

Download von <https://mint-symposium.de/tagungsbaende/>

Elmar Junker, Anne Sanewski, Nicole Kraus, Thomas Schweser, Finn Schmidt, André Kajtar, Ulrich Wellisch, Silke Deschle-Prill, TH Rosenheim, [www.pro-aktjv.de](http://www.pro-aktjv.de)  
Predictive Learning Analytics generiert Lernfeedback:  
KI-Design, Herausforderungen, erste Ergebnisse  
Tagungsband 6. MINT-Symposium 2025, S. 272-284



[https://doi.org/10.57825/repo\\_in-6432](https://doi.org/10.57825/repo_in-6432)

# TAGUNGSBAND MINT SYMPOSIUM 2025

Zukunft MINT Lehre:  
Was bleibt?  
Was kommt?  
Was wirkt?



# TAGUNGSBAND ZUM 6. MINT SYMPOSIUM

ZUKUNFT MINT LEHRE:  
WAS BLEIBT?  
WAS KOMMT?  
WAS WIRKT?

# PREDICTIVE LEARNING ANALYTICS GENERIERT LERNFEEDBACK: KI-DESIGN, HERAUSFORDERUNGEN, ERSTE ERGEBNISSE

Elmar Junker, Anne Sanewski, Nicole Kraus, Thomas Schweser, Finn Schmidt, André Kajtar, Ulrich Wellisch, Silke Deschle-Prill  
Technische Hochschule Rosenheim, [www.pro-aktjv.de](http://www.pro-aktjv.de)

## ZUSAMMENFASSUNG

Das Projekt FANTASTIC nutzt Learning Analytics, um Studierenden personalisiertes Feedback und Prognosen zum möglichen Prüfungserfolg zu geben, den Lernfortschritt zu fördern und Studienabbrüche zu reduzieren.

Im Physikkurs für Wirtschaftsingenieurwesen werden KI-Modelle mit historischen Daten aus 6 Jahren trainiert. Indikatoren aus Vorwissen und Moodle-Aktivitäten fließen in erklärbare Prognosemodelle (Decision Tree, Logistische Regression) ein. Herausforderungen sind Datenaufbereitung und Merkmalsauswahl.

Das mit Studierenden entwickelte Feedback-Design kombiniert motivierende E-Mails mit Peer-Coachings. Die E-Mails enthalten die KI-Prognose, individuelle Lernempfehlungen sowie Vergleichsdaten mit Kommilitonen und Hinweise auf Unterstützungsangebote. Etwa 95 % der Studierenden nutzen das Angebot. Im Vergleich zum Sommersemester 2023 (SS23) ohne Learning Analytics sinkt die Durchfallrate im SS24 mit hoher statistischer Signifikanz ( $p < 0.001$ ) von 34 % auf 20 %.

Die Verarbeitung persönlicher Daten erfolgt mit Einwilligung und Datenschutzkonzept.

*Keywords: Learning Analytics, Künstliche Intelligenz (KI), Coaching, Lernverhalten, Durchfallraten*

## 1. (PREDICTIVE) LEARNING ANALYTICS

Learning Analytics (LA) umfasst die Erfassung, Analyse und Interpretation von Daten aus Lernprozessen, um Lernverhalten zu verstehen, Lehrstrategien zu verbessern und Studierende gezielt zu unterstützen. Es dient der retrospektiven Analyse und auch der Echtzeit-Unterstützung.

Predictive Learning Analytics (PLA) ist eine spezifische Unterkategorie von LA, die sich auf die Vorhersage zukünftiger Lernereignisse oder -erfolge konzentriert. Mithilfe von KI-gestützten Modellen und statistischen Methoden werden individuelle Risiken (z. B. Nichtbestehen der Prüfung oder Studienabbruch) frühzeitig erkannt, um gezielte Interventionen zu ermöglichen.

LA analysiert also Lernprozesse, während PLA zukünftige Entwicklungen prognostiziert, um präventiv einzugreifen. Das Forschungsfeld ist über die letzte Dekade sehr stark gewachsen (Suhonen, 2018; Lang et al., 2017; Suhonen et al., 2019; Lang et al., 2022; Sghir et al., 2023; SoLAResearch, 2025).

## 2. MOTIVATION UND ZIEL

Unsere Forschung ist angeregt durch Studien, in denen mit Hilfe von Learning Analytics und einer kurzen E-Mail die Durchfallraten in Mathematik halbiert wurden (Popp et al., 2018; Ciolacu, 2022).

Das Projekt FANTASTIC (Feedback based on Analytics of Teaching and Studying meets Individual Coaching) integriert folgende drei Säulen, um besseres Lernverhalten und niedrigere Durchfallraten zu realisieren:

- Entwicklung von Machine-Learning-Modellen (MLM), die das wahrscheinliche Prüfungsergebnis von Studierenden durch Vergleich ihrer Datenspuren mit Vorgängerkohorten vorhersagen. Sie dienen als Grundlage für die Generierung von Feedback-E-Mails (Abb. 1), die das prognostizierte Prüfungsergebnis in Kombination mit dem aktuellen Leistungsstand in einem datenbasierten Dashboard, sowie personalisierten Lernempfehlungen an die Studierenden übermitteln.
- Qualifizierung von Peer-Coaches, die als Lernbegleiter für die Studierenden fungieren. Sie unterstützen nicht nur fachliches Lernen, sondern tragen auch zur Verbesserung übergreifender Herausforderungen wie Zeitmanagement, Motivation und Selbstwirksamkeit bei.
- Differenzierung der Lernmaterialien, insbesondere durch die Optimierung des fachlichen Feedbacks in Quizaufgaben, sowie die präzisere Formulierung und Anpassung der Lernziele für einzelne Kapitel.

