

# MASTERARBEIT | MASTER'S THESIS

Titel | Title

KI in der Bildung - die soziale Repräsentation und Akzeptanz von KI-  
Sprachmodellen

verfasst von | submitted by

Julia Zacher BSc

angestrebter akademischer Grad | in partial fulfilment of the requirements for the degree of  
Master of Science (MSc)

Wien | Vienna, 2024

Studienkennzahl lt. Studienblatt |  
Degree programme code as it appears on the  
student record sheet:

UA 066 840

Studienrichtung lt. Studienblatt | Degree  
programme as it appears on the student  
record sheet:

Masterstudium Psychologie

Betreut von | Supervisor:

emer. Univ.-Prof. Mag. Dr. Dr. Christiane Spiel

## Inhalt

|                                                                          |    |
|--------------------------------------------------------------------------|----|
| Kurzzusammenfassung.....                                                 | 4  |
| Abstract .....                                                           | 5  |
| 1 Einleitung .....                                                       | 6  |
| 2 Theoretischer und empirischer Hintergrund.....                         | 7  |
| 2.1 KI-Sprachmodelle.....                                                | 7  |
| 2.2 Künstliche Intelligenz im Bildungskontext .....                      | 9  |
| 2.3 Technologieakzeptanz.....                                            | 10 |
| 2.4 Soziale Repräsentationen.....                                        | 12 |
| 2.5 Digitale Kompetenz als Prädiktor der Technologieakzeptanz .....      | 14 |
| 2.6 Hypothesen .....                                                     | 16 |
| 3 Methode.....                                                           | 18 |
| 3.1 Durchführung.....                                                    | 18 |
| 3.2 Erhebungsinstrumente .....                                           | 19 |
| 3.3 Soziale Repräsentationen zu KI-Sprachmodelle .....                   | 20 |
| <i>Lexikografische Analyse</i> .....                                     | 21 |
| 3.4 Datenanalyse.....                                                    | 23 |
| 3.5 Stichprobenbeschreibung.....                                         | 24 |
| 4 Ergebnisse .....                                                       | 25 |
| 4.1 Ergebnisse der statistischen Datenanalyse.....                       | 26 |
| 4.2 Ergebnisse der Lexikografischen Analyse.....                         | 28 |
| <i>Ergebnisse im Gruppenvergleich</i> .....                              | 30 |
| 5 Diskussion .....                                                       | 32 |
| 5.1 Diskussion der Datenanalyse.....                                     | 33 |
| 5.2 Diskussion der sozialen Repräsentationen von KI-Sprachmodellen ..... | 34 |
| 6 Limitationen .....                                                     | 38 |
| 7 Konklusion und Ausblick .....                                          | 39 |
| Literatur .....                                                          | 40 |

|                                                                                                                             |    |
|-----------------------------------------------------------------------------------------------------------------------------|----|
| Anhang .....                                                                                                                | 46 |
| Anhang A - Digitale Kompetenz (Quast et al., 2023).....                                                                     | 46 |
| Anhang B – Variablen des TAM (Deutsch) (Pletz & Zinn, 2021).....                                                            | 49 |
| Anhang C – Lexikografische Analyse der Lehrer:innen, die MINT-Fächer oder digitale<br>Grundbildung unterrichten .....       | 50 |
| Anhang D - Lexikografische Analyse der Lehrer:innen, die keine MINT-Fächer oder<br>digitale Grundbildung unterrichten ..... | 51 |
| Anhang E – Lexikografische Analyse der Lehrerinnen (Frauen).....                                                            | 52 |
| Anhang F – Lexikografische Analyse der Lehrer (Männer).....                                                                 | 53 |

## Kurzzusammenfassung

In der vorliegenden Studie wurde der Zusammenhang zwischen den Kernvariablen des *Technologieakzeptanzmodells* (TAM) (Davis, 1989), ein etabliertes Modell zur Beschreibung des Einflusses verschiedener Faktoren auf die Akzeptanz von Technologien, und digitaler Kompetenz in Bezug auf KI-Sprachmodellen von Lehrer:innen in Österreich untersucht. Zusätzlich wurden nach der *Theorie der Sozialen Repräsentationen* (Moscovici & Duveen, 2000), die inhaltlichen Assoziationen zu KI-Sprachmodellen der Stichprobe analysiert und visualisiert. 110 Personen zwischen 26 und 64 Jahren nahmen an der Online-Befragung teil. Die digitale Kompetenz wurde mit dem Instrument der *berufsbezogenen digitalen Kompetenzüberzeugungen* (Quast et al., 2023) gemessen. Die einzelnen Variablen des TAMs, wahrgenommene Nützlichkeit, wahrgenommene Benutzungsfreundlichkeit und Nutzungsintention von Technologien wurden auf KI-Sprachmodelle abgestimmt und anhand der Items des Technologieakzeptanzmodells (Venkatesh et al., 2003) ermittelt. Anschließend wurden die sozialen Repräsentationen mit der Methode der freien Assoziationen (Kulich et al., 2005) analysiert. Hierfür nannten Teilnehmende Begriffe, die sie mit KI-Sprachmodellen assoziieren und bewerteten diese anschließend auf einer Skala von positiv bis negativ. Die Bewertungen wurden pro Person berechnet und in einem sogenannten Polaritätsindex zusammengefasst. Die Ergebnisse der einfachen und multiplen linearen Regressionen zeigen konsistent zur Literatur, dass digitale Kompetenz, wahrgenommene Nützlichkeit und wahrgenommene Benutzungsfreundlichkeit korrelieren. Außerdem besteht eine positive Beziehung zwischen den drei Variablen und der Polarität von KI-Sprachmodellen. Die Polarität korreliert wiederum mit der Nutzungsintention. Zur Visualisierung der sozialen Repräsentation von KI-Sprachmodellen wurde eine lexikografische Analyse durchgeführt (Kulich et al., 2005), bei der insbesondere der Begriff *ChatGPT* herausstach.

