

Lübcke, Maren; Schrumpf, Johannes; Seyfeli-Özhizalan, Funda; Wannemacher, Klaus
Künstliche Intelligenz zur Studienindividualisierung. Der Ansatz von SIDDATA

Schmohl, Tobias [Hrsg.]; Watanabe, Alice [Hrsg.]; Schelling, Kathrin [Hrsg.]: *Künstliche Intelligenz in der Hochschulbildung. Chancen und Grenzen des KI-gestützten Lernens und Lehrens.* Bielefeld : transcript 2023, S. 213-226. - (Hochschulbildung: Lehre und Forschung; 4)



Quellenangabe/ Reference:

Lübcke, Maren; Schrumpf, Johannes; Seyfeli-Özhizalan, Funda; Wannemacher, Klaus: *Künstliche Intelligenz zur Studienindividualisierung. Der Ansatz von SIDDATA* - In: Schmohl, Tobias [Hrsg.]; Watanabe, Alice [Hrsg.]; Schelling, Kathrin [Hrsg.]: *Künstliche Intelligenz in der Hochschulbildung. Chancen und Grenzen des KI-gestützten Lernens und Lehrens.* Bielefeld : transcript 2023, S. 213-226 - URN: urn:nbn:de:0111-pedocs-278392 - DOI: 10.25656/01:27839

<https://nbn-resolving.org/urn:nbn:de:0111-pedocs-278392>

<https://doi.org/10.25656/01:27839>

Nutzungsbedingungen

Dieses Dokument steht unter folgender Creative Commons-Lizenz: <http://creativecommons.org/licenses/by-sa/4.0/deed.de> - 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 und die daraufhin neu entstandenen Werke bzw. Inhalte nur unter Verwendung von Lizenzbedingungen weitergeben, die mit denen dieses Lizenzvertrags identisch, vergleichbar oder kompatibel sind. Mit der Verwendung dieses Dokuments erkennen Sie die Nutzungsbedingungen an.

Terms of use

This document is published under following Creative Commons-Licence: <http://creativecommons.org/licenses/by-sa/4.0/deed.en> - You may copy, distribute and transmit, adapt or exhibit the work or its contents in public and alter, transform, or change this work as long as you attribute the work in the manner specified by the author or licensor. New resulting works or contents must be distributed pursuant to this licence or an identical or comparable licence.

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



Kontakt / Contact:

peDOCS
DIPF | Leibniz-Institut für Bildungsforschung und Bildungsinformation
Informationszentrum (IZ) Bildung
E-Mail: pedocs@dipf.de
Internet: www.pedocs.de

Künstliche Intelligenz zur Studienindividualisierung

Der Ansatz von SIDDATA

Maren Lübcke, Johannes Schrupf, Funda Seyfeli-Özhizalan und Klaus Wannemacher

Abstract: *Derzeit wird in unterschiedlichen Forschungszusammenhängen diskutiert, wie Studierende bei der Erreichung individueller Bildungsziele unterstützt werden können. Die Studienindividualisierung wird aktuell insbesondere im Zusammenhang mit der Fähigkeit zum eigenaktiven Studieren erörtert. Neben der Hochschulbildung bieten auch die Diskussion zum lebenslangen Lernen und zur weiteren Differenzierung von Lebensläufen wichtige Anknüpfungspunkte. Die Frage stellt sich jedoch, wie Studienindividualisierung trotz enger curricularer Strukturen ermöglicht werden kann und inwiefern hier auch eine technologische Unterstützung möglich ist. Diese Idee wird durch das BMBF-geförderte Projekt SIDDATA verfolgt. SIDDATA ist ein Studienassistenzsystem, das mit Hilfe von intelligenten und selbstlernenden Algorithmen adaptives und individuelles Studieren unterstützt. Im Fokus stehen KI-gestützte Module, die Studierenden dabei helfen, individuelle Interessen zu definieren und diese im Laufe ihres Studiums zu verfolgen. Dieser Beitrag beschäftigt sich mit dem Konzept des Moduls »Fachliche Interessen«, den darin verwendeten KI-Algorithmen, den ersten Erfahrungen mit Test und Einsatz dieses Moduls sowie mit den Potenzialen und Hindernissen für den Einsatz von KI zur Studienindividualisierung. Die Ergebnisse der ersten Testerfahrungen mit dem Modul bestätigen, dass der Einsatz von KI in dem digitalen Studienassistenten SIDDATA Möglichkeiten bietet, die Individualisierung im Studium zu fördern, und auf diese Weise einen Beitrag leistet, Potenziale der KI-gestützten Hochschulbildung zu entdecken und diese weiterzuentwickeln.*

Self-regulated learning is an important aspect of lifelong and individual learning. In higher education however, the question arises how individualisation of study can be enabled despite narrow curricular structures and to what extent technological support is appropriate to achieve this aim. The idea of supporting an individualisation of study is being pursued by the BMBF-funded project SIDDATA. SIDDATA is a study assistance system that uses intelligent and self-learning algorithms to support adaptive and individualised studying. The focus is on AI-supported modules that help students define individual interests and pursue them throughout their studies. This paper deals with the idea behind the SIDDATA module »Specialised Interests«, the AI algorithms used, the first experiences with testing and using this module as well as with the potentials and obstacles higher education may have to face when using

AI to strengthen individual study approaches for their students. The results of the first test experiences with the module confirm that the use of AI in the digital study assistant SIDDATA offers opportunities to promote individualisation in studies and in this way contributes to discovering potentials of AI-supported higher education and development.