Das Learning Analytics Feedback mit KI wird LAKI genannt und besteht aus i) KI-Prognose, ii) Dashboard-Grafiken mit Feedback, iii) Lerntipps und Coaching-Angeboten. Dieser Artikel fokussiert dabei auf KI- und Feedback-Design mit Ergebnissen.

## 3. KURSDESIGN UND DATENBASIS

Die Untersuchungen finden im Kurs Physik für Wirtschaftsingenieurwesen statt. Der zweisemestrige Kurs schließt im ersten Semester mit einem unbenoteten Leistungsnachweis (LN) als Prüfungszulassung ab, im zweiten mit einer Prüfung über die gesamten Inhalte. Der Kurs ist seit zehn Jahren stabil: gleiche Inhalte, gleiche Lehrperson und ein aktivierender Unterrichtsstil mit Just-in-Time-Teaching (JiTT), Peer Instruction und Tutorials nach McDermott (Novak et al., 1999; Mazur, 1997; McDermott, 2011; Schäfle et al., 2023). Das Studiermaterial wurde und wird kontinuierlich verbessert.

Jedes Studienjahr hat begleitende Moodle-Kursräume mit Studiermaterial und bis zu 39 Quiz: WarmUp-Quiz für die JiTT-Vorbereitung und Deepening-Quiz für die Nachbereitung.

Zusätzlich liegen Daten der Studierenden außerhalb von Moodle vor, z. B. Ergebnisse des Forced-Concept-Inventories (FCI) nach Hestenes et al. (1992), sowie Fragebogendaten zur Art der Hochschulzugangsberechtigung und zur Zahl der Physik-Schulstunden.

Seit dem Studienjahr 2023/24 erhalten die Studierenden Learning Analytics Feedback. Dazu werden die 6 Studienjahre von 2014/15 bis 2019/20 für das Training der MLMs verwendet. Nur die Daten von 431 sogenannten „echten Erstsemestern“, die zum frühestmöglichen Zeitpunkt die Prüfung geschrieben haben, fließen ein. Die Daten von Wiederholern werden nicht verwendet.

#### 4. FEEDBACK-DESIGN

Feedback umfasst (Hattie et al., 2007; Hattie, 2018):

- Feedback (aktueller Lernstand): Individuelle Rückmeldungen zu Vorwissen, Quiz-Ergebnissen und Aktivität im Kursraum.
- Feedup (angestrebte Lernziele): Eine Übersicht der Lernziele, die den Studierenden klare Orientierung darüber gibt, welche Kenntnisse und Fähigkeiten für den erfolgreichen Abschluss erforderlich sind.
- Feedforward (nächste Schritte zum Lernziel): Individuelle Empfehlungen, wie der Lernprozess durch zusätzliche Lernhilfen optimiert werden kann.

Diese drei Elemente des Feedbacks arbeiten synergetisch zusammen. Durch diese integrierte Herangehensweise wird der Lernprozess gezielt unterstützt und die Studierenden erhalten eine strukturierte Grundlage, um ihre Lernziele effektiv zu erreichen.

Die Feedback-E-Mail von LAKI (Abb. 1) ist deutlich komplexer und lernförderlicher umgesetzt als in der einfachen E-Mail der Pilotstudie von Popp et al. (2018), denn sie gibt ein Gesamtfeedback, wo man im Lernprozess steht inkl. motivierenden Rückmeldungen auf verschiedenen Ebenen:

- KI-basiertes Feedback mit Prognose über das mögliche Prüfungsergebnis,
- Dashboard-Grafiken als detaillierte Statusrückmeldungen mit Analysen und Lernempfehlungen und Vergleichen mit den Kommilitonen,
- Tipps zu Lerntechniken & Selbstmanagement sowie Coaching-Angeboten.

In einem EMPAMOS-Workshop (2023) wurden Studierende aktiv in die Entwicklung der Feedback-E-Mails eingebunden. Außerdem geben die aktuellen Studierenden nach jeder LAKI-Mail

in einer Befragung Rückmeldungen ab, die in einem iterativen Prozess in die Gestaltung der folgenden E-Mails einfließen. Wichtig ist das „Framing“ im Unterricht, um das Ziel von LAKI zu vermitteln und die Sorgen (z. B. ‚mehr Druck‘) sowie Erwartungen der Studierenden ernst zu nehmen.

Flankiert werden die E-Mails durch Peer-Coaching: Studierende höherer Semester werden in einem Wahlfach zu Lernbegleitern ausgebildet. Sie helfen, Lernprozesse zu reflektieren, und unterstützen ihre Mitstudierenden bei der Weiterentwicklung des Lernverhaltens. Peer-Coaches ergänzen das technologiegestützte System aus Learning Analytics und KI-basiertem Feedback. Diese Kombination fördert das Lernen nicht nur kognitiv, sondern auch auf sozialer und emotionaler Ebene – und steigert so die Akzeptanz und Umsetzung des Feedbacks.

Die Mehrheit der Studierenden zeigt sich insgesamt sehr zufrieden mit dem Vorgehen. Besonders geschätzt wird, dass der aktuelle Lernstand sowie Stärken und Schwächen auf einen Blick erkennbar sind. Es besteht der Wunsch nach noch individuellerem Feedback. Nur eine kleinere Gruppe hält das KI-basierte Feedback für nicht erforderlich, einige wenige lehnen den Vergleich mit Mitstudierenden eher ab.

