



## Teil I: Kurzbericht

# DiSEA – Digitale Studiengänge: Analyse von Erfolgs- und Abbruchfaktoren

Förderkennzeichen: 16PX21001A, 01PX21001B

## 1 Ursprüngliche Aufgabenstellung und Stand der Forschung

Das *DiSEA*-Projekt beschäftigt sich mit der Analyse und Identifikation von Faktoren für Erfolg bzw. Misserfolg und Studienabbruch in digitalen Studienformaten, genauer gesagt in Online-Studiengängen der Virtuellen Fachhochschule (VFH). Das Ziel des Vorhabens ist es, ein integriertes Modell zur Vorhersage von Studienerfolg in digitalen Studienformaten zu entwickeln und entsprechende Handlungsempfehlungen (z.B. für die Gestaltung der Studienberatung) abzuleiten. Um die gewonnenen Erkenntnisse in praktische Veränderungen umsetzen zu können, muss von Beginn an eine Vielzahl an Akteuren an den Hochschulen beteiligt werden (Studiengangsleitung, Studienberatung, Lehrende, Instructional Designer, Studierende, Datenschutzbeauftragte, Studierendenverwaltung, Qualitätssicherung).

Das Vorhaben thematisiert drei Hauptfragestellungen:

1. Übertragbarkeit bisheriger Forschungsergebnisse auf digitale Studienformate.
2. Analyse von Daten zum Lernverhalten.
3. Erkenntnisse zum Einsatz des Dashboards für Studierende.

Das *DiSEA*-Projekt knüpft an die Erkenntnisse mancher Projekte der Förderlinie „Studienerfolg und Studienabbruch I“ wie *FragSte* (Berens et al. 2019, Schneider et al. 2019) und *PIRanHa*-Projekts (Ispording & Wozny 2018) an. Diese Forschungsprojekte untersuchen Daten aus traditionellen Studienformaten, d.h. Präsenzstudiengänge mit überwiegend „klassischen“ Studienanfänger\*innen. In den Online-Studiengängen der VFH arbeiten die meisten Studierenden Vollzeit und studieren Teilzeit.

## 2 Ablauf des Vorhabens

Der Ablauf des Vorhabens orientierte sich an der typischen Struktur eines Projekts im Bereich des maschinellen Lernens. Da das Projekt personenbezogene Daten verarbeitet, wurde bereits im Vorfeld des Projekts ein Datenschutz- und Sicherheitskonzept entwickelt, das in enger Zusammenarbeit mit dem Datenschutzbeauftragten der Berliner Hochschule für Technik (BHT) erstellt und im Projekt umfassend ergänzt wurde. Vor der Datenakquise wurden aufwändige Gespräche mit den Datenschutzbeauftragten von unterschiedlichen Hochschulen der VFH geführt. Es wurden schließlich akademische Daten von drei Hochschulen gesammelt, die gemäß § 3 HStatG von allen Hochschulen in Deutschland erhoben werden müssen. Parallel wurden nach Opt-In der Studierenden Log-Daten gesammelt, die von der Lernplattform Moodle gespeichert werden. Auf Basis theoretischer Grundlagen wurde ein eigenes Datenmodell entwickelt, in das die Daten integriert wurden. Schließlich wurden in einem User-Centered-Design-Prozess mit engem Einbezug der relevanten Akteure Modelle

und Empfehlungen entwickelt, um Studienerfolgs- und -misserfolgsk Faktoren in digitalen Studienformaten zu identifizieren und frühzeitige Interventionen zu ermöglichen.

### **3 Wesentliche Ergebnisse (und ggf. die Zusammenarbeit mit anderen Forschungseinrichtungen)**

**Erkenntnisse und Empfehlungen zur Datenakquise und -integration:** Verschiedene Datenschutzvorgaben und die Heterogenität der Verwaltungsdaten verhindern die wissenschaftliche Analyse der Bildungsdaten. Es wird empfohlen, die Datenerhebungssysteme in der Hochschuladministration zu vereinheitlichen und die Transparenz in Bezug auf die Nutzung personenbezogener Daten in den Hochschulen zu verstärken.

**Ergebnisse der Vorhersage zum Studienabbruch.** Mit Hilfe der akademischen Daten wurden Modelle erstellt, um vorherzusagen, ob Studierende das Bachelor-Studium am Ende des 1., 2. oder 3. Semesters abbrechen werden. Dafür wurden zwei erklärbare Algorithmen gewählt, die Logistische Regression und Entscheidungsbäume. Im Studiengang Bachelor „Medieninformatik“ wurde ein „Recall“ von über 90% erzielt, was bedeutet, dass die Modelle 90% oder mehr der Studierenden, die abbrechen, vorhersagen können. Es wurde ein Vorgehen entwickelt, um die Kurse, die für die Vorhersage am wichtigsten sind, zu identifizieren. Diese wurden DozentInnen und Studiengangsleitungen präsentiert. In einer Diskussion wurden erste Schlussfolgerungen erörtert. Etwas schwächere Ergebnisse wurden im Studiengang „Wirtschaftsinformatik“ erzielt. Ein Grund dafür könnte sein, dass weniger Daten zur Verfügung standen.

**Ergebnisse zum Zusammenhang zwischen Aktivität in Moodle und Erfolg im Kurs.** Unsere Daten-Exploration hat gezeigt, dass die Aktivitäten in Moodle in den verschiedenen Kursen sehr unterschiedlich sind und dass wir pro Kurs und Semester ein Daten-Sparsity Problem haben. Daher ist es nicht sinnvoll zu untersuchen, ob es einen allgemeinen Zusammenhang in allen Kursen zwischen bestimmten Aktivitäten und Noten gibt. Stattdessen haben wir untersucht, ob es einen Zusammenhang zwischen Aktivitätsregelmäßigkeit (*Regularity*) der Zugriffe in Moodle und Noten in ausgewählten Kursen gibt. Wir könnten nur in ein Paar Kursen eine mittlere bis starke Korrelation finden. Wir interpretieren dieses Ergebnis so: wenn Studierende sich regelmäßig mit dem Material eines Kurses beschäftigen, erzielen sie eine bessere Note. Diese Untersuchung benötigt mehr Forschung mit mehr Daten, nicht nur 3 Semester von verknüpften Daten, und nicht nur Moodle-Daten von Studierenden, die der Nutzung ihrer Moodle-Daten zugestimmt haben.

**Veröffentlichung der Forschungsdaten.** Um die Forschungsgemeinschaft zu unterstützen, werden vier Datensätze veröffentlicht und stehen für weitere Forschungsarbeiten zur Verfügung. Zwei Datensätze enthalten die aggregierten akademischen Daten der Studierenden, die von zwei verschiedenen Studiengängen stammen: der Bachelor Medieninformatik (Daten aus zwei Standorten) und der Bachelor Wirtschaftsinformatik (Daten aus einem Standort). Ein weiterer Datensatz enthält die aggregierten Moodle-Log-Daten, die pro Kurs und Studierende aufgeschlüsselt sind. Der vierte Datensatz ist eine Verknüpfung von Moodle-Log-Daten mit den Noten im Kurs.

**Verwertung der Projektergebnisse.** Die Projektergebnisse wurden mit Akteuren aus der VFH beim jährlichen Symposium diskutiert, um sie zu befähigen, die Ergebnisse in ihren Tätigkeiten zu verwerten. Sie stehen außerdem in einem Moodle-Kurs für alle Akteure aller Standorte der VFH zur Verfügung. Die Projektergebnisse wurden auch mit Akteuren aus dem Berliner Zentrum für Hochschullehre (BZHL) und dem Kompetenzzentrum Digitale Medien der BHT diskutiert. Das BZHL verwertet die Ergebnisse in ihrer Ressourcenseite "[Learning Analytics an Hochschulen](https://www.tu.berlin/bzhl/ressourcen-fuer-ihre-lehre/learning-analytics-an-hochschulen)" (<https://www.tu.berlin/bzhl/ressourcen-fuer-ihre-lehre/learning-analytics-an-hochschulen>). Ausgewählte Ergebnisse wie Veröffentlichungen stehen auf der Webseite <https://disea-projekt.de/> zur Verfügung.



## Teil II: Eingehende Darstellung

# DiSEA – Digitale Studiengänge: Analyse von Erfolgs- und Abbruchfaktoren

Förderkennzeichen: 16PX21001A, 01PX21001B

Laufzeit: 01.02.2021 - 30.09.2024

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung unter dem Förderkennzeichen 16PX21001A gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei dem/der Autor/in bzw. den Autor/inn/en.

## Inhaltsverzeichnis

### 1 Aufgabenstellung

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

### 3 Planung und Ablauf des Vorhabens

### 4 Inhaltliche Ergebnisse

#### 4.1 Ist-Analyse der akademischen Daten

#### 4.2 Datenaufbereitung und -integration der akademischen Daten

#### 4.3 Vorhersage-Modelle zum Abbruch des Studiums

##### 4.3.1 Ansatz und Ergebnisse der Vorhersage für den Studiengang Medieninformatik

##### 4.3.2 Ansatz und Ergebnisse der Vorhersage im Studiengang Wirtschaftsinformatik

#### 4.4 Ist-Analyse und Datenvorbereitung der Daten aus Lernmanagementsystem

##### 4.4.1 Ist-Analyse der Moodle-Daten

##### 4.4.2 Datenvorbereitung der Moodle-Daten

##### 4.4.3 Aktivitätsregelmäßigkeit (regularity) und Kurserfolg

#### 4.5 Akzeptanz und Wirksamkeit von Dashboards zur Anzeige studienrelevanter Daten

#### 4.6 Entwicklung eines integrierten Learning-Analytics-Konzeptes für digitale Studienformate

### 5 Wichtigste Positionen des zahlenmäßigen Nachweises

### 6 Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten

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

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

### 9 Erfolgte oder geplante Veröffentlichungen der Projektergebnisse

### 10 Literaturverzeichnis

## 1 Aufgabenstellung

Obwohl Studienabbrüche an Hochschulen inzwischen mit einer relativ guten Trefferquote vorhergesagt werden könnten, ist diese Information bislang häufig weder für Studiengangsleitungen, Lehrende noch für Studierende zugänglich. Mit Methoden aus dem maschinellen Lernen werden dazu Modelle entwickelt, trainiert und evaluiert, wobei die zur Verfügung stehenden Daten eine wesentliche Rolle für die Modellqualität spielen. Diese Modelle können in Frühwarnsystemen eingesetzt werden, um gefährdete Studierende früher zu erkennen und gezielter zu beraten. Die Ergebnisse können auch an Akteure wie Studiengangsleitungen und Dozierende zur Reflexion kommuniziert werden, um z.B. Maßnahmen zu ergreifen, welche die Studierbarkeit verbessern könnten.

Ein Beispiel hierfür ist das Frühwarnsystem *FragSte* (Berens et al. 2019, Schneider et al. 2019, Projekt der Förderlinie „Studienerfolg und Studienabbruch I“), das ausschließlich Daten nutzt, die jede Hochschule in Deutschland laut §3 HStatG erhebt. Diese Daten können in zwei Kategorien gegliedert werden: Daten, die am Anfang des Studiums verfügbar sind – wie Geschlecht, Alter, Art und Note der Zugangsberechtigung usw. – und akademische Leistungen, die im Hochschulinformationssystem während des Studiums gespeichert werden, wie Noten in Kursen, Anzahl der Belegungen, Anzahl abgeschlossener Module, Durchschnittsnote usw. *FragSte* wurde an einer staatlichen Universität und an einer privaten Fachhochschule evaluiert. Erste weitere Untersuchungen deuten an, dass der in *FragSte* verfolgte Ansatz für andere Hochschulen in Deutschland verallgemeinerbar ist (Wagner et al. 2020).

Es zeigte sich, dass sich die Performanz des Frühwarnsystems erheblich verbessert, sobald auf Daten bezüglich der akademischen Leistungen zugegriffen werden kann. Außerdem bestimmen die akademischen Leistungen nach dem ersten Semester weitgehend die Performanz des Frühwarnsystems: der Einbezug weiterer Daten verbessert die Prognosequalität kaum. Auch die Untersuchungen des *PIRanHa*-Projekts (Isphording & Wozny 2018, Projekt der Förderlinie „Studienerfolg und Studienabbruch I“) zeigen, dass Studierendencharakteristika alleine wenig Erklärungskraft besitzen. Eine Studie von Falk et al. (2018) zur Steigerung des Studienerfolgs an deutschen Hochschulen kommt zu dem Schluss, dass die beste Praxis darin besteht, mehrere Maßnahmen – darunter Monitoring mit Datenanalysen – zu kombinieren.

Sowohl *FragSte* als auch andere (internationale) Forschungsprojekte untersuchen Daten aus traditionellen Studienformaten, d.h. Präsenzstudiengänge mit überwiegend „klassischen“ Studienanfänger\*innen, die im frühen Erwachsenenalter bzw. im Anschluss an den Schulabschluss ihr Studium beginnen. Neben diesen traditionellen Studienformaten, die nach wie vor den Großteil der Studienangebote ausmachen, etwa 95% in Deutschland, siehe (Hochschulkompass 2024), gewinnen jedoch digitale Studienangebote zunehmend an Bedeutung, d.h. Studiengänge, die ganz oder überwiegend als Online- bzw. Fernlehr-Angebot stattfinden und sich in der Zusammensetzung der Studierendenschaft deutlich von klassischen Studiengängen unterscheiden: Zielgruppe digitaler Studienformate sind typischerweise Personen, die bereits im Berufsleben stehen und sich neu bzw. weiter qualifizieren möchten oder die aufgrund ihrer persönlichen Lebenssituation – z.B. Kindererziehung, Pflege von Angehörigen, Erkrankungen – ein Studium in Präsenz nur schwer realisieren könnten und die Flexibilität von Online-Angeboten schätzen. Dementsprechend zeigen diese Personen auch ein anderes Studierverhalten: Häufig wird berufsbegleitend studiert, was mit einer – geplant – deutlich längeren Studiendauer und häufig auch geringeren Priorisierung des Studiums einhergeht. Die Anforderungen an die Selbstregulations- und Motivationsfähigkeiten der Studierenden sind deutlich höher: Online-Formate bieten zwar viel Flexibilität, das Studium an die persönliche Lebenssituation anzupassen, verlangen aber auch ein hohes Maß an Disziplin und Organisationsfähigkeit (vgl. Minks et al. 2011, Wöhrle et al. 2024).