Keywords: Studienindividualisierung, Eigenaktives Studieren, Künstliche Intelligenz / Individualisation of Study, Self-regulated Learning, Artificial Intelligence.

Einleitung

Der Hype um die Möglichkeiten der Künstlichen Intelligenz (KI) macht auch vor der Hochschullandschaft nicht Halt. Grundsätzlich bieten alle Bereiche der Hochschulen die Möglichkeit, Technologien zu nutzen. So können Verwaltungen beispielsweise mit Hilfe von KI-Algorithmen neue Steuerungs- und Servicemöglichkeiten nutzen. Durch Nutzung von Chatbots und persönlichen Sprachassistenten können Verwaltungen ihre Dienste ausweiten oder Service-Roboter als digitale Assistenten einsetzen. In der Forschung verändern KI-Verfahren nicht nur Natur- und Technikwissenschaften, sondern auch Lebens-, Sozial- und Geisteswissenschaften. Verfahren des Machine und Deep Learning werden in verschiedenen Bereichen bereits erfolgreich angewendet. Die Anwendungsbereiche erstrecken sich dabei vom Generieren neuer Kunstwerke im Stil bekannter Künstler:innen aus Fotos (Ji et al., 2020) über das Spielen von Videospiele (Smenov et al., 2017) bis hin zur Erkennung von Lungenkrebs (Alakwaa et al., 2017).

Ein häufiges Einsatzgebiet ist zudem der Bereich des Lehrens und Lernens und der »Learning Analytics«, in dem mit Hilfe intelligenter, selbstlernender Algorithmen das Verständnis von Lernprozessen erweitert wird, um so adaptives und individuelles Lernen zu ermöglichen. In Orientierung an Baker und Smith (2019) unterscheiden Zawacki-Richter, Marin, Bond et al. (2020, S. 504) in diesem Bereich zwischen Anwendungen, die an die Lernenden gerichtet sind (z.B. ein intelligentes Tutoringsystem), Tools für Lehrende (z.B. ein Automated Essay Scoring-System) und Anwendungen, die der Hochschule Informationen liefern (z.B. ein Monitoringsystem zum Studienabbruchverhalten). Für den Bereich der Lernunterstützung bieten KI-Technologien damit eine Vielzahl potenzieller Anwendungsmöglichkeiten. Weniger stark diskutiert, aber ebenfalls ein wichtiges Thema ist die Unterstützung des Studiums selbst. Dabei kommt der Studienindividualisierung besondere Bedeutung zu. Die Studienindividualisierung in der Hochschulbildung wird in Zusammenhang mit der Fähigkeit zum eigenaktiven Studieren angesichts der Diskussionen zum lebenslangen Lernen und zur weiteren Differenzierung von Lebensläufen hohe Relevanz beigemessen. Es ist eine der zentralen Zukunftskompetenzen:

»Future-ready students need to exercise agency, in their own education and throughout life. Agency implies a sense of responsibility to participate in the world and, in so doing, to influence people, events and circumstances for the better. Agency requires the ability to frame a guiding purpose and identify actions to achieve a goal.« (OECD, 2018, S. 4)

Die Frage stellt sich jedoch, wie Studienindividualisierung trotz enger curriculärer Strukturen ermöglicht werden kann und wie in diesem Zusammenhang eine KI-basierte Unterstützung möglich ist.

Eine Antwort darauf versucht das BMBF-geförderte Verbundprojekt SIDDATA »Studienindividualisierung durch digitale, datengestützte Assistenten« (<https://www.siddata.de/>) zu geben, an dem die Universitäten Osnabrück, Hannover und Bremen sowie HIS-HE beteiligt sind. Im Fokus steht die Entwicklung eines datengestützten Studienassistenten, der das Studieren, basierend auf personalisierten Empfehlungen, individueller werden lässt. Natürliche Sprachverarbeitungsverfahren sollen für die Analyse und Verarbeitung halbstrukturierter Daten, also Daten aus Campus- und Lernmanagementsystemen, die sowohl Metainformationen als auch einen weiter analysierbaren Inhalt enthalten, angewendet werden. KI-Komponenten helfen dabei, auf individuelle Interessen der Studierenden abgestimmte Inhalte anzuzeigen.

Anhand des konkreten Anwendungsfalls des Moduls »Fachliche Interessen« im Forschungsprojekt SIDDATA beschreibt der vorliegende Beitrag im Folgenden Konzept und Vorhaben hinter dem Modul (Abschnitt 2), die verwendeten KI-Algorithmen (Abschnitt 3) und die ersten Erfahrungen mit Test und Einsatz dieses Moduls (Abschnitt 4), um im Anschluss Potenziale und Hindernisse für den Einsatz von KI zur Studienindividualisierung zu reflektieren (Abschnitt 5). SIDDATA befindet sich im Mai 2021 noch im prototypischen Einsatz: Das Modul »Fachliche Interessen«, das den KI-Algorithmus verwendet, wird in der zweiten Prototypversion von über 1.500 Studierenden der drei Universitäten genutzt. Im Vorfeld war das Modul im Zuge eines Pre-Tests von einer ausgewählten Gruppe von Studierenden aus den drei Standorten erprobt worden. Die Erfahrungen des Pre-Tests mit diesem Modul vom Dezember 2020 vermitteln interessante Erkenntnisse und Ausblicke auf die Möglichkeiten der Unterstützung von Studienindividualisierung durch den Einsatz von KI.

