

AI-Driven Learning Engagement Design

Studentisches Engagement als steuerbare Prozessgröße
im digitalen Hochschulkontext



Der Wachstumsmarkt privater Hochschulen in Deutschland

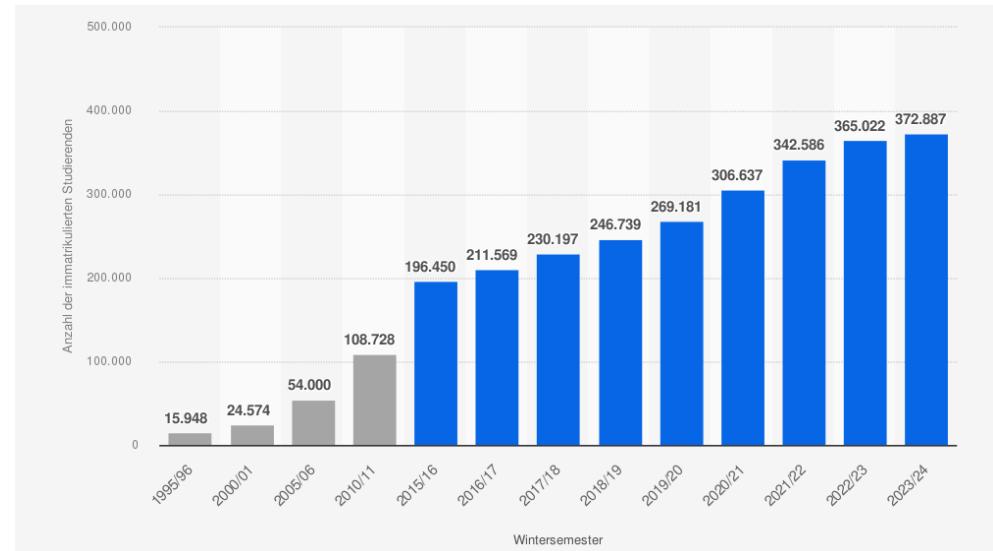
Der Markt der privaten Hochschulen in Deutschland verzeichnet seit Jahren ein stetiges und signifikantes Wachstum.

Im Wintersemester 2023/2024 waren über 372.000 Studierende an privaten Hochschulen eingeschrieben. Dies entspricht einem Anstieg von mehr als 1.000 % im Vergleich zum Jahr 2000 (Bundesamt, 2024).

Diese dynamische Entwicklung unterstreicht die zunehmende Relevanz privater Bildungsanbieter in der deutschen Hochschullandschaft und wirft zugleich Fragen nach den spezifischen Herausforderungen dieses Sektors auf, insbesondere im Bereich der Studierendenbindung.

Abbildung 1

Anzahl der Studierenden an privaten Hochschulen in Deutschland in den Wintersemestern von 1995/1996 bis 2023/2024 (Bundesamt, 2024)



Studienabbruch ist eine Herausforderung

Trotz des Wachstums bleibt die Studierendenbindung eine kritische Herausforderung. An staatlichen Universitäten liegen die Abbruchquoten in bestimmten Fächergruppen bei über 40 % (Heublein et al., 2020).

Im Fern- und Online-Studium, einem Kernbereich privater Anbieter, verschärfen sich diese Probleme durch **fehlende soziale Kontrolle und hohe Anforderungen an die Selbstregulation, was zu Desengagement und Dropouts führt** (Wong et al., 2019).

Für private Hochschulen haben Studienabbrüche nicht nur pädagogische, sondern auch erhebliche wirtschaftliche Konsequenzen.

Forschungsfrage und Zielsetzung

Forschungsfrage

Wie lässt sich studentisches Engagement durch eine adaptive, regelkreisbasierte Architektur als steuerbare Prozessgröße operationalisieren, um durch psychologisch fundierte KI-Interventionen die Studierendenbindung im Fernstudium zu erhöhen?

Ziel dieses Beitrags ist die Vorstellung des AI-Driven Learning Engagement Design (AILED), eines verhaltenspsychologisch und lernanalytisch fundierten Modells, das Künstliche Intelligenz, Datenanalyse und gezielte Interventionen kombiniert, um das Engagement zu steigern und das Dropout-Risiko zu minimieren.



Theoretischer Rahmen I: Self-Determination Theory

Die Self-Determination Theory (SDT) postuliert, dass Motivation und Engagement maßgeblich von der Erfüllung dreier psychologischer Grundbedürfnisse abhängen: Autonomie (Gefühl der Selbstbestimmung), Kompetenz (Gefühl der Wirksamkeit) und soziale Eingebundenheit (Gefühl der Zugehörigkeit) (Ryan & Deci, 2000).

