

Informationsgehalt von Teilnehmerdaten in einem webbasierten Vorkurs: Zusammenhänge zwischen Selbsttests, Fragebögen, LMS Logfiles und späterem Studienerfolg

Als Reaktion auf zunehmend diverse Eingangsvoraussetzungen der Studienanfänger/-innen hat sich das Angebot an Kursen zur Studienvorbereitung in den vergangenen Jahren deutlich erhöht (Bargel, 2015, Wild & Esdar, 2014). Insbesondere in Grundlagenfächern wie Mathematik liegt der Fokus darauf, die Studieneingangsphase von der Wiederholung von Schulstoff zu entlasten. Ein Ansatz, um die sehr heterogene Gruppe der Vorkursteilnehmer/-innen zu adressieren, sind E-Learning oder Blended Learning Angebote, bei denen Unterschiede im Vorwissen, Lerntempo, aber auch in der Lebens- und Arbeitssituation in der Zeit vor Studienbeginn berücksichtigt werden können. Ein weiterer Vorteil solcher Kursformate ist, dass Teilnehmerdaten, Test- und Umfrageergebnisse in digitaler Form vorliegen, was die Durchführung von statistischen Analysen sehr erleichtert. Auch wenn nicht alle Daten, die über Lernmanagementsysteme gesammelt werden auch einen Mehrwert liefern (Macfadyen & Dawson, 2010), kann die Digitalisierung zu neuen Fragestellungen führen, beispielsweise der Identifikation von Risikofaktoren im Kontext von Learning Analytics (Ferguson, 2012).

In diesem Beitrag werden die Ergebnisse einer systematischen Auswertung von Lernerdaten in einem webbasierten Mathematik-Vorkurs vorgestellt. Hintergrund der Analysen war die Frage, ob das Vorkursangebot die Chancen von „Risiko“-Studierenden auf eine erfolgreiche Studieneingangsphase erhöht. Eingangsvoraussetzungen und demografische Daten wurden mit Teilnehmerdaten des Vorkurses und Studienerfolg in einem ingenieurwissenschaftlichen Studium in Beziehung gesetzt (Datenbasis: vier Jahrgänge einer technischen Fakultät, N = 2367). Die Lernaktivitäten im Vorkurs wurden über unterschiedliche Quellen analysiert: Selbstauskunft der Studierenden, ein Fragebogen zum Einsatz von Lernstrategien (Schiefele et al., 1993), sowie die Analyse von LMS-Logfiles. Es wurde erwartet, dass Teilnehmer/-innen mit der Fähigkeit zum selbstregulierten Lernen und einem hohen Level an Engagement auch einen höheren Lernzuwachs im Vorkurs zeigen würden. Darüber hinaus wurde angenommen, dass sich affektive Variablen, beispielsweise die Einstellung gegenüber dem Fach Mathematik, positiv auf Lernaktivität und -erfolg auswirken würden (TIMSS Subskalen, siehe Kadujevich, 2006).

Über multiple Regression konnten bestehende Annahmen zum starken Zusammenhang zwischen Vorwissen und akademischer Leistung in MINT-Fächern bestätigt werden (z.B. Ackerman et al., 2013). Sowohl die Art der Hochschulzugangsberechtigung als auch die Schulnoten hatten einen signifikanten Einfluss auf Klausurergebnisse und GPA (Grade Point Average) am Ende des Studiums. Den stärksten Beitrag zur Erklärung späteren Studienerfolgs lieferten die Ergebnisse in einem Mathematik-Eingangstest. Der Einfluss anderer Faktoren, beispielsweise Geschlecht oder Alter der Studienanfänger/-innen, war unerwartet schwach oder inkonsistent. Es konnte außerdem gezeigt werden, dass von allen Klausuren, die im ersten Studienjahr geschrieben werden, Mathematik I den stärksten Zusammenhang mit dem GPA am Ende des Studiums aufweist.

Die Ergebnisse legen nahe, dass Studienanfänger/-innen mit geringen Mathematik-Vorkenntnissen eine deutlich schwierigere Startposition haben. Im nächsten Schritt wurde untersucht, ob diese durch

Teilnahme am Vorkurs verbessert wurde. Tatsächlich zeigte der Lernerfolg, gemessen als Differenz zwischen dem Eingangstestergebnis und einem Post-Test, einen signifikanten, allerdings nicht sehr starken Einfluss im multiplen Modell. Das heißt, nicht alle Teilnehmer/-innen konnten gleichermaßen von der Vorkursteilnahme profitieren.

