



Précis [pʁe 'si:]

// APR 2023

## Responsible Academic Performance Prediction (RAPP)

Stefan Conrad, Frank Marcinkowski, Johannes Krause, Ulrich Rosar, Michael Leuschel, Christopher Starke  
Kontakt: johannes.krause@hhu.de

### ABSTRACT

*Academic Performance Prediction (APP) Systeme, also Systeme zur Leistungsvorhersage von Studierenden, als unterstützende KI-Systeme in der Hochschulbildung versprechen die frühzeitige Erkennung von potentiellen Misserfolgen. Damit ermöglichen sie einen gezielten Ressourceneinsatz der Hochschule, um individuelle Unterstützungsmaßnahmen zu schaffen und gleichzeitig den Studienerfolg zu erhöhen. Allerdings wird einer an der Heinrich-Heine-Universität (HHU) Düsseldorf durchgeführten Studie zufolge der Einsatz KI-basierter Systeme von Studierenden als problematisch betrachtet. Dies stellt ein ernsthaftes Hindernis für den Einsatz und den Erfolg solcher Systeme dar. Ziel dieses Projektes ist daher ein sozial verträglicher Einsatz von KI-Systemen, wozu ethische Aspekte und deren Wahrnehmung durch die Betroffenen erforscht werden. Hierzu wird einerseits ein KI-System zur APP entwickelt. Andererseits wird der Einsatz dieses Systems untersucht. Hieraus sollen Handlungsempfehlungen für den Einsatz solcher Systeme abgeleitet werden.*



Als Primärforscher sind Birte Keller, Marco Lünich, Frank Marcinkowski, Bettina Ülpenich, Luisa Junghänel, Johannes Krause, Ulrich Rosar, Christopher Starke, Michael Leuschel, Jannik Dunkelau, Manh Khoi Duong und Stefan Conrad zusammen am Projekt beteiligt. Das Projekt wird vom Bundesministerium für Bildung und Forschung gefördert.

### REFERENZEN ZUM THEMA

Askinadze, A., & Conrad, S. (2019). Predicting Student Dropout in Higher Education Based on Previous Exam Results. *Proceedings 12th Int. Conf. On Educational Data Mining (EDM 2019)*, 500-503.

Keller, B., Lünich, M. & Marcinkowski, F. (2022). How Is Socially Responsible Academic Performance Prediction Possible? Insights From a Concept of Perceived AI Fairness. In F. Almaraz-Menéndez, A. Maz-Machado, C. López-Esteban & C. Almaraz-López (Hrsg.) *Advances in Higher Education and Professional Development. Strategy, Policy, Practice, and Governance for AI in Higher Education Institutions* (S. 126–155). IGI Global. <https://doi.org/10.4018/978-1-7998-9247-2.ch006>

Kieslich, K., Lünich, M., Marcinkowski, F. & Starke, C. (2019). Hochschule der Zukunft- Einstellung von Studierenden gegenüber Künstlicher Intelligenz an der Hochschule, *DIID-Précis* (Oktober). <https://doi.org/10.36200/0013>

## Einleitung

Hohe Studienabbrucherquoten stellen eine der größten Herausforderungen der Hochschulbildung in Deutschland dar. Der Erfolg von Studierenden spielt nicht nur innerhalb von Bildungseinrichtungen eine entscheidende Rolle, da er oft als Maßstab für die Leistungsfähigkeit der Institution verwendet wird. Auch bildungspolitisch und volkswirtschaftlich gilt jeder Studierende, der aus vermeidbaren Gründen eine Hochschule vorzeitig und ohne Abschluss verlässt, als ein verlorenes Talent. Einer Studie des Deutschen Zentrums für Hochschul- und Wissenschaftsforschung (DZHW) zufolge, brach beinahe jeder dritte Studienanfänger (32 Prozent) eines universitären Bachelorstudiengangs des Jahrgangs 2016 seine Ausbildung vorzeitig ab.

