

Learning Analytics in digitalen Selbstlernkursen.

In: Learning Analytics, Artificial Intelligence und Data Mining in der Hochschulbildung, Beiträge zur Learning AID 2024.

Robert Queckenberg, Jonas Leschke, Malte Persike (Hrsg.), Zukunft der Hochschule (S. 51–60). Transcript Verlag.

**Böttcher, R., Rüter,
M., Schug, J. (2025).**

Learning Analytics in digitalen Selbstlernkursen¹

Roland Böttcher, Marina Rüter und Jonas Schug

Der Beitrag diskutiert die Verarbeitung, Auswertung und Nutzung von Learning-Analytics-Daten in umfangreichen digitalen Moodle-Selbstlernkursen. Ausgewertet wird das Lernverhalten von 492 Studierenden eines Selbstlernkurses mit automatisierter Portfolioprüfung. Die Datenbasis umfasst u.a. den zeitlichen Verlauf der Bearbeitung von Lernelementen, Zeitstempel von Aktivitätsabschlüssen, Zeitstempel von automatisierten Nachrichten zur Motivationssteuerung, individuelle Ergebnisse von 105 formativen Tests sowie Daten eines lernstrategischen Verhaltensprofils. Dabei wurden drei Steuerungsdimensionen identifiziert: langfristige Kursoptimierung (1), Ad-hoc-Anpassungen (2) und die Förderung von Kommunikation und Motivation (3). Die Ergebnisse zeigen, dass Learning Analytics Lehrenden Ansätze bietet, um – im Rahmen dieser Dimensionen –, Risikogruppen zu definieren, kritische Lernelemente zu identifizieren, Dropout-Raten zu reduzieren und das Kursdesign zu optimieren.

Learning analytics in digital self-learning courses

The report discusses the processing, evaluation and use of learning analytics data in extensive digital Moodle self-learning courses. The learning behaviour of 492 students of a self-study course with automated portfolio assessment is evaluated. The database includes, the time course of the processing of learning elements, time stamps of activity completions, time stamps of automated messages for motivation control, individual results of 105 formative tests of each participant as well as data of a learning-strategic behaviour profile. Three dimensions of control were identified: long-term course optimization (1), ad hoc adjustments (2) and the promotion of communication and motivation (3). The results show that learning analytics offers teachers approaches for identifying risk groups at an early stage, identifying critical learning elements, reducing dropout rates and optimizing course design within the scope of these dimensions.

1 Basiert auf einem Impulsbeitrag im Rahmen der Tagung.

Einleitung

Im Zuge der Digitalisierung werden in Hochschulen zunehmend digitale Lernwelten implementiert. Dieser Beitrag untersucht ein asynchrones Selbstlernangebot, das zeit- und ortsunabhängiges Lernen ermöglicht. Trotz dieser Flexibilität bleibt die Betreuung durch Lehrende essenziell, um fachliche Fragen zu klären, Motivation zu fördern und Feedback zu geben. Ohne diese Unterstützung können isolierte Lernsituationen und erhöhte Dropout-Raten entstehen. Da Lehrende oft nur begrenzte Einblicke in den Lernfortschritt haben, bieten Learning Analytics eine Lösung durch systematische Datensammlung und -auswertung, um gezielte Anpassungen und Interventionen vorzunehmen.

Steuerung von digitalen Selbstlernkursen mittels Learning Analytics

Seit den 1990er Jahren wird selbstgesteuertes Lernen – als ein zentrales Merkmal digitaler Selbstlernkurse – intensiv erforscht. Hattie und Timperley (2007) betonen die Rolle von Feedback, während Ifenthaler und Drachsler (2019) auf die Bedeutung von Learning Analytics zur Analyse des Lernverhaltens und zur Umsetzung von Interventionen hinweisen. Leitner und Ebner (2017) heben hervor, dass Learning Analytics zur Identifikation von Risikogruppen und Reduzierung von Dropout-Raten genutzt werden kann. Der Beitrag orientiert sich an Studien zu datengesteuerter Entscheidungsfindung (Kaspi & Venkatraman, 2023) und evidenzbasierten Interventionen (Utamachant et al., 2023) und folgt einem Design-Based Research (DBR)-Ansatz, um die Lernumgebung iterativ zu optimieren (Bakker & Van Eerde 2015).

