


ASSIST

Eine KI-gestützte Smartphone-App zur Unterstützung der Selbstreflexion



Projekt | Daten

- ❑ ASSIST ist ein Feedback-Portal für Smartphones, welches es Studierenden ermöglicht, ihre Abschlusswahrscheinlichkeit anhand der Note und der Leistungspunkte für das kommende Semester vorherzusagen und ihre Leistungen mit denen ihrer Kommilitonen zu vergleichen.
- ❑ Zentrale Fragen sind:
 - a) Wie können wir ein skalierbares Instrument zur Unterstützung der studentischen Leistung entwickeln?
 - b) Beeinflusst die Selbstreflexion das Lernverhalten?
- ❑ Die App ist für iOS und Android verfügbar und kann mit den Anmelde- und Leistungsdaten der Universität aufgerufen werden.
- ❑ ASSIST kann an jeder deutschen Hochschule eingesetzt werden.
- ❑ Die App nutzt die Daten einer öffentlichen Universität mit 68,124 eindeutigen IDs von 2007 bis 2023.
- ❑ Der Datensatz enthält Variablen zu demografischen Merkmalen, Schulleistungen und akademischen Leistungen.

Modell | Performance

- ❑ Wir verwenden ein Multi-Layer Perceptron zur Vorhersage des Studienerfolgs.
- ❑ Für die Überprüfung einzelner Prognosen verwenden wir Shapely-Values und befragen zufällig ausgewählte Studierende.
- ❑ In einem nächsten Schritt wollen wir Aktivitätsdaten von universitären Lernplattformen einbeziehen, um unsere Vorhersagen zu verbessern und die Wahrscheinlichkeiten häufiger zu aktualisieren.

Abb. 2. Durchschnittliche Veränderung der Wahrscheinlichkeiten (PDP/ICE)