Dabei gehen bei den meisten Studienabbrüchen mehr oder weniger deutliche Anzeichen für Lernschwierigkeiten und/oder psychologische Belastungen durch das Studium voraus. So zeigt sich, dass die Anzahl von Studierenden, die eine psychologische Studienberatung aufsuchten von 2006 bis 2017 um 65 Prozent gestiegen ist (Deutsches Studentenwerk, 2019). Die genaue Vorhersage und frühzeitige Identifikation von Studierenden, bei denen die Gefahr des Studienabbruchs besteht, ist für die Hochschulen von großer Bedeutung. Sie hilft nicht nur den Studierenden, sondern auch der Bildungsverwaltung und den Institutionen, wenn es um die Verbesserung der akademischen Ausbildung und die effiziente Nutzung der verfügbaren Ressourcen für ein wirksames Eingreifen geht (Martini & Botta, 2020).

Da konventionellen Mitteln der Früherkennung – insbesondere günstigen Betreuungsrelationen – angesichts hoher Studierendenzahlen aus finanziellen Gründen enge Grenzen gesetzt sind, richten sich die Hoffnungen zunehmend auf automatisierte Verfahren des Data Mining und maschinellen Lernens. In Anbetracht eines geschätzten Datenzuwachses von 35 Prozent pro Jahr im Bildungssektor (Liebowitz, 2017) erscheint ein produktiver Umgang mit diesen Datenmengen naheliegend (Daniel, 2015).

## Zielsetzung

Auf das Problem des Studienabbruchs reagieren die sogenannten Academic Performance Prediction (APP) Systeme auf der Basis von KI-Methoden (Alyahyan & Düstegör, 2020). Solche KI-Systeme können zu einer Verbesserung der individuellen Studienleistung führen, indem auf Grundlage von Informationen über das Lernen und die Lernumgebung eine Vorhersage über die zukünftige Performance getroffen und entsprechende Maßnahmen ergriffen werden können. Auf diese Weise können Ungleichheiten im Lernfortschritt und -ergebnis entgegengewirkt und gerade leistungsschwächeren Studierenden eine Hilfestellung gegeben werden (Mishra et al., 2014).

Durch die Verwendung von APP Systemen mit hoher Vorhersagequalität kann außerdem eine zukunftsfähigere Zulassungsentscheidung für und eine bessere pädagogische und psychologische Betreuung von Studierenden gewährleistet werden (Chen & Do, 2014). Die Arbeit an der Verbesserung solcher Systeme konzentriert sich einerseits auf die Suche nach geeigneten Input-Daten (Adejo & Connolly, 2017) und andererseits auf die Wahl der passenden KI-Methoden (Sweeney et al. 2016). Gleichzeitig stehen einem Einsatz von APP allerdings ethische und datenschutzrechtliche Bedenken entgegen. Beispielsweise gilt als fraglich, wer von einem solchen System tatsächlich profitiert: Ist der Einsatz für alle Beteiligten vorteilhaft oder werden bestehende Ungleichheiten verstärkt (Roberts et al., 2017)?

Im Folgenden wird davon ausgegangen, dass technische Optimierung und sozial-ethisch verantwortliche Implementierung solcher Systeme am besten erreicht werden kann, wenn

Informatik und Sozialwissenschaften gemeinsam an deren Entwicklung arbeiten. Vor diesem Hintergrund verfolgt das interdisziplinär zusammengesetzte Team mit dem Projekt folgende Ziele:

- Die Entwicklung eines diskriminierungsfreien, transparenten und verantwortlichen APP Systems für die Bachelor-Studiengänge der

Informatik und der Sozialwissenschaften, das die Auswahl geeigneter Gegenmaßnahmen unterstützt und auf eigenen Vorarbeiten sowie vorhandener Technologie aufbaut.

- Die Erschließung, die Beschaffung und das Management geeigneter Input-Daten, in Abstimmung mit den zuständigen Studiendekanaten, der Datenschutzbeauftragten der Hochschule, dem Studierenden Service Center, dem International Office und im informierten Konsens mit den betroffenen Studierenden.
- Die permanente Beobachtung und Erfassung der Wahrnehmungen und Einschätzungen der Studierenden über den gesamten Entwicklungsprozess, sowie Nutzung dieser Einsichten für den iterativen Prozess der Ausgestaltung des sozio-technischen Systems.
- Die Entwicklung eines Best Practice-Modells für die Überführung solcher Systeme in den Regelbetrieb von Hochschulen.

