

Initial Investigations of Grade Predictions for a Course Recommender System

Kerstin Wagner, Agathe Merceron and Petra Sauer¹

Abstract: Course recommendation systems can support students' success. An important component of such a system is the prediction of the grade students can expect when they take a course. In this paper, different algorithms for predicting grades are used and compared. Linear regression models provide the better results; furthermore, they have the advantage of being comprehensible, which enables users to better assess the limitations of the model and thus decide how much trust they want to place in the system.

Keywords: Grade prediction, course recommender system, data analysis, linear regression

¹ Beuth Hochschule für Technik Berlin, Fachbereich VI, Luxemburger Straße 10, 13353 Berlin,
{kerstin.wagner, merceron, sauer}@beuth-hochschule.de

Erste Untersuchungen zur Notenprognose für ein Kursempfehlungssystem

Kerstin Wagner, Agathe Merceron und Petra Sauer¹

Abstract: Kursempfehlungssysteme können den Studienerfolg unterstützen. Eine wichtige Komponente eines solchen Systems ist die Prognose der Note, die Studierende bei Kursbelegung erwarten können. In diesem Beitrag werden verschiedene Algorithmen zur Notenprognose eingesetzt und verglichen. Die Modelle der linearen Regression liefern die besseren Ergebnisse. Darüber hinaus haben sie den Vorteil, nachvollziehbar zu sein, was Nutzende befähigt, die Grenzen des Modells besser einzuschätzen, und somit zu entscheiden, wie viel Vertrauen sie dem System schenken möchten.

Keywords: Notenprognose, Kursempfehlungssystem, Datenanalyse, Lineare Regression.

1 Einleitung

Relativ hohe Zahlen an Studienabbrechern führen Hochschulen dazu, innovative Maßnahmen zu ergreifen, um diesem Problem aktiv zu begegnen. Falk et al. argumentieren, dass eine Kombination von unterstützenden Maßnahmen die beste Erfolgsaussicht hat [FTV18]. Unter den von Falk et al. genannten Maßnahmen sind diejenigen besonders wichtig, die auf der Analyse der Daten der Studierenden beruhen. Ein maßgebliches Ziel der analytischen Forschung mit akademischen Daten ist es, Kursempfehlungssysteme zu entwickeln und zu evaluieren.

Während im ersten Semester das Belegungsverhalten innerhalb von Kohorten recht homogen ist und die Empfehlungen des Curriculums weitgehend berücksichtigt, folgen bereits nach einem Semester nicht mehr alle Studierende dem Curriculum. Gründe dafür sind u.a. das Bestehen oder Nicht-Bestehen der belegten Module und die Erfahrungen der Studierenden zur Handhabbarkeit der *Workloads* aus dem ersten Semester. Die Datenexploration zeigt, dass manche Studierende es schaffen, alle Kurse, die sie in einem Semester belegen, erfolgreich abzuschließen, während andere Studierende teilweise systematisch mehr Kurse belegen, als sie erfolgreich abschließen. Abbildung 1 zeigt einen solchen Verlauf: der Studierende, dessen Belegungsverhalten links zu erkennen ist, schließt in jedem Semester erfolgreich alle belegten Kurse ab und absolviert den Bachelorstudiengang in sechs Semestern, wie in der Studienordnung vorgesehen. Der Studierende rechts belegt mehr Kurse (grau) als er erfolgreich abschließt (grün), außer im letzten Semester, und benötigt für den gleichen Bachelorstudiengang neun Semester und

¹ Beuth Hochschule für Technik Berlin, Fachbereich VI, Luxemburger Straße 10, 13353 Berlin,
{kerstin.wagner, merceron, sauer}@beuth-hochschule.de

somit drei Semester mehr, als in der Studienordnung vorgesehen. Studierende, die fortwährend mehr Kurse belegen als abschließen, laufen Gefahr, exmatrikuliert zu werden, da ein Kurs maximal vier Mal belegt werden kann. Ein Kursempfehlungssystem kann unterstützen und das Belegungsverhalten positiv beeinflussen.

