



## Teil I: Kurzbericht

### FragSte 2.0

Förderkennzeichen: 16PX21002

#### 1 Ursprüngliche Aufgabenstellung und Stand der Forschung

In FragSte 2.0 werden Fragen adressiert, die sich aus den Arbeiten der ersten Förderphase ergeben haben. Studienabbrüche können anhand administrativer Studierendendaten sehr gut prognostiziert werden (Berens et al., 2019); allerdings erst in fortgeschrittenen Semestern, wenn ein großer Anteil der Abbrecher\*innen die Hochschulen bereits verlassen hat oder der Abbruchprozess schon weit fortgeschritten ist (Schneider et al., 2019; Stinebrickner & Stinebrickner, 2014; Ma & Cragg, 2013). Daher verspricht eine frühe Prognose und damit auch die Möglichkeit zur frühen Intervention, drohende Studienabbrüche effektiver zu verringern. Die konkrete Ansprache von abbruchgefährdeten Studierenden ist jedoch mit Herausforderungen verbunden und der konkrete Mehrwert von Unterstützungsmaßnahmen konnte in internationalen Studien nicht immer bestimmt werden (Ibsen & Rosholm, 2024; Oreopoulos & Petro-nijevic, 2019; Oreopoulos et al., 2018). Jedoch wurde im Kontext deutscher Universitäten die Wirksamkeit unterschiedlicher Interventionen wiederholt nachgewiesen (Himmler et al., 2019; Sandner, 2015). Damit haben sich aus der ersten Projektphase weitere offene Forschungsfragen ergeben:

- a) Prognosen sollen bereits im ersten Semester verfügbar sein;
- b) Studienabbrecher\*innen sollen differenzierter und nicht nur binär klassifiziert werden;
- c) Bereits bestehende digitale Unterstützungsangebote, die in E-Learning Plattformen integriert werden, sollen auf ihre Wirksamkeit geprüft werden.

Im Projekt wurden Klausuranmeldungen und Moodle-Daten als zusätzliche Information zur Klassifizierung genutzt. Zur präziseren Identifikation potenzieller Studienabbrecher\*innen wurden Aktivitätsniveaus und alternative Abschlussdefinitionen mithilfe überwachter und unüberwachter Verfahren des maschinellen Lernens analysiert. Zudem wurden zwei experimentelle Interventionen (Self-Assessment Moveo & Informationsbereitstellung zur Studienberatung) und die Abschaffung der Studienbeiträge, also einer Veränderung der finanziellen Rahmenbedingungen, getestet und deren Einfluss auf Studierendenleistungen ausgewertet.

#### 2 Ablauf des Vorhabens

Innerhalb des **Jahres 2021** wurden der Zugriff auf die Aktivitätsdaten aus *Learning Management Systems* (LMS Daten) beantragt und der Austausch eingerichtet. Neben einer automati-

sierten Aufbereitung der durch die Hochschule zur Verfügung gestellten Daten wurden verschiedene Datenaufbereitungsverfahren und Machine Learning (ML) Algorithmen für die Implementierung in einer Produktivumgebung getestet. Außerdem wurden erste Berechnungen und Testläufe zur Identifizierung von Abbruchclustern durchgeführt.

Zur Vorbereitung der Intervention zum Self-Assessment, wurde das Self-Assesment Moveo von ORCA.nrw in einen Moodlekurs übertragen. Dieser Kurs ist exportierbar und kann auch anderen zur wiederholten Anwendung verfügbar gemacht werden. Außerdem wurden die §3HStatG Daten genutzt, um mit einer Analyse zu den Auswirkungen der Abschaffung der Studiengebühren auf das Studierverhalten zu beginnen.

Im Jahr **2022** wurden die begonnenen Arbeiten vertieft und erste Ergebnisse aufbereitet und diskutiert. Die Hochschuldaten konnten genutzt werden, um die Auswirkung von Studiengebühren auf das Studier- und Abbruchverhalten zu ermitteln. Das Self-Assesment wurde über Moodle in einer experimentellen Studie an Testpersonen in der Studierendenschaft verteilt.

Im Jahr **2023** wurde die Analyse der Abbruchcluster weiterhin bearbeitet. Die Ergebnisse der Clusteranalyse und die Ergebnisse zu den Auswirkungen der Studiengebühren wurden auf nationalen und internationalen Tagungen präsentiert. Die administrativen Studierendendaten wurden genutzt, um die Auswirkung der Covid-19 Pandemie auf die Leistung der Studierendenschaft zu schätzen.

Um die Teilnehmerquote an den Experimenten zum Self-Assesment zu erhöhen, wurden Studierende über eine randomisierte Zuweisung in der Universität vor Ort zur Nutzung der Anwendung eingeladen. Außerdem wurde mit der Auswertung der Langzeitergebnisse der Intervention zur Informationsbereitstellung über die Studienberatung basierend auf den Warnprognosen begonnen.

Im Jahr **2024** wurden die Ergebnisse der unterschiedlichen Studien konsolidiert, aufbereitet und erste Arbeitspapiere zur Veröffentlichung erstellt.

### **3 Wesentliche Ergebnisse**

Prognosegüte:

Die Berücksichtigung von Daten der Lernplattform und Klausuranmeldungen führen zu signifikanten Verbesserungen der Prognosegüte für Studienabbrüche im Vergleich zu Prognosen, die zum Zeitpunkt der Einschreibung durchgeführt werden. Diese Verbesserung lässt sich über verschiedene Prognoseziele hinweg beobachten. Tatsächlich zeigen Informationen zur Klausuranmeldung eine ähnliche Prognosegüte wie Klausurergebnisse. Über die Anwendung von Verfahren des nicht überwachten maschinellen Lernens lassen sich intuitive Studierend- und Abbruchcluster bilden, die sich unter anderem über Unterschiede in ihrem Aktivitätslevel unterscheiden lassen. Der zusätzliche Einbezug der Clusterzugehörigkeit konnte die Prognoseergebnisse jedoch nicht weiter verbessern.