Für die LAKI-Mail im SS24 haben sich 59 von 63 Erstsemestern in Moodle auf Grundlage eines Datenschutzkonzeptes für die Verarbeitung ihrer personenbezogenen Daten und die Teilnahme an der Learning Analytics Prognose entschieden, zusätzlich erhielten 19 Wiederholer die Dashboard-Grafiken und Lerntipps.

Einen Auszug aus der Feedback-E-Mail mit Dashboard-Grafiken zeigt Abb. 1.

Servus vorname\_35 nachname\_35,



wir kennen uns zwar schon, aber ich stelle mich trotzdem nochmal kurz vor: Mein Name ist LAKI und ich bin deine **LearningAnalytics-KI**. In den letzten Wochen habe ich deine Datenspuren ausgewertet und daraus folgende Informationen für dich zusammenstellen können:

- deine persönliche **KI-Prognose**
- eine **Datenspuren-Übersicht** mit den Zahlen-Daten-Fakten zu wichtigen Lernindikatoren mit individuellem **Feedback** – dieses Mal auch mit **Grafiken**
- **Vorbereitungs-Tipps** für die anstehende Prüfung

Dieser Link führt dich zu einer [Umfrage im LC](#), für die es wieder einen Bonuspunkt gibt. Deine Teilnahme hilft mir sehr, mich weiter zu verbessern! Den Link gibt es auch nochmal im PS am Ende des Briefes!

## KI-Prognose

Hier wurden viele lernrelevante Indikatoren in einem mathematischen Modell ausgewertet und eine Prognose für deinen denkbaren Prüfungserfolg berechnet, dies ist ein Trend und soll dir helfen, den letzten Lernmonat zu optimieren. Wahrscheinlich macht es Sinn in deiner Lernstrategie etwas zu verändern.

Viele Studierende mit ähnlichen Daten haben sich mit der Prüfung eher schwer getan. Bitte beachte: Diese Prognose zeigt lediglich eine Wahrscheinlichkeit auf und keine Gewissheit. Deine individuellen Fähigkeiten, deine Vorbereitung und dein Engagement im Endspurt haben einen entscheidenden Einfluss darauf, wie du in der Prüfung abschnidest. Nutze meine Prognose als Ansporn, um deine Vorbereitung zu intensivieren und zu fokussieren, d.h. gezielt an den Inhalten zu arbeiten, bei denen du noch unsicher bist. Hole dir weitere Unterstützung in (d)einer Lerngruppe, beim Tutor oder Prof! Bleib optimistisch, du hast es in der Hand, das Ergebnis zu beeinflussen!

Viele der hier gezeigten Daten sind sicher keine Überraschung für dich. Und unter Umständen hast du sogar überlegt, die Prüfung zu schieben. Dies ist aber keine Option! Die Vergangenheit hat gezeigt, dass dies eher zu noch größeren Lücken führt. Daher nutze den Endspurt, schreibe die Prüfung unbedingt mit, um zu sehen, wo du wirklich stehst.

In deinem letzten Mechanik-Test vom 3.5.2024 hast du 57% erreicht (Semesterschnitt: 42%). Überprüfe auch hier nochmal deinen aktuellen Wissensstand, um dortige Lücken angehen zu können.

Abb. 1: Auszug aus der LAKI-Mail vom SS24. Zwei aktuellere Beispiele siehe LAKI (2025)