Im Kontext des AILed-Modells dient die SDT als theoretische Grundlage, um adaptive Interventionen zu gestalten, die gezielt diese Bedürfnisse fördern, beispielsweise durch Wahloptionen in Lernpfaden oder die Nutzung von Peer-Foren.

Die drei psychologischen Grundbedürfnisse

Autonomie

Selbstbestimmtes Handeln und Wahlfreiheit in Lernprozessen

Kompetenz

Erleben von Wirksamkeit und Meisterung von Herausforderungen

Soziale Eingebundenheit

Verbundenheit mit anderen und Zugehörigkeitsgefühl

Diese Theory beantwortet die Frage: „**Wie lauten die Rahmenbedingungen von Engagement (Fredricks et al., 2004)?**“

Theoretischer Rahmen II: Fogg Behavior Model und Nudging-Theory

Das Fogg Behavior Model (Fogg, 2009) erklärt Verhalten als Zusammenspiel von Motivation, Fähigkeit und Auslöser.



Motivation



Der Wunsch, ein bestimmtes Verhalten auszuführen



Fähigkeit



Die Kapazität zur Verhaltensausführung

Auslöser



Der gezielte Impuls zum richtigen Zeitpunkt

Ergänzend dazu zielt die Nudging-Theory darauf ab, Verhalten durch die Gestaltung von Entscheidungsarchitekturen zu beeinflussen, ohne die Wahlfreiheit einzuschränken (Thaler & Sunstein, 2009).

Beide Theorien sind zentral für das AI-Led-Modell, um den Zeitpunkt und die Art von KI-Interventionen (z. B. personalisierte Erinnerungen) zu steuern. Diese Theorien beantwortet die Frage: „**Wann wird das Engagement (Fredricks et al., 2004) gesteigert?**“

Theoretischer Rahmen III: BCT & Cognitive Load Theory

Behavior Change Technique Taxonomy

Die Behavior Change Technique Taxonomy (BCT) stellt ein Repertoire von 93 wissenschaftlich validierten Verhaltenstechniken zur Verfügung, wie z. B. Zielsetzung oder Feedback (Michie et al., 2013).

- Zielsetzung und Handlungsplanung
- Feedback und Monitoring
- Soziale Unterstützung
- Belohnung und Verstärkung

Cognitive Load Theory

Die Cognitive Load Theory (CLT) besagt, dass die Gestaltung von Lerninhalten die kognitive Belastung minimieren muss, um den Lernerfolg zu maximieren (Sweller, 1988)

Im AI-Led-Modell wählt die KI passende BCTs (Michie et al., 2013) aus und optimiert die Informationsdarbietung, um kognitive Überlastung (Sweller, 1988) zu vermeiden.

Diese Theorien beantwortet die Frage: „**Wie wird das Engagement (Fredricks et al., 2004) gesteigert?**“

Das AI²Modell: Psychologisch-technologische Synthese

Das AI²Modell integriert die fünf vorgestellten Theorien zu einer psychologisch-didaktischen und algorithmischen Gesamtlogik.