Wirksamkeit von Interventionen:

Wie auch in anderen Studien, sind die Teilnahmequoten an den durchgeführten Experimenten sehr gering, schwanken jedoch stark über die Fachrichtungen hinweg. Auch unter dem Einsatz von kleinen monetären Anreizen nehmen nur wenige Studierende an den Self-Assesment Interventionen teil. Erst die Ansprache der Studierenden über verschiedene Lehrveranstaltungen vor Ort konnten die Teilnahmequote erhöhen. Die geringe Teilnahmequote kann

teilweise auf die den erheblichen Anteil inaktiver Studierender zurückgeführt werden. Insgesamt zeigen die Interventionen keine relevanten Anpassungen im Studierendenverhalten. Unsere Arbeit zu der Abschaffung der Studiengebühren, die auch eine viel und kontrovers diskutierte Intervention ist, zeigt, dass Studierende ohne Studiengebühren langsamer studieren und öfter inaktiv werden.

#### 4 Literatur

- Berens, J., Schneider, K., Görtz, S., Oster, S., and Burghoff, J. (2019). Early Detection of Students at Risk - Predicting Student Dropouts Using Administrative Student Data from German Universities and Machine Learning Methods. *Journal of Educational Data Mining*, 11(3), 1–41.
- Himmler, O., Jäckle, R., & Weinschenk, P. (2019). Soft commitments, reminders, and academic performance. *American Economic Journal: Applied Economics*, 11(2), 114-142.
- Ibsen, K., & Rosholm, M. (2024) What Works? Interventions Aimed at Reducing Student Dropout in Higher Education. IZA Discussion Paper No. 16853.
- Ma, Y., & Cragg, K. M. (2013). So close, yet so far away: Early vs. late dropouts. *Journal of College Student Retention: Research, Theory & Practice*, 14(4), 533-548.
- Oreopoulos, P., Patterson, R. W., Petronijevic, U., & Pope, N. G. (2018). Lack of Study Time Is the Problem, but What Is the Solution? Unsuccessful Attempts to Help Traditional and Online College Students. Working Paper 25036. National Bureau of Economic Research.
- Oreopoulos, P., & Petronijevic, U. (2019). The remarkable unresponsiveness of college students to nudging and what we can learn from it (No. w26059). National Bureau of Economic Research.
- Schneider, K., Berens, J. & Burghoff, S. (2019). Drohende Studienabbrüche durch Frühwarnsysteme erkennen: Welche Informationen sind relevant? *Zeitschrift für Erziehungswissenschaften*.
- Stinebrickner, R., & Stinebrickner, T. (2014). Academic performance and college dropout: Using longitudinal expectations data to estimate a learning model. *Journal of Labor Economics*, 32(3), 601-644.
- Sandner, M. (2015). The effects of high-quality student mentoring. *Economics letters*, 136, 227-232.



## Teil II: Eingehende Darstellung

### FragSte 2.0

Förderkennzeichen: 16PX21002

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung unter den Förderkennzeichen **16PX21002** gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei dem/der Autor/in bzw. den Autor/inn/en.

### Inhaltsverzeichnis

<b>1</b>	<b>Aufgabenstellung .....</b>	<b>2</b>
<b>2</b>	<b>Wissenschaftlicher und technischer Stand, an den angeknüpft wurde.....</b>	<b>3</b>
<b>3</b>	<b>Planung und Ablauf des Vorhabens .....</b>	<b>4</b>
<b>4</b>	<b>Inhaltliche Ergebnisse .....</b>	<b>5</b>
<b>5</b>	<b>Wichtigste Positionen des zahlenmäßigen Nachweises.....</b>	<b>8</b>
<b>6</b>	<b>Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten .....</b>	<b>8</b>
<b>7</b>	<b>Voraussichtlicher Nutzen, Verwertbarkeit der Ergebnisse und zukünftige Planungen im Sinne des Verwertungsplans .....</b>	<b>8</b>
<b>8</b>	<b>Fortschritt auf dem Gebiet des Vorhabens während der Durchführung des Vorhabens bei anderen Stellen.....</b>	<b>9</b>
<b>9</b>	<b>Erfolgte oder geplante Veröffentlichungen der Projektergebnisse.....</b>	<b>10</b>
<b>10</b>	<b>Literaturverzeichnis .....</b>	<b>10</b>

## 1 Aufgabenstellung

Im BMBF-geförderten Projekt „Früherkennung abbruchgefährdeter Studierender und experimentelle Studien zur Wirksamkeit von Maßnahmen“, FragSte, wurde im Zeitraum 2017-2019 ein Frühwarnsystem zur Identifikation drohender Studienabbrüche im Bachelor-Studium entwickelt. Ziel war es, mögliche Abbrüche frühzeitig mit Hilfe von Prozessdaten und Methoden des maschinellen Lernens zu erkennen, die betreffenden Studierenden durch ein automatisiertes Feedback anzusprechen und somit auch die Auswirkungen eines Feedbacks bei Früherkennung auf Studienabbrüche zu testen. Damit verbindet FragSte zwei Forschungsstränge:

1. Wie können drohende Studienabbrüche durch weitgehend automatisierte Verfahren erkannt werden?
2. Wie kann mit diesem Wissen das Studierverhalten verändert werden?

Das im Projekt entwickelte gleichnamige Frühwarnsystem FragSte basiert ausschließlich auf administrativen Daten, die gem. § 3 HStatG erfasst werden. FragSte ist daher an allen deutschen Hochschulen einsetzbar. Durch eine selbstlernende Konzeption passt sich das Frühwarnsystem an die jeweilige Hochschule und deren Studiengänge an.

In FragSte 2.0 werden Fragen adressiert, die sich aus den Arbeiten der ersten Förderphase ergeben haben. Studienabbrüche können anhand administrativer Studierendendaten sehr gut prognostiziert werden (Berens et al., 2019); allerdings erst in fortgeschrittenen Semestern, wenn ein großer Anteil der Abbrecher\*innen die Hochschulen bereits verlassen hat oder der Abbruchprozess schon weit fortgeschritten ist. Daher verspricht eine frühe Intervention ein besonders hohes Potenzial drohende Studienabbrüche zu verringern. Die Ansprache von Studierenden ist jedoch mit Herausforderungen verbunden und der konkrete Mehrwert von Unterstützungsmaßnahmen konnte in internationalen Studien nicht immer bestimmt werden. Jedoch wurde im Kontext deutscher Universitäten die Wirksamkeit unterschiedlicher Interventionen wiederholt nachgewiesen. Damit haben sich aus der ersten Projektphase weitere offene Forschungsfragen ergeben:

- a) Prognosen sollen bereits im ersten Semester verfügbar sein;
- b) Studienabbrecher\*innen sollen differenzierter und nicht nur binär klassifiziert werden;
- c) Bereits bestehende digitale Unterstützungsangebote, die in E-Learning Plattformen integriert werden, sollen auf ihre Wirksamkeit geprüft werden.