## Forschungsstand

### **Academic Performance Prediction**

Die Gründe für Studienerfolg bzw. –abbruch sind vielfältig und lassen sich grob in Persönlichkeitsmerkmale und Strukturmerkmale unterteilen. Die zentralen Einflussfaktoren auf individueller Ebene sind dabei die Einstellung, die Fähigkeit, das Studium selbstständig zu organisieren, die Studienmotivation (z.B. Interesse, Zielorientierung), das Vorwissen, die soziale Herkunft sowie familiäre Unterstützung (z.B. Heublein et al., 2017; Lattner & Haddou, 2013; Lörz, 2019). Ein weiterer Schlüsselfaktor ist, ob die Studierenden ihr Studium selbst finanzieren müssen (Lattner & Haddou, 2013).

KI-basierte APP Systeme sollen Abhilfe schaffen, indem sie rechtzeitig Beratungsbedarfe erkennen und individuell zuschneiden. Die existierenden empirischen Befunde zeigen gemischte Evidenzen hinsichtlich der Daten über die Studierenden, die dazu beitragen, den Studienerfolg vorherzusagen. Darüber hinaus untersuchen einige Studien den Einfluss der Nutzung digitaler E-Learning-Dienste (z.B. webbasiertes Training), mit denen Studierende inter-

aktiv lernen und ihr Nutzungsverhalten auswerten können. Hier sind die Ergebnisse wesentlich eindeutiger: So schlussfolgern Saa et al. (2019), dass die Nutzung solcher Angebote einen positiven Einfluss auf die gesamte Leistung der Studierenden hat und die Wahrscheinlichkeit des Erreichens besserer Noten steigert.

Ergänzend zu APP betrachten einige Studien zudem die Dropout Prediction, wobei sich diese typischerweise auf den gesamten Studienverlauf innerhalb eines Studienganges bezieht. Dropout Prediction wird in der Regel dazu eingesetzt, potentielle Studienabbrecher(innen) frühzeitig zu erkennen und kann somit als eine spezielle Form von APP angesehen werden. Auch in diesen Modellen werden verschiedene Machine Learning Verfahren, wie Support Vector Machines, Entscheidungsbäume, Random Forests und neuronale Netze verwendet (Alban & Mauricio, 2019). Auch für Dropout Prediction gibt es verschiedene Studien, die versuchen, die aussagekräftigsten Merkmale zu bestimmen. So zeigen Behrens et al. (2019), dass sich Informationen über die Performanz und Demographie der Studierenden dazu eignen, einzelne Abbrecher(innen) zu identifizieren. Ferner benennen Dekker et al. (2009) die Form der voruniversitären Bildung, die Anzahl der belegten Kurse oder die Durchschnittsnote in bestimmten Kursen als relevante Merkmale.

Zusammenfassend zeigt sich, dass sich die bisherige Forschung in erster Linie damit beschäftigt, mittels verschiedener Machine Learning Verfahren die Vorhersagegenauigkeit der Modelle zu verbessern. Ethische Aspekte, wie eine fehlerhafte und diskriminierende Vorhersage, intransparente und unfaire Prozesse oder die Verwendung geschützter Variablen (wie Ethnizität, Geschlecht) werden bislang kaum berücksichtigt. Auch die Wahrnehmungen der betroffenen Studierenden spielen in der bisherigen Forschung keine Rolle. Diese Forschungslücke wird durch das Projekt geschlossen.

### **Ethische Bedenken gegenüber Academic Performance Prediction**

Neben den Potentialen von APP Systemen, leistungsschwächere Studierende zu unterstützen und somit

systematische Ungleichheiten auszugleichen, existieren einige ethische Bedenken. So belegt die Forschung zu Fair Machine Learning, dass Entscheidungen und Empfehlungen auf Basis von KI dazu beitragen können, real existierende soziale Ungleichheiten zu reproduzieren und sogar zu verstärken (Barocas & Selbst, 2016). Aufgrund von Verzerrungen in den Trainingsdaten diskriminieren solche sozio-technischen Systeme dabei vor allem gesellschaftliche Minderheiten. Solche fehlerhaften Klassifikationen können einerseits bei Studierenden zu substanziellen Motivationsverlusten führen, was ebenfalls ein wichtiger Indikator für den Studienerfolg ist (Lattner & Haddou, 2013). Andererseits können sogenannte False Positive Klassifikationen dazu beitragen, dass Dozierende systematisch Vorurteile gegenüber Studierenden oder Gruppen von Studierenden entwickeln, beispielsweise, weil sie erhöhten Betreuungsaufwand verursachen.