Der untersuchte Selbstlernkurs

Die Datenerhebung und -analyse erfolgte an dem digitalen Selbstlernkurs »Einführung in die Betriebswirtschaftslehre« (EBWL), der in einem Konsortium von sieben Hochschulen in NRW entwickelt wurde und curricular eingesetzt wird. Der Kurs umfasst eine narrative Rahmung, Lehrvideos, ein animiertes Glossar, Skripte, interaktive Vertiefungstexte, Tests, Quizze sowie Lektions- und einen Kursabschlusstest. Der Kurs ist über Moodle jederzeit zugänglich. Der Ablauf ist sequentiell und Lerneinheiten werden erst

nach Abschluss der vorherigen freigeschaltet. Studierende sammeln Punkte, hauptsächlich durch Lektionsabschlusstests (LAT – jeweils 100 Punkte) und den Kursabschlusstest (KAT – 300 Punkte), deren Fragen zufällig aus lektions-spezifischen Fragen-Pools gezogen werden (>1.500 Fragen in verschiedenen Fragetypen).

Datenauswertung

Aus bisherigen Forschungsarbeiten (siehe Abschnitt 2) lassen sich drei Steuerungsdimensionen (SD) identifizieren:

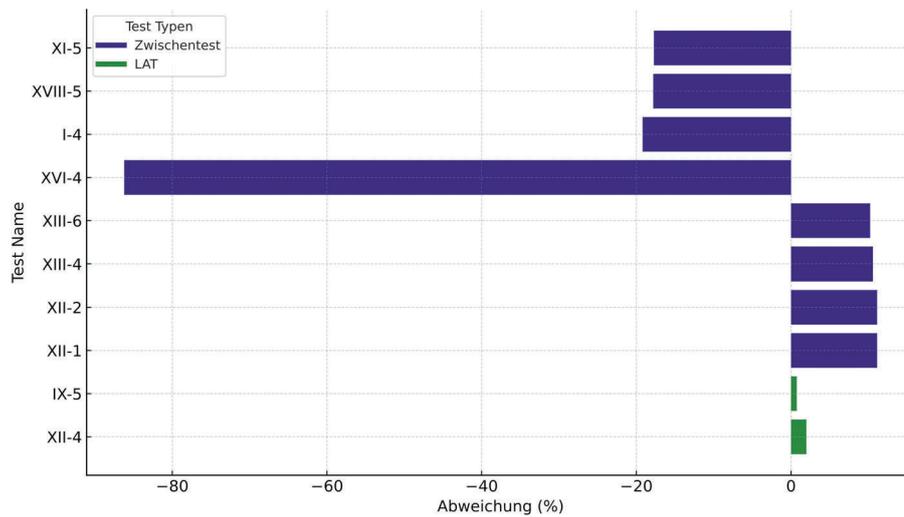
- **SD1:** Langfristige Kursoptimierung (z.B.: Weiterentwicklung des Kursdesigns, Implementierung neuer Lernelemente) – z.B. Buckingham Shum et al., 2019
- **SD2:** Ad-hoc-Kursoptimierungen (z.B.: Identifikation von inhaltlichen/formalen Fehlern) – z.B. Kaspi & Venkatraman, 2023
- **SD3:** Kommunikation und Motivation (z.B.: (Teil-)Automatisierte Nachrichten an Studierende/Studierendengruppen; motivationale Elemente) – z.B. Utamachant et al., 2023

Die Datenanalyse sowie die daraus abgeleiteten Empfehlungen für Maßnahmen, Interventionen und zur Kommunikation werden nun anhand dieser Dimensionen erläutert. Alle im Folgenden dargestellten Interventionsmechanismen wurden tatsächlich im dargestellten Kurs erprobt.

SD1: Langfristige Kursoptimierung

a) Testergebnisse: Einzelne Testergebnisse weichen signifikant vom errechneten Mittelwert ab (vgl. Abb. 1).