*Stichwörter:* KI-Sprachmodelle, Lehrer:innen, digitale Kompetenz, Technologieakzeptanzmodel, Soziale Repräsentation

### Abstract

The current study investigated the relationship between the variables of the *technology acceptance model* (TAM) (Davis, 1989) and digital competence alongside teachers. Following the theory of social representations (Moscovici & Duveen, 2000), the associations were analyzed and visualized. 110 teachers in an age range from 26 to 64 years completed the online survey. *Digital competence* was measured with an inventory for job-related digital competences for teachers (Quast et al., 2023). The TAM variables, *perceived use*, *perceived ease of use* and *behavioral intention* were measured with the original inventory (Venkatesh et al., 2003) and the social representations were analyzed with the method of free associations (Kulich et al., 2005). Participants named associations related to the term *AI-language models* and rated them on a scale from positive to negative. The emotional evaluations summarized in a polarity index. The results of the single and multiple linear regressions indicated that digital competence, perceived ease of use and perceived use correlate. On top, these 3 variables are related to the polarity of the associations to AI-language models. Additionally, the polarity correlates with behavioral intention. To visualize the results of the associations, a lexicographic analysis was carried (Kulich, et al., 2005), in which the term *ChatGPT* was dominant.

*Keywords:* AI-language models, teachers, digital competence, technology acceptance model, social representation

## 1 Einleitung

In Österreich werden nach Bildungseinrichtung wie Kindergärten, Schulen oder Fachhochschulen unterschiedliche Bildungsaufträge definiert, die mit Besuch dieser Einrichtung erreicht werden sollten. In Bezug auf Schulen gibt das Bundesministerium für Bildung, Wissenschaft und Forschung auf ihrer Website vier Wirkungsziele der Schulbildung in Österreich vor: (1) die Erhöhung des Leistungs- und Bildungsniveaus der Schüler:innen sowie von Zielgruppen in der Erwachsenenbildung, (2) die Chancen- und Geschlechtergerechtigkeit im Bildungswesen, (3) die Steigerung der Effektivität und Effizienz in der Schulorganisation und Bildungsverwaltung und (4) die Verbesserung der Bedarfsorientierung. Die Erreichung des ersten Wirkungsziels, die *Erhöhung des Leistungs- und Bildungsniveaus der Schüler:innen*, erfordert die laufende Weiterentwicklung pädagogischer Konzepte, um bestmögliche Bildungs-, Entwicklungs- und Qualifizierungsmöglichkeiten für jedes Kind zu gewährleisten. Eine besondere Herausforderung stellt hier unter anderem die fortschreitende Digitalisierung dar (*Das österreichische Schulsystem*, o.D.).

Durch den gesellschaftlichen Wandel, den Digitalisierung mit sich bringt, ist es notwendig, dass Lehrer:innen mit den technologischen Entwicklungen und veränderten Informations- und Kommunikationswegen der Schüler:innen Schritt halten (Huwer et al., 2019). Eine aktuelle Veränderung im Zuge der Digitalisierung ist die Entwicklung von Modellen der künstlichen Intelligenz. Das Thema *künstliche Intelligenz (KI)*, mit all seinen Folgen, Vor- und Nachteilen, scheint spätestens mit der Veröffentlichung des Large Language Models ChatGPT am 30. November 2022 omnipräsent. Die Thematisierung in den Medien und der dadurch entstehende Diskurs hat erheblichen Einfluss auf die Bildung der Schüler:innen. Das Recherchieren und Verfassen von Texten verändert sich beinahe schlagartig. Hausaufgaben, die Schüler:innen durch intensive Recherche und der eigenständigen Formulierung von Argumenten ausarbeiten sollten, können nun mit Hilfe eines KI-Sprachmodells erarbeitet werden. Dafür wird die Aufgabenstellung, die Thematik und die benötigte Anzahl an Wörtern vorgegeben und die KI erledigt die Aufgabe binnen weniger Sekunden. Somit kann nicht mehr die eigene Leistung und Kreativität nach herkömmlicher Art beurteilt werden. Allerdings bietet KI neben diesen Herausforderungen auch viele Vorteile. Bei verantwortungsvoller Nutzung und den richtigen Befehlen, die man einer KI vorgibt, sogenannten Prompts, können beispielsweise Lehrpläne individualisiert und zu Denkanstößen und Inspiration verholfen werden. KI bietet sehr schnell viele Informationen und kann Sachverhalte auf Nachfrage wiederholt in einfacher Sprache erklären. Aus diesem

Grund ist es im Bildungskontext notwendig, dass vor allem Lehrer:innen diese neue Art der Technologie kennen und anzuwenden wissen sollten. Um sowohl Vorteile als auch Risiken von KI zu kennen, ist es essentiell sich detaillierter mit KI auseinanderzusetzen. Doch wie stehen Lehrkräfte zu dem Thema KI? Gibt es Kompetenzen, die die Haltung zu KI beeinflussen und wie stehen sie in Verbindung mit der Intention KI anzuwenden?

