

Steuer, Tim; Herrmann, Oliver; Rensing, Christoph; Drachsler, Hendrik
**Learning Analytics Anwendungen für den Hochschuleinsatz. Eine
praxisnahe Übersicht. Version 1.0**

Frankfurt am Main : Innovationsforum Trusted Learning Analytics 2021, 39 S., 10.25657/wfyy-vf36



Quellenangabe/ Reference:

Steuer, Tim; Herrmann, Oliver; Rensing, Christoph; Drachsler, Hendrik: Learning Analytics Anwendungen für den Hochschuleinsatz. Eine praxisnahe Übersicht. Version 1.0. Frankfurt am Main : Innovationsforum Trusted Learning Analytics 2021, 39 S. - URN: urn:nbn:de:0111-dipfdocs-215867 - DOI: 10.25657/02:21586

<https://nbn-resolving.org/urn:nbn:de:0111-dipfdocs-215867>

<https://doi.org/10.25657/02:21586>

Nutzungsbedingungen

Dieses Dokument steht unter folgender Creative Commons-Lizenz: <http://creativecommons.org/licenses/by/3.0/de/deed> - Sie dürfen das Werk bzw. den Inhalt vervielfältigen, verbreiten und öffentlich zugänglich machen sowie Abwandlungen und Bearbeitungen des Werkes bzw. Inhaltes anfertigen, solange Sie den Namen des Autors/Rechteinhabers in der von ihm festgelegten Weise nennen.

Mit der Verwendung dieses Dokuments erkennen Sie die Nutzungsbedingungen an.

Terms of use

This document is published under following Creative Commons-License: <http://creativecommons.org/licenses/by/3.0/de/deed.en> - You may copy, distribute and render this document accessible, make adaptations of this work or its contents accessible to the public as long as you attribute the work in the manner specified by the author or licensor.

By using this particular document, you accept the above-stated conditions of use.



Kontakt / Contact:

DIPF | Leibniz-Institut für
Bildungsforschung und Bildungsinformation
Frankfurter Forschungsbibliothek
publikationen@dipf.de
www.dipfdocs.de

Mitglied der


Leibniz-Gemeinschaft

Learning Analytics Anwendungen für den Hochschuleinsatz

Eine praxisnahe Übersicht

Autoren: Tim Steuer¹, Oliver Herrmann²,
Christoph Rensing³, Hendrik Drachsler^{2,4}

¹ Technische Universität Darmstadt tim.steuer@kom.tu-darmstadt.de

² Goethe-Universität Frankfurt am Main Ol.Schneider@em.uni-frankfurt.de

³ Technische Universität Darmstadt Christoph.Rensing@kom.tu-darmstadt.de

⁴ DIPF | Leibniz-Institut für Bildungsforschung und Bildungsinformation drachsler@dipf.de

Impressum

Innovationsforum Trusted Learning Analytics
Goethe-Universität Frankfurt am Main
Theodor-W.-Adorno-Platz 1
60323 Frankfurt am Main

Empholene Zitierweise:

Steuer, T., Herrmann, O., Rensing, C. & Drachsler, H.
(2021). Learning Analytics Anwendungen für den
Hochschuleinsatz. Eine praxisnahe Übersicht.
Version 1.0, [urn:nbn:de:0111-dipfdocs-215867](https://nbn-resolving.org/urn:nbn:de:0111-dipfdocs-215867)

Gefördert vom



Im Rahmen des Projektes
Digital gestütztes Lehren und Lernen in Hessen



Inhaltsverzeichnis

1	Einleitung.....	6
2	OnTask	9
2.1	Datengrundlage	9
2.2	Datenschutzfunktionen	9
2.3	Datenanalyse	10
2.4	Dashboards & Interventionen	10
2.5	Didaktik / Empirische Befunde	10
2.6	Referenzen.....	10
3	Wooclap.....	11
3.1	Datengrundlage	11
3.2	Datenschutz Funktionen.....	11
3.3	Datenanalyse	11
3.4	Dashboards & Interventionen	11
3.5	Didaktik / Empirische Befunde	12
3.6	Referenzen.....	12
4	Moodle Learning Analytics API.....	13
4.1	Datengrundlage	13
4.2	Datenschutzfunktionen	13
4.3	Datenanalyse	13
4.4	Dashboards & Interventionen	13
4.5	Didaktik / Empirische Befunde	14
4.6	Referenzen.....	14
5	Studenten Beratungs- & Analysetool (S-BEAT)	15
5.1	Datengrundlage	15
5.2	Datenschutz Funktionen.....	15
5.3	Datenanalyse	15
5.4	Dashboards & Interventionen	16
5.5	Didaktik / Empirische Befunde	16
5.6	Referenzen.....	16
6	StREAM (Solutionpath Inc.)	17
6.1	Datengrundlage	17
6.2	Datenschutz Funktionen.....	17
6.3	Datenanalyse	17
6.4	Dashboards & Interventionen	18
6.5	Didaktik / Empirische Befunde	18

6.6	Referenzen.....	18
7	Learning Tracker (TU Delft)	19
7.1	Datengrundlage	19
7.2	Datenschutz Funktionen.....	19
7.3	Datenanalyse	19
7.4	Dashboards & Interventionen	20
7.5	Didaktik / Empirische Befunde	20
7.6	Referenzen.....	20
8	Group Activity Widget (Open Universiteit)	21
8.1	Datengrundlage	21
8.2	Datenschutz Funktionen.....	21
8.3	Datenanalyse	22
8.4	Dashboards & Interventionen	22
8.5	Didaktik / Empirische Befunde	22
8.6	Referenzen.....	22
9	StudyCore Quiz	23
9.1	Datengrundlage	23
9.2	Datenschutz Funktionen.....	23
9.3	Datenanalyse	23
9.4	Dashboards & Interventionen	24
9.5	Didaktik / Empirische Befunde	24
9.6	Referenzen.....	24
10	Student Success Platform (SEAtS Software).....	25
10.1	Datengrundlage	25
10.2	Datenschutz Funktionen.....	25
10.3	Datenanalyse	25
10.4	Dashboards & Interventionen	26
10.5	Didaktik / Empirische Befunde	26
10.6	Referenzen.....	26
11	Course Signals (Purdue University; USA).....	27
11.1	Datengrundlage	27
11.2	Datenschutz Funktionen.....	27
11.3	Datenanalyse	27
11.4	Dashboards & Interventionen	28
11.5	Didaktik / Empirische Befunde	28
11.6	Referenzen.....	28
12	LOCO-Analyst.....	29

12.1	Datengrundlage	29
12.2	Datenschutz Funktionen.....	29
12.3	Datenanalyse	29
12.4	Dashboards & Interventionen	29
12.5	Didaktik / Empirische Befunde	30
12.6	Referenzen.....	30
13	LADA: Learning Analytics Dashboard for Academic Advising	31
13.1	Datengrundlage	31
13.2	Datenschutz Funktionen.....	31
13.3	Datenanalyse	31
13.4	Dashboards & Interventionen	32
13.5	Didaktik / Empirische Befunde	32
13.6	Referenzen.....	32
14	OUAnalyse (Open University of Australia)	33
14.1	Datengrundlage	33
14.2	Datenschutz Funktionen.....	33
14.3	Datenanalyse	33
14.4	Dashboards & Interventionen	33
14.5	Didaktik / Empirische Befunde	33
14.6	Referenzen.....	34
15	Student Explorer (University of Michigan)	35
15.1	Datengrundlage	35
15.2	Datenschutz Funktionen.....	35
15.3	Datenanalyse	36
15.4	Dashboards & Interventionen	36
15.5	Didaktik / Empirische Befunde	36
15.6	Referenzen.....	36
16	Exploratory Learning Analytics Toolkit (eLAT).....	37
16.1	Datengrundlage	37
16.2	Datenschutz Funktionen.....	37
16.3	Datenanalyse	37
16.4	Dashboards & Interventionen	37
16.5	Didaktik / Empirische Befunde	37
16.6	Referenzen.....	38

1 Einleitung

Das Forschungsfeld Learning Analytics wächst in den letzten Jahren beständig. Mit dem Wachstum entstanden eine Vielzahl von Technologien und Anwendungen. Diese reichen von der Durchführung von kleinen Machbarkeitsstudien mit innovativen, prototypischen Anwendungen bis hin zu in großen empirischen Studien evaluierten kommerziellen Systemen. Es ist jedoch für potentielle Anwender von Learning Analytics schwierig, die Forschungslandschaft zu überschauen und sich einen Einblick in die Thematik zu verschaffen. Folglich sind viele Hochschulen und Lehrende beim Einsatz von Learning Analytics zögerlich, da alleine ein Überblick über die Möglichkeiten eine hohe Einarbeitungszeit erfordert.

Auf Basis des ersten *Verhaltenskodex für Trusted Learning Analytics (Hansen, Rensing, Herrmann, Drachsler, 2020)*, der vom Innovationsforum *Trusted Learning Analytics* des Projektes: *Digital gestütztes Lehren und Lernen in Hessen (digLL)* im Januar 2020 veröffentlicht wurde, möchten wir mit diesem Report einen Überblick über vielversprechende Anwendungen und Technologien geben, mit denen eine Umsetzung von Learning Analytics Anwendungsfällen in der Hochschullehre gelingen kann. Wir beschränken uns dabei auf eine Kurzbeschreibung der wichtigsten Charakteristika von Technologien und Anwendungen, um den Leser*Innen einen ersten Eindruck davon zu vermitteln. Leser*Innen sollen danach abschätzen können, ob der Einsatz solch einer Technologie in ihrem Kontext Sinn ergibt. Bei weiterführendem Interesse an der Anwendung verweisen wir via Referenzen auf mögliche Bezugsquellen und Ansprechpartner für die beschriebene Technologie.

Die Kurzbeschreibungen sind immer gleich strukturiert. Sie geben zunächst eine Zusammenfassung über das Ziel der Anwendung oder Technologie. Dies kann beispielsweise eine frühzeitige Erkennung von Risiko-Studierenden sein oder das Finden und Verbessern von suboptimalem Kursmaterial. Anschließend wird die für die Analyse benötigte Datenbasis erläutert. Werden beispielsweise ausschließlich bereits existierende Daten aus dem Learning Management System (LMS) importiert oder werden neue Daten gesammelt. Es folgt eine Erörterung der Datenschutzumsetzung der Anwendung. Werden Daten beispielsweise von der Anwendung anonymisiert oder existiert ein Rechtesystem für Nutzer, um den Datenzugriff zu beschränken. Anschließend werden die Analysealgorithmen der Anwendung erläutert. Es wird beispielsweise beschrieben, ob der Anwendung ein regelbasierter oder ein statistischer Vorhersagealgorithmus zu Grunde liegt. Abschließend werden die Benutzerschnittstelle der Anwendung und die empirischen Befunde zur Nützlichkeit der Anwendung beschrieben. Es wird beispielweise diskutiert ob man eine Dashboard-Ansicht hat, in der die Daten übersichtlich visualisiert werden oder ob man die erfassten Daten en détail filtern und durchsuchen kann. Die hier beschriebenen Anwendungen und Technologien sind dabei lediglich eine Auswahl und stellen keineswegs eine erschöpfende Auflistung aller Learning Analytics Anwendungen dar. Stattdessen konzentrieren wir uns auf verschiedenartige Systeme, um einen möglichst breiten Überblick über das Feld Learning Analytics zu bieten. Während einige der beschriebenen Anwendungen bereits kommerziell verfügbar sind, liegen andere als Open Source Lösungen oder nur als Forschungsprototypen auf Anfrage vor. Wir geben deshalb vor Einführung des Tools an, wie einfach verwendbar die Anwendung ist. Wir nutzen dazu drei Kategorien: Kommerziell verfügbar, ausgereifte Open Source Software oder Forschungsprototyp. Kommerzielle Software hat dabei in der Regel den höchsten Reifegrad und kann mit Installations- und Wartungsdienstleistungen eingekauft werden. Wir fassen hierunter auch Software, die zwar Open Source ist, die allerdings zusätzlich auch kommerziell vertrieben wird. Anwendungen der Kategorie ausgereifte Open Source Software sind in verschiedenen Anwendungsfällen getestet und frei verfügbar. Sie müssen allerdings von einer technischen Fachkraft installiert werden und es existiert abseits der Dokumentation meist keine direkte Unterstützung des Herstellers. In der Kategorie Forschungsprototyp fassen wir noch nicht weit ausgerollte Open Source Software sowie Anwendungen, die nur

in wissenschaftlichen Veröffentlichungen dokumentiert sind, zusammen. Hier muss meist ein Kontakt mit den Autoren hergestellt werden, um Genaueres über eine Adaption auf eine neue Hochschule zu erfahren.