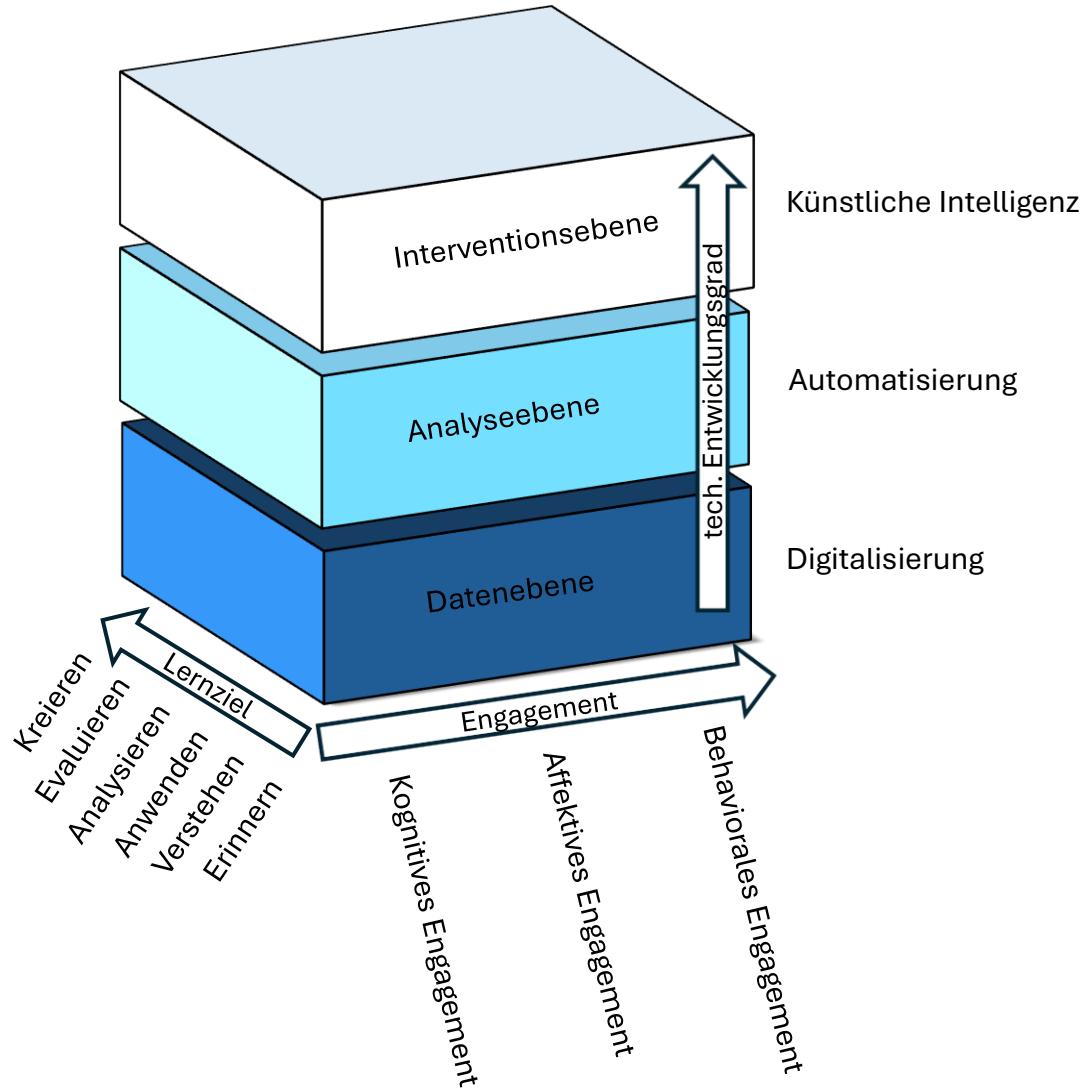
Es operationalisiert studentisches Engagement als Ergebnis eines regelkreisbasierten Zusammenspiels von Daten, Analyse und Intervention.

Die empirische Grundlage für die technologische Umsetzung liefert die Erkenntnis, dass Bildungstechnologien gezielt behaviorales, affektives und kognitives Engagement fördern können (Fredricks et al., 2004; Godsk & Møller, 2025):

- **Behaviorales Engagement (Verhaltensebene):** Es beschreibt die **Teilnahme und Beteiligung** an Lernaktivitäten.
- **Affektives Engagement (Emotionale Ebene):** Dies bezieht sich auf die **Gefühle und die emotionale Bindung** der Studierenden zum Lernprozess, zur Hochschule und zu den Lehrenden.
- **Kognitives Engagement (Gedankliche Ebene):** Es beschreibt die **mentale Anstrengung und Investition** in das Lernen.

Das Modell übersetzt psychologische Variablen in technische Parameter, um Lernprozesse personalisiert zu unterstützen.

Der AI^{Led} Engagement Cube: Technologische Architektur



Die operative Architektur des Modells ist der AI^{Led} Engagement Cube.

Er strukturiert den Prozess entlang von drei Ebenen:

- Die Datenebene erfasst Lernaktivitäten digital,
- die Analyseebene erkennt Muster und
- die Interventionsebene leitet personalisierte Impulse ab (Buxmann & Schmidt, 2021).

Gesteuert wird dieser Prozess durch pädagogisch-psychologische Zieldimensionen, welche die Lernprogression (Bloom et al., 1956) und die verschiedenen Engagement-Typen (Fredricks et al., 2004) abbilden.

Die technologische Entwicklung gibt an, welcher Schritt in der Digitalisierung gegangen werden soll.

Operatives Wirkmodell: Vom Cube zum Multiagentensystem

Die Architektur des AI-Led Engagement Cubes wird durch spezialisierte Agenten operationalisiert. Jeder Agent agiert auf einer spezifischen Prozessebene, um pädagogisch-psychologische Ziele zu erreichen und gezielte Wirkmechanismen auszulösen.

Prozessebene	Technologischer Grad	Ziele	MAS-Umsetzung	Wirkmechanismus
Datenebene	Digitalisierung	Behaviorales Engagement & Lernziele (Erinnern, Verstehen)	Monitoring-Agent	Erfasst kontinuierlich digitale Spuren (Klicks, Logins, Abgaben) in Lernmanagementsystemen und Quizzes. Übersetzt beobachtbares Verhalten in quantitative Daten und macht behaviorales Engagement messbar.
Analyseebene	Automatisierung	Affektives Engagement & Lernziele (Anwenden, Analysieren)	Analyse-Agent	Nutzt Machine Learning zur Mustererkennung in den Monitoring-Daten. Identifiziert proaktiv Risikofaktoren durch Korrelation von Verhaltensabweichungen mit Indikatoren für niedriges affektives Engagement.
Interventionsebene	Künstliche Intelligenz (KI)	Kognitives Engagement & Lernziele (Evaluieren, Kreieren)	Motivations-Agent & Kommunikations-Agent	Generiert psychologisch fundierte, personalisierte Impulse (z.B. SDT-basiertes Feedback). Wählt optimalen Zeitpunkt und Kanal zur Auslieferung, um gezielt kognitives Engagement zu fördern.