Dies bedingt, dass sich auch die Gründe für Modul- oder Studienabbrüche in digitalen Studienangeboten von traditionellen Studienformaten unterscheiden. So ist für berufstätige Personen das Semester oft schlechter planbar, unvorhergesehene arbeitsbezogene Beanspruchungen können verhindern, dass ein Modul erfolgreich absolviert wird. Teilweise unterschätzen die Studierenden zu

Beginn den Aufwand, den ein Studium erfordert bzw. die Vereinbarkeit von Studium und Beruf erweist sich als schlechter als vorab angenommen. Z.T. verringert sich auch die Bedeutung des formalen Studienabschlusses im Verlauf des Studiums – wenn beispielsweise Qualifikationserwerb auch durch verliehene Zwischenzertifikate nachgewiesen werden kann oder Arbeitgeber die im Studium erworbenen Kompetenzen bereits durch bessere Entlohnung oder Aufstiegsmöglichkeiten honorieren, auch wenn noch kein formaler Abschluss vorliegt (Wöhrle et al. 2024). Auch die höheren Anforderungen an Eigenständigkeit und Selbstorganisation werden nicht von allen Studierenden erfolgreich bewältigt. All diese Aspekte führen dazu, dass Abbruchquoten in Online-Formaten generell höher ausfallen (vgl. Diaz 2002, Beard & Harper 2002, Baker et al. 2015), was in unsrem Projekt bestätigt wurde.

Bislang fokussiert sich die Forschung zu Studienerfolg und -abbruch v. a. auf traditionelle Studienformate. Eine Analyse der aktuellen Literatur und insbesondere auch der Projekte der ersten Förderlinie zu Studienerfolg und Studienabbruch zeigt, dass digitale Studienformate allenfalls am Rand thematisiert werden. Vorhaben bzw. Studien, die gezielt Daten aus Online-Studiengängen betrachten, sind uns nicht bekannt. Aus diesem Grund ist fraglich, ob und wie diese Ergebnisse für digitale Studienformate verallgemeinerbar sind.

Das vorliegende Projekt beschäftigt sich mit der Analyse und Identifikation von Faktoren für Erfolg bzw. Misserfolg und Studienabbruch speziell in digitalen Studienformaten. Hierzu sollen die umfangreichen Erfahrungen und Daten aus dem Hochschulverbund Virtuelle Fachhochschule (VFH, <https://www.vfh.de/>) herangezogen werden.

Der VFH-Verbund wurde 2001 im Rahmen des Bundesleitprojekts „Virtuelle Hochschule“ gegründet. Aktuell gehören 13 Hochschulen aus mehreren Bundesländern sowie eine aus der Schweiz dem Verbund an; Studierende kommen aus ganz Deutschland, einzelne aus dem Ausland. Derzeit bietet die VFH 11 akkreditierte Bachelor- und Master-Studiengänge als Online-Studiengänge an.

Folgende Prinzipien liegen den Studienmodulen der VFH-Studienangebote zugrunde:

1) Die Lernmaterialien werden mit Unterstützung von Instructional Designern interaktiv (inklusive Animationen und Tests) und multimedial vorbereitet; 2) Kurse werden mit Einsendeaufgaben, Web-Konferenzen und ggf. ergänzenden Blockveranstaltungen in Präsenz (teilweise auch virtuell) strukturiert, die im Modulhandbuch beschrieben sind; 3) das Lernangebot wird durch eine hochschulübergreifende Lernplattform – konkret Moodle – bereitgestellt, die Lehrende wie Studierende verbindlich nutzen und die mit ergänzenden Tools zur Unterstützung der Online-Kommunikation und -Kooperation verknüpft ist. Diese Verpflichtung ist in den Studienordnungen verankert.

Unser Vorhaben thematisiert drei Hauptfragestellungen:

1. **Übertragbarkeit bisheriger Forschungsergebnisse auf digitale Studienformate.** Vorhergesagemodelle zum Studienerfolg, die auf Daten aus traditionellen Studienformaten basieren (u.a. Projekte *FragSte*, *PIRanHa*), sollen auf Online-Studiengänge der VFH übertragen und hinsichtlich der Vorhersagequalität in diesem Kontext untersucht sowie um spezifische Faktoren ergänzt werden.

2. **Analyse von Daten zum Lernverhalten.** Digitale Studienformate zeichnen sich dadurch aus, dass aufgrund der verpflichtenden Nutzung von Lern-Management- und anderen Kommunikations- und Kooperationssystemen eine Vielzahl von Daten zur Verfügung stehen könnte, aus denen sich Rückschlüsse auf das Lernverhalten ziehen lassen (bspw. Nutzungshäufigkeit und -rhythmus). Daher sollen Nutzungsdaten aus dem Lernraumsystem Moodle im Hinblick auf Zusammenhänge mit Studienerfolg untersucht werden mit dem Ziel, die Vorhersagequalität der Modelle durch den Einbezug entsprechender Faktoren zu verbessern. Im Projekt werden die Studierenden um ihre Einwilligung gefragt, da Nutzungsdaten sonst im regulären Geschäft regelmäßig gelöscht werden.

3. **Einsatz von Dashboards zur Verbesserung der Selbstreflexion.** Die Selbstregulationskompetenz der Studierenden ist wesentlich für den Erfolg in digitalen Lernformaten. Dabei ist zentral, dass die Studierenden ausreichende Rückmeldungen zu ihren Lernaktivitäten erhalten, um etwa problematische Verhaltensweisen zu reflektieren und Veränderungsbedarfe zu erkennen. Solche

Rückmeldungen können in Lernraumsystemen in Form von sogenannten Dashboards zur Verfügung gestellt werden, die Lernaktivitäten, Nutzungsdaten, bevorstehende Anforderungen und Deadlines etc. grafisch aufbereitet darstellen. Im vorliegenden Vorhaben sollen lern- und studienbezogene Daten in Form eines Dashboards zur Verfügung gestellt werden, mit dem Ziel, die Reflektion und somit die Selbstregulationskompetenz der Studierenden zu erhöhen. Die Dashboards werden prototypisch in ausgewählten Kursen eingesetzt und deren Akzeptanz sowie Einfluss auf Lernverhalten und -erfolg evaluiert.

Das Ziel des Vorhabens ist es, ein integriertes Modell zur Vorhersage von Studienerfolg in digitalen Studienformaten zu entwickeln und entsprechende Handlungsempfehlungen (z.B. für die Gestaltung der Studienberatung) abzuleiten. Um die gewonnenen Erkenntnisse in praktische Veränderungen umsetzen zu können, muss von Beginn an eine Vielzahl an Akteuren an den Hochschulen beteiligt werden (Studiengangsleitung, Studienberatung, Lehrende, Instructional Designer, Studierende, Datenschutzbeauftragte, Studierendenverwaltung, Qualitätssicherung) – das machen auch die Ergebnisse des SHEILA-Projektes (<https://sheilaproject.eu/>) deutlich. Insbesondere die Beteiligung der Studierenden ist im Hinblick auf die Akzeptanz der Maßnahmen von zentraler Bedeutung. Untersuchungen zeigen, dass Studierende Datenanalysen akzeptieren und befürworten, wenn sie davon überzeugt sind, dass diese ihnen Vorteile bringen (Ifenthaler & Schumacher 2017, Slade et al. 2019). Allerdings sind die Folgen der Adaption von Learning-Analytics-Lösungen nicht immer absehbar. Ein von Jayaprakash et al. (2014) beschriebenes Frühwarnsystem wurde so eingesetzt, dass Lehrkräfte als gefährdet identifizierte Studierende kontaktierten. Neben einer Verbesserung der Ergebnisse der Studierenden zeigten die Fallstudien aber auch eine signifikante Erhöhung von Kursabbrüchen, was nicht beabsichtigt war. Eine mögliche Erklärung ist, dass die entsprechenden Rückmeldungen auch zu einer Entmutigung von Studierenden geführt haben oder sich diese unangenehm exponiert fühlten und daher den Kurs abbrachen. Schneider et al. (2021) berichten, dass eine per Email gesendete Warnung nahezu wirkungslos blieb. Somit müssen die Grenzen und die Erklärbarkeit der Modelle in diesem Projekt mit Sorgfalt berücksichtigt und mit den Akteuren – insbesondere den Studierenden – diskutiert werden.

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

Auch auf internationaler Ebene zeigen Untersuchungen, dass demographische Daten bzw. solche, die vor Aufnahme des Studiums erhoben wurden, weniger aussagekräftig für die Vorhersage des Studienerfolgs sind als die Daten zu bereits erbrachten akademischen Leistungen (vgl. den Übersichtsartikel von Hanover Research 2014). So wurden in einer breit angelegten Studie von Aulck et al. (2019) Daten der Studienverwaltung einer amerikanischen Universität von über 66.000 Studierenden, die zwischen 1998 und 2010 das Studium aufgenommen haben, mit entsprechendem Ergebnis analysiert. Dieses Fazit wurde ebenfalls von Berens et al. (2019) und Dekker et al. (2009) gezogen, wobei in letzterer Untersuchung lediglich Daten aus dem ersten Studienjahr von 648 Studierenden eines einzigen Studiengangs betrachtet wurden.

Verschiedene Untersuchungen unterscheiden sich hinsichtlich der Vorhersagemodelle. So erzielten Dekker et al. (2009) die besten Ergebnisse mit Entscheidungsbäumen, Aulck et al. (2019) mit logistischer Regression und Berens et al. (2019) in der oben bereits erwähnten Untersuchung aus dem Projekt *FragSte* mit der Ensemble-Methode AdaBoost.

Berens et al. (2019) und Aulck et al. (2019) nutzen hochschulweit einsetzbare Modelle. Daher wird die akademische Leistung mit sogenannten „global features“ beschrieben, die nicht spezifisch für einen Studiengang sind (wie z.B. Anzahl bestandener Kurse, Durchschnittsnote oder auch Anzahl belegter Kurse). Manrique et al. (2019) verglichen die Performanz von Modellen mit „global features“ sowie „local features“ (d.h. studiengangsspezifischen Leistungen wie Noten in bestimmten Kursen) und konnten zeigen, dass mit lokalen Attributen bessere Vorhersageergebnisse erzielt werden können als mit globalen Attributen. Uneinheitlich sind die Befunde hinsichtlich der Anzahl der betrachteten Semester: Berens et al. (2019) erzielen bessere Ergebnisse, je mehr Semester sie für die Vorhersage

berücksichtigen, während sich in der Untersuchung von Manrique et al. (2019) ein gegenteiliges Bild zeigte. Eine mögliche Erklärung ist, dass die weniger guten Ergebnisse von Manrique et al. (2019) an der geringen Datenmenge liegen, da es weniger Abbrecher-Daten in höheren Semestern gibt.

Neben Untersuchungen, die den Studienerfolg global betrachten, gibt es Versuche, Frühwarnsysteme für einzelne Kurse zu entwickeln. So soll „Course Signals“ vorhersagen, welche Studierende gefährdet sind, einen Kurs nicht zu bestehen (Arnold & Pistilli 2012); auch Baneres et al. (2019) untersuchen spezifische Risikofaktoren in einzelnen Kursen, wobei sie auch Online- und Blended-Learning-Kurse betrachten und Daten aus Learning-Management-Systemen auswerten (wie Nutzungshäufigkeit, Bearbeitung von Aufgaben und deren Bewertung). Allgemein jedoch gilt auch im internationalen Kontext, dass die Spezifika rein digitaler Studiengänge selten untersucht werden. Baker et al. (2015) konnten ebenso wie Kuzilek et al. (2015) für einzelne Online-Kurse zeigen, dass Studierende, die sich frühzeitig und regelmäßig im Kursverlauf mit den Online-Materialien auseinandersetzen und entsprechende Kursaufgaben bewältigen, eine höhere Wahrscheinlichkeit aufweisen, den Kurs erfolgreich zu bestehen. Van Goidsenhoven et al. (2020) zeigen, dass es möglich ist, präzise Vorhersagemodelle für den Erfolg von Studierenden basierend auf Logdaten eines Online-Moduls zu erzielen, und dass die Modelle Gründe für den Studienerfolg liefern. Auch Akçapınar et al. (2019) konnten für einen E-Book-basierten Kurs zeigen, dass Studierende, die bessere Kursresultate erzielten, häufiger und intensiver mit den Online-Materialien interagiert hatten. Diese Befunde sprechen dafür, dass es aussichtsreich ist, Daten aus Lernmanagementsystemen in digitalen Studienformaten zu betrachten.

Im Kontext der Forschung zu Learning Analytics und Educational Data Mining werden sogenannte „Learning Dashboards“, die lernrelevanten Daten meist grafisch aufbereitet darstellen und sich sowohl an Lernende als auch an Lehrende richten können, häufiger betrachtet (Verbert et al. 2014). Dashboards können auf Seiten der Lernenden Awareness, Reflexion und Selbststeuerung unterstützen (Martinez-Maldonado et al. 2014). Im Hinblick auf die Auswirkungen von Dashboards auf den Studienerfolg liegen bislang kaum Erkenntnisse vor (Jivet et al. 2018).

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

Die Einstellung der wissenschaftlichen Mitarbeiter\*innen erfolgte nicht wie im Antrag geplant. Eine erste Mitarbeiterin wurde am 01.05.2021 eingestellt, der zweite Mitarbeiter am 01.07.2021, der aber zum 30.11.2021 kündigte. Die Einstellung einer neuen Mitarbeiterin erfolgte erst am 01.08.2022. Die Verzögerungen der Einstellungen haben mehrere Ursachen, insbesondere:

- Rahmenbedingungen der Einstellungsverfahren an der Berliner Hochschule für Technik.
- pandemiebedingt erschwerte Absprachen mit Verantwortlichen aufgrund schlechterer Erreichbarkeit sowie eines erhöhten Arbeitsaufkommens bei vielen Personen.