Um die Diskriminierung durch KI-Systeme zu minimieren (Calders & Žliobaitė, 2013), entwickelt die Informatik mathematische Fairnessmodelle sowie fairnessensitive Algorithmen (für einen systematischen Überblick siehe Dunkelau & Leuschel, 2019; Verma & Rubin, 2018). Zudem zeigen Beispiele (z.B. Arizona State University, USA), dass zum Teil sensible Daten der Studierenden erhoben werden, wie Einträge bei der Campus-Polizei oder Daten über ausgeliehene Bücher (Martini & Botta, 2020).

Das Bewusstsein über eine solche Dauerbeobachtung kann wiederum negative psychologische Auswirkungen auf die Studierenden haben (Martini & Botta, 2020). Neben solch manifesten systematischen Diskriminierungen einzelner Merkmalsträger(innen) existieren zudem ethische Bedenken in Bezug auf individuelle Wahrnehmungen der betroffenen Studierenden. Unabhängig davon, ob APP Systeme de facto diskriminieren, können Betroffene sie als ungerecht wahrnehmen. Die empirische Forschung zeigt, dass formale Fairnessdefinitionen und individuelle Wahrnehmungen von algorithmischer Fairness mitunter erheblich voneinander abweichen (Saha et al., 2019; Saxena et al., 2019; Srivastava et al., 2019). Darüber hinaus deuten die Ergebnisse einiger Studien darauf hin,

dass die Wahrnehmung davon, ob Menschen oder Algorithmen fairere Entscheidungen treffen, entscheidend vom Anwendungsfall abhängt (Araujo et al., 2020; Lee, 2018).

## Eigene Vorarbeiten

### *Academic Performance Prediction*

Das Konsortium hat in den letzten Jahren verschiedene Verfahren zur Academic Performance Prediction (Askinadze & Conrad, 2018b; Askinadze et al., 2019) und zur Dropout Prediction (Askinadze & Conrad, 2019) entwickelt und evaluiert. Für die Dropout Prediction wurden studentische Leistungsdaten über absolvierte Prüfungen, die in der Zeit vom WS 2002/2003 bis WS 2010/2011 im Bachelor-Studiengang Informatik ihr Studium aufgenommen haben, verwendet. Verschiedene Machine Learning Methoden wurden hinsichtlich ihrer Prognosegüte erprobt und aus den Modellen (z.B. den entstandenen Entscheidungsbäumen) studiengangsspezifische Frühindikatoren, d.h. bestimmte Prüfungsleistungen, die häufig einen Studienabbruch nach sich ziehen, identifiziert (Askinadze & Conrad, 2019). Zur Academic Performance Prediction wurden ebenfalls verschiedene Machine Learning Verfahren angewendet und angepasst (Askinadze et al., 2019). Hier wurden Nutzungsdaten aus Online-Kursen eines kommerziellen Anbieters für akademische Weiterbildungskurse verwendet. Aus der Nutzung (z.B. Zeitpunkt der Bearbeitung der Kursmaterialien) konnte früh das spätere Ergebnis der zugehörigen Prüfung vorhergesagt werden. Kursteilnehmer(innen) konnten so rechtzeitig zusätzliche Lernhilfen angeboten werden, um ein Scheitern (Abbruch oder Nichtbestehen der Prüfung) zu vermeiden. Hierzu wurde auch ein Dashboard entworfen, in dem die erprobten Verfahren integriert werden können und das den Lehrenden einen Überblick über die Lernleistungen der einzelnen Teilnehmenden bietet (Askinadze & Conrad, 2018a).

Das Konsortium hat zudem viel Erfahrung mit regelbasierter Datenvvalidierung (Hansen et al., 2016; Leuschel et al., 2011) bis hin zum zertifizierten industriellen Einsatz. Die unterliegende symbolische

KI-Technik wurde auch im Hochschulbereich erfolgreich, zur Prüfung und Verbesserung der Studierbarkeit von Studiengangskombinationen an der HHU Düsseldorf, (Schneider et al., 2018). Andere Arbeiten (Dunkelau et al., 2020) fokussieren sich auf die Extraktion menschenverständlichen Wissens aus Klassifikationen von Machine Learning Verfahren. Alle genannten Arbeiten zielen auf eine technische Optimierung ab, lassen aber die Wirkung auf die Betroffenen, d.h. wie die Durchführung und ggfs. Kommunikation der Ergebnisse wahrgenommen werden, außer Acht. Diesen Aspekt decken jedoch weitere Vorarbeiten der sozialwissenschaftlichen Kortsortialpartner ab.