Eigenaktives Studieren und Studienindividualisierung

SIDDATA besteht aus einer Reihe von Modulen, die den Studierenden Unterstützung und Hilfestellung im Studienalltag bieten sollen. Das übergeordnete Ziel von SIDDATA ist dabei die Förderung von eigenaktivem Studieren (in der englischsprache-

chigen Diskussion häufig als *self-regulated learning* (SRL) bezeichnet). Vor dem Hintergrund der Diskussionen zum lebenslangen Lernen und zur weiteren Differenzierung von Lebensläufen ist diese Fähigkeit eine der Schlüsselkompetenzen für gelingendes Studieren (Heublein et al., 2017, S. 147f.).

Das eigenaktive Studieren umfasst verschiedene Modelle, Formen und Grade individualisierten Studierens. Für Schmohl (2019) bedeutet selbstgesteuertes Lernen aus didaktischer Perspektive einen noch stärkeren Wechsel des Fokus von den Lerngegenständen zum Lernprozess selbst (Schmohl, 2019, S. 19f.). Ein einheitliches Verständnis davon fehlt jedoch. Zimmermann betont den Unterschied von Theorien des selbstregulierten Lernens zu anderen Lerntheorien:

»Self-regulated learning theories of academic achievement are distinctive from other accounts of learning and instruction by their emphasis (a) on how students select, organize, or create advantageous learning environments for themselves and (b) on how they plan and control the form and amount of their own instruction.« (Zimmerman, 1990, S. 13f.)

In dieser Definition von SRL ist der kognitionspsychologische Hintergrund der Theorie deutlich erkennbar. SRL impliziert ein regulatorisches Verständnis, bei dem die Studierenden ihre inneren und äußeren Zustände in Kongruenz bringen, um ihre eigenen Lernziele individuell und effektiv zu erreichen. Eine Erweiterung dieses Verständnisses wird jedoch erreicht, wenn SRL um das Konzept der *Agency* erweitert wird. *Agency* impliziert ein Gefühl der Verantwortung, an der Welt teilzunehmen und dabei Menschen, Ereignisse und Umstände zum Besseren zu beeinflussen. *Agency* erfordert die Fähigkeit, einen leitenden Zweck zu formulieren und Handlungen zu identifizieren, um ein Ziel zu erreichen, sowohl in der eigenen Bildung als auch im gesamten Leben (OECD, 2018, S. 4). Dieses umfassendere Verständnis entspricht mehr der Konnotation des deutschen Begriffs des eigenaktiven Studierens, bei dem es nicht nur um Regulation geht, sondern um aktives Gestalten. Von Studierenden werden in diesem Zusammenhang die oft strengen curricularen Vorgaben – darunter Pflichtveranstaltungen, vorgeschriebene Themen und Hausarbeiten – kritisiert. Studieren wird häufig als zu stark »verschult« empfunden (Lübcke et al., 2020a, 2020b). Es gebe einen Zwang, nach den Vorgaben von stark und restriktiv strukturierten Studienprogrammen zu studieren, welche ein Studieren im Sinne des eigenaktiven und selbstregulierten Lernens nicht zuließen.

Dabei reicht das eigenaktive Studieren über die reine Organisation des eigenen Lern- und Studienprozesses hinaus. Es geht darum, das Studium stärker zu individualisieren und selbstgewählte Wege einzuschlagen, zu reflektieren und ggf. zu ändern. Dies ist für viele Studierende der Kern des eigenaktiven Studierens: eigene Interessen zu entwickeln, aus einer großen Bandbreite an Möglichkeiten zu wählen und damit einen eigenen individuellen Studienverlauf zu entwickeln (ebenda).

Im Zentrum von SIDDATA stehen deshalb die folgenden Komponenten:

- Persönlichkeitsmodul
- Auslandssemester
- Matchmaking
- Fachliche Interessen

Das »Persönlichkeitsmodul« gibt kognitionspsychologische Hinweise auf Lernvorlieben und versucht, Studierende bei der Optimierung ihres Lernverhaltens zu unterstützen. Durch das Modul »Auslandssemester« sollen die Studierenden bei der Planung und Durchführung eines Auslandsaufenthaltes unterstützt werden. Das Modul »Matchmaking« zielt darauf ab, Studierende mit ähnlichen Interessen auch studiengang- und standortübergreifend zu vernetzen und zu einem Erfahrungsaustausch anzuregen.

Das Modul »Fachliche Interessen« soll wiederum in zwei Richtungen wirken. Zum einen werden nach Angabe eigener fachlicher Interessen passgenaue Empfehlungen für Veranstaltungen, Seminare, Vorträge, doch auch für Open Educational Resources (OER) und Bücher gegeben. Zum anderen soll diese Komponente dazu dienen, die eigenen fachlichen Interessen stärker zu reflektieren und im Idealfall während des Studienverlaufs zu verfeinern, zu präzisieren oder auch zu modifizieren. Durch Nachfragen, Rückmeldungen und Wiedervorlage der angegebenen fachlichen Interessen will SIDDATA die Reflexion und Auseinandersetzung mit den eigenen Interessen stärken und zu einer Individualisierung des Studierens beitragen.

KI-Algorithmus

Das Modul »Fachliche Interessen« arbeitet KI-basiert. Den Kern dieses Systems bildet »SidBERT«, ein natürliches Sprachverarbeitungssystem auf Grundlage des Sprachverarbeitungssystems Google BERT. Google BERT (Bidirectional Encoder Representations from Transformers; vgl. Devlin et al., 2019) ist ein tiefes neuronales Netzwerk, welches auf der in Vaswani et al. (2017) beschriebenen Transformer-Architektur basiert. Im Vergleich zu anderen natürlichen Sprachverarbeitungsprogrammen erzielt BERT in verschiedenen Benchmarks eine hohe allgemeine Sprachverarbeitungsfähigkeit (Wang et al., 2018; Rajpurkar et al., 2016; Zellers et al., 2018). Die hier genutzte Version von BERT, BERT-base multilingual cased, wurde mittels Wikipedia-Artikeln in insgesamt 104 Sprachen vortrainiert und besitzt dadurch sowohl bereits ein Grundkorpus als auch die Fähigkeit, natürlichsprachliche Informationen syntaktisch und semantisch zu verarbeiten.¹

SidBERT ist damit in der Lage, Eingaben in natürlicher Sprache in eine von insgesamt 534 Wissenskategorien zu klassifizieren. Um Empfehlungen für Studieren-

1 Derzeit läuft SIDDATA nur auf Deutsch.

de nach Wissenskategorien zu generieren, wurde die deutsche Version des Dewey Decimal Classification (DDC) Systems genutzt. Die DDC ist ein in Bibliotheken verwendetes System zur Kategorisierung von Werken. Wissenskategorien innerhalb der DDC werden mit einem eindeutigen Code referenziert.²

Für SidBERT wurden ein Auszug der Bücher im Register der Deutschen Nationalbibliothek sowie die Bibliotheksregister der Universität Osnabrück und der Universität Bremen verwendet. Die Register wurden in einen Gesamtdatensatz zusammengefügt und doppelte Buchtitel sowie Buchtitel mit weniger als drei Zeichen entfernt. 534 DDC-Klassen wurden daraufhin ausgewählt, auf die SidBERT trainiert wurde. Die Auswahl erfolgte anhand statistischer Eigenschaften des Gesamtdatensatzes, sowie der Regel folgend, keine DDC-Klassen unter Level 3 zu nutzen, da diese in der Regel zu allgemein sind, um für die Ziele von SIDDATA nützlich zu sein.³

Die verbleibenden Klassen mit Level ≥ 3 wurden anhand ihrer Verteilungseigenschaften ausgewählt: So wurden DDC-Klassen aufgenommen, die mindestens 250 Buchtitel enthalten. Um eine ungleichmäßige Verteilung der Buchtitel innerhalb der verschiedenen DDC-Klassen zu vermeiden, wurden bis zu 750 Buchtitel für eine DDC-Klasse ausgewählt.

Die Aufgabe von SidBERT ist es, Bildungsressourcen wie z. B. OER, Kurse oder Einzelveranstaltungen sowie zuvor abgefragte Studierendeninteressen in Form von natürlichen Spracheingaben in eine der 534 DDC-Kategorien zu klassifizieren. Um dies zu leisten, besitzt SidBERT neben der BERT-Architektur von 12 Transformer-Encoder-blocks einen sogenannten classification head. Die Transformer-Encoder-Decoder-blocks enthalten die vortrainierten Neuronen des BERT-base-Netzwerkes und verarbeiten einen eingegebenen Text vor. Der classification head besteht aus weiteren Netzwerkschichten (Layers), um eine höhere Kategorisierungspräzision (Performanz) des gesamten Netzwerkes zu erzielen und um den Output des Netzwerkes einer DDC-Kategorie zuzuordnen zu können. Dieses Vorgehen folgt der Annahme, dass es lediglich einen vernachlässigbaren Unterschied von Buchtiteln in DDC-Klassen zu Titeln von anderen Bildungsressourcen, die das gleiche Thema behandeln, gibt. Um SidBERT zum Klassifizieren von Bildungsressourcen verwenden zu können, muss SidBERT trainiert werden. Dies geschieht, indem der Trainingsdatensatz durchlaufen wird und basierend auf den Fehleinschätzungen des Netzwerkes dessen Parameter angepasst werden. Durch das mehrfache Durchlaufen des Da-

2 So besitzt die Kategorie »Künstliche Intelligenz und Natural Computing« beispielsweise den DDC-Code »006.3«. Die DDC ist nach einem hierarchischem Baumsystem aufgebaut. Dies bedeutet, dass die Wissenskategorie »006.3« eine Unterkategorie der Elternkategorie »006«, »Spezielle Computerverfahren«, ist. Diese ist wiederum eine Unterkategorie in der Elternkategorie »00«, »Informatik, Wissen & Systeme«.

3 Ein Beispiel hierfür ist die Klasse »15«, »Psychologie« oder Klasse »63«, »Landwirtschaft«.

tensatzes kann so die Fehlerrate minimiert werden. Ein Durchlauf eines Trainingsdatensatzes entspricht dabei einer sogenannten »Epoche«.

Insgesamt wird das Modell für zwölf Epochen trainiert: In den ersten zehn Epochen sind die Parameter für den BERT-basierten Anteil eingefroren, das heißt, dass während des Trainings lediglich der classification head trainiert wird, indem dieser die vorverarbeiteten Informationen aus dem BERT-basierten Netzwerk erhält und dann interpretiert. Diese Vorgehensweise basiert auf Erkenntnissen von Lee et al. (2019). Nach zehn Epochen hat der classification head ein lokales Optimum erreicht, sodass das gesamte Netzwerk inklusive der Parameter im BERT-basierten Teil des Netzwerks trainiert wird. Dies führt dazu, dass sich das Netzwerk stärker auf die für die Klassifikation wichtigen Faktoren wie Sprache einstellen kann, ohne die allgemeine Sprachverarbeitungsfähigkeit zu verlieren. Diese Tandem-Training-Strategie führt zu einer Klassifikationspräzision von $\sim 44,8\%$ auf dem Testdatensatz. Der Trainingsprozess benötigt rund 21 Tage.

Bewertung durch die Studierenden

Im Januar 2021 wurde SIDDATA an den Universitäten Bremen, Hannover und Osnabrück als Stud.IP-Plugin freigeschaltet. Die Aktivierung des Plugins und der einzelnen SIDDATA-Module ist den Studierenden freigestellt. Auch die Erhebung und Verarbeitung der Datenquellen, die Grundlage der Empfehlungen des Studienassistenten sind, bestimmen die Nutzenden selbst. Mitte Dezember 2020 wurde das Modul »Fachliche Interessen« als Pre-Test vorab für einen kleinen Nutzendenkreis freigeschaltet. In dieser Pre-Test-Phase beinhaltete das Modul »Fachliche Interessen« Veranstaltungsempfehlungen der drei Standorte, jedoch keine Hinweise auf andere Bildungsressourcen.

Mitte Dezember wurden Studierende, die über die Projektpartner:innen an den drei Standorten rekrutiert wurden, mit der Bitte kontaktiert, das Modul »Fachliche Interessen« zur Gestaltung des eigenen Semesterplans genauer zu erkunden und anschließend einen Online-Fragebogen im Sinne eines Pre-Tests zu bewerten.

Neben demografischen Angaben wurden in dem Themenblock *Nutzungserfahrungen* allgemeine Fragen zum Moduleinsatz wie Zufriedenheit, Nutzen und Relevanz sowie auch KI-orientierte Fragestellungen im Hinblick auf eine intelligente Konstruktion gestellt.⁴

4 Beispielfrage: »Wie stark würde sich Dein Semesterplan von Deinem jetzigen unterscheiden, wenn Du SIDDATA schon zu Beginn des Semesters eingesetzt hättest?« Antwortoptionen: sehr stark, eher stark, eher weniger, überhaupt nicht.

Gruppe der Befragten

An dem Pre-Test haben insgesamt 15 Studierende teilgenommen (71,4 % von der Leibniz Universität Hannover, 21,4 % von der Universität Bremen und 7,1 % von der Universität Osnabrück). Die sehr geringe Teilnehmendenzahl ist auch darauf zurückzuführen, dass durch Verzögerungen in der Freischaltung von SIDDATA erst kurz vor Weihnachten 2020 mit der Rekrutierung begonnen werden konnte. Die folgenden Angaben können vor diesem Hintergrund lediglich als erste Anhaltspunkte interpretiert werden.

Die Mehrheit der Teilnehmenden (57,1 %) sind Studierende eines Bachelorstudiengangs, 42,9 % Studierende eines Masterstudiengangs. Die Befragten kommen aus den Studiengängen der Wirtschaftswissenschaften, Sozialwissenschaften, Chemie, Informatik und aus dem konstruktiven Ingenieurbau. Die Teilnehmenden befinden sich überwiegend in der fortgeschrittenen Studienphase (79,6 % im 5. Semester oder höher). Nur 21,4 % befinden sich hingegen in der Studieneingangsphase (1. Semester). Dass das Feedback zum Modul »Fachliche Interessen« vor allem aus der Gruppe der älteren Studierenden kommt, ist insofern erfreulich, als anzunehmen ist, dass diese Gruppe bereits eigene fachliche Interessen entwickelt hat und routiniert in der Stundenplanung ist. Folglich können die von SidBERT empfohlenen Veranstaltungen durchaus auf Eignung bewertet werden.

Ergebnisse der Befragung

Die Teilnehmenden gaben an, jeweils 1 bis 15 fachliche Interessen formuliert zu haben. Im Durchschnitt wurden fünf fachliche Interessen angegeben. Während rund 71,5 % der Studierenden angaben, dass ihnen die Formulierung von fachlichen Interessen leicht (50 %) bis sehr leicht (21,5 %) gefallen ist, fiel es rund 28,5 % der Studierenden schwer (21,4 %) bis sehr schwer (7,1 %), individuelle Interessen zu formulieren. Es gibt also – trotz der geringen Teilnehmendenzahl – erste Hinweise darauf, dass doch ein relativ großer Anteil an Studierenden Schwierigkeiten hat, solche Interessen zu formulieren.


Qualität der Empfehlungen

Auf Basis der angegebenen Interessen erhielten die Studierenden Veranstaltungsempfehlungen. Die Zufriedenheit mit den Empfehlungen ergibt ein geteiltes Bild: Rund die Hälfte der Studierenden äußerte sich positiv. Demgegenüber waren rund 50 % unzufrieden mit den empfohlenen Veranstaltungen. Dieses Ergebnis wirkt sich zudem direkt auf die Wahrnehmung der Nützlichkeit des Moduls aus. Insgesamt gab die Hälfte der teilnehmenden Studierenden an, dass das Modul einen hohen Nutzen für ihr Studium habe (7,1 % »stimme voll zu«, 42,9 % »stimme eher zu«), wäh-

rend für die andere Hälfte der Befragten das Modul »Fachliche Interessen« keinen hohen Nutzen hatte.

SidBERT war immerhin nach Einschätzung von 64,3 % der Befragten in der Lage, diese auf neue Veranstaltungen aufmerksam zu machen, die sie zuvor nicht berücksichtigt hatten. Dies hätte aber nur bei 21,4 % tatsächlich zu einem anderen Semesterplan geführt, wenn SIDDATA zu diesem Zeitpunkt schon zur Verfügung gestanden hätte. 42,9 % der Studierenden gaben demnach an, dass sich ihr Semesterplan mit der Unterstützung von SIDDATA nicht anders darstellen würde als ohne.

Abbildung 1: Einfluss auf die Semesterplanung durch das Modul »Fachliche Interessen«.



Die durchaus gemischte Beurteilung des Moduls »Fachliche Interessen« durch die Studierenden hatte sich bereits während des Trainings des SidBERT-Netzwerkes angedeutet. Mit 44,8 % Klassifikationspräzision ist die Performanz von SidBERT auf dem Validierungsdatensatz signifikant unter anderen Performanzen von BERT-Architekturen in anderen Aufgabendomänen. Des Weiteren ist SidBERT mit 534 DDC-Klassen nicht in der Lage, eine besonders feine Granularität der vorgeschlagenen Bildungsressourcen zu erreichen. Beide Kritikpunkte lassen sich auf den von uns verwendeten Datensatz zurückführen: Mit einer höheren Anzahl an Trainingsdaten pro Klasse könnte die Performanz von SidBERT gesteigert werden. Gleichzeitig könnte eine höhere Anzahl an Buchtiteln es ermöglichen, mehr DDC-Klassen in SidBERT einzubinden, was eine feinere Granularität in der Klassifizierung von Studienzielen und Bildungsressourcen ermöglichen würde.

Reflexion

Neben dem Empfehlen konkreter Veranstaltungen sollte das Modul »Fachliche Interessen« den Reflexionsprozess der Studierenden zu den eigenen fachlichen Interessen anstoßen. Dies scheint weitestgehend gelungen zu sein: 64,3 % der Befragten geben an, zuvor genannte fachliche Interessen auf Basis der vorgeschlagenen Veranstaltungen modifiziert zu haben. Immerhin knapp ein Drittel (28,5 %) der Studierenden gab an, dass ihnen die Formulierung von fachlichen Interessen schwer bis sehr schwer gefallen sei. Bei 64,3 % der Befragten hat die Frage eine Reflexion über die eigenen fachlichen Interessen angestoßen (21,4 % »stimme voll zu«, 42,9 % »stimme eher zu«). Damit also das KI-Modul richtig funktionieren kann, müssen Studierende bei Bedarf Hilfestellungen zur Formulierung der eigenen fachlichen Interessen erhalten. Denn nur wenn diese richtig benannt sind, kann SIDDATA zufriedenstellende Empfehlungen generieren.

In den offenen Fragen nach dem Mehrwert dieses Moduls kann somit auf diesen Reflexionsaspekt verwiesen werden. Die Möglichkeit, basierend auf eigenen Interessen Veranstaltungsempfehlungen zu erhalten, ermögliche es, »[a]ndere Blickwinkel einzuschlagen« (Auszug aus einem studentischen Eintrag in das Kommentarfeld »Was hat Dir bei der Funktion »Fachliche Interessen« gefallen?«).

Wahrnehmung des Moduls »Fachliche Interessen«

So gemischt die Ergebnisse bewertet wurden, fällt auch die generelle Einschätzung des dahinter liegenden Algorithmus aus. 57,2 % der Befragten geben an, dass das Modul basierend auf eigenen Einträgen individuelle Empfehlungen gibt und damit intelligent konstruiert ist (14,3 % »stimme voll zu«, 42,9 % »stimme eher zu«). 42,9 % können dieser Aussage dagegen nicht zustimmen. Es scheint tendenziell aber ein generelles Interesse an dieser Art der Studierendenunterstützung zu geben (64,3 %). So ist ein solches Angebot nur für rund ein Drittel der Befragten (35,7 %) von geringem Interesse.

Diskussion

Der Grundansatz des SIDDATA-Projekts, Anwendungen aus dem Bereich KI für die Studienunterstützung zu entwickeln und datengestützte Assistenzsysteme einzusetzen, um ein eigenaktives und individuelleres Studium zu ermöglichen, scheint sich anhand erster Erfahrungen mit dem Einsatz des Moduls »Fachliche Interessen« zu bestätigen. Studierende scheinen entsprechende Anwendungen im Grundsatz zu akzeptieren: für 64,3 % der befragten Studierenden ist das KI-basierte Modul von Interesse; 50,0 % attestierten dem Modul bereits einen hohen bis sehr hohen Nut-

zen. Angesichts der Limitationen des durchgeführten Pre-Tests unter ausgewählten Studierenden an den drei Standorten wie einer geringen Teilnehmendenzahl sollen Folgeerhebungen weiteren Aufschluss über studentische Nutzungserfahrungen und die Wahrnehmung des Nutzens des Moduls geben. Bedeutsam erscheint jedoch schon jetzt die Erkenntnis, dass Module, die natürlichsprachliche Eingaben von Nutzenden verarbeiten, eine gute und didaktisch sinnvolle Nutzerunterstützung benötigen. In diesem Fall müssen Studierende in der Lage sein, eigene fachliche Interessen zu formulieren, was keinesfalls eine Selbstverständlichkeit darstellt. Nur wenn man hier Unterstützungsangebote gerade für Studierende der ersten Semester anbietet, können gute Empfehlungen generiert werden. Ansonsten gilt das Motto »garbage in – garbage out«.

Als Herausforderung erweist sich die Notwendigkeit, entsprechende KI-basierte Module bzw. Machine-Learning-Modelle über einen gewissen Zeitraum zu trainieren, bevor sie produktiv verwendet werden können. Je ausgiebiger das Modell anhand einer erheblichen Menge von Daten und Trainingsiterationen kalibriert und nachjustiert wird, desto zufriedenstellender dürften Ergebnisse aus Sicht der Studierenden ausfallen. Eine hierfür wichtige Grundvoraussetzung ist die Verfügbarkeit hinreichend großer Datensätze, die die Struktur der DDC repräsentieren. Je größer die Anzahl der genutzten Buchtitel zum Trainieren der Anwendung und zur Ausdifferenzierung der Klassifizierung von Studienzielen und Bildungsressourcen ist und je mehr das System im Live-Betrieb eingesetzt wird, desto besser kann der Algorithmus werden und desto hilfreicher können Empfehlungen ausfallen.

Während die DDC an sich durch ihren hohen Grad an Kuratierung gut für Machine-Learning-Modelle geeignet ist, bieten große Archive wie die Deutsche Nationalbibliothek keine digitalen Schnittstellen, um einen hinreichend großen Datensatz für das Trainieren von Machine-Learning-Modellen zu generieren. Lokale Universitätsbibliotheken, die ein digitales Register der geführten Werke leicht zur Verfügung stellen können, besitzen in der Regel hingegen lediglich ein kleines Korpus an Werken, die die DDC nicht hinreichend abdecken. Um in Zukunft eine zufriedenstellende Granularität der in diesem Modul verwendeten DDC-Klassen sicherzustellen, müssen solche Schnittstellen geschaffen und genutzt werden.

Auch die Ausweitung auf andere Bildungsressourcen wie OER, Einzelvorträge oder einzelne Veranstaltungen innerhalb eines Kurses wird den subjektiv wahrgenommenen Nutzen und das Potenzial dieser Funktion verbessern. Die aus dem Pre-Test gewonnenen ersten positiven Rückmeldungen von Studierenden aller drei beteiligten Universitäten deuten gegenwärtig darauf hin, dass KI-basierende und ausgiebig mit geeigneten Datensätzen trainierte Studienassistenten tatsächlich helfen können, Möglichkeiten und Spielräume im Studium aufzuzeigen und dadurch zu einer stärkeren Individualisierung beitragen.

Da Potenziale der Nutzung von KI-Komponenten für die Unterstützung Studierender zwar auch in anderen Kontexten diskutiert werden (beispielsweise die

Nutzung eines KI-basierten mobilen Avatars als Coaching-Assistent für die psychologische Unterstützung Studierender oder die Nutzung eines KI-basierten Tutors in Großveranstaltungen, s. Wannemacher & Bodmann, 2021, S. 16, 30f.), jedoch kaum im Hinblick auf den Aspekt der Studienindividualisierung im Engeren, der bei SIDDATA im Vordergrund steht, lassen sich bislang nur sehr eingeschränkt Bezüge des spezifischen Ansatzes und der ersten Evaluationsergebnisse bei SIDDATA zu anderen Forschungsprojekten darstellen. Angesichts der bislang begrenzten Reichweite der Nutzung des Studienassistenten durch eine begrenzte Gruppe von Studierenden an wenigen Hochschulen erscheint eine Validierung der Ergebnisse des Pre-Tests sinnvoll, sobald sich die Nutzung des Systems auf einen breiteren Kreis von Studierenden erweitert hat. Entsprechende Möglichkeiten zeichnen sich in Zusammenhang mit der Verfeinerung des »Fachliche Interessen«-Moduls und weiterer Kernfunktionen des Systems im Rahmen eines weiteren Prototyps und der in diesem Zusammenhang angestrebten breiteren Dissemination des Systems an den Hochschulen ab.

Ausblick

Zukünftige Weiterentwicklungen des »Fachliche Interessen«-Moduls von SIDDATA sollen sowohl individueller als auch reflexiver werden: Mit einer kontextsensitiven Filterung könnten so z. B. nur fachliche Ressourcen empfohlen werden, die dem Wissensstand der Studierenden im jeweiligen Gebiet entsprechen oder die einen möglichst hohen Grad an Differenz in ihren epistemologischen Grundannahmen innerhalb eines Feldes aufweisen. Dies würde dazu beitragen, dass die empfohlenen fachlichen Ressourcen insgesamt noch genauer mit fachlichen Interessen der Studierenden korrespondieren. Eine kontextsensitive Filterung verfügbarer Ressourcen würde die Auswahl geeigneter Studien- und Lernangebote dadurch weiter vereinfachen, dass Studierenden passendere Ressourcen angeboten würden.

Zusätzlich werden die Daten aus dem »Fachliche Interessen«-Modul auch zur Selbstreflexion des eigenen Bildungsweges beitragen, indem die bereits genutzten Bildungsressourcen visuell innerhalb der DDC-Baumstruktur dargestellt und Trends im eigenen Studium erkannt werden können. In Verbindung mit einem allgemeinen Fragebogen zur Reflexion von Studienzielen könnten Studierende hierdurch noch selbstbestimmter ihre Semesterplanung eigenen Interessen anpassen.

Maren Lübcke: HIS-Institut für Hochschulentwicklung, Geschäftsbereich Hochschulmanagement; luebcke@his-he.de

Johannes Schruppf: Universität Osnabrück, Institut für Kognitionswissenschaft; jschruppf@uni-osnabrueck.de

Funda Seyfeli-Özhizalan: HIS-Institut für Hochschulentwicklung, Geschäftsbereich Hochschulmanagement; seyfeli@his-he.de

Klaus Wannemacher: HIS-Institut für Hochschulentwicklung, Geschäftsbereich Hochschulmanagement; wannemacher@his-he.de

Literatur

- Alakwaa, W.; Nassef, M.; Badr, A.: Lung cancer detection and classification with 3D convolutional neural network (3D-CNN). In: International Journal of Biology and Biomedical Engineering Bd. 11 (2017), Nr. 8, S. 66–73.
- Baker, T. & Smith, L. (2019). Educ-AI-tion Rebooted? Exploring the future of artificial intelligence in schools and colleges. Nesta Foundation. Abgerufen 15.12.2020, von https://media.nesta.org.uk/documents/Future_of_AI_and_education_v5_WEB.pdf.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. NAACL HLT 2019 – 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies – Proceedings of the Conference, 1(Mlm), S. 4171–4186.
- Heublein, U., Ebert, J., Hutzsch, C., Isleib, S., König, R., Richter, J., & Woisch, A. (2017). Zwischen Studierenerwartungen und Studienwirklichkeit (Bd. 1). German Centre for Higher Education Research and Science Studies (DZHW), S. 147f.
- Ji, W.; Guo, J.; Li, Y.: Multi-head mutual-attention CycleGAN for unpaired image-to-image translation. In: IET Image Processing Bd. 14 (2020), Nr. 11, S. 2395–2402.
- Lee, J., Tang, R., & Lin, J. (2019). What Would Elsa Do? Freezing Layers During Transformer Fine-Tuning. Abgerufen 06.01.2021, von <http://arxiv.org/abs/1911.03090>.
- Lübcke, M., Seyfeli, F. & Wannemacher, K. (2020a). What does the future tell us about the present? Learning pathways as future models for universities and a stimulus for student reflection. In: ETH Learning and Teaching Journal, Vol 2, No 2, 20. ICED 2020 proceedings. S. 487–490.
- Lübcke, M., Seyfeli, F., Wannemacher, K. & Rhein, R. (2020b). Nudging self-regulation as a means of study assistance and educational development. In: ETH Learning and Teaching Journal, Vol 2, No 2, 20. ICED 2020 proceedings. S. 523–526.
- OECD (2018): The Future of Education and Skills: Education 2030 Position Paper OECD The future we want. Abgerufen 10.08.2020, von [https://www.oecd.org/education/2030/E2030%20Position%20Paper%20\(05.04.2018\).pdf](https://www.oecd.org/education/2030/E2030%20Position%20Paper%20(05.04.2018).pdf)

- Rajpurkar, P., Zhang, J., Lopyrev, K., & Liang, P. (2016). SQuAD: 100,000+ questions for machine comprehension of text. *EMNLP 2016 – Conference on Empirical Methods in Natural Language Processing, Proceedings*, ii, S. 2383–2392.
- Schmohl, T. (2019): Selbstgesteuertes Lernen. Explorative hochschuldidaktische Formate mit Modellcharakter für vier akademische Statusgruppen. In: Schmohl et al.: *Selbstorganisiertes Lernen an Hochschulen. Strategien, Formate und Methoden*. Bielefeld. (wbv).
- Semenov, A.; Romov, P.; Korolev, S.; Yashkov, D.; Neklyudov, K.: Performance of Machine Learning Algorithms in Predicting Game Outcome from Drafts in Dota 2. In: Ignatov, D. I.; Khachay, M. Y.; Labunets, V. G.; Loukachevitch, N.; Nikolenko, S. I.; Panchenko, A.; Savchenko, A. V.; Vorontsov, K. (Hg.): *Analysis of Images, Social Networks and Texts*. Cham: Springer International Publishing, 2017 — ISBN 978-3-319-52920-2, S. 26–37.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 2017-Decem. (Nips), S. 5999–6009.
- Wannemacher, K. & Bodmann, L. (2021). *Künstliche Intelligenz an den Hochschulen – Potenziale und Herausforderungen in Forschung, Studium und Lehre sowie Curriculumentwicklung*. Berlin: Hochschulforum Digitalisierung (Arbeitspapier Nr. 59).