Über Varianzanalysen wurde untersucht, welche Faktoren sich positiv auf den Lernerfolg auswirken. Entgegen der Erwartung konnte kein Einfluss affektiver und meta-kognitiver Variablen beobachtet werden. Die Einstellung gegenüber Mathematik und auch der effiziente Einsatz von Lernstrategien korrelierten zwar mit den Vorkenntnissen, d.h. Studienanfänger/-innen mit guten Noten / Eingangstestergebnissen zeigten auch eher positive Einstellungen und hohe Werte in Bezug auf die Fähigkeit zum selbstregulierten Lernen. „Risiko“-Studierende hatten dagegen selten eine positive Einstellung gegenüber dem Fach. Falls doch, hatte dies, ebenso wie ein effizienter Einsatz von Lernstrategien, keinen Einfluss auf ihren Lernzuwachs. Auch die investierte Lernzeit oder die Zahl der besuchten Lernmodul-Seiten waren wenig aussagekräftig. Ein signifikantes und nicht-moderiertes Ergebnis wurde nur für die Anzahl der durchgeführten Selbsttests beobachtet. Je mehr Online-Tests ein Teilnehmer abgeschlossen hatte, desto höher war auch der Lernerfolg im Vorkurs. Im multiplen Modell konnte diese Variable sogar einem signifikanten Anstieg in Mathematik I zugeordnet werden.

Die Ergebnisse zeigen, dass nicht alle Daten, die von offenen Online-Lernangeboten erfasst werden, aussagekräftige und konsistente Resultate liefern. In einem sehr volatilen Datensatz wurde die Anzahl der durchgeführten Selbsttests als stärkster Indikator für einen effektiven und erfolgreichen Lernprozess in Mathematik identifiziert. Auf Basis dieser Analysen soll die Rolle des Übens im weiteren Projektverlauf intensiver untersucht werden, in Verbindung mit einer Erweiterung des Angebots an Übungsaufgaben. Die Resultate werden außerdem in aufbereiteter Form an Studienanfänger/-innen weitergegeben, um auf die Relevanz der Grundlagenkenntnisse in Mathematik für ihr Studium hinzuweisen.

Einschränkend ist zu sagen, dass die Vorhersagekraft solcher Modelle begrenzt ist. Trotz des stabilen und überzeugenden Zusammenhangs insbesondere der kognitiven Variablen führte das multiple Modell in dieser Studie zu einer erklärten Varianz von maximal 36%. Ganz offenbar sind also noch weitere Faktoren nötig, um zuverlässige Prognosen über akademischen Erfolg anstellen zu können, beispielsweise die Zufriedenheit mit dem Studiengang oder das persönliche Umfeld (Heublein & Wolter, 2011).

Referenzen

- Ackerman, P. L., Kanfer, R. & Beier, M. E. (2013). Trait Complex, Cognitive Ability, and Domain Knowledge Predictors of Baccalaureate Success, STEM Persistence and Gender Differences. *Journal of Educational Psychology*, 105 (3), 911–927.
- Bargel, T. (2015). *Studieneingangsphase und heterogene Studentenschaft - neue Angebote und ihr Nutzen. Befunde des 12. Studierendensurveys an Universitäten und Fachhochschulen*. Hefte zur Bildungs- und Hochschulforschung 83. Universität Konstanz.
- Ferguson, R. (2012). Learning analytics: drivers, developments and challenges. *IJTEL International Journal of Technology Enhanced Learning*, 4 (5/6), 304–317.
- Heublein, U. & Wolter, A. (2011). Studienabbruch in Deutschland. Definitionen, Häufigkeit, Ursachen, Maßnahmen. *Zeitschrift für Pädagogik*, 57 (2), 214–236.

- Kadijevich, D. (2006). Developing Trustworthy Timss Background Measures: A Case Study On Mathematics Attitude. *The Teaching of Mathematics* (2), 41–51.
- Macfadyen, L. P. & Dawson, S. (2010). Mining LMS data to develop an 'early warning system' for educators: A proof of concept. *Computers & Education*, 54 (2), 588–599.
- Schiefele, U., Krapp, A. & Winteler, A. (1993). Der Fragebogen zum Studieninteresse (FSI). Study Interest Questionnaire (SIQ). *Diagnostica*, 39, 335–351.
- Wild, E. & Esdar, W. (2014). *Eine heterogenitätsorientierte Lehr-/Lernkultur für eine Hochschule der Zukunft*. Hochschulrektorenkonferenz HRK.