### **Sozial verträglicher Einsatz von KI im Hochschulbereich**

Die Forschenden können Expertise im Bereich eines sozial verträglichen Einsatzes von KI in der Hochschulbildung durch einschlägige Vorarbeiten nachweisen. So zeigt eine Bestandsaufnahme zur Entwicklung und Implementierung von KI an deutschen Universitäten, dass diese eher durch einzelne Projekte und weniger durch eine systematische Strategie-Ebene der Hochschulleitung vorangetrieben wird (Keller et al., 2019). Zudem spielen die Meinungen der betroffenen Studierenden bei der Umsetzung solcher sozio-technischer Systeme kaum eine Rolle. Zum anderen sehen die Expert(innen) neben verschiedenen Potentialen durch den Einsatz KI-basierter Systeme an Hochschulen auch zahlreiche Risiken, insbesondere ethischer und datenschutzrechtlicher Natur (Keller et al., 2019). Schließlich ist eine Laborstudie mit Studierenden der HHU Düsseldorf durchgeführt worden, um die Reaktionen der Studierenden auf eine mögliche Implementierung von KI-basierten Systemen in der Hochschulbildung zu erfassen (Kieslich et al., 2019). Die Ergebnisse lassen darauf schließen, dass es keine einheitliche Gesamtschätzung seitens der Betroffenen gibt. Stattdessen unterscheiden sich die Einstellungen in Abhängigkeit von der Zielsetzung von KI und ihrer Funktionsweise. In einem anderen Artikel (Marcinkowski et al., 2020) wurde gezeigt, dass die wahrgenommene Ungerechtigkeit der Algorithmischen Entscheidungsfindung (ADM) im Hochschulzulassungsverfahren Konsequenzen für die Loyalität ge-

genüber der Hochschule, das Protestverhalten und die Reputation der Organisation hat.

### **Soziale Ungleichheit im Bildungsbereich**

Die Forschenden bringen nachgewiesene Kompetenzen in der Ungleichheitsforschung mit. Hierbei untersuchten sie sowohl Einflussfaktoren auf soziale Ungleichheit, als auch den Einfluss von Ungleichheit auf verschiedene Dimensionen von Sozialität. Im Schulkontext wurde analysiert, welche Strukturmerkmale (u.a. Bildung im Elternhaus, Migrationshintergrund, Geschlecht, physische Attraktivität) und welche Prozess- bzw. Persönlichkeitsmerkmale (u.a. Intelligenzquotient, akademisches Selbstkonzept) einen Effekt auf die Schulnoten haben (Dunkake et al., 2012). Im Rahmen weiterer Publikationen wurde der Einfluss der äußeren Erscheinung auf politische Wahlen (Gaßner et al., 2019; Klein et al., 2019; Rosar, 2009; Rosar & Klein, 2015) ebenso untersucht wie auf die Performanzbeurteilung von Dozierenden an Hochschulen (Rosar & Klein, 2009, 2010). Des Weiteren wurde der Effekt des Humankapitalbestandes auf die Entlohnung am Arbeitsmarkt im Zeitverlauf erforscht (Krause & Apolinarski, 2012). Darüber hinaus liegen Publikationen zur Wirkung des Strukturmerkmals Attraktivität (als Ergebnis sozialer Ungleichheit) auf die soziale Ungleichheit vor (Krause, Rosar et al., 2020), ebenso wie Einflüsse der vertikalen und horizontalen Ungleichheit auf die Bearbeitung des Körpers (Krause, 2018).