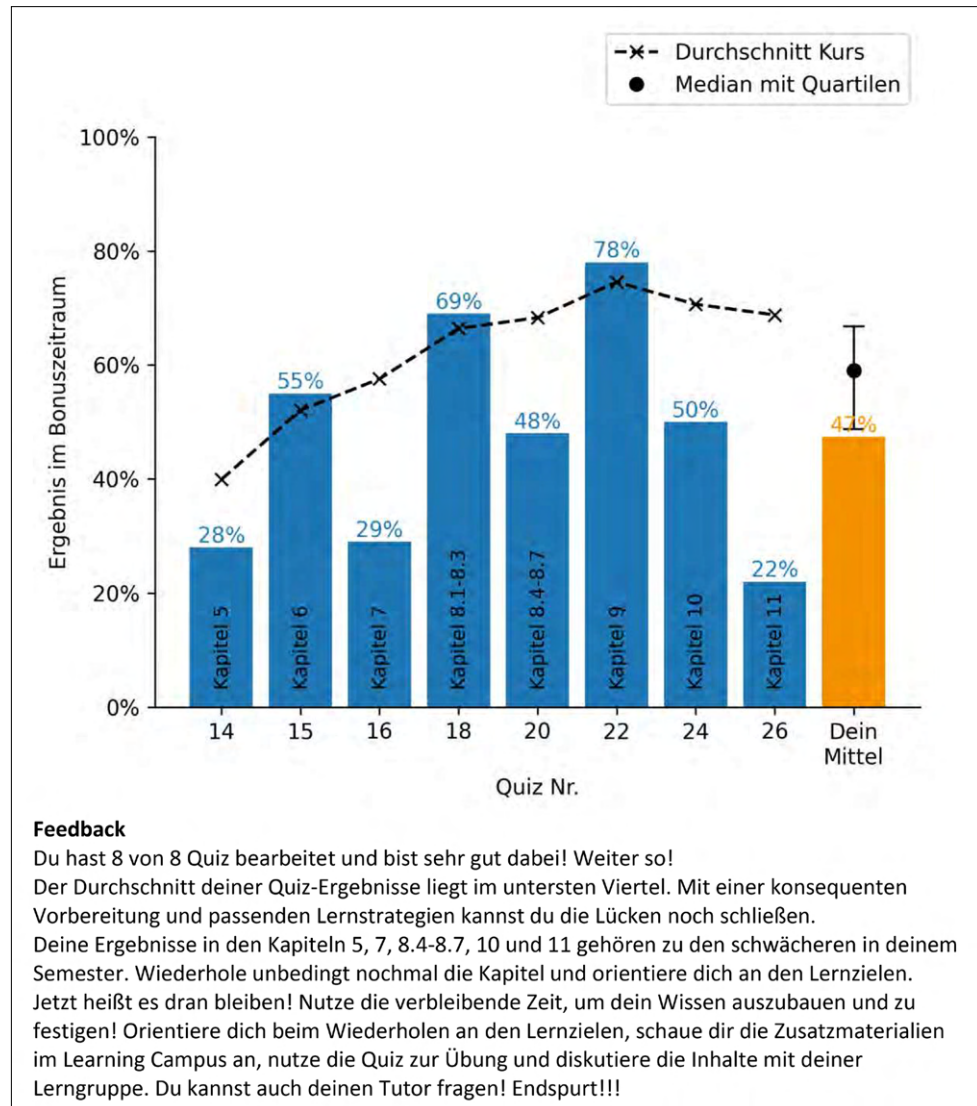


Abb. 1: Auszug aus der LAKI-Mail vom SS24. Zwei aktuellere Beispiele siehe LAKI (2025)

## 5. KI-DESIGN

Um qualifiziertes Feedback geben zu können, ist der Fokus auf MLMs gelegt, die intrinsisch erklärbar sind: Decision Tree (DT) und Logistische Regression (LR). Bei diesen Modelltypen ist nachvollziehbar, warum eine Person einer bestimmten Klasse (z. B. „Gefährdet“) zugeordnet wird, dies kann für das Feedback genutzt werden. Da künstliche neuronale Netze (NN) dies nicht einfach leisten können, werden sie explizit zurückgestellt.

Hier fokussieren wir auf die Prognose für die Prüfung im SS24, die final nur LR nutzt. Ein geplantes Ensemble von DT und LR kommt nicht zum Einsatz, da die LR dem DT und dem Ensemble nach den verwendeten Gütemaßen überlegen ist (s. u.).

Es werden alle 431 Studierende in zwei Klassen eingeordnet: ‚0‘= ‚Gefährdet‘, d. h. schlechte Prüfungen  $\leq 57\%$  Prüfungspunkte (etwa Note 4) und ‚1‘= ‚Besteher‘, d. h. bessere Prüfungen  $> 57\%$ . Die LR berechnet die Wahrscheinlichkeit zur Klasse 1 zu gehören.

Im ersten Schritt werden im Team fast 100 mögliche Indikatoren/Merkmale identifiziert, die vermutlich mit dem Prüfungserfolg korrelieren. Einige davon werden im Entwicklungsprozess der MLMs bearbeitet, z. B. Quiz-Ergebnisse oder die Klicks über bestimmte Zeiträume gemittelt. Mehr zu MLMs: Hosmer et al., 2000; Mahesh, 2020; Iqbal et al., 2015; Hastie et al., 2009.

Weiterhin ist beim Data-Preprocessing das sogenannte NULL-Handling wichtig. Dabei wird festgelegt, wie mit fehlenden Werten verfahren wird, z. B. falls es weniger Quiz in früheren Studienjahren gab, oder falls Studierende bei einzelnen Quiz oder beim FCI nicht teilnahmen (z. B. Quiz fehlt, dann Wert := 0).

Für die LR-Modellierung werden 10 % der Daten (43 von 431) als Testdatensatz zurückgehalten. Die übrigen 388 Fälle werden im Verhältnis 70:30 in Trainings- (271) und Validierungsdaten (117) aufgeteilt.

Auf den Trainingsdaten erfolgen:

- i) die finale Merkmalsauswahl mittels schrittweiser Regression, basierend auf dem Akaike-Informationskriterium (AIC) sowie
- ii) die Bestimmung der Bestehenswahrscheinlichkeit, ab der Klasse 1 zugeordnet wird (Threshold), wobei dieser Schwellenwert mithilfe von Leave-One-Out-Cross-Validation auf 0,5 festgelegt wird. Validierungsdaten dienen der Modellanpassung und Testdaten der abschließenden Leistungsbeurteilung des Modells (Generalisierbarkeit).

Nach erfolgter Validierung wird das Modell auf Trainings- und Validierungsdaten trainiert, um präzisere Gütekriterien zu erhalten.

Aufgrund des sehr kleinen Datensatzes wird das finale Modell nach abgeschlossener Merkmal- und Thresholdauswahl auf allen 431 Daten trainiert und damit leicht modifiziert. Es umfasst 7 Merkmale (alle nach Wald-Tests hoch signifikant  $p < 0.003$ ). Für das KI-basierte Feedback werden 5 Gruppen („auf sehr gutem Weg“ bis „schwer getan“, abhängig von der Wahrscheinlichkeit der Klasse 1 anzugehören) gebildet und den Studierenden kommuniziert.

		Vorhersage			
		Positiv (Besteher ,1')		Negativ (Gefährdet ,0')	
		N / % der 43 Testdaten		N / % der 43 Testdaten	
Tatsächlich	Positiv (Besteher ,1')	True Positives (TP) <i>Besteher mit Besteher-Prognose</i>	14 / 33%	False Negatives (FN) <i>Besteher mit Gefährdet-Prognose</i>	5 / 12%
	Negativ (Gefährdet ,0')	False Positives (FP) <i>Gefährdete mit Besteher-Prognose</i>	7 / 16%	True Negatives (TN) <i>Gefährdete mit Gefährdet-Prognose</i>	17 / 40%

Tab. 1: Konfusionsmatrix für die 43 Testdaten der Logistischen Regression (trainiert auf 388 Daten).