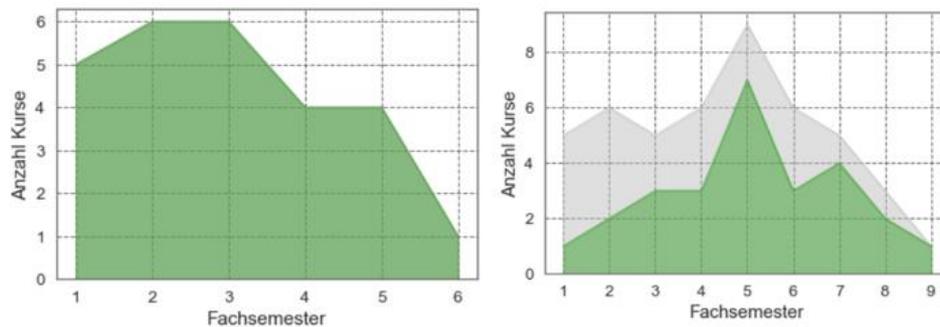


Abb. 3: Belegungsverhalten von Studierenden

Dieser Beitrag zeigt, wie eine Ausgangsbasis für Kursempfehlungen alleine aus der Analyse der bisherigen Kursbelegungen und erreichten Prüfungsergebnisse geschaffen werden kann, indem Notenprognosen für Kurse des kommenden Semesters gegeben und daraus Belegungsempfehlungen abgeleitet werden.

Grundlagen des Beitrags sind Daten aus drei Bachelor-Studiengängen seit deren Start im Jahr 2005 bis ins Jahr 2019. Die für die Vorhersage verwendeten Algorithmen sind dem Gebiet des maschinellen Lernens zuzuordnen. In dieser Untersuchung erfolgt zunächst eine Beschränkung auf Pflichtkurse, da diese erfolgreich abgeschlossen werden müssen, während ein Wahlpflichtkurs durch einen anderen ersetzt werden kann. Ferner erfolgt eine Beschränkung auf die drei ersten Semester des jeweiligen Studienganges: einerseits bestehen diese vorwiegend aus Pflichtkursen, andererseits liegen in diesem Zeitraum wegen der Studienabbrüche über die Semester mehr Daten vor, was prinzipiell für die eingesetzten Algorithmen in dieser frühen Phase der Untersuchung von Vorteil ist. Mehrere Algorithmen werden untersucht, um deren Ergebnisse zu vergleichen und wie in [PK16] wird ein Modell pro Kurs erstellt. Die besten Ergebnisse für alle drei Studiengänge liefert die lineare Regression. Ein Vorteil der linearen Regression ist die Interpretierbarkeit der Koeffizienten, die es Studierenden und Lehrende ermöglicht nachzuvollziehen, wie das Modell die Vorhersage konstruiert, was wichtig ist, damit sie die Stärken und Grenzen des Modells erkennen und entscheiden können, wie viel Vertrauen sie dem System schenken.

2 Verwandte Arbeiten

Polyzou und Karypis untersuchen eine kurs-spezifische Regression und kollaboratives Filtern, genauer *Matrix Factorization*, um die Note in einem bestimmten Kurs vorherzusagen, den Studierende belegen möchten [PK16]. Dabei werden alle Noten betrachtet, die Studierende erhalten haben, ehe sie den bestimmten Kurs belegen. Der *Matrix-Factorization*-Ansatz ist der gleiche Ansatz, der in Empfehlungssystemen verwendet wird. Die Zeilen der Matrix sind die Studierenden, die Spalten die Kurse und der Wert $g_{i,j}$ ist die Note, die ein Studierender i im Kurs j erhalten hat. In ihrer Untersuchung erhalten die Autoren leicht bessere Ergebnisse mit dem Ansatz der kurs-spezifischen Regression ($RMSE$ (Root Mean Square Error) = 0.632) als mit dem Ansatz der *Matrix Factorization* ($RMSE$ = 0.661).