In nachfolgender Tabelle haben wir die einzelnen Verwendungszwecke der hier beschriebenen Anwendungen kurz zusammengefasst um Leser*Innen einen schnellen Einstieg in die für Sie relevanten Anwendungen zu ermöglichen.

Anwendung	Verwendbarkeit	Verwendungszweck
<i>OnTask</i>	Open Source	Datengetriebene semi-automatische persönliche Email-kommunikation mit Risikostudierenden
<i>Wooclap</i>	Kommerziell	Quizzes und Umfragen sowie deren Datenauswertung
<i>Moodle Learning Analytics API</i>	Open Source	Vorhersage von Studienverläufen und Einbindung eigener Vorhersagealgorithmen.
<i>S-BEAT</i>	Kommerziell	Risikoanalyse von Studienverläufen
<i>StREAM</i>	Kommerziell	Hochschulweite Datenanalyse für alle Stakeholder vom Studierenden bis zur Hochschulverwaltung.
<i>Learning Tracker</i>	Forschungsprototyp	Motivation von Lernenden durch datenbasierten Vergleich mit einer Referenzgruppe
<i>Group Activity Widget</i>	Forschungsprototyp	Motivation von Lernenden durch datenbasierten Vergleich mit einer Referenzgruppe
<i>StudyCore Quiz</i>	Kommerziell	Quizzes und Umfragen sowie deren Datenauswertung
<i>Student Success Platform</i>	Kommerziell	Hochschulweite Datenanalyse für alle Stakeholder vom Studierenden bis zur Hochschulverwaltung. Außerdem Überwachung des Effektes von neu eingeführten institutionellen Maßnahmen.
<i>Course Signals</i>	Forschungsprototyp	Risikoanalyse von Studienverläufen. Außerdem personalisierte Emails und Interaktion mit den Studierenden.
<i>LOCO-Analyst</i>	Forschungsprototyp	Analyse von Studienverläufen und von Kursmaterial
<i>LADA</i>	Forschungsprototyp	Analyse von Studienverläufen und datengestützte Beratung von Studierenden.
<i>OUAnalyse</i>	Forschungsprototyp	Vorhersage von Studienverläufen
<i>Student Explorer</i>	Open Source	Vorhersage von Studienverläufen
<i>eLAT</i>	Forschungsprototyp	Analyse von Studienverläufen und datengestützte Beratung.

Für Leser*Innen, die an einem wissenschaftlichen Überblick über das Feld mehr interessiert sind als an einem praxisnahen Überblick empfehlen, wir folgende Artikel.

Referenzen

- Sclater, N., Peasgood, A., & Mullan, J. (2016). Learning Analytics in Higher Education: A review of UK and international practice Full report. JISC. Publiziert unter der Lizenz CC BY 4.0
- Ifenthaler, D., & Yau, J. Y. K. (2020). Utilising learning analytics to support study success in higher education: a systematic review. Educational Technology Research and Development, 1-30.
- Ifenthaler, D., & Schumacher, C. (2016). Learning Analytics im Hochschulkontext. wirtschaftswissenschaftliches Studium, 45(4), 176-181.
- Hansen, J., Rensing, C., Herrmann, O., Drachsler, H. (2020). Verhaltenskodex für Trusted Learning Analytics. Version 1.0. Entwurf für die hessischen Hochschulen. Frankfurt am Main: Innovationsforum Trusted Learning Analytics 2020.

2 OnTask

(Open Source)

Die Anwendung OnTask ist eine an der Universität Sydney entwickelte quelloffene Learning Analytics Anwendung. Sie kann von Lehrenden dafür genutzt werden, Studierenden personalisiertes Feedback basierend auf der aktuellen Datenlage der Anwendung zukommen zu lassen. Einsatzszenarios sind beispielsweise größere Lehrveranstaltungen in Universitäten oder im Online Learning, bei denen eine persönliche Betreuung durch den Lehrenden nicht mehr möglich ist. OnTask teildautomatisiert in diesen Fällen die Betreuung durch personalisierte Emails, die Lehrende nach bestimmten Regeln semi-automatisch verschicken können.

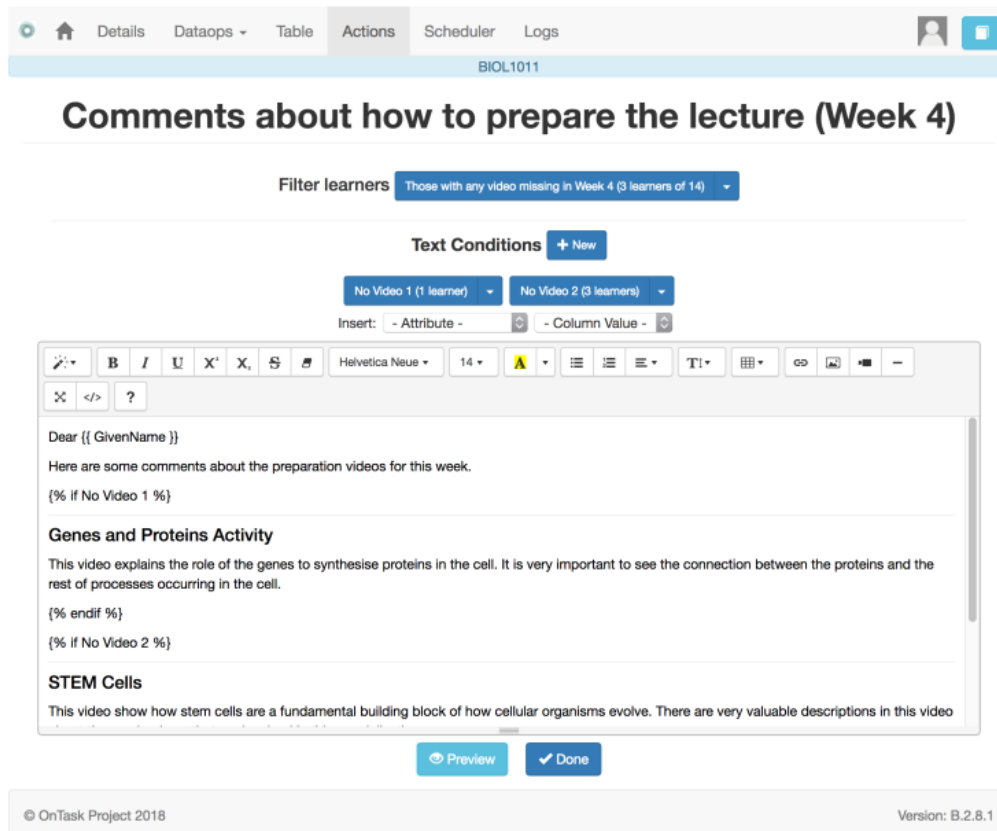


Abbildung 1: Im Beispiel wird eine Erinnerungs-Email zur Vorbereitung der Vorlesung nur an diejenigen Lernenden geschickt, die versäumten, in den letzten Wochen Vorlesungsvideos zu schauen.¹

2.1 Datengrundlage

OnTask besitzt zunächst keine eigene Datenhaltung für die meisten Daten, sondern hat Schnittstellen zu den typischen Datenquellen für Lernenden-Daten wie LMS (z. B. Moodle) oder den Stammdaten-Datenbanken von Institutionen. Lediglich die in OnTask generierten Regeln und benötigten Email-Adressen werden direkt in OnTask gespeichert. Da das Werkzeug dennoch Zugriff auf alle Daten hat, die es verarbeitet, sollte beim Anbinden von Datenquellen immer auch der Datenschutz berücksichtigt werden.

2.2 Datenschutzfunktionen

Keine besonderen.

¹ Grafik aus Pardo, A., Bartimote, K., Shum, S. B., Dawson, S., Gao, J., Gašević, D., ... & Moskal, A. C. M. (2018). OnTask: Delivering data-informed, personalized learning support actions. *Journal of Learning Analytics*, 5(3), 235–249

2.3 Datenanalyse

Ein Lehrender kann basierend auf den durch die Schnittstellen bereitgestellten Daten, Wenn-Dann Regeln formulieren, um auf eine Änderung in der Datenbasis zu reagieren, und entsprechende Aktionen auszuführen zu lassen. Beispielsweise kann der Lehrende eine Regel formulieren, die prüft, ob sich ein Lernender in den letzten zwei Wochen im LMS angemeldet hat. Er kann dann anschließend eine Aktion definieren, die ausgeführt wird, wenn die Regel zutrifft, wie beispielsweise eine lobende E-Mail zu schicken, wenn die Regel zutrifft und eine motivierende E-Mail zu schicken, wenn die Regel nicht zutrifft. Anstelle der individuellen Analyse der Datenpunkte eines jeden einzelnen Lernenden tritt durch OnTask also eine Art Clustering, bei der Lehrende mit vielen Lernenden, die ähnlich geartete Probleme aufweisen, schnell kommunizieren können.

2.4 Dashboards & Interventionen

Die Interventionen in OnTask finden alle über E-Mail statt. Je nach getroffener Wenn-Dann Regel werden unterschiedliche E-Mails an die Studierenden versandt. Die E-Mail-Nachrichten können vom Lehrenden ganz nach seinen Wünschen angepasst werden. Dazu bietet die Anwendung eine webbasierte Benutzerschnittstelle, die es erlaubt, sowohl die E-Mail-Texte als auch die auslösenden Regeln ohne Programmierkenntnisse anzupassen.

2.5 Didaktik / Empirische Befunde

Der Einfluss der Anwendung auf den Lernerfolg von Studierenden wurde empirisch untersucht. An der Studie nahmen innerhalb von drei Jahren ca. 1000 Erstsemester Studierende der Informatik teil. Die Studie fand einen positiven Einfluss der Anwendung auf die Wahrnehmung des gegebenen Feedbacks von Studierenden. Studierende empfanden das Feedback als qualitativ besser. Weiterhin wurde ein positiver Einfluss von OnTask auf die akademischen Leistungen von Studierenden gemessen.