## 6. ERGEBNISSE UND SCHLUSSFOLGERUNGEN

Die Konfusionsmatrix in Tab. 1 zeigt für die LR, dass ein MLM teils richtige (TP, TN), teils falsche Vorhersagen (FP, FN) trifft. Befragungen von Lehrenden und Studierenden ergaben, dass FP (Prognose: „du bestehst“, aber man fällt durch) kritischer wahrgenommen werden als FN. Daher wird für alle drei MLMs die Spezifität bei gleichzeitig guten weiteren Gütemaßen (Tab. 2) maximiert. Die Gütemaße berechnen sich aus den dazugehörigen Konfusionsmatrizen.

Tab. 2 zeigt, dass die LR sowohl dem DT als auch dem Ensemble zwischen DT und LR überlegen ist, alle Gütemaße sind höher. Daher wird die finale Prognose für die LAKI-Mail mit LR durchgeführt.

Der Liftplot in Abb. 2 zeigt die gute Vorhersagekraft und Trennungseigenschaft der LR. Dazu werden die Validierungsdaten nach den Prognosewahrscheinlichkeiten der auf den Trainingsdaten entwickelten LR aufsteigend geordnet und in 10 etwa gleich große Gruppen eingeteilt (Gruppe 1: niedrige, Gruppe 10: hohe Bestehenswahrscheinlichkeit). Der Plot zeigt in blau für

MLM-Typ	DT	LR	DT-LR-Ensemble
Sensitivität (Recall)	0,53	0,74	0,63
Spezifität	0,67	0,71	0,71
Accuracy	0,60	0,72	0,67
Precision	0,56	0,67	0,63
F1-Score (auf Klasse 0)	0,65	0,74	0,71
F1-Score (auf Klasse 1)	0,54	0,70	0,63

Tab. 2: Gütemaße der auf 388 Daten trainierten MLM bezogen auf die 43 Testdaten berechnet aus den zugehörigen Konfusionsmatrizen. F1-Score auf Klasse 0:  $2TN / (2TN + FP + FN)$ ; F1-Score auf Klasse 1:  $2TP / (2TP + FP + FN)$ , Details: Wikipedia (2025).

jede Gruppe den Mittelwert der Prognosewahrscheinlichkeiten und in rot den Anteil der tatsächlichen Besteher. Die Gruppenmittelwerte sind durch Linien verbunden. Der Vergleich der ersten mit den letzten Gruppen belegt die gute Trennungseigenschaft des Modells. Da die Mittel der Prognosewahrscheinlichkeiten und die Anteile der Besteher innerhalb der Gruppen

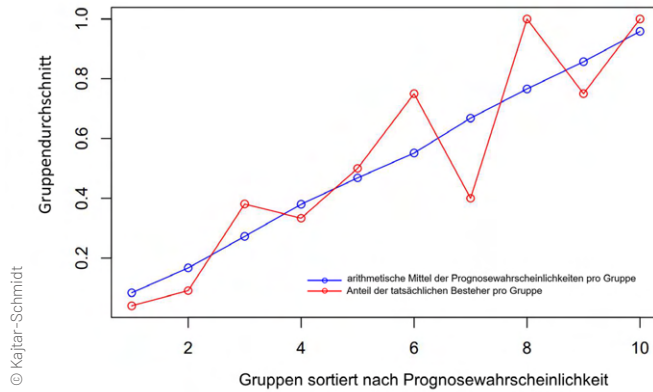


Abb. 2: Der Liftplot zeigt die Effektivität der Logistischen Regression für die Validierungsdaten für 10 Gruppen, sortiert nach Prognosewahrscheinlichkeit. Blau: arithmetische Mittel der Prognosewahrscheinlichkeiten pro Gruppe, Rot: Anteil der tatsächlichen Besteher pro Gruppe.

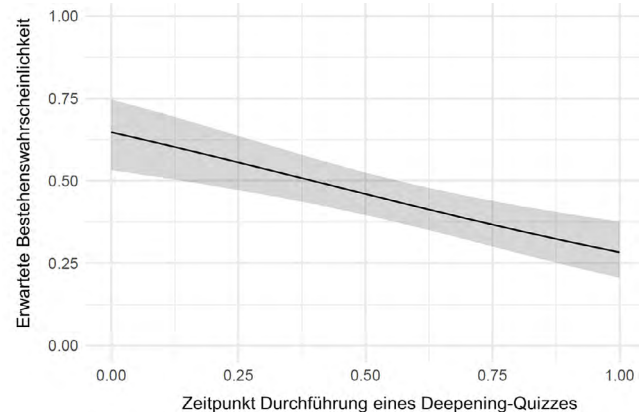
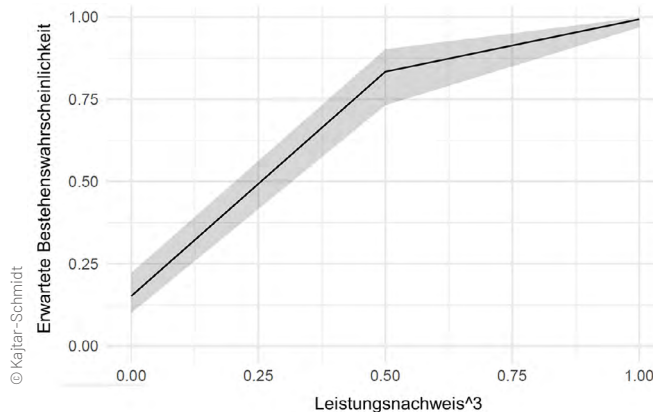