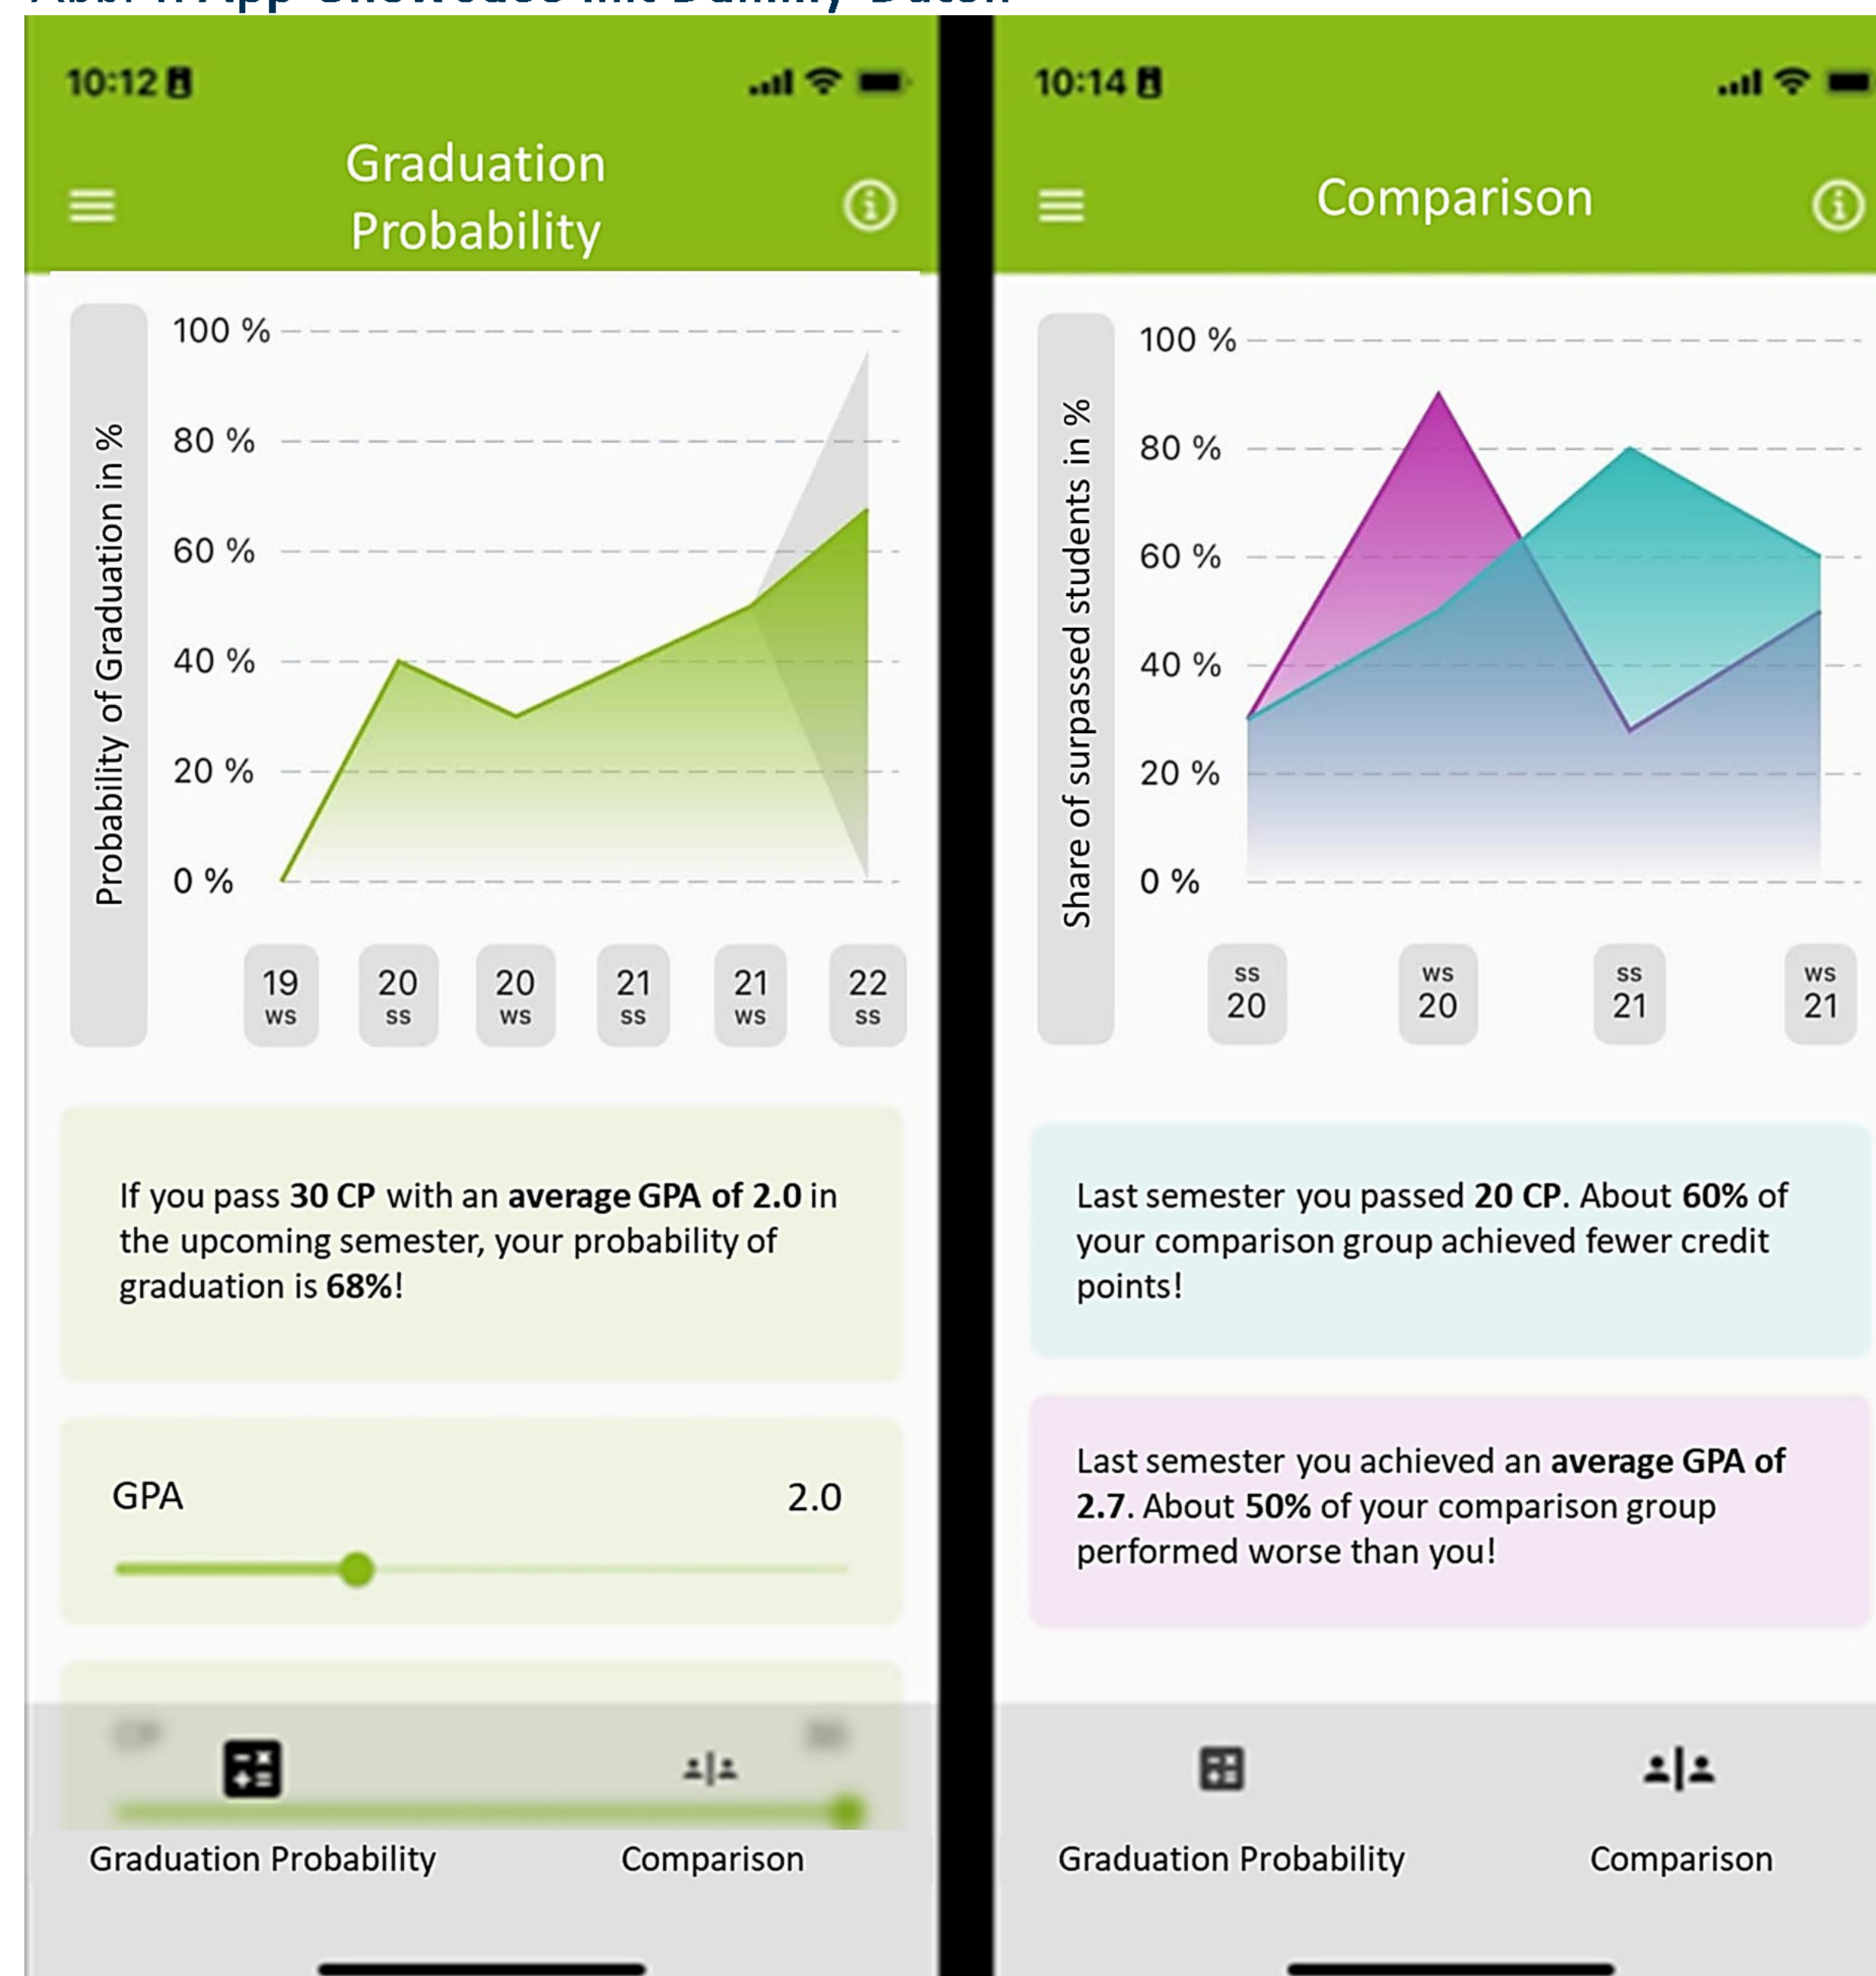
Abb. 3. MLP-Kalibrierungskurven



Tab. 1. MLP-Klassifizierungsperformance

	Imm.	Sem. 1	Sem. 2	Sem. 3	Sem. 4
Accuracy	0.71	0.80	0.82	0.84	0.84
Precision	0.76	0.81	0.79	0.80	0.77
Recall	0.78	0.81	0.79	0.80	0.77
Negative Predictive Value	0.68	0.80	0.83	0.87	0.88
Specificity	0.70	0.80	0.84	0.86	0.88

Abb. 1. App-Showcase mit Dummy-Daten



Experimente

- ❑ In zwei RCTs wurde die Wirkung von ASSIST auf Studierende getestet.
 - a) In der ersten Intervention haben wir 800 Studierende per E-Mail eingeladen, die ASSIST-App zu nutzen.
 - b) In der zweiten Intervention gab es eine persönliche Ansprache in ausgewählten Vorlesungen (165 Personen) mit einem kleinen monetären Anreiz.