Im Projekt wurden Klausuranmeldungen und Moodle-Daten zur Klassifizierung früher Prognosen genutzt. Zur präziseren Identifikation potenzieller Studienabbrecher\*innen wurden Aktivitätsniveaus und alternative Abschlussdefinitionen mithilfe überwachter und unüberwachter Verfahren des maschinellen Lernens analysiert. Zudem wurden zwei experimentelle Interventionen (Self-Assessment Moveo & Informationsbereitstellung zur Studienberatung) getestet und deren Einfluss auf Studierendenleistungen ausgewertet. Darüber hinaus konnte der Effekt einer hochschulpolitischen Maßnahme getestet werden, die die finanziellen Anreize für Studierende verändert: die Abschaffung der Studiengebühren.

## 2 Wissenschaftlicher und technischer Stand, an den angeknüpft wurde

**Zu a)** Eines der wesentlichen Ziele des *educational data mining* ist die Prognose von Lernerfolgen (Baker, 2010; Baker & Yacef, 2009). Es können die Ergebnisse unterstützender Maßnahmen wie Tutorien, das Bestehen einer Klausur oder eines Studiums prognostiziert werden (Asif et al., 2017). Beispiele für internationale Studien, in denen der Studienerfolg prognostiziert wurde, sind die Arbeiten Zhang et al. (2010), Bayer et al. (2012), Er (2012), Sara et al. (2015) und Berens et al. (2019), Aggarwal et al. (2022), Matz et al. (2023), oder Zanellati et al. (2024). Grundsätzlich kommen alle der genannten Studien zu dem Ergebnis, dass die Prognosen in höheren Semestern genauer werden, da zu einem späteren Zeitpunkt mehr Informationen über die Studienleistungen vorliegen und die Kohorten zunehmend aus gut zu prognostizierenden künftigen Absolventen bestehen.

Ein später Prognosezeitpunkt senkt jedoch den Nutzen eines Frühwarnsystems, da das erste Studienjahr einen besonderen Einfluss auf den akademischen Werdegang hat (Brahm et al., 2016) und viele der abbruchgefährdeten Studierenden die Hochschule bereits verlassen haben (Schneider et al., 2019; Stinebrickner & Stinebrickner, 2014; Ma & Cragg, 2013). Um eine möglichst genaue Prognose früher in das erste Semester zu verschieben können Aktivitätsdaten aus *Learning Management Systems* (LMS) wie Moodle verwendet werden. Mehrere Studien haben ergeben, dass LMS Daten, einschließlich der Aufrufe von Ressourcen, der Einreichung von Aufgaben und der Beteiligung in Foren, wirksame Prädiktoren für akademische Leistung sein können (Koprinska et al., 2015; Tamada et al., 2022). Aus Moodle extrahierte Merkmale wie Dauer der Aktivität, Aufgabenerledigung und Materialansichten zeigen eine klare Korrelation mit akademischen Leistungen (Zhang et al. 2020).

**Zu b)** Für die Prognose und Beurteilung von Studienabbrüchen an deutschen Hochschulen ist der Anteil von Scheinstudierenden (Ticket-, Kindergeld-, Aufenthalts- und Statusstudenten) relevant. Ist der Anteil der Studierenden, die nie einen Abschluss anstrebten, unbekannt, kann weder das Ausmaß der Studienabbrüche noch die Effektivität von Maßnahmen beurteilt werden. Allerdings ist die Identifikation von Scheinstudierenden nicht trivial und in der Literatur noch wenig präsent, da die finanziellen Anreize in Deutschland im internationalen Vergleich sehr hoch sind. Scheinstudierende können entweder durch die Erhebungsform (Befragung, Beobachtung) im Wesentlichen ausgeschlossen werden oder – bei Verwendung administrativer Studierendendaten – zunächst nicht von Studierenden mit Abschlussinteresse unterschieden werden. Düchs & Matzdorf (2014) betrachten den Studiengang Physik an mehreren Universitäten und treffen die Annahme, dass alle gänzlich inaktiven Studierenden Scheinstudierende sind; das trifft auf etwa 30% aller Studierenden des Studiengangs zu. Auch Wittenberg et al. (1999) ermitteln durch Befragung einen Anteil von etwa 30% Scheinstudierenden. Analysen, in denen Scheinstudierende mittels administrativer Daten identifiziert werden konnten, sind uns nicht bekannt.

Im internationalen Kontext gibt es Studien die LMS Daten nutzen, um Inaktivität in Onlinekursen (Hussain et al., 2018 a) oder Lernaktivität in virtuellen Lernumgebungen wie einem Online-Campus zu klassifizieren (Hussain et al., 2018 b). Neben der Klassifikation von Studierenden gibt es auch einige explorative Studien die durch den Einsatz von Clusteralgorithmen die Studierendenschaft datengetrieben gruppieren (Ammon et al., 2008; Valles-Coral et al., 2022). Dadurch sollen neue Untergruppen von Studierenden identifiziert und die Zusammensetzung der Studierenden besser verstanden werden.

**Zu c)** Die Abbruchneigung von Studierenden sollte früh erkannt werden, um im Prozess des Studienabbruchs möglichst kurzfristig Unterstützung anbieten zu können (Heublein et al., 2017; Wilson et al., 2016; Arulampalam et al., 2005). Interventionen erweisen sich zudem in der Regel als wirksamer, wenn sie zielgerichtet abbruchgefährdeten Studierenden angeboten werden (Zhang et al., 2014). Internationale Studien zeigen jedoch, dass eine erfolgreiche Ansprache von Studierenden nicht immer gelingt (Ibsen & Rosholm, 2024; Oreopoulos & Petro-nijevic, 2019; Oreopoulos et al., 2018). Dennoch konnte im Kontext deutscher Universitäten die Wirksamkeit verschiedener Interventionen mehrfach belegt werden (Brade et al., 2024; Brade et al., 2022; Himmler et al., 2019; Sandner, 2015).