Abb. 3: Effectplots zeigen den Einfluss zentraler Prädiktoren auf die prognostizierte Bestehenswahrscheinlichkeit der Prüfung: links Leistungsnachweisergebnis hoch 3, rechts Zeitpunkt der Quizdurchführung eines der Deepening-Quizzes (0,0 bedeutet Quizdurchführung bei Quizöffnung; 1,0 bedeutet: Durchführung kurz vor Quizschließung).

meist eng beieinanderliegen, ist auch die Prognosegüte hoch. Zudem lassen sich Über- und Unterschätzungen erkennen, die Hinweise auf mögliche Modelloptimierungen liefern.

In die finale LR fließen 7 ausgewählte Merkmale ein. Beispielhaft zeigen die Effectplots (Fox et al., 2019; Fox, 2003) in Abb. 3

den Einfluss des Leistungsnachweises (LN) am Ende des ersten Semesters und des Zeitpunkts der Durchführung eines Deepening-Quiz auf die geschätzte Bestehenswahrscheinlichkeit. Der kubisch transformierte LN (links) weist einen deutlich positiven Zusammenhang auf: Höhere Punktzahlen gehen mit steigender Bestehenswahrscheinlichkeit einher, wobei sich




Abb. 4: Notenstatistiken vergleichbarer Physikprüfungen, links SS24 mit LAKI-Feedback, rechts SS2023 ohne LAKI-Intervention (d. h. KI-Prognose, Dashboard- & Lernfeedback, Coachings).

der Anstieg bei höheren Werten abschwächt. Der Deepening-Quiz-Zeitpunkt (rechts) zeigt hingegen einen negativen Effekt – spätere Durchführungen sind mit geringerer Bestehenswahrscheinlichkeit assoziiert.

Die dargestellten Analysen zeigen, dass die Prüfungsergebnisse auf der Datenbasis mithilfe von LR sehr gut prognostizierbar sind und die Wirkungsweise der Merkmale eine sachlogisch konsistente Erklärung geben.

Im Einführungsstudienjahr der LAKI-Mails ist der Einfluss auf die finalen Prüfungsergebnisse deutlich und überraschend groß. Die Notenverteilung in der Prüfung mit LAKI-Feedback (SS24) ist deutlich besser als im Vorjahr ohne LAKI-Feedback und die Durchfallrate sinkt stark (siehe Abb. 4 und Tab. 3).

Statistische Tests (Kolmogorov-Smirnov, Wilcoxon, Fisher) zeigen mit hoher Signifikanz (p-Werte zwischen 0.0024 und

	Ø 2014-2023	SS 2023	SS 2024
Durchfallrate in %	41,0	32,7	20,0
Notenmittel	3,79	3,86	3,10
%-Mittel	51,4	49,5	59,9
N	708	49	35

Tab. 3: Kennzahlen der Prüfungsergebnisse, 2023 ohne LAKI, 2024 mit LAKI.

0.0097 für Notenverteilung (Abb. 4), sowie Punkte- und Notenmittelwerte), dass sich die Prüfungsergebnisse durch LAKI im SS24 signifikant verbessert haben. Nur beim Verhältnis „bestanden/nicht bestanden“ liegt mit  $p=0.15$  kein signifikanter Unterschied vor, was an der kleinen Anzahl der Prüfungen in diesem Semester liegen könnte. Die Durchfallrate (DFR) 2024 sinkt – bei etwa gleicher Antrittsrage – auf die niedrigste seit 2014; im Vergleich zum Schnitt aller DFR seit 2014 ist sie höchst signifikant kleiner ( $p=0.00068$ ) (Tab. 3).

## 7. AUSBLICK

Es ist geplant, künstliche neuronale Netze (NN) als Konkurrenz zur LR zu testen. Ist die Prädiktionsgüte tatsächlich höher? Dennoch sollte an der Erklärbarkeit der Modelle festgehalten werden. Methoden der erklärbaren KI (xAI, Adadi et al., 2018; Khosravi et al., 2022) könnten auch bei NN oder anderen ML-Verfahren wie Ensemble-Methoden oder Gradient Boosting zum Einsatz kommen.

Das Ziel der Übertragung des MLM auf andere Kurse, erweist sich wegen der notwendigen Aufbereitung eines brauchbaren Datensatzes und der Erstellung neuer Modelle als sehr aufwändig. Für künftige Implementierungen entwickeln wir derzeit eine Anleitung auf Basis unseres bisherigen Vorgehens. Es wäre evtl. denkbar, das Feedback ohne Prognose, ausschließlich über Grafiken und passende Texte zu geben.

Geplant ist eine genauere Untersuchung, bei welchen Studierenden das Projekt nicht wirkte und warum. Die Daten vom SS24 dienen als Grundlage für weitere Analysen, um etwa Art und Zeitpunkt der Kommunikation mit Studierenden zu optimieren – der Beginn einer datenbasierten Lernschleife.

Offene Fragen bei dieser Anwendung von Predictive Learning Analytics, die man in neuen Projekten, besonders auch bei größeren Studierendenzahlen untersuchen sollte:

- Es gibt keine Kontrollgruppe wie in klinischen Studien mit Placebos. Dies ist praktisch kaum umsetzbar, da aus Gleichbehandlungsgründen niemandem Informationen vorenthalten werden dürfen. Zudem wäre die Zahl der Datenpunkte zu stark reduziert. Es sollte daher über alternative Kontroll-Mechanismen zur Prognosegüte und Wirksamkeit geforscht werden.