Abb. 1: Abweichende Testelemente



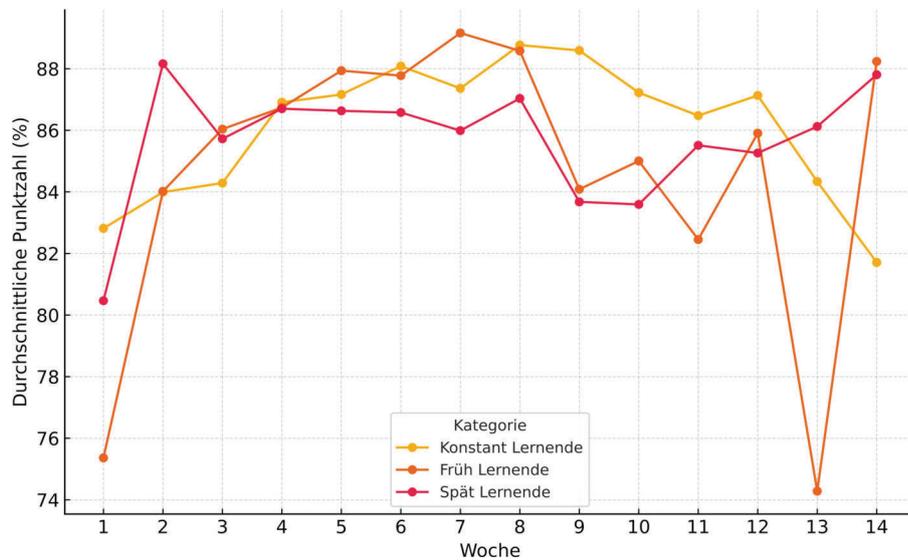
Lektionsabschlussstests (LAT): IX-5, XII-4

Zwischentests: XII-1, XII-2, XIII-4, XIII-6, XVI-4, I-4, XCIII-5, XI-5

Maßnahmen: Dies ermöglicht Lehrenden, gezielt Tests zu identifizieren und zu überarbeiten die auffallend erfolgreich oder unerfolgreich absolviert werden.

b) Erfolgsquoten: Der durchschnittliche Prozentsatz der erreichten Punkte im Zeitverlauf lässt sich – auf Basis einer Clusteranalyse (sortiert nach durchschnittlichem Testzeitpunkt) – in drei Gruppen differenzieren (vgl. Abb. 2): früh Lernende, konstant Lernende und spät Lernende. Die Gruppe der »Früh Lernenden« zeigt dabei anfangs hohe Durchschnittswerte, die im Laufe der Zeit leicht abnehmen, während die »Konstant Lernenden« stabile Durchschnittswerte aufweisen. »Späte Lernende« beginnen später im Kursverlauf, zeigten jedoch eine steigende Tendenz in den erreichten Prozentzahlen.

Abb. 2: Durchschnittlicher Prozentsatz nach Gruppen

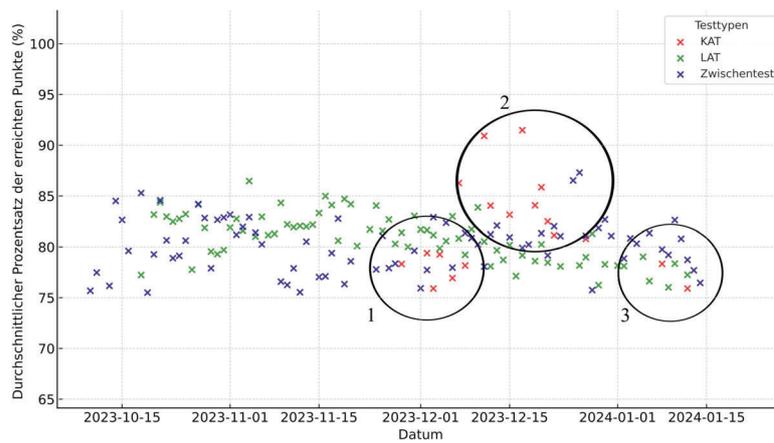


Maßnahmen: Das vorliegende Muster bietet Lehrenden die Möglichkeit, gezielte Interventionen für späte und unregelmäßige Lernende durch frühzeitige Erkennung dieser Gruppen zu entwickeln, etwa durch motivierende Mitteilungen oder gezielte Unterstützung, sowie die Kurskonzeption so zu gestalten, dass frühes und kontinuierliches Lernen stärker gefördert und damit dafür Anreize geschaffen werden.

b) Leistungsprofil nach Testtyp und Testzeitpunkt: Der durchschnittliche Prozentsatz der erreichten Punkte kann nach Testtypen und Testzeitpunkten (z.B. Lektionsabschluss-tests, Kursabschluss-tests) differenziert werden. Dabei lassen sich drei Gruppen identifizieren (Abb. 3): »frühe Finalisten« mit niedrigen Erfolgen (1), die »Hauptgruppe« mit konstant hohen Ergebnissen im Kursabschluss-test (2), und »späte Finalisten« (3), die erst spät beginnen und ebenfalls geringe Punktzahlen erzielen. Es zeigt sich, dass nicht nur der Startzeitpunkt, sondern auch die kontinuierliche Teilnahme entscheidend für den Lernerfolg ist.

