

Personalisierte und adaptive Lernumgebungen für Onlineweiterbildungen

YVONNE M. HEMMLER, DIRK IFENTHALER

Zusammenfassung

Fortschritte in der Bildungstechnologie sowie auf dem Gebiet der künstlichen Intelligenz (KI) ermöglichen die Entwicklung personalisierter und adaptiver Lernumgebungen. Das Ziel dieses Beitrags ist es, einen Überblick über aktuelle Forschungsbeiträge zu personalisierten und adaptiven Lernumgebungen sowie deren Potenziale für Onlineweiterbildungen zu geben. Da Forschungsbeiträge zu personalisierten und adaptiven Lernumgebungen für die Onlineweiterbildung nur vereinzelt vorliegen, werden empirische Befunde aus der Hochschulforschung auf die Forschung und Praxis von Onlineweiterbildungen übertragen. Dabei wird herausgearbeitet, welche Indikatoren (z. B. kognitive Fähigkeiten, Vorwissen) wichtige Informationen über Lernverhalten preisgeben und daher für die Vorhersage und gezielte Unterstützung von Lernprozessen verwendet werden sollten. Herausforderungen für die Entwicklung personalisierter und adaptiver Lernumgebungen für die Onlineweiterbildung werden diskutiert.

Schlagerworte: Onlineweiterbildung; adaptive Lernumgebung; Learning Analytics; künstliche Intelligenz

Abstract

Advances in educational technology and artificial intelligence (AI) enable the development of personalized and adaptive learning environments. The aim of this chapter is to provide an overview of recent research contributions on personalized and adaptive learning environments and their potentials for online further education. Since research on personalized and adaptive learning environments for online further education is scarce, empirical findings from higher education research are applied to research and practice of online further education. We elaborate which indicators (e. g., cognitive abilities, prior knowledge) reveal important information about learning behavior and should, therefore, be used to predict and specifically support learning processes. Challenges for the development of personalized and adaptive learning environments for online further education are discussed.

Keywords: online further education, adaptive learning environment, learning analytics, artificial intelligence

1 Einleitung

Aufgrund der fortschreitenden Digitalisierung und Globalisierung befindet sich die moderne Arbeitswelt in einem ständigen Wandel. Arbeitnehmende müssen sich permanent neuen Herausforderungen stellen sowie an Veränderungen anpassen, um den Arbeitsanforderungen gerecht zu werden (Manuti, Pastore, Scardigno, Giancaspro & Morciano 2015; Tynjälä 2008). Lebenslanges Lernen und Weiterbildung sind daher für Arbeitnehmende sowie für Unternehmen unabdingbar, um erforderliche Kompetenzen zu erwerben und in der schnelllebigen Arbeitswelt Schritt halten zu können (Ifenthaler, 2018). Traditionelle Weiterbildungsangebote, die meist in Form formaler Präsenzs Schulungen außerhalb des Arbeitsplatzes stattfinden, sind dabei jedoch häufig nicht flexibel genug, um den sich ständig ändernden Arbeitsanforderungen gerecht zu werden (Manuti et al., 2015; Schumacher, 2018). Darüber hinaus nehmen Arbeitnehmende mit unterschiedlichen Erwartungen an Weiterbildungen teil und verfügen über unterschiedliche Vorkenntnisse, Fähigkeiten und Bedürfnisse. Die Berücksichtigung dieser unterschiedlichen Voraussetzungen und Bedürfnisse der Lernenden ist in traditionellen Präsenzs Schulungen, die eine One-size-fits-all-Strategie verfolgen, nur schwer möglich (Fake & Dabbagh, 2020; Kinshuk, 2016).

Vor diesem Hintergrund wird das Potenzial digitaler Medien und Technologien für Weiterbildungsangebote deutlich. Fortschritte in der Bildungstechnologie sowie auf dem Gebiet der künstlichen Intelligenz (KI) ermöglichen die Entwicklung personalisierter und adaptiver Lernumgebungen. Wenn Lernende in digitalen Lernumgebungen interagieren, hinterlassen sie Datenspuren, die nützliche Einblicke in das Lernverhalten und den Lernprozess liefern können (Long & Siemens, 2011). Mithilfe dieser Datenspuren sowie spezieller Methoden der KI kann das Lernangebot kontinuierlich an die individuellen Voraussetzungen und Bedürfnisse der Lernenden sowie an die aktuellen Arbeitsanforderungen angepasst werden (Xie, Chu, Hwang & Wang, 2019; Zawacki-Richter, Marín, Bond & Gouverneur, 2019).

Trotz ihres vielversprechenden Potenzials sind personalisierte und adaptive Lernumgebungen in der Onlineweiterbildung kaum implementiert (Giacumo, Villachica & Breman, 2018; Xie et al., 2019). Obwohl digitale Medien und Technologien in der beruflichen Weiterbildung immer mehr Einsatz finden (Ifenthaler, 2018), stehen Onlineweiterbildungsangebote häufig nur als statisches Gesamtpaket zur Verfügung und ahmen damit die One-size-fits-all-Strategie von traditionellen Präsenzs Schulungen nach (Fake & Dabbagh, 2020). Eine Herausforderung bei der Gestaltung personalisierter und adaptiver Lernumgebungen liegt in der Identifikation zuverlässiger Indikatoren (z. B. soziodemografische Merkmale, kognitive Fähigkeiten, Vorwissen), nach denen die Lernumgebung mithilfe spezieller Algorithmen personalisiert und angepasst werden soll (Plass & Pawar 2020a; Yau & Ifenthaler, 2020). Indikatoren sind Variablen, in denen sich Lernende unterscheiden und die einen relevanten Einfluss auf Lernprozesse und Lernerfolg ausüben können (Plass & Pawar, 2020a). Forschungsbeiträge zur Identifikation zuverlässiger Indikatoren für die Onlineweiterbildung liegen bislang nur vereinzelt vor (Seufert, Guggemos & Ifenthaler 2021; Xie et al., 2019). Ziel dieses

Beitrags ist es daher, aktuelle Forschungsbeiträge aus dem Bereich der Hochschulbildung auf die Onlineweiterbildung zu übertragen. Nach einer Einführung in das Konzept des personalisierten und adaptiven Lernens sowie einem Überblick über den aktuellen Stand der Forschung und empirischen Evidenz zu personalisierten und adaptiven Lernumgebungen in der Hochschulbildung soll dabei speziell diskutiert werden, wie zuverlässige Indikatoren für personalisierte und adaptive Lernumgebungen für Onlineweiterbildung identifiziert werden können und welche Herausforderungen sich daraus ergeben.

2 Personalisiertes und adaptives Lernen

Die beiden Bezeichnungen personalisiertes Lernen und adaptives Lernen werden in der Literatur häufig synonym verwendet und meist nicht klar voneinander abgegrenzt. Nur wenige Forschende definieren die beiden Bezeichnungen getrennt voneinander (Xie et al., 2019). Dabei bezeichnet personalisiertes Lernen die Anpassung des Lernangebots an die individuellen Voraussetzungen und Bedürfnisse (z. B. Erwartungen, Vorkenntnisse, Fähigkeiten, Präferenzen, Lernstrategien) der Lernenden. Personalisiertes Lernen beinhaltet somit eine Variation der Lerninhalte und -materialien sowie der pädagogischen Methoden und Tools zwischen den Lernenden. Ziel des personalisierten Lernens ist es, das Lernen effizienter zu gestalten, indem Lernende ein auf ihre Person möglichst optimal zugeschnittenes Lernangebot erhalten (Fake & Dabbagh, 2020; U. S. Department of Education, 2017). Personalisiertes Lernen war schon lange vor dem Aufkommen KI-basierter Technologien von Interesse für Bildungsforschende (Plass & Pawar, 2020a). So kann die Personalisierung beispielsweise auch durch die Lehrperson oder die Lernenden selbst vollzogen werden und ist nicht zwingenderweise an den Einsatz KI-basierter Technologien geknüpft (Fake & Dabbagh, 2020).

Die meisten Definitionen zu adaptivem Lernen fokussieren hingegen auf die Analyse großer Mengen an Bildungsdaten (Big Data) sowie den Einsatz KI-basierter Technologien zur Anpassung des Lernangebots an individuelle Voraussetzungen und Bedürfnisse. Dementsprechend kann adaptives Lernen als personalisiertes Lernen, das mithilfe KI-basierter Technologien umgesetzt wird, bezeichnet werden (Aleven, McLaughlin, Glenn & Koedinger, 2017; Peng, Ma & Spector, 2019; Plass & Pawar, 2020b). Obwohl die Wirksamkeit KI-basierter Technologien hinsichtlich Lernerfolg (z. B. Abschließen des Kurses, Erreichen der Lernziele, guter Notendurchschnitt) nur unzureichend erforscht ist (Ifenthaler & Yau, 2020), bieten KI-basierte Technologien gegenüber einer Personalisierung durch die Lehrperson oder die Lernenden selbst einige Vorteile. So können mithilfe KI-basierter Technologien sowohl statische individuelle Merkmale als auch sich ständig ändernde Informationen kontinuierlich erhoben und analysiert werden, um in nahezu Echtzeit Änderungen am Lernangebot vorzunehmen und Lernen dadurch zu unterstützen (Ifenthaler, 2015; Xie et al., 2019). Menschliche Lehrpersonen verfügen wohl kaum über die notwendigen Ressourcen, um den Lernprozess der einzelnen Lernenden kontinuierlich zu überwachen und den

Unterricht entsprechend anzupassen sowie auf einzelne Lernende individuell einzugehen. Lernende verfügen nicht immer über die entsprechenden Kompetenzen, um geeignete Lernmaterialien selbst auszuwählen (Ebner, Neuhold & Schön, 2013; Kinschuk, 2016).

Sowohl personalisiertes als auch adaptives Lernen zielen somit auf eine Unterstützung des Lernens durch Anpassung des Lernangebots an die aktuelle Situation der Lernenden ab. Die in diesem Beitrag verwendete Bezeichnung *personalisierte und adaptive Lernumgebungen* bezieht sich somit auf KI-basierte, digitale Lernsysteme, die kontinuierlich Informationen über Lernende, den Lernprozess sowie die Lernumgebung sammeln und analysieren, um das Lernangebot an die individuellen Voraussetzungen und Bedürfnisse der Lernenden anzupassen und Lernen fortlaufend zu unterstützen (Gašević, Dawson & Siemens, 2015; Ifenthaler, 2015; Wozniak, 2020). Personalisierte und adaptive Lernumgebungen funktionieren nach dem gleichen Prinzip wie Online-shopping-Plattformen und Streamingportale. Anbieter wie Amazon oder Netflix sammeln riesige Mengen an Nutzerdaten, die durch spezielle Algorithmen geleitet werden, um Nutzenden personalisierte Werbung und Produktvorschläge zu präsentieren. Nach demselben Prinzip sammeln personalisierte und adaptive Lernumgebungen riesige Mengen an Bildungsdaten, um Lernverhalten zu analysieren, das Lernangebot automatisch an die individuelle Situation der Lernenden anzupassen und den Lernprozess dadurch effizienter zu gestalten sowie den Lernerfolg zu optimieren (Roberts-Mahoney, Means & Garrison, 2016; Wozniak, 2020).

Die Anwendungsmöglichkeiten und Funktionen von personalisierten und adaptiven Lernumgebungen sind vielseitig. So können beispielweise Lerninhalte und Lernmaterialien wie spezielle Übungen, Videos oder Texte an die jeweiligen Interessen und Präferenzen sowie den aktuellen Wissenstand der Lernenden angepasst werden (Hsu, Hwang & Chang, 2013; Huberth, Chen, Tritz & McKay, 2015; Zawacki-Richter et al., 2019). Personalisierte Nutzeroberflächen, adaptives Feedback sowie personalisierte Lernpfade und Lernzielempfehlungen, angepasst an die jeweiligen Voraussetzungen und Bedürfnisse der Lernenden, stellen weitere mögliche Funktionen personalisierter und adaptiver Lernumgebungen dar (Ley, Kump & Gerdenitsch, 2010; Schumacher & Ifenthaler, 2021). Personalisierte und adaptive Lernumgebungen können berufstätige Lernende dabei unterstützen, ihre Karriere und persönliche Entwicklung zu planen, indem sie Empfehlungen hinsichtlich zu erwerbender Kompetenzen geben sowie geeignete Lerninhalte vorschlagen (Xie et al., 2019; Zawacki-Richter et al., 2019).

Ein Potenzial personalisierter und adaptiver Lernumgebungen liegt darüber hinaus in der Unterstützung von informellem Lernen am Arbeitsplatz (Schumacher, 2018). Im Arbeitskontext ist Lernen nicht nur auf formale Weiterbildungsangebote begrenzt, sondern findet häufig auf informellem Wege während der Arbeit statt. Wenn Arbeitnehmende Aufgaben bearbeiten, Probleme lösen oder mit Teammitgliedern interagieren, erweitern sie (häufig unbewusst) ihr Wissen und ihre Kompetenzen. Der Arbeitsalltag selbst bietet viele Möglichkeiten des Lernens (Manuti et al., 2015; Tynjälä, 2008). Da informelles Lernen häufig spontan und unbewusst auftritt, ist es schwer, informelle Lernprozesse und deren Qualität zu erfassen (Manuti et al.,

2015; Schumacher, 2018). Durch die zunehmende Verwendung digitaler Medien und Technologien am Arbeitsplatz können jedoch nützliche Daten aus dem Arbeitsalltag (z. B. Onlinerecherchen, Aktivitäten auf sozialen Netzwerken, Kalendereinträge) gesammelt und von personalisierten und adaptiven Lernumgebungen genutzt werden, um informelles Lernen am Arbeitsplatz zu unterstützen. Wenn Arbeitnehmende bei der Bearbeitung einer Aufgabe mit einem Problem konfrontiert werden (was durch Suchen in Google oder internen Wikis angezeigt werden könnte), könnten personalisierte und adaptive Lernumgebungen geeignete Lernmaterialien oder Teammitglieder im Unternehmen vorschlagen, die mit diesem Problem bereits Erfahrungen gemacht haben und somit weiterhelfen könnten. Eine solche Unterstützung von informellem Lernen setzt jedoch eine Verknüpfung unterschiedlicher digitaler Lern- und Arbeitssysteme voraus (Schumacher, 2018).

3 Aktueller Stand der Forschung und empirische Evidenz

Forschungsbeiträge zu personalisierten und adaptiven Lernumgebungen für die Onlineweiterbildung liegen nur vereinzelt vor (Seufert et al., 2021). Daher werden aktuell robuste empirische Befunde aus den Bereichen der Hochschulforschung und angrenzenden Kontexten auf die Forschung und Praxis der Onlineweiterbildung übertragen. Vorliegende Forschungsarbeiten fokussieren den Einsatz unterschiedlicher Werkzeuge (z. B. Netzwerkanalysertools, Dashboards; Atif, Richards, Bilgin & Marrone, 2013), reflektieren internationale Praxiserfahrungen (z. B. Erfolgsfaktoren von Maßnahmen; Sclater, Peasgood & Mullan, 2016), analysieren institutionelle Rahmenbedingungen (z. B. Veränderungsmanagement; Buckingham, Shum & McKay, 2018) und empfehlen administrative Regularien (z. B. Datenschutzbestimmungen; Tsai et al., 2018). Erste systematische Übersichtsarbeiten zu KI-unterstützten personalisierten und adaptiven Lernumgebungen formulieren Gelingensbedingungen zur Organisationsentwicklung (z. B. Weiterbildung von Stakeholdern; Ferguson et al., 2016), identifizieren offene Forschungsbereiche (z. B. faire Algorithmen; Papamitsiou & Economides, 2014) und prüfen die Effizienz von KI-basierten Interventionen (z. B. Feedback- und Unterstützungsmaßnahmen; Larrabee Sønderlund, Hughes & Smith, 2019).

3.1 Learning Analytics

Der Forschungsbereich um Datenanalysen und Algorithmen im Kontext der Bildung wird seit nahezu einer Dekade als Learning Analytics bezeichnet. Learning Analytics verwenden statische Daten von Lernenden und dynamische, in Lernumgebungen gesammelte Daten über Aktivitäten (und den Kontext) von Lernenden, um diese in nahezu Echtzeit zu analysieren und zu visualisieren, mit dem Ziel der Modellierung und Unterstützung von Lern- und Lehrprozessen sowie Lernumgebungen (Ifenthaler, 2015). Eine der Prämissen um Learning Analytics geht davon aus, dass Indikatoren, welche zum Erfolg von Lernenden beitragen sowie die Entscheidung von Lernenden, einen Lernprozess abzubrechen, vielfältig und komplex sind (Tinto, 1997; 2005). Es

lassen sich soziodemografische Indikatoren der Lernenden (z. B. Geschlecht, ethnische Zugehörigkeit, familiärer Hintergrund), kognitive Fähigkeiten und frühere akademische Leistungen (z. B. Notendurchschnitt), individuelle Eigenschaften (z. B. Persönlichkeitsmerkmale), aktives Lernen und Aufmerksamkeit sowie Umweltfaktoren im Zusammenhang mit Unterstützungsmaßnahmen identifizieren (Bijmans & Schakel, 2018; Brahm, Jenert & Wagner, 2017; Mah & Ifenthaler, 2020; Remedios, Clarke & Hawthorne, 2008; Tinto, 2017). In der Berufs- und Wirtschaftspädagogik werden weitere Konzepte analysiert, wie z. B. Gründe für einen Abbruch der Berufsausbildung (Beinke, 2011; Schöngen, 2003; Schuster, 2016) sowie informelle Lerngelegenheiten (Schumacher, 2018). Möglichkeiten, umfassende Daten für die o. g. Indikatoren zu sammeln und zu speichern und sie in einer (nahezu) Echtzeitanalyse zu kombinieren, eröffnen erweiterte Zugänge, um personalisierte und adaptive Interventionen zur Unterstützung des Lernerfolgs umzusetzen (Fuchs, Henning & Hartmann, 2016; Ifenthaler & Yau, 2020; Pistilli & Arnold, 2010).

3.2 Anwendung und Wirksamkeit von Learning Analytics für die Hochschulbildung

Anfängliche Learning-Analytics-Anwendungen beschränkten sich auf die Analyse von Trace-Data (Logfiles) oder Web-Statistiken, um das Verhalten von Lernenden in Onlinelernumgebungen zu beschreiben (Veenman, 2013). Inzwischen werden zunehmend Machine-Learning-Ansätze wie z. B. Support Vector Machines (Christmann & Steinwart, 2008), Random Forest (Breiman, 2001) und Decision Tree (Quinlan, 1986) verwendet. Zusätzlich werden Netzwerkanalysen für die Identifikation sozialer Interaktionen (Gašević, Joksimović, Eagan & Shaffer, 2019) oder zur Optimierung curricularer Planungen (Ifenthaler, Gibson & Dobozy, 2018) herangezogen. Auch semantische Analysen (Natural Language Processing; NLP) und damit verbundenes informatives Feedback in Echtzeit finden zunehmend mehr Anwendung im Kontext von Learning Analytics (Gurevych & Kim, 2013; Ifenthaler, 2014). Aktuelle Entwicklungen um Learning Analytics fokussieren auf (a) die Verbesserung des Lernens und der Motivation der Lernenden und damit verbunden die Reduktion von Abbrecherquoten (oder deren Inaktivität) (Colvin et al., 2015; Glick et al., 2019; Hinkelmann & Jordine, 2019; Mah, 2016) und auf (b) die Unterstützung bzw. Optimierung von Lern- und Lehrprozessen, indem personalisierte und adaptive Lernpfade sowie -hilfen zur Erreichung bestimmter vorgegebener oder selbst gesetzter Ziele bereitgestellt werden (Dawson, Tan & McWilliam, 2011; Gašević, Jovanovic, Pardo & Dawson, 2017; Ifenthaler, 2011; Ifenthaler, Mah & Yau, 2019).

Forschungsarbeiten aus dem Bereich der Hochschulbildung zeigen die Wirksamkeit von Learning-Analytics-Anwendungen hinsichtlich der Reduzierung von Studienabbrüchen, der Verbesserung von Notendurchschnitten sowie selbstreguliertem Lernen (Larrabee Sønderlund et al., 2019; Sclater et al., 2016). Allerdings unterliegen diese Forschungsarbeiten methodischen Limitationen (z. B. fehlende Kontrollgruppe, unzureichende Operationalisierung der untersuchten Konstrukte, begrenzter Stichprobenumfang) und somit fehlen weitestgehend robuste Erkenntnisse hinsichtlich der

Effektivität und Wirksamkeit von Learning Analytics zur Unterstützung von Lernerfolg (Ifenthaler & Yau, 2020; Larrabee Sønderlund et al., 2019; Suchithra, Vaidhedi & Iyer, 2015). Zudem liegt der Fokus bisheriger Forschungsarbeiten primär darin, mithilfe spezifischer Indikatoren den Lernerfolg vorherzusagen und gefährdete Lernende (z. B. Lernende, die den Kurs sehr wahrscheinlich abbrechen werden) zu identifizieren. Nur wenige Forschungsarbeiten beschäftigen sich mit konkreten Interventionsstrategien, mithilfe derer gefährdete Lernende gezielt unterstützt werden können (Ifenthaler & Yau, 2020; Larrabee Sønderlund et al., 2019).

Die Befunde einer aktuellen systematischen Übersichtsarbeit mit über 6.000 gesichteten Publikationen zeigen (Ifenthaler & Yau, 2020), dass Learning Analytics als datengestützte Methoden zur Erkennung von Risikosituationen in Verbindung mit Lernerfolg eingesetzt werden können (Chai & Gibson, 2015; Hinkelmann & Jordine, 2019; Okubo, Yamashita, Shimada & Ogata, 2017; Rogers, Colvin & Chiera, 2014). Trotz robuster analytischer Befunde fehlen an den betreffenden Bildungseinrichtungen jedoch umfassende pädagogische Unterstützungssysteme, um auf die individuellen Bedarfe der durch Learning-Analytics-Systeme identifizierten Lernenden einzugehen (Mah, 2016; Viberg, Hatakka, Bälter & Mavroudi, 2018). Als konkrete Interventionsstrategien konnten in bisherigen Forschungsarbeiten hauptsächlich visuelle Signale und andere Dashboard-Merkmale identifiziert werden, die gefährdete Lernende über ihren Risikostatus informieren (Ifenthaler & Yau, 2020; Larrabee Sønderlund et al., 2019). Aus pädagogischer Sicht sind jedoch diese Dashboard-Elemente nur eingeschränkt wirkungsvoll (Bodily et al., 2018; Schumacher & Ifenthaler, 2018a; Sedra-kyan, Mannens & Verbert, 2018). Demzufolge sollten Learning-Analytics-Dashboards informative Rückmeldefunktionen enthalten und durch Lernende selbst personalisierbar sein (Kokoç & Altun, 2019; Roberts, Howell & Seaman, 2017). Auch werden Learning-Analytics-Interventionen gefordert, welche adaptive Lernpfade empfehlen und ermutigende Interventionen vorschlagen, um Lernende zum Lernerfolg zu führen (Howell, Roberts & Mancini, 2018; Schumacher & Ifenthaler, 2018b).

In einer vertiefenden Analyse aus $N=49$ Studien konnten fünf spezifische Indikatorengruppen für Learning-Analytics-Anwendungen in der Hochschulbildung identifiziert werden (Yau & Ifenthaler, 2020):

1. Für die Unterstützung bzw. Vorhersage von aufgabenbezogener Lernleistung werden in den vorliegenden Studien Indikatoren aus dem Lernprozessprofil (z. B. Zugriff auf Lernartefakte/-materialien, Ergebnisse aus Selbsttests) verwendet.
2. Für die Unterstützung bzw. Vorhersage von Persistenz beim Lernen werden sowohl Indikatoren aus dem Lernendenprofil (z. B. historische akademische Leistungen, demografische Informationen, Lernbelastung) als auch aus dem Lernprozessprofil (z. B. Zugriffshäufigkeiten, Diskussionsbeiträge, Testergebnisse) herangezogen.
3. Für die Unterstützung bzw. Vorhersage von Risikosituationen werden Indikatoren aus dem Lernendenprofil (z. B. historische akademische Leistungen, demografische Informationen, Interesse, Motivation, Wahlverhalten), dem Lernprozessprofil (z. B. Zugriffshäufigkeiten, Diskussionsbeiträge, Testergebnisse) und

dem Curriculumprofil (z. B. Struktur der Lernumgebung, summative Evaluation) verwendet.

4. Für die Unterstützung bzw. Vorhersage von individueller Lernperformanz kommen Indikatoren aus dem Lernendenprofil (z. B. historische akademische Leistungen, demografische Informationen) und dem Lernprozessprofil (z. B. Zugriffshäufigkeiten, Diskussionsbeiträge, Testergebnisse) zur Anwendung.
5. Für die Unterstützung bzw. Vorhersage von Erfolgszuversicht in Kursen oder Programmen werden Indikatoren aus dem Lernendenprofil (z. B. historische akademische Leistungen, demografische Informationen) und dem Lernprozessprofil (z. B. Zugriffshäufigkeiten, Diskussionsbeiträge, Testergebnisse) verwendet.

Die Übersicht lässt erkennen, dass spezifische Learning-Analytics-Indikatoren für unterschiedliche Learning-Analytics-Anwendungen geeignet sind. Dennoch erscheint es wichtig, dass die Learning-Analytics-Indikatoren den *Kontext der Datenerhebung* bzw. *-analyse* berücksichtigen, um valide Analyseergebnisse für Unterstützungen und Empfehlungen zu erreichen (Gašević, Dawson, Rogers & Gasevic, 2016; Ifenthaler & Widanapathirana, 2014).

4 Indikatoren für personalisierte und adaptive Lernumgebungen für Onlineweiterbildung

Um Learning-Analytics-Anwendungen sowie personalisierte und adaptive Lernumgebungen für Onlineweiterbildung zu entwickeln, müssen zunächst zuverlässige Indikatoren für die Anwendung im Arbeitskontext identifiziert werden (Gašević et al., 2016; Ifenthaler & Yau, 2020). Die oben diskutierten Forschungsbeiträge aus dem Bereich der Hochschulbildung können hierzu als nützliche Ausgangsbasis dienen, sollten allerdings nur unter Vorbehalt auf den Arbeitskontext angewendet werden. Da sich Lernen im Arbeitskontext in mehreren Facetten vom Lernen in der formalen Hochschulbildung unterscheidet (Tynjälä, 2008), bleibt unklar, inwiefern sich die in bisherigen Forschungsbeiträgen aus dem Bereich der Hochschulbildung identifizierten Indikatoren auf den Arbeitskontext übertragen lassen. Indikatoren für Learning-Analytics-Anwendungen sowie personalisierte und adaptive Lernumgebungen sind kontextabhängig und können je nach Kontext der Datenerhebung bzw. -analyse eine unterschiedliche Bedeutung und Relevanz haben (Gašević et al., 2016; Ifenthaler & Widanapathirana, 2014).

4.1 Relevanz theoriegeleiteter Indikatoren

Neben dem Fokus auf die Hochschulbildung stellt die fehlende Einbettung in pädagogische Theorien eine weitere Einschränkung bisher entwickelter Learning-Analytics-Anwendungen dar. Bisher entwickelte Learning-Analytics-Anwendungen konzentrieren sich auf datengetriebene Ansätze und die Analyse von Trace-Data (z. B. Lerndauer,

Zugriff auf Lernmaterialien) zur Identifikation zuverlässiger Indikatoren. Pädagogische Theorien und Ergebnisse aus empirisch-pädagogischen Studien wurden bislang nur unzureichend berücksichtigt (Gašević et al., 2015; Zawacki-Richter et al., 2019). Forschende erkennen jedoch zunehmend das Potenzial theoriegeleiteter Indikatoren. Pädagogische Theorien können grundlegende Mechanismen des Lernens erklären und erleichtern damit die Interpretation von Forschungsergebnissen sowie die Entwicklung wirksamer Interventionen zur Unterstützung von Lernerfolg (Gašević et al., 2016; Gašević et al., 2015). Eine bekannte Problematik KI-basierter Technologien liegt in der Komplexität der zugrunde liegenden Algorithmen und statistischen Modelle (Blackbox). Vorhersagen und Empfehlungen KI-unterstützter personalisierter und adaptiver Lernumgebungen sind daher schwer nachvollziehbar und können zu unerwartetem Verhalten führen oder einzelne Personengruppen diskriminieren (Dignum, 2017; Prinsloo & Slade, 2014). Die Verwendung theoriegeleiteter, pädagogisch relevanter Indikatoren kann dabei helfen, KI-basierte Vorhersagen und Empfehlungen zu erklären, und damit die Transparenz und Vertrauenswürdigkeit von personalisierten und adaptiven Lernumgebungen erhöhen (Gašević et al., 2016; Ifenthaler & Schumacher, 2016).

Im Folgenden werden nun zwei Indikatorengruppen vorgestellt, die sich aus pädagogischen Theorien und empirisch-pädagogischen Befunden ableiten lassen und in bisherigen Learning-Analytics-Anwendungen nur unzureichend berücksichtigt wurden (Yau & Ifenthaler, 2020): das *Lernumfeld* und die *dynamischen Lernziele*. Diese beiden Indikatorengruppen stellen einen ersten Ansatz zur Identifikation theoriegeleiteter Indikatoren für personalisierte und adaptive Lernumgebungen für Onlineweiterbildungen dar. Dabei soll nicht ausgeschlossen werden, dass weitere Indikatorengruppen für den Kontext der Onlineweiterbildung ebenfalls eine Rolle spielen.

Lernumfeld

Konstruktivistische Lerntheorien beschreiben Lernen als individuellen Prozess, bei dem Lernende Wissen u. a. in Interaktion mit ihrer äußeren Umgebung konstruieren (Bada, 2015; Winne & Hadwin, 1998). Demnach stellt das Lernumfeld eine aus pädagogischer Sicht relevante Indikatorengruppe für personalisierte und adaptive Lernumgebungen dar. Winne und Hadwin (1998) postulieren, dass das Lernumfeld sich durch verschiedene interne (z. B. kognitive Fähigkeiten, Emotionen) und externe (z. B. Kursmerkmale, Lernort und -zeit) Bedingungen auszeichnet, die die Entscheidungen und Verhaltensweisen der Lernenden beeinflussen. Nach Winne (2010) ist das Lernumfeld daher für das Verständnis von Lernprozessen wesentlich und Daten können Lernen nur dann angemessen darstellen, wenn sie Informationen über das interne und externe Lernumfeld enthalten. Vereinzelt empirisch-pädagogische Studien aus dem Arbeitskontext zeigen darüber hinaus, dass Indikatoren des internen und externen Lernumfelds wie Emotionen (z. B. Angst, Freude, Stolz), Kursmerkmale (z. B. Schwierigkeitsniveau) oder Merkmale des Jobs (z. B. Branche, berufliche Stellung) Lernverhalten und -erfolg sowie Zufriedenheit mit dem Lernprozess vorhersagen können (Lee et al., 2021; Zhou, Mao & Tang, 2020). Informationen über das interne

und externe Lernumfeld sollten von personalisierten und adaptiven Lernumgebungen daher genutzt werden, um Lernprozesse zu verstehen und gezielt zu unterstützen (Gašević et al., 2016; Winne, 2010). Vor allem das externe Lernumfeld wurde in bisherigen Learning-Analytics-Anwendungen allerdings nur begrenzt berücksichtigt (Yau & Ifenthaler, 2020).

Dynamische Lernziele

Lernziele sind gewünschte Ergebnisse oder Soll-Zustände, die Lernende in der Weiterbildung anstreben. Nach Lockes und Lathams Zielsetzungstheorie wirken sich Ziele positiv auf Leistung aus, indem sie Aufmerksamkeit auf relevante Aufgaben lenken sowie Energie und Ausdauer erhöhen (Locke & Latham, 2002). Empirische Studien sprechen für die Annahmen der Zielsetzungstheorie und zeigen, dass bestimmte Merkmale von Lernzielen (z. B. Zielbindung, intrinsisch definierte vs. extern gesetzte Ziele) sich unterschiedlich auf Lernerfolg und -leistung auswirken können (Erez, Early & Hulin 1985; Neubert, 1998; Seijts & Latham, 2011). Informationen über Lernziele sollten daher von personalisierten und adaptiven Lernumgebungen berücksichtigt werden, um Lernprozesse und -erfolg zu unterstützen. Unterschiedliche Lernziele erfordern unterschiedliche Lernmaterialien und unterschiedliche Interventionen zur Unterstützung des Lernens. Lernende, die freiwillig und aus reinem Interesse an einer Weiterbildung teilnehmen, schätzen womöglich herausfordernde Aufgaben sowie eine breite Auswahl an unterschiedlichen Lernmaterialien (Buder & Schwind, 2012; Rigolizzo, 2019). Bei Lernenden, die auf Anordnung von Vorgesetzten an einer Weiterbildung teilnehmen, um eine spezifische im Arbeitsalltag benötigte Kompetenz zu erwerben, sollte die Auswahl der Lernmaterialien dahingegen auf den Erwerb dieser spezifischen Kompetenz fokussieren (Tavakoli, Faraji, Molavi, Mol & Kismihók, 2022). In der Onlineweiterbildung können Lernziele dabei sowohl intrinsisch definiert (z. B. Lernen aus Interesse, persönliche Weiterbildung) als auch extern gesetzt (z. B. Vorgaben durch Vorgesetzte, organisationale Anforderungen) sein (Fitzpatrick, Hayes, Naughton & Ezhova, 2021; Lemmetty, 2021). Aufgrund der sich ständig ändernden Arbeitsanforderungen sind Lernziele darüber hinaus nicht fix gesetzt, sondern dynamischer Natur und können sich im Laufe des Weiterbildungsprozesses ändern (Manuti et al., 2015).

4.2 Herausforderungen

Neben der Identifikation zuverlässiger Indikatoren stellt sich die Frage, wie diese von personalisierten und adaptiven Lernumgebungen valide gemessen werden können. Vor allem die Erhebung interner Indikatoren wie Emotionen oder Motivation sowie die Veränderung von Lernzielen stellt Forschende dabei vor Herausforderungen (Di Mitri, Schneider, Specht & Drachslar, 2018). Explizite Messverfahren wie Fragebögen ermöglichen die Erhebung von Indikatoren durch direktes Befragen der Lernenden, können den Lernprozess aber auch stören und beeinträchtigen. Aktuelle Forschungsbeiträge widmen sich daher der Erhebung interner Indikatoren durch implizite Messverfahren

wie die Analyse von Klickverhalten oder Forumeinträgen (Azevedo & Gašević, 2019; Xing, Tang & Pei, 2019).

Weitere Herausforderungen bei der Implementation personalisierter und adaptiver Lernumgebungen sind ethische Bedenken und Datenschutz (Ifenthaler & Schumacher, 2016). Lernende in personalisierten und adaptiven Lernumgebungen könnten sich durch die kontinuierliche Datenerhebung bzw. -analyse manipuliert und überwacht fühlen sowie den Lernprozess als wenig selbstbestimmt wahrnehmen, was sich negativ auf die Lernmotivation auswirken kann (Deci, Ryan & Williams, 1996; Schumacher, 2018; Tsai et al., 2018). Aktuelle Forschungsbeiträge plädieren daher für ein vorheriges Einverständnis der Lernenden sowie die Möglichkeit, dass Lernende selbst entscheiden können, welche Daten erhoben und analysiert werden (Kinshuk, 2016). Eine solche Opt-in-Option kann allerdings eine unzureichende Datengrundlage zur Folge haben und damit zu Verzerrungen in KI-basierten Vorhersagen und Entscheidungen führen (Tsai et al., 2018). Um die Akzeptanz einer kontinuierlichen Datenerhebung bzw. -analyse unter den Lernenden zu erhöhen, spielt Transparenz daher eine entscheidende Rolle. Lernende sollten genau darüber informiert werden, welche Daten wie erhoben und gespeichert werden, welche Personen Zugriff auf die Daten erhalten sowie welche Analysen KI-basierten Entscheidungen zugrunde liegen (Ifenthaler & Schumacher, 2016).

5 Fazit

Umfangreiche Forschungsarbeiten mit Schwerpunkt in der Hochschulbildung zeigen das Potenzial personalisierter und adaptiver Lernumgebungen hinsichtlich verbessertem Lernerfolg, der Reduzierung von Studienabbrüchen oder der gezielten Unterstützung von Lernprozessen (z. B. Larrabee Sønderlund et al., 2019; Ifenthaler & Yau, 2020; Sclater et al., 2016; Tsai et al., 2018). Im Bereich der Onlineweiterbildung liegen jedoch unzureichende Befunde im Hinblick auf die Wirksamkeit und Implementierung von personalisierten und adaptiven Lernumgebungen vor (Giacumo et al., 2018; Schumacher, 2018).

Aufgrund von Heterogenität der aktuellen Wissensstände, individuell bevorzugter Lernstrategien als auch der dynamisch veränderlichen Lernziele der Lernenden sind herkömmliche Lernplattformen häufig nicht flexibel genug, um den individuellen Anforderungen der beruflichen Onlineweiterbildung gerecht zu werden. Ein Kernproblem beim Einsatz von KI in der Onlineweiterbildung ist die Kontextabhängigkeit, Fragmentierung und Verzerrung verfügbarer Daten (Gašević et al., 2015). KI-basierte Entscheidungen, welche aus umfangreichen Trainingsdaten hervorgehen, können bei unzureichender Datengrundlage und mangelnder Transparenz zu Einseitigkeiten oder Befangenheiten führen. Eine Diskriminierung von Personen durch KI-Systeme ist somit nicht auszuschließen (Prinsloo & Slade, 2014). Folglich sind holistische KI-Systeme, die theoretisch fundierte und transparente Datenanalysen mit pädagogisch relevanten Indikatoren und verlässlichen Interventionen ermöglichen,

Ziel aktueller Forschungs- und Entwicklungsarbeiten. Dabei ist zu erwarten, dass neben bereits bestehenden datenschutzrechtlichen Standards auch ethische Leitprinzipien zum Austausch und der Analyse von Daten aus dem Onlineweiterbildungskontext weiterentwickelt werden (West, Huijser & Heath, 2016; Willis, Slade & Prinsloo, 2016).

Das Projekt "Kontextbasierte und adaptive Maßnahmen für effektive Lernunterstützung in der Onlineweiterbildung" (KAMAELEON; <https://www.bwl.uni-mannheim.de/ifenthaler/forschung/kamaeleon-kontextbasierte-und-adaptive-massnahmen-fuer-effektive-lernunterstuetzung-in-der-online-weiterbildung/>) setzt an der Forschungs- und Implementationslücke personalisierter und adaptiver Lernumgebungen im Bereich der Onlineweiterbildung an. Unter Berücksichtigung der heterogenen Voraussetzungen und flexiblen Bedingungen von Weiterbildungsprozessen sowie der Dynamik von Weiterbildungszielen fokussiert das Projekt auf die Entwicklung und Erforschung von KI-basierten Personalisierungsansätzen mittels der edyoucated-Lernplattform, einer Online-Lernplattform für personalisierte berufliche Weiterbildung (<https://www.edyoucated.org/>).

Literaturverzeichnis

- Aleven, V., McLaughlin, E. A., Glenn, R. A. & Koedinger, K. R. (2017). Instruction based on adaptive learning technologies. In R. E. Mayer & P. Alexander (Eds.), *Handbook of research on learning and instruction* (2nd ed., pp. 552–560). London: Routledge.
- Atif, A., Richards, D., Bilgin, A. & Marrone, M. (2013). Learning analytics in higher education: A summary of tools and approaches. In H. Carter, M. Gosper & J. Hedberg (Eds.), *Proceedings of the 30th Australian Society for Computers in Learning in Tertiary Education annual conference* (pp. 68–72). Sydney: Macquarie University.
- Azevedo, R. & Gašević, D. (2019). Analyzing multimodal multichannel data about self-regulated learning with advanced learning technologies: Issues and challenges. *Computers in Human Behavior*, 96, 207–210. doi: 10.1016/j.chb.2019.03.025
- Bada, S. O. (2015). Constructivism learning theory: A paradigm for teaching and learning. *Journal of Research & Method in Education*, 5(6), 66–70. doi: 10.9790/7388-05616670
- Beinke, L. (2011). Ausbildungsabbruch und eine verfehlte Berufswahl. *bwp@Spezial*, 5, 1–16.
- Bijsmans, P. & Schakel, A. H. (2018). The impact of attendance on first-year study success in problem-based learning. *Higher Education*, 76(5), 865–881. doi: 10.1007/s10734-018-0243-4
- Bodily, R., Kay, J., Aleven, V., Jivet, I., Davis, D., Xhakaj, F. & Verbert, K. (2018). Open learner models and learning analytics dashboards: A systematic review. In *Proceedings of the 8th International Conference on Learning Analytics and Knowledge* (pp. 41–50). New York City: Association for Computing Machinery. doi: 10.1145/3170358.3170409

- Brahm, T., Jenert, T. & Wagner, D. (2017). The crucial first year: A longitudinal study of students' motivational development at a Swiss business school. *Higher Education*, 73(3), 459–478. doi: 10.1007/s10734-016-0095-8
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5–32.
- Buckingham Shum, S. & McKay, T. A. (2018). Architecting for learning analytics innovating for sustainable impact. *Educause Review*, 53(2), 25–37.
- Buder, J. & Schwind, C. (2012). Learning with personalized recommender systems: A psychological view. *Computers in Human Behavior*, 28(1), 207–216. doi: 10.1016/j.chb.2011.09.002
- Chai, K. E. K. & Gibson, D. (2015). Predicting the risk of attrition for undergraduate students with time based modelling. In D. G. Sampson, J. M. Spector, D. Ifenthaler & P. Isaias (Eds.), *Proceedings of the 12th International Conference of Cognition and Exploratory Learning in the Digital Age* (pp. 109–116). International Association for Development of the Information Society.
- Christmann, A. & Steinwart, I. (2008). *Support vector machines*. Heidelberg: Springer.
- Colvin, C., Rogers, T., Wade, A., Dawson, S., Gasevid, D., Buckingham Shum, S., Nelson, K., Alexander, S., Lockyer, L., Kennedy, G., Corrin, L. & Fisher, J. (2015). *Student retention and learning analytics: A snapshot of Australian practices and a framework for advancement*. Edinburgh: The University of Edinburgh.
- Dawson, S., Tan, J. P. L. & McWilliam, E. (2011). Measuring creative potential: Using social network analysis to monitor a learners' creative capacity. *Australasian Journal of Educational Technology*, 27(6), 924–942. doi: 10.14742/ajet.921
- Deci, E. L., Ryan, R. M. & Williams, G. C. (1996). Need satisfaction and the self-regulation of learning. *Learning and Individual Differences*, 8(3), 165–183. doi: 10.1016/S1041-6080(96)90013-8
- Dignum, V. (2017). Responsible artificial intelligence: Designing AI for human values. *ITU Journal: ICT Discoveries*, 1(1), 1–8.
- Di Mitri, D., Schneider, J., Specht, M. & Drachsler, H. (2018). From signals to knowledge: A conceptual model for multimodal learning analytics. *Journal of Computer Assisted Learning*, 34(4), 338–349. doi: 10.1111/jcal.12288
- Ebner, M., Neuhold, B. & Schön, M. (2013). Learning Analytics: Wie Datenanalyse helfen kann, das Lernen gezielt zu verbessern. In K. Wilbers & A. Hohenstein (Hg.), *Handbuch E-Learning* (S. 1–20). Köln: Deutscher Wirtschaftsdienst.
- Erez, M., Earley, P. C. & Hulin, C. L. (1985). The impact of participation on goal acceptance and performance: A two-step model. *Academy of Management journal*, 28(1), 50–66. doi: 10.5465/256061
- Fake, H. & Dabbagh, N. (2020). Personalized learning within online workforce learning environments: Exploring implementations, obstacles, opportunities, and perspectives of workforce leaders. *Technology, Knowledge and Learning*, 25(4), 789–809. doi: 10.1007/s10758-020-09441-x

- Ferguson, R., Brasher, A., Clow, D., Cooper, A., Hillaire, G., Mittelmeier, J., Rienties, B., Ullmann, T. & Vuorikari, R. (2016). *Research evidence on the use of learning analytics: Implications for education policy*. Joint Research Center. Retrieved May 20, 2022 from <http://oro.open.ac.uk/48173/1/Analytics%20research%20evidence.pdf>
- Fitzpatrick, J. M., Hayes, N., Naughton, C. & Ezhova, I. (2021). Evaluating a specialist education programme for nurses and allied health professionals working in older people care: A qualitative analysis of motivations and impact. *Nurse Education Today*, 97. doi: 10.1016/j.nedt.2020.104708
- Fuchs, K., Henning, P. A. & Hartmann, M. (2016). Intuitel and the hypercube model – developing adaptive learning environments. *Journal on Systemics, Cybernetics and Informatics*, 14(3), 7–11.
- Gašević, D., Dawson, S., Rogers, T. & Gasevic, D. (2016). Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. *The Internet and Higher Education*, 28, 68–84. doi: 10.1016/j.iheduc.2015.10.002
- Gašević, D., Dawson, S. & Siemens, G. (2015). Let's not forget: Learning analytics are about learning. *TechTrends*, 59(1), 64–71. doi: 10.1007/s11528-014-0822-x
- Gašević, D., Joksimović, S., Eagan, B. R. & Shaffer, D. W. (2019). SENS: Network analytics to combine social and cognitive perspectives of collaborative learning. *Computers in Human Behavior*, 92, 562–577. doi: 10.1016/j.chb.2018.07.003
- Gašević, D., Jovanovic, J., Pardo, A. & Dawson, S. (2017). Detecting learning strategies with analytics: Links with self-reported measures and academic performance. *Journal of Learning Analytics*, 4(2), 113–128. doi: 10.18608/jla.2017.42.10
- Giacumo, L. A., Villachica, S. W. & Breman, J. (2018). Workplace learning, big data, and organizational readiness: Where to start? In D. Ifenthaler (Ed.), *Digital workplace learning: Bridging formal and informal learning with digital technologies* (pp. 107–125). Heidelberg: Springer. doi: 10.1007/978-3-319-46215-8_7
- Glick, D., Cohen, A., Festinger, E., Xu, D., Li, Q. & Warschauer, M. (2019). Predicting success, preventing failure. In D. Ifenthaler, D.-K. Mah & J. Y.-K. Yau (Eds.), *Utilizing learning analytics to support study success* (pp. 249–273). Heidelberg: Springer. doi: 10.1007/978-3-319-64792-0_14
- Gurevych, I. & Kim, J. (2013). *The people's web meets NLP: Collaboratively constructed language resources*. Heidelberg: Springer. doi: 10.1007/978-3-642-35085-6.
- Hinkelmann, M. & Jordine, T. (2019). The LAPS project: Using machine learning techniques for early student support. In D. Ifenthaler, D.-K. Mah & J. Y.-K. Yau (Eds.), *Utilizing learning analytics to support study success* (pp. 105–117). Heidelberg: Springer. doi: 10.1007/978-3-319-64792-0_7
- Howell, J. A., Roberts, L. D. & Mancini, V. O. (2018). Learning analytics messages: Impact of grade, sender, comparative information and message style on student affect and academic resilience. *Computers in Human Behavior*, 89, 8–15. doi: 10.1016/j.chb.2018.07.021

- Hsu, C.-K., Hwang, G.-J. & Chang, C.-K. (2013). A personalized recommendation-based mobile learning approach to improving the reading performance of EFL students. *Computers & Education*, 63, 327–336. doi: 10.1016/j.compedu.2012.12.004
- Huberth, M., Chen, P., Tritz, J. & McKay, T. A. (2015). Computer-tailored student support in introductory physics. *PLoS one*, 10(9). doi: 10.1371/journal.pone.0137001
- Ifenthaler, D. (2011). Intelligent mode-based feedback: Helping students to monitor their individual learning progress. In S. Graf, F. Lin, Kinshuk & R. McGreal. (Eds.), *Intelligent and adaptive systems: Technology enhanced support for learners and teachers* (pp. 88–100). Pennsylvania: IGI Global. doi: 10.4018/978-1-60960-842-2.ch006
- Ifenthaler, D. (2014). AKOVIA: Automated knowledge visualization and assessment. *Technology, Knowledge and Learning*, 19(1–2), 241–248. doi: 10.1007/s10758-014-9224-6
- Ifenthaler, D. (2015). Learning analytics. In J. M. Spector (Ed.), *The Sage Encyclopedia of Educational Technology* (Vol. 2, pp. 447–451). Thousand Oaks: Sage Publications.
- Ifenthaler, D. (2018). How we learn at the digital workplace. In D. Ifenthaler (Ed.), *Digital workplace learning: Bridging formal and informal learning with digital technologies* (pp. 3–8). Heidelberg: Springer. doi: 10.1007/978-3-319-46215-8_1
- Ifenthaler, D., Gibson, D. & Dobozy, E. (2018). Informing learning design through analytics: Applying network graph analysis. *Australasian Journal of Educational Technology*, 34(2), 117–132. doi: 10.14742/ajet.3767
- Ifenthaler, D., Mah, D.-K. & Yau, J. Y.-K. (2019). Utilising learning analytics for study success: Reflections on current empirical findings. In D. Ifenthaler, D.-K. Mah & J. Y.-K. Yau (Eds.), (pp. 88–100). *Utilizing learning analytics to support study success* (pp. 27–36). Heidelberg: Springer. doi: 10.1007/978-3-319-64792-0_2
- Ifenthaler, D. & Schumacher, C. (2016). Student perceptions of privacy principles for learning analytics. *Educational Technology Research and Development*, 64(5), 923–938. doi: 10.1007/s11423-016-9477-y
- Ifenthaler, D. & Widanapathirana, C. (2014). Development and validation of a learning analytics framework: Two case studies using support vector machines. *Technology, Knowledge and Learning*, 19(1–2), 221–240. doi: 10.1007/s10758-014-9226-4
- 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*, 68(4), 1961–1990. doi: 10.1007/s11423-020-09788-z
- Kinshuk (2016). *Designing adaptive and personalized learning environments*. London: Routledge.
- Kokoç, M. & Altun, A. (2019). Building a learning experience: What do learners' online interaction data imply? In D. G. Sampson, J. M. Spector, D. Ifenthaler, P. Isaias & S. Stylianos (Eds.), *Learning technologies for transforming large-scale teaching, learning, and assessment* (pp. 55–70). Heidelberg: Springer. doi: 10.1007/978-3-030-15130-0_4
- Larrabee Sønderlund, A., Hughes, E. & Smith, J. (2019). The efficacy of learning analytics interventions in higher education: A systematic review. *British Journal of Educational Technology*, 50(5), 2594–2618. doi: 10.1111/bjet.12720

- Lee, M., Na, H. M., Kim, B., Kim, S. Y., Park, J. & Choi, J. Y. (2021). Mediating effects of achievement emotions between peer support and learning satisfaction in graduate nursing students. *Nurse Education in Practice*, 52. doi: 10.1016/j.nepr.2021.103003
- Lemmetty, S. (2021). Employee opportunities for self-directed learning at technology organisations: features and frames of self-directed learning projects. *Studies in Continuing Education*, 43(2), 139–155. doi: 10.1080/0158037X.2020.1765758
- Ley, T., Kump, B. & Gerdenitsch, C. (2010). Scaffolding self-directed learning with personalized learning goal recommendations. In P. Bra, A. Kobsa & D. Chin (Eds.), *Proceedings of the 18th International Conference on User Modeling, Adaptation, and Personalization* (pp. 75–86). Heidelberg: Springer. doi: 10.1007/978-3-642-13470-8_9
- Locke, E. A. & Latham, G. P. (2002). Building a practically useful theory of goal setting and task motivation: A 35-year odyssey. *American Psychologist*, 57(9), 705–717. doi: 10.1037//0003-066X.57.9.705
- Long, P. & Siemens, G. (2011). Penetrating the FOG: Analytics in learning and education. *Educause Review*, 46(5), 31–40. doi: 10.17471/2499-4324/195
- Mah, D.-K. (2016). Learning analytics and digital badges: Potential impact on student retention in higher education. *Technology, Knowledge and Learning*, 21(3), 285–305. doi: 10.1007/s10758-016-9286-8
- Mah, D.-K. & Ifenthaler, D. (2020). What do first-year students need? Digital badges for academic support to enhance student retention. *Journal of Applied Research in Higher Education*, 12(1), 86–96. doi: 10.1108/JARHE-12-2018-0258
- Manuti, A., Pastore, S., Scardigno, A. F., Giancaspro, M. L. & Morciano, D. (2015). Formal and informal learning in the workplace: A research review. *International Journal of Training & Development*, 19(1), 1–17. doi: 10.1111/ijtd.12044
- Neubert, M. J. (1998). The value of feedback and goal setting over goal setting alone and potential moderators of this effect: A meta-analysis. *Human Performance*, 11(4), 321–335. doi: 10.1207/s15327043hup1104_2
- Okubo, F., Yamashita, T., Shimada, A. & Ogata, H. (2017). A neural network approach for students' performance prediction. In *Proceedings of the 7th International Learning Analytics & Knowledge Conference* (pp. 598–599). New York City: Association for Computing Machinery. doi: 10.1145/3027385.3029479
- Papamitsiou, Z. K. & Economides, A. A. (2014). Learning analytics and educational data mining in practice: A systematic literature review of empirical evidence. *Journal of Educational Technology & Society*, 17(4), 49–64.
- Peng, H., Ma, S. & Spector, J. M. (2019). Personalized adaptive learning: An emerging pedagogical approach enabled by a smart learning environment. *Smart Learning Environments*, 6(1), 1–14. doi: 10.1186/s40561-019-0089-y
- Pistilli, M. D. & Arnold, K. E. (2010). Purdue signals: Mining real-time academic data to enhance student success. *About Campus*, 15(3), 22–24. doi: 10.1002/abc.20025
- Plass, J. L. & Pawar, S. (2020a). Toward a taxonomy of adaptivity for learning. *Journal of Research on Technology in Education*, 52(3), 275–300. doi: 10.1080/15391523.2020.1719943

- Plass, J. L. & Pawar, S. (2020b). Adaptivity and personalization in game-based learning. In J. L. Plass, R. E. Mayer & B. D. Homer (Eds.), *Handbook of game-based learning* (pp. 263–282). Cambridge: MIT Press.
- Prinsloo, P. & Slade, S. (2014). Student data privacy and institutional accountability in an age of surveillance. In M. E. Menon, D. G. Terkla & P. Gibbs (Eds.), *Using data to improve higher education: Research policy and practice* (pp. 197–214). Rotterdam: Sense Publishers. doi: 10.1007/978-94-6209-794-0_12
- Quinlan, J. R. (1986). Induction of decision trees. *Machine learning*, 1, 81–106.
- Remedios, L., Clarke, D. & Hawthorne, L. (2008). Framing collaborative behaviors: Listening and speaking in problem-based learning. *Interdisciplinary Journal of Problem-Based Learning*, 2(1), 1–20. doi: 10.7771/1541-5015.1050
- Rigolizzo, M. (2019). Ready and willing to learn: Exploring personal antecedents to taking on learning challenges. *Journal of Workplace Learning*, 31(4), 289–304. doi: 10.1108/JWL-08-2018-0101
- Roberts, L. D., Howell, J. A. & Seaman, K. (2017). Give me a customizable dashboard: Personalized learning analytics dashboards in higher education. *Technology, Knowledge and Learning*, 22(3), 317–333. doi: 10.1007/s10758-017-9316-1
- Roberts-Mahoney, H., Means, A. J. & Garrison, M. J. (2016). Netfixing human capital development: personalized learning technology and the corporatization of K-12 education. *Journal of Education Policy*, 31(4), 405–420. doi: 10.1080/02680939.2015.1132774
- Rogers, T., Colvin, C. & Chiera, B. (2014). Modest analytics: Using the index method to identify students at risk of failure. In *Proceedings of the 4th International Conference on Learning Analytics and Knowledge* (pp. 118–112). New York City: Association for Computing Machinery. doi: 10.1145/2567574.2567629
- Schöngen, K. (2003). Lösung von Ausbildungsverträgen – schon Ausbildungsabbruch? *Informationen für die Beratungs- und Vermittlungsdienste*, 25(3), 5–19.
- Schumacher, C. (2018). Supporting informal workplace learning through analytics. In D. Ifenthaler (Ed.), *Digital workplace learning: Bridging formal and informal learning with digital technologies* (pp. 43–61). Heidelberg: Springer. doi: 10.1007/978-3-319-46215-8
- Schumacher, C. & Ifenthaler, D. (2018a). Features students really expect from learning analytics. *Computers in Human Behavior*, 78, 397–407. doi: 10.1016/j.chb.2017.06.030
- Schumacher, C. & Ifenthaler, D. (2018b). The importance of students' motivational dispositions for designing learning analytics. *Journal of Computing in Higher Education*, 30(3), 599–619. doi: 10.1007/s12528-018-9188-y
- Schumacher, C. & Ifenthaler, D. (2021). Investigating prompts for supporting students' self-regulation – A remaining challenge for learning analytics approaches? *The Internet and Higher Education*, 49. doi: 10.1016/j.iheduc.2020.100791
- Schuster, M. (2016). *Ursachen und Folgen von Ausbildungsabbrüchen*. European Institute for Knowledge & Value Management. Verfügbar unter <http://hdl.handle.net/10419/142429> (Zugriff am: 20.05.2022).

- Sclater, N., Peasgood, A. & Mullan, J. (2016). *Learning analytics in higher education: A review of UK and international practice*. Joint Information Systems Committee. Retrieved May 20, 2022 from https://www.jisc.ac.uk/sites/default/files/learning-analytics-in-he-v2_0.pdf
- Sedrakyan, G., Mannens, E. & Verbert, K. (2018). Guiding the choice of learning dashboard visualizations: Linking dashboard design and data visualization concepts. *Journal of Visual Languages and Computing*, 50, 19–38. doi: 10.1016/j.jvlc.2018.11.002
- Seijts, G. H. & Latham, G. P. (2011). The effect of commitment to a learning goal, self-efficacy, and the interaction between learning goal difficulty and commitment on performance in a business simulation. *Human Performance*, 24(3), 189–204. doi: 10.1080/08959285.2011.580807
- Seufert, S., Guggemos, J. & Ifenthaler, D. (2021). Zukunft der Arbeit mit intelligenten Maschinen: Implikationen der Künstlichen Intelligenz für die Berufsbildung. *Zeitschrift für Berufs- und Wirtschaftspädagogik, Beiheft 31*, 9–27.
- Suchithra, R., Vaidhehi, V. & Iyer, N. E. (2015). Survey of learning analytics based on purpose and techniques for improving student performance. *International Journal of Computer Applications*, 111(1), 22–26. doi: 10.5120/19502–1097
- Tavakoli, M., Faraji, A., Molavi, M., Mol, S. T. & Kismihók, G. (2022). Hybrid human-AI curriculum development for personalised informal learning environments. *Proceedings of the 12th International Learning Analytics and Knowledge Conference*, 1(1). Vorab-Online-Veröffentlichung.
- Tinto, V. (1997). Classrooms as communities: Exploring the educational character of student persistence. *The Journal of Higher Education*, 68(6), 599–623. doi: 10.1080/00221546.1997.11779003
- Tinto, V. (2005). Moving from theory to action: A model of institutional action for student success. In A. Seidmann (Ed.), *College student retention: Formula for student success* (2nd ed., pp. 251–266). Washington D. C.: American Council on Education.
- Tinto, V. (2017). Through the eyes of students. *Journal of College Student Retention: Research, Theory & Practice*, 19(3), 254–269. doi: 10.1177/1521025115621917
- Tsai, Y.-S., Moreno-Marcos, P. M., Jivet, I., Scheffel, M., Tammets, K., Kollom, K. & Gašević, D. (2018). The SHEILA framework: Informing institutional strategies and policy processes of learning analytics. *Journal of Learning Analytics*, 5(3), 5–20. doi: 10.18608/jla.2018.53.2
- Tynjälä, P. (2008). Perspectives into learning at the workplace. *Educational Research Review*, 3(2), 130–154. doi: 10.1016/j.edurev.2007.12.001
- U.S. Department of Education (2017). *Reimagining the role of technology in education: 2017 national technology plan update*. Retrieved May 20, 2022 from <https://tech.ed.gov/files/2017/01/NETP17.pdf>
- Veenman, M. V. J. (2013). Assessing metacognitive skills in computerized learning environments. In R. Azevedo & V. Aleven (Eds.), *International handbook of metacognition and learning technologies* (Vol. 28, pp. 157–170). Heidelberg: Springer. doi: 10.1007/978-1-4419-5546-3_11

- Viberg, O., Hatakka, M., Bälter, O. & Mavroudi, A. (2018). The current landscape of learning analytics in higher education. *Computers in Human Behavior*, 89, 98–110. doi: 10.1016/j.chb.2018.07.027
- West, D., Huijser, H. & Heath, D. (2016). Putting an ethical lens on learning analytics. *Educational Technology Research and Development*, 64(5), 903–922. doi: 10.1007/s11423-016-9464-3
- Willis, J. E., Slade, S. & Prinsloo, P. (2016). Ethical oversight of student data in learning analytics: A typology derived from a cross-continental, cross-institutional perspective. *Educational Technology Research and Development*, 64(5), 881–901. doi: 10.1007/s11423-016-9463-4
- Winne, P. H. (2010). Improving measurements of self-regulated learning. *Educational Psychologist*, 45(4), 267–276. doi: 10.1080/00461520.2010.517150
- Winne, P. H. & Hadwin, A. E. (1998). Studying as self-regulated learning. In D. J. Hacker, J. Dunlosky & A. C. Graesser (Eds.), *Metacognition in educational theory and practice* (pp. 227–304). Mahwah: Lawrence Erlbaum Associates.
- Wozniak, K. (2020). Personalized learning for adults: An emerging andragogy. In S. Yu, M. Ally & A. Tsinakos (Eds.), *Emerging technologies and pedagogies in the curriculum* (pp. 185–198). Heidelberg: Springer. doi: 10.1007/978-981-15-0618-5
- Xie, H., Chu, H.-C., Hwang, G.-J. & Wang, C.-C. (2019). Trends and development in technology-enhanced adaptive/personalized learning: A systematic review of journal publications from 2007 to 2017. *Computers & Education*, 140, 1–16. doi: 10.1016/j.compedu.2019.103599
- Xing, W., Tang, H. & Pei, B. (2019). Beyond positive and negative emotions: Looking into the role of achievement emotions in discussion forums of MOOCs. *The Internet and Higher Education*, 43. doi: 10.1016/j.iheduc.2019.100690
- Yau, J. Y.-K. & Ifenthaler, D. (2020). Reflections on different learning analytics indicators for supporting study success. *International Journal of Learning Analytics and Artificial Intelligence for Education*, 2(2), 4–23. doi: 10.3991/ijai.v2i2.15639
- Zawacki-Richter, O., Marín, V. I., Bond, M. & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1), 1–27. doi: 10.1186/s41239-019-0171-0
- Zhou, Q., Mao, J.-Y. & Tang, F. (2020). Don't be afraid to fail because you can learn from it! How intrinsic motivation leads to enhanced self-development and benevolent leadership as a boundary condition. *Frontiers in Psychology*, 11, 1–12. doi: 10.3389/fpsyg.2020.00699

Autor und Autorin

Yvonne Hemmler (M. Sc.) arbeitet seit April 2021 als wissenschaftliche Mitarbeiterin am Lehrstuhl für Wirtschaftspädagogik – Technologiebasiertes Instruktionsdesign der Universität Mannheim. Ihre aktuellen Forschungsschwerpunkte liegen in den Bereichen Onlineweiterbildung, adaptives Lernen und Learning Analytics.

Kontakt: hemmler@uni-mannheim.de

Prof. Dr. Dirk Ifenthaler ist Inhaber des Lehrstuhls für Wirtschaftspädagogik – Technologiebasiertes Instruktionsdesign an der Universität Mannheim und UNESCO Deputy Chair on Data Science in Higher Education Learning and Teaching an der Curtin University, Australien. Sein Forschungsschwerpunkt verbindet Fragen der Lern-Lehr-Forschung, Bildungstechnologie, Data Analytics und des organisationalen Lernens.

Kontakt: ifenthaler@uni-mannheim.de