### **3 Planung und Ablauf des Vorhabens**

Innerhalb des Jahres 2021 wurden der regelmäßige Zugriff auf die Verwaltungsdaten der Studierenden und LMS Daten beantragt und der Austausch eingerichtet. Die Daten können universitätsintern über ein verschlüsseltes Austauschlaufwerk von der zentralen IT-Stelle genutzt werden. Die Aufbereitung der Daten soll über ein einheitliches Python-Skript laufen. Die Programmierung lief über die ersten beiden Jahre und wurde über die Zeit erweitert und verbessert. Für die Verarbeitung und Speicherung der Daten wurde eine PostgreSQL-Datenbank eingerichtet. Durch den automatisierten Ansatz der Datenaufbereitung können manuelle Spezifikationen minimiert und die für die Prognosen und Analysen relevanten Modelle in ein einheitliches Skript überführt werden. Neben der Implementierung und Testung der Prognosemodelle wurden unterschiedliche Datenaufbereitungsprozesse und Modellspezifikationen für den Einsatz in einer Produktivumgebung getestet.

Im Jahr 2022 wurden die begonnen Arbeiten vertieft, erste Ergebnisse aufbereitet und diskutiert. Außerdem wurden erste Berechnungen und Testläufe zur Identifizierung von Abbruchclustern durchgeführt. Dadurch sollte, neben dem Einsatz von Verfahren des überwachten maschinellen Lernens, die Machbarkeit einer automatisierten Segmentierung der Studierendenschaft untersucht werden. Die Bezeichnung der identifizierten Cluster ergeben sich dabei aus der Zusammensetzung und dem Studierverhalten der Studierenden und werden nicht von der Institution festgelegt. Das Verfahren sollte unter der die Notwendigkeit manueller Spezifikationen minimieren. Hierfür wurden unterschiedliche Algorithmen und Datenaufbereitungsprozesse miteinander kombiniert und die resultierenden Cluster verglichen. Außerdem wurde die Cluster Zugehörigkeit als zusätzliche Information für die Prognoseverfahren getestet.

Um die Wirksamkeit von Interventionen zu überprüfen und zu verstehen wurde das Self-Assessment Moveo von ORCA.nrw in einen Moodlekurs übertragen. Bei der Auswahl des Tools lag der Fokus auf der einer kosteneffizienten Skalierbarkeit, damit möglichst viele Studierende und Universitäten das Tool prinzipiell kostenfrei nutzen können. Außerdem kann die Anwendung bereits zu Beginn des Studiums an die Studierendenschaft verteilt werden, womit ein großer Teil der potenziell abbruchgefährdeten Studierenden erreicht wird. Moveo zielt darauf ab, die aktuelle Studienmotivation von Studierenden und deren Einfluss auf ihr Lernverhalten zu bewerten. Dabei fokussiert sich das Tool nicht auf feste Persönlichkeitsmerkmale, sondern betont anpassbare Faktoren wie die Motivation, die eine entscheidende Rolle für den Studien-erfolg spielen. Es konnten sowohl alle Fragen als auch das dynamische Feedback für die Studierenden eingefügt werden. Je nachdem welche Antworten gegeben werden, wird in der

Form eines Ampelsystems über mehrere Dimensionen das Verhalten der Studierenden beschrieben. Neben dieser Einschätzung werden die Erläuterungs- und Hilfevideos von Moveo zu Themen wie Prokrastination und Prüfungsangst bereitgestellt. Der daraus resultierende Kurs kann exportiert werden und in den Moodle-Systemen anderer Universitäten für die Nutzung installiert werden. Für die erste Runde des Experiments wurden Studierende über ein randomisiertes Auswahlverfahren zur Nutzung des Tools eingeladen.

Im Jahr 2023 wurde die Analyse der Abbruchcluster ausgeweitet und gemeinsam mit der Arbeit zu den Auswirkungen der Studiengebühren auf mehreren Konferenzen und Workshops vorgestellt (beispielsweise auf der Tagung der Gesellschaft für empirische Bildungsforschung oder auf der Konferenz der Association Economics of Education). Außerdem wurden die Hochschuldaten für eine Schätzung der Auswirkung der COVID-19 Pandemie auf die Leistung der Studierendenschaft verwendet. Um die Teilnehmerquote an den Experimenten zum Self-Assessment zu erhöhen, wurden Studierende über eine randomisierte Zuweisung in der Universität vor Ort zur Nutzung der Anwendung eingeladen. Das Experiment wurde über eine Woche hinweg in mehreren Veranstaltungen mit den Studierenden durchgeführt und hat zu deutlich höheren Teilnehmerquoten geführt. Neben der Durchführung neuer Experimente wurde mit der Auswertung der Langzeitergebnisse der Intervention zur Informationsbereitstellung über die Studienberatung basierend auf den Warnprognosen begonnen. Dieses Experiment wurde im Rahmen des Vorläuferprojekts gestartet. Dabei wurden basierend auf den Prognosen des in dem Projekt entwickelten Frühwarnsystems Informationen zum Thema Studienabbruch und Studienberatung per E-Mail an die Studierenden verschickt. Einige Semester später können die Auswirkungen auf Studierverhalten und Studienabschluss untersucht werden.

Im Jahr 2024 wurden die Ergebnisse der unterschiedlichen Studien konsolidiert, aufbereitet und Arbeitspapiere zur Veröffentlichung erstellt. Da die Moodle Daten aus Gründen der Speicherkapazität und des Datenschutzes laufend von der Universität gelöscht wurden, musste der Datensatz über die Zeit aufgebaut werden. Die Aktivitätsdaten über Klausuranmeldungen und Moodle wurden mit der Hilfe mehrerer Prognoseverfahren auf ihre Prognosegüte untersucht. Dabei sollte insbesondere der Rahmen der zu prognostizierenden Zielvariablen erweitert werden (Studienerfolg bzw. -abbruch). Neben dem Studienabbruch wurde auch die Anzahl der zu registrierenden Klausuren, potenzielle Inaktivität und das erneute Einschreiben im Anschluss an das erste Semester prognostiziert.

#### **4 Inhaltliche Ergebnisse**

Im Rahmen des Projektes wurden drei Ziele verfolgt: **a)** Genaue Prognose möglichst früh im ersten Semester durchführen **b)** Exploration und Evaluation alternativer Verfahren, um Studierende neben den binären Klassifizierungen in Absolventen und Abbrecher als Abbruchgefährdet zu identifizieren **c)** Wirksame und skalierbare Unterstützungsangebote für (abbruchgefährdete) Studierende identifizieren.