Abb. 3: Erfolg nach Datum und Testtyp

- 1: frühe Finalisten mit niedrigen Erfolgen im Kursabschlusstest
- 2: Hauptgruppe mit konstant hohen Ergebnissen im Kursabschlusstest
- 3: späte Finalisten mit niedrigen Erfolgen im Kursabschlusstest



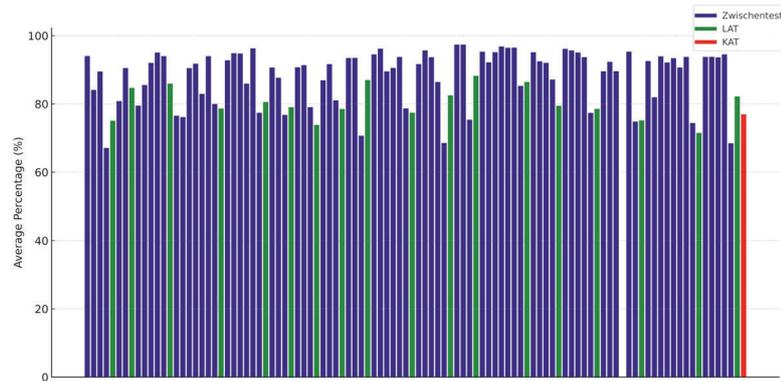
Maßnahmen: Zielgerichtete Interventionen können an den spezifischen Bedürfnissen der jeweiligen Gruppen ansetzen.

SD2: Ad-hoc-Kursoptimierungen

a) Testergebnisse: Abb. 4 zeigt die durchschnittlichen Testresultate.

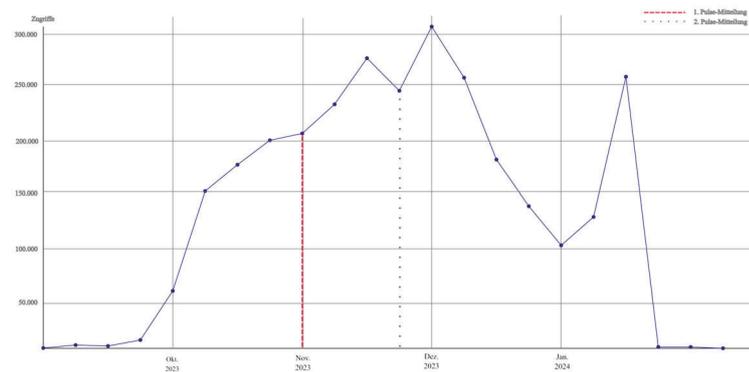
Maßnahmen: Ausreißer können z.T. auf einen Fehler im Kurs zurückgeführt und ad hoc-behoben werden.

Abb. 4: Durchschnittliche Testresultate



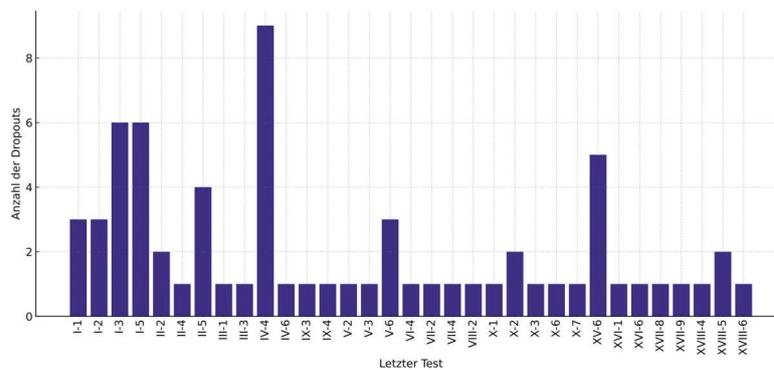
a) Automatisierte Mitteilungen: Abb. 5 zeigt die Anzahl der Zugriffe (Seitenauf-rufe) pro Woche im Verlauf des Semesters. Im Kursverlauf wurden automati-siert Nachrichten («Pulse-Mitteilungen») an Studierende versandt, die bisher noch geringe Beteiligungswerte am Kurs hatten. Diese Mitteilungen forderte Sie auf, sich zeitnah stärker im Kurs zu engagieren, um den Kurs erfolgreich zu absolvieren. Die sichtbare Steigerung der Lernaktivitäten nach den Mitteilun-gen zeigt, dass gezielte, motivierende Nachrichten ein wirksames Instrument zur Steuerung von Selbstlernprozessen darstellen.