In [MK19a] erweitern Morsy und Karypis den kurs-spezifischen Regressionsansatz von [PK16], um zu berücksichtigen, dass nicht alle Kurse gleich wichtig sind. Zum Beispiel sollte der Wahlpflichtkurs „Amerikanische Literatur“ für den Kurs „Informatik II“ weniger wichtig sein als der Kurs „Informatik I“. Sie führen neuronale Netze ein (*Single-Layer Perceptron* mit einem *Attention Mechanism*), um Gewichte für die Kurse zu trainieren. In einer Untersuchung verbessert dieses Modell die Ergebnisse des kurs-spezifischen Regressionsansatzes. In [MK19b] kombinieren Morsy und Karypis die Kursempfehlung mit der Notenvorhersage und vergleichen dabei mehrere Ansätze. Die Kursempfehlung basiert auf den Belegungen der Studierenden anhand historischer Daten. Aus der Liste der Top-N-Kurse, die Studierende am meisten belegen, werden diejenigen mit einer besseren Vorhersage der Note empfohlen. Der Ansatz, der die besten Ergebnisse gibt, verwendet die kurs-spezifische Regression für die Vorhersage der Note und eine Singulärwertzerlegung (*Singular Value Decomposition*) für die Empfehlung der Kurse.

Backenköhler et al. verwenden ebenso kollaboratives Filtern, um eine Note in einem Kurs vorherzusagen [Ba18]. Dabei werden weitere Merkmale wie z.B. der den Kurs anbietende Dozent berücksichtigt. Die Vorhersage der Note wird mit der Reihenfolge der Belegungen kombiniert, die wiederum auf statistischen Methoden beruht: Kurs A wird vor Kurs B empfohlen, wenn die Wahrscheinlichkeit einer besseren Note durch diese Reihenfolge höher ist.

Jiang et al. sagen nicht direkt eine Note vorher, sondern berechnen, ob Studierende ihre Zielnote für einen Kurs, den sie belegen möchten, erreichen werden [JPW19]. Dafür verwenden sie rekurrente neuronale Netze, genauer *LSTMs* (*Long Short-Term Memory*). Die Folge der *Hidden Layer* spiegelt die Folge der Semester, die Studierende nacheinander studieren.

Basierend auf den Ergebnissen von [PK16] und [MK19b] und auf der eigenen Vorarbeit mit dem Datensatz [WMS20] werden in diesem Beitrag Algorithmen aus dem Gebiet des maschinellen Lernens in den Mittelpunkt gestellt, um Noten in Kursen vorherzusagen.

3 Methodisches Vorgehen

3.1 Überblick über die Daten und Datenvorbereitung

Für die Entwicklung der Prognosen des Kursempfehlungssystems wurden Daten von drei verschiedenen Bachelor-Studiengängen (codiert mit 113, 143, 153) einer mittelgroßen deutschen Hochschule verwendet. Die Daten liegen vom Wintersemester 2005 bis zum Sommersemester 2019 vor und umfassen 6.049 Studierende (113: 1038, 143: 2351, 153: 2660). Ein Datensatz eines Studierenden beinhaltet unter anderem Informationen zur Kursbelegung, zur erreichten Kursnote und zum Bestehen des Kurses.

Die Studierenden- und die Prüfungsdaten werden bereits in einer anonymisierten Form durch die Hochschule zur Verfügung gestellt, um Rückschlüsse auf Studierende über die Prüfungsergebnisse zu erschweren, d.h. die Studierenden-ID ist randomisiert und die Noten sind wie folgt zusammengefasst: (1.0, 1.3) → (1.3), (2.0, 2.3, 2.7) → (2.3), (3.0, 3.3, 3.7) → (3.3), die Noten 1.7, 4.0 und 5.0 wurden separat belassen.

Die Rohdatenverarbeitung bis hin zum *Feature Engineering* für die Regression umfasste grob die folgenden vier Schritte: 1. allgemeine Datenbereinigung, 2. *Mapping* zu aktuell gültigen Lehrveranstaltungen gemäß aktueller Studienordnung, 3. Zusammenfassen einzelner Lehrveranstaltungen zu Kursen und 4. Datenfilterung und *Feature Engineering* für die Regression, wobei die drei ersten Schritte die grundlegenden sind und die so vorverarbeiteten Daten auch für andere Arbeiten verwendet werden können.