### **Fragestellung**

Die übergreifende Frage des Projektes lautet: „Wie können die Anforderungen an die technische Leistungsfähigkeit (Genauigkeit und Fruchtbarkeit der Vorhersagen) und die sozial-ethische Verträglichkeit (Diskriminierungsfreiheit, Fairness, Transparenz, Accountability) eines Academic Performance Prediction Systems für die Hochschullehre in Übereinstimmung gebracht werden?“ Hieraus leiten sich insgesamt sechs konkrete Forschungsfragen ab:

- Welche Input-Daten sind verfügbar bzw. müssen erhoben werden, die eine gültige Vorhersage erlauben, ohne datenschutzrechtliche Bestimmungen und/oder die Privatsphäre der Betroffenen zu verletzen?

- Welche Merkmale müssen geschützt werden, um Diskriminierung zu vermeiden?
- Welche Methode eignet sich, um vorhandene Input-Daten systematisch zu modifizieren?
- Wie muss ein faires *APP* System technisch gestaltet und institutionell implementiert werden?
- Mit welchen Instrumenten kann die Transparenz und Verständlichkeit eines *APP* Systems für die Endnutzer(innen) erhöht werden?
- Wie können die Wahrnehmungen und Einschätzungen der Betroffenen erfasst und systematisch in das Design des sozio-technischen Systems eingespeist werden?

### Forschungsansatz & Use Case

Das Projekt basiert auf der Annahme, dass KI-basierte *APP* Systeme einen wichtigen Beitrag dazu leisten können, die Performanz der Studierenden vorherzusagen und somit die Quote der Studienabbrecher(innen) zu reduzieren. Dies geschieht, indem die Studierenden frühzeitig und individuell bei der Studienplanung beraten und passende Lernunterstützungen sowie psychologische Betreuungsangebote bereitgestellt werden. Diese Ziele können jedoch nur erreicht werden, wenn die ethischen Anforderungen an sozio-technische Systeme bereits während des technischen Entwicklungs- und institutionellen Umsetzungsprozesses miteinbezogen werden. Im Projekt werden die ethischen Systemanforderungen in zwei Klassen von Attributen unterteilt. Zunächst werden manifeste Eigenschaften des sozio-technischen Systems untersucht, etwa die Qualität der verwendeten Input-Daten, die Vorkehrungen zum Datenschutz, die Ausgestaltung der konkreten Verfahrensregeln, die Güte der Vorhersagen etc. Sie definieren das, was als „faktische Fairness“ eines KI-Systems bezeichnet wird (Marcinkowski & Starke, 2019). Davon zu unterscheiden ist die subjektive Komponente des sozio-technischen Systems, die „wahrgenommene Fairness“. Sie speist sich aus den Perzeptionen und Einschätzungen der betroffenen Endnutzer(innen) (v.a. Studierende, Dozierende), die auf spezifischer Weise auf eine Technologie reagieren (Baleis et al., 2019). Aus ethischer Perspektive ist zu fordern, dass manifeste Eigenschaften und subjektive Eindrücke

in die Gesamtbeurteilung des *APP* Systems eingehen müssen. Denn einerseits müssen Nutzer(innen) auch vor solchen Risiken geschützt werden, die sie selber gar nicht wahrnehmen, und andererseits reicht es nicht aus, wenn Expert(innen) ein System für unbedenklich erklären, das bei den Betroffenen Angst und Ablehnung hervorruft. Das interdisziplinäre Forschungsprogramm fußt darauf, den technischen Entwicklungsprozess kontinuierlich durch eine sozialwissenschaftliche Erforschung der beiden Gesichter von Fairness“ (Marcinkowski & Starke, 2019) zu evaluieren und die Ergebnisse wieder in den Entwicklungsprozess eines *APP* Systems einfließen zu lassen.