2.6 Referenzen

- Pardo, A., Bartimote, K., Shum, S. B., Dawson, S., Gao, J., Gašević, D., ... & Moskal, A. C. M. (2018). OnTask: Delivering data-informed, personalized learning support actions. *Journal of Learning Analytics*, 5(3), 235–249.
- Pardo, A., Jovanovic, J., Dawson, S., Gašević, D., & Mirriahi, N. (2019). Using learning analytics to scale the provision of personalised feedback. *British Journal of Educational Technology*, 50(1), 128–138.
- <https://www.ontasklearning.org/tool/>
- <https://demo.ontasklearning.org>

3 Wooclap

(kommerziell)

Wooclap ist eine niedrigschwellige, mit verschiedenen LMS Systemen integrierbare App. Sie erlaubt es, einen Rückmeldungskanal für Studierende aufzubauen. Die App ist über eine SMS Schnittstelle und eine interaktive Webanwendung bedienbar. Sie steht also sowohl für ältere Mobiltelefone, Smartphones als auch Computer zur Verfügung. Über den etablierten Rückmeldungskanal können Lehrende und Studierende über vielfältige multimediale Interaktionstypen interagieren. Die App bietet beispielsweise die Möglichkeit, Abfragen durchzuführen, Meinungen zu erfragen oder ein kolaboratives Brainstorming durchzuführen.

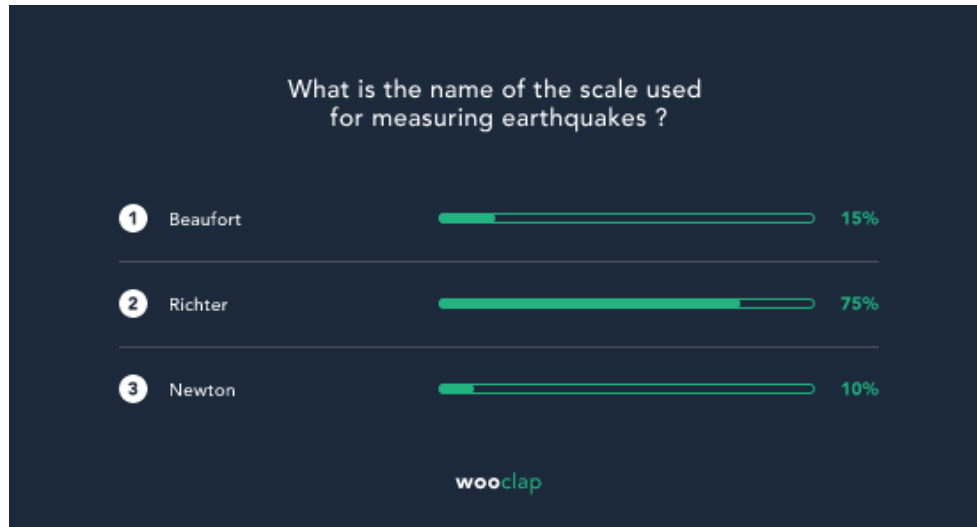


Abbildung 2: Eine Auswertung einer Frage, die an Studierende über wooclap gestellt wurde.²

3.1 Datengrundlage

Als Datengrundlage dienen lediglich die durch die Umfrage erzeugten Daten.

3.2 Datenschutz Funktionen

Wooclap sammelt die Daten anonym. Jedoch fallen die üblichen Verbindungsdaten (z. B. IP Adressen und Handynummern) während der Kommunikation mit der Plattform an und es ist nicht klar, inwiefern diese gespeichert werden.

3.3 Datenanalyse

Wooclap hat keine Vorhersagekomponenten. Es aggregiert Daten jedoch zu zusammenfassenden Statistiken. Außerdem besteht die Möglichkeit des Datenexportes nach Excel oder PDF zur weiteren Analyse.

3.4 Dashboards & Interventionen

Die Daten einer Umfrage werden aggregiert und in einem Dashboard visualisiert. Dort kann zu jeder Frage die Antwortverteilung eingesehen werden. Ein sogenannter kompetitiver Modus soll mithilfe von Gamification Elementen die Motivation der Antwortenden steigern. Im Feedback Modus können Lernende anonym Feedback zu einer Vorlesung geben, welches an den Dozenten weitergeleitet wird.

² <https://www.wooclap.com/de/> abgerufen am 17.11.2020

3.5 Didaktik / Empirische Befunde

-

3.6 Referenzen

- <https://www.wooclap.com/>

4 Moodle Learning Analytics API

(Open Source)

Das weit verbreitete und bekannte LMS Moodle besitzt ab Version 3.7 eine Learning Analytics Programmierschnittstelle. Die API dient dazu verschiedene Machine Learning Algorithmen zur Vorhersage des Verhaltens von Lernenden in Moodle zu integrieren. So kann ein Modul beispielsweise Vorhersagen zum Kursabbruch von Lernenden treffen. In der Standardinstallation existieren drei Vorhersagealgorithmen. Bei Bedarf können eigene Algorithmen hinzugefügt werden.

4.1 Datengrundlage

Die API von Moodle stellt verschiedene Eingabevariablen für die Modelle bereit (Indikatoren in Moodle Terminologie). Es existieren zwei Gruppen von Indikatoren: Allgemeine Indikatoren (z. B. Zugriffe auf Lernressourcen, Anzahl Teilnehmer ...) und Indikatoren der Community of Inquiry (z. B. potentielle kognitive Tiefe des Kurses, Teilnahme an Umfragen). Die Werte der Indikatoren werden aus den Logdateien von Moodle gelesen und für die Verarbeitung in der API angepasst. Der Wertebereich liegt zwischen [-1:1]. Aus technischer Sicht erleichtert dies das Einbringen von eigenen Modellen stark, da ein Großteil der Datenvorverarbeitung bereits in Moodle integriert ist.

4.2 Datenschutzfunktionen

Die Analytics-API ist standardmäßig deaktiviert und muss explizit vom Administrator eingeschaltet und konfiguriert werden. Daneben bezieht sich die *Moodle Learning Analytics Working Group* sowohl auf EU als auch US Datenschutzgesetze. Es existieren Schutzmaßnahmen, um die Daten auf individueller Ebene zu pseudonymisieren. Dazu werden personenbezogene Daten wie beispielsweise E-Mail-Adressen, Namen oder Kurztexthe durch numerische, nicht personenbezogene Daten ersetzt. Andere Texteingaben werden ebenfalls durch Platzhaltertext gleicher Länge anonymisiert und Dateianhänge werden durch Platzhalterdateien gleichen Typs und Größe ersetzt. Auf Institutioneller Ebene werden Kursnamen, Namen von Studenten und Dozenten verschlüsselt und bei Bedarf pseudonymisiert.

4.3 Datenanalyse

Die API definiert einen Einbindepunkt für Machine Learning basierte und regelbasierte Modelle. Mit der Hilfe der durch die API eingebundenen Modelle können Vorhersagen über Lernende getroffen werden. Basierend auf den Vorhersagen können Regeln definiert werden, ob und wann Lernende wie benachrichtigt werden sollen. In der Grundinstallation bietet Moodle drei Modelle an:

- Vorhersage vom Kursabbruch einzelner Teilnehmer (Machine Learning)
- Vorhersage von Fälligkeit von Aktivitäten (regelbasiert)
- Vorhersage von fehlender Lehrtätigkeit nach anstehendem Kursbeginn (regelbasiert)

Daneben können auch benutzerdefinierte Modelle eingebunden werden.

4.4 Dashboards & Interventionen

Die API bietet flexible Einsatzmöglichkeiten für die Modelle an. Dazu kann ein Entwickler verschiedene Ziele definieren, die sein Modell erreichen möchte. Im Standardpaket gibt es vier Ziele:

- Teilnehmer/innen sind gefährdet die Kernkompetenzen nicht zu erreichen
- Teilnehmer/innen sind gefährdet, den Kursabschluss nicht zu erreichen
- Teilnehmer/innen sind gefährdet, den Kurs abzubrechen
- Teilnehmer/innen sind gefährdet, die Bewertung zum Bestehen des Kurses nicht zu erreichen

Mit der regelmäßigen Auswertung des Modells für ein Ziel können zusammenfassende Statistiken für dieses Ziel generiert werden und außerdem sogenannte „Actions“ basierend auf den Auswertungsergebnissen ausgelöst werden. Diese Aktionen können als Interventionen betrachtet werden und können beispielsweise den einzelnen Lernenden über seinen bedrohten Kurserfolg benachrichtigen oder den entsprechenden Dozenten darauf hinweisen.

4.5 Didaktik / Empirische Befunde

-

4.6 Referenzen

- https://docs.moodle.org/39/de/Learning_Analytics
- https://docs.moodle.org/39/de/Analytics_nutzen
- <https://docs.moodle.org/39/de/Analytics-Indikatoren>
- https://docs.moodle.org/dev/Analytics_API
- <https://moodle.org/mod/page/view.php?id=8305>

5 Studenten Beratungs- & Analysetool (S-BEAT)

(kommerziell)

Die quelloffene Anwendung S-BEAT richtet sich nicht direkt an Lehrende, sondern an beratende Stellen an Universitäten. Zielsetzung ist eine frühzeitige Erkennung von kritischen Studienverläufen, um beratend intervenieren zu können. Dazu bietet S-BEAT eine detaillierte Darstellung der Daten und vielfältige Analysemöglichkeiten. Es kann dabei helfen, verschiedene suboptimale Verhaltensmuster von Studierenden zu entdecken, wie beispielsweise Schiebehaviorn in Bezug auf Prüfungen oder die Feststellung von Über- und Unterforderung im Studium. Hierzu bietet S-BEAT eine Benutzeroberfläche, die in einer einfach interpretierbaren Tabelle anzeigt, welche Studierendengruppen besonders gefährdet sind.

90.4% (14.5%) 968 / 1071 / 6658	Semester mit Prüfu... >= 1	Nicht bestandene P... > 2	Erreichte ECTS nac... < 30	Studium erfolgreich Nein		
90.3% (5.0%) 299 / 331 / 5949	Klausuren im 2. Se... > 4	Erreichte ECTS nac... < 40	Semester mit Prüfu... >= 2	HZB Note 3.0 ≤x≤ 3.9	Studium erfolgreich Nein	
90.3% (5.2%) 308 / 341 / 5949	Erreichte ECTS nac... < 40	Alter bei Immatrikul... 18 ≤x≤ 21	Klausuren im 2. Se... > 4	Semester mit Prüfu... >= 2	Nicht bestandene P... >= 1	Studium erfolgreich Nein
90.3% (6.6%) 438 / 485 / 6658	Nicht bestandene P... > 2	Semester mit Prüfu... >= 1	Alter bei Immatrikul... 18 ≤x≤ 21	Erreichte ECTS nac... < 30	Studium erfolgreich Nein	
90.3% (6.6%) 438 / 485 / 6658	Nicht bestandene P... > 2	Semester mit Prüfu... >= 1	Alter bei Immatrikul... 18 ≤x≤ 21	Studium erfolgreich Nein		
90.1% (7.3%) 485 / 538 / 6658	Semester mit Prüfu... >= 1	Erreichte ECTS nac... < 20	Nicht bestandene P... > 2	HZB Note 2.0 ≤x≤ 2.9	Studium erfolgreich Nein	

Abbildung 3: Die Regeln in S-BEATs Dashboard sind einfach zu interpretieren. Die erste Zeile der Tabelle zeigt beispielsweise, dass Lernende, die bereits in mehreren Semestern Prüfungen absolviert haben, in mehr als zwei Prüfungen gescheitert sind und weniger als 30 ECTS erreicht haben, ihr Studium nur selten abschließen.³

5.1 Datengrundlage

Die Anwendung sammelt selbst keine Daten, sondern analysiert importierte Studien- und Prüfungsleistungen. Zum Import können mehrere CSV Dateien in die Anwendung geladen werden, die aus anderen Systemen stammen. Laut Hersteller sollte dieser Import zwei Mal im Semester erfolgen. Erstmals wenn die Prüfungen aus dem letzten Semester gemeldet sind, und dann noch einmal, wenn die Prüfungsanmeldephase für das aktuelle Semester erledigt ist. Während des Imports dieser Daten fallen personenbezogene Daten wie Name, Nachname, E-Mail, Geburtsdatum, erworbene Hochschulzugangsberechtigung und Matrikelnummer an.