Da nur Noten vorliegen, wenn ein Kurs “bestanden” oder “nicht bestanden” ist, nicht jedoch “belegt” oder “nicht belegt”, werden fehlende Noten mit 5.0 ersetzt, so dass die 5.0 alle Fälle abdeckt, in denen ein Kurs nicht erfolgreich abgeschlossen wurde. Bei den bereits zusammengefassten Noten werden für die Regression auch (1.3, 1.7) gleichbehandelt, so dass für die Regression die Noten 1.0, 2.0, 3.0, 4.0, 5.0 im Sinne von “sehr gut”, “gut”, “befriedigend”, “ausreichend” und “nicht bestanden” vorliegen. Diese Zusammenfassung entspricht nicht dem gängigen Schema (1.0, 1.3) → “sehr gut”, (1.7, 2.0, 2.3) → “gut”, (2.7 3.0, 3.3) → “befriedigend”, (3.7, 4.0) → “ausreichend” und resultiert daraus, dass die Daten bereits bei Bereitstellung innerhalb der Hochschule aus Datenschutzgründen in einer abweichenden, aggregierten Form vorliegen, worauf kein Einfluss genommen werden konnte.

3.2 Algorithmen und Evaluierung der Modelle

In der Datenexploration wurden die Korrelationsmatrizen zwischen den Noten der Kurse des 1. und 2. sowie des 1., 2. und 3. Plansemesters gebildet – unabhängig davon, in welchem Fachsemester der Kurs abgeschlossen wurde. Etwa ein Drittel der Korrelationskoeffizienten ist größer als 0.3, was darauf hinweist, dass die vorhandenen Noten sinnvolle Eingangsvariablen für die Vorhersage der Noten im nächsten Semester

sind. Abbildung 4 (links) zeigt beispielhaft die Korrelationsmatrix des Studiengangs 143 für das 1. und 2. Semester. In dieser Studie wurden

1. die Noten des jeweils ersten Semesters als Features verwendet und die Noten für jeden Kurs des zweiten Semesters vorhergesagt, und
2. die Noten des jeweils ersten und zweiten Semesters als Features verwendet und die Noten für jeden Kurs des dritten Semesters vorhergesagt.

Tabelle 1 zeigt die Anzahl der Kurse und die Anzahl der Studierenden, die für das jeweilige Semester und den Studiengang in die Regression aus dem Gesamtdatensatz eingegangen sind. Die geringere Anzahl an Studierenden im 3. Semester ergibt sich durch Studierende, für die im 3. Semester keine Prüfungsergebnisse vorlagen, z.B. durch Studiengangsabbrecher oder genommene Urlaubssemester. Der Studiengang 113 hat im 3. Semester einen einzigen Pflichtkurs, alle anderen sind Wahlpflichtkurse.

Studiengang	113	113	143	143	153	153
Semester	2	3	2	3	2	3
Anzahl Kurse	6	1	5	5	6	6
Anzahl Studierende	854	713	1756	1377	1861	1565

Tab. 2: Anzahl der Pflichtkurse und Studierenden nach Studiengang und Semester

Mittels verschiedenartiger Algorithmen (lineare Regression (LR), *Decision Tree* (DT), *k-Nearest-Neighbors* (KNN) [Ja13], *Multi-Layer Perceptron* (MLP) [HTF09]) wurde untersucht, ob eine Prognose von Kursnoten und Kursbelegungen grundsätzlich machbar ist. Die Implementierung der Modelle erfolgte in Python 3.8.3 und Scikit-Learn 0.22.1 mit Default-Einstellungen bezüglich der Modellparameter. Eine Ausnahme bildet der *MLP-Regressor*: hier wurde die Zahl der Neuronen im ersten *Hidden Layer* auf 10 herabgesetzt, um *Overfitting* zu vermeiden. Die Datensätze wurden in 60% Trainingsdaten und 40% Testdaten gesplittet, wobei die Zuordnung zufällig erfolgte.

Die Güte der Modelle wurde mittels des Fehlermaßes *RMSE* (*Root Mean Square Error*, Wurzel der mittleren quadratischen Abweichung) ermittelt. Der *RMSE* gibt an, wie weit die prognostizierten Werte im Durchschnitt von den tatsächlichen Werten abweichen und hat 0 als den besten Wert.