Im vorliegenden Use Case wird ein KI-basiertes *APP* System für die beiden Bachelor-Studiengänge Informatik und Sozialwissenschaften an der HHU Düsseldorf entwickelt. Die konkreten ethischen Anforderungen und Zielsetzungen müssen dabei zunächst in Kooperation mit den relevanten Stakeholder(innen) innerhalb der Universität erarbeitet werden. Um die Vorhersage der Studienleistung zu optimieren und gleichzeitig den ethischen Anforderungen zu entsprechen, greift das Projekt sowohl auf bestehende Daten zurück und hat zudem eigene Daten erhoben. Die Daten bisheriger Studienleistungen (z.B. die Ergebnisse wöchentlicher Hausaufgaben) werden zudem auf freiwilliger Basis durch Befragungsdaten von Studierenden ergänzt, um die Vorhersagekraft des Systems zu erhöhen. Dabei werden persönliche Faktoren wie Studienmotivation und Studiumsorganisation, aber auch bestehendes Wissen über zentrale Inhalte des Studiums erhoben. Die Nutzung von personenbezogenen Daten erfolgt dabei ausschließlich im Einverständnis mit den Studierenden und unter strenger Berücksichtigung rechtlicher Grundlagen, allen voran des Landeshochschulrechts sowie des Datenschutzrechts (Martini & Botta, 2020). Für die Erfassung und Speicherung der Daten wird begleitend ein Datenschutzkonzept in Zusammenarbeit mit der Datenschutzbeauftragten und weiteren involvierten Akteuren der Universität aufgestellt und im Projekt weiterentwickelt.