5.2 Datenschutz Funktionen

Laut Hersteller bietet S-BEAT eine Authentifizierung über das jeweilige System der Hochschule. Weiterhin regelt es den Datenzugriff auf Gruppenbasis. Gruppen können je nach Berechtigung personenbezogene Daten einsehen oder lediglich pseudonymisierte oder aggregierte Daten sehen.

5.3 Datenanalyse

Die Datenanalyse beinhaltet statistische Auswertungen sowie ein Machine Learning Verfahren (Apriori-Algorithmus). S-BEAT lernt mithilfe des Apriori-Algorithmus aus den historischen Daten Regeln für Studienerfolg oder Studienabbruch und kann so eine Risikobewertung für derzeitige Studierende vornehmen.

³ Grafik der offiziellen S-BEAT Dokumentation (Stand 27.08.2018):
<https://web.archive.org/web/20180827213340/https://s-beat.de/?page=funktionen>

Dabei kann ein Anwender die Konfidenz, also ab wann eine Regel relevant wird, selbst konfigurieren. Die deskriptiven statistischen Kenngrößen aggregieren Daten über Semester oder Studiengänge hinweg, wie beispielsweise die Abbruchquote pro Semester oder die Anzahl der zurückgestellten Prüfungsversuche.

5.4 Dashboards & Interventionen

S-BEAT bietet ein webbasiertes Dashboard an, welches die Ergebnisse der Datenanalyse wiedergibt. Im Dashboard werden die typischen Muster für das Risiko eines Studienabbruches übersichtlich und für Menschen interpretierbar dargestellt. Außerdem werden sowohl die Statistiken über die Studierenden als auch über Studiengänge und Semester gezeigt. Bei Bedarf kann über alle Datenpunkte hinweg gesucht und gefiltert werden. Die Filtermöglichkeiten umfassen beispielsweise das nicht Erreichen einer gegebenen ECTS Grenze oder die Studiendauer.

5.5 Didaktik / Empirische Befunde

-

5.6 Referenzen

- Hinkelmann, M., Maucher, J., & Seidl, T. (2016). Softwaregestützte Studienverlaufsanalyse zur frühzeitigen gezielten Studienberatung. die Hochschullehre, 2(9).
- <https://s-beat.de/>
- <https://github.com/sbeat/s-beat>
- <https://github.com/sbeat/s-beat/blob/master/Datenspezifikation.md>

6 StREAM (Solutionpath Inc.)

(kommerziell)

Die Anwendung STREAM der englischen Firma Solutionpath Inc. dient dazu, das Engagement von Studierenden zu messen und zu verbessern. Dazu analysiert die Anwendung die Aktivität von Studierenden im Universitätskontext und bietet Rückmeldungen für Studierende, Tutoren und Universitäten an. Als Beispiel können Rückmeldungen Studierenden typische Aktivitätsmuster aufzeigen, so dass diese in die Lage versetzt werden, ihre Lernprozesse besser zu verstehen. Universitäten können problematische Kurse in Studiengängen identifizieren.




Abbildung 4: Die Anwendung bietet viele nützliche Visualisierungen für Lernende und Lehrende. Im Beispiel kann der Lernende sofort sehen, wie sein Engagement im Kurs im Vergleich zum durchschnittlichen Lernenden ist.⁴

6.1 Datengrundlage

Die Anwendung zieht zur Analyse des Engagements die Aktivitätsdaten der Studierenden heran und verzichtet überwiegend auf demographische oder andere Daten. Aktivitätsdaten können hierbei Anmeldungen in ein LMS digital abgegebene Übungen, aber auch physikalische Besuche der Universität oder Ausleihen in der Bibliothek sein. Das Tracking der physikalischen Aktivitäten passiert über Zugangssysteme zur Universität oder über das Bibliothekssystem. Die Auswahl der Datenquellen bleibt dabei der einsetzenden Institution überlassen und nicht alle Datenquellen müssen angebunden werden.

6.2 Datenschutz Funktionen

-

6.3 Datenanalyse

Der in StREAM eingesetzte Vorhersagealgorithmus ist Eigentum von Solutionpath und ist nicht veröffentlicht. Er wurde jedoch in einer Studie an der Universität Nottingham erprobt und dort als akkurat und nützlich wahrgenommen.

⁴ Grafik aus "CASE STUDY I: Predictive analytics at Nottingham Trent University" von Solutionpath Inc.

6.4 Dashboards & Interventionen

Die Anwendung bietet Dashboards für Tutoren, Studierende und Institutionen. Studierende können sich mit den Dashboards mit ihren Kommilitonen vergleichen und ihr eigenes Engagement im Verlauf überwachen. Tutoren können sich das Engagement von ganzen Kohorten anschauen und Bedarf die Visualisierung weiter aufschlüsseln, um einen genaueren Eindruck von einzelnen Studierenden oder Gruppen von Studierenden zu erhalten. Wenn das Engagement abfällt, können sowohl Studierende als auch Tutoren benachrichtigt werden. Damit haben Tutoren die Möglichkeit, Studierende erneut zu motivieren. Außerdem können Studierende ihr Verhalten durch die Erinnerungsmails überdenken und werden benachrichtigt, wenn sie dem Studium unzuträgliches Verhalten zeigen.

6.5 Didaktik / Empirische Befunde

In einer Case Study an der Universität Nottingham konnte gezeigt werden, dass der Einsatz von StREAM für die Universitätsmitarbeiter als auch für die Studierenden Vorteile zeigt. So konnte beispielsweise über die Messung des Engagements gezeigt werden, dass nur < 25 % der Studierenden mit unterdurchschnittlichem Engagement es ins zweite Studienjahr schaffen, während 90 % mit überdurchschnittlichem Engagement das zweite Studienjahr erreichten. Generell war das Engagement eine weitaus aussagekräftigere Metrik als demografische Daten oder Noten aus den Hochschulzugangsberechtigungen.

6.6 Referenzen

- CASE STUDY I: Predictive analytics at Nottingham Trent University von Solutionpath Inc:
<https://analytics.jiscinvolve.org/wp/files/2016/04/CASE-STUDY-I-Nottingham-Trent-University.pdf>
- What have we learned from implementing learning analytics at NTU?
<http://analytics.jiscinvolve.org/wp/files/2015/07/jisc-la-network-ed-foster-ntu.pdf>
- <http://info.dtpgroup.co.uk/solutionpath-at-NTU>

7 Learning Tracker (TU Delft)

(Forschungsprototyp)

Der an der TU Delft entwickelte Learning Tracker hilft Lernenden dabei, ihr Zeitmanagement im Studium zu reflektieren. Dazu visualisiert der Tracker die für Lernaktivitäten aufgewendete Zeit im aktuellen Kurs und erlaubt auf Wunsch auch einen Vergleich mit den Durchschnittswerten von ehemaligen Kursteilnehmern. Über diese soziale Norm können Lernende dazu angespornt und motiviert werden.

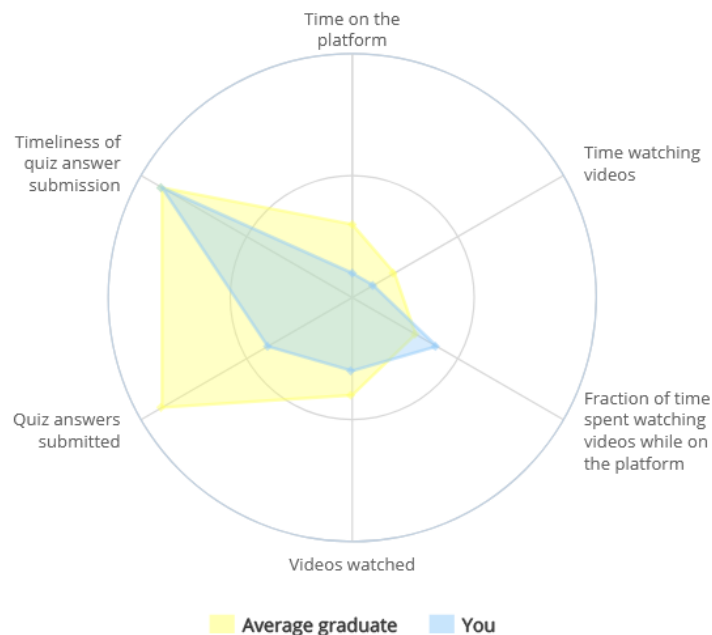


Abbildung 5: Der LearningTracker nutzt zur Visualisierung Netzdiagramme.⁵

7.1 Datengrundlage

Der Learning Tracker importiert seine Daten von einem LMS oder einer MOOC Plattform. Die Anwendung speichert, während des Imports, demographische Daten wie Geschlecht oder Alter und Daten zur Lernaktivität im LMS wie beispielsweise besuchte Kurse, bearbeitete Abfragen, Anzahl der Forumssuchanfragen oder angesehene Ressourcen. Dabei sind die importierten Daten recht feingranular und erlauben ein umfassendes Überwachen der Aktivitäten des Lernenden in der Anwendung. Des Weiteren speichert die Anwendung Selbsteinschätzungen von Lernenden zu ihrem Zeitbudget.

7.2 Datenschutz Funktionen

Zur Kalkulation der Metriken der Vergleichsgruppe können anonymisierte Daten herangezogen werden. So können keine Rückschlüsse auf die Identitäten der Lernenden getroffen werden. Jedoch müssen die Daten vor dem Import anonymisiert werden, die Anwendung selbst bietet keine direkte Anonymisierung an.

7.3 Datenanalyse

Die im Lernenden Modell gespeicherten Informationen werden zur Berechnung von zusammenfassenden statistischen Kennzahlen, wie durchschnittliche Arbeitszeit auf der Plattform oder der Pünktlichkeit der

⁵ Grafik aus der Masterarbeit „The Learning Tracker: A Learner Dashboard that Encourages Self-regulation in MOOC Learners“ von Ioana Jivet

Übungsabgabe, aggregiert. Es findet keine weiterführende Analyse im Sinne von Vorhersagealgorithmen oder Klassifikationsalgorithmen statt.