Um abschließend eine Belegung für einen Kurs zu empfehlen oder nicht, wurden die prognostizierten Noten wieder auf die im Rahmen dieser Arbeit verwendeten Notenwerte gerundet (1.0, 2.0, 3.0, 4.0, 5.0) und bei einer Note besser als 4.0 wurde die Belegung empfohlen. Für die tatsächlichen und empfohlenen Belegungen wurden analog zu einer Klassifikation Konfusionsmatrizen erstellt (siehe Abb. 2) und die folgende Metriken abgeleitet:

- Genauigkeit (*Accuracy*): Anteil empfohlener Kurse, die tatsächlich belegt wurden (RP) und Anteil nicht empfohlener Kurse, die tatsächlich nicht belegt wurden (RN), an allen möglichen Belegungen (RP+RN+FP+FN)
- Relevanz (*Precision*): Anteil empfohlener Kurse, die tatsächlich belegt wurden (RP) an allen empfohlenen Kursen (RP+FP),
- Sensitivität (*Recall*): Anteil empfohlener Kurse, die tatsächlich belegt wurden (RP) an allen tatsächlich belegten Kursen (RP+FN),
- F1: harmonisches Mittel aus Relevanz und Sensitivität mit 1 als den besten Wert

		Modell	
		Kurs empfohlen	Kurs nicht empfohlen
Realität	Kurs belegt	RP (richtig positiv)	FN (falsch negativ)
	Kurs nicht belegt	FP (falsch positiv)	RN (richtig negativ)

Abb. 4: Schema der Konfusionsmatrix für die abgeleitete Belegungsempfehlung

4 Ergebnisse

Im Folgenden werden die Ergebnisse der Vorhersage der Noten für Kurse des 2. Semesters dargestellt. Die Ergebnisse für die Prognose der Noten des 3. Semesters werden aus Platzmangel nicht abgebildet. Sie unterscheiden sich nicht wesentlich von den Ergebnissen des 2. Semesters.

Tabelle 2 beinhaltet die Evaluierungsergebnisse der Notenprognose über den *RMSE* für das 2. Semester. Der je Kurs kleinste (beste) Wert ist hervorgehoben. Die lineare Regression weist in 12 von 17 Fällen den kleinsten Wert auf. Ihre Werte schwanken zwischen 1.062 (143 / Kurs B06) und 1.743 (113 / Kurs B12) und ihr Mittelwert liegt bei 1.238. Für das 3. Semester erreicht die lineare Regression in 9 von 12 Fällen den kleinsten Wert, schwankend zwischen 1.162 und 1.407 und mit einem Mittelwert von 1.272.

Studiengang	Kurs	DT	KNN	LN	MLP
113	B07	1.807	1.390	1.363	1.387
113	B08	1.697	1.369	1.346	1.361
113	B09	1.486	1.130	1.101	1.162
113	B10	1.632	1.340	1.353	1.333
113	B11	1.465	1.169	1.122	1.109
113	B12	2.152	1.802	1.743	1.812
143	B06	1.311	1.163	1.062	1.069

Studiengang	Kurs	DT	KNN	LN	MLP
143	B07	1.621	1.419	1.312	1.320
143	B08	1.562	1.417	1.278	1.286
143	B09	1.455	1.281	1.162	1.169
143	B10	1.605	1.417	1.318	1.321
153	B08	1.431	1.357	1.201	1.202
153	B09	1.461	1.343	1.181	1.177
153	B10	1.408	1.337	1.274	1.262
153	B11	1.539	1.427	1.352	1.355
153	B12	1.396	1.318	1.231	1.227
153	B13	1.416	1.295	1.219	1.229

Tab. 3: RMSE der Notenprognosen für das 2. Semester

Abbildung 3 veranschaulicht die Verteilungen der prognostizierten Noten in Abhängigkeit von der tatsächlichen Note über alle Kurse eines Studiengangs. Die Box-Plots zeigen die Mediane, die oberen und unteren Quartile sowie Ausreißer. Die Boxen sind sowohl bezüglich der tatsächlichen Noten als auch der Studiengänge unterschiedlich groß, wobei eine kleinere Box eine geringere Verteilung der prognostizierten Noten und damit ein besseres Ergebnis darstellt. Der allgemeine Trend für die drei Studiengänge ist: pessimistisch für die Noten 1 und 2, eher realistisch für die Note 3 und optimistisch für die Noten 4 und 5 ist. Die Prognosen für das 3. Semester zeigen ein ähnliches Ergebnis.