- Daniel, B. (2015). Big Data and analytics in higher education: Opportunities and challenges. *British Journal of Educational Technology*, 46(5), 904–920.
- Dekker, G. W., Pechenizkiy, M. & Vleeshouwers, J. M. (2009). Predicting Students Drop Out: A Case Study. *Proceedings 2nd Int. Conf. on Educational Data Mining (EDM 2009)*, 41–50.
- Deutsches Studentenwerk. (2019). *Beratung im Profil. Die Sozialberatung und Psychologische Beratung der Studenten- und Studierendenwerke*. Link: <https://www.studentenwerke.de/de/content/beratungim-profil>
- Dunkake, I., Kiechle, T., Klein, M. & Rosar, U. (2012). Schöne Schüler, schöne Noten? Eine empirische Untersuchung zum Einfluss der physischen Attraktivität von Schülern auf die Notenvergabe durch das Lehrpersonal, *Zeitschrift für Soziologie*, 41(2), 142–161.
- Gaßner, A., Masch, L., Rosar, U. & Schöttle, S. (2019). Schöner wählen: Der Einfluss der physischen Attraktivität des politischen Personals bei der Bundestagswahl 2017. In: K. Korte & J. Schoofs (Hrsg.), *Die Bundestagswahl 2017* (S. 63–82) Springer.
- Dunkelau, J. & Leuschel, M. (2019). Fairness-Aware Machine Learning- An Extensive Overview. *Working Paper*. (Fairness in Artificial Intelligence). Düsseldorf.
- Dunkelau, J., Schmidt, J. & Leuschel, M. (2020). Analysing ProB's Constraint Solving Backends. *Proceedings ABZ'2020*.
- Hansen, D., Schneider, D. & Leuschel, M. (2016). Using B and ProB for Data Validation Projects. In *Proceedings ABZ 2016* (S. 167–182). Springer.
- Heublein, U., Ebert, J., Hutzsch, C., Isleib, S., König, R., Richter, J. & Woisch, A. (2017). *Zwischen Studiererwartungen und Studienwirklichkeit. Ursachen des Studienabbruchs, beruflicher Verbleib der Studienabbrecherinnen und Studienabbrecher und Entwicklung der Studienabbruchquote an deutschen Hochschulen*. DZHW.
- Heublein, U. & Schmelzer, R. (2018). *Die Entwicklung der Studienabbruchquoten an den deutschen Hochschulen. Berechnungen auf Basis des Absolventenjahrgangs 2016*.
- Keller, B., Baleis, J., Starke, C. & Marcinkowski, F. (2019). Machine Learning and Artificial Intelligence in Higher Education: A State-of-the-Art Report on the German University Landscape (Fairness in Artificial Intelligence). Düsseldorf.
- Kieslich, K., Lünich, M., Marcinkowski, F. & Starke, C. (2019). Hochschule der Zukunft- Einstellung von Studierenden gegenüber Künstlicher Intelligenz an der Hochschule. *DIID-Précis* (Oktober). Link: <https://doi.org/10.36200/0013>
- Klein, M., Springer, F., Masch, L., Ohr, D. & Rosar, U. (2019). Die politische Urteilsbildung der Wählerschaft im Vorfeld der Bundestagswahl 2017. Eine empirische Analyse in der Tradition von „The People's Choice“. *Zeitschrift für Parlamentsfragen*, 50(1), 22–41.
- Krause, J. (2018). *Schönheitshandeln*. Wiesbaden: Springer.
- Krause, J. & Apolinarski, B. (2012). Lohnt sich Bildung noch? In: J. Hagenah & H. Meulemann (Hrsg.), *Mediatisierung der Gesellschaft?* (S. 257–276). Lit.
- Krause, J., Rosar, U., & Binckli, J. (Hrsg.). (2020). *Soziale Wirkung physischer Attraktivität*. Springer.
- Lattner, K. & Haddou, N. (2013). Abschlussbericht: *Langzeitstudie „Bedingungen von Studienerfolg“*. Osnabrück. Link: <https://opus.hs-osnabrueck.de/frontdoor/index/index/docId/105>
- Lee, M. K. (2018). Understanding perception of algorithmic decisions: Fairness, trust, and emotion in response to algorithmic management. *Big Data & Society*, 5(1), 1-16.
- Leuschel, M., Falampin, J., Fritz, F. & Plagge, D. (2011). Automated property verification for large scale B models with ProB. *Formal Aspects of Computing*, 23(6), 683–709.
- Liebowitz, J. (2017). Thoughts on Recent Trends and Future Research Perspectives in Big Data and Analytics in Higher Education. In: B. K. Daniel (Hrsg.), *Big data and learning analytics in higher education: Current theory and practice* (S. 7–17). Springer.
- Marcinkowski, F., Kieslich, K., Starke, C. & Lünich, M. (2020). Implications of AI (Un-)Fairness in Higher Education. Admissions: The Effects of Perceived AI (Un-)Fairness on Exit, Voice and Organizational Reputation. In *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency*. Association for Computing Machinery.
- Martini, M. & Botta, J. (2020). Studiererfolg auf Kosten informationeller Selbstbestimmung? Rechtliche Grenzen algorithmenbasierter Studienberatungsprogramme. In: Bertelsmann Stiftung (Hrsg.), *Automatisch erlaubt? Fünf Anwendungsfälle algorithmischer Systeme auf dem juristischen Prüfstand* (S. 22–31). Bertelsmann.
- Mishra, T., Kumar, D. & Gupta, S. (2014). Mining students' data for prediction performance. *International Conference on Advanced Computing and Communication Technologies*, ACCT, (Februar), 255–262.
- Roberts, L. D., Chang, V. & Gibson, D. (2017). Ethical Considerations in Adopting a University- and System-Wide Approach to Data and Learning Analytics. In: B. K. Daniel (Hrsg.), *Big data and learning analytics in higher education: Current theory and practice* (S. 89-108). Springer.
- Rosar, U. (2009). Fabulous Front-Runners. Eine empirische Untersuchung zur Bedeutung der physischen Attraktivität von Spitzenkandidaten für den Wahlerfolg ihrer Parteien. *Politische Vierteljahresschrift*, 50(4), 754–773.
- Rosar, U. & Klein, M. (2009). Mein(schöner)Prof.de, *Kölner Zeitschrift für Soziologie und Sozialpsychologie*, 61(4), 621–645.
- Rosar, U. & Klein, M. (2010). Mein(nach-wie-vorschöner) Prof.de. *Kölner Zeitschrift für Soziologie und Sozialpsychologie*, 62(2), 327–342.
- Rosar, U. & Klein, M. (2015). Politische Wahlen als Schönheitskonkurrenz: Ursachen- Mechanismen- Befunde. *Politische Vierteljahresschrift*, 50(2), 217–240.

Saa, A. A., Al-Emran, M. & Shaalan, K. (2019). Factors Affecting Students' Performance in Higher Education: A Systematic Review of Predictive Data Mining Techniques. *Technology, Knowledge and Learning*, 24(4), 567–598.

Schneider, D., Leuschel, M. & Witt, T. (2018). Modelbased problem solving for university timetable validation and improvement. *Formal Aspects of Computing*, 30(5), 545–569.

Sweeney, M., Rangwala, H., Lester, J. & Johri, A. (2016). *Next-Term Student Performance Prediction: A Recommender Systems Approach*. Link: <https://arxiv.org/abs/1604.01840>

Verma, S. & Rubin, J. (2018). Fairness Definitions Explained. In *ACM/IEEE International Workshop on Software Fairness*. Gothenburg: Association for Computing Machinery.