7.4 Dashboards & Interventionen

Die Anwendung bietet eine Visualisierung in Form eines Netzdiagramms des aktuellen Zeitpunkts an. Das Diagramm erlaubt es dem Studierenden, alle Metriken auf einen Blick zu sehen und sich auf Wunsch mit historischen Studierendendaten zu vergleichen. Dadurch, dass das Diagramm sich in regelmäßig Abständen aktualisiert, können Lernende außerdem ihre selbstregulativen Fähigkeiten im zeitlichen Verlauf überwachen. Idealerweise werden Lernende so dazu, angespornt sich mindestens an die historischen Daten anzunähern oder diese gar zu übertreffen.

7.5 Didaktik / Empirische Befunde

Die empirische Evaluation der Anwendung zeigte, dass sie die Abschlussrate von MOOCs signifikant erhöhen kann. Allerdings profitieren von dem Feedback vor allem Lernende, die bereits gute Selbstregulation mitbringen und weniger Lernende, die problematische Selbstregulation aufweisen.

7.6 Referenzen

- Davis, D., Jivet, I., Kizilcec, R. F., Chen, G., Hauff, C., & Houben, G. J. (2017, March). Follow the successful crowd: raising MOOC completion rates through social comparison at scale. In Proceedings of the seventh international learning analytics & knowledge conference (pp. 454–463).
- The Learning Tracker: A Learner Dashboard that Encourages Self-regulation in MOOC Learners: <https://repository.tudelft.nl/islandora/object/uuid%3Af6c2ede4-a4e3-4ff0-b681-b0d057854e3c>

8 Group Activity Widget (Open Universiteit)

(Forschungsprototyp)

Das Group Activity Widget der Open Universiteit der Niederlande ist ein Learning Analytics Tool, das die Teilnahme in Gruppenarbeiten erfasst und an Lernende zurückspegelt. Durch die erfassten Daten sollen zum einen Vorhersagen über die Noten der einzelnen Studierenden getroffen werden und zum anderen durch die regelmäßige Rückmeldung an die Studierenden deren Motivation erhöht werden.

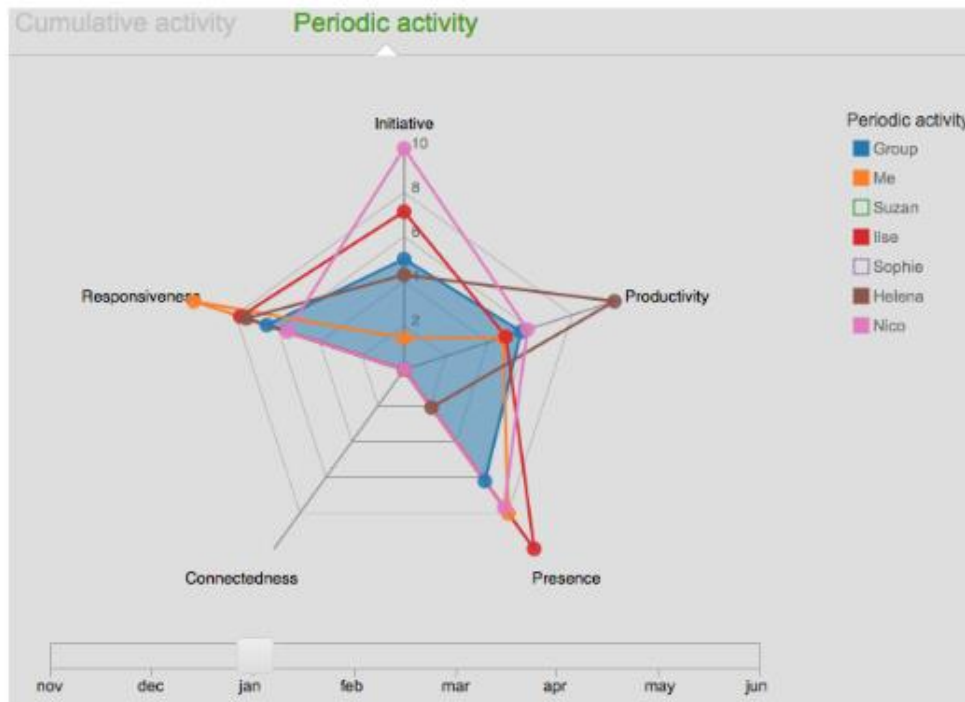


Abbildung 6: Wie auch der LearningTracker stellt das Group Activity Widget den Lernverlauf über mehrere Netzdiagramme dar.⁶

8.1 Datengrundlage

Die Datengrundlage der Anwendung besteht aus den Protokolldateien der Lernplattform. Die Anwendung analysiert dabei die Anzahl der Beiträge auf der Plattform, die Anzahl der Kommentare, die Anzahl der Seitenansichten und die Vernetzung mit anderen Lernenden auf der Plattform.

8.2 Datenschutz Funktionen

Das Group Activity Widget implementiert sogenannte Reciprocal Privacy. Studierende können entscheiden, ob ihre Daten von anderen Teilnehmern gesehen werden oder nicht. Umgekehrt sehen auch sie nur die Daten von anderen Teilnehmern, sofern sie auch ihre Daten freigeben. Durchschnittswerte der Gruppe sind allerdings für alle Teilnehmer sichtbar.

⁶ Grafik aus Scheffel, M., Drachler, H., Kreijns, K., De Kraker, J., & Specht, M. (2017, March). Widget, widget as you lead, I am performing well indeed! Using results from an exploratory offline study to inform an empirical online study about a learning analytics widget in a collaborative learning environment. In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (pp. 289–298).

8.3 Datenanalyse

Die Anwendung nutzt die aus den Protokolldateien entnommenen Daten meist direkt in ihrem Dashboard. Zur Berechnung der Produktivität werden allerdings Kennziffern aus den Protokolldateien miteinander in Verbindung gesetzt, um die Produktivitätskennziffer zu berechnen.

8.4 Dashboards & Interventionen

Die Anwendung bildet sechs Dimensionen der Gruppenarbeit in einem Netzdiagramm ab: Initiative des Lernenden, Antwortverhalten, Präsenz, Verbundenheit zu anderen Lernenden sowie Produktivität. Lernende können ihr Netzdiagramm sowohl im zeitlichen Verlauf als auch im Vergleich mit den Werten ihrer Gruppenmitglieder betrachten.

8.5 Didaktik / Empirische Befunde

Das Group Activity Widget wurde in einer fünfmonatigen empirischen Studie innerhalb eines Online Kurses evaluiert. Dabei zeigte sich eine starke Korrelation zwischen dem Antwortverhaltensindikator und den erzielten Noten im Kurs. Außerdem existiert quantitative und qualitative Evidenz dafür, dass das Widget Studierenden zu mehr Achtsamkeit gegenüber ihrem eigenen Verhalten verhilft und die Selbstreflexion ihrer Arbeitsweise im Kurs steigert.

8.6 Referenzen

- Scheffel, M., Drachsler, H., Kreijns, K., De Kraker, J., & Specht, M. (2017, March). Widget, widget as you lead, I am performing well indeed! Using results from an exploratory offline study to inform an empirical online study about a learning analytics widget in a collaborative learning environment. In Proceedings of the Seventh International Learning Analytics & Knowledge Conference (pp. 289–298).

9 StudyCore Quiz

(kommerziell)

StudyCore ist eine Quiz App, die auf dem Mobiltelefon von Lernenden eingesetzt wird. Die App bietet verschiedene Aufgabenformate an. Außerdem können Lehrende und Lernende sich über Dashboards über den Lernfortschritt von sich selbst oder der Kohorte informieren. Die App nutzt dabei sowohl Learning Analytics Elemente als auch Gamification Elemente, um Lernenden einen Vergleich mit ihrer Peergruppe zu bieten und sie zu motivieren.

Erfolgsquoten aller Kapitel




Abbildung 7: StudyCore bietet neben anderen Visualisierungen auch ein Netzdiagramm, welches die Erfolgsquote der Lernenden pro Kapitel zeigt.

9.1 Datengrundlage

Als Datengrundlage dienen zunächst ausschließlich die in der App erfassten Datenpunkte. Die App legt ein Benutzerprofil an, in dem unter anderem die Antworten auf die Quizfragen, die Bearbeitungszeitpunkte so wie Stammdaten der Lernenden hinterlegt werden. Bei Bedarf können weitere Informationen mit anderen Datenbanken von Institutionen eingebunden werden. So bietet die Anwendung eine LDAP Integration oder eine Integration für fast all LMSe mittels LTI.

9.2 Datenschutz Funktionen

Der Hersteller wirbt mit einer DSGVO konformen Speicherung der Daten.

9.3 Datenanalyse

Die Anwendung beinhaltet abseits von Aggregation von Daten keine Vorhersage- oder Klassifikationsalgorithmen.

9.4 Dashboards & Interventionen

Die App arbeitet mit Gamification und Learning Analytics Dashboards, um Nutzern einen Einblick von ihrem Wissensstand relativ zu allen anderen Nutzern zu geben und sie zu motivieren, regelmäßig an Abfragen teilzunehmen. Dabei erhält der Nutzer Medaillen bei verschiedenen Meilensteinen (z. B. 50 Fragen beantwortet), sammelt Erfahrungspunkte pro beantwortete Frage und steigt mit dem Erfahrungsanstieg Stufen auf. Das auf Lernende zentrierte Dashboard zeigt den Erfolg, gemessen an der Anzahl der beantworteten Fragen des Lernenden und erlaubt dem Lernenden sich mit der Gesamtgruppe der Lernenden zu vergleichen. Außerdem kann sich der Lernende seinen Fortschritt pro Kapitel anzeigen lassen und seine Nutzungsdauer in verschiedenen Diagrammen einsehen. Neben den Statistiken für einzelne Lernende gibt es ähnliche Statistiken zusammengefasst für Lehrende, um den Erfolg ihrer Lehre kontrollieren zu können. Sie können beispielsweise die Anzahl der Nutzer pro Frageblock einsehen oder sich die Anzahl der richtig beantworteten Fragen pro Themengebiet analysieren.

9.5 Didaktik / Empirische Befunde

-

9.6 Referenzen

- <https://studycore.de/solutions>

10 Student Success Platform (SEAtS Software)

(kommerziell)

Die Student Success Platform der Firma SEAtS Software ist eine komplett in die Hochschule integrierbare Plattform. Sie analysiert die Teilnahme an Veranstaltungen sowie den Lernverlauf und trifft Vorhersagen über den Studienerfolg. Angeboten werden Auswertungen auf Lernenden-, Lehrenden und Institutsebene. Die Anwendung kann beispielsweise genutzt werden, um die Effekte von neu eingeführten Maßnahmen auf Institutsebene zu messen.