- ❑ Die Teilnahme an der ersten niedrigschwelligen Intervention war sehr gering (2%). Die Ansprache der Studierende in der Vorlesung führte jedoch dazu, dass sich 27% der Treatmentgruppe für die App anmeldeten.

Tab. 2. Durchschnittliche Treatment-Effekte (IV-Modell) in RCT (b)

	Klausur-anmeldungen		Leistungs-punkte		Abbruchwahrscheinlichkeit	
ITT-Effekte (Ansprache)	0.22 (0.43)	0.14 (0.43)	-0.74 (1.33)	-1.02 (1.35)	-0.03 (0.03)	-0.02 (0.03)
Take-up Rate	0.27*** (0.05)	0.26*** (0.05)	0.27*** (0.05)	0.26*** (0.05)	0.27*** (0.06)	0.26*** (0.06)
LATE-Effekte (Compliers)	0.80 (1.60)	0.53 (1.65)	-2.70 (4.81)	-3.80 (4.94)	-0.09 (0.10)	-0.09 (0.11)
Kontrollvariablen		X		X		X

* p < 0.1, ** p < 0.05, *** p < 0.01



Projektteam:

Johannes Berens, Thomas Gößl, Leandro Henao, Luis Rumert, Moritz Salamon, Kerstin Schneider



Literatur:

Berens, J., Schneider, K., Görtz, S., Oster, S., & Burghoff, J. (2019). Early Detection of Students at Risk-Predicting Student Dropouts Using Administrative Student Data and Machine Learning Methods. *Journal of Educational Data Mining*, 11(3), 1–41.
 Lew, M. D. N., & Schmidt, H. G. (2011). Self-reflection and academic performance: Is there a relationship? *Advances in Health Sciences Education*, 16(4), 529–545.
 Niculescu-Mizil, A., & Caruana, R. (2005). Predicting Good Probabilities With Supervised Learning. *Proceedings of the 22nd International Conference on Machine Learning*, Bonn.



BERGISCHE
UNIVERSITÄT
WUPPERTAL