Abb. 5: Zeitachse der Zugriffe (Seitenauf-rufe) mit Zeitpunkten (1. und 2.) automatisierter Benachrichtigungen



b) Dropouts: Die Analyse der letzten abgeschlossenen Tests zeigt, dass Dropouts sich auf bestimmte Tests konzentrieren, was auf kritische Lernelemente hinweist (Abb. 6). Der Vergleich der durchschnittlichen Punktzahlen der Dropouts (79,56 %) mit den Nicht-Dropouts (85,17 %) zeigt nur eine geringe Differenz, was darauf hinweist, dass die Abbrecher ähnliche Leistungen erbrachten. Dies lässt die Schlussfolgerung zu, dass der Kursabbruch oft nicht auf mangelndem Verständnis, sondern auf externen Faktoren wie Zeitdruck, fehlender Motivation oder persönlichen Umständen basiert.

Abb. 6: Dropouts



Maßnahmen: Für die Kurssteuerung bedeutet dies, dass Interventionen nicht allein auf die Verbesserung der Testresultate abzielen sollten, sondern auch unterstützende Maßnahmen zur Steigerung der Motivation, zum besseren Zeitmanagement und zur persönlichen Betreuung notwendig sind, um Dropouts präventiv entgegenzuwirken.

Zusammenfassung

Langfristige Kursoptimierung (SD1): Analysiert signifikante Abweichungen und Korrelationen von Testergebnissen, um gezielte Interventionen zu entwickeln und das Kursdesign anzupassen.

Ad-hoc-Kursoptimierungen (SD2): Nutzt zeitliche Analyse der Testergebnisse, um Fehler im Kurs zu identifizieren und Inhalte in Echtzeit anzupassen.

Kommunikation und Motivation (SD3): Überwacht die Testaktivität und Dropout-Muster, um motivationsfördernde Maßnahmen wie Pulse-Mitteilungen gezielt einzusetzen.

Fazit und Ausblick

Es konnte gezeigt werden, dass Lehrende in digitalen Selbstlernkursen durch die Auswertung der in Moodle vorliegenden Daten Lernprozesse ihrer Studierenden besser verstehen und steuern können. Insbesondere die Identifikation technischer Fehler und Risikogruppen sowie die Analyse von Dropout-Raten bieten Einblicke, die zur Optimierung der Kursgestaltung und zur Entwicklung gezielter Interventionsmaßnahmen beitragen können. Allerdings bleibt eine zentrale Einschränkung bestehen: Learning Analytics zeigen meist nur, *was* Studierende tun, aber nicht *warum* (Buckingham Shum et al., 2019). Deshalb erfordert ihre Anwendung fundiertes didaktisches Wissen und eine kontextsensitive Dateninterpretation. Zukünftige Arbeiten sollten die Ergebnisse in ein umfassenderes Modell integrieren, um Learning Analytics gezielter für die Steuerung von Selbstlernprozessen einsetzen zu können.

Literatur

- Bakker, A., & van Eerde, D. (2015). An Introduction to Design-Based Research with an Example from Statistics Education, In: A. Bikner-Ahsbals, C. Knipping, & N. Presmeg (Eds.), *Approaches to Qualitative Research in Mathematics Education: Examples of Methodology and Methods* (pp. 429–466). Springer.
- Buckingham Shum, S, Ferguson, R & Martinez-Maldonado, R 2019, Human-centred learning analytics, In: *Journal of Learning Analytics*, vol. 6, no. 2, pp. 1–9.
- Hattie, J. & Timperley, H. (2007). *The power of feedback*. In: *Review of Educational Research*, 77(1), pp. 81–112.

- Ifenthaler, D., Drachsler, H. (2018). Learning Analytics. In: Niegemann, H., Weinberger, A. (eds) *Lernen mit Bildungstechnologien*. Springer Reference Psychologie. Springer, Berlin, Heidelberg.
- Kaspi, Samuel & Venkatraman, Sitalakshmi. (2023). Data-Driven Decision-Making (DDDM) for Higher Education Assessments: A Case Study. In: *Systems*. 11. 306
- Leitner, P, Khalil, M & Ebner, M 2017, Learning Analytics in Higher Education — A Literature Review. in A Peña-Ayala (ed.), *Learning Analytics: Fundamentals, Applications, and Trends*. vol. 94, Studies in Systems, Decision and Control, Springer International Publishing AG
- Utamachant, P., Anutariya, C. & Pongnumkul, S. i-Ntervene: applying an evidence-based learning analytics intervention to support computer programming instruction. *Smart Learn. Environ.* 10, 37 (2023).