Die Akquise der akademischen Daten erfolgte nicht wie im Antrag geplant und verzögerte sich. Dies hat auch mehrere Ursachen, insbesondere:

- zusätzliche Abstimmungsbedarfe mit Datenschutzbeauftragten durch Änderung der Stelleninhaber in Lübeck und dem Outsourcing des Datenschutzbeauftragten in Berlin an eine externe Firma.
- zum Teil pandemiebedingte aufwändige Kommunikation mit den Datenschutzbeauftragten verschiedener Standorte der VFH und verminderte Personalressourcen.

Aufgrund dieser Verzögerungen wurde eine kostenneutrale Verlängerung des Projektes von 8 Monaten beantragt und bewilligt, da die Fertigstellung des ersten Meilensteins mit 8 Monate Verspätung erreicht wurde. Meilenstein 1 wurde im Januar 2023 erreicht, Meilenstein 2 im Januar 2024 und Meilenstein 3 im September 2024. Die Ziele des Projektes haben sich im Wesentlichen nicht verändert.

Die Arbeit wurde mit einem wöchentlichen Treffen des Teams in Berlin sowie bedarfsorientiert weiteren Treffen organisiert, ergänzt von 14-tägigen Treffen der WiMi der Standorte Lübeck und Berlin und monatlichen Treffen der gesamten Teams Lübeck und Berlin.

## 4 Inhaltliche Ergebnisse

### 4.1 Ist-Analyse der akademischen Daten

Die Universitäten in Deutschland erheben die akademischen Daten laut § 3 Hochschulstatistikgesetz (HStatG). Aus der Liste der Erhebungsmerkmale nach § 3 HStatG werden im Projekt DiSEA folgende Daten analysiert:

1. Stammdaten: Matrikelnummer, Geschlecht, Geburtsjahr (oder Geburtsdatum), Erstein-schreibung, Immatrikulationsdatum (oder Semester), Studiengang, Exmatrikulationsdatum (oder Semester), Exmatrikulationsgrund.
2. Abschlussdaten: Hochschulzugangsberechtigung-Jahr, -Art, -Note; Abschluss-Jahr, -Art, -Note.
3. Verlaufsdaten: Fachsemester, Hochschulsesemester, Studierstatus, Studiengang.
4. Prüfungsdaten: Modulname, Studiengang, Semester, Versuch, Note.

Die Daten werden lokal anonymisiert: Namen und Matrikelnummer werden systematisch mit einem laufenden Schlüssel ersetzt (Studierenden-ID), so dass die ursprünglichen Namen oder Matrikelnummern für Dritte nicht mehr rekonstruierbar sind. Wenn es für einen Wert nur 3 oder weniger Studierende in einem Studiengang gibt, wird das Feld ignoriert oder die Werte werden aggregiert, so dass eine 3-Anonymisierung gewährleistet ist.

Im DiSEA-Projekt liegen Daten von drei Hochschulen vor: Technische Hochschule Brandenburg (THB)<sup>1</sup>, Berliner Hochschule für Technik (BHT)<sup>2</sup> und Technische Hochschule Lübeck (THL)<sup>3</sup>.

Auch wenn die Anfrage nach akademischen Daten bei allen Hochschulen ähnlich war, zeigten sich erhebliche Unterschiede in der Art und Weise, welche Daten bereitgestellt und wie diese aufbereitet wurden.

Die Daten, die von der THB bereitgestellt wurden, liegen in einer Tabelle vor. Hierzu werden für die Studenten ausschließlich das Geschlecht sowie die abgelegten Prüfungen mit der Prüfungsnummer, der Kursbeschreibung und der erreichten Note erfasst. Da das Semester der abgelegten Prüfungen fehlte, wurden diese Daten für die weitere Auswertung nicht verwendet.

Im Vergleich zur THB liegen von der BHT und THL umfangreichere Informationen zu den Studierenden vor. Zu den soziodemografischen Angaben zählen Geschlecht, Geburtsjahr und die Staatsangehörigkeit der Studierenden<sup>4</sup>. Darüber hinaus liegen Informationen über den bisherigen Bildungsweg: Ort\*, Jahr, Art und Note<sup>5</sup> der Hochschulzugangsberechtigung; Land, Hochschule und das Semester der Ersteinschreibung an einer Hochschule\* vor. Zusätzlich werden Informationen über Parallelstudiengänge/-fächer\*, das Land\*, die Hochschule\* und die Art des letzten erworbenen Abschlusses, falls der aktuelle Studiengang nicht der erste ist, bereitgestellt.

Zu den akademischen Leistungen zählen folgende Angaben: Kursnummer, Semester, in dem die Prüfung abgelegt wurde, die Anzahl der Versuche, Prüfungsstatus und -art<sup>‡</sup>, und die Note. Dazu werden Informationen über den Studienverlauf der Studierenden bereitgestellt wie Studierstatus (semesterweise), das Fach- und Hochschulsesemester. Ebenfalls werden Informationen zum Imma- und Exmatrikulationssemester sowie zum Exmatrikulationsgrund zur Verfügung gestellt.

---

<sup>1</sup> Studiengang Bachelor Medieninformatik

<sup>2</sup> Studiengänge Bachelor Medieninformatik und Bachelor Wirtschaftsinformatik

<sup>3</sup> Studiengang Medieninformatik (Bachelor und Master)

<sup>4</sup> \* nur in der Berliner Hochschule für Technik

<sup>5</sup> ‡ nur in der Technischen Hochschule Lübeck

## 4.2 Datenaufbereitung und -integration der akademischen Daten

Im Rahmen der Datenaufbereitung wurden die Daten analysiert, um deren Struktur und Inhalt zu verstehen. Die Analyse zeigte, dass die Daten der drei Hochschulen nicht nur in ihrer Beschaffenheit, sondern auch in ihrer Struktur und der Art und Weise, wie dieselbe Information codiert ist, signifikante Unterschiede aufweisen. Bei der Analyse der Daten haben wir folgende wichtige Ergebnisse festgestellt:

1. Unterschiede in der Anzahl der Tabellen zwischen den drei Hochschulen.
2. Unterschiede in den Werten in den Tabellen für dieselbe Information. Ein Beispiel hierfür ist der Exmatrikulationsgrund eines Studierenden, der in jeder Hochschule unterschiedlich codiert wird.
3. Anomalien und Fehler in den Daten, die eine korrekte Auswertung und Interpretation erschweren.

Um die Daten für die spätere Vorhersage vorzubereiten, müssen sie aufbereitet werden (Abb. 1). Dazu gehören folgende Schritte: a) Auswahl der relevanten Daten, die für die Vorhersage benötigt werden; b) Bereinigung der Daten, um Fehler und Ungenauigkeiten zu korrigieren oder zu entfernen; c) Zusammenführung der Daten aus verschiedenen Quellen, um einen einheitlichen Datenbestand zu erstellen; d) Transformation der Daten, um sie in eine Form zu bringen, die für die Vorhersage geeignet ist.

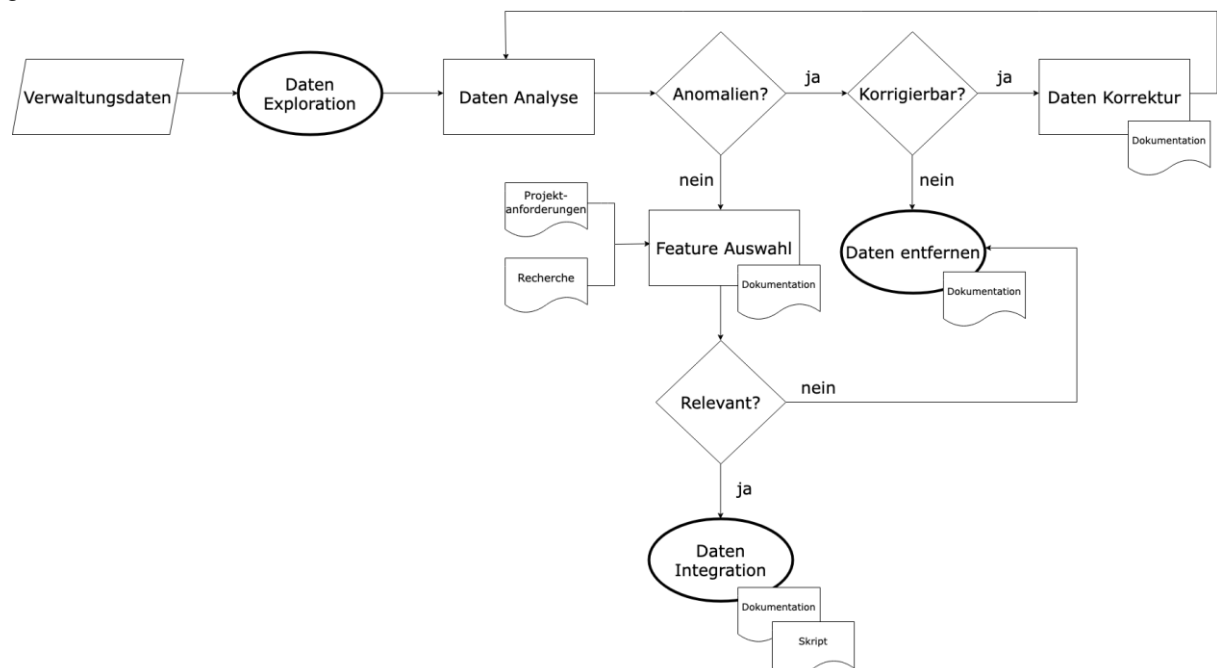


Abbildung 1: Schematische Darstellung des Datenintegrationsprozesses im Projekt DiSEA.

Da die Struktur der Quelldaten unterschiedlich war, haben wir einen neuen Datenbankentwurf erstellt (Abb. 2). Wir haben die einzelnen Werte nach dem Schlüsselverzeichnis für die Studenten- und Prüfungsstatistik, Promovierendenstatistik und Gasthörerstatistik aufbereitet<sup>6</sup>. Das Schlüsselverzeichnis, das vom Statistischen Bundesamt zur Verfügung gestellt wird, bietet eindeutige und universelle Schlüssel, die jeder nachschlagen kann.

<sup>6</sup> Stand: 31.05.2021.



Die *SemesterStatus*-Tabelle verwaltet für jeden Studenten für jedes Semester den aktuellen Studierstatus sowie das Fach- und Hochschulsemester. Die *Module*-Tabelle verwaltet zu jedem Modul den Modultitel, das Plansemester, den Studiengang und die Hochschule.

Die Tabelle *Pruefungen* verwaltet alle abgelegten Prüfungen der Studenten. Zu jeder Prüfung werden der Student, das Modul, die Prüfungsart und der Prüfungsstatus sowie die erreichte Note und der gezählte Versuch zu der Prüfung gespeichert.

Die *HZB*-Tabelle verwaltet für jeden Studenten die aktuelle Hochschulzugangsberechtigung, die Note, das Jahr des Erwerbs und die Art für die Zulassung zum aktuellen Studiengang, in dem er immatrikuliert ist. Die *Abschluesse*-Tabelle verwaltet für jeden Studenten alle erworbenen Abschlüsse der Studenten, darunter auch die Note, die Art und das Jahr des Erwerbs.

### 4.3 Vorhersage-Modelle zum Abbruch des Studiums

#### 4.3.1 Ansatz und Ergebnisse der Vorhersage für den Studiengang Medieninformatik

Für die Vorhersage haben wir ausschließlich die Daten der BHT und THL verwendet, da die Datenmenge aus der THB für die Berechnung unserer Vektoren nicht ausreichend war und Daten von anderen Standorten aus Datenschutz-Bedenken nicht zur Verfügung standen. Aufgrund signifikanter Änderungen in den Studienordnungen haben wir Daten vor dem Wintersemester 2014 für das Bachelorstudium "Medieninformatik", das 2001 gegründet wurde, ausgeschlossen. Wir erhielten von der THL Daten bis zum Wintersemester 2022 und von der BHT Daten bis zum Sommersemester 2023 von Studenten, die ihr Studium begonnen und entweder abgeschlossen haben oder aus dem Programm ausgeschieden waren, in diesem Zeitraum. Die Ergebnisse werden anonymisiert präsentiert.

	A			B		
	S1	S2	S3	S1	S2	S3
G	28	27	26 <sup>8</sup>	54	54	54
D	233	156	114	423	256	168
Total	261	183	140	477	310	222

Tabelle 1. Anzahl der Studierenden am Ende ihres 1. (S1), 2. (S2) oder 3. (S3) Semesters, die schließlich ihren Abschluss machten (G) oder das Studium abbrachen (D) an den Hochschulen A und B.

Tabelle 1 präsentiert die Anzahl der Studierenden am Ende des 1., 2., und 3. Semesters an den beiden Hochschulen, unterteilt nach ihrem Abschlussstatus „Absolvent (G)“ oder „Abbrecher (D)“. So zeigt sich beispielsweise, dass an der Hochschule (HS) A am Ende des 2. Semesters 183 Studierende eingeschrieben waren, von denen 156 ihr Studium abgebrochen haben (siehe Zeilen Total und D).

Die Gesamtsumme in Tabelle 1 verdeutlicht, dass an der HS B mehr Studierende eingeschrieben sind als an der HS A. Weiterhin zeigt die Tabelle auf, dass die Daten unausgewogen verteilt sind: nur rund 15% (27 von 183) der Studierenden, die sich im zweiten Semester befinden, haben ihren Abschluss an der HS A gemacht (G), im Vergleich zu 19% in B. Die Daten sind an der HS B ausgeglichener als an der HS A, und das Ungleichgewicht nimmt von Semester zu Semester ab (geringer im dritten Semester (S3) als im zweiten (S2), als im ersten (S1)).

<sup>8</sup> Die Diskrepanz in der Anzahl der Absolvent\*innen an der HS A ist auf Inkonsistenzen in den ursprünglich ungefilterten Daten zurückzuführen. Wir verfügen über die Informationen zum Abschlussstatus aller Studierenden, jedoch nicht über die entsprechenden Noten für alle Semester ihres Studiengangs. Daher verlieren wir einen Studierenden im 2. und 3. Semester.