**Zu a)** Um eine möglichst frühe Prognose zum Studienabbruch durchzuführen sollten sowohl Daten über das Registrierungsverhalten von Klausuren als auch Daten aus dem LMS Moodle untersucht werden. Die Berücksichtigung von Klausuranmeldungen verbessert die Qualität der Prognose im Vergleich zu der Prognose basierend auf Immatrikulationsdaten deutlich. Bei Immatrikulation konnten ungefähr 71% der Studierenden korrekt in zukünftige Absolventen und

Abbrecher unterteilt werden. Nachdem Informationen über Klausuranmeldungen berücksichtigt werden können, steigt die Genauigkeit auf ungefähr 77%. Die Genauigkeit steigt auf 81%, nachdem Informationen über Klausurergebnisse vorhanden sind. Damit steigt die Prognosegüte mehrere Monate bevor Klausurergebnisse vorliegen auf ein ähnliches hohes Niveau, das bei Verfügbarkeit der Klausurergebnisse erreicht wird. Zwar kann mit der Verfügbarkeit von Anmeldedaten die Prognose verbessert werden, aber diese Informationen liegen meistens erst zu einem fortgeschrittenen Zeitpunkt im Semester vor. Um die Lernaktivität und die Anzahl der Klausuranmeldungen (und damit den Studienfortschritt) durch eine Intervention bereits während des ersten Semesters zu erhöhen, müssten die Prognosen aber auf Informationen bereits zu Beginn des Semesters zugreifen können. Genau hierfür bieten sich die Aktivitätsdaten eines LMS an.

Durch die verzögerte Verfügbarkeit der LMS Daten für die Arbeit im Projekt konnten jedoch keine mit den ursprünglichen Prognosen vergleichbare Abbruchprognosen durchgeführt werden. Stattdessen wurde die Prognosegüte mit alternativen Zielvariablen getestet: Anzahl der zu registrierenden Klausuren, Inaktivität und der Studienverbleib nach dem ersten Semester. Allgemein lässt sich festhalten, dass Moodle Aktivitätsdaten die Prognosegüte der Modelle über alle Zielvariablen hinweg deutlich verbessern, jedoch leicht hinter der Prognosegüte von angemeldeten Klausuren zurückbleiben. Zum Zeitpunkt der Immatrikulation konnten ungefähr 80% der Studierenden korrekt in aktive und inaktive Studierende unterteilt werden. Nach der Berücksichtigung der Moodle Daten der ersten beiden Studienmonate konnte die Prognose auf 86% verbessert werden; also ein bis zwei Monate bevor Informationen zum Anmeldeverhalten vorliegen. Durch das Einbinden von Aktivitätsdaten lässt sich die Prognosegüte über das erste Semester hinweg verbessern, wodurch der Kompromiss zwischen frühen, aber umfassenderen und späteren, aber genaueren Vorhersagen abgemildert werden kann. Unsere Analyse zeigt auch, dass die Lernaktivität kurz vor den Prüfungen wichtiger ist als die Lernaktivität zu Beginn des Semesters. Zusammenfassend zeigen unsere Ergebnisse, dass Aktivitäts- und Lerndaten ein vielversprechender Schritt sind, um abbruchgefährdete Studierende zu identifizieren und mögliche Unterstützungsmaßnahmen einzuleiten.

**Zu b)** Die Identifikation abbruchgefährdeter Studierender über alternative Verfahren wurde bereits in dem Aufgabenteil zu a) angeschnitten. Die Prognose der Aktivität, gemessen an der Anzahl angemeldeter Klausuren, zeigt gute Prognoseergebnisse und ist mit der klassischen Studienerfolgsprognose vergleichbar. Die Prognose von Inaktivität scheint ebenfalls eine weniger stigmatisierende Alternative zu der Gruppierung in erfolgreiche und abbruchgefährdete Studierende zu sein. Auch wenn die Prognose der Wiedereinschreibung nach dem ersten Semester durch die Moodle Daten verbessert werden konnte, bleibt der Anteil der identifizierten Abbrecher mit 43% vergleichsweise gering (zum gleichen Zeitpunkt konnten 77% der inaktiven Studierenden korrekt identifiziert werden).

Neben der Klassifikation von inaktiven oder abbruchgefährdeten Studierenden mit der Hilfe von Verfahren des überwachten maschinellen Lernens wurden Cluster-Verfahren zur automatisierten Segmentierung der Studierendenschaft getestet. Der favorisierte Verarbeitungsprozess kombiniert eine nichtparametrische Methode zu Dimensionsreduzierung der Daten mit einem hierarchisch und dichte-basierten Cluster Algorithmus. Das Verfahren gruppiert die Studierenden und bildet, insbesondere mit Blick auf die akademischen Leistungen, intuitive und gut voneinander unterscheidbare Cluster von Studierenden. So lassen sich die von dem Ver-

fahren automatisch gebildeten „großen Abbruchcluster“ in ihrer Abschlussintention voneinander unterscheiden. Beispielsweise zeigen aktive aber nicht erfolgreiche Ingenieursstudierende ein Anmeldeverhalten, welches auf einen intendierten Studienfortschritt schließen lässt, aber sie bestehen wenige bis keine Klausuren. Daneben zeigt das Cluster von Scheinstudierenden aus demselben Fachbereich keinen Studienfortschritt, weil sehr wenige oder keine Klausuranmeldungen vorliegen. Damit bildet das erste Cluster von Studierenden ein vielversprechendes Interventionscluster, welches durch zusätzliche Unterstützungsmaßnahmen adressiert werden könnte, während Studierende aus dem zweiten Cluster womöglich kein Interesse an einem Unterstützungsangebot haben.

Bisher gruppiert das Verfahren die Studierendenschaft jedoch in viele und verhältnismäßig kleine Cluster. Für eine einfachere Bedienung und Analyse sollten Anpassungsschritte untersucht werden die zu einer geringeren Anzahl an Clustern führen. Zuletzt wurde die Clusterzugehörigkeit als zusätzliche Variablen in den bereits beschriebenen Prognoseverfahren eingesetzt. Diese Erweiterung hat jedoch zu keiner Verbesserung der Vorhersage geführt.