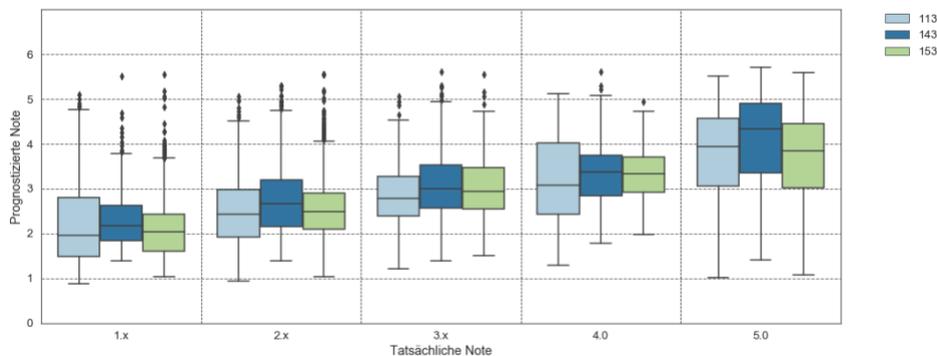


Abb. 3: Verteilung der prognostizierten Note für alle Kurse des 2. Semesters

Abbildung 4 stellt die Korrelationskoeffizienten (links) den Koeffizienten der linearen Regression (rechts) beispielhaft für den Studiengang 143 und die Noten des 1. und 2. Semesters gegenüber. Korrelationskoeffizienten mit hohen Werten entsprechen den Koeffizienten der linearen Regression mit höheren Werten. Die größten Koeffizienten

liegen für B01 und B06 (0.612) sowie B05 und B09 (0.616) vor und zeigen einen starken positiven Einfluss.

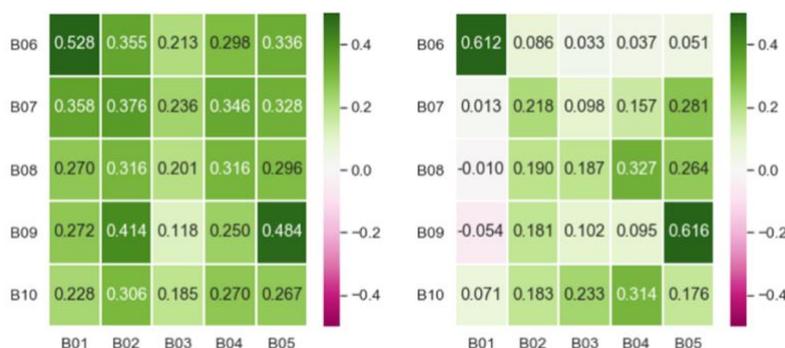


Abb. 4: Korrelationsmatrix (links) und Regressionskoeffizienten (rechts) jeweils für die Kurse des 1. und 2. Semesters des Studiengangs 143

Tabelle 3 zeigt die Ergebnisse Evaluierung der Belegungsempfehlung über alle Kurse für das 2. und 3. Semester auf Basis der Notenprognose (Note <4.0: Belegung empfohlen). Der je Metrik höchste (beste) Wert ist hervorgehoben – er wird für alle Metriken vom Studiengang 113 für das 3. Semester erreicht. Beim studiengangsspezifischen Vergleich der Ergebnisse zwischen dem 2. und 3. Semester schneidet die Vorhersage für das 3. Semester bis auf eine Ausnahme (Sensitivität / Studiengang 143) besser ab.