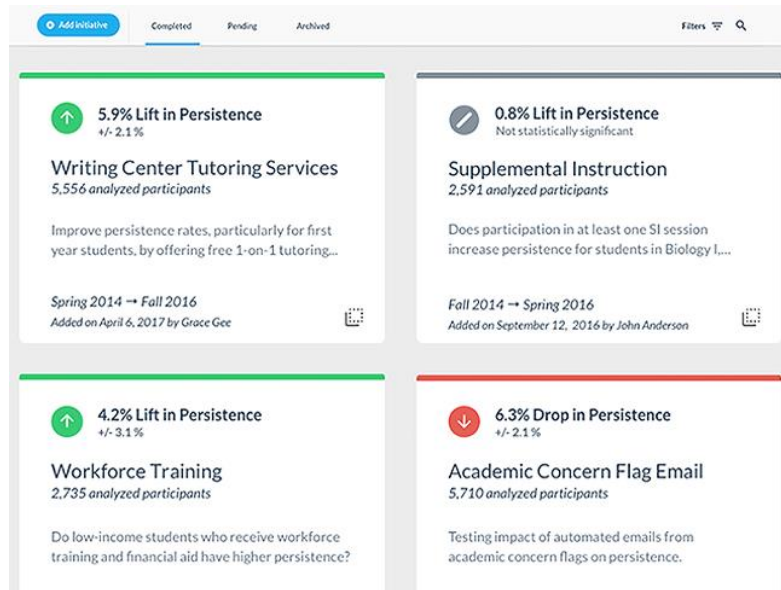


Abbildung 8: Im Dashboard der Student Success Platform können beispielsweise die Einflüsse von verschiedenen Maßnahmen auf das Verhalten der Lernenden analysiert werden.⁷

10.1 Datengrundlage

Als Datengrundlage für die Teilnahme an Kursen dient ein Standortverlauf, der über in der Universität verteilte Bluetooth Sender erstellt wird. Dazu muss auf den mobilen Endgeräten der Lernenden eine App installiert werden und die entsprechenden Freigaben für das Kommunizieren mit den Bluetooth-Sendern erteilt werden. Für die Dashboards und Vorhersagemodule von SEAtS werden zusätzlich digitale Daten wie Demographie, Bibliotheksausleihdaten und vorherige Testergebnisse herangezogen, um eine Vorhersage über den Lernverlauf zu treffen. Die digitale Datenbasis wird dabei aus den diversen universitären Systemen (z. B. LMS) importiert.

10.2 Datenschutz Funktionen

-

10.3 Datenanalyse

Laut Hersteller kommen nicht näher spezifizierte Machine Learning Algorithmen zum Einsatz, um den Lernverlauf auszuwerten und potentielle Risiken (z. B. Studienabbruch) zu erkennen. Dabei werden die Vorhersagealgorithmen anhand von historischen Daten antrainiert.

⁷Grafik aus https://www.civitaslearning.com/wp-content/uploads/2020/07/screencap_successmgt_700pxby550px_leftalign_impacttiles2.png (28.10.2020)

10.4 Dashboards & Interventionen

SEAtS bietet Dashboards für administratives Personal an. Diese Dashboards visualisieren personalisiertes Engagement, Wissenserhalt und Lernerfolge jedes einzelnen Studierenden. Verschiedene Indikatoren werden im System intern aggregiert, so dass die resultierenden Diagramme leichter interpretierbar werden. Basierend auf den Vorhersagen des Systems und der Datenlage können dann Gespräche mit potentiell gefährdeten Studierenden gesucht werden.

10.5 Didaktik / Empirische Befunde

-

10.6 Referenzen

- <https://www.seatssoftware.com>

11 Course Signals (Purdue University; USA)

(Forschungsprototyp)

Dass an der Purdue Universität entwickelte Course Signals Learning Analytics Dashboard dient als Frühwarnsystem für Lernende und Lehrende. Von Lehrenden ausgelöst, verschafft es Lernenden eine Übersicht über ihren derzeitigen Lernverlauf über personalisierte E-Mails. Dadurch können sie sich selbst einfach im Vergleich zu anderen Lernenden einordnen und im Zweifelsfall rechtzeitig Hilfe suchen.



Abbildung 9: Die Lernendenansicht von Course Signals signalisiert über eine Ampel, ob man in seinem Lernverlauf auf dem richtigen Weg ist.⁸

11.1 Datengrundlage

Als Datengrundlage zieht das Dashboard historische Evaluationsdaten wie Noten und Übungsergebnisse, demografische Informationen und die Protokolldateien des LMS heran. Die historischen Evaluationsdaten sind dabei detailliert und beinhalten nicht nur die Noten aus den vorangegangenen Semestern, sondern auch die Highschool Noten, sowie die angestrebten Credit Points im Studium pro Semester.

11.2 Datenschutz Funktionen

11.3 Datenanalyse

Die herangezogenen Daten können vom Lehrenden bei Bedarf durch einen proprietären Vorhersagealgorithmus analysiert werden. Der Algorithmus nutzt die derzeit erreichten Punktzahlen in Kursen, die Interaktionsdaten mit dem LMS, die historischen Lernendendaten und demografische Daten, um einen Risikoindikator für den Lernenden zu berechnen. Dieser Risikoindikator ist angelehnt an eine Ampel mit drei Risikobewertungen (Grün, Gelb, Rot). Grün bedeutet eine hohe Erfolgswahrscheinlichkeit im aktuellen Kurs, Gelb ein potentielles Durchfallrisiko und Rot zeigt ein hohes Durchfallrisiko an.

⁸ Grafik aus <https://er.educause.edu/articles/2010/3/signals-applying-academic-analytics> (26.09.2020)

11.4 Dashboards & Interventionen

Nach der Analyse der Lernendendaten hat der Lehrende verschiedene Interaktionsmöglichkeiten. Er kann die Risikobewertung in Form einer Ampel auf die Login-Seite des Lernenden stellen, so dass der Lernende bei seinem nächsten Login benachrichtigt wird. Er kann den Lernenden direkt über personalisierte E-Mail-Nachrichten oder SMS-Nachrichten über das System kontaktieren. Weiterhin kann er über das System einem anderen akademischen Betreuer Bescheid geben oder ein persönliches Treffen mit dem Lernenden vereinbaren.

11.5 Didaktik / Empirische Befunde

Das System wurde an der Universität Purdue mit einer Großzahl an Studierenden (> 23.000) und Lehrenden (> 140) eingesetzt. Es gab überwiegend positives Feedback von den Studierenden und Lehrenden. Die Studierenden nahmen dabei die aus dem System generierten E-Mails als persönliche Kommunikation zwischen ihnen und dem Dozenten wahr. Sie fühlten sich dadurch nicht mehr so anonym und stärker als Lernender wahrgenommen. Negative Punkte der Studierenden wurden vor allem im Zusammenhang mit der Benutzung durch die Dozenten genannt, so dauerte es oft lange, bis ein Dozent einen Risikoindikator neu berechnete, oder Dozenten sendeten immer wieder die gleiche E-Mail über das System. Die Lehrenden berichteten von gesteigerter Kommunikation mit den Lernenden durch die frühzeitige Kontaktaufnahme ihrerseits, sowie von positiven Effekten dadurch, dass die Lernenden rechtzeitig herausfinden, wie gut oder schlecht ihr Lernverlauf gerade ist. Alles in Allem zieht die Studie ein sehr positives Fazit und berichtet von Verbesserungen der Noten von Lernenden mit den Dashboards, gegenüber Lernenden ohne das Dashboard. So erreichten Lernende mit dem Dashboard 10 % häufiger eine sehr gute oder gute Note.

11.6 Referenzen

- Arnold, K. E. (2010). Signals: Applying academic analytics. *Educause Quarterly*, 33(1), n1.
- Arnold, K. E., & Pistilli, M. D. (2012, April). Course signals at Purdue: Using learning analytics to increase student success. In *Proceedings of the 2nd international conference on learning analytics and knowledge* (pp. 267–270).

12 LOCO-Analyst

(Forschungsprototyp)

Die Software LOCO (Learning Object Context Ontologies) Analyst ist eine auf dem LOCO Ontologie-Framework basierende Learning Analytics Anwendung die in LMS Systeme wie beispielsweise Moodle integriert werden kann. Zielgruppe der Anwendung sind die Lehrenden. Sie erhalten Rückmeldung zu den Aktivitäten der Lernenden, zu der Verständlichkeit ihrer Lehrmaterialien und zu den sozialen Interaktionen innerhalb der Lern/Lehrumgebung.

12.1 Datengrundlage

LOCO-Analyst baut auf der LOCO Ontologie auf. Die ontologischen Repräsentationen der Lernverläufe werden aus manuell von den Lehrenden und Lernenden eingetragenen Annotationen sowie den Standardprotokolldaten des LMS erzeugt. Es werden verschiedene Artefakte der Online Plattform, wie beispielsweise Vorlesungen, Tests und versendete Nachrichten semantisch annotiert und miteinander in Beziehung gebracht. Neben dieser Ontologie werden weiterhin eine Benutzerontologie und eine Domänenontologie verwendet. um die Lernenden und den Inhalt der Lernmaterialien semantisch zu repräsentieren.

12.2 Datenschutz Funktionen

-

12.3 Datenanalyse

Der LOCO-Analyst versucht aus den Antwortmustern zu im LMS angebotenen Onlinetests zu erkennen, warum bestimmte Lernende mit bestimmten Tests Probleme haben. Dazu setzt er die Punktzahlen über verschiedene Tests miteinander in Beziehung, um herauszufinden, ob das Problem eher beim Lernenden liegt (viele Testergebnisse schlecht) oder eher bei dem spezifischen Test liegt (Testergebnisse nur dort schlechter). So kann auf dem Modullevel herausgefunden werden, ob bestimmte Modulinhalte problematisch sind. In einem weiteren Analyseschritt werden die Muster der Testergebnisse genutzt, um erfolgreiche und weniger erfolgreiche Lernverläufe aufzudecken. Dabei werden Muster analysiert wie „Studierende die Video Y geschaut und dann im Forum Rückfragen gestellt haben, haben besser abgeschnitten als Studierende die Video Y geschaut und dann Übung Z gemacht haben“. Solche Muster können dem Lehrenden Aufschluss darüber geben, welche Lernsequenz für welchen Typ von Studierenden am nützlichsten ist. Um diese Analysen durchzuführen werden nicht nur die Protokolldaten herangezogen, sondern auch die Foren und sozialen Interaktionen von Lernenden betrachtet. So kann man über die am häufigsten angesprochenen Fehlverständnisse im Forum beispielsweise potentiell schwerere Themen aufdecken.

12.4 Dashboards & Interventionen

Der LOCO-Analyst bietet eine Oberfläche zur Analyse der gesammelten Daten für Lehrende an. Dabei beinhaltet er Dashboards, die die zeitlichen Zusammenhänge der Lernverläufe visualisieren (z. B. wie lange wurde mit jedem Lerninhalt gearbeitet). Außerdem werden statistische Auswertungen, wie die durchschnittliche kognitive Belastung von Studierenden zu jedem Kursinhalt oder die durchschnittliche Anzahl an Wiederholungen des Kursinhaltes, angezeigt und sprachlich aggregiert („dieser Kursinhalt hat 3 schwierige Inhalte“). Weiterhin können Lernende Inhalte taggen. Diese Tags werden Lehrenden angezeigt und sind durchsuchbar, um besser zu verstehen, was Lernende an dem Kursinhalt als wichtig erachtet haben.