**Zu c)** Insgesamt beobachten wir geringe Teilnahmequoten bei den Interventionen. Selbst kleine monetäre Anreize haben die meisten Studierenden nicht zu einer Teilnahme an dem Self-Assessment Moveo bewegen können (zwischen 4% und 9% der Studierenden nehmen die Einladung zur Nutzung an). Die Teilnahmequote konnte erst über eine direkte Ansprache in verschiedenen Kursen erhöht werden (44% der Studierenden haben die Einladung zur Nutzung angenommen). Ein Teil des geringen Rücklaufs kann durch Studierende, die nie eine Klausur anmelden, erklärt werden. Bei der Auswertung der Intervention zeigen die Punktschätzer einen Anstieg in angemeldeten Klausuren and bestandenen Leistungspunkten. Durch die geringe Anzahl der Beobachtungen ergibt sich jedoch kein statistisch signifikanter Unterschied. Die Ergebnisse weisen auch auf eine Reduzierung der angemeldeten Klausuren und bestandene Leistungspunkte für ausländische Studierende und eine Erhöhung der Abbruchwahrscheinlichkeit für Studierende die älter als 25 Jahre sind hin.

Zusätzlich zeigen die Analysen, dass auch die auf dem Frühwarnsystem basierte Informationsintervention per E-Mail zu keiner bedeutsamen Veränderungen im Studierverhalten geführt hat. Die Effekte weisen jedoch eine starke Heterogenität zwischen den Studiengängen auf, insbesondere zwischen Studiengängen mit hohem und niedrigem Anteil an Inaktivität. Unsere Ergebnisse zeigen, dass aktive Studierende – definiert als jene mit mindestens einer Prüfungsanmeldung im ersten Semester – in Studiengängen mit typischerweise hohen Inaktivitätsanteilen (Informatik sowie Mathematik und Naturwissenschaften) auf eine Warnung am Ende des zweiten Semesters reagieren. Sie melden sich vermehrt zu Prüfungen an und erzielen mehr bestandene Leistungspunkte. Im Gegensatz dazu zeigen Studierende aus Studiengängen mit geringerem Inaktivitätsanteil (Wirtschaftswissenschaften und Ingenieurwissenschaften) keine signifikante Anpassung. Unsere Ergebnisse geben auch einen Hinweis darauf, dass Studierende aus den Studiengängen mit geringerem Inaktivitätsanteil eher zu einem Abbruch des Studiums tendieren. Das Phänomen inaktiver Studierender wurde im Rahmen einer Analyse zu der Abschaffung der Studiengebühren, einer Reform, die die finanziellen Rahmenbedingungen des Studiums veränderte, näher untersucht. Die Ergebnisse zeigen, dass nach der Abschaffung der Gebühren aktive Studierende 12% weniger Leistungspunkte bestehen und mehr Studierende inaktiv werden und sich für keine Klausuren registrieren.

## **5 Wichtigste Positionen des zahlenmäßigen Nachweises**

Die wissenschaftlichen Mitarbeiter waren für die automatisierte Datenaufbereitung, die Datenanalyse mit der Hilfe der Clusteralgorithmen und die Analyse der Moodle Daten verantwortlich. Außerdem mussten die experimentellen Interventionen konzipiert, durchgeführt und analysiert werden. Die sich aus den Arbeiten ergebenden wissenschaftlichen Erkenntnisse wurden in wissenschaftlichen Papieren verschriftlicht. Die Ergebnisse wurden sowohl auf nationalen als auch internationalen Tagungen präsentiert.

## **6 Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten**

Die im Rahmen des Projekts durchgeführten Analysen und Experimente haben stark von der automatisierten Datenaufbereitung profitiert. Neue Datenlieferungen können nun ohne weiteren Aufwand aufbereitet und für die wissenschaftlichen Mitarbeiter zur Verfügung gestellt werden. Die ersten Ergebnisse zur Prognosegüte der LMS Aktivitätsdaten sind vielversprechend. Für eine abschließende Analyse wird jedoch mehr Zeit benötigt. Der Datensatz muss über die kommenden Jahre weiter aufgebaut werden, da die Aktivitätsdaten regelmäßig gelöscht wurden. Das Projekt und auch die Aufarbeitung der Verwaltungsdaten wurde so konzipiert, dass die Analysen auf andere Hochschulen in Deutschland übertragbar sind.

Neben der Identifizierung von abbruchgefährdeten Studierenden können die Aktivitätsdaten dazu genutzt werden, um Aktivitätslevel oder Inaktivität zu prognostizieren. Beide Faktoren hängen stark mit dem Studienerfolg zusammen. Die Verwendung von Clusteralgorithmen für die Segmentierung der Studierendenschaft ist eher selten in der Literatur zu finden, was womöglich an dem explorativen Charakter der Methodik liegt. Erst durch umfangreiche Simulationen und Recherchearbeit konnte ein zielführender Ansatz gefunden werden. Für einen Einsatz in der Praxis sollten weitere Verarbeitungsschritte getestet werden, damit die relevanten Cluster klarer hervorgehoben werden.

Letztlich zeigen beide im Rahmen des Projekts durchgeführten Interventionen, dass sich die optimistischen Ergebnisse zur Effektivität von niedrigschwelligen Unterstützungsmaßnahmen aus einigen Studien nicht ohne weiteres auf verschiedene Ansätze und Hochschulen übertragen lassen. Wir beobachten Vergleichbares in dem Projekt ASSIST. Außerdem bleibt die Frage bestehen, wie Prognosewahrscheinlichkeiten genutzt werden können, um die Studierendenschaft effektiv zu unterstützen.

## **7 Voraussichtlicher Nutzen, Verwertbarkeit der Ergebnisse und zukünftige Planungen im Sinne des Verwertungsplans**

Der Datenaufbereitungsprozess konnte größtenteils automatisiert werden und basiert auf den gem. §3HStatG von jeder Hochschule gesammelten Daten. Das auf diesen Daten im Vorgängerprojekt entwickelte Modell wurde weiterentwickelt und in den Datenaufbereitungsprozess integriert.

Unsere explorativen Clusteranalysen zeigen vielversprechende Ergebnisse, sollten aber für eine in der Praxis relevante Anwendung verfeinert und ausgebaut werden. Der Einbezug von

Lernaktivitätsdaten des LMS Moodle haben gezeigt, dass wir die Genauigkeit der Prognosen noch vor den Klausuranmeldungen deutlich verbessern können. Da der Datenbestand jedoch durch regelmäßige Löschung begrenzt war und erst über die Zeit aufgebaut werden musste, ist mehr Zeit für eine umfangreichere Analyse notwendig.