Studiengang	113	113	143	143	153	153
Semester	2	3	2	3	2	3
Genauigkeit	0.781	0.829	0.785	0.795	0.786	0.823
F1	0.832	0.897	0.812	0.829	0.841	0.866
Relevanz	0.779	0.862	0.771	0.804	0.805	0.846
Sensitivität	0.893	0.934	0.857	0.855	0.881	0.887

Tab. 3: Ergebnis der Evaluierung der Kursempfehlungen für das 2. Semester für alle Studiengänge

5 Diskussion

Aus den in Tabelle 2 gezeigten *RMSE* lässt sich schließen, dass die lineare Regression mit den etwas besseren Ergebnissen eine gut interpretierbare Basis für ein Kursempfehlungssystem liefern kann. Im besten Fall kann jedoch eine Notenvorhersage um +/- 1.062 von der tatsächlichen Note abweichen, d.h. eine tatsächliche 3.0 würde ggfs. als 4.0 vorhergesagt und entsprechend würde von einer Belegung abgeraten werden. In

[PK16] liegt der *RMSE* bei 0.632 und die erlaubten Noten sind 4.0, 3.667, 3.333 usw. bis 0. Im Unterschied zu [PK16] wird in der vorliegenden Arbeit nicht zwischen 1.0, 1.3, 1.7, usw., differenziert, was einen wesentlichen Teil der weniger guten Vorhersage erklärt. Die Verwendung der echten, nicht zusammengefassten Noten und eine Verbesserung der Modelle, z.B. über Hyperparameter-Tuning, sollten die Ergebnisse der Prognose verbessern. Die für die Verteilung der prognostizierten Noten ersichtliche Schwäche für die besseren und die schlechteren Noten sind nach einer Optimierung der Modelle erneut zu untersuchen.

Die größten Koeffizienten (B01 und B06 sowie B05 und B09) der linearen Regression in Abbildung 4 (rechts) sind nachvollziehbar, da es sich jeweils um einen Grundlagen- und den zugehörigen Aufbaukurs handelt (Mathematik I und II, Programmierung I und II), und somit lassen sich die Werte geeignet interpretieren. Für ein Kursempfehlungssystem sollte jedoch das Vorwissen der Nutzenden über lineare Regression und ihre Koeffizienten berücksichtigt und entsprechende Erklärungen zur Verfügung gestellt werden.

Hinsichtlich der Evaluierung der Kursempfehlungen zeigt das 3. Semester, abgesehen von der im Abschnitt 4 genannten Ausnahme, bessere Ergebnisse als das 2. Semester, was darauf beruhen kann, dass mehr Daten (Kursnoten aus dem 1. und 2. Semester) über die Studierenden vorliegen. Der Studiengang 113 hat im 3. Semester insgesamt die besseren Werte, was möglicherweise darauf zurückzuführen ist, dass nur ein Pflichtkurs existiert. Die erreichten Werte für die Genauigkeit liegen zwischen 0.781 und 0.829 und für *F1* zwischen 0.812 und 0.897 – dies sind sehr ermutigende Ergebnisse für eine erste Untersuchung. Mit den bereits genannten Maßnahmen zur Verbesserung der Notenprognose ist auch eine Verbesserung der Kursempfehlung zu erwarten.

6 Fazit und Ausblick

Der vorliegende Beitrag zeigt, dass anhand von akademischen Daten einer deutschen Hochschule eine Notenprognose und darauf basierend eine Kursempfehlung für künftig zu belegende Kurse machbar ist. Das entwickelte Prognosemodell hat eine akzeptable Prognosequalität, was anhand des Fehlermaßes *RMSE* gezeigt wurde: der durchschnittliche Fehler liegt bei weniger als 1.3 Notenabweichung. Eine Ergebnisverbesserung wird durch die Optimierung der Modelle und Verwendung der echten Noten erwartet. Darüber hinaus könnte auch die Klassifikation der Studierenden mit Abbruchrisiko, die in [WMS20] mit dem betrachteten Datensatz durchgeführt wird, als zusätzliches Feature die Prognosegüte erhöhen.