- Korrelation heißt nicht Kausalität, es gibt auch Scheinkorrelationen (z. B. Störche- und Baby-Zahlen korrelieren mit  $p < 0.01$ , Matthews, 2000). Die Kausalität zwischen Lernaktivitäten, Vorwissen und Prüfungserfolg wird jedoch allgemein akzeptiert.
- Interessant wären Studien, die Lernfeedback ohne KI und MLM geben:
  - nur Dashboard-Grafiken mit Kohortenvergleich und allgemeinen Lerntipps ohne Prüfungsprognose.
  - nur intensive allgemeine Lerntipps zu Retrieval (Roediger et al., 2006), Zeitmanagement und Peer-Coaching.

### Danksagung

Diese Arbeit wird von der Stiftung für innovative Hochschullehre mit den Projekten HigH-RoQ (ProjektNr FMM2020-EA-150) und FANTASTIC (ProjektNr FR-388/2023) gefördert.

Danke auch an Josip Lackovic für das Datenbankmanagement, Stefanie Neumaier für den EMPAMOS Workshop und Birgit Naumer für die Unterstützung in der Projektleitung.

### Literatur

Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: A survey on explainable artificial intelligence (xAI). *IEEE Access*, 6, 52138–52160. <https://doi.org/10.1109/ACCESS.2018.2870052>

- Ciolacu, M., & Popp, H. (2022). KI- und IoT-unterstützter Blended Learning Prozess – Education 4.0. In C. Walter & P. Riegler (Hrsg.), Tagungsband zum Forum der Lehre an der OTH Regensburg (S. 95–105). BayZiel - Didaktikzentrum. Abgerufen am 14.07.2025, von [https://bayziel.de/wp-content/uploads/DiNa\\_2022-05\\_Sonderausgabe\\_FdL.pdf](https://bayziel.de/wp-content/uploads/DiNa_2022-05_Sonderausgabe_FdL.pdf)
- EMPAMOS. (2023). Abgerufen am 14.07.2025, von <https://www.empamos.de/de/>
- Fox, J. (2003). Effect displays in R for generalised linear models. *Journal of Statistical Software*, 8(15), 1-27. <https://doi.org/10.18637/jss.v008.i15>
- Fox, J., & Weisberg, S. (2019). *An R companion to applied regression* (3rd ed.). Sage Publications. Abgerufen am 14.07.2024, von <https://www.john-fox.ca/Companion/index.html>
- Hastie, T., Tibshirani, R. & Friedman, J. (2009). The elements of statistical learning. In Springer series in statistics. <https://doi.org/10.1007/978-0-387-84858-7>
- Hattie, J., & Timperley, H. (2007). The power of feedback. *Review of Educational Research*, 77(1), 81-112. <https://doi.org/10.3102/003465430298487>
- Hattie, J. (2018). Lernen sichtbar machen für Lehrpersonen (S. 131-156). Baltmannsweiler: Schneider Verlag Hohengehren.
- Hestenes, D., Wells, M., & Swackhamer, G. (1992). Force concept inventory. *The physics teacher*, 30(3), 141-158.
- Hosmer, D. W., Lemeshow, S. (2000). *Applied logistic regression*. Wiley. <https://doi.org/10.1002/0471722146>
- Iqbal, M. & Zhu, Y. (2015). Supervised machine learning approaches: A survey. *ICTACT Journal on Soft Computing*, 5(3), 946-952. <https://doi.org/10.21917/ijsc.2015.0133>
- Khosravi, H., Shum, S. B., Chen, G., Conati, C., Tsai, Y.-S., Kay, J., Knight, S., Martinez-Maldonado, R., Sadiq, S., & Gašević, D. (2022). Explainable artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 3. <https://doi.org/10.1016/j.caeai.2022.100074>
- LAKI. (2025). LAKI Feedback-E-Mails des Projekts FANTASTIC. PRO-Aktiv-Team. Abgerufen am 14.07.2025, von [https://tlp.de/pro-aktiv\\_laki-beispiel-emails](https://tlp.de/pro-aktiv_laki-beispiel-emails)
- Lang, C., Siemens, G., Wise, A., & Gašević, D. (2017). *The handbook of learning analytics* (1st ed.). SoLAR Vancouver. <https://doi.org/10.18608/hla17>
- Lang, C., Siemens, G., Wise, A., Gašević, D., & Merceron, A. (2022). *The handbook of learning Analytics* (2nd ed.). SoLAR Vancouver. <https://doi.org/10.18608/hla22>
- Mahesh, B. (2020). Machine learning algorithms – A review. *International Journal of Science and Research (IJSR)*, 9(1), 382-386. <https://doi.org/10.21275/ART20203995>
- Matthews, R. (2000). Storks deliver babies ( $p=0.008$ ). *Teaching Statistics*, 22(2), 36–38. <https://doi.org/10.1111/1467-9639.00013>
- Mazur, E. (1997). *Peer instruction: A user's manual*. Prentice-Hall. Deutsche Übersetzung: Mazur, E. (2017). *Peer Instruction: Interaktive Lehre praktisch umgesetzt* (G. Kurz und U. Harten, Hrsg.). Springer Spektrum. <https://doi.org/10.1007/978-3-662-54377-1>

McDermott, L. C., & Shaffer, P. S. (2011). Tutorien zur Physik. Pearson Deutschland. <https://elibrary.pearson.de/book/99.150005/9783863266660>

Novak, G. M., Patterson, E. T., Gavrin, A. D., & Christian, W (1999): Just-in-time teaching: blending active learning with web technology. Prentice-Hall.