12.5 Didaktik / Empirische Befunde

-

12.6 Referenzen

- Torniai, C., Jovanovic, J., Gašević, D., Bateman, S., & Hatala, M. (2008, July). E-learning meets the social semantic web. In *2008 Eighth IEEE International Conference on Advanced Learning Technologies* (pp. 389–393). IEEE.
- Jovanovic, J., Gasevic, D., Brooks, C., Devedzic, V., Hatala, M., Eap, T., & Richards, G. (2008). LOCO-Analyst: semantic web technologies in learning content usage analysis. *International journal of continuing engineering education and life long learning*, *18*(1), 54–76.
- <http://jelenajovanovic.net/LOCO-Analyst/loco-analyst.html>

13 LADA: Learning Analytics Dashboard for Academic Advising

(Forschungsprototyp)

LADA unterstützt Studierendenberatungen und Dozenten in ihrem Entscheidungsprozess über einzelne Lernende. Dazu nutzt LADA vergleichende und vorhersagende Learning Analytics Modelle, welche übersichtlich in einem Dashboard zusammengefasst werden. Durch dieses Dashboard können Lehrende und Beratende dann schneller einschätzen, wie der Studienverlauf eines Lernenden aussieht. Außerdem können sie verschiedene Studienverläufe für den Lernenden durchplanen und auf Basis der Vorhersagen von LADA einschätzen, wie hoch die Erfolgsaussichten je nach Wahl von verschiedenen Kursen sind.

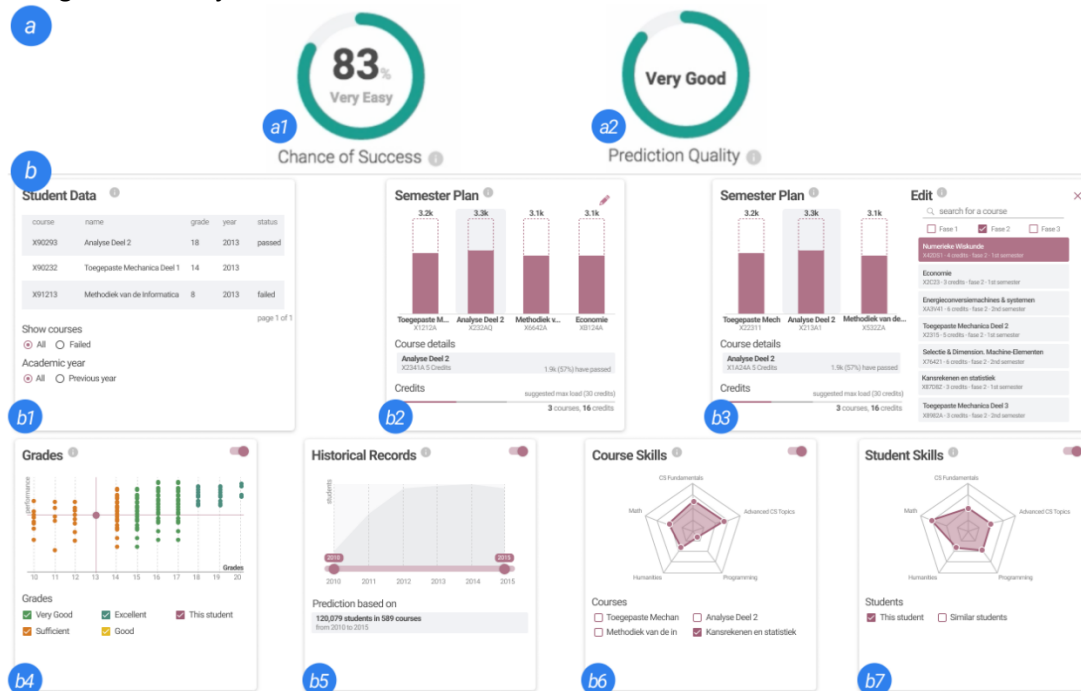


Abbildung 10: Die verschiedenen in LADA verfügbaren Visualisierungen.⁹

13.1 Datengrundlage

LADA nutzt als Datengrundlage Daten aus vorangegangenen Semestern und aktuelle Daten. Insgesamt werden die Noten der Lernenden, die Liste aller Kurse im Studienprogramm, die Kurseinschreibungen von Lernenden in die und die Creditpoints eines jeden Kurses erfasst.

13.2 Datenschutz Funktionen

13.3 Datenanalyse

LADA nutzt zur Vorhersage des akademischen Risikos einen mehrstufigen Clustering Algorithmus. Einzelne Cluster werden zunächst nach relativ generellen Kriterien, wie beispielsweise der Anzahl der besuchten Kurse, gebildet und dann durch genauere Features, wie beispielsweise Anzahl an Mathematikkursen, noch einmal

⁹ Gutiérrez, F., Seipp, K., Ochoa, X., Chiluiza, K., De Laet, T., & Verbert, K. (2020). LADA: A learning analytics dashboard for academic advising. *Computers in Human Behavior*, 107, 105826.

verfeinert. Durch die so analysierte Hierarchie von Clustern können durchschnittlich Lernende durch sehr spezifische Cluster analysiert werden und Ausreißer in generelleren Clustern identifiziert werden.

13.4 Dashboards & Interventionen

LADA bietet sechs verschiedene Visualisierungen im Dashboard an, die jeweils helfen sollen einen konkreten Lernenden zu beraten, sowie zwei Aussagen aus dem Vorhersagealgorithmus. Die vorherigen Kursbesuche und Noten des Lernenden können in tabellarischer Ansicht angesehen werden, um sich eine erste Übersicht über den Studienfortschritt zu verschaffen. Die Semesterplan-Ansicht visualisiert kompakt, welche Kurse gerade besucht werden und wie hoch die Bestehensquote ist. Außerdem können dort verschiedene Kurse hinzu- oder abgewählt werden um verschiedene Studienverläufe zu simulieren. Die Notenvisualisierung erlaubt es, die Noten des Lernenden in einem Kurs relativ zu anderen Lernenden darzustellen und zu filtern. Außerdem können Beratende auf die vorherigen Daten der Analyse einwirken, die benötigten Fähigkeiten in einem Kurs als Spinnendiagramm visualisieren und die bisher vorhandenen Fähigkeiten des Studierenden visualisieren. Die Vorhersagen, ob der Lernende in der gegebenen Kurskonfiguration erfolgreich studieren kann, wird dabei jeweils mit an eine Ampel angelehnte Farbcodes sowie als Prozentzahl angezeigt. Weiterhin wird die Unsicherheit der Vorhersage des Algorithmus ebenfalls als Prozentzahl und Farbcode angezeigt.

13.5 Didaktik / Empirische Befunde

Das System wurde in einer empirischen Studie mit zwei Universitäten evaluiert. Dabei wurde LADA gegen das vorherige Learning Analytics Dashboard der Studienberatung verglichen und es wurde untersucht, inwiefern Laien mit dem System nützliche Erkenntnisse gewinnen können. Die Hauptergebnisse waren, dass mithilfe von LADA mehrere potentielle Studienverläufe in der gleichen Zeit analysiert werden können, bevor der Beratende eine Entscheidung über seine Empfehlung treffen muss. Außerdem zeigen die Ergebnisse, dass Laien das System gerne nutzen und ihre Beratungsentscheidung durch das System als fundierter wahrnehmen. Als negativer Punkt wurde angeführt, dass die Vorhersagekomponenten des Algorithmus noch zu intransparent seien und dass es hier mehr Erklärung bedarf, um das Vertrauen in die Vorhersagen zu steigern.

13.6 Referenzen

- Gutiérrez, F., Seipp, K., Ochoa, X., Chiliza, K., De Laet, T., & Verbert, K. (2020). LADA: A learning analytics dashboard for academic advising. *Computers in Human Behavior*, 107, 105826.
- Ochoa, X. (2016, October). Adaptive multilevel clustering model for the prediction of academic risk. In 2016 XI Latin American Conference on Learning Objects and Technology (LACLO) (pp. 1-8). IEEE.
- <https://github.com/FranciscoGutierrez/KUDashboard>

14 OUAAnalyse (Open University of Australia)

(Forschungsprototyp)

Das OUA der Open University sagt auf wöchentlicher Basis die Einreichung- und Bestehenswahrscheinlichkeit für abzugebenden Übungen der Lernenden voraus. Im Gegensatz zu den meisten anderen Systemen benötigt es dazu keine Daten aus vorherigen Semestern. Lehrende können anhand der Vorhersagen proaktiv auf Lernende zugehen und ihnen mit Feedback und Hilfestellung zur Seite stehen. Somit erlaubt die Anwendung es Lernende zu unterstützen, noch bevor diese durch zu viele nicht abgegebene oder nicht bestandene Übungen im Kurs zurückfallen.

14.1 Datengrundlage

Als Datengrundlage von OUA dienen Demografie, Informationen über die Kursregistrierung sowie Daten aus dem LMS. Die demografischen Daten umfassen neben Alter, Geschlecht, und möglicher Lernbehinderung auch vorherige Qualifikationen, die Anzahl der bisher erhaltenen ECTS sowie die Anzahl der bisherigen Klausurversuche einer Vorlesung. Die Daten aus dem LMS geben an, wie oft der Lernende im Kurs aktiv war und sich eingeloggt hat sowie welche Inhalte er abgerufen hat.

14.2 Datenschutz Funktionen

-

14.3 Datenanalyse

Die Datenanalyse funktioniert ohne historische Daten früherer Teilnehmer. Dazu wird ein Verfahren namens Ouroboros eingesetzt. Technisch wird das Problem dabei als binäres Klassifizierungsproblem formuliert und es wird vorhergesagt, mit welcher Wahrscheinlichkeit ein Lernender seine Übung in den nächsten Tagen einreicht. Das Verfahren nutzt die in der jetzigen Kursiteration angefallenen Daten, extrahiert die bereits vorhandenen Features, balanciert und gewichtet die angefallenen Labels und trainiert einen Klassifizierer mit Hilfe von XGBoost. Je nach Wahrscheinlichkeitsabschätzung dieses Klassifizierers werden dann unterschiedliche Ampelfarben in der Benutzungsoberfläche angezeigt.

14.4 Dashboards & Interventionen

Das Dashboard steht den Lernenden zur Verfügung und ist einfach strukturiert. Es zeigt eine Liste aller Lernenden im Kurs sowie einen Zeitstrahl, der für jeden Lernenden die vergangenen Übungen bis zur nächsten einzureichenden Übung anzeigt. Je nachdem ob der Lernender eine frühere Übung bestanden hat oder nicht ist diese entweder grün oder rot gefärbt. Die nächste einzureichende Übung wird vom System je nach Einreichungswahrscheinlichkeit grün, gelb oder rot markiert. So kann ein Lehrender sich schnell eine Übersicht darüber verschaffen, bei welchen Studierenden bei der jetzigen Übung ein Risiko besteht, dass diese nicht einreichen, oder welche Studierende in vorangegangenen Übungen häufig gescheitert sind.

14.5 Didaktik / Empirische Befunde

Sowohl OUA als auch der zugrundeliegende Algorithmus Ouroboros wurden in wissenschaftlichen Studien evaluiert. Es wurde gezeigt, dass der Ouroboros Ansatz zur Vorhersage von Übungsabgaben mit Ansätzen, die sich auf Daten aus vergangenen Kursen beziehen, mithalten kann. Empirische Befunde mit 14.000 Lernenden und 559 Lehrenden an der Open University zur generellen Nützlichkeit des Systems für den didaktischen Betrieb legen nahe, dass ein Einsatz des Systems die Lehre verbessert.