Unser Fokus liegt auf der Vorhersage des Studienabbruchs oder des erfolgreichen Abschlusses nach dem 1., 2. oder 3. Semester. Die Datenanalyse hat ergeben, dass die Mehrheit der Studierenden ihr Studium innerhalb der ersten drei Semester abbricht. Wir haben separate Prognosen für die Studierenden an beiden Hochschulen durchgeführt und dann die Daten der Studierenden beider Hochschulen zu einem gemeinsamen Datensatz zusammengeführt. Dies ist aufgrund der identischen Kurse und Lehrpläne der Studiengänge in der ganzen VFH möglich.

M01_1_N	M02_1_N	M03_1_N	M04_1_N	M05_1_N	M06_1_N
5.0	2.3	3.3	5.1	5.0	5.1

Tabelle 2: Vektorielle Repräsentation eines Studierenden am Ende des ersten Semesters.

**Feature Set.** Um die Studierenden zu repräsentieren, haben wir eine Reihe von Kursen als Merkmale verwendet. Unsere Datenexploration hat gezeigt, dass die Studierenden zwar nicht strikt an den Plan des Studienhandbuchs sich halten müssen, aber die meisten von ihnen dies in ihrem ersten Studiensemester tun. Da die meisten Studierenden Teilzeit studieren, belegen nur wenige von ihnen alle Kurse eines Semesters, wie im Modulhandbuch beschrieben. Dies bedeutet, dass für jede Lehrveranstaltung fehlende Werte vorliegen. Da alle Kurse des ersten, zweiten und dritten Semesters verpflichtend sind und Studierende früher oder später alle bestehen müssen, um ihren Abschluss zu machen, haben wir uns entschieden, einen Wert nahe 5,0 (nicht bestanden) als fehlenden Wert zu wählen. Die Wahl eines höheren Wertes als 5,0, z. B. 6,0, könnte als Strafe wirken, was nicht getan werden sollte, da viele Studierende in Teilzeit studieren. Eine solche Darstellung ist in Tabelle 2 dargestellt. M01, M02, ..., M06 sind die Codes der sechs Pflichtmodule des 1. Semesters, wie sie im Modulhandbuch beschrieben sind. Der in Tabelle 2 dargestellte Studierende hat die Module M01 und M05 nicht bestanden (M01\_1\_N und M05\_1\_N haben den Wert 5,0), die Module M02 und M03 mit den Noten 2,3 bzw. 3,3 bestanden und die Module M04 und M06 nicht belegt (M04\_1\_N und M06\_1\_N haben den fehlenden Wert 5,1). Ein Studierender ist am Ende des 1. Semesters durch sechs Merkmale repräsentiert, die den im Modulhandbuch vorgesehenen sechs Pflichtmodulen entsprechen.

Um den Studienabbruch oder den Studienerfolg am Ende des zweiten Semesters vorherzusagen, wurden alle für die ersten beiden Semester im Studienhandbuch vorgesehenen Kurse herangezogen. Die Repräsentation erfolgte in der gleichen Weise wie oben beschrieben. Um die Historie zu berücksichtigen, wiederholten wir die Kurse des ersten Semesters. Tabelle 3 zeigt die Merkmale, die zu den Merkmalen des ersten Semesters hinzugefügt werden, um den Studienabbruch am Ende des zweiten Semesters vorherzusagen.

Der Student hat erneut M01 belegt und bestand den Kurs mit einer Note von 1,7 (M01\_2\_N = 1,7). Da Studierende ein bestandenes Modul nicht wiederholen können, wurden die Werte von M02\_2\_N und M03\_2\_N aus Tabelle 2 übernommen, da diese die Werte von M02\_1\_N und M03\_1\_N darstellen. Der Student hat sich für den Kurs M12 im zweiten Semester eingeschrieben und bestand ihn mit einer Note von 1,7, aber den Kurs M11 nicht belegt (M11\_2\_N = 5,1).

Bei der Vorhersage des Studienabbruchs am Ende des zweiten Semesters wird ein Student also durch 18 Merkmale repräsentiert: die sechs Merkmale, die die Noten des ersten Semesters anzeigen, und 12 zusätzliche Merkmale, die die Noten (oder fehlenden Werte) anzeigen, die er/sie im zweiten Semester für Kurse des ersten und zweiten Semesters laut Handbuch erhalten hat.

M01_2_N	M02_2_N	...	M11_2_N	M12_2_N
1.7	2.3	...	5.1	1.7

Tabelle 3: Zusätzliche Merkmale am Ende des 2. Semesters.

Für den Aufbau der vektoriellen Repräsentation am Ende des dritten Semesters haben wir ein ähnliches Vorgehen wie im zweiten Semester angewendet.

**Training, Testen und Abstimmung der Hyperparameter.** Wir haben eine klassische 5-fache Kreuzvalidierung durchgeführt, um die Modelle zu trainieren und zu testen, und zeigen die durchschnittlichen Ergebnisse. Während des Trainings der Modelle führten wir erneut eine (verschachtelte) Fünffach-Kreuzvalidierung zur Hyperparameter-Optimierung mit Hilfe einer Gittersuche durch.

**Algorithmen.** Wir haben den binären Entscheidungsbaum (DT) und die logistische Regression (LR), beide erklärbare Algorithmen, benutzt, damit die Ergebnisse der Vorhersage für unsere Akteure verständlich sind. Wir haben Python und die Bibliothek scikitlearn2 (<https://scikit-learn.org>) verwendet.

**Datenabgleich (Data Balancing).** Wir haben keinen Datenabgleich mit einem populären Ansatz wie SMOTE (Han et al. (2005)) durchgeführt, weil wir festgestellt haben, dass je nach Art wie die synthetischen Daten generiert werden, unterschiedliche Wege gewählt werden, um die Daten mit Entscheidungsbäumen aufzuteilen. Die Ergebnisse waren somit nicht vertrauenswürdig. Stattdessen haben wir die Option `class_weight = 'balanced'` verwendet, die in scikitlearn angeboten wird. Jede Instanz wird mit dem umgekehrten Verhältnis der Klassenhäufigkeit gewichtet. Somit haben die Instanzen der Minderheitenklasse ein höheres Gewicht als die Instanzen der Mehrheitsklasse.

**Evaluierung der Modelle.** Wir haben die folgenden Metriken verwendet:

*Accuracy (ACC):* Anteil der richtigen Vorhersagen.

*Recall (REC),* auch True-Positive-Rate (TPR) genannt: Anteil der Studierenden, die das Studium abgebrochen haben und deren Abbruch korrekt vorhergesagt wurde.

*Spezifität (SPE),* auch „True Negative Rate“ (TNR) genannt: Anteil der Studierenden, die einen Abschluss gemacht haben und deren Abschluss korrekt vorhergesagt wurde.

*Balanced Accuracy (BAC):* Mittelwert aus REC (TPR) und SPE (TNR). Wir hielten diese Metrik für die wichtigste, da unsere Daten unausgewogen sind, und verwendeten sie für die Optimierung der Hyperparameter.

**Ergebnisse der Vorhersage.** Table 4 zeigt die Ergebnisse der Vorhersage nach dem ersten Semester (S1), dem zweiten Semester (S2) und dem dritten Semester (S3). In diesem Teil betrachten wir die Vorhersage, die mit den getrennten Datensätzen der beiden Hochschulen, den Spalten A und B, durchgeführt wurde. Betrachtet man beispielsweise die Spalte DT, dann S1 und die Metrik Recall (REC), so sieht man, dass der Algorithmus DT 91,0% der Studenten finden kann, die an der Hochschule B abgebrochen haben, und 98,0% an der Hochschule A. Wir stellen fest, dass die Werte für die Spezifität (SPE) am stärksten zwischen den Spalten variieren. Dies könnte auf die geringe Anzahl von Studierenden mit dem Status „Absolvent“ (G) in den Daten zurückzuführen sein. Wir stellen auch fest, dass die Werte der Metriken in der Hochschule B tendenziell etwas höher sind als in der Hochschule A. Dies könnte auf den größeren Datensatz der Hochschule B zurückzuführen sein. Man beachte jedoch, dass DT bessere Ergebnisse als LR für S1 an der Hochschule B liefert.

	DT						LR					
	S1		S2		S3		S1		S2		S3	
	B	A	B	A	B	A	B	A	B	A	B	A
<b>BAC</b>	<b>92.0</b>	74.0	78.4	68.0	85.8	74.4	89.8	82.4	80.4	69.0	83.2	71.3
<b>REC</b>	91.0	<b>98.0</b>	96.8	92.5	77.8	88.8	90.8	89.8	80.8	87.9	80.6	82.6
<b>SPE</b>	<b>93.4</b>	50.0	60.0	43.7	93.0	60.0	88.9	75.0	80.0	50.0	85.7	60.0
<b>ACC</b>	91.4	<b>94.0</b>	90.8	87.0	82.6	83.6	90.6	88.7	80.6	83.8	82.2	78.6

Tabelle 4: Ergebnisse der Vorhersage für die Standorte A und B.

Wir haben diese Werte mit den Werten verglichen, die in anderen Arbeiten erzielt wurden, die lokale Merkmale verwendet haben. Die Recall-Werte sind in der Regel vergleichbar mit den Werten, die von Wagner et al. (2023) in drei Studiengängen mit fünf verschiedenen Algorithmen erzielt wurden, während die Werte für die Balanced Accuracy tendenziell etwas niedriger sind. Wir haben die Werte in Tabelle 4 auch mit den Werten verglichen, die von Manrique et al. (2019) in zwei Face-to-Face-Studienprogrammen mit vier verschiedenen Algorithmen ermittelt wurden. Die Recall- und Genauigkeitswerte sind tendenziell vergleichbar. Wie die Ergebnisse von Wagner et al. (2023), aber im Gegensatz zu den Ergebnissen von Berens et al. (2019) und Manrique et al. (2019), sind die Ergebnisse nicht besser, wenn die Vorhersage für ein höheres Semester gemacht wird. Zum Beispiel sinkt die Balanced Accuracy mit LR von 89,8 % bei B im ersten Semester auf 83,2 % im dritten Semester und bei A von 82,4% auf 71,3%. Dies könnte darauf zurückzuführen sein, dass die Datensätze kleiner werden (siehe Tabelle 1).

Wir haben die Datensätze zusammengeführt, um den Abbruch für die zwei Standorte gemeinsam vorherzusagen. Es ist keine allgemeine Verbesserung der Ergebnisse zu erkennen, siehe Merceron et al. (2024). Es ist interessant, eine Parallele zu den Arbeiten von Wagner et al. (2023) zu ziehen. Die Autoren haben globale Merkmale wie Durchschnittsnote, Anzahl bestandene Kurse usw. zur Vorhersage des Studienabbruchs verwendet, was die Zusammenführung von Daten aus verschiedenen Studiengängen ermöglicht. Das mit einem Datensatz trainierte Modell nach der Zusammenführung der Daten aus den drei Studiengängen schnitt nicht gleich gut ab, wenn es mit Daten aus den einzelnen Studiengängen getestet wurde.

**Features und Kurse, die die Vorhersage am meisten beeinflussen.** Wir schlagen vor, eine Liste der Kurse zu erstellen, die den größten Einfluss auf die Vorhersage haben, und zwar getrennt für jede Universität zu erstellen, da die Zusammenführung der beiden Datensätze keine besseren Ergebnisse brachte. Da es keinen klaren Gewinner gibt, verwenden wir die Ergebnisse beider Algorithmen, um eine solche Liste zu erstellen. Für jedes Modell listen wir die Features in der Reihenfolge ihrer Wichtigkeit für die Vorhersage auf. Bei den Entscheidungsbäumen wird die Wichtigkeit durch die Anzahl der Elemente im Knoten gemessen. Derzeit berücksichtigen wir Knoten, die mindestens 10 % des Datensatzes enthalten. Diese Grenze sollte mit unseren Interessengruppen besprochen werden. Bei der logistischen Regression wird die Reihenfolge durch den Wert der Koeffizienten bestimmt. Für jedes Modell wählen wir die sieben wichtigsten Merkmale aus, falls das Modell mehr als sieben wichtige Merkmale verwendet. Die Zahl 7 wurde gewählt, um die Übersicht nicht mit zu vielen Merkmalen zu überfrachten. Dann werden Kurse extrahiert, die in diesen Features erscheinen. Die Kurse, die mindestens drei Mal erscheinen, bilden die Liste der Kurse, die sich am stärksten auf die Vorhersage auswirken, siehe Merceron et al. (2024) für eine genauere Beschreibung des Ansatzes. Tabelle 5 zeigt die Liste der wichtigsten Kurse für die zwei Standorte. Man merkt, dass die zwei Listen nur einen Kurs gemeinsam haben, das Modul M02. Man merkt auch, dass die zwei Listen

hauptsächlich Kurse enthalten, die im 1. Semester im Modulhandbuch geplant sind, bis auf M08, Liste A, und M09, Liste B, beide im 2. Semester geplant. Eine erste Diskussion mit den Beteiligten hat jedoch gezeigt, dass eine solche Liste ohne Kontext nicht sehr hilfreich ist. Die erzeugten Entscheidungsbäume und Koeffizienten sollten den Akteuren auch gezeigt werden, siehe Merceron et al. (2024).

A	B
M03 Kommunikation, Führung und Selbstmanagement	M02 Grundlagen der Programmierung 1
M04 Grundlagen der Mathematik	M01 Einführung in die Informatik
M06 Computerarchitektur und Betriebssysteme	M09 Mensch-Computer-Kommunikation
M02 Grundlagen der Programmierung 1	M05 Mediendesign 1
M08 Mediendesign 2	

Tabelle 5: Listen der für die Vorhersage wichtigsten Kurse für die Standorte A und B.

Wir haben acht Studiengangsleiter und Lehrkräfte von fünf verschiedenen Hochschulen des Netzwerks unsere Ergebnisse und unseren Ansatz zur Ermittlung wichtiger Kurse vorgestellt. Die Beteiligten fanden die Ergebnisse verständlich, und ihr Feedback war positiv. Sie sahen das Potenzial, auf mögliche problematische Kurse für das Qualitätsmanagement hinzuweisen und die Einführungsveranstaltung zu Beginn des ersten Semesters anders zu gestalten. Einer schlug vor, dass Studierende zu Beginn ihres Studiums besser über kritische Kurse informiert werden sollten.