Weitere Untersuchungen betreffen künftig die Möglichkeiten der Vorhersage des besten Wiederholungszeitpunktes für Studierende, die in einem Semester nicht alle Pflichtfächer erfolgreich abgeschlossen haben: Wann ist der bessere Zeitpunkt, um Kurse zu wiederholen? Welche weiteren Pflichtkurse des entsprechenden Fachsemesters können oder sollten kombiniert belegt werden? Auch die Einbeziehung der Wahlpflichtkurse, die

Analyse ihrer Einflüsse auf Ergebnisse der Pflichtkurse sowie die von den Studierenden angestrebten Noten und Studiendauer stellt interessante Weiterentwicklungen dar.

Damit die Studierenden jedoch nicht blind einer Empfehlung folgen, sondern selbst entscheiden können, ob sie dem System vertrauen, sind sowohl einfache, interpretierbare Modelle oder Ansätze zur Erklärung komplexerer Modelle nötig, als auch Kompetenzen, um diese Erklärungen nachvollziehen und kritisch hinterfragen zu können. Die Analyse dieser Kompetenzen und ihrer Bedeutung für das Vertrauen in das System sind – neben den Vorhersagemodellen an sich – ein wesentlicher Bestandteil für den Erfolg eines Kursempfehlungssystems und damit Schwerpunkte zukünftiger Arbeiten.

Literaturverzeichnis

- [Ba18] Backenköhler, M.; Scherzinger, F.; Singla, A.; Wolf, V.: Data-driven approach towards a personalized curriculum. In (Boyer, K.K. et al. Eds.) Proceedings of the 11th International Conference on Educational Data Mining EDM 2018, 246–251, 2018. <https://educationaldatamining.org/EDM2018/proceedings/>
- [FTV18] Falk, S.; Tretter, M.; Vrdoljak, T.: Angebote an Hochschulen zur Steigerung des Studienerfolgs: Ziele, Adressaten und Best Practice. In: Bayerische Staatsinstitut Für Hochschulforschung Und Hochschulplanung (IHF), IHF Kompakt, 2018. <https://www.ihf.bayern.de/publikationen/ihf-kompakt/detail/angebote-an-hochschulen-zur-steigerung-des-studienerfolgs-ziele-adressaten-und-best-practice>
- [HTF09] Hastie, T.; Tibshirani, R.; Friedman, J. H.: The elements of statistical learning. Springer, New York, 2009. DOI: 10.1007/978-0-387-84858-7
- [Ja13] James, G.; Witten, D.; Hastie, T.; Tibshirani, R.: An Introduction to Statistical Learning. Springer, New York, 2013. DOI: 10.1007/978-1-4614-7138-7
- [JPW19] Jiang, W.; Pardos, Z.A.; Wei, Q.: Goal-based Course Recommendation. In (R. Ferguson et al. Eds.): LAK19: The 9th International Learning Analytics & Knowledge Conference, Tempe AZ, USA, March 2019, Association for Computing Machinery, New York, NY, United States, pp 36–45, 2019. DOI: 10.1145/3303772.3303814
- [MK19a] Morsy, S.; Karipys, G.: Sparse Neural Attentive Knowledge-based Models for Grade Prediction. In (Desmarais, M. et al. Eds.): Proceedings of the 12th International Conference of Educational Data Mining EDM 2019, pp. 366–371, 2019. <https://educationaldatamining.org/edm2019/proceedings/>
- [MK19b] Morsy, S.; Karipys, G.: Will this Course Increase or Decrease Your GPA? Towards Grade-aware Course Recommendation. In (Olney A. Ed.) JEDM Journal of Educational Data Mining, 11(2), 20-46, 2019. DOI: 10.5281/zenodo.3554677
- [PK16] Polyzou, A.; Karipys, G.: Grade prediction with course and student specific models. In J. Bailey et al. (Eds.): PAKDD 2016, Part I, LNAI 9651, pp. 89–101, Springer International Publishing Switzerland, 2016. DOI: 10.1007/978-3-319-31753-3_8

- [WMS20] Wagner, K., Merceron, A. & Sauer, P., (2020). Accuracy of a Cross-Program Model for Dropout Prediction in Higher Education. In Companion Proceedings of the 10th Learning Analytics and Knowledge Conference (LAK'20), p. 744-749. Workshop on Addressing Dropout Rates in Higher Education, Frankfurt am Main, Germany, 2020.