, S. (2016). Digital Games, Design, and Learning: A Systematic Review and Meta-Analysis. *Review of Educational Research* 86, 79–122.
- Guo, P., Kim, J. & Rubin, R. (2014). How Video Production Affects Student Engagement: An Empirical Study of MOOC Videos. *Proceedings of the first ACM conference on Learning*, 41–50.
- Hershkovitz, A. & Nachmias, R. (2011). Online persistence in higher education web-supported courses. *Internet and Higher Education* 14, 98–106.
- Lee, E., Wong, K. & Fung C. (2010). How does desktop virtual reality enhance learning outcomes? A structural equation modeling approach. *Computers & Education* 55, 1424–1442.
- Lee, M. (2010). Explaining and predicting users' continuance intention toward e-learning: An extension of the expectation-confirmation model. *Computers & Education* 54, 506–516.
- Macfadyen, L. & Dawson, S. (2010). Mining LMS data to develop an „early warning system“ for educators: A proof of concept. *Computers & Education* 54, 588–599.
- Merchant, Z., Goetz, E., Cifuentes, L., Keeney-Kennicutt, W. & Davis, T. (2014). Effectiveness of virtual reality-based instruction on students' learning outcomes in K-12 and higher education: A meta-analysis. *Computers & Education* 70, 29–40.
- Peña-Ayala, A. (2014). Educational data mining: A survey and a data mining-based analysis of recent works. *Expert systems with Applications* 41, 1432–1462.
- You, J. (2016). Identifying significant indicators using LMS data to predict course achievement in online learning. *Internet and Higher Education* 29, 23–30.