Die getesteten Interventionen sind gut skalierbar und das Self-Assesment kann als Moodle-Kurs an jeder Universität importiert und getestet werden. Durch die direkten Ansprachen konnte die Teilnehmerquote stark erhöht werden, jedoch zeigen die im Rahmen des Projekts ausgewerteten Interventionen eine nur begrenzte Wirksamkeit bei der Unterstützung von Studierenden.

Insgesamt haben die oben präsentierten Analysen neue Erkenntnisse für das Prognosesystem und potenzielle Unterstützungsmaßnahmen geliefert. Dabei bleibt die Frage der verbesserten Erreichbarkeit und effektiven Unterstützung von Studierenden bestehen. Gleichzeitig haben sich neue Fragestellungen ergeben:

1. Kann das generierte Wissen für die Hochschul- und Studiengangsverwaltung eingesetzt werden?
2. Sind Ansätze, die allein auf die Angebote seitens der Hochschulen zielführend?
3. Wie kann die Bereitschaft der Studierenden erhöht werden, Unterstützungsangebote anzunehmen?
4. Wie ist mit dem Phänomen der Scheinstudierenden in Deutschland umzugehen?

## **8 Fortschritt auf dem Gebiet des Vorhabens während der Durchführung des Vorhabens bei anderen Stellen**

Es wurden weitere Studien zur Leistungsfähigkeit und möglichen Verbesserung von Frühwarnsystemen an Universitäten verfasst. Matz et al. (2023) untersuchen die Prognosegüte von sogenannten Meso-Daten, also Interaktionen von Studierenden auf Kommunikationsplattformen der Universität. Sie zeigen, dass der Einbezug solcher Interaktionen zwischen den Studierenden die Identifizierung abbruchgefährdeter Studierender signifikant verbessern kann. In Kombination mit unseren eigenen Ergebnissen aus der Verwendung der LMS Daten scheinen insbesondere Informationen über das Interaktions- und Lernverhalten von Studierenden die Prognosen weiter verbessern zu können. Die Unterscheidung von tatsächlichen Hochschulabbrechern von Studierenden die einfach nur die Hochschule wechseln führt nur zu einer marginalen Verbesserung der Klassifikationsergebnisse (siehe BMBF Projekt ASSIST).

Insgesamt besteht weiterhin die Frage, über welche Maßnahmen Studierende kosteneffizient unterstützt werden können und welche Rolle Frühwarnsysteme dabei spielen können. Unsere Ergebnisse deuten an, dass eine Informationsbereitstellung über Unterstützungsmaßnahmen zu keiner Verbesserung der Abbruchquote führt. Plak et al. (2021) adressieren nicht die Studierenden, sondern stellen Informationen basierend auf dem Frühwarnsystem direkt der Studienberatung zu Verfügung. Die Unterstützungsmaßnahme hat ebenfalls zu keiner Reduzierung der Abbruchquote geführt.

Auch wenn die im Rahmen dieses Projekts beschriebenen Interventionen keine klare Wirkung auf die Studierenden zeigen, finden Brade et al. (2024) wiederholt, dass niedrigschwellige Interventionen einen starken Einfluss auf den Studienerfolg haben können. In ihrer systematischen Literaturübersicht schlussfolgern Ibsen & Rosholm (2024), dass insbesondere Eingriffe in die Zusammensetzung von Peer- und Lerngruppen abbruchgefährdete Studierende unterstützen können. Auch über die Fakultät organisierte Mentoring-Programme scheinen einem Studienabbruch entgegenwirken zu können.

## 9 Erfolgte oder geplante Veröffentlichungen der Projektergebnisse

Berens, J., Henao, L., & Schneider, K. (2024). Tuition fees and academic (in) activity in higher education: How did students adjust to the abolition of tuition fees in Germany? (No. 1074). Ruhr Economic Papers. (Überarbeitung eingereicht bei *Labour Economics*)

Berens, J., Henao, L., Rumert, L., Schneider, K. (2025). Keeping an Eye on Students: Experimental Evaluation of an Early Alert System. Working Paper.

Berens, J., Henao, L., Rumert, L., Schneider, K. (2025). Can You Lead Students to Water and Make Them Drink? Academic Inactivity and Unresponsiveness to Higher Education Interventions. Working Paper.

Gößl, T., Henao, L., Rumert, L. (2025). Can Clustering support Student at-risk Identification? A Framework to receive Intuitive Groups of Students. Working Paper.

Gößl, T., Rumert, L., Schneider, K. (2025). Following Freshman Footprints: Early Student Activity & Academic Performance. Working Paper.

## 10 Literaturverzeichnis

Aggarwal, D., Mittal, S., & Bali, V. (2021). Significance of non-academic parameters for predicting student performance using ensemble learning techniques. *International Journal of System Dynamics Applications (IJSDA)*, 10(3), 38-49.

Ammon, B. V., Bowman, J., Mourad, R. (2008). Who Are Our Students? Cluster Analysis as a Tool for Understanding Community College Student Populations. *Journal of Applied Research in the Community College*, 16, 29-41.

Asif, R., Merceron, A., Ali, S. A., & Haider, N. G. (2017). Analyzing undergraduate students' performance using educational data mining. *Computers & education*, 113, 177-194.

Azmat, G., Bagues, M., Cabrales, A., & Iriberry, N. (2019). What You Don't Know... Can't Hurt You? A Natural Field Experiment on Relative Performance Feedback in Higher Education. *Management Science*, 65(8), 3714–3736.

Baker, R.S.J. (2010). Statistical Data Mining Tutorials. In B. McGaw, P. Peterson & E. Baker, eds. *International encyclopedia of education*. UK: Elsevier. 112-18.

Baker, R.S.J. & Yacef, K. (2009). The state of educational data mining in 2009: A review and future visions. *Journal of Educational Data Mining*, 1(1), 3-16.

Bayer, J. et al. (2012). Predicting Drop-Out from Social Behaviour of Students. *Proceedings of the 5th International Conference on Educational Data Mining*, 103-09.