#### 4.3.2 Ansatz und Ergebnisse der Vorhersage im Studiengang Wirtschaftsinformatik

Für die Vorhersage haben wir ausschließlich die Daten vom BHT-Standort verwendet, da weder THL noch THB diesen Studiengang anbieten. Daten aus anderen Standorten standen aus Datenschutz-Bedenken nicht zur Verfügung. Derselbe Ansatz, wie im Studiengang Medieninformatik mit der Nutzung von lokalen Features, konnte nicht verwendet werden. Aufgrund signifikanter Änderungen in den Studienordnungen hätten wir Daten vor dem Wintersemester 2017 ausschließen müssen. Es blieben zu wenig Daten übrig, um sinnvoll Modelle zu trainieren. Wir haben globale Features berechnet und sie für die Repräsentation der Studierenden verwendet. Ansonsten sind Training, Testen und Abstimmung der Hyperparameter, Algorithmen, Datenabgleich (Data Balancing), Evaluierung der Modelle gleich geblieben. Wir erhielten Daten seit Gründung des Studiengangs im Wintersemester 2008 bis zum Sommersemester 2023 von Studierenden, die ihr Studium begonnen und entweder abgeschlossen haben oder aus dem Programm ausgeschieden waren, in diesem Zeitraum.

	S1	S2	S3	S4
G	107	107	107	107
D	173	108	74	62
Total	280	215	181	169

Tabelle 6. Anzahl der Studierenden am Ende ihres 1. (S1), 2. (S2), 3. (S3) oder 4. (S4) Semesters, die schließlich ihren Abschluss machten (G) oder das Studium abbrachen (D).

**Feature Set.** Um die Studierenden zu repräsentieren, haben wir, orientiert an (Berens et al. 2019), 4 so-genannte globale Features berechnet und verwendet: die Anzahl der Kurse, die in einem Semester erfolgreich abgeschlossen wurden (**no\_passed\_courses**), die Anzahl der Kurse, die in einem Semester nicht bestanden wurden (**no\_failed\_courses**), die Anzahl der Kurse, die belegt wurden, aber wofür es keine Note gibt (**no\_unattempted\_courses**) und die Durchschnittsnote aller Prüfungen (**avg\_grade\_all\_courses**). Diese Features werden in jedem Fachsemester berechnet. Wie vorher, um die Historie zu berücksichtigen, wiederholten wir die Features vom 1.Semester, um Studierende im 2. Semester zu repräsentieren. Der in Tabelle 7 dargestellte Studierende hat im 1.Semester einen Kurs erfolgreich abgeschlossen und einen Kurs nicht bestanden. Die Durchschnittsnote dieser zwei Kurse ist 4.2. Da **no\_unattempted\_courses** 0 ist, wurden nur 2 Kurse im 1.Semester belegt. Im 2. Semester hat dieser Studierende wieder 2 Kurse belegt und beide wurden nicht bestanden. Somit ist die Durchschnittsnote 5.0.

passed_1	failed_1	unappted_1	avg_grad_e_1	passed_2	failed_2	unattented_2	avg_grad_e_2
1	1	0	4.2	0	2	0	5.0

Tabelle 7: Vektorielle Repräsentation eines Studierenden am Ende des zweiten Semesters. Für eine bessere Lesbarkeit wurden die Namen der Features gekürzt.

Bei der Vorhersage des Studienabbruchs am Ende des dritten Semesters wird ein Student also durch 12 Merkmale oder Features repräsentiert, und am Ende des 4.Semesters durch 16 Merkmale.

**Ergebnisse der Vorhersage.** Table 8 zeigt die Ergebnisse der Vorhersage nach dem ersten Semester (S1), dem zweiten Semester (S2), dem dritten Semester (S3), und dem vierten Semester (S4). Betrachtet man beispielsweise die Spalte DT, dann S3 und die Metrik Recall (REC), so sieht man, dass der Algorithmus DT 73.6% der Studenten finden kann, die abgebrochen haben. Wir stellen fest, dass die Werte für die Spezifität (SPE) besser sind als die Werte für Recall (REC). Dies könnte vor allem ab dem 3.Semester auf die geringe Anzahl von Studenten mit dem Status „Abbruch“ (D) in den Daten zurückzuführen sein. Man beachte, dass LR bis auf den Wert in der Spalte S4, Zeile SPE, bessere Ergebnisse als DT liefert.

	DT				LR			
	S1	S2	S3	S4	S1	S2	S3	S4
<b>BAC</b>	68.79	72.28	78.22	79.53	73.31	78.59	83.93	80.5
<b>REC</b>	59.28	72.22	73.63	68.54	62.14	73.3	78.97	74.66
<b>SPE</b>	78.3	72.35	82.80	90.51	84.48	83.85	88.89	86.33
<b>ACC</b>	66.57	72.16	79.08	82.22	70.5.	78.47	84.72	82.22

Tabelle 8: Ergebnisse der Vorhersage für die Standorte A und B.

Wenn wir diese Werte mit den Werten der Tabelle 4 vergleichen, merken wir, dass sie insgesamt weniger gut sind. Manrique et al. (2019) haben beobachtet, dass die Vorhersage mit globalen Features weniger gute Ergebnisse als die Vorhersage mit lokalen Features liefert; diese Beobachtung wurde in (Wagner et al. 2023) jedoch nicht bestätigt. Die Ergebnisse sind auch im 1. und 2. Semester weniger gut als die Ergebnisse in (Berens et al. 2019). Es ist möglich, dass die globalen Features, die wir verwenden, für unsere Fallstudie nicht die richtigen sind. Eine künftige Arbeit wäre, diesen Feature-Engineering Step zu vertiefen, und andere globale Features zu berechnen und zu verwenden.

**Features, die die Vorhersage beeinflussen.** Wir betrachten nur die Logistic Regression und nur die Vorhersage nach dem 3. Semester, weil dieser Algorithmus in diesem Fall die besseren Ergebnisse liefert. Die Abbildung 3 zeigt die Koeffizienten der Features. Die Koeffizienten liefern keine neuen Erkenntnisse: je mehr Kurse Studierende im Semester 3, 2 oder 1 absolvieren, desto mehr steigt die Wahrscheinlichkeit, dass sie das Studium abschließen.

variable	coefficient
no_passed_courses_3	0.281630
no_passed_courses_2	0.260480
no_passed_courses_1	0.144860
avg_grade_all_courses_3	0.000000
no_of_failed_courses_1	0.000000
no_of_unattempted_courses_1	0.000000
avg_grade_all_courses_2	-0.189390
no_of_failed_courses_2	-0.225760
no_of_unattempted_courses_3	-0.359860
no_of_failed_courses_3	-0.424560
avg_grade_all_courses_1	-0.476920
no_of_unattempted_courses_2	-0.818090

Abbildung 3: Koeffizienten der Logistic Regression für die Vorhersage am Ende des 3. Semesters.

## 4.4 Ist-Analyse und Datenvorbereitung der Daten aus Lernmanagementsystem

### 4.4.1 Ist-Analyse der Moodle-Daten

Im Rahmen des *DiSEA*-Projekts benutzen wir ausschließlich Moodle-Logs von Nutzern, die der Verwendung ihrer Daten über ein speziell entwickeltes Einwilligungs-Plugin zugestimmt haben. Dieses Plug-in wurde nur in Kursen für die Online-Studiengänge Wirtschaftsinformatik und Medieninformatik aktiviert. Beim ersten Zugriff auf einen Kurs müssen die Nutzer entscheiden, ob sie ihre Daten mit unserem Projekt teilen möchten oder nicht. Wenn sie der Verwendung ihrer Daten zustimmen, erhalten wir Zugriff auf alle ihre Log-Daten der letzten 30 Tage. Es ist jedoch zu beachten, dass auch Studierende aus anderen Studiengängen des VFH-Hochschulverbunds in einen der Wirtschaftsinformatik- oder Medieninformatik-Kurse sich einschreiben können, was bedeutet, dass das gesammelte Log auch Einträge über Studierende aus anderen Studiengängen enthalten kann. Der Datensatz ändert sich ständig, da entweder neue Nutzer der Verwendung ihrer Log-Daten zustimmen oder bestehende Nutzer ihre Zustimmung zurückziehen.

Moodle verwendet eine relationale Datenbank (DB), in unserem Fall MySQL, um seine Daten zu speichern. Im Rahmen unseres Projekts sammeln wir die Logs alle 7 Tage mithilfe einer spezifischen SQL-Abfrage, die zu Beginn des Projekts entwickelt wurde. Diese SQL-Abfrage greift direkt auf die Moodle-DB der VFH zu und sammelt ausschließlich Logdaten von Nutzern, die ihre Zustimmung zur Datenverwendung erteilt haben. Die gesammelten Logs werden anschließend verschlüsselt und in einer CSV-Datei gespeichert, die zum Download bereitsteht. Um die sensiblen Informationen in unseren Logs zu schützen, haben wir uns entschieden, diese auf Serverebene zu verschlüsseln, so dass nur verschlüsselte Daten zum Herunterladen verfügbar sind. Die Download-Option ist in das Zustimmungs-Plugin als versteckte Schaltfläche integriert, die nur für autorisierte Mitarbeiter\*innen sichtbar ist. Neben den Log-Daten enthält die heruntergeladene Datei auch eine Tabelle mit der Liste der Nutzer, die ihre Einwilligung innerhalb der letzten sieben Tage zurückgezogen haben. Da wir im

Projekt nur Daten von Nutzern mit aktiver Einwilligung verwenden, nutzen wir diese Informationen, um alle Log-Daten der Nutzer zu löschen, die ihre Einwilligung zurückgezogen haben. Dieser Prozess stellt sicher, dass wir die Privatsphäre und die Rechte der Nutzer schützen.

Ursprünglich wurden die Moodle-Logs nicht für Data-Mining-Analysen konzipiert, sondern dienen hauptsächlich der Wartung des Lernmanagementsystems. Aufgrund dessen sind viele dieser Felder für die Zwecke unseres Projekts nicht relevant. Daher haben wir die oben genannte SQL-Abfrage so gestaltet, dass sie nur solche Spalten auswählt, die für die Definition von *tasks* (vgl. 4.4.2) relevant sind, während alle anderen verworfen werden. Im Kontext unseres Projekts definieren wir ein *event* als ein Tripel, das aus *component*, *target* und *action* besteht.

id	timecreated	userid	relateduserid	courseid	component	action	target
110051230	1642761738	1361	-2	0	core	sent	message

Tabelle 9: Beispiel für einen Log-Eintrag. Hier hat der Nutzer 1361 eine Nachricht über das Moodle-Nachrichtensystem an einen anderen Nutzer (=relateduserid) geschickt, der der Verwendung seiner Daten nicht zugestimmt hat. Das *event* für diesen Fall wäre (*core*, *message*, *sent*).

Nach der Entschlüsselung der heruntergeladenen Daten wurden die Felder *userid* und *relateduserid*, die die IDs der Nutzer enthalten, pseudonymisiert. Bei Log-Einträgen, bei denen nur ein Nutzer zwischen *userid* und *relateduserid* der Verwendung seiner Daten zugestimmt hat, wurde der andere Nutzer auf -2 gesetzt (s. Tabelle 9).

Um die ständig wachsende Menge an Log-Daten zu bewältigen und nur die für unseren Zweck relevanten Daten aufzubewahren, war es unerlässlich, dass wir die Datenmenge reduzieren. Zu diesem Zweck haben wir drei Strategien entwickelt: a) Wir konzentrieren uns ausschließlich auf Logs, die Studierendenaktivitäten dokumentieren, und löschen die Log-Daten von anderen Moodle-Nutzern wie Systemadministrator, Gäste, Dozierende usw. b) Wir haben uns auf Komponenten konzentriert, die häufig genug auftreten (mindestens 600 Log-Einträge), um für die Analyse relevant zu sein. c) Wir haben uns auf Kurse mit mindestens 75 Einträgen konzentriert, um das Studierendenverhalten analysieren zu können.

#### 4.4.2 Datenvorbereitung der Moodle-Daten

Nach der Auswahl relevanter Log-Einträge müssen die Daten zunächst aufbereitet werden, bevor eine Analyse des Studierendenverhaltens durchgeführt werden kann. Für die Verarbeitung unserer Daten haben wir die von Rotelli und Monreale (2022, 2023) vorgestellte Methodologie angewandt, um eine Lernaktivitäten (*task*) zu definieren und deren Dauer zu berechnen. Eine *task* wird dabei als eine Sequenz von Interaktionen eines Nutzers innerhalb eines Lernmoduls betrachtet, wobei jede Interaktion durch einen einzelnen Log-Eintrag repräsentiert wird. Dieser Prozess umfasst drei Schritte: die Neudefinition und Anpassung der Komponenten, die Berechnung der Dauer und die Definition der *task*.

**Neudefinition und Anpassung der Komponenten.** In Moodle wird jedes Event durch eine Aktion beschrieben, die an einer Komponente, zu einem bestimmten Zeitpunkt, in einem bestimmten Kurs oder Bereich der Plattform durchgeführt wird. Die Komponenten entsprechen den Modulen der Plattform, wie Dashboard, Quiz, Aufgabe, *core* usw. Die *core*-Events werden auf der Systemebene von Moodle geloggt, obwohl sie Aktionen darstellen, die der Nutzer in bestimmten Modulen durchgeführt hat. Um Informationsverluste und ein mögliches Missverständnis des Nutzerverhaltens zu vermeiden, müssen die Events mit der Komponente *core* neu definiert werden. Dabei werden solche Events einer inhaltlich verwandten Komponente zugewiesen. Beispielsweise kann das Event, das durch das Triple (*core*, *course*, *viewed*) definiert wird, je nach Wert der Kurs-ID unterschiedliche

Bedeutungen haben. Es kann bedeuten, dass ein Nutzer entweder die Moodle-Startseite besucht hat oder die Startseite eines bestimmten Kurses aufgerufen hat.