14.6 Referenzen

- Herodotou, C., Hlosta, M., Boroowa, A., Rienties, B., Zdrahal, Z., & Mangafa, C. (2019). Empowering online teachers through predictive learning analytics. *British Journal of Educational Technology*, 50(6), 3064–3079.
- Hlosta, M., Zdrahal, Z., & Zendulka, J. (2017, March). Ouroboros: early identification of at-risk students without models based on legacy data. In *Proceedings of the seventh international learning analytics & knowledge conference* (pp. 6–15).
- <https://analyse.kmi.open.ac.uk/>

15 Student Explorer (University of Michigan)

(Open Source)

Student Explorer ist ein Frühwarnsystem, das an der Universität von Michigan entwickelt wird und sich an Lehrende richtet. Ziel des Student Explorer ist es, Lehrende dabei zu unterstützen, gefährdete Studenten zu identifizieren und rechtzeitig auf potentielle Risiken hinzuweisen. Der Algorithmus klassifiziert dazu die Lernenden in Risikoklassen. Lehrende können diese Klassifikationen in einem Dashboard einsehen und sich über zusammenfassende und detaillierte Ansichten eine genauere Übersicht über den Studienverlauf verschaffen bevor sie mit dem Studierenden in Kontakt treten.

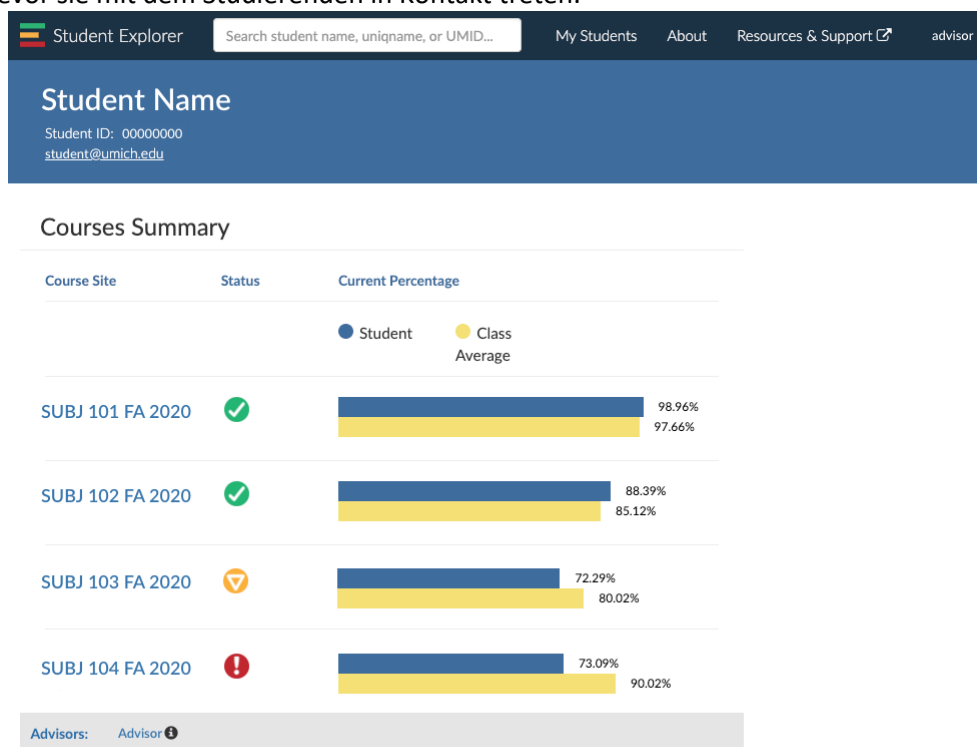


Abbildung 11: Der Student Explorer zeigt im Beispiel die Punktzahl eines Lernenden im Vergleich zum Durchschnitt in verschiedenen Lehrveranstaltungen.¹⁰

15.1 Datengrundlage

Grundlage der Datenerfassung sind LMS Daten, welche die akademischen Leistungen und den Aufwand, der von den Lernenden in die Kurse gesteckt wurde, erfassen. Die akademische Leistung wird anhand von Daten aus dem Klassenbuch des Lernmanagementsystems (LMS) und von Zuweisungsinstrumenten gemessen. Der investierte Aufwand wird anhand von Logins in die Kurswebsite gemessen.

15.2 Datenschutz Funktionen

Mögliche Datenschutzbedenken, die durch den Student Explorer erzeugt werden könnten, wurden in einer Studie systematisch untersucht. Studierende und Lehrende äußerten sich kritisch zur Datenqualität und Datenherkunft. Gleichzeitig stehen sie dem System aber aufgeschlossen gegenüber und sehen die Vorteile der Datensammlung und Datenanalyse. Darum erachten sie vor allem eine Verbesserung der Transparenz bei der

¹⁰ Grafik aus <https://documentation.its.umich.edu/student-explorer-student-detail> (18.10.2020)

Verwendung der Applikation als wichtig sowie die Pflicht einer expliziten Einwilligung für die Verwendung ihrer Daten in der Applikation.

15.3 Datenanalyse

Zur Datenanalyse kommt ein regelbasierter Algorithmus zum Einsatz, der Lernende in drei Stufen einem Risiko zuordnet (Ampelsystem). Die Autoren weisen explizit darauf hin, dass dieser recht sensitiv ist und Lernende oft in die mittlere Risikokategorie klassifiziert werden, obwohl wenig Anlass zur Sorge besteht. Lehrende würden dies allerdings nicht als störend wahrnehmen. Stattdessen sensibilisiert es Lehrende in solchen Fällen kurze Nachfragen bei den Betroffenen zu stellen, um deren Sicht auf die Dinge zu hören.

15.4 Dashboards & Interventionen

Die Benutzungsschnittstelle wurde iterativ entwickelt und bietet Lehrenden mehrere Ansichten. Der Zusammenfassungsbildschirm enthält ein „Alarm“-Feld, das anzeigt, welche Studenten gefährdet sind. Außerdem umfasst er ein Balkendiagramm und eine Tabelle, die Lernenden ihre gesammelten Punkte relativ zum Klassendurchschnitt und ihr Risiko anzeigt. Auf dem detaillierten Klassenbildschirm können die Lehrenden eine Liste mit den akademischen Leistungen und der Risikoeinstufung aller Lernenden über die Zeit sowie abhängig von der LMS Zugriffszahl einsehen. Diese Informationen werden dann von Betreuenden genutzt, um mit den gefährdeten Lernenden Kontakt aufzunehmen.

15.5 Didaktik / Empirische Befunde

Student Explorer wurde im Winter 2011 in mehreren Studien evaluiert. In einer Studie stieg der Punktdurchschnitt (GPA) der Studenten im zweiten Studienjahr, nachdem die Lehrenden das System genutzt hatten. In einer anderen Studie begannen die Lehrenden, den detaillierten Klassenbildschirm in persönlichen Treffen mit den Studenten zu verwenden, um ihren Studienverlauf zu diskutieren. Heute unterstützt Student Explorer 67 Lehrende und erreicht damit 16.600 Lernende.

15.6 Referenzen

- Krumm, A. E., Waddington, R. J., Teasley, S. D., & Lonn, S. (2014). A learning management system-based early warning system for academic advising in undergraduate engineering. In *Learning analytics* (pp. 103–119). Springer, New York, NY.
- Sun, K., Mhaidli, A. H., Watel, S., Brooks, C. A., & Schaub, F. (2019, May). It's My Data! Tensions Among Stakeholders of a Learning Analytics Dashboard. In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems* (pp. 1–14).
- https://github.com/tl-its-umich-edu/student_explorer
- <https://documentation.its.umich.edu/student-explorer-general>

16 Exploratory Learning Analytics Toolkit (eLAT)

(Forschungsprototyp)

Die an der RWTH Aachen entwickelte Anwendung eLAT sammelt Daten über Kurse und Leistungen von Lernenden, um Lehrende bei der Verbesserung ihrer Kurse zu unterstützen. Die Anwendung erlaubt es Lehrenden Benutzerverhalten, Eigenschaften und Prüfungsergebnisse miteinander zu korrelieren und in grafischen Indikatoren zusammenzufassen. Dadurch können Lehrende besser über ihre Kurse reflektieren und Verbesserungspotentiale identifizieren.

16.1 Datengrundlage

Die Anwendung aggregiert Daten aus fünf verschiedenen Kategorien, wie sie beispielsweise während der Benutzung eines LMS anfallen können: Nutzerdaten, Inhaltsdaten, Prüfungsdaten, Aktivitätsdaten und Ereignisdaten. Nutzerdaten umfassen beispielsweise das Alter, Geschlecht oder das Pseudonym des Nutzers. Die Inhaltsdaten umfassen beispielsweise Daten über das Kursforum oder über die hochgeladenen Materialien sowie deren Erstellungszeitraum und Autoren. Prüfungsdaten können via Erweiterung von einer Vielzahl von Prüfungsformaten importiert werden. Aktivitätsdaten zeichnen die Interaktionen zwischen Nutzern und Inhalten im zeitlichen Verlauf auf (z. B. Clickstream) und Ereignisdaten beinhalten typische Ereignisse wie Kursstart, Prüfungsfristen oder andere Zeitspannen.

16.2 Datenschutz Funktionen

Alle Nutzerdaten werden beim Import pseudonymisiert, indem der Benutzername mithilfe von MD5 gehashed wird. Das bedeutet, dass Benutzernamen auf Zahlenkombinationen abgebildet werden, die nicht mehr zurückrechenbar sind. Dadurch ist zumindest eine unmittelbare Identifikation von Nutzern im Datenbestand ausgeschlossen. Jedoch können Nutzer im Zweifelsfall trotzdem erkannt werden (z. B. der einzig männliche Lernende in einem Kurs). Deshalb führt eLAT Anfragen mit einer zu geringen Datenmenge nicht aus, da diese zu einer Deanonymisierung führen könnten.

16.3 Datenanalyse

Die Anwendung erlaubt es Hypothesen von Lehrenden anhand von Daten zu überprüfen. Dabei können vom Lehrenden Daten ausgewählt und dann mithilfe der Anwendung mit Hilfe eines Indikators miteinander in Beziehung gesetzt.

16.4 Dashboards & Interventionen

Die Anwendung beinhaltet verschiedene Ansichten, die es Lehrenden ermöglichen sollen, ihre Daten möglichst schnell und benutzerfreundlich zu analysieren. Im Fokus stehen dabei immer sogenannte Indikatoren, die vom Lehrenden konfiguriert werden können und die Datenströme aus dem System miteinander kombinieren und dann grafisch anzeigen. Die Anwendung bringt dabei sechs grafische Indikatoren mit: „Inhaltszugriffe und zugreifende Lehrende“, „Aktivitätsbereiche“, „Top 10 Lernressourcen“, „Benutzung des Forums“ und „Adoptionsrate“. In der Monitoringansicht können Lehrende verschiedene konfigurierte grafische Indikatoren gleichzeitig sehen, um sich eine Übersicht über den Kursverlauf zu verschaffen. In der Analyseansicht können Lehrende Details des aktuellen Kurses nachgehen und durch Parameteränderungen gezielt einzelne Aspekte der Indikatoren untersuchen. Daten können z.B. nach Zeitraum, Studienfach des Lernenden oder Aktivität des Lernenden auf der Lernplattform gefiltert werden oder auf einen bestimmten Zeitraum begrenzt werden.

16.5 Didaktik / Empirische Befunde

-

16.6 Referenzen

- Dyckhoff, A. L., Zielke, D., Chatti, M. A., & Schroeder, U. (2011). eLAT: An Exploratory Learning Analytics Tool for Reflection and Iterative Improvement of Technology Enhanced Learning. In *EDM* (pp. 355–356).