Berens, J., Schneider, K., Görtz, S., Oster, S., and Burghoff, J. (2019). Early Detection of Students at Risk - Predicting Student Dropouts Using Administrative Student Data from

- German Universities and Machine Learning Methods. *Journal of Educational Data Mining*, 11(3), 1–41.
- Brade, R., Himmler, O., & Jäckle, R. (2022). Relative performance feedback and the effects of being above average—field experiment and replication. *Economics of Education Review*, 89, 102268.
- Brade, R., Himmler, O., Jaeckle, R., & Weinschenk, P. (2024). Helping Students to Succeed—The Long-Term Effects of Soft Commitments and Reminders. CESifo Working Paper No. 11001.
- Brahm, T., Jenert, T. & Wagner, D. (2016) The crucial first year: a longitudinal study of students' motivational development at a Swiss Business School. *Higher Education*, 73(3), 459-78.
- Düchs, G. & Matzdorf, R. (2014). Stabilisierung auf hohem Niveau - Statistiken zum Physikstudium an den Universitäten in Deutschland 2014. *Physik Journal*, 8, 23-28
- Er, E. (2012). Identifying at-risk students using machine learning techniques: A case study with IS 100. *International Journal of Machine Learning and Computing*, 2(4), 476.
- Heublein, U., Ebert, J., Hutzsch, C., Isleib, S., König, R., Richter, J., & Woisch, A. (2017). Zwischen studienwartungen und studienwirklichkeit. Ursachen des Studienabbruchs, beruflicher Verbleib der Studienabbrecherinnen und Studienabbrecher und Entwicklung der Studienabbruchquote an deutschen Hochschulen, 1.
- Himmler, O., Jäckle, R., & Weinschenk, P. (2019). Soft commitments, reminders, and academic performance. *American Economic Journal: Applied Economics*, 11(2), 114-142.
- Hussain, M., Hussain, S., Zhang, W., Zhu, W., Theodorou, P., & Abidi, S. M. R. (2018 a). Mining moodle data to detect the inactive and low-performance students during the moodle course. In *Proceedings of the 2nd International Conference on Big Data Research* (pp. 133-140).
- Hussain, M., Zhu, W., Zhang, W., & Abidi, S. M. R. (2018 b). Student Engagement Predictions in an e-Learning System and Their Impact on Student Course Assessment Scores. *Computational intelligence and neuroscience*, 2018(1), 6347186.
- Ibsen, K., & Rosholm, M. (2024) What Works? Interventions Aimed at Reducing Student Dropout in Higher Education. IZA Discussion Paper No. 16853.
- Koprinska, I., Stretton, J., & Yacef, K. (2015). Predicting student performance from multiple data sources. In *Artificial Intelligence in Education: 17th International Conference, AIED, Madrid, Spain, June 22-26, 2015. Proceedings 17* (pp. 678-681). Springer International Publishing.
- Ma, Y., & Cragg, K. M. (2013). So close, yet so far away: Early vs. late dropouts. *Journal of College Student Retention: Research, Theory & Practice*, 14(4), 533-548.
- Matz, S.C., Bukow, C.S., Peters, H., Deacons, C., Dinu, A., & Stachl, C. (2023). Using machine learning to predict student retention from socio demographic characteristics and app based engagement metrics. *Scientific Reports*, 13, 5705.
- Oreopoulos, P., Patterson, R. W., Petronijevic, U., & Pope, N. G. (2018). Lack of Study Time Is the Problem, but What Is the Solution? Unsuccessful Attempts to Help Traditional and Online College Students. Working Paper 25036. National Bureau of Economic Research.
- Oreopoulos, P., & Petronijevic, U. (2019). The remarkable unresponsiveness of college students to nudging and what we can learn from it (No. w26059). National Bureau of Economic Research.
- Sandner, M. (2015). The effects of high-quality student mentoring. *Economics letters*, 136, 227-232.

- Sara, N. B., Halland, R., Igel, C., & Alstrup, S. (2015). High-School Dropout Prediction Using Machine Learning: A Danish Large-scale Study. In ESANN (Vol. 2015, p. 23rd).
- Schneider, K., Berens, J. & Burghoff, S. (2019). Drohende Studienabbrüche durch Frühwarnsysteme erkennen: Welche Informationen sind relevant? Zeitschrift für Erziehungswissenschaften.
- Stinebrickner, R., & Stinebrickner, T. (2014). Academic performance and college dropout: Using longitudinal expectations data to estimate a learning model. *Journal of Labor Economics*, 32(3), 601-644.
- Tamada, M. M., Giusti, R., & Netto, J. F. D. M. (2022). Predicting students at risk of dropout in technical course using LMS logs. *Electronics*, 11(3), 468.
- Valles-Coral, M. A., Salazar-Ramírez, L., Injante, R., Hernandez-Torres, E. A., Juárez-Díaz, J., Navarro-Cabrera, J. R., Pinedo, L., Vidaurre-Rojas, P. (2022). Density-Based Unsupervised Learning Algorithm to Categorize College Students into Dropout Risk Levels. *Data*, 7, 165.
- Wilson, K. L., Murphy, K. A., Pearson, A. G., Wallace, B. M., Reher, V. G., & Buys, N. (2016). Understanding the early transition needs of diverse commencing university students in a health faculty: informing effective intervention practices. *Studies in Higher Education*, 41(6), 1023-1040.
- Wittenberg, R., Rothe, T., Proske, S., Wenzig, C., & Wenzig, K. (1999). Studienabbruch sowie Studienfach- und/oder Studienortwechsel an der Wirtschafts- und Sozialwissenschaftlichen Fakultät der Universität Erlangen-Nürnberg.
- Zanellati, A., Zingaro, S. P., & Gabbrielli, M. (2024). Balancing Performance and Explainability in Academic Dropout Prediction. *IEEE Transactions on Learning Technologies*.
- Zhang, Y., Ghandour, A., & Shestak, V. (2020). Using learning analytics to predict students performance in moodle LMS. *International Journal of Emerging Technologies in Learning (Online)*, 15(20), 102.
- Zhang, Y., Oussena, S., Clark, T. & Kim, H. (2010). Use Data Mining to Improve Student Retention in Higher Education - a Case Study. *Proceedings of the 12th International Conference on Enterprise Information Systems, Volume 1, DISI, Funchal, Madeira, Portugal, June 8 - 12, 2010*.
- Zhang, Y., Fei, Q., Quddus, M., & Davis, C. (2014). An examination of the impact of early intervention on learning outcomes of at-risk students. *Research in Higher Education Journal*, 26.