Danach gehen wir dazu über, die verwandten Komponenten (*events*) aneinander anzupassen. Bei der Analyse der Komponenten haben wir festgestellt, dass einige semantisch verwandte Ereignisse über mehrere Komponenten verstreut sind. Z.B. sind "Dateieinsendungen", "Einsendungskommentare", "Online-Texteinsendungen" folgenden Komponenten zugeordnet worden: *assignsubmission\_file*, *assignsubmission\_comments* und *assignsubmission\_onlinetext*. Alle diese Werte wurden einer einzigen Komponente zugeordnet.

Da das LMS Moodle sehr flexibel und funktionsreich ist und die Installation mehrerer Plugins und E-Portfolios ermöglicht, fanden wir *events*, die in Rotelli & Monreale (2022) nicht beschrieben sind, wie (*mod\_bigbluebuttonbn*, *activity*, *viewed*). Ihre Methodik wurde angepasst, um diese Ereignisse zu behandeln und die Komponenten neu zu definieren.

**Berechnung der Dauer.** Nachdem wir den Datensatz durch die Neudefinition und Anpassung der Komponenten transformiert haben, fügen wir jedem Datensatz nun eine "Dauer"-Spalte hinzu. Unser Ziel ist es, aus den Events abzuleiten, wie viel Zeit der Nutzer mit Lernen auf der Moodle-Plattform verbracht hat. Um die Dauer von Events zu bestimmen, erstellen wir zunächst eine chronologisch geordnete Zeitreihe aller Events jedes Nutzers. Auf Basis dieser Zeitreihe und unter Berücksichtigung des jeweiligen Event-Typs<sup>9</sup> berechnen wir dann die Dauer eines Events.

**Definition der Task.** Nachdem die Komponenten neu definiert und mit der Dauer angereichert wurden, können die einzelnen Datensätze nun in sogenannte Tasks gruppiert werden. Ein Task kann definiert werden als eine Abfolge von Log-Einträgen mit der gleichen Komponente für einen Benutzer, die zusammen als eine einzelne, zielgerichtete Aktivität in einem Kurs oder einem bestimmten Bereich der Plattform interpretiert werden kann (z.B. Forum, Quiz, Einsendeaufgabe). Ein *task* besteht typischerweise aus einer Benutzer-ID, Komponente, Kurs-ID, Startzeit und Dauer.

#### 4.4.3 Aktivitätsregelmäßigkeit (*regularity*) und Kurserfolg

Die Aktivität der Studierenden in Moodle wurde mit ihren Leistungen (Noten), wenn vorhanden, verknüpft. Auf dieser Grundlage wurde ein neuer Datensatz erstellt, mit dem eine Analyse von Zusammenhängen zwischen Moodle-Aktivitäten und dem Kurserfolg der Studierenden durchgeführt wurde.

Unsere Analyse unterliegt folgenden Einschränkungen:

- Wir nutzen nur Moodle-Daten von Studierenden, die der Verwendung ihrer Daten für die Auswertung ausdrücklich zugestimmt haben<sup>10</sup>.
- Wir haben Zugriff nur auf die von Moodle registrierten Aktivitäten, ohne Interaktions-Daten aus Loop oder anderen Authoring Tools für die Erstellung des interaktiven Lernmaterials.
- Wir haben nur Moodle-Daten mit akademischen Daten aus drei Hochschulsemestern verknüpfen können, die zwischen den Sommersemestern 2022 und 2023 liegen, als aufgrund der Corona-Pandemie Ausnahmeregelungen an den Hochschulen des Verbunds galten. Zwischenzeitlich wurde die Note 5 nur dann in den akademischen Daten eingetragen, wenn ein Täuschungsversuch vorlag. Ansonsten wurde bei einer durchgefallenen Prüfung keine Note in den Daten festgehalten.
- Die Studierenden können ein Modul belegen, ohne an der Prüfung teilzunehmen. In diesem Fall wird die Aktivität in Moodle beobachtet, jedoch wird keine Note in den Verwaltungsdaten eingetragen. Diese Fälle sind in den Daten nicht von den Fällen mit durchgefallenen Prüfungen ohne Note zu unterscheiden, obwohl sie sich inhaltlich deutlich unterscheiden.

---

<sup>9</sup> Laut der Systematik von Rotelli & Monreale (2023) gibt es in Moodle 5 Typen von Events. Abhängig vom jeweiligen Event-Typ wird für die Berechnung der Dauer eine spezifische Formel angewendet.

<sup>10</sup> Nur ein kleiner Teil der Studierenden (7% der Studierenden aus dem Studiengang Bachelor Medieninformatik) hat der Verwendung ihrer Daten zugestimmt.

Die Nutzung der Kurse in Moodle ist sehr heterogen, was sich daraus erklärt, dass die Kurse in ihrer Struktur (z.B. Anzahl der Webkonferenzen, Anzahl der Einsendeaufgaben) sowie in der Anzahl der beteiligten Studierenden stark variieren. Darüber hinaus ist zu beachten, dass viele Aktivitäten, die für die Beurteilung des Kurserfolgs relevant sind, nicht in Moodle erfasst werden, da in vielen Kursen das multimediale Lernmaterial mit Authoring Tools erstellt wird, die unabhängig von einer Lernplattform sind; die Interaktion mit z.B. Tests aus diesem Lernmaterial werden als Moodle-Log Daten nicht erfasst. Zudem können Aktivitäten, die über Moodle-Plugins angeboten werden und normalerweise von Moodle verfolgt werden, auch ohne die Plattform genutzt werden. Ein Beispiel hierfür ist die Teilnahme an einer BigBlueButton-Webkonferenz: Studierende müssen nicht unbedingt über Moodle darauf zugreifen, sondern können den Zugang auch über den von ihnen gespeicherten Link nutzen. Dies erschwert die Auswahl relevanter Aktivitäten, die mit dem Erfolg der Studierenden in Zusammenhang stehen.

Da keine direkte Verbindung zwischen Aktivitätstyp und Kurserfolg bestand, entschieden wir uns, das Studierendenverhalten in Moodle unabhängig vom Aktivitätstyp zu analysieren. Im Rahmen dieser Analyse untersuchten wir, ob Studierende mit regelmäßiger Aktivität in Moodle bessere Ergebnisse in den Modulen erzielten, wie in (Shirvani Boroujeni et al., 2016) untersucht.

Die Aktivitätsregelmäßigkeit (*Regularity*) in Moodle misst, ob die Studierenden über die Wochen des Kurses hinweg an ähnlichen Wochentagen arbeiten (vgl. Shirvani Boroujeni et al., 2016). *Regularity* lässt sich durch eine Zahl zwischen 0 und 1 ausdrücken. Der Maximalwert 1 wird erreicht, wenn der Studierende jede Woche an genau denselben Tagen aktiv ist. Shirvani Boroujeni et al. (2016) haben eine Korrelation von 0.9 zwischen der wöchentlichen *Regularity* und Note in einem MOOC (Massiv Open Online Course) festgestellt: *Regularity* kann als Proxy für Zeitmanagement, Motivation und regelmäßiges Lernen betrachtet werden; Studierende, die sich regelmäßig mit dem Kurs beschäftigen erzielen bessere Note in der Prüfung.

**Zusammenhang zwischen Regelmäßigkeit und Kurserfolg.** Da Kurse aufgrund ihrer unterschiedlichen Charakteristika, Struktur und Teilnehmendenzahl sehr unterschiedlich sind, ist es nicht sinnvoll, eine pauschale Berechnung der Korrelation für alle Kurse zu versuchen. Deswegen haben wir uns entschieden, die Korrelation zwischen Regelmäßigkeit (*Regularity*) und Note im Kurs kursweise zu berechnen, um die Beziehung zwischen diesen beiden Variablen in jedem Kurs einzeln zu untersuchen. Ein Nachteil der kursweisen Korrelationsanalyse ist die geringe Anzahl an Teilnehmenden in den Kursen, was die Berechnung weniger aussagekräftig macht, und dies obwohl wir die Daten der Standorte und der 3 Semester aggregiert haben.

Um die lineare Beziehung zwischen der Regelmäßigkeit (*Regularity*) und der Note zu untersuchen, wurde der Pearson-Korrelationskoeffizient (r-Wert) wie in (Shirvani Boroujeni et al., 2016) berechnet. Der Koeffizient ist leicht zu interpretieren, da er zwischen -1 und 1 liegt. Ein Wert von 1 bedeutet eine vollkommene positive, während ein Wert von -1 eine vollkommene negative Korrelation bedeutet. In unserem Fall ist es umgekehrt: ein hoher negativer Wert bedeutet, dass Studierende, die regelmäßig in Moodle aktiv waren, tendenziell bessere Noten erzielten als Studierende, die weniger aktiv waren. Dies liegt daran, dass im deutschen Bildungssystem die besten Noten (1) die niedrigsten Werte und die schlechtesten Noten (5) die höchsten Werte auf der Skala darstellen.

Um die Signifikanz der Korrelation richtig zu interpretieren, haben wir neben dem Pearson-Korrelationskoeffizienten auch den p-Wert berechnet. Dabei gilt: wenn der p-Wert kleiner als 0,05 ist, ist die Korrelation statistisch signifikant, d.h. die Wahrscheinlichkeit, dass die Korrelation durch Zufall entstanden ist, ist kleiner als 5%. Wenn der p-Wert hingegen größer oder gleich 0,05 ist, kann die Korrelation nicht als statistisch signifikant betrachtet werden, was darauf hinweist, dass die Korrelation möglicherweise durch Zufall entstanden ist.

Im Folgenden werden die Kurse aus dem Studiengang Bachelor Medieninformatik näher analysiert, die den größten Einfluss auf die Vorhersage haben (s. 4.3.1, Tabelle 5).

	Grundlagen der Programmierung 1	Mensch-Computer-Kommunikation	Mediendesign 1	Mediendesign 2	Einführung in die Informatik
Koeffizient	0.10	-0.23	-0.43	0.08	-0.47
p-Wert	0.73	0.23	0.12	0.68	0.04
Teilnehmer	54	65	44	53	47

Tabelle 10.1: Pearson-Korrelationskoeffizient, p-Wert und Teilnehmerzahl für die Kurse mit dem größten Einfluss auf die Vorhersage im Studiengang Medieninformatik (Teil 1).

	Grundlagen der Mathematik	Kommunikation, Führung und Selbstmanagement	Computerarchitektur und Betriebssysteme
Koeffizient	-0.55	-0.71	-0.23
p-Wert	0.04	0.01	0.39
Teilnehmer	41	29	38

Tabelle 10.2: Pearson-Korrelationskoeffizient, p-Wert und Teilnehmerzahl für die Kurse mit dem größten Einfluss auf die Vorhersage im Studiengang Medieninformatik (Teil 2).

Unsere Analyse zeigt, dass in einigen der ausgewählten Kurse keine signifikante Beziehung zwischen der Regelmäßigkeit der Aktivität in Moodle und der Note festgestellt werden kann. In insgesamt fünf Modulen konnten wir so gut wie keine Korrelation zwischen diesen beiden Variablen nachweisen. Die Ergebnisse in zwei Kursen liegen im positiven Bereich und sind zu klein (0.10 und 0.08), in den restlichen drei im negativen Bereich. Allerdings ist die Stärke der Korrelation in den negativen Fällen zu schwach, um eine signifikante Beziehung festzustellen. Im spezifischen Fall der Module "Mensch-Computer-Kommunikation" und "Computerarchitektur und Betriebssysteme" sind die Koeffizientenwerte zu gering (größer als -0.3), um eine Korrelation zu belegen. Im Modul "Mediendesign 1" liegt der r-Wert im mittleren Bereich (-0,43), jedoch ist der p-Wert zu hoch, was bedeutet, dass die Korrelation keine statistische Signifikanz aufweist.

In den Modulen "Einführung in die Informatik" und "Grundlagen der Mathematik" zeigt sich eine statistisch signifikante Korrelation zwischen Aktivitätsregelmäßigkeit und Note, wie durch den p-Wert deutlich wird. Für diese beiden Kurse liegt eine mittlere Beziehung zwischen *Regularity* und erzielter Leistung im Kurs.

Nur im Modul "Kommunikation, Führung und Selbstmanagement" zeigte sich eine starke Korrelation zwischen Aktivitätsregelmäßigkeit und Note, wie durch den Pearson-Korrelationskoeffizienten im negativen Bereich mit einem hohen Wert ( $-r > 0,7$ ) deutlich wird. Diese Korrelation ist auch statistisch signifikant, da der p-Wert unter 0,05 lag. Dieses Ergebnis deutet darauf hin, dass es in diesem Modul eine klare Beziehung zwischen Aktivitätsregelmäßigkeit und Note gibt, d.h. dass Studierende, die regelmäßig aktiv waren, tendenziell bessere Noten erzielten als Studierende, die weniger aktiv waren.

Das Ergebnis dieser Analyse zeigt, dass die Beziehung zwischen Aktivitätsregelmäßigkeit und Note in den verschiedenen Kursen unterschiedlich ist und dass es schwierig ist, eine allgemeine Aussage über die Korrelation zwischen diesen beiden Variablen zu machen.

Um belastbare Ergebnisse zu erzielen und die Korrelation zwischen Aktivitätsregelmäßigkeit und Note in den verschiedenen Kursen besser zu verstehen, wäre es wichtig, eine größere und repräsentativere Stichprobe von Daten zu haben, die über einen längeren Zeitraum und von einer größeren Anzahl von Teilnehmenden gesammelt wurden. Darüber hinaus sollte die Verfolgung der Daten über Authoring-Tools so gestaltet werden, dass alle Aktivitäten mit dem Lernmaterial nachverfolgt werden können.

## 4.5 Akzeptanz und Wirksamkeit von Dashboards zur Anzeige studienrelevanter Daten

Das AP wird federführend vom Projektpartner THL bearbeitet.