- Hinweis:* Die Aufschlüsselung operationalisiert die theoretische Architektur des AI-Led Engagement Cubes durch konkrete Agentenfunktionen und macht die Wirkmechanismen auf jeder Ebene explizit (vgl. Burkhard, 2003; Buxmann & Schmidt, 2021; Fredricks et al., 2004; Ryan & Deci, 2002).

Diskussion, Limitationen und Ausblick

Chancen und Potenziale

- Erhöhte Effizienz in der Studierendenbetreuung
- Hochgradige Personalisierung von Lernprozessen
- Evidenzbasierte Interventionsentscheidungen
- Skalierbarkeit für große Studierendenkohorten

Herausforderungen und Risiken

- Algorithmische Verzerrungen (Bias)
- Transparenz und Nachvollziehbarkeit
- Datenschutz und ethische Implikationen
- Technologische Abhängigkeit

Fazit und wissenschaftlicher Beitrag

Das AI²ed-Modell definiert studentisches Engagement erstmals als steuerbare Prozessgröße und liefert einen Beitrag zur digitalen Transformation an Hochschulen. Der AI²ed Cube fungiert als soziotechnischer Bauplan für adaptive, KI-gestützte Lernumgebungen. Zukünftige Forschung sollte empirische Validierungen, Langzeiteffekte und ethische Rahmenbedingungen systematisch untersuchen (López-Pernas et al., 2026).

Literatur

Bendel, P. D. O. (2021, Juli 13). *Definition: Digitalisierung* [Text]. Springer Fachmedien Wiesbaden GmbH. <https://wirtschaftslexikon.gabler.de/definition/digitalisierung-54195>

Bloom, B. S., Engelhart, M. D., Furst, E. J., Hill, W. H., & Krathwohl, D. R. (1956). *Taxonomy of Educational Objectives*.

David McKay Company. Bond, M., & Bedenlier, S. (2019). Facilitating student engagement through educational technology. *Journal of Interactive Media in Education*, 2019(1), 11. <https://doi.org/10.5334/jime.528>

Bundesamt, S. (2024, August 8). *Anzahl der Studierenden an privaten Hochschulen in Deutschland 1995–2024*. Statista.

Burkhard, H.-D. (2003). *Software-Agenten*. In G. Görz et al. (Hrsg.), *Handbuch der Künstlichen Intelligenz* (S. 943–1020). Oldenbourg.

Buxmann, P., & Schmidt, H. (Hrsg.). (2021). *Künstliche Intelligenz: Mit Algorithmen zum wirtschaftlichen Erfolg*. Springer Berlin Heidelberg.

Deci, E. L., & Ryan, R. M. (2000). The “What” and “Why” of Goal Pursuits. *Psychological Inquiry*, 11(4), 227–268.

Fogg, B. (2009). A behavior model for persuasive design. *Proceedings of the 4th International Conference on Persuasive Technology*, 1–7.

Fredricks, J. A., Blumenfeld, P. C., & Paris, A. H. (2004). School Engagement. *Review of Educational Research*, 74(1), 59–109.

Godsk, M., & Møller, K. L. (2025). Engaging students in higher education with educational technology. *Education and Information Technologies*, 30(3), 2941–2976.

Heublein, U., Richter, J., & Schmelzer, R. (2020). *Die Entwicklung der Studienabbruchquoten in Deutschland*. DZHW Brief, 03/2020.

Michie, S., et al. (2013). The Behavior Change Technique Taxonomy (v1). *Annals of Behavioral Medicine*, 46(1), 81–95.

Ryan, R. M., & Deci, E. L. (2002). *Overview of Self-Determination Theory*. University of Rochester Press.

Sweller, J. (1988). Cognitive load during problem solving. *Cognitive Science*, 12(2), 257–285.

Thaler, R. H., & Sunstein, C. R. (2009). *Nudge: Improving Decisions About Health, Wealth and Happiness*. Penguin Books.

Wong, J., et al. (2019). Supporting Self-Regulated Learning in Online Learning Environments. *International Journal of Human–Computer Interaction*, 35(4–5), 356–373.

Wooldridge, M. J. (2012). *An Introduction to Multiagent Systems* (2. Aufl.).

Wiley. López-Pernas, S., et al. (2026). AI and Evaluative AI in Education. In M. Saqr (Ed.), *Advanced Learning Analytics Methods*. Springer.