Popp, H., Beer, R., & Ciolacu, M. (2018). Blended Learning 4.0: KI-unterstützte digitale Lehre. In F. Waldherr & C. Walter (Hrsg.), Tagungsband zum Forum der Lehre an der TH Ingolstadt (S. 72-78). DiZ - Didaktikzentrum. Abgerufen am 14.07.2025, von [https://bayziel.de/wp-content/uploads/DiNa\\_2018-05\\_Sonderausgabe\\_FdL.pdf](https://bayziel.de/wp-content/uploads/DiNa_2018-05_Sonderausgabe_FdL.pdf)

Roediger, H. L., Karpicke, J. D. (2006). The power of testing memory. Perspectives on Psychological Sciences, 1(3), 181-209. <https://doi.org/10.1111/j.1745-6916.2006.00012.x> und <https://www.retrievalpractice.org/>

Schäfle, C., & Junker, E. (2023). Just-in-time teaching mit Peer Instruction: Agil, aktivierend, lernendenzentriert, wirksam. In T. Buchner et al. (Hrsg.), Inverted Classroom and Beyond 2023: Agile Didaktik für nachhaltige Bildung (S. 130-145). Verein Forum neue Medien in der Lehre Austria. [https://www.icmbeyond.net/?page\\_id=2038](https://www.icmbeyond.net/?page_id=2038), mehr auf [www.pro-aktiv.de](http://www.pro-aktiv.de)

Sghir, N., Adadi, A., & Lahmer, M. (2023). Recent advances in predictive learning analytics: A decade systematic review (2012-2022). Education and Information Technologies, 28, 8299-8333. <https://doi.org/10.1007/s10639-022-11536-0>

SoLARResearch. (2025). Society for Learning Analytics Research.

Abgerufen am 14.07.2025., von <https://www.solaresearch.org>

Suhonen, S. (2018, 16. Mai). Learning analytics [Video]. Tampere University of Applied Sciences. <https://www.youtube.com/watch?v=FXMbjvDvebo>

Suhonen, S., & Kinnari-Korpela, H. (2019). Using Moodle data for analytics for early warning of dropping out. In Proceedings of the SEFI 47th Annual Conference (pp. 1113-1122). print: [https://www.sefi.be/wp-content/uploads/2019/10/SEFI2019\\_Proceedings.pdf](https://www.sefi.be/wp-content/uploads/2019/10/SEFI2019_Proceedings.pdf)  
video: <https://www.youtube.com/watch?v=yk3H8w1sJWw>

Wikipedia. (2025). Beurteilung eines binären Klassifikators, statistische Gütekriterien. Abgerufen am 16.07.2025, von <https://t1p.de/KI-Guetemasse>

## Angaben zu den Autorinnen und Autoren

### Prof. Dr. Elmar Junker

Diplomphysiker. Nach 12 Jahren industrieller Entwicklungsprojekte beforstet er seine eigene Lehre (SoTL) an der TH, Mehr: [www.th-rosenheim.de/junker.html](http://www.th-rosenheim.de/junker.html)

### Anne Sanewski

Informatikerin (B.Sc.), FuE im Bereich Learning Analytics

### Nicole Kraus

Informatikerin (M.Sc.), FuE im Bereich Learning Analytics

**Prof. Dr. Thomas Schweser**

Mathematiker (M.Sc.), befasst sich mit Graphenzerlegungen & Datenbankoptimierung. Mehr: <https://t1p.de/THRO-Schweser>

**Prof. Dr. Ulrich Wellisch**

Diplommathematiker, FuE Data Analytics & mathematische Statistik, befasst sich mit maschinellem und statistischem Lernen. Mehr: <https://t1p.de/Research-Wellisch>

**Finn Schmidt, André Kajtar**

Bacheloranden Wirtschaftsmathematik, modellierten die Logistische Regression

**Silke Deschle-Prill**

Diplompädagogin, FuE im Bereich Coaching.

## **IMPRESSUM**

Der **Tagungsband zum 6. Symposium zur Hochschullehre in den MINT-Fächern** erscheint als DiNa-Sonderausgabe.

ISSN 1612-4537

### **HERAUSGEBER**

Dr. Hanna Dölling und Prof. Dr. Claudia Schäfle  
BayZiel - Bayerisches Zentrum für Innovative Lehre  
Technische Hochschule Ingolstadt, vertreten durch  
den Präsidenten Prof. Dr. Walter Schober (V.i.S.d.P.)  
Atelierstraße 1, 81671 München  
E-Mail: [Lehr-Lernforschung@bayziel.de](mailto:Lehr-Lernforschung@bayziel.de)  
[www.bayziel.de](http://www.bayziel.de)

### **REDAKTION**

Dr. Susanne Kürsten  
Marianne Hunger  
Jana Bay  
Anila Sahitaj

### **ABBILDUNGEN & FOTOS**

Die Rechte liegen bei den Autorinnen und Autoren, soweit nicht anders angegeben.

### **DESIGNKONZEPT, LAYOUT UND SATZ**

Susanne Stumpf, Dipl. Designerin (FH)  
Hutstraße 31, 91207 Lauf a.d. Peg.  
[www.stumpf-design.de](http://www.stumpf-design.de)

Die Verantwortung für den Inhalt der einzelnen Beiträge in dieser Veröffentlichung liegt bei den jeweiligen AutorInnen.

© BayZiel, München, September 2025

[www.mint-symposium.de](http://www.mint-symposium.de)