Das Lernenden-Dashboard wurde im Projektverlauf entwickelt und nutzt vielfältige Aktivitätsdaten aus Moodle. Um die spätere Akzeptanz des Dashboards für Studierende, das auf personenbezogenen Daten basiert, zu sichern, wurden mehrere Faktoren im Vorfeld beachtet. Dazu zählen die Auswahl der ausgelesenen Daten, die Art und Weise der Speicherung und Verarbeitung dieser Daten sowie, wie mit ihnen umgegangen wird. Darüber hinaus spielen die Präsentation der Analyseergebnisse und die Zielgruppe, an die sie gerichtet sind, eine wichtige Rolle. Um die Wünsche und Bedürfnisse der Studierenden besser zu verstehen, wurden an der BHT im Sommer 2022 unter Mitwirkung der Studierenden des Kurses "Ethik in der IT-Sicherheit" ethische Leitlinien (<https://disea-projekt.de/index.php/ethische-leitlinien/>) erarbeitet, die für alle Mitarbeitenden des DiSEA-Projekts maßgeblich sind.

Die Auswertung und anschließende Veröffentlichung weiterer Studierendenbefragungen an der VFH zu den Erwartungen und Bedürfnisse der Online-Studierenden an ein Lernenden-Dashboard wurde vor allem vom Partner TH Lübeck ausgeführt, sowie die Entwicklung des Dashboards und seine Einbindung in Kursen. Es fand hierzu ein regelmäßiger Austausch von Rechercheergebnissen statt. Analysen von Usability und Akzeptanz wurden jedoch gemeinsam mit dem Projektpartner TH Lübeck vorgenommen. Die Gestaltung des Dashboards berücksichtigt die kognitive Belastung der Nutzer. An der BHT wurde das Dashboard in ausgewählten Kursen freigeschaltet.

#### **4.6 Entwicklung eines integrierten Learning-Analytics-Konzeptes für digitale Studienformate**

Ein integriertes Learning-Analytics-Konzept als solches konnte nur in Grundzügen entwickelt werden, da die durchgeführte Analyse der Moodle-Log Daten keinen verlässlichen Zusammenhang zwischen Verhalten in Moodle und Note im Kurs gezeigt hat. Wie in 4.4.3 geschrieben, vermuten wir, dass es daran liegt, dass wir nicht genügend Daten hatten, um Zusammenhänge zu finden. Einerseits hatten wir nicht von allen Nutzern Daten, sondern nur von denen, die ihre Zustimmung gegeben haben. Andererseits hatten wir nur drei Semester von Log-Daten aus Moodle verknüpft mit akademischen Daten. Nicht alle Moodle-Daten eines Semesters können mit einer Note verknüpft werden. Da Online-Studierende Teilzeit studieren, belegen sie oft einen Kurs mehr als einmal und sind somit über mehrere (nicht unbedingt konsekutive) Semester mehr oder weniger für einen Kurs in Moodle aktiv. Das Semester mit der Note ist nicht unbedingt das Semester, in dem sie wirklich in Moodle aktiv waren.

Die Vorhersage des Abbruches im Studiengang Medieninformatik (stabiles Curriculum seit 2014) zeigt, dass es möglich ist, die Kurse zu identifizieren, die für den Abbruch am wichtigsten sind. Da die Vorhersage nur akademische Daten verwendet, die jede Hochschule per Gesetz speichern muss, könnte eine solche Vorhersage im Qualitätsmanagement der Lehre integriert werden. Solche Kurse könnten als erste für den Einsatz eines Dashboards ausgewählt werden.

Ein Dashboard wurde entwickelt, das den Erwartungen der Online-Studierenden für Ihre Selbstreflexion in Kursen entspricht. Die Gestaltung des Dashboards wurde regelmäßig mit dem Partner THL diskutiert. Mit einer besseren Datenlage könnten vermutlich Zusammenhänge zwischen Verhalten in Moodle und Note im Kurs gefunden werden und somit eine Rückmeldung zum Verhalten im Kurs bezüglich des zu erwartenden Erfolges im Dashboard integriert werden.

Alle diese Ergebnisse stehen in einem Moodle-Kurs allen Akteuren aller Standorte der VFH zur Verfügung.

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

Die Personalmittel für die geplanten wissenschaftlichen Mitarbeiter wurden z.T. verzögert abgerufen, durch verzögerte Einstellungen zu Projektbeginn sowie nach einer Kündigung eines Mitarbeiters und

der erneuten Ausschreibung der Stelle. Durch die kostenneutrale Verlängerung des Projektes um 8 Monate wurden die Personalmittel für die wissenschaftlichen Mitarbeiter zeitlich verzögert verausgabt.

Sehr erfolgreich verstärkt wurde das Team durch studentische Mitarbeiter, die aufgabenbezogen eingestellt wurden und deren Mittel bis Projektende wie geplant abgerufen wurden.

Dienstreisen wurden, wie vorab geplant, z.T. realisiert, z.T. wurden pandemiebedingt Konferenzbesuche abgesagt oder in Form von Videokonferenzen wahrgenommen.

#### *Personalkosten*

Eine wissenschaftliche Mitarbeiterin wurde am 01.05.2021 eingestellt, der zweite wissenschaftliche Mitarbeiter am 01.07.2021. Dieser kündigte zum 30.11.2021. Die Einstellung einer neuen wissenschaftlichen Mitarbeiterin konnte erst zum 01.08.2022 erfolgen. Beide erhielten Bezüge der Entgeltstufe TVL 13.

Aufgrund der schwierigen Personalsituation am Standort Berlin und des verspäteten Projektstartes wurde nur ein studentischer Mitarbeiter früh im Projektverlauf gewonnen. Dieser startete am 1.7.2021 und arbeitete im Projekt bis zum 31.8.2023. Ein weiterer studentischer Mitarbeiter wurde ab Q4/2022 gewonnen und blieb bis Projektende im Projektteam. Eine weitere studentische Mitarbeiterin wurde ab Q1/2023 gewonnen und arbeitete ein Jahr im Projekt. Ein weiterer studentischer Mitarbeiter konnte ab Q2/2024 die Arbeit im Projekt aufnehmen und ergänzte das Projektteam bis Projektende.

Ein Gastdozent sowie verschiedene Lehrbeauftragte vertraten die Professoren, die im Projekt mitwirkten, seit SoSe2021 bis einschließlich SoSe2024 in den Übungen und teilweise der Vorlesung in der Datenbanklehre. Die Aufwände dafür von 4 SWS wurden über Projektmittel abgegolten. Diese Mittel mussten im Projektverlauf verstärkt werden, da der Stundensatz für Lehrbeauftragte in der Projektlaufzeit angehoben wurde. Die Verstärkung wurde aus den Mitteln für wissenschaftliche Mitarbeiter vorgenommen.

#### *Dienstreisen*

Die geplanten Dienstreisen des wissenschaftlichen Mitarbeiters und der wissenschaftlichen Mitarbeiterinnen wurden teilweise wie geplant durchgeführt. So erfolgte die geplante Teilnahme an den jährlichen Symposien der Virtuellen Fachhochschule. Weitere Dienstreisen zu nationalen Konferenzen wurden teilweise durchgeführt, teilweise wurden sie ersetzt durch Online-Teilnahme. Europäische oder weltweite Dienstreisen wurden nicht durchgeführt.

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

Die Beschaffung der Daten war aufwändiger als geplant. Der Aufwand in der Kommunikation mit den Datenschutzbeauftragten und im Preprocessing der Einwilligung der Studierenden war notwendig, um das Vertrauen und die Akzeptanz aller Akteure, insbesondere der Studierende zu gewinnen und zu bewahren.

Die eingesetzten Methoden für die Datenmodellierung und Datenexploration wurden angemessen ausgesucht, um die weitere Analyse der Daten zu realisieren. Für die Vorhersage haben wir uns auf erklärbare Algorithmen konzentriert, da diese transparent und interpretierbar sind. Transparenz ist entscheidend, um sicherzustellen, dass die Entscheidungsprozesse hinter den Vorhersagen verständlich sind. Insbesondere in der Learning Analytics ist dies von wesentlicher Bedeutung, da die Ergebnisse direkt auf die Lehr- und Lernprozesse wirken. Wenn die Algorithmen transparent sind, können Stakeholder das Vertrauen in die Ergebnisse aufbauen. Die Interpretierbarkeit erklärbarer Algorithmen ermöglicht es, die Ergebnisse zu interpretieren und zu verstehen, wie die Algorithmen die Vorhersage treffen. Dies ist entscheidend, um die Akzeptanz der Ergebnisse bei den Stakeholdern zu

erhöhen und sicherzustellen, dass die Ergebnisse vertrauenswürdig, nachvollziehbar und benutzbar sind.

Die Analyse der akademischen Daten und der Moodle-Daten war notwendig, um die Projektziele zu erreichen, da die jetzige Forschung vor allem klassische Präsenz-Studiengänge betrachtet, und nicht Online-Studiengänge wie in diesem Vorhaben. Dies ist vermutlich der Tatsache geschuldet, dass Fernstudiengänge wie die Online-Studiengänge in diesem Vorhaben nur etwa 5% aller Studiengänge in Deutschland ausmachen, siehe (hochschulkompass 2024).

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

Die Verwertung der Projektergebnisse erfolgt einerseits unmittelbar an den Hochschulen des gesamten VFH-Verbundes durch die Bereitstellung eines VFH-Moodle-Kurses, der alle wichtigen Ergebnisse des Projektes enthält. Durch die regelmäßige Präsentation und Diskussion der Ergebnisse im jährlichen VFH-Symposium (am 24.10.2021, 09.06.2022, 15.06.2023, und 13.06.2024), sind die Akteure der VFH in der Lage, die Inhalte des Kurses sich anzueignen. Die Identifizierung von Kursen, die für die Vorhersage des Abbruchs am relevantesten sind, ist ein wesentliches Ergebnis unseres Vorhabens.

Andererseits wurden wesentliche Erkenntnisse auf Tagungen veröffentlicht und können von anderen Hochschulen und Interessierten verwertet werden.

Außerdem wurden die Ergebnisse dem Kompetenzzentrum "Digitale Medien<sup>11</sup> der BHT in Treffen am 30.09.2022 und am 16.08.2024 präsentiert. Da die Reduzierung der Abbrecherquote und die Erhöhung der Zufriedenheit der Studierenden wichtige Bestandteile von Fachbereichsstrategien der Berliner Hochschulen sind, sind die Ergebnisse dieses Projektes für die gesamte Hochschule relevant und können Auswirkungen haben.

Ferner wurden die Ergebnisse mit dem Berliner Zentrum für Hochschullehre (BZHL, <https://www.bzhl.tu-berlin.de>) in Treffen am 30.09.2022 und am 05.07.2024 diskutiert. Somit können Erkenntnisse aus dem DiSEA-Projekt in die innovativen Projekte des BZHL, in das Bildungsangebot und in die Beratung der Lehrenden von 13 staatlichen Hochschulen des Landes Berlin einfließen. Das BZHL referenziert unser Vorhaben auf der Ressourcenseite über Learning Analytics, <https://www.tu.berlin/bzhl/ressourcen-fuer-ihre-lehre/learning-analytics-an-hochschulen>.

Darüber hinaus wurden vier Datensätze im Sinne der Open Data veröffentlicht, siehe <https://zenodo.org/records/14025857>, und können für weitere Forschungsarbeiten genutzt werden.

An der BHT sind vier Bachelorarbeiten und drei Masterarbeiten zu den Projektthemen entstanden, eine weitere Masterarbeit wird im Dezember 2024 beginnen. Die Studierenden haben in ihren Abschlussarbeiten auf realen Datensätzen gearbeitet, was einen direkten Wissenstransfer in die Praxis ermöglicht hat.

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

Es wurden international weitere Arbeiten auf dem Gebiet der Vorhersage des Abbruchs eines Studienganges veröffentlicht, die sowohl die Daten als auch die Algorithmen betreffen. Z.B. wurde die Anwendung von demographischen Daten für die Vorhersage des Abbruchs in (Baker et al. 2023) oder in (Cohausz et al. 2022) kritisch diskutiert, was die Entscheidung, in diesem Projekt nur akademische Daten zu verwenden, bestätigt. Cai and Fleischhacker (2024) haben einen anderen Algorithmus für die Vorhersage vorgeschlagen. Der Algorithmus sieht aber vor, dass demographische Daten für die Vorhersage mit verwendet werden. Die Arbeit von (Wagner et al. 2023) bestätigt, dass der erklärbare Algorithmus Logistische Regression gute Ergebnisse liefert. Log- Daten von Studierenden in einer

---

<sup>11</sup> <https://www.bht-berlin.de/digitale-lehre>

Lernplattform wurden weiter analysiert und die Ergebnisse veröffentlicht. Zum Beispiel bestätigt die Arbeit von (Hoq et al. 2023), dass die erfolgreiche Einreichung von Programmieraufgaben auf der Plattform während des Semesters am besten den Erfolg bei der Klausur vorhersagt. Alle diese Arbeiten konzentrieren sich auf klassische Präsenzstudiengänge und nicht auf Online-Studiengänge, wie es in diesem Projekt der Fall ist.

Der Austausch mit anderen Projekten der Förderlinie und die Hinweise der "Critical Friends" während der Durchführung des Vorhabens waren immer konstruktiv und haben unser Projekt bereichert. Zu den Treffen zählen: die Auftaktveranstaltung – "Forschung über Studienerfolg und Studienabbruch II" am 11.11.2021, der Workshop zum Austausch über die Definitionen von Studienabbruch und Studienerfolg zusammen mit den Projekten SaFe und LAMASS@DiLea aus der Förderlinie "Studienerfolg und Studienabbruch II" am 09.12.2022, die Statustagung der Förderlinie Studienerfolg und Studienabbruch am 16.06.2023, die Abschlusstagung der BMBF-Förderlinie Studienerfolg und Studienabbruch II am 05.03.2024, die Wissenschaftskonferenz "Studienerfolg durch Digitalisierung? – Neue wissenschaftliche Erkenntnisse zu Einflussfaktoren, Datennutzung und Interventionen" vom Verbundprojekt LAMASS@DiLea organisiert am 14.03.2024 sowie die Tagung der TU Braunschweig "Karriereentscheidungen zwischen Studienabbruch und Studienerfolg" am 24.04.2024. Diese Treffen haben uns ermöglicht, unsere Ergebnisse zu präsentieren und zu diskutieren, Feedback zu erhalten und von den Erfahrungen anderer Projekte zu lernen.

## 9 Erfolgte oder geplante Veröffentlichungen der Projektergebnisse

Während des Projektes sind folgende Veröffentlichungen erschienen:

- Veröffentlichung unserer mit Online-Studierenden erarbeiteten ethischen Leitlinien auf der Projekt-Homepage <https://disea-projekt.de/index.php/ethische-leitlinien/>
- Dogaru, Teodora; Götze, Nora; Rotelli, Daniela; Berendsohn, Yoel; Merceron, Agathe; Sauer, Petra (2023). Task Definition in Big Sets of Heterogeneously Structured Moodle LMS Courses. Poster. 21. Fachtagung Bildungstechnologien (DELFI). DOI: 10.18420/delfi2023-71
- Merceron, Agathe; Dogaru, Teodora; Waghela, Raj; Harper, Tabea Sophie; Sauer, Petra (2024). Predicting Dropout in an Online Degree across Two Institutions - A Case Study. In Proceedings of the Machine Learning and Principles and Practice of Knowledge Discovery in Databases - International Workshops of ECML PKDD 2024, Vilnius, Lithuania, September 9-13, 2024. Langer Beitrag. To appear December 2024.
- Veröffentlichung von vier Datensätzen: <https://zenodo.org/records/14025857>.

Geplante Veröffentlichung:

- Dogaru, Teodora; Fröhlich, Julian; Merceron, Agathe; Sauer, Petra (2024). "Does Regularity Relate to Students' Performance in Courses of an Online degree Program? A Case Study" word in <https://arxiv.org/> 11/2024 hochgeladen

## 10 Literaturverzeichnis

Akçapınar, G., Hasnine, M.H., Majumdar, R., Flanagan, B., & Ogata, H. (2019). Developing an early-warning system for spotting at-risk students by using eBook interaction logs. *Smart Learning Environments* 6:4, <https://doi.org/10.1186/s40561-019-0083-4>.

Arnold, K.E. & Pistilli, M.D. (2012). Course signals at Purdue: using learning analytics to increase student success. *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*, April 29-May 02, 2012, Vancouver, British Columbia, Canada.

Aulck, L. S., Nambi, D., Velagapudi, N., Blumenstock, J. E., & West, J. (2019). Mining University Registrar Records to Predict First-Year Undergraduate Attrition. In *Proceedings of the 12th*

*International Conference on Educational Data Mining (EDM)* (Montreal, Canada, July 2-4). EDM 2019, 9-18. <http://educationaldatamining.org/edm2019/proceedings/>

Baker, S., Esbenschade, L., Vitale, J., Karumbaiah, S. (2023). Using demographic data as predictor variables: a questionable choice. *Journal of Educational Data Mining* 15(2), 22–52.

Baker, R.S., Lindrum, D., Lindrum, M. J., & Perkowski, D. (2015). Analyzing Early At-Risk Factors in Higher Education E-Learning Courses. *International Conference on Educational Data Mining (EDM)*, Madrid, Spain.

Baneres, D., Rodriguez, M. E., & Serra, M. (2019). An Early Feedback Prediction System for Learners At-Risk Within a First-Year Higher Education Course. *IEEE Transactions on Learning Technologies*, 12(2), 249–263. <https://doi.org/10.1109/TLT.2019.2912167>.

Beard, L.A., & Harper, C. (2002). Student Perceptions of Online versus on Campus Instruction. *Education*, 122(4).

Berens, J., Schneider, K., Görtz, S., Oster, S., & 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. <https://doi.org/10.5281/zenodo.3594771>.

Cai, C., Fleischhacker, A. (2024). Structural neural networks meet piecewise exponential models for interpretable college dropout prediction. *Journal of Educational Data Mining* 16(1), 279–302.

Cohausz, L., Tschalzev, A., Bartelt, C., Stuckenschmidt, H. (2023). Investigating the importance of demographic features for edm-predictions. In: Feng, M., Käser, T., Talukdar, P. (eds.) *Proceedings of the 16th International Conference on Educational Data Mining (EDM)*. pp. 125–136. International Educational Data Mining Society.

Constapel, M., Doberstein, D., Hoppe, H. U., & Hellbrück, H. (2019). IKARion: Enhancing a learning platform with intelligent feedback to improve team collaboration and interaction in small groups. *Proceedings of the 18th International Conference on Information Technology Based Higher Education and Training*.

Dekker, G., Pechenizkiy, M., & Vleeshouwers, J. (2009). Predicting Students Drop Out: A Case Study. *Proceedings of the 2nd International Conference on Educational Data Mining*, Cordoba, Spain, EDM'09 , 41–50. <http://www.educationaldatamining.org/EDM2009/uploads/proceedings/dekker.pdf>

Diaz, D.P. (2002) Online Drop Rates Revisited. *The Technology Source*, May/June 2002. [http://www.technologysource.org/article/online\\_drop\\_rates-revisited/](http://www.technologysource.org/article/online_drop_rates-revisited/) Last accessed 23.09.2024.

Dogaru T., Fröhlich, J., Waghela, R., Merceron, A., Sauer, P. (2024). Open Educational Datasets from the DiSEA Project. <https://zenodo.org/records/14025857>

Falk, S., Tretter, M., & Vrdoljak, T. (2018). Angebote an Hochschulen zur Steigerung des Studienerfolgs: Ziele, Adressaten und Best Practice. Bayerische Staatsinstitut für Hochschulforschung und Hochschulplanung (IHF), *IHF Kompakt*, März 2018. <https://www.ihf.bayern.de/publikationen/ihf-kompakt/detail/angebote-an-hochschulen-zur-steigerung-des-studienerfolgs-ziele-adressaten-und-best-practice>

Ferguson, R. and Clow, D. (2017). Where is the evidence? A call to action for learning analytics. In: *LAK '17 Proceedings of the Seventh International Learning Analytics & Knowledge Conference*, ACM International Conference Proceeding Series, ACM, New York, USA, 56–65.

Han, H., Wang, W.Y., Mao, B.H. (2005). Borderline-smote: a new over-sampling method in imbalanced data sets learning. In: *Proceedings of the 2005 International Conference on Advances in Intelligent Computing - Volume Part I*. p. 878–887. ICIC'05, Springer-Verlag, Berlin, Heidelberg (2005). [https://doi.org/10.1007/11538059\\_91](https://doi.org/10.1007/11538059_91), [https://doi.org/10.1007/11538059\\_91](https://doi.org/10.1007/11538059_91)

Hanover Research (2014). Early Alert Systems in Higher Education. <https://www.hanoverresearch.com/wp-content/uploads/2017/08/Early-Alert-Systems-in-Higher-Education.pdf>

Hochschulkompass Stiftung zur Förderung der Hochschulrektorenkonferenz: Studium - fernstudium, <https://www.hochschulkompass.de/studium/rund-umsstudieren/studienformen/fernstudium.html>

Letzter Zugriff 19.09.2024

Hoq M.; Brusilovsky, P.; Akram, B. (2023). Analysis of an Explainable Student Performance Prediction Model in an Introductory Programming Course. In (Feng, M., Käser, T., Talukdar, P. eds.) the *Proceedings of the 16th International Conference on Educational Data Mining (EDM)*, International Educational Data Mining Society, pp. 79-90.

Ifenthaler, D., & Schumacher, C. (2016). Student perceptions of privacy principles for learning analytics. *Education Technology Research and Development*, 64, 923–938.

<https://doi.org/10.1007/s11423-016-9477-y>

Isphording, I. & Wozny, F. (2018). Ursachen des Studienabbruchs – eine Analyse des Nationalen Bildungspanels. *IZA Research Report No. 82*.

Kuzilek, J., Hlostá, M., Herrmannová, D., Zdrahal, Z. & Wolff, A. (2015). LAK15 Case Study 1: OU Analyse: Analysing At-Risk Students at The Open University, *Learning Analytics Review*, no. LAK15-1, <http://www.laceproject.eu/learning-analytics-review/analysing-at-risk-students-at-open-university/>

Jayaprakash, S.M., Moody, E.W., Lauría, E.J.M., Regan, J.R., and Baron, J.D. (2014). Early alert of academically at-risk students: An open source analytics initiative. *Journal of Learning Analytics* 1, 1 (2014), 6–47.

Jivet, J., Scheffel, M., Specht, M., & Drachlser, H. (2018). License to evaluate: Preparing learning analytics dashboards for educational practice. *Proceedings of the 8th international conference on learning analytics & knowledge LAK'18*, Sydney, Australia. ACM, 31-40.

Krämer, N., Rummel, N., Hoppe, H.U., Janneck, M. (2017). Intelligente Unterstützung von Kleingruppenarbeit in der online-gestützten Hochschullehre. *e-teaching.org*,

[https://www.e-](https://www.e-teaching.org/etresources/pdf/erfahrungsbericht_2017_kaemer_et_al_intelligente_unterstuetzung_von_kleingruppenarbeit_in_der_online_gestuetzten_hochschullehre.pdf)

[teaching.org/etresources/pdf/erfahrungsbericht\\_2017\\_kaemer\\_et\\_al\\_intelligente\\_unterstuetzung\\_von\\_kleingruppenarbeit\\_in\\_der\\_online\\_gestuetzten\\_hochschullehre.pdf](https://www.e-teaching.org/etresources/pdf/erfahrungsbericht_2017_kaemer_et_al_intelligente_unterstuetzung_von_kleingruppenarbeit_in_der_online_gestuetzten_hochschullehre.pdf)

Manrique, R., Nunes, B. P., Marino, O., Casanova, M. A., & Nurmikko-Fuller, T. (2019). An Analysis of Student Representation, Representative Features and Classification Algorithms to Predict Degree Dropout. *Proceedings of the 9th International Conference on Learning Analytics & Knowledge - LAK19*, 401-410. <https://doi.org/10.1145/3303772.330380>

Martinez-Maldonado, R., Clayphan, A., Yacef, K., & Kay, J. (2014). Towards providing notifications to enhance teacher's awareness in the classroom. In *Proceedings of the International Conference Intelligent Tutoring Systems*, 510-515.

Merceron, A., Dogaru T., Waghela, R., Harper, T.S. Sauer, P. (2024). Predicting Dropout in an Online Degree across Two Institutions - A Case Study. In *Proceedings of the Machine Learning and Principles and Practice of Knowledge Discovery in Databases - International Workshops of ECML PKDD 2024*, Vilnius, Lithuania, September 9-13, 2024. To appear December 2024.

Minks, K.-H., Netz, N., & Völk, D. (2011). Berufsbegleitende und duale Studienangebote in Deutschland: Status quo und Perspektiven. HIS: *Forum Hochschule* 11/2011.

Rotelli, Daniela & Monreale, Anna. (2022). Time-on-Task Estimation by data-driven Outlier Detection based on Learning Activities. in *Proceedings of the 12th International Conference on Learning Analytics and Knowledge (LAK22)*. ACM. 336-346. [10.1145/3506860.3506913](https://doi.org/10.1145/3506860.3506913).

Rotelli, Daniela & Monreale, Anna. (2023). Processing and Understanding Moodle Log Data and Their Temporal Dimension. *Journal of Learning Analytics*. 1-23. [10.18608/jla.2023.7867](https://doi.org/10.18608/jla.2023.7867).

Schneider, K., Berens, J., & Burghoff, J. (2019). Drohende Studienabbrüche durch Frühwarnsysteme erkennen: Welche Informationen sind relevant? *Zeitschrift für Erziehungswissenschaft*, 22, 1121–1146. <https://doi.org/10.1007/s11618-019-00912-1>.

Schneider, K., Berens, J., Görtz, S. (2021). Maschinelle Früherkennung abbruchgefährdeter Studierender und Wirksamkeit niedrigschwelliger Intervention. In: Neugebauer, M., Daniel, H., Wolter, A. (eds.) *Studienerfolg und Studienabbruch*, pp. 367–391. Springer VS.

Shirvani Boroujeni, Mina & Sharma, Kshitij & Kidziński, Łukasz & Lucignano, Lorenzo & Dillenbourg, Pierre. (2016). How to Quantify Student's Regularity? In *Proceedings of the 11th European Conference on Technology Enhanced Learning EC-TEL*, pages 41-52, Cham, Springer, 9891. 277-291. 10.1007/978-3-319-45153-4\_21.

Slade, S., Prinsloo, P., & Khalil, M. (2019). Learning analytics at the intersections of student trust, disclosure and benefit. *Proceedings of the 9th International Conference on Learning Analytics & 29 Knowledge LAK19*, March 2019, 235–244. <https://doi.org/10.1145/3303772.3303796>.

Verbert, K., Govaerts, S., Duval, E., Santos, J. L., Van Assche, F., Parra, G., & Klerkx, J. (2014). Learning dashboards: an overview and future research opportunities. *Personal and Ubiquitous Computing*, 18(6), 1499-1514.

Van Goidsenhoven S., Bogdanova, D., Deeva, G., vanden Broucke, S., De Weerd, J. & Snoeck, M. (2020). Predicting Student Success in a Blended Learning Environment. *Proceedings of the 10th International Conference on Learning Analytics & Knowledge LAK20*, March 2020, 17–25. <https://doi.org/10.1145/3375462.3375494>

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](https://www.solaresearch.org/core/lak20-companion-proceedings/). <https://www.solaresearch.org/core/lak20-companion-proceedings/>

Wagner, K., Volkening, H., Basyigit, S., Merceron, A., Sauer, P., Pinkwart, N. (2023). Which Approach Best Predicts Dropouts in Higher Education? In *Proceedings of the 15th International Conference on Computer Supported Education (CSEDU)*. pp. 15–26. INSTICC, SciTePress, Prague, Czech Republic.

Wöhrle, J., Karolyi, H., Weidlich, J., Blanc, B., Woick, A. (2024) Wechselwirkungen zwischen digitalisierter hochschulbildung und studienerefolg. In: Wissenschaftskonferenz: Studienerefolg durch Digitalisierung? FernUniversität in Hagen, <https://www.fernuni-hagen.de/forschung/schwerpunkte/catalpa/aktuelles-termine/aktuelles/wissenschaftskonferenz-lamass.shtml> Last accessed 23.09.2024.