Die vorliegende Arbeit untersucht den Zusammenhang zwischen digitaler Kompetenz und den Variablen des etablierten Technologieakzeptanzmodells in Bezug auf KI. Gemäß dem Technologieakzeptanzmodell (TAM) (Davis, 1989) spielt die persönliche Haltung gegenüber verschiedenen Aspekten von Technologien eine zentrale Rolle bei der Bereitschaft von Personen, Technologie zu akzeptieren und somit zu nutzen. Hierbei beeinflussen die wahrgenommene Benutzungsfreundlichkeit und Nützlichkeit einer Technologie die Intention, diese anzuwenden. Das Technologieakzeptanzmodell ist ein empirisch erprobtes und weit verbreitetes Modell zur Erklärung der Absicht von Personen, Technologie zu nutzen (Antonietti et al., 2022). In vergangenen Studien wurde anhand des TAMs die Technologieakzeptanz bei Lehrkräften untersucht (Antonietti et al., 2022; Pletz & Zinn, 2021). Dabei wurde jedoch entweder Technologie im Allgemeinen (Antonietti et al., 2022) oder Virtual Reality in den Fokus genommen (Pletz & Zinn, 2021). In dieser Arbeit wird das Technologieakzeptanzmodell auf KI angepasst. Ziel ist es, mögliche Beziehungen und potenzielle Ursachen für geringe Integration von KI in den Unterricht aufzuzeigen. Dafür werden die Zusammenhänge der Variablen digitale Kompetenz, Nutzungsintention, wahrgenommene Benutzungsfreundlichkeit und wahrgenommene Nützlichkeit von künstlicher Intelligenz ermittelt. Da künstliche Intelligenz eine neue und komplexe Form der Technologie ist, wird die persönliche Bewertung von KI-Sprachmodellen durch eine qualitative Analyse untersucht. Dabei werden Lehrer:innen nach Worten gefragt, die sie mit KI assoziieren. Die Begriffe werden anschließend bewertet. Diese Analyse dient zur Visualisierung, wie Proband:innen KI emotional bewerten und welche Worte mit KI in Verbindung gebracht werden. Durch das freie Antwortformat bietet diese Methode unvoreingenommene Antworten und zusätzliche Informationen.

## **2 Theoretischer und empirischer Hintergrund**

### **2.1 KI-Sprachmodelle**

IBM definiert zwei grundlegende Arten von künstlicher Intelligenz (KI): starke KI und schwache KI. *Starke KI* (engl. strong AI) setzt sich aus künstlicher allgemeiner Intelligenz (engl. Artificial General Intelligence, AGI) und künstlicher Superintelligenz (engl. Artificial Super Intelligence, ASI) zusammen. Starke künstliche Intelligenz wird intensiv erforscht, ist

momentan allerdings noch theoretisch. *Schwache KI*, auch unter der englischen Bezeichnung *narrow AI* bekannt, ist hingegen fester Bestandteil des heutigen Alltags. Sie bezeichnet die Form von KI, welche spezifische Befehle und Aufgaben ausführt. Programme wie Siri, Alexa und Chatbots im Kundenservice vieler Unternehmen gehören zur Kategorie der schwachen KI (*Was ist künstliche Intelligenz?*, o.D.). Im Bereich der schwachen KI gibt es unterschiedliche Modellarten. Neben Programmen, die Bilder und Videos erzeugen können, gibt es auch künstliche Intelligenz-Modelle, die auf geschriebene Fragen oder Anweisungen Texte als Antworten generieren. Diese Arten von KI werden als *KI-Sprachmodelle* bezeichnet. Nutzer:innen formulieren sogenannte *Prompts* und fordern die KI damit auf, ihnen in Form von Texten zu antworten (Kullmann, 2023). KI-Sprachmodelle funktionieren mittels sogenanntem maschinellem Lernen, was bedeutet, dass sie durch die Verwendung von Nutzer:innen stetig anhand neuer Daten lernen und sich optimieren. Mittels Wahrscheinlichkeitsrechnungen wird ermittelt, mit welcher Wahrscheinlichkeit vor oder nach einem Wort ein bestimmtes anderes auftritt. Außerdem wird die Beziehung der Wörter untereinander bestimmt. Somit lernen KI-Sprachmodelle, wie Sätze in natürlicher Sprache formuliert und angeordnet werden. Eines der bekanntesten KI-Sprachmodelle ist momentan ChatGPT, aber auch DeepL und Grammarly sind im heutigen Alltag kaum noch wegzudenken. Zur Illustration ließ ich an meine recherchierten Erklärungen anschließend ChatGPT die Begriffe künstliche Intelligenz und KI-Sprachmodelle definieren.

*Julia Zacher: „Definiere mir Künstliche Intelligenz und KI-Sprachmodelle.“*

*ChatGPT: Natürlich, hier sind die Definitionen für "Künstliche Intelligenz" (KI) und "KI-Sprachmodelle": Künstliche Intelligenz (KI): Künstliche Intelligenz bezeichnet ein Feld der Informatik, das sich mit der Entwicklung von Systemen und Maschinen befasst, die Aufgaben ausführen können, die normalerweise menschliche Intelligenz erfordern würden. KI-Systeme können in der Lage sein, Muster zu erkennen, Schlussfolgerungen zu ziehen, Probleme zu lösen, zu lernen und zu kommunizieren. Das Ziel der KI ist es, Computer zu befähigen, menschenähnliche Fähigkeiten zu entwickeln und in bestimmten Aufgaben sogar menschenähnliche oder übermenschliche Leistungen zu erbringen. KI-Sprachmodelle: KI-Sprachmodelle sind spezielle Arten von KI-Systemen, die darauf trainiert sind, menschenähnliche Sprachfähigkeiten zu erlernen und anzuwenden. Diese Modelle verwenden komplexe Algorithmen und große Mengen an Textdaten, um natürliche Sprache zu verstehen, zu generieren und darauf zu reagieren. KI-Sprachmodelle können Texte verstehen, kontextbezogene Antworten generieren, Übersetzungen vornehmen, Texte*

*zusammenfassen, Fragen beantworten und vieles mehr. Sie sind darauf trainiert, natürliche Sprache in verschiedenen Kontexten zu verstehen und zu produzieren. Ein bekanntes Beispiel für ein KI-Sprachmodell ist OpenAI's GPT (Generative Pre-trained Transformer) -Reihe, zu der auch GPT-3 gehört, das größte und leistungsfähigste Modell seiner Art bislang.*

(ChatGPT, 2024)

## **2.2 Künstliche Intelligenz im Bildungskontext**

Die Bildungspsychologie versteht Bildung sowohl als Produkt, als auch als Prozess (Götz et al., 2018). Während Bildung als Produkt den Erwerb von Wissen und Kompetenzen beschreibt, inkludiert Bildung als Prozess die Entwicklungen, die diesen Erwerb beeinflussen können. Neben persönlichen Voraussetzungen, wie kognitive Fähigkeiten, sind dabei auch die Umweltbedingungen ausschlaggebend. Außerschulische Peergruppen und Medien gehören zu proximalen Umwelten und stellen in der Bildung einen wichtigen Faktor dar. Sie sind abhängig von sogenannten distalen Umwelten, gesellschaftlichen Rahmenbedingungen wie Politik, Wertekulturen, Bildungssystem und Wirtschaft (Götz et al., 2018). Da die Thematik der künstlichen Intelligenz in den Umwelten, wie Politik, Wirtschaft und Medien präsent ist, ist es essentiell, die Bedeutung von KI im Bildungssystem anzuerkennen. Schüler:innen sollten mit den Vor- und Nachteilen, Möglichkeiten und dem Umgang mit künstlicher Intelligenz auf neutraler, kompetenter Ebene vertraut gemacht werden. In Österreich wurde mit dem Schuljahr 2022/2023, wie auf der Website des österreichischen Bundesministeriums für Bildung, Wissenschaft und Forschung zu entnehmen ist, der Unterrichtsgegenstand digitale Grundbildung verpflichtend eingeführt, um digitale Technologien und deren kritischen Umgang im Unterricht zu lehren (*Digitale Grundbildung*, o.D.). In der Primarstufe wurden ebenfalls mit dem Schuljahr 2023/2024 digitale Grundkompetenzen in den Lehrplan eingebunden (*Medienbildung in der Volksschule*, 2024). Da die komplexe Thematik der KI vor allem ab der Sekundarstufe relevant scheint, wird im Folgenden von Lehrkräften und Schüler:innen ab der fünften Schulstufe gesprochen.

Neben dem Bildungssystem und anderen Umwelten stellt auch die persönlichen Voraussetzungen wie Motivation, Selbstkonzepte und Emotionen der Schüler:innen Grundlagen für erfolgreiche Bildung dar. Besonders Emotionen wie Ängste, beispielsweise durch Misserfolge aber auch Interesse oder Freude am Lernen stehen mit Lernleistung in Zusammenhang (Pekrun, 2018). Dieses Wissen über die Beziehung zwischen Emotionen und Lernleistung kann für erfolgreiche Bildung genutzt werden. Pekrun stellte 2018 beispielsweise fest, dass bei Schüler:innen Lernfreude entsteht, wenn sie sich kompetent

fühlen und das Lernmaterial für relevant betrachten. Durch die Integration von KI in den Unterricht ist es möglich, das Lernmaterial individuell gestalten und auf Bedürfnisse anpassen zu lassen. Die praxisnahe Anwendung von gesellschaftlich relevanten Tools vermittelt zudem Aktualität und macht Lerninhalte spannender, relevanter und abwechslungsreicher.

Doch um KI in der Unterricht einbeziehen zu können, müssen diverse Aspekte berücksichtigt werden. In einer Studie von 2016 zeigten Krumsvik und Kolleg:innen, dass das Integrieren von Technologien in den Unterricht von vielen Faktoren beeinflusst wird, die auf der Makro-, Meso- und Mikroebene interagieren. Auf der Makroebene können politische Rahmenbedingungen und das Bildungssystem den Einsatz von Technologien in Schulen durch die Bereitstellung von Ressourcen, wie Finanzierung und Weiterbildungen, unterstützen. Allerdings zeigen aktuelle Studien, dass die institutionelle Unterstützung nicht automatisch zu einem höheren Selbstvertrauen der Lehrkräfte bei der Nutzung von Technologie führt und somit oftmals den Einsatz von Technologien im Unterricht mindert (Scherer et al., 2021). Einzelne Schulen können auf der Mesoebene den Zugang zu digitalen Ressourcen und Infrastrukturen, wie Computern und Internetzugang zur Verfügung stellen. Dies sind zwar notwendige Voraussetzungen für den Technologieeinsatz, reichen allein jedoch nicht aus (Drossel & Eickelmann, 2017). Die Integration von Technologien in den Unterricht wird maßgeblich durch die Mikroebene beeinflusst, insbesondere durch die Überzeugungen, Einstellungen, Motivationen und Selbstwirksamkeit einzelner Lehrkräfte (Backfisch et al., 2021). Dass gewisse Überzeugungen von Lehrkräften eine maßgebliche Rolle bei der Nutzungsintention von Technologien darstellen, zeigt auch das Technologieakzeptanzmodell (TAM) (Davis, 1989). Laut diesem Modell spielen die wahrgenommene Nützlichkeit, Benutzungsfreundlichkeit und die persönliche Bewertung einer Technologie eine wichtige Rolle für die Absicht, eine Technologie zu nutzen. Im Folgenden wird das Technologieakzeptanzmodell und dessen Variablen detailliert erklärt.

## 2.3 Technologieakzeptanz

Davis (1989) entwickelte das *Technologieakzeptanzmodell (TAM; technology acceptance model)*, um das Verhalten von Personen gegenüber Technologien zu erklären (Marangunić & Granić, 2015). Das Modell wurde auf Grundlage der *Theorie des begründeten Verhaltens (TRA)* aufgebaut, die besagt, dass das menschliche Verhalten von der Einstellung einer Person zum Verhalten sowie ihren Überzeugungen abhängen. Dadurch ist das Verhalten eng mit Einstellungen und Überzeugungen verbunden (Ajzen & Fishbein, 1975). Das Technologieakzeptanzmodell besagt, dass die Einstellung zu einer Technologie und die Wahrnehmungen von Personen hinsichtlich der Benutzungsfreundlichkeit und Nützlichkeit

der Technologie, die wichtigsten Faktoren für die Vorhersage der Akzeptanz und Nutzungsintention einer Technologie sind (Antonietti et al., 2022). Das Modell wurde auf verschiedene Technologien in einer Vielzahl von Kontexten angewandt, jedoch sind die Ergebnisse nicht immer einheitlich. In verschiedenen Studien (siehe Scherer & Teo, 2019) wurden unterschiedliche Beziehungsmuster zwischen den TAM-Variablen und der Nutzungsabsicht gefunden. Es gibt mittlerweile mehrere Versionen des TAMs (Venkatesh & Davis, 2000; Venkatesh & Bala, 2008), die alle eine unterschiedliche Anzahl an Variablen in das Modell einschließen.

Im Allgemeinen beinhaltet das TAM folgende Kernvariablen. Anhand der Variable des *wahrgenommenen Nutzens (PU; perceived usefulness)* wird die subjektive Einschätzung einer Person, inwiefern die Anwendung einer Technologie ihre Arbeitsleistung verbessern würde, erfragt. *Wahrgenommene Benutzungsfreundlichkeit (PEU; perceived ease of use)* ermittelt, wie einfach und unkompliziert Personen die Anwendung der Technologie einschätzen. Dabei wird ermittelt, wie leicht es scheint, die Technologie zu erlernen, zu bedienen und damit zu interagieren. Die *Einstellung gegenüber der Technologie (ATT; attitude towards technology)* bestimmt die persönliche Bewertung der Technologie, welche von positiven oder negativen Gefühlen geprägt ist. Diese Einstellung kann auf persönlichen Erfahrungen, Vorurteilen, sozialem Einfluss und anderen Faktoren basieren und beeinflusst letztendlich die Bereitschaft einer Person, die Technologie zu akzeptieren und zu verwenden (Antonietti et al., 2022).

Im ursprünglichen TAM (Davis, 1989) wurde ein Einfluss von der wahrgenommenen Benutzungsfreundlichkeit auf den wahrgenommenen Nutzen festgestellt. Das bedeutet, dass eine Technologie umso nützlicher erschien, je einfacher sie zu bedienen war. Die Einstellung gegenüber der Technologie wurde gleichermaßen von wahrgenommenem Nutzen und wahrgenommener Benutzungsfreundlichkeit beeinflusst. Diese Einstellung wiederum beeinflusste die Absicht eine Technologie zu nutzen. In dieser Arbeit werde ich mich auf das Kernmodell des TAMs mit den vorstehenden und modellübergreifend vorkommenden Variablen beziehen.

Als Outcome wird in den meisten Versionen des TAM die *Nutzungsintention (BI; behavioral intention)* oder die tatsächliche *Nutzung (USE; technology use)* genannt, wobei sich die Nutzungsintention auf beabsichtigtes und die tatsächliche Nutzung auf beobachtbares Verhalten bezieht. Unter Berücksichtigung der Beziehungen innerhalb des Technologieakzeptanzmodells sagt die wahrgenommene Nützlichkeit neben der wahrgenommenen Benutzungsfreundlichkeit das beabsichtigte Verhalten über die Einstellung

zur Technologie signifikant voraus (Scherer et al., 2019). Aufgrund unterschiedlicher Ergebnisse wird die tatsächliche Nutzung in manchen Versionen des TAM nicht ermittelt. Bei Einbeziehung erweitert die Variable die Möglichkeiten, Schlussfolgerungen aus den Ergebnissen zu ziehen, die die Vorhersage der Nutzung über die Nutzungsabsichten betreffen (Scherer, 2019). Trotz dessen wurde in der vorliegenden Studie nicht die tatsächliche Nutzung, sondern die Nutzungsintention als Outcome festgelegt. Grund dafür ist einerseits das Untersuchungsdesign. Die Vorhersage, ob die Nutzungsintention zu der tatsächlichen Nutzung führt, lässt sich in einer Studie mit mehreren Befragungszeitpunkten bestimmen. Andererseits besteht die Möglichkeit, dass, durch die erst aufkommende Etablierung und die damit verbundene Unwissenheit über KI, Lehrer:innen KI bereits nutzen könnten, ohne dies aktiv zu wissen. KI ist in vielen alltäglichen Programmen, die verwendet werden, tätig. Im Gegensatz zur Ermittlung, wie viele Lehrkräfte KI momentan nutzen, untersucht diese Studie den Zusammenhang verschiedener Variablen und einer positiven Haltung zu KI. Für die Beantwortung der Fragestellung ist es deshalb ausreichend, als Outcome die Nutzungsintention von KI-Sprachmodellen festzulegen.

Wie zuvor erwähnt, beschreibt die Variable ATT des Technologieakzeptanzmodells die Einstellung von Personen zu einer Technologie. Auch diese Variable wird in ein paar Anwendungen des Technologieakzeptanzmodells nicht eingeschlossen (Venkatesh & Davis, 1996). Grund dafür war, dass die Einstellung den Einfluss von wahrgenommener Benutzungsfreundlichkeit und wahrgenommener Nützlichkeit von Technologien auf die Nutzungsintention nicht ausreichend medierte. Es gibt die Möglichkeit die Einstellung aus dem Modell zu entfernen und einen direkten Pfad zwischen wahrgenommener Benutzungsfreundlichkeit und wahrgenommener Nützlichkeit und Nutzungsintention zu untersuchen, jedoch bietet die Einbeziehung der Variable, vor allem bei einer neuen Technologie wie KI, wichtige Erkenntnisse. Eine Einstellung wird im Allgemeinen als eine generelle Bewertung eines Objektes, einer Person oder eines Ereignisses definiert (Eagly & Chaiken, 1993 zitiert nach Heddy et al., 2017). Eine Wertung von negativ bis positiv, auch Valenz genannt, findet auf individueller Ebene von Personen auf Basis sozial erworbenen Informationen statt (Moliner & Tafani, 1997). Laut den Autor:innen bestehen enge Zusammenhänge zwischen Einstellungsbildungen und sozialen Repräsentationen.

## 2.4 Soziale Repräsentationen

Die *Theorie der sozialen Repräsentationen (SRT)* wurde 1961 von Serge Moscovici aufgestellt (Andreouli & Chryssochoou, 2015). Soziale Repräsentationen werden als Gedankenkonstrukte und Ideen innerhalb eines Kollektivs, beispielsweise einer Kultur

beschrieben. Sie entstehen und verfestigen sich über die Zeit. Im Allgemeinen verbreiten Individuen durch Kommunikation ihre persönlichen Werte, Erfahrungen und Überzeugungen zu verschiedenen Themen (Andreouli & Chrysoschoou, 2015). Bei dem Auftreten eines komplexen oder neuen Objektes entsteht eine soziale Repräsentation durch persönliche Überlegungen und Werte aber auch durch Kommunikation mit anderen Individuen (Moliner, 1993, zitiert nach Moliner & Tafani, 1997). Im Laufe der Zeit verknüpfen sich Individuen mit verschiedenen sozialen Gruppen. In dieser Zeit übermitteln sie ihr Wissen, ihre Überzeugungen und ihre Werte und erwerben durch den Austausch neues Wissen. Durch das Teilen von Gedanken und Ideen zu Objekten, entsteht eine soziale Komponente. Gemäß der *Central Core*-Theorie (Abric, 1976, zitiert nach Moliner & Abric, 2015) lassen sich soziale Repräsentationen in Kern- und Peripherieelemente unterteilen. Die Kernelemente einer sozialen Repräsentation werden innerhalb einer Gruppe geteilt und sind relativ stabil. Die Peripherie hingegen umfasst individuelle Unterschiede. Die Assoziationen in den peripheren Bereichen sind heterogener und veränderbarer als die Kernelemente. Soziale Repräsentationen sind trotz ihres relativ stabilen Kerns mit der Zeit veränderbar, da Veränderungen in den peripheren Elementen mit der Zeit zu Veränderungen im Kern führen können.

Soziale Repräsentationen ermöglichen es, breite Informationen und Verbindungen zu erfassen und bieten somit mehr Information als herkömmliche Skalen. Bei neuen, noch unbekannten Inhalten ist es sinnvoll, ein weites Spektrum an Informationen einzuholen. Im Gegensatz zu strukturierten Interviews und Fragebögen werden soziale Repräsentationen mit Methoden untersucht, in denen Proband:innen frei antworten, indem sie spontane Assoziationen zu einem Stimulusbegriff hervorrufen. Diese Methode der empirischen Untersuchung wird freie Assoziationen genannt (Kulich et al., 2005). Freie Assoziationen zeigen oftmals unbewusste, automatisierte Antworten auf, die durch das spontane Abrufen meist befreit von politischer Korrektheit und sozialer Erwünschtheit sind (Moloney & Walker, 2007). Proband:innen haben die Möglichkeit, mithilfe der Angabe einer Valenz, also einer positiven bis negativen Bewertungsskala, die Assoziationen zu bewerten. Durch die daraus berechnete Polarität wird sichtbar, ob die genannte Assoziation eine negative, positive oder neutrale Bedeutung für die Proband:innen hat. Zusätzlich werden die Begriffe nach Bedeutung für die Assoziation hierarchisiert.

Diese Methode bietet die Möglichkeit, die persönliche Bewertung der teilnehmenden Lehrer:innen von KI zu ermitteln. Durch die Integration der sozialen Repräsentation als Variable im Technologieakzeptanzmodell werden Informationen über Zusammenhänge der

etablierten Variablen wahrgenommener Benutzungsfreundlichkeit und wahrgenommene Nützlichkeit zur Erklärung der Nutzungsabsicht von KI, gewonnen. Wie bereits erwähnt, wurde das Technologieakzeptanzmodell schon häufig mit zusätzlichen Variablen erweitert (Venkatesh & Davis, 2000; Venkatesh & Bala, 2008; Antonietti et al., 2022). 2008 entwickelten Venkatesh und Bala das Technologieakzeptanzmodell 3, indem sie Faktoren wie sozialen Einfluss als Prädiktor der wahrgenommenen Nützlichkeit und wahrgenommenen Benutzungsfreundlichkeit von Technologien definierten. Auch der Zusammenhang der digitalen Kompetenzen mit den Variablen wurde demonstriert (Antonietti et al., 2022). Digitale Kompetenzen sind eine Voraussetzung für professionelle und sachgemäße Nutzung von Technologien. Das Bayrische Forschungsinstitut für digitale Transformation definiert digitale Kompetenzen als Kenntnisse und Fähigkeiten, die für die Nutzung von Informations- und Kommunikationstechnologien sowie digitalen Medien erforderlich sind. Diese Kenntnisse und Fähigkeiten können per Definition bei der Bewältigung von Aufgaben, der Lösung von Problemen, Kommunikation, Verwaltung, Zusammenarbeit sowie der Erstellung von Inhalten angewendet werden (Markus et al., o.D.). Durch den ständigen Wandel, dem das Schulsystem ausgesetzt ist, wurden schon in vergangenen Jahren, passend zu den gesellschaftlichen Veränderungen und Weiterentwicklungen, digitale Medien in den Unterricht integriert. Noch vor dem Aufkommen der möglichen Integrierung von KI wurden beispielsweise Computer, statt in spezifischen Unterrichtsfächern wie Informatik, auch fachübergreifend und fachbezogen angewandt (Nattland & Kerres, 2006). Zusätzlich zu der technischen Ausstattung in Schulen ist es essenziell, auch bei betroffenen Personen, wie Lehrer:innen und Schüler:innen, eine kritische Anwendung zur sinnvollen Nutzung sicherzustellen (Nattland & Kerres, 2006).

## **2.5 Digitale Kompetenz als Prädiktor der Technologieakzeptanz**

Bei digitalen Kompetenzen im Bildungskontext sind für Lehrer:innen neben den allgemeinen technischen Fertigkeiten im Umgang mit technologischen Geräten und digitalen Ressourcen, auch spezifische Fertigkeiten relevant. Die pädagogische Dimension, Einstellung, Strategien und das Bewusstsein, die es Lehrpersonen ermöglichen, Technologie effektiv zur Erreichung von Lehr- und Lernzielen einzusetzen, zählen im Schulkontext zu digitaler Kompetenz dazu (Antonietti et al., 2022). Um digitale Medien kritisch reflektiert in den Unterricht einbringen zu können, ist es notwendig, dass Lehrer:innen über digitale Kompetenzen verfügen (Guggemos & Seufert, 2021). Die Autor:innen zeigten in ihrer Studie von 2021, dass technisches Wissen von Lehrpersonen mit dem Einsatz digitaler Medien im Unterricht zusammenhängt. Bereits 2012 stellten dies Wong und Kolleg:innen fest. Sie

demonstrierten, dass die von Lehrer:innen selbst eingeschätzte Fähigkeit, mit Computern zu unterrichten, ihre Einstellung und wahrgenommene Benutzungsfreundlichkeit und Nützlichkeit signifikant und positiv beeinflusst und einen indirekten positiven Effekt auf ihre Verhaltensabsicht zur Computernutzung hat. Die berufsbezogenen digitalen Kompetenzen von Lehrer:innen beeinflussten das berufliche Verhalten bei der Nutzung dieser Medien positiv. 2022 bekräftigten Antonietti und Kolleg:innen diese Ergebnisse, in dem sie zeigten, dass digitale Kompetenz als ein Prädiktor für die wahrgenommene Nützlichkeit und die wahrgenommene Benutzungsfreundlichkeit im TAM wirken kann. Um digitale Kompetenzen zu ermitteln, werden oftmals Personen zu ihren eigenen Einschätzungen über ihre Kompetenzen erfragt. Diese Kompetenzüberzeugungen beziehen sich auf die selbstbewerteten Fähigkeiten zur Nutzung digitaler Medien und können in allgemeine und berufsbezogene Überzeugungen unterteilt werden (Krumsvik, 2014).

Es existieren unterschiedliche Kompetenzrahmen, die die vielfältigen Facetten der digitalen Kompetenzen von Lehrkräften beschreiben (Zhao et al., 2021). Eines dieser ist der Europäische Rahmen für die *Digitale Kompetenz von Pädagog:innen (DigCompEdu)*. Das DigCompEdu definiert digitale Kompetenz als die Fähigkeit, Technologie sicher, kritisch und kreativ einzusetzen, um Lehr- und Lernziele zu bereichern (Redecker, 2017). Das Rahmenwerk identifiziert 22 spezifische, berufsbezogene, digitale Kompetenzen von Pädagog:innen, die in sechs Bereiche gegliedert sind: 1) berufliche Einbindung, 2) digitale Ressourcen, 3) Lehren und Lernen, 4) Bewertung, 5) Ermächtigung von Lernenden und 6) Förderung der digitalen Kompetenz von Lernenden. Mithilfe eines Selbstbewertungstools, das auf diesem Rahmenwerk basiert, können Lehrkräfte ihre eigenen digitalen Kompetenzen einschätzen. Das Tool bietet detailliertes Feedback zu individuellen Stärken und Schwächen und soll einen Reflexionsprozess zur beruflichen Weiterentwicklung fördern. Ein Vorteil dieses Instruments liegt in seiner spezifischen und praxisnahen Ausrichtung. Die Items beziehen sich auf konkrete Handlungen im Kontext der Technologienutzung in der Bildung und nicht auf allgemeine Fragen zur Selbstwirksamkeit bei der Verwendung von Technologie. Allerdings wird in diesem Selbstbewertungstool jede der 22 Kompetenzen lediglich durch ein einzelnes Element repräsentiert, und in einigen Fällen wurde nur eine von mehreren Kompetenzen aus jeder Kompetenzdimension ausgewählt. Im Bereich *digitale Ressourcen* wurde beispielsweise lediglich der Datenschutz bewertet, ohne jedoch die Anwendung von Urheberrechtsregeln oder die Bereitstellung digitaler Ressourcen für andere zu berücksichtigen (Ghomi & Redecker 2019).

Auf der Grundlage des DigCompEdu (Redecker, 2017) entwickelten Quast und

Kolleginnen (2023) ein Instrument zur Bewertung der berufsbezogenen digitalen Kompetenzüberzeugungen von Lehrkräften, angehenden Lehrkräften und Studienanfänger:innen. Statt den 22 Kompetenzen in sechs Bereichen (DigCompEdu), wurden bei Quast und Kolleginnen (2023) insgesamt 33 Items erstellt und bei der Stichprobe von Lehramtstudent:innen und Lehrer:innen aus Deutschland, Österreich und der Schweiz erhoben. Da manche ursprünglichen Kompetenzen so formuliert waren, dass sie mehr als eine Kompetenz ansprechen. Zur Validierung wurden diese Skalen explorativen und konfirmatorischen Faktoranalysen unterzogen und aufgrund schlechter Fit-Werte vier Items ausgeschlossen. Die Faktoranalysen zeigten außerdem, dass die Faktorenstruktur nicht für sechs Kompetenzbereiche, sondern für sieben spricht. Somit liefert dieses Instrument die Möglichkeit zur Bewertung berufsbezogener digitaler Kompetenzüberzeugungen mit 29 Items zugeordnet zu sieben Kompetenzdimensionen anstelle der sechs Dimensionen, die von Redecker (2017) definiert wurden. Die Dimensionen wurden benannt in 1) Verwaltung und berufliche Entwicklung, 2) Unterrichtsvorbereitung, 3) Unterrichten und Unterstützen von Schüler:innen, 4) Bewertung, 5) Befähigen aller Schüler:innen, 6) Förderung der digitalen Kompetenz der Schüler:innen und 7) Datenschutz und Urheberrechtsbestimmungen (Quast et al., 2023).

## 2.6 Hypothesen

Die Studienlage lässt darauf schließen, dass das Technologieakzeptanzmodell ein weit verbreitetes und etabliertes Modell zur Erklärung der Akzeptanz von Technologie ist. Es wurde vielfach für die Erklärung von Akzeptanz von Technologien im Allgemeinen (Venkatesh et al., 2003) aber auch spezielle Formen von Technologien, wie Virtual Reality (Pletz & Zinn, 2021) eingesetzt. In dieser Studie wird das Technologieakzeptanzmodell auf eine neue Art der Technologien angewandt: künstliche Intelligenz. Aufgrund der Vielfältigkeit von KI entschied ich mich dazu, dieses Themengebiet einzugrenzen. Diese Arbeit behandelt KI im Schulkontext und hierbei finden vor allem KI-Sprachmodelle ihre