

Reichow, Insa; Buntins, Katja; Paaßen, Benjamin; Abu-Rasheed, Hasan; Weber, Christian; Dornhöfer, Mareike
Recommendersysteme in der beruflichen Weiterbildung. Grundlagen, Herausforderungen und Handlungsempfehlungen. Ein Dossier im Rahmen des INVITE-Wettbewerbs

Berlin 2022, 26 S.



Quellenangabe/ Reference:

Reichow, Insa; Buntins, Katja; Paaßen, Benjamin; Abu-Rasheed, Hasan; Weber, Christian; Dornhöfer, Mareike: Recommendersysteme in der beruflichen Weiterbildung. Grundlagen, Herausforderungen und Handlungsempfehlungen. Ein Dossier im Rahmen des INVITE-Wettbewerbs. Berlin 2022, 26 S. - URN: urn:nbn:de:0111-pedocs-245172 - DOI: 10.25656/01:24517

<https://nbn-resolving.org/urn:nbn:de:0111-pedocs-245172>

<https://doi.org/10.25656/01:24517>

Nutzungsbedingungen

Dieses Dokument steht unter folgender Creative Commons-Lizenz: <http://creativecommons.org/licenses/by-nc-nd/4.0/deed.de> - Sie dürfen das Werk bzw. den Inhalt unter folgenden Bedingungen vervielfältigen, verbreiten und öffentlich zugänglich machen: Sie müssen den Namen des Autors/Rechteinhabers in der von ihm festgelegten Weise nennen. Dieses Werk bzw. dieser Inhalt darf nicht für kommerzielle Zwecke verwendet werden und es darf nicht bearbeitet, abgewandelt oder in anderer Weise verändert werden.

Mit der Verwendung dieses Dokuments erkennen Sie die Nutzungsbedingungen an.

Terms of use

This document is published under following Creative Commons-License: <http://creativecommons.org/licenses/by-nc-nd/4.0/deed.en> - You may copy, distribute and transmit, adapt or exhibit the work in the public as long as you attribute the work in the manner specified by the author or licensor. You are not allowed to make commercial use of the work or its contents. You are not allowed to alter, transform, or change this work in any other way.

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

Mitglied der


Leibniz-Gemeinschaft

Insa Reichow, Katja Buntins, Benjamin Paaßen, Hasan Abu-Rasheed, Christian Weber & Mareike Dornhöfer

Recommendersysteme in der beruflichen Weiterbildung Grundlagen, Herausforderungen und Handlungsempfehlungen

Ein Dossier im Rahmen des INVITE-Wettbewerbs

GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung

 Bundesinstitut für
Berufsbildung

Impressum

Dr. Insa Reichow, Dr. Benjamin Paaßen

Deutsches Forschungszentrum für Künstliche Intelligenz GmbH (DFKI)
Alt-Moabit 91c
10559 Berlin

Katja Buntins

mmb Institut GmbH
Folkwangstraße 1
45128 Essen

Hasan Abu-Rasheed, Dr. Christian Weber, Dr. Mareike Dornhöfer

Institut für Wissensbasierte Systeme und Wissensmanagement
Universität Siegen
Hölderlinstraße 3
57076 Siegen

Gemeinsame Kontaktadresse der Autor_innen: invite@mmb-institut.de

Dieses Dossier ist im Rahmen des Innovationswettbewerbs INVITE im Projekt „INVITE-Meta“ in Zusammenarbeit mit den INVITE-Projekten „KIPerWeb“ und „WBsmart“ entstanden. Dr. Insa Reichow und Katja Buntins sind Teil des Projektteams von INVITE-Meta. Dr. Benjamin Paaßen arbeitet im Projekt KIPerWeb und Hasan Abu-Rasheed, Dr. Christian Weber und Dr. Mareike Dornhöfer sind Teil des Projektteams von WBsmart.

Danksagung

Wir möchten uns herzlich bei allen weiteren Personen bedanken, die sich an der Ausarbeitung und Kommentierung dieses Dossiers beteiligt haben. Dazu gehören insbesondere alle weiteren Mitarbeiter und Mitarbeiterinnen des Projekts INVITE-Meta: Dr. Berit Blanc, Dr. Lutz Goertz, Monica Hochbauer, Prof. Dr. Niels Pinkwart, Dr. Faisal Rashid und Dr. Ulrich Schmid.

Zitiervorschlag:

Reichow, I., Buntins, K., Paaßen, B., Abu-Rasheed, H., Weber, C., Dornhöfer, M. (2022). Recommendersysteme in der beruflichen Weiterbildung. Grundlagen, Herausforderungen und Handlungsempfehlungen. Berlin. <https://doi.org/10.25656/01:24517>

1. Auflage 2022
Mai 2022



Herausgeber

Deutsches Forschungszentrum
für Künstliche Intelligenz GmbH
Alt-Moabit 91c
10559 Berlin

CC Lizenz

Dieses Werk ist lizenziert unter einer CC BY-NC-ND 4.0 Lizenz (Namensnennung – Keine kommerzielle Nutzung – Keine Bearbeitung – 4.0 International). Weitere Informationen finden Sie auf der Creative-Commons-Webseite: <https://creativecommons.org/licenses/>

Inhaltsverzeichnis

Kurzzusammenfassung	4
Einleitung.....	5
1 Allgemeine Grundlagen zu Recommendersystemen	6
1.1 Definition und Begriffsklärung	6
1.2 Technische Umsetzung.....	6
1.3 Was haben Recommendersysteme mit künstlicher Intelligenz zu tun?	8
2 Recommendersysteme beim technologiegestützten Lernen.....	10
2.1 Recommendersysteme im Bildungsbereich allgemein	10
2.2 Recommendersysteme in der beruflichen Weiterbildung.....	11
2.2.1 Review zu Recommendersystemen in der beruflichen Bildung	11
2.2.2 Recommendersysteme im INVITE-Wettbewerb.....	12
3 Implementierung von Recommendersystemen – Herausforderungen und Handlungsempfehlungen	14
3.1 Didaktisches Ziel klären und fundierte (instruktionale) Mechanismen nutzen	14
3.2 Datengrundlage	15
3.3 Datenpflege und Taxonomien	16
3.4 Zielgruppenspezifische Ausgestaltung und Anpassbarkeit der Empfehlungen	18
3.5 Evaluation des Recommendersystems	19
3.6 Fairness, Erklärbarkeit und Nachvollziehbarkeit der Empfehlungen	20
3.7 Berücksichtigung der Betriebe	21
3.8 Verknüpfung von Recommendersystemen und persönlicher Bildungsberatung	22
4 Fazit	23
5 Literaturverzeichnis	24

Kurzzusammenfassung

An wen richtet sich dieses Dossier?

Dieses Dossier richtet sich an **Personen, die verstehen wollen, was Recommendersysteme sind** und wie sie auf **digitalen Weiterbildungsplattformen** eingesetzt werden (können). Das Dossier beinhaltet neben diesen Grundlagen aber auch weitergehende Betrachtungen von Herausforderungen, die es bei der Implementierung eines Recommendersystems zu betrachten gilt. Daher richtet sich dieses Dossier explizit auch an **Entwickler_innen** und andere Personen, die mit der konkreten Entwicklung und Implementierung von Recommendersystemen befasst sind.

Auf welchen Quellen basiert dieses Dossier?

Die in diesem Dossier beschriebenen Erkenntnisse und Empfehlungen basieren auf einer Literaturrecherche zu Recommendersystemen im Bildungsbereich, auf den Diskussionen eines Expert_innenworkshops zum Thema und auf der Expertise einzelner Projekte im Rahmen des INVITE-Wettbewerbs¹.

Was steht in diesem Dossier?

Das vorliegende Dossier erläutert zunächst, was Recommendersysteme sind und wie sie technisch umgesetzt werden (Kapitel 1). Nachfolgend wird im zweiten Kapitel aufgezeigt, zu welchem Zweck Recommendersysteme beim technologiegestützten Lernen eingesetzt werden – sowohl im Bildungsbereich allgemein (Kapitel 2.1) als auch speziell in der beruflichen Weiterbildung (Kapitel 2.2).

Der größere Teil dieses Dokuments widmet sich anschließend spezifischen Herausforderungen der Entwicklung und Implementierung konkreter Recommendersysteme auf digitalen Weiterbildungsplattformen. Dabei werden basierend auf der bestehenden Literatur und Aussagen von Expert_innen Handlungsempfehlungen aufgeführt (Kapitel 3).

Insgesamt soll das vorliegende Dossier damit den Einsatz von Recommendersystemen in der beruflichen Aus- und Weiterbildung sowohl aus technischer als auch didaktischer Perspektive beleuchten.

¹ Der „Innovationswettbewerb INVITE (Digitale Plattform berufliche Weiterbildung)“ ist eine BMBF-geförderte Projektlinie (Laufzeit März 2021–Februar 2025), in der insgesamt 35 Projekte innovative Lösungen für digital-gestützte Weiterbildungsformate entwickeln – u. a. auch Recommendersysteme.

Einleitung

Der deutsche Weiterbildungsmarkt wird von zahlreichen und unterschiedlichen Akteuren gestaltet: Millionen Lernende, die in Millionen Betrieben unterschiedlicher Größe angestellt sind, treffen auf Zehntausende Weiterbildungsanbieter, die Weiterbildungen zu allen denkbaren Themen in unterschiedlichen Formaten anbieten. Dabei weisen Lernende und Betriebe unterschiedliche Bedarfe, Perspektiven und Ressourcen auf, die es bei der Auswahl einer passenden Weiterbildung zu berücksichtigen gilt. Diese Herausforderung stellt somit ein „Matching-Problem“ dar: Lernende, Betriebe und Weiterbildungsangebot müssen bestmöglich zusammengebracht werden.

Für Weiterbildungsinteressierte und Weiterbildungsverantwortliche in Unternehmen bedeutet dies meist, sich inmitten der vielen Angebote zurechtzufinden und eine Entscheidung nach eigenem Ermessen zu treffen. Unterstützt wird dieser Entscheidungsprozess durch verschiedene Herangehensweisen: Lernenden und Betrieben wird durch umfassende und möglichst übersichtlich strukturierte Kurskataloge eine gute Informationsbasis dargeboten, Checklisten verschiedener Einrichtungen zeigen auf, welche Aspekte bei einer Kursauswahl besonders zu bedenken sind (z. B. Borowiec et al., 2018), Erfahrungswerte und Empfehlungen von Kolleg_innen und Bekannten werden genutzt (vgl. Leuphana Universität Lüneburg, 2012) und professionelle Weiterbildungsberatungen bieten Lernenden und Betrieben Orientierung auf einem komplexen Markt und individuelle Empfehlungen für den eigenen Karrierepfad.

Durch die zunehmende Verlagerung von Kursangeboten ins Internet spielt eine weitere Lösung für das Matching-Problem eine steigende Rolle: Recommendersysteme, wie man sie z. B. schon von Video- oder Shoppingportalen kennt.

In der Bildungswirtschaft sind mittlerweile Kursbeschreibungen von einem Großteil aller existierenden Weiterbildungsangebote im Internet zu finden. Recommendersysteme können hier eingesetzt werden, um basierend auf diesen Kursbeschreibungen passende Präsenzkurse zu empfehlen. Außerdem finden immer mehr Weiterbildungsangebote selbst online statt. Werden diese Kurse direkt auf einer Lernplattform absolviert, werden Daten über den Lernprozess generiert, die zusätzlich für ein Recommendersystem genutzt werden können (Drachslers et al., 2015). Recommendersysteme können hier demnach nicht nur Kurse vorschlagen, sondern basierend auf individuellen Lernaktivitätsdaten beispielsweise personalisierte Empfehlungen für ganze Lernpfade formulieren. Dieses Beispiel zeigt bereits, dass Recommendersysteme im Bildungsbereich nicht nur eingesetzt werden, um einzelne „Produkte“ zu empfehlen und das Matching-Problem zwischen Lernenden und Lernangebot zu lösen, sondern dass sie auch weitergehende didaktische Unterstützungsfunktionen erfüllen können.

Im folgenden Dossier werden diese möglichen Einsatzzwecke und Ausgestaltungen von Recommendersystemen beim technologiegestützten Lernen vorgestellt und dann spezifisch für die berufliche Weiterbildung betrachtet. Weiterhin werden verschiedene Herausforderungen bei der Implementierung von Recommendersystemen für die berufliche Weiterbildung erörtert und erste Handlungsempfehlungen abgeleitet. Die Herausforderungen und Handlungsempfehlungen wurden einerseits auf Basis einer Literaturrecherche und andererseits auf Basis eines Expert_innen-Workshops herausgearbeitet.

1 Allgemeine Grundlagen zu Recommendersystemen

1.1 Definition und Begriffsklärung

Recommendersysteme (dt. manchmal „Empfehlungssysteme“²) sind Softwaresysteme, die Nutzer_innen auf personalisierte Weise zu interessanten oder nützlichen Objekten in einem großen Feld möglicher Optionen führen (basierend auf Burke, 2002; eine Übersicht verschiedener Definitionen von Recommendersystemen findet sich bei Manouselis et al., 2012). Sie werden gerade in solchen Bereichen eingesetzt, in denen die Menge an verfügbaren Informationen die Fähigkeit des Einzelnen, diese Informationen alle zu überblicken, bei weitem übersteigt. Dies ist beispielsweise bei vielen Online-Diensten (z. B. E-Commerce- oder Video-On-Demand-Dienste), die eine Fülle an Produkten anbieten, der Fall. Recommendersysteme werden hier eingesetzt, um Nutzer_innen in der Auswahl passender oder interessanter Produkte oder Inhalte zu unterstützen. Recommendersysteme können beispielsweise passende Bücher basierend auf den Kaufentscheidungen anderer, ähnlicher Nutzer_innen vorschlagen. In dieser oder vergleichbarer Form sind Ihnen Recommendersysteme sicherlich schon begegnet, so dass hier weitere Erläuterungen zu Recommendersystemen bei Online-Diensten gar nicht folgen sollen. Wichtig ist an dieser Stelle noch festzuhalten, dass Recommendersysteme über bloße Filterfunktionen (wie z. B. einer kriterienbasierten Auswahl passender Mietwohnungen) weit hinausgehen. Vielmehr sind Recommendersysteme Algorithmen, die häufig implizite Erkenntnisse über das Nutzerverhalten oder errechnete Informationen zu Produkteigenschaften und -ähnlichkeiten nutzen, um personalisierte Empfehlungen auszusprechen. Die technischen Grundlagen zu den verschiedenen Typen von Recommendersystemen sollen im folgenden Abschnitt in aller Kürze thematisiert werden.

1.2 Technische Umsetzung

Recommendersysteme werden häufig nach dem gewählten technischen Ansatz klassifiziert. Diese verschiedenen Ansätze (siehe Abbildung 1) beruhen auf verschiedenen Wissens- bzw. Datenquellen (Burke et al., 2011). Die zentralen Ansätze sollen hier kurz vorgestellt werden.

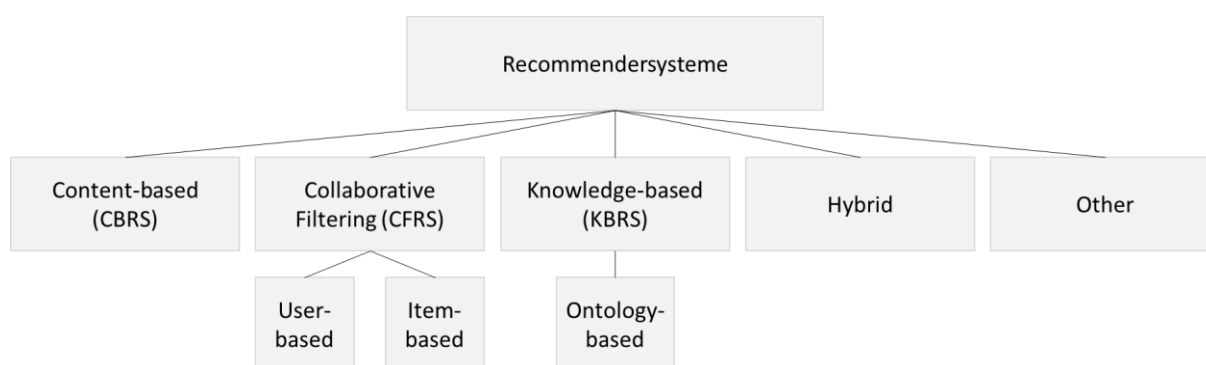


Abbildung 1: Verschiedene Ansätze von Recommendersystemen. Eigene Darstellung basierend auf Guruge et al. (2021), Krauß (2018) und Tarus et al. (2018).

² Wir nutzen den eingedeutschten Begriff „Recommendersystem“, um deutlich zu machen, dass wir hier über das sprechen, was im englischsprachigen Diskurs „recommender system“ oder „recommender engine“ genannt wird. Die teilweise genutzten deutschen Begriffe „Empfehlungssystem“ oder „Empfehlungsdienst“ sind unserer Meinung nach weniger eindeutig.

Bei *content-based* Recommendersystemen (CBRS) werden die Interessen der Nutzenden mit dem Inhalt von Objekten verglichen und die am besten passenden Items empfohlen. Informationen über die Interessen des Nutzers können entweder explizit durch Fragebögen erfasst oder implizit über das Nutzerverhalten (z. B. Lesegeschwindigkeit, Analyse der angeklickten Seiten oder Items) abgeleitet werden. Der Inhalt von Objekten kann etwa über Methoden der automatischen Sprachverarbeitung (engl. natural language processing) repräsentiert werden.

Beispiel: Alle Kurse in einem Kurskatalog werden durch Kursautor_innen, unterstützt durch natural language processing, mit thematischen Schlagworten versehen. Nutzende werden dann gebeten, aus einer Wolke von Schlagworten solche auszuwählen, die sie interessieren. Ein CBRS kann dann den Kurskatalog danach sortieren, wie gut die Schlagworte der Kurse zu den Interessen der Nutzenden passen. Die Empfehlung des Systems entspricht den obersten Einträgen der sortierten Liste.

Collaborative filtering Recommendersysteme (CFRS; Guruge et al., 2021) gehören zu den am häufigsten implementierten Recommendersystemen (Tarus et al., 2018). Sie basieren auf der Annahme, dass Personen, die in der Vergangenheit Elemente ähnlich bewertet haben, auch zukünftig ähnliche Präferenzen aufweisen. So wird bei CFRS die Nutzungshistorie anderer, ähnlicher Nutzer genutzt, um passende Vorschläge zu machen. Dabei sind zwei Ansätze zu unterscheiden: Entweder werden möglichst ähnliche Items, also z. B. Weiterbildungsangebote, identifiziert (*item-based collaborative filtering*) oder es werden möglichst ähnliche Nutzer_innen identifiziert (*user-based collaborative filtering*), um passende Vorschläge zu machen.

Beispiel: Ein CFRS vergleicht die bisher angeschauten Lerninhalte einer neuen Nutzerin x mit den bisher angeschauten Lerninhalten aller bisherigen Nutzer_innen y und z. Sagen wir etwa, x hat bisher die Inhalte 1, 2 und 3 angeschaut, y die Inhalte 1, 3 und 5 und z die Inhalte 2 und 4. Dann würde das CFRS der Nutzerin x sowohl die Inhalte 4 und 5 empfehlen, allerdings 5 höher ranken, weil x mehr gemeinsame Inhalte mit y aufweist (1 und 3) als mit z (2).

Ein Nachteil der CFRS ist das sogenannte „cold start“-Problem: Bei neuen Nutzer_innen (oder neuen Items) existieren keine Datenpunkte anhand derer man ähnliche Nutzer_innen (oder Items) identifizieren könnte. Das Aussprechen erster Empfehlungen ist daher besonders schwierig. Ein weiteres Problem, das die Genauigkeit von CFRS betrifft, ist „sparsity“, also eine spärlich besetzte User-Item-Matrix. Hier ist die Anzahl der durch eine_n Nutzer_in bewerteten Items zu gering, um daraus in der Folge eine Ähnlichkeit zu anderen Nutzer_innen zu ermitteln. Schließlich tendieren sowohl CBRS als auch CFRS dazu, auch dann noch thematisch ähnliche Kurse zu empfehlen, wenn ein Thema bereits verstanden wurde.

Die „cold start“- und „sparsity“-Probleme, die CBRS und CFRS mit sich bringen, sollen von wissensbasierten Recommendersystemen überwunden werden. *Wissensbasierte Recommendersysteme* (knowledge-based oder knowledge-aware Recommendersysteme, KBRS) verwenden Domänenwissen über die Präferenzen von Nutzer_innen, über die Items und über die Passung zwischen Nutzer_in und Item, um Empfehlungen auszusprechen (Tarus et al., 2018). Im Bildungskontext können KBRS beispielsweise zum Einsatz kommen, wenn Wissen über die zu lernende Domäne didaktisch wichtig für eine Generierung von passenden Empfehlungen ist. Eine Unterkategorie von KBRS stellen *Ontology-based Recommendersysteme* (OBRS) dar. OBRS nutzen Domänenontologien zur Bereitstellung von explizitem Wissen über die Domäne, in der Empfehlungen generiert werden sollen. Dieses Wissen ist nicht in Nutzerprofilen oder Item-Beschreibungen gespeichert. Ontology-based Recommendersysteme können dabei klassische Ansätze wie collaborative filtering nutzen oder die vernetzte Wissensstruktur für explorative Ansätze von Recommendersystemen nutzen (Vas et al., 2018).

Beispiel: Für die Domäne der Mittelstufenmathematik lässt sich etwa im Rahmen einer Ontologie definieren, dass das Lösen von Gleichungen mit einer Variablen Kenntnisse in den Grundrechenarten voraussetzt. Wenn nun ein_e Nutzer_in bereits einen Lerninhalt zu Grundrechenarten erfolgreich abgeschlossen hat, liegt es nahe, als nächstes einen Inhalt zum Lösen von Gleichungen mit einer Variablen vorzuschlagen.

Obwohl KBRS und OBRS viele Probleme von CBRS und CFRS ausgleichen, ist ihr zentraler Nachteil, dass sie wesentlich aufwändiger in der Entwicklung sind: Eine maschinenlesbare und feine Annotation der Kompetenzen, die ein Lerninhalt vermittelt, braucht Zeit und Expertise, die nicht für jeden Lerninhalt zur Verfügung steht. Daher kommen nicht für alle Situationen KBRS in Frage.

Neben diesen bereits beschriebenen Ansätzen gibt es eine ganze Reihe anderer Ansätze, die in spezifischen Kontexten sinnvoll sein können. Beispielsweise können *gruppenbasierte Recommendersysteme* Empfehlungen für Gruppen von Nutzer_innen und nicht nur einzelne Anwender_innen generieren. Eine weitere Möglichkeit stellen *kontextbasierte Recommendersysteme* (context-aware, CARS) dar, die den Kontext (z. B. Ort des Lernens, verfügbare Zeit) zur Generierung von personalisierten Empfehlungen heranziehen (Verbert et al., 2012).

Alle diese Ansätze haben Vor- und Nachteile, die hier jedoch nicht im Detail diskutiert werden sollen (eine gute Übersicht bietet das zweite Kapitel in Krauß, 2018). Um die Vorteile der einzelnen Ansätze bestmöglich auszunutzen und gleichzeitig die jeweiligen Nachteile auszugleichen, werden häufig *hybrid filtering*-Ansätze verwendet. Dabei werden verschiedene Ansätze gemeinsam genutzt, z. B., indem die Ergebnisse verschiedener Ansätze durch Gewichtung miteinander kombiniert werden, um Nutzer_innen einen Vorschlag zu machen (Tarus et al., 2018).

Was alle vorgestellten Recommender-Ansätze gemeinsam haben, ist, dass sie anders als Suchmaschinen keine explizite Nutzereingabe benötigen, sondern basierend auf dem Nutzerverhalten Empfehlungen generieren können. Zusätzlich können aber auch konkrete Datenpunkte, z. B. aus Nutzerfragebögen, mit eingebracht werden. Das Ergebnis solcher Empfehlungsalgorithmen ist häufig eine Liste von Empfehlungen, sortiert nach einer Relevanzbewertung, z. B. eine Bewertung der Wahrscheinlichkeit, mit der ein Produkt zum Interesse eine_r Nutzer_in passt.

1.3 Was haben Recommendersysteme mit künstlicher Intelligenz zu tun?

Recommendersysteme können auf Methoden der Künstlichen Intelligenz (KI) zurückgreifen, müssen das aber nicht notwendigerweise. Collaborative filtering basiert beispielsweise auf statistischen KI-Methoden. Je nach Ziel und Einsatzbereich können Recommendersysteme darüber hinaus auch auf eine Reihe von KI-Methoden aufsetzen (für eine Übersicht siehe Zhang et al., 2020). So kann beispielsweise natural language processing (dt. etwa „Verarbeitung natürlicher Sprache“) genutzt werden, um Kursbeschreibungen oder frei formulierte Nutzerbewertungen zu analysieren und in die weiteren Empfehlungen mit einzubeziehen. Reinforcement learning (dt. etwa „bestärkendes Lernen“) kann dazu dienen, das langfristige Nutzerverhalten in Recommendersystemen zu simulieren und damit die langfristige Nutzerzufriedenheit zu erhöhen. Beispielsweise setzt YouTube reinforcement learning ein (Zhang et al., 2020).

Ob ein Recommendersystem KI-Ansätze nutzt oder nicht, spielt aus Anwenderperspektive bei der Erklärbarkeit der Empfehlungen eine Rolle (das Konzept der Erklärbarkeit wird in Abschnitt

3.6 näher erläutert). Aus Entwicklerperspektive ist die Frage erstens relevant, weil abgeschätzt werden muss, welche Art von Recommendersystem sich auf die eigene Weiterbildungsplattform sinnvoll aufsetzen lässt und dadurch eine grobe Einschätzung des Datenbedarfs vorgenommen werden kann. Zweitens ist die Frage nach der KI in Recommendersystems relevant, weil eine geplante EU-Verordnung die Regulierung von KI-Anwendungen in Zukunft gesetzlich regeln soll („Gesetz über Künstliche Intelligenz“, Europäische Kommission, 2021b). Der aktuelle Entwurf von April 2021 sieht vor, dass alle KI-Systeme nach ihrem potenziellen Risiko eingestuft werden. Recommendersysteme im Bereich der beruflichen Weiterbildung dürften zu den Systemen gehören, bei denen Konsequenzen für Karriereverläufe zu erwarten sind (siehe ebd., Absatz 35), so dass diese Systeme vermutlich als „hochriskant“ klassifiziert werden. Für hochriskante Anwendungen sollen grundsätzlich strenge Vorgaben, u. a. zum Risikomanagement, zu Dokumentationspflichten und zur Qualität der Datensätze, gelten. Auch wenn die politischen Verhandlungen über den Regulierungsvorschlag noch andauern, könnte der bestehende Entwurf ein Anreiz sein, sich über die zu erwartenden Auswirkungen des eingesetzten Recommendersystems Gedanken zu machen und sich die geforderten Maßnahmen bereits jetzt näher anzusehen.

2 Recommendersysteme beim technologiegestützten Lernen

2.1 Recommendersysteme im Bildungsbereich allgemein

Recommendersysteme werden seit Beginn der 2000er auch im Bildungssektor zu verschiedensten Zwecken eingesetzt (Manouselis et al., 2012), normalerweise im Rahmen von Online-Plattformen (z. B. Lernplattformen), auf denen Nutzer_innen ein Profil besitzen müssen, um passgenaue Empfehlungen zu erhalten. Dabei können Recommendersysteme im Bildungsbereich für verschiedene Einsatzzwecke genutzt werden, die anhand des Empfehlungsinhalts des Systems unterschieden werden (basierend auf Drachslers et al., 2015).

Was schlägt das Recommendersystem vor?

Recommendersysteme können verschiedene Objekte oder sogar Personen empfehlen. Die Arbeitsgruppe rund um Hendrik Drachslers kategorisiert die möglichen Aufgaben eines Recommendersystems folgendermaßen:

- (1) **„Gute Inhalte finden“**: Das Recommendersystem schlägt qualitativ hochwertige, neue oder relevante Inhalte vor. Beispielsweise wurden bereits Recommendersysteme implementiert, die Bücher, Blogartikel, Lernmaterial, wissenschaftliche Publikationen oder Videos vorschlagen (Deschênes, 2020). Einige Recommendersysteme schlagen auch ganze Kurse (z. B. Universitätsseminare oder Weiterbildungsangebote) vor. Diese werden unter dem Begriff „course recommender systems“ zusammengefasst (Guruge et al., 2021). Die meisten der Recommendersysteme im Bildungsbereich können diesem ersten Aufgabenbereich zugeordnet werden (Drachslers et al., 2015).
- (2) **„Einen Lernpfad empfehlen“**: Das Recommendersystem schlägt eine Abfolge an Lerninhalten und -aktivitäten vor. Dies ist eine wichtige didaktische Aufgabe, die durch die Recommendersysteme unterstützt werden soll. Dabei ist wichtig zu betonen, dass kein verpflichtender, linearer Lernpfad generiert wird, sondern lediglich ein Vorschlag erstellt wird, den Lernende auch ablehnen können (Kerres & Buntins, 2020).
- (3) **„Eine Lernaktivität vorschlagen“**: Einige Recommendersysteme schlagen nicht Lerninhalte, sondern Lernaktivitäten vor (z. B. basierend auf affektiven Merkmalen, Santos et al., 2014).
- (4) **„Lernpartner_innen finden“**: Das Recommendersystem schlägt passende oder verfügbare Lernpartner_innen vor (siehe z. B. Rajagopal et al., 2017). Das Finden und Vernetzen geeigneter Personen, die gemeinsam lernen, kann beispielsweise gerade beim Online-Lernen hilfreich sein, um Gefühle der Isolation zu vermeiden (Drachslers et al., 2015).
- (5) **„Vorhersage von Lernerfolg“**: Einige wenige Systeme nutzen Recommenderalgorithmen, um Lernerfolg oder -performanz von Lernenden vorherzusagen (z. B. Thai-Nghe et al.).

Bei der Erfüllung dieser Aufgaben richten sich die Recommendersysteme meist an Lernende (Deschênes, 2020). Da die meisten Recommendersysteme (bzw. Publikationen dazu) im Hochschulbereich entwickelt werden, sind diese Lernenden zudem meist Studierende. Es ist jedoch auch denkbar, dass sich Recommendersysteme an Lehrende richten, z. B. beim Auffinden geeigneter Ressourcen für die Vorbereitung der Lehre.

Unterschied zu anderen Produktbereichen

Recommendersysteme im Bildungsbereich unterscheiden sich grundlegend von denen in anderen Bereichen: Um passende „Produkte“, z. B. Lernmaterialien, zu empfehlen, spielt eine Vielzahl an Faktoren eine Rolle, beispielsweise das Vorwissen oder der Lernkontext (Winoto

et al., 2012). Außerdem wollen sich Lernende selten von Empfehlungen „überraschen lassen“ oder die neueste Auflage eines Produkts finden, sie wollen vor allem gut gemachte und korrekte Lernangebote (Kerres & Buntins, 2020). Durch die Vielzahl an Kontextfaktoren und Bildungsinteressen sind Recommendersysteme im Bildungsbereich ungleich komplexer als in anderen Produktbereichen. Dies ist bei der Entwicklung und Evaluation der Recommendersysteme zu beachten (siehe auch Abschnitte 3.1 und 3.5).

2.2 Recommendersysteme in der beruflichen Weiterbildung

Zwar werden Recommendersysteme für unterschiedliche Bildungszwecke inzwischen immer häufiger eingesetzt, insgesamt sind sie in den verschiedenen Bildungsbereichen jedoch noch wenig verbreitet (Krauß, 2018, S. 8). In der beruflichen Aus- und Weiterbildung werden Recommendersysteme bislang nur selten eingesetzt: In einer Übersichtsstudie wurden nur vier der 44 identifizierten Systeme in der beruflichen Bildung eingesetzt (Carrera Rivera et al., 2018).

2.2.1 Review zu Recommendersystemen in der beruflichen Bildung

Die Forschung zu Recommendersystemen in der Bildung konzentriert sich bislang auf den Hochschulkontext (siehe z. B. Review von Deschênes, 2020). Da es bislang keine Übersichtsarbeit der verwendeten Ansätze und didaktischen Unterstützungsfunktionen von Recommendersystemen in der beruflichen Bildung gibt, sichten wir aktuell in einem systematischem Review Primärstudien, die Recommendersysteme in der beruflichen Aus- oder Weiterbildung verwenden. Dafür haben wir die Datenbanken ISI, Scopus und ERIC nach relevanten Primärstudien durchsucht.

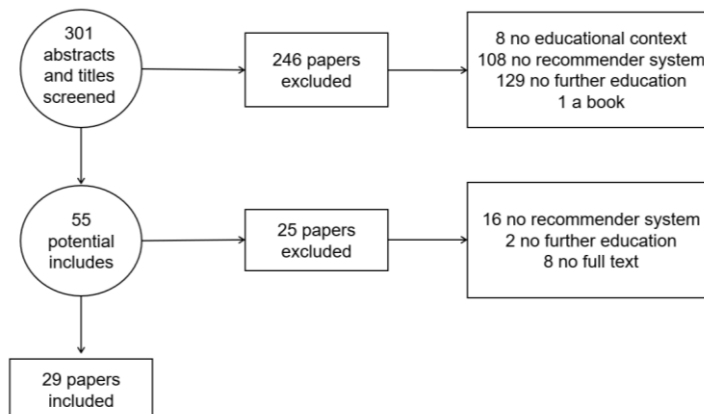


Abbildung 2: PRISMA-Diagramm

Es wurden nur englischsprachige Artikel, die zwischen 2015 und 2021 veröffentlicht wurden, einbezogen. Nach einem ersten Screening der Abstracts und einer Sichtung der Volltexte verblieben insgesamt 29 Artikel, die sich mit Recommendersystemen in der beruflichen Aus- und Weiterbildung auseinandersetzen (siehe Abbildung 2). Folgende erste Ergebnisse können zum jetzigen Zeitpunkt berichtet werden:

Die Recommendersysteme der identifizierten 29 Artikel lassen sich anhand der anvisierten didaktischen Unterstützungsfunktion und des genutzten technischen Ansatzes unterscheiden. So beschreiben beispielsweise 16 Studien Recommendersysteme, die dabei helfen sollen, gute Lerninhalte zu finden. Acht Studien beschreiben Recommendersysteme, die dabei helfen sollen, Lernpfade zu optimieren und eine Studie versucht mittels Recommendersystemen den Lernerfolg vorherzusagen. Besonders häufig werden dabei Recommendersysteme in Bezug auf Open Educational Resources ($n=5$) und MOOCs ($n=3$) erforscht.

Der Großteil der 29 Studien beschreibt einen einzelnen Ansatz genauer, z. B. hybride Recommendersysteme, collaborative filtering oder ontologiebasierte Modelle. Zehn der 29 Artikel vergleichen mehrere technische Ansätze miteinander. Während die Beschreibung und Evaluierung der technischen Umsetzung den Fokus der meisten Artikel darstellt, wird der didaktische Einsatzzweck häufig nur nachgelagert betrachtet. So wird beispielsweise, die Unterstützung, die ein Recommendersystem im Lernprozess leisten soll, nur unzureichend überprüft oder im praktischen Einsatz evaluiert. Dies entspricht dem Eindruck, der auch bei Recommendersystemen im Hochschulkontext überwiegt (siehe z. B. Review von Deschênes, 2020). Hinweise zur didaktischen Konzeption von Recommendersystemen und einer lernbezogenen Evaluation finden sich im weiteren Verlauf des Dossiers (siehe Abschnitte 3.1 und 3.5).

2.2.2 Recommendersysteme im INVITE-Wettbewerb

Aus der aktuellen Literaturlage lässt sich schließen, dass die Entwicklung und Erforschung von Recommendersystemen in der beruflichen Bildung noch nicht weit fortgeschritten sind – vor allem im Vergleich zu Anwendungen für das hochschulische Lernen. Dies wird sich möglicherweise auch durch den INVITE-Wettbewerb ändern. Hier sollen in zahlreichen Projekten Recommendersysteme zu verschiedenen Zwecken eingesetzt werden (siehe Abbildung 3). Es ist zu erwarten, dass hier reichhaltige Erkenntnisse gewonnen werden, in welcher Form und zu welchem Zweck verschiedene Zielgruppen (z. B. Lernende, Betriebe oder Anbieter) durch Recommendersysteme unterstützt werden können.

Recommendersysteme in INVITE-Projekten

Der BMBF-geförderte INVITE-Wettbewerb (Laufzeit von 2021–2025) hat zum Ziel, innovative Lösungen für die digitale, berufliche Weiterbildung zu entwickeln. In vielen der 35 geförderten Projekte sollen Recommendersysteme implementiert werden. Eine Auswahl dieser Projekte, ihrer Ansätze und Ziele werden hier vorgestellt.

ADAPT: Auf Basis von Stellenanzeigen werden aktuelle berufliche Qualifikationsanforderungen erfasst. Das Recommendersystem schlägt Lernmedien vor, die zu den Nutzerwünschen und diesen Qualifikationsanforderungen passen.

APOLLO: Es wird ein digitaler Weiterbildungsassistent als App implementiert. Die App schlägt passende Weiterbildungsangebote basierend auf dem individuellen Skill-Profil vor, dazu werden beispielsweise bestehende Zertifikate integriert und Lebensläufe analysiert.

DigiPlat4Train: Das Recommendersystem soll passende Schulungen für Mitarbeiter_innen in Produktionsbetrieben vorschlagen. Der Erfolg von Schulungen zur Reduzierung bestimmter Fehler soll erfasst werden und genutzt werden, um gezielte Empfehlungen auszusprechen.

EduPLex_API: Es soll ein Recommendersystem eingesetzt werden, das basierend auf dem Lernverhalten und dem Lernerfolg passgenaue Weiterbildungsinhalte empfiehlt und Marketingaktivitäten der Anbieter erlaubt.

EXPAND+ER WB³: Es soll ein Prototyp für die Suche und Empfehlung von Weiterbildungsangeboten, z. B. anhand von Interesse und Bildungsgrad, entwickelt werden. Ein großer Fokus liegt dabei auf dem Schutz der persönlichen Daten.

HUB-Grade: Für Weiterbildungen im Handwerk soll ein Matching-Algorithmus entwickelt werden, der Nutzer_innen zu ihren Qualifikationen passende Weiterbildungen vorschlägt.

KAMAELEON: Über die Berücksichtigung verschiedener Lernvoraussetzungen wie Vorwissen, Motivation und Affekt sollen passgenaue Lernangebote empfohlen werden.

KIPerWeb: Angestrebt wird ein personalisiertes Empfehlungsmanagement, um Lerner_innen auf individuelle Bedarfe zugeschnittene Weiterbildungen zu empfehlen. Für vier verschiedene Lernplattformen wird eine jeweils passende Kombination aus CBRS, CFRS und KBRS erforscht.

KIRA Pro: Unternehmen sollen zukunftsfähige Kompetenz- und Rollenprofile ermitteln, für die dann passende Mitarbeiter_innen ausgewählt werden, die eine entsprechende, individuelle Weiterbildung erhalten, um diese Rollen ausfüllen zu können. Hier werden somit gezielt Interessen des Betriebs mit integriert.

KUPPEL: Ein hybrides System soll Nutzerinnen und Nutzern auf ihren Hintergrund und ihre Interessen angepasst Lerninhalte oder -partnerschaften über verschiedene Weiterbildungsplattformen hinweg empfehlen. Komponenten dieses Recommendersystems sollen beliebig (de-)aktivierbar sein.

NetÖV: Weiterbildungsinteressierten aus der Mobilitätsbranche werden mittels eines Recommendersystems passende Weiterbildungsangebote verschiedenster Anbieter empfohlen. Hierbei werden die Bildungshistorie der Personen sowie mögliche Qualifikationspfade im ÖPNV bei der Empfehlung der Angebote berücksichtigt.

MyEduLife: Auf Basis des Weiterbildungsverhaltens von Nutzer_innen sollen Weiterbildungsempfehlungen ausgesprochen werden. Zudem sollen – nach Zustimmung der Nutzer_innen – die pseudonymisierten Nutzerdaten von Anbietern genutzt werden können, um Preismodelle und Angebotskataloge zu optimieren.

OnCa Pflege: Basierend auf europäischen und deutschen Kompetenzrahmen werden bestehende Kompetenzen mit angestrebten Ziel-Kompetenzen abgeglichen, um passgenaue Inhalte für Weiterbildungen in der Pflege vorzuschlagen.

SG4BB: Zum Auffinden personalisierter Serious Games soll ein Matching-Konzept entwickelt werden, um personalisierte digitale Lernspiele mittels einer Berufe-Klassifikation und ggf. weiteren Merkmalen zu zuordnen.

TripleAdapt: Durch die Auswertung von Lernerdaten und Produktionskennzahlen werden passende, individuelle Lernpfade vorgeschlagen.

WBsmart: Es soll eine bildungswissenschaftliche Grundlegung eines smarten KI-basierten digitalen Weiterbildungsraums für die Altenhilfe (außerklinische Pflege) mittels personalisierter und erklärbarer Recommendersysteme für die Lernenden entstehen.

WISY@KI: Basierend auf Bildungsabschluss, Berufserfahrung und Selbsteinschätzungen sollen individualisierte Kursempfehlungen aus der WISY-Datenbank generiert werden.

Abbildung 3: Recommendersysteme in Projekten des INVITE-Wettbewerbs

3 Implementierung von Recommendersystemen – Herausforderungen und Handlungsempfehlungen

Bei der Entwicklung und Implementierung von Recommendersystemen auf Weiterbildungsplattformen gibt es vielfältige Herausforderungen zu bedenken, die z. B. technischer, diagnostischer, ethischer oder didaktischer Art sind. Die zentralen Herausforderungen und mögliche Ideen zur Lösung sollen im Folgenden vorgestellt werden.

Die hier genannten Herausforderungen und Handlungsempfehlungen basieren maßgeblich auf der Analyse drei verschiedener Datenquellen. Erstens sind dies Aussagen, die in einem Expert_innenworkshop protokolliert wurden. Der Workshop wurde im Rahmen des Projekts „INVITE-Meta“ – dem Metavorhaben zum INVITE-Wettbewerb – im Oktober 2021 durchgeführt. Teilnehmer_innen waren Expert_innen für Matching-Prozesse in der beruflichen Weiterbildung, z. B. Bildungsberater_innen, und Weiterbildungsbeauftragte verschiedener Sozialpartner, und Informatiker_innen und Machine Learning-Spezialist_innen, die mit der Implementierung von verschiedenen Recommendersystemen betraut sind.

Als zweite Datenquelle diente ein Workshop auf der Auftakttagung des INVITE-Wettbewerbs im November 2021. Hier stellten Vertreter_innen der verschiedenen INVITE-Projekte aktuelle Herausforderungen und Herangehensweisen ihrer Projekte vor.

Als dritte Datenquelle wurde Forschungsliteratur zu Recommendersystemen in verschiedenen Bildungsbereichen (meist Hochschulbildung) und speziell in der beruflichen Aus- und Weiterbildung gesichtet. Aus einigen Studien konnten weitere Herausforderungen und Handlungsempfehlungen abgeleitet werden.

Die Erkenntnisse dieser verschiedenen Datenquellen werden gemeinsam, aber nach Thema gruppiert, vorgestellt.

3.1 Didaktisches Ziel klären und fundierte (instruktionale) Mechanismen nutzen

Recommendersysteme im Bildungsbereich sollen verschiedene Aspekte des Bildungsprozesses unterstützen. Welches konkrete didaktische Ziel das Recommendersystem unterstützt, sollte zu Beginn jeder Entwicklung eines Recommendersystems spezifiziert werden. Ein solches Ziel kann beispielsweise das Auffinden passender Lernressourcen sein (siehe auch Unterscheidung der Recommendersysteme nach Empfehlungsinhalt in Abschnitt 2.1). Darüber hinaus sind weitere oder neue didaktische Ziele denkbar, für die zukünftige Recommendersysteme eingesetzt werden können, um z. B. auch eine betriebliche Perspektive stärker zu bedienen (siehe auch Handlungsempfehlung 3.7 „Berücksichtigung der Betriebe“).

Nach der Zielsetzung eines Recommendersystems gilt es zu überlegen, wie dieses Ziel erreicht werden kann:

- Welche Merkmale der Lernenden oder des Lernmaterials müssen beispielsweise herangezogen werden, um gute Empfehlungen auszusprechen?
- Welche instruktionalen Theorien liegen den konkreten Empfehlungen zu Grunde?

Manouselis und Kolleg_innen (2011) beispielsweise äußern mit Rückbezug auf Vygotskys „Zone of proximal development“ (1978) die Idee, dass Recommendersysteme solche Lernressourcen vorschlagen, die knapp über dem Fähigkeitslevel der Lernenden liegen. Lerntheoretisch begründete Überlegungen scheinen jedoch die Ausnahme zu sein: Kerres und

Buntins (2020) kritisieren, dass viele Studien über im Bildungsbereich eingesetzte Recommendersysteme nicht beschreiben, auf welchen didaktischen Mechanismen oder instruktionalen Überlegungen diese basieren. So sind zwar umfassende technische oder mathematische Beschreibungen der eingesetzten Algorithmen zu finden, aber nur selten instruktionale oder didaktische Argumente für eine konkrete Ausgestaltung. Die Autor_innen Kerres und Buntins zweifeln, ob ein didaktisch nicht fundierter Einsatz von Recommendersystemen ethisch überhaupt vertretbar ist. Zu empfehlen bleibt daher, empirisch belegte Mechanismen oder instruktionale Theorien als Grundlage für die Entwicklung eines Recommendersystems heranzuziehen und im späteren Einsatz entsprechend zu prüfen. Allerdings ist gerade diese Evaluation der Nützlichkeit von Recommendersystemen schwierig und auch in der Literatur noch ein wenig beforschter Bereich (siehe auch Kapitel 3.5 „Evaluation“).

3.2 Datengrundlage

Ein Recommendersystem lebt von der verwendeten Datengrundlage bzw. -auswahl. Dabei hängt die verwendete Datengrundlage einerseits von der anvisierten didaktischen Unterstützungsfunktion (siehe Kapitel 2.1), andererseits vom gewählten technischen Ansatz ab (siehe Kapitel 1.2) ab.

Prinzipiell gibt es eine Reihe von Aspekten, die betrachtet werden können, um passende Weiterbildungen oder Lernmaterialien vorzuschlagen. Diese betreffen sowohl die Lernenden und Betriebe als auch das Weiterbildungsangebot selbst (siehe Abbildung 4). Dabei ist angesichts der schier unendlichen Anzahl der Aspekte bereits klar, dass sie nicht alle betrachtet werden können. Vielmehr sollte überlegt werden, welche Variablen als Grundlage für Recommendersysteme genutzt werden, welche Variablen evtl. in der Beschreibung der Angebote verwendet werden und welche Variablen zusätzlich über einfache Filterfunktionen durch die Nutzer_innen angesteuert werden können (z. B. Dauer des Kursangebots). Es gilt hier insgesamt eine Abwägung zu treffen zwischen der größtmöglichen Datensparsamkeit und dem Ziel, möglichst gute Empfehlungen auszusprechen. Bei der Abwägung sind nicht alle Daten gleich, denn sowohl Erhebungsaufwand als auch Sensitivität der Daten unterscheiden sich stark. Statistiken über Kursbesuche etwa werden von den meisten Lernplattformen automatisch erhoben, während Daten über die individuellen Präferenzen von Nutzenden direkt erfragt oder indirekt abgeleitet und Metadaten über Kurse meist von Autor_innen händisch eingetragen werden müssen. Personenbezogene Daten – erst recht indirekt erschlossene – sind wiederum sensibler als Metadaten über Kurse, die keinen Personenbezug haben. Schließlich ist auch die Auswirkung auf die Empfehlungsqualität nicht gleich: Bei statistischen Daten sind üblicherweise viele Daten notwendig, um die Empfehlungsqualität zu verbessern, während bei Kursannotationen bereits eine einfache, thematische Verschlagwortung die Qualität deutlich heben kann. Der Abwägungsprozess zwischen Datensparsamkeit und Empfehlungsqualität fällt daher vermutlich je nach Branche, Weiterbildungsplattform und Einsatzzweck unterschiedlich aus.

Die schließlich ausgewählten Datenfelder sollten valide erhoben werden. Variablen, die das Individuum betreffen, z. B. Interesse und Persönlichkeit, werden in anderen Bereichen häufig mit Tests erhoben, die diagnostische Gütekriterien erfüllen und ein Merkmal valide, reliabel und objektiv erfassen. Es ist denkbar, solche Testverfahren auch als Datengrundlage für Recommendersysteme zu nutzen, z. B. indem neue Nutzer_innen einer Plattform einen fundierten Interessenstest absolvieren. Doch auch hier gilt es, eine Abwägung zu treffen zwischen dem Wunsch, vollständige und valide Informationen zu den Nutzer_innen zu erheben, und dem zeitlichen Aufwand, der dafür investiert werden muss. Kerres und Buntins (2020) führen an, dass in vielen Fällen das Verwenden von Expertenbewertungen (z. B. der angebotenen Kurse) inhaltlich

zielführender und finanziell sparsamer sein kann als das Umsetzen eines komplexen Recommendersystems, das auf vielfältigen Lernendenvariablen basiert. Hier bedarf es einer realistischen Kosten-Nutzen-Einschätzung auf Seiten der Entwickler_innen und Didaktiker_innen.

Neben den betrachteten Variablen und der Qualität ihrer Erfassung, spielt auch die Quantität der vorhandenen Daten eine Rolle. Die Implementierung eines Algorithmus, der statistische Muster in den Nutzungsdaten betrachtet, benötigt Informationen von mehreren hundert Lernenden, um sinnvolle Aussagen zu treffen. Gerade, wenn nicht nur einzelne Kurse, sondern Kursabfolgen empfohlen werden sollen, braucht es eine umfassende Datenbasis, damit für alle Kursübergänge Daten vorliegen. Die Anzahl der benötigten Datenpunkte steigt dabei mit der Anzahl der angebotenen Kurse. Besonders herausfordernd ist die Berücksichtigung neuer Kurse, für die noch keine Daten vorliegen („cold start“-Problem“, siehe auch Abschnitt 1.2).

3.3 Datenpflege und Taxonomien

Anzahl und Natur der betrachteten Datenfelder eines Recommendersystems sind relevant für einen weiteren herausfordernden Punkt: die Datenpflege. Gerade bei historisch gewachsenen Kurskatalogen und der Integration externer Angebote fällt viel personeller Arbeitsaufwand für die Überprüfung und Übersetzung der Datenfelder an. Auch aus diesem Grund sollte es Ziel sein, ein möglichst datensparsames Recommendersystem zu implementieren. Im Kern des Datenpflegeproblems dürfte allerdings auch das Fehlen geteilter bildungsbezogener Begrifflichkeiten stecken (Kerres & Buntins, 2020). Taxonomien könnten hier zumindest für einige Bereiche eine Hilfe darstellen. Diese können sich auf unterschiedliche Einsatzzwecke und Ebenen beziehen: Auf die Beschreibung und Zuordnung von Berufsfeldern, Branchen und Berufsqualifikationen (z. B. ESCO, Europäische Kommission, 2021a), auf die Beschreibung von Lernformaten (z. B. klare und geteilte Begrifflichkeit von „blended learning“) oder die Erfassung von Lernzielen und -niveaus (z. B. Blooms überarbeitete Taxonomie der Lernziele, Anderson & Krathwohl, 2001). Für einige dieser Bereiche, z. B. Beschreibungen von digitalen Lernformaten, fehlt es noch an stringenten Taxonomien, auf die man sich explizit oder implizit geeinigt hat. Für andere Bereiche dagegen gibt es umfassende und aktuelle Taxonomien (z. B. die Berufsklassifikationen der Bundesagentur für Arbeit), die jedoch nicht flächendeckend genutzt werden. Eher scheint es so zu sein, dass jede Plattform eigene Datensets entwirft, um die eigenen Angebote zu beschreiben. Dies macht die Verknüpfung von Angeboten verschiedener Anbieter im Sinne der Interoperabilität jedoch sehr aufwändig oder unmöglich, z. B., um eine umfassende Suche nach passenden Kursen anzubieten.

Wenn man sich zwischen verschiedenen Anbietern oder Plattformen auf entsprechende Taxonomien z. B. für Kursangebote, Stellenanzeigen oder Lernmaterial einigen und diese in einheitlichen, maschinenlesbaren Metadatenformaten implementieren würde, könnte dies den Aufwand für die Datenpflege erheblich minimieren. Zudem würde die Vergleichbarkeit und Durchsuchbarkeit von Angeboten auch plattformübergreifend erleichtert. Schließlich ist auch zu erwarten, dass weitreichend akzeptierte Taxonomien das Bilden einer gemeinsamen Fachsprache fördern und die Kommunikation über Weiterbildungsangebote zwischen Bildungsträgern, Arbeitgebern und Lernenden erleichtern können. Hier ist allerdings von der Community noch viel Arbeit zu leisten. Eine Handlungsempfehlung der Expert_innen im Workshop war es, zumindest – wo möglich – bestehende Taxonomien (z. B. ESCO) heranzuziehen und sich für andere Bereiche mit Gleichgesinnten auf ein minimales Set geteilter Begrifflichkeiten und Datenfelder zu einigen. Aktuell laufende Vorhaben wie die Nationale Bildungsplattform, die GAIA-X Bildungsdomäne und auch der INVITE-Wettbewerb, werden in den kommenden Jahren sicherlich zu einer Standardisierung in diesem Bereich beitragen.

Aspekte, die für die Auswahl eines passenden digitalen Weiterbildungsangebots potenziell relevant sind.

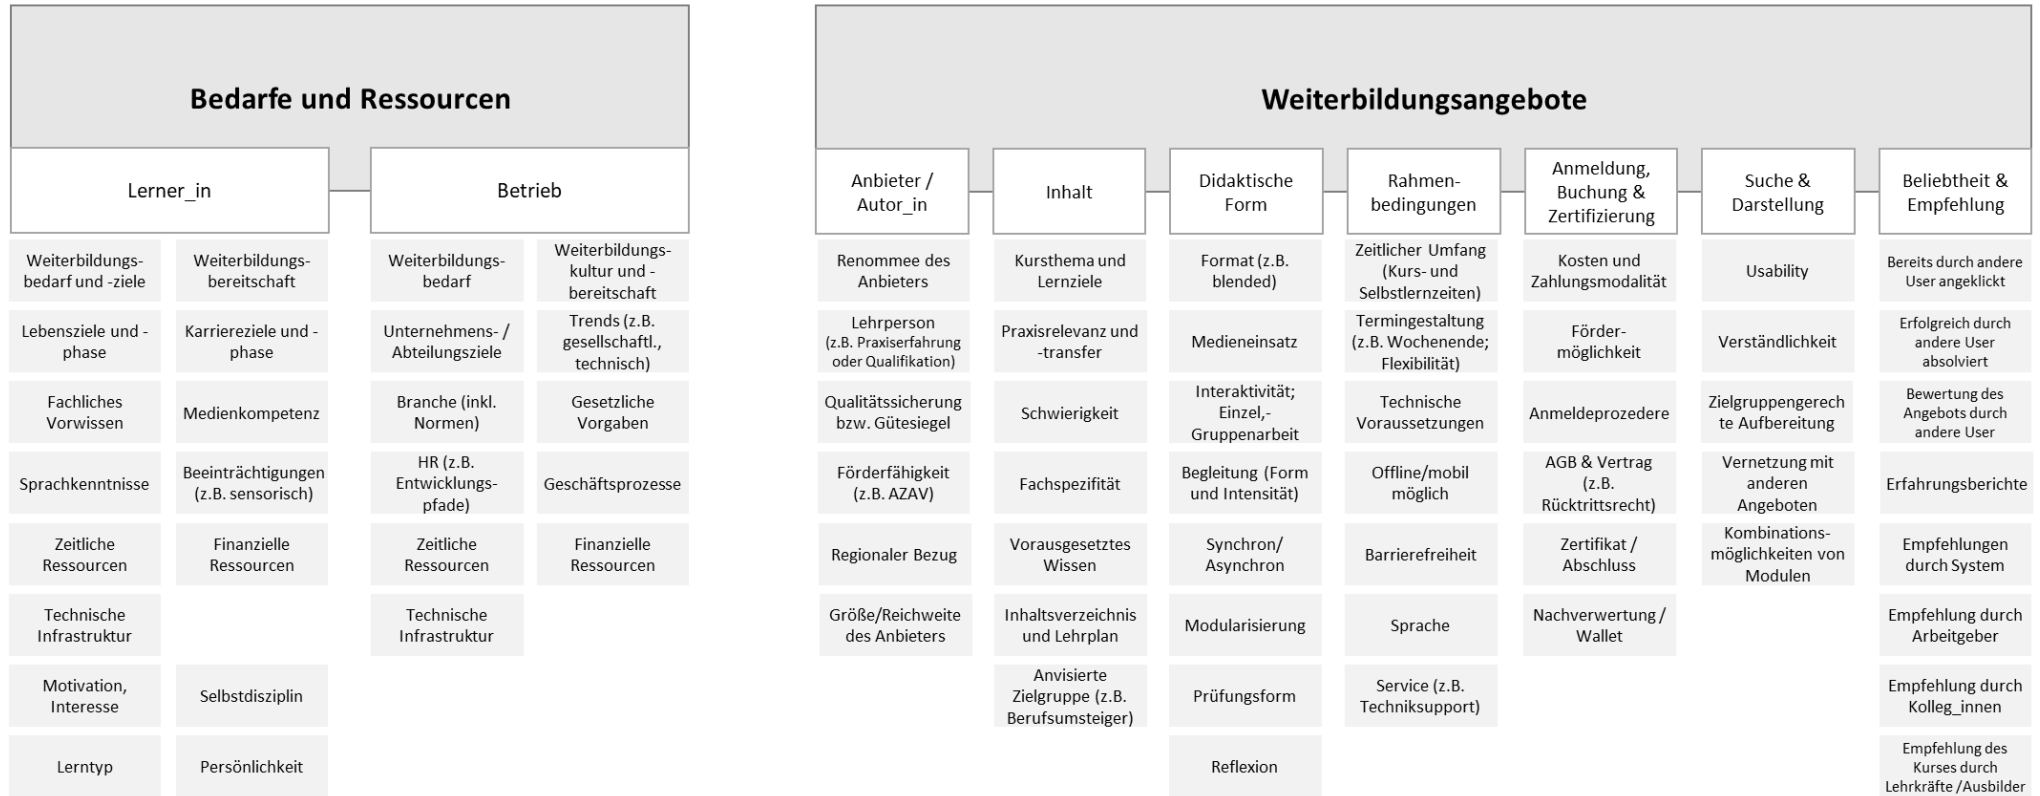


Abbildung 4: Aspekte, die für die Auswahl passender Weiterbildungen relevant sein können.

3.4 Zielgruppenspezifische Ausgestaltung und Anpassbarkeit der Empfehlungen

Ein weiterer Aspekt, der betrachtet werden sollte, ist die Interaktion zwischen Nutzer_innen und Recommendersystem. Generell muss hier bedacht werden, dass je nach anvisierter Branche und Nutzergruppe die Lernenden mit unterschiedlichen Voraussetzungen an eine Weiterbildungsplattform herantreten, beispielsweise mit unterschiedlichen Ausprägungen von Medienkompetenz, Weiterbildungsmotivation und Sprachkompetenz. Diese Aspekte sollten bei der Implementierung der Plattform insgesamt, aber auch bei der Ausgestaltung eines Recommendersystems mitgedacht werden. Gerade Personen mit geringerer Medienkompetenz und weniger ausgeprägten Bildungs- oder Karrierevorstellungen sollten in geeigneter Weise im Gebrauch der Weiterbildungsplattform unterstützt werden, möglicherweise auch durch hybride Formate (z. B. durch die Unterstützung eines Mentors im Gebrauch der Plattform). Dies betrifft einerseits die gewählte Unterstützungsfunktion des Recommendersystems und andererseits die Darstellung der Ergebnisse. Es sollte gründlich überlegt werden, welche typischen Probleme oder Hindernisse die anvisierte Zielgruppe mitbringt und wie diese Hindernisse durch ein passendes Recommendersystem minimiert werden können, um Überforderungen zu vermeiden und eine positive Konnotation von Weiterbildung zu begünstigen, ohne die Autonomie der Lernenden zu untergraben. Dies ist ein komplexer Abwägungsprozess, der die Aufgaben des Recommendersystems und die Auswahl der dazu passenden Daten bedingt (siehe auch Kapitel 3.2 „Datengrundlage“).

Daneben ist die Anpassbarkeit oder gezielte Beeinflussung des Recommendersystems relevant, um für eine höhere Akzeptanz des Systems zu sorgen. Zum Teil geschieht dies bereits automatisiert, wenn das Nutzerverhalten direkt die Empfehlung weiterer Inhalte oder Aktivitäten beeinflusst. Eine wichtige Zielgröße ist hier beispielsweise nicht nur das Anklicken eines Kurses, sondern vor allem auch der erfolgreiche Abschluss eines Kurses. Hieraus können Rückschlüsse über den Lernstand der Lernenden als auch über die Qualität oder Schwierigkeit des Kurses gezogen werden, die dann wiederum weitere Empfehlungen beeinflussen. Vorsicht ist hier insofern geboten, als dass sich durch solche Rückkopplungsschleifen Effekte auch manifestieren können: so werden z. B. wenig besuchte Kurse kaum empfohlen, so dass sie weiterhin geringe Nutzerzahlen aufweisen. Umgekehrt kann es auch vorkommen, dass ein bestimmter Kurs in einer kurzen Zeit höhere Bewertungen durch mehrere Nutzer_innen erhält. Die meisten Empfehlungsalgorithmen werden diesen Kurs entsprechend häufiger oder eher empfehlen. Dies wiederum bedeutet, dass der Kurs voraussichtlich weiterhin mehr Bewertungen erhalten wird als andere Kurse. Dieser Effekt wird auch als Lemmingeffekt bezeichnet (Wiedermann et al., 2014). Dieser und andere Effekte können über verschiedene Methoden statistisch ausgeglichen werden (z. B. Abdollahpouri et al., 2019).

Eine andere Möglichkeit, Nutzer_innen das Recommendersystem anpassen zu lassen, bietet das Einholen expliziten Feedbacks. Dies kann beispielsweise realisiert werden, indem Nutzende die Option erhalten, bestimmte Kurse oder Inhalte von einer weiteren Empfehlung auszuschließen oder vorgeschlagene Inhalte zu bewerten. So lernt das System sich noch gezielter an die persönlichen Präferenzen der Nutzer_innen anzupassen. Durch die Beteiligung der Nutzer_in an den Empfehlungen des Systems soll eine höhere Individualisierung und Passung der Empfehlungen erreicht werden. Zudem ist das Ziel, die Kontrolle über und das Vertrauen in das eingesetzte Recommendersystem durch die Lernenden sicherzustellen.

3.5 Evaluation des Recommendersystems

Die Entwicklung und Implementierung eines Recommendersystems sind zeitlich und finanziell aufwändige Tätigkeiten. Umso wichtiger ist es, zu prüfen, ob das Recommendersystem tatsächlich die anvisierten Unterstützungsfunktionen leisten kann.

In anderen Produktbereichen werden für die Evaluation von Recommendersystemen üblicherweise vor allem technisch-mathematische sowie statistische Kriterien herangezogen, wie etwa Genauigkeit („accuracy“), Präzision („precision“), Trefferquote („recall“) und F-Maß („F-measure“). Diese Kriterien werden auch für zahlreiche Recommendersysteme im Bildungssystem herangezogen (für eine Übersicht siehe Deschênes, 2020).

Ebenso aus anderen Produktbereichen bekannt sind Evaluationen anhand verschiedener nutzerzentrierter Maße, z. B. der Nutzerzufriedenheit (Knijnenburg & Willemsen, 2015). Diese wird beispielsweise quantitativ über die Anzahl der Klicks der Nutzer_innen abgeschätzt oder qualitativ über eine Abfrage der Nützlichkeit der Empfehlungen des Recommendersystems („War dieser Vorschlag für Sie hilfreich?“). Die Evaluation der Nutzerzufriedenheit stellt in einem Review aktueller Recommendersysteme im Bildungsbereich die meistgenutzte Evaluationsgröße dar (Deschênes, 2020).

Darüber hinaus erfordert der Bildungskontext auch didaktische Zielgrößen, um den Effekt des Recommendersystems zu untersuchen. Eine mögliche Zielgröße, um die Wirksamkeit eines Recommendersystems zu bestätigen, sind verschiedene Maße von Lernleistungen (beispielsweise verbesserte Sprachfähigkeit oder besseres Abschneiden in einem Wissenstest). Diese werden häufig durch Pre- und Posttests, also Tests vor und nach Benutzung des Recommendersystems, erfasst und dann mit der Leistung einer Kontrollgruppe (meist einer Gruppe, die zufällige und keine individuellen Empfehlungen erhält) abgeglichen. Im bereits angesprochenen Review von Deschênes haben 10 von 56 Studien eine solche experimentelle oder quasi-experimentelle Leistungsevaluation vorgenommen. Neben solchen Maßen der Testleistung sind aber auch andere lernbezogene Evaluationsmaße denkbar, beispielsweise die Effektivität (z. B. Lernfortschritt) und Effizienz (z. B. benötigte Lernzeit) des Lernens oder die Kollaboration mit Lernpartner_innen (Drachsler et al., 2015).

Zu bedenken bleibt hier, dass sich die meisten bislang entwickelten und untersuchten Recommendersysteme an Lernende, meist Studierende, richten. Bei Anwendungen für andere Zwecke oder Zielgruppen müssen entsprechend andere sinnvolle Zielgrößen für die Evaluation gefunden werden. Dies könnten in der beruflichen Weiterbildung auch betriebliche Zielgrößen sein, wie z. B. die betriebliche Weiterbildungsbeteiligung.

Neben einer gründlichen Überlegung, welche technisch, statistischen und didaktischen Zielvariablen für eine Evaluation des Recommendersystems sinnvoll sind, empfehlen Manouselis und Kolleg_innen (2012) die Verwendung eines standardisierten Evaluationsablaufs. Ein Vorschlag für einen solchen Prozess ist bei den Autor_innen nachzulesen. Festzuhalten bleibt, dass die Evaluation von Recommendersystemen keinesfalls trivial ist, was vermutlich erklärt, warum es bislang nur wenige aus didaktischer Perspektive evaluierte Recommendersysteme gibt.

3.6 Fairness, Erklärbarkeit und Nachvollziehbarkeit der Empfehlungen

Im Workshop wiesen viele der beteiligten Expert_innen immer wieder auf zentrale ethische Grundprinzipien hin, so z. B. das Beachten von Fairness bei der Generierung der Empfehlungen und die Erklärbarkeit und Nachvollziehbarkeit der Empfehlungen für die Nutzer_innen.

Fairness

Fairness in Bezug auf Recommendersysteme für die Weiterbildung kann beispielsweise bedeuten, dass ein Recommender-Algorithmus nicht bestimmte Anbieter systematisch bevorzugen darf. Stattdessen sollte die Unabhängigkeit der Kurs- oder Materialempfehlungen geprüft und sichergestellt werden. In Bezug auf die Lernenden bedeutet Fairness, dass jede_r eine faire Chance auf eine passende Weiterbildungsempfehlung erhalten sollte. Gerade bei der Implementierung von selbstlernenden KI-Algorithmen, in denen demografische Daten genutzt werden, ist hier besondere Vorsicht geboten. Schließlich wird immer wieder gezeigt, dass KI-Implementierungen zu unfairen Schlüssen kommen und teilweise Minderheiten oder beeinträchtigte Personen benachteiligen (z. B. Ntoutsi et al., 2020). Wie in anderen Bereichen auch, sollte daher das Vermeiden von Verzerrungen schon in der Entwicklungsphase mitgedacht werden (Hao, 2019) und später auf diverse Testsamples, z. B. bezüglich Geschlecht, Bildungsstand, sozioökonomischem Status, Beeinträchtigungen, geachtet werden.

Erklärbarkeit und Nachvollziehbarkeit

Eine von einem Recommendersystem generierte Empfehlung sollte laut der Expert_innen den Nutzer_innen erklärt und nachvollziehbar präsentiert werden. Dies bezieht sich einerseits auf die Herleitung der Entscheidung und andererseits auf die gewählte Darstellung des Outputs. Allerdings stellen moderne KI-basierte Algorithmen häufig eine Art „Black-Box“ dar, deren Empfehlungen nur schwerlich zu erklären sind. Die Anforderung, dass die Mechanismen und Ergebnisse von KI-Systemen transparent und nachvollziehbar erläutert werden können, wird unter dem Stichwort „Explainable AI“ aktuell breit diskutiert (Saeed & Omlin, 2021). In einer aktuellen Betrachtung leiten Saeed und Omlin (2021) fünf Perspektiven ab, aus denen ein Bedarf an erklärbaren KI-Algorithmen notwendig wird:

- (1) **Regulatorische Perspektive:** Diese Perspektive beschäftigt sich mit der Erklärbarkeit von KI-Algorithmen für Nutzer_innen, die aufgrund von rechtlichen Anforderungen notwendig sind (z. B. der „Anspruch auf Erläuterung“ in der DSGVO, Erwägungsgrund 71, oder die neue KI-Verordnung, siehe hierzu auch hierzu auch Kapitel 1.3).
- (2) **Wissenschaftliche Perspektive:** Diese Perspektive erforscht die Erklärung von KI-basierten Empfehlungen, die zu neuen Erkenntnissen oder Zusammenhängen im Anwendungsfeld führen kann.
- (3) **Industrielle Perspektive:** Diese Perspektive betrachtet Regularien für interpretierbare KI-Anwendungen, Skepsis durch die Nutzer_innen gegenüber KI-Lösungen und der Balance zwischen Interpretierbarkeit und Performance der verwendeten Algorithmen.
- (4) **Modellentwicklungs-Perspektive:** Diese Perspektive untersucht die Möglichkeiten für Verständnis, Ableitung und Verbesserung von KI-Algorithmen.
- (5) **Endnutzer_in und soziale Perspektive:** Diese Perspektive reflektiert das Nutzervertrauen und potenziell unfaire Entscheidungen von KI-Systemen.

Im Expert_innenworkshop wurde vor allem die Perspektive der Endnutzer_innen diskutiert: So könnten beispielsweise die Empfehlungen des Systems begründet werden, z. B. indem angezeigt wird, auf Basis welches Datenpunktes oder welcher Nutzereingabe eine konkrete Kursempfehlung ausgesprochen wurde. Mit Blick auf die Darstellung der generierten Empfehlungen kann es sinnvoll sein, auf plastische und – je nach Zielgruppe – simple Darstellungen zu

setzen. Eine Möglichkeit, um Akzeptanz und Verständnis für die Systemempfehlungen zu fördern, könnten auch visuelle Darstellungen der Ergebnisse sein (für den Hochschulbereich erprobt durch Ma et al., 2021). Ein aktueller Überblick verschiedener Erklärbarkeitstechniken findet sich bei Bennetot et al. (Bennetot et al., 2021).

Die Berücksichtigung von Fairness, Erklärbarkeit und Nachvollziehbarkeit sind wichtige ethische Kernprinzipien an sich, begünstigen möglicherweise aber auch das Herstellen von Vertrauen gegenüber Recommendersystemen. So dürften Recommendersysteme den meisten Nutzer_innen zwar aus anderen Kontexten (z. B. Video- und Shoppingportalen) bekannt sein, nichtsdestotrotz ist der Bildungsbereich ein ungleich sensiblerer Bereich, in dem Skepsis gegenüber computergestützten Systemen eine weitaus höhere Rolle spielen dürfte. Die transparente Darstellung des Recommendersystems könnte hier – natürlich neben einer offensichtlichen Nützlichkeit des eingesetzten Systems – vertrauensbildend wirken. Gerade wenn jedoch kein Vertrauen gegenüber Recommendersystemen besteht oder eine vollständig selbstgesteuerte Erkundung der Inhalte gewünscht ist, wäre es auch denkbar, den Nutzer_innen die Option zu bieten, das Recommendersystem „abzuschalten“.

3.7 Berücksichtigung der Betriebe

Die Mehrzahl der bereits angeführten Argumente betrifft die Lernenden, die auf der Suche nach einem passenden Weiterbildungsangebot, Lernmaterialien oder Lernpartnern sind. Dies entspricht dem Aufbau der meisten Recommendersysteme: Individuelle Personen suchen Angebote oder Produkte, die bestmöglich zu ihren eigenen Bedarfen und Interessen passen. Doch gerade im Rahmen der beruflichen Weiterbildung müssen diese individuellen Bedarfe häufig mit den Bedarfen eines Betriebs übereinstimmen. Diese zusätzliche Perspektive macht den Einsatz von Recommendersystemen im Bereich der beruflichen Weiterbildung noch einmal ungleich komplexer als in anderen Bereichen. Im Grunde erfordert ein Recommendersystem in der beruflichen Bildung eine Multistakeholder-Perspektive. Unter dem Begriff der *Multistakeholder Recommendation* werden solche Systeme aber erst seit wenigen Jahren überhaupt erforscht (Abdollahpouri et al., 2020). Für den Bildungsbereich existieren erste Ideen, wie verschiedene Bildungsinteressen in einem Recommendersystem berücksichtigt werden können (Zheng et al., 2019).

Recommendersysteme – oder Weiterbildungsplattformen allgemein – die spezifisch auf die Bedarfe von Betrieben ausgerichtet sind, gibt es unseres Wissens bislang nicht oder werden bislang nicht öffentlich diskutiert. Dabei liegt gerade hier ein großes Potenzial: In Deutschland gibt es ca. 3,4 Mio. Unternehmen (Stand 2019; Statistisches Bundesamt, 2021). Davon sind etwa 99,4 % kleine und mittlere Unternehmen (KMU) mit maximal 249 Beschäftigten (KMU-Definition der Europäischen Kommission). Auch wenn KMU viel Zeit und Geld in Weiterbildung investieren, so hat ein Großteil dieser Unternehmen doch keine eigene Weiterbildungsabteilung (Seyda, 2021). Entsprechend fehlt es häufig an formalisierten Prozessen zur Personalentwicklung, z. B. durch detaillierte Bedarfsanalysen zur Feststellung von Weiterbildungsbedarfen der Mitarbeiter_innen. Weiterbildungsplattformen mit entsprechenden Recommendersystemen böten hier bei entsprechender Ausrichtung eine Möglichkeit, insbesondere KMU bei der Feststellung von Weiterbildungsbedarfen und der Auswahl passender Lerninhalte für diese Weiterbildungen zu unterstützen. Wie genau eine Weiterbildungsplattform und Recommendersysteme implementiert sein müssen, damit gerade KMU ermächtigt werden ihre Weiterbildungsprozesse zu professionalisieren, ist unseres Wissens nach, eine offene Frage. Zu bedenken bleibt hier allerdings, dass sich ein praktisches Problem aus der großen Menge an verschiedenen, aber unverknüpften Lernplattformen ergibt: hunderte Lernplattformen bieten

mittlerweile Kurse an und implementieren Recommendersysteme, die auf die Kurse der eigenen Plattform zugreifen. Dadurch droht ein 'lock-in'-Effekt: Betriebe finden nicht unbedingt die passendsten Angebote, sondern nur die passendsten Kurse, die innerhalb der Plattform, die sie gerade nutzen, angeboten werden. In Zukunft könnte dieses Problem durch interoperable Plattformen oder durch gemeinsame Vorhaben im Rahmen der Nationalen Bildungsplattform, Gaia-X oder auch dem INVITE-Wettbewerb verringert werden.

3.8 Verknüpfung von Recommendersystemen und persönlicher Bildungsberatung

Karrierecoachings, Bildungs- und Berufsberatung sind wichtige Komponenten des beruflichen Bildungssektors. Egal ob durch öffentliche Stellen (z. B. städtische Bildungsberatung oder Bundesagentur für Arbeit) angeboten oder privat finanziert, diese Leistungen bieten Menschen Orientierung und helfen bei der Identifikation von Karriere- und Weiterbildungszielen. Auch Betriebe – gerade solche ohne eigene Weiterbildungsabteilung – nutzen öffentliche Unterstützungsstrukturen, um relevante gesellschaftliche und technologische Transformationen zu analysieren und entsprechende Bildungsbedarfe zu identifizieren.

Idealerweise ergänzen Recommendersysteme diese bestehenden Infrastrukturen der Bildungsberatung. Denkbar wäre beispielsweise die Umsetzung eines mehrstufigen Verfahrens: Durch eine persönliche Bildungsberatung klären Personen erst ihre individuellen Karriereziele und konkretisieren dazu passende Weiterbildungsbedarfe. Mit einem spezifischen Ziel und einer klaren Erwartungshaltung nutzen diese Personen in einem zweiten Schritt das Recommendersystem einer geeigneten Weiterbildungsplattform, um eine Weiterbildung auszuwählen, die zu den Zielen und eigenen Ressourcen passt. Andersherum wäre es denkbar, dass über eine Weiterbildungsplattform Karriereziele und Weiterbildungsbedarfe schon vorab spezifiziert werden, z. B. durch eine entsprechende Abfrage. Mit diesen Informationen könnten Bildungsberater_innen dann gezielter ihre Klient_innen beraten. Es gibt erste Projekte, die eine Kopplung von Recommendersystemen an eine persönliche Beratung oder ein persönliches Mentoring umsetzen (z. B. Gábor Kismihók et al., 2022). Es wäre denkbar, ein ähnliches System für die berufliche Bildung gemeinsam mit Bildungsberater_innen aufzusetzen und zu prüfen, welche individuellen Bedarfe und Ziele schon geklärt sein müssen, damit die Nutzung eines Recommendersystems hilfreich ist und welche persönliche Beratung sich noch anschließen sollte. Insgesamt wäre bei einem solchen Methodenmix das Ziel, dass Algorithmen und Mensch im Sinne der „Hybrid Intelligence“ (Dellermann et al., 2019) jeweils das machen, was sie am besten können: Das Recommendersystem generiert basierend auf unüberschaubaren Datenmengen passende Vorschläge und der Mensch bietet Orientierung und gestaltet individualisierte Abwägungsprozesse über die Sinnhaftigkeit der angestrebten beruflichen Transformation.

4 Fazit

Im vorliegenden Dossier wurden Recommendersysteme grundlegend erläutert und zahlreiche Einsatzfelder für Recommendersysteme im Bildungsbereich vorgestellt. Insgesamt möchten wir mit diesem Dossier betonen, dass die Entwicklungen von Recommendersystemen im Bildungsbereich nicht bloße mathematische oder datenwissenschaftliche Probleme darstellen, sondern immer auch didaktische Betrachtungen erfordern. Im Kern aller Neuentwicklungen sollte demnach stets die Frage stehen: warum und wofür sollten Recommendersysteme überhaupt eingesetzt werden? Wir haben versucht, mögliche Antworten auf diese Frage zu finden und abzuwägen.

Dabei fällt auf, dass sich gerade für die berufliche Aus- und Weiterbildung Forschung und Entwicklung noch ganz am Anfang befinden: Hier gibt es erst wenige abgeschlossene Vorhaben, die aufzeigen und auch evident belegen, welche Unterstützung ein Recommendersystem leisten kann. Dennoch zeichnet sich ab, dass in den kommenden Jahren gänzlich neue Einsatz- und Unterstützungsmöglichkeiten für Recommendersysteme auch und gerade in der beruflichen Bildung entstehen. Die Entwicklungen innerhalb des INVITE-Wettbewerbs werden im deutschen Raum sicherlich einen ganz erheblichen Anteil an diesen Entwicklungen haben.

5 Literaturverzeichnis

- Abdollahpouri, H., Adomavicius, G., Burke, R., Guy, I., Jannach, D., Kamishima, T., Krasno-debski, J. & Pizzato, L. (2020). Multistakeholder recommendation: Survey and research directions. *User Modeling and User-Adapted Interaction*, 30(1), 127–158. <https://doi.org/10.1007/s11257-019-09256-1>
- Abdollahpouri, H., Burke, R. & Mobasher, B. (2019, 22. Januar). *Managing Popularity Bias in Recommender Systems with Personalized Re-ranking*. <http://arxiv.org/pdf/1901.07555v4>
- Anderson, L. W. & Krathwohl, D. R. (2001). *A taxonomy for learning, teaching and assessing: A revision of Bloom's taxonomy of educational objectives*. Longman.
- Bennetot, A., Donadello, I., Qadi, A. E., Dragoni, M., Frossard, T., Wagner, B., Saranti, A., Tulli, S., Trocan, M., Chatila, R., Holzinger, A., Garcez, A. d. & Díaz-Rodríguez, N. (2021, 13. November). *A Practical Tutorial on Explainable AI Techniques*. <https://arxiv.org/pdf/2111.14260>
- Borowiec, T., Mettin, G. & Zöllner, M. (2018). *Checkliste Qualität beruflicher Weiterbildung* (4. Aufl.). Bundesinstitut für Berufsbildung.
- Burke, R. (2002). Hybrid Recommender Systems: Survey and Experiments. *User-Modeling und User-Adapted Interaction*(12), 331–370.
- Burke, R., Felfernig, A. & Göker, M. H. (2011). Recommender Systems: An Overview. *AI Magazine*, 32(3), 13–18.
- Carrera Rivera, A., Tapia-Leon, M. & Lujan-Mora, S. (2018). Recommendation Systems in Education: A Systematic Mapping Study. In Á. Rocha & T. Guarda (Hrsg.), *Advances in Intelligent Systems and Computing. Proceedings of the International Conference on Information Technology & Systems (ICITS 2018)* (Bd. 721, S. 937–947). Springer International Publishing. https://doi.org/10.1007/978-3-319-73450-7_89
- Dellermann, D., Ebel, P., Söllner, M. & Leimeister, J. M. (2019). Hybrid Intelligence. *Business & Information Systems Engineering*, 61(5), 637–643. <https://doi.org/10.1007/s12599-019-00595-2>
- Deschênes, M. (2020). Recommender systems to support learners' Agency in a Learning Context: a systematic review. *International Journal of Educational Technology in Higher Education*, 17(1). <https://doi.org/10.1186/s41239-020-00219-w>
- Drachler, H., Verbert, K., Santos, O. C. & Manouselis, N. (2015). Panorama of Recommender Systems to Support Learning. In F. Ricci, L. Rokach & B. Shapira (Hrsg.), *Recommender Systems Handbook* (S. 421–451). Springer US. https://doi.org/10.1007/978-1-4899-7637-6_12
- Europäische Kommission. (2021a). ESCO. <https://ec.europa.eu/esco/portal>
- Europäische Kommission. (2021b). *Vorschlag für eine Verordnung des Europäischen Parlaments und des Rates zur Festlegung harmonisierter Vorschriften für Künstliche Intelligenz (Gesetz über Künstliche Intelligenz) und zur Änderung bestimmter Rechtsakte der Union*. <https://eur-lex.europa.eu/legal-content/DE/TXT/?uri=CELEX:52021PC0206>
- Gábor Kismihók, Inês Gaspar, Joe Delaney, Mathias Schroißen, Mohammadreza Tavakoli, Abdolali Faraji, Hasan Abu-Rasheed, Stéphanie Gauttier, Stefan T. Mol, Christian Weber, Ana Raquel Santa Maria & Renaud B. Jolivet. (2022). *OSCAR Conceptual and Technical Framework for Researcher Well-being and Career Development Training and Mentoring*. Zenodo. <https://zenodo.org/record/5911816#.Yj26HzUxkuV> <https://doi.org/10.5281/zenodo.5911816>

- Guruge, D. B., Kadel, R. & Halder, S. J. (2021). The State of the Art in Methodologies of Course Recommender Systems—A Review of Recent Research. *Data*, 6(2), 18. <https://doi.org/10.3390/data6020018>
- Hao, K. (2019). *This is how AI bias really happens - and why it's so hard to fix*. <https://www.technologyreview.com/2019/02/04/137602/this-is-how-ai-bias-really-happens-and-why-its-so-hard-to-fix/>
- Kerres, M. & Buntins, K. (2020). Recommender in AI-enhanced Learning: An Assessment from the Perspective of Instructional Design. *Open Education Studies*, 2(1), 101–111. <https://doi.org/10.1515/edu-2020-0119>
- Knijnenburg, B. P. & Willemsen, M. C. (2015). Evaluating Recommender Systems with User Experiments. In F. Ricci, L. Rokach & B. Shapira (Hrsg.), *Recommender Systems Handbook* (S. 309–352). Springer US. https://doi.org/10.1007/978-1-4899-7637-6_9
- Krauβ, C. (2018). *Time-dependent recommender systems for the prediction of appropriate learning objects* [Doctoral Thesis]. Technische Universität Berlin, Berlin. <https://doi.org/10.14279/depositonce-7119>
- Leuphana Universität Lüneburg (2012). Qualitätsstandards und Transparenz in der Quartären Bildung: Orientierung in der berufsbegleitenden Weiterbildung und Handlungsempfehlungen für Bildungsakteure.
- Ma, B., Lu, M., Taniguchi, Y. & Konomi, S. (2021). CourseQ: the impact of visual and interactive course recommendation in university environments. *Research and practice in technology enhanced learning*, 16(1), 18. <https://doi.org/10.1186/s41039-021-00167-7>
- Manouselis, N., Drachsler, H., Verbert, K. & Duval, E. (2012). *Recommender systems for learning: An introduction*. Springer.
- Manouselis, N., Drachsler, H., Vuorikari, R., Hummel, H. & Koper, R. (2011). Recommender Systems in Technology Enhanced Learning. In F. Ricci, L. Rokach, B. Shapira & P. B. Kantor (Hrsg.), *Recommender Systems Handbook* (S. 387–415). Springer US. https://doi.org/10.1007/978-0-387-85820-3_12
- Ntoutsi, E., Fafalios, P., Gadiraju, U., Iosifidis, V., Nejdil, W., Vidal, M.-E., Ruggieri, S., Turini, F., Papadopoulos, S., Krasanakis, E., Kompatsiaris, I., Kinder-Kurlanda, K., Wagner, C., Karimi, F., Fernandez, M., Alani, H., Berendt, B., Kruegel, T., Heinze, C., . . . Staab, S. (2020). Bias in data-driven artificial intelligence systems—An introductory survey. *WIREs Data Mining and Knowledge Discovery*, 10(3). <https://doi.org/10.1002/widm.1356>
- Rajagopal, K., Bruggen, J. M. & Sloep, P. B. (2017). Recommending peers for learning: Matching on dissimilarity in interpretations to provoke breakdown. *British Journal of Educational Technology*, 48(2), 385–406. <https://doi.org/10.1111/bjet.12366>
- Saeed, W. & Omlin, C. (2021, 11. November). *Explainable AI (XAI): A Systematic Meta-Survey of Current Challenges and Future Opportunities*. <https://arxiv.org/pdf/2111.06420>
- Santos, O. C., Saneiro, M., Salmeron-Majadas, S. & Boticario, J. G. (2014). A Methodological Approach to Eliciting Affective Educational Recommendations. In *2014 IEEE 14th International Conference on Advanced Learning Technologies* (S. 529–533). IEEE. <https://doi.org/10.1109/ICALT.2014.234>
- Seyda, S. (2021). *Weiterbildung boomt in kleinen Unternehmen*. https://www.kofa.de/fileadmin/Dateiliste/Publikationen/KOFA_Kompakt/Weiterbildung.pdf
- Statistisches Bundesamt. (2021). *Unternehmen und abhängig Beschäftigte nach Wirtschaftsabschnitten 2019*. <https://www.destatis.de/DE/Themen/Branchen-Unternehmen/Unternehmen/Unternehmensregister/Tabellen/stat-unternehmen-beschaeftigten-groessenklassen-wz08.html>

- Tarus, J. K., Niu, Z. & Mustafa, G. (2018). Knowledge-based recommendation: a review of ontology-based recommender systems for e-learning. *Artificial Intelligence Review*, 50(1), 21–48. <https://doi.org/10.1007/s10462-017-9539-5>
- Thai-Nghe, N., Drumond, L., Tomáš Horváth, Artus Krohn-Grimberghe, Alexandros Nanopoulos & Lars Schmidt-Thieme. Factorization Techniques for Predicting Student Performance. In *Educational Recommender Systems and Technologies: Practices and Challenges* (S. 129–153). IGI Global. <https://doi.org/10.4018/978-1-61350-489-5.ch006>
- Vas, R., Weber, C. & Gkoumas, D. (2018). Implementing connectivism by semantic technologies for self-directed learning. *International Journal of Manpower*, 39(8), 1032–1046. <https://ideas.repec.org/a/eme/ijmpps/ijm-10-2018-0330.html>
- Verbert, K., Manouselis, N., Ochoa, X., Wolpers, M., Drachsler, H. & Bosnic, I. (2012). Context-aware recommender systems for learning: a survey and future challenges. *IEEE Transactions on Learning Technologies*, 5(4), 318–335. <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=6189308>
- Vygotsky, L. S. (1978). *Mind in Society: The Development of Higher Psychological Processes*. Harvard University Press.
- Wiedermann, W., Niggli, J. & Frick, U. (2014). The Lemming-effect: harm perception of psychotropic substances among music festival visitors. *Health, Risk & Society*, 16(4), 323–338. <https://doi.org/10.1080/13698575.2014.930817>
- Winoto, P., Tang, T. Y. & McCalla, G. (2012). Contexts in a paper recommendation system with collaborative filtering. *The international review of research in open and distance learning*, 13(5), 56–75.
- Zhang, Q., Lu, J. & Jin, Y. (2020). Artificial intelligence in recommender systems. *Complex & Intelligent Systems*, 7(1), 439–457. <https://doi.org/10.1007/s40747-020-00212-w>
- Zheng, Y., Ghane, N. & Sabouri, M. (2019). Personalized Educational Learning with Multi-Stakeholder Optimizations. In G. A. Papadopoulos, G. Samaras, S. Weibelzahl, D. Jannach & O. C. Santos (Hrsg.), *Adjunct Publication of the 27th Conference on User Modeling, Adaptation and Personalization - UMAP'19 Adjunct* (S. 283–289). ACM Press. <https://doi.org/10.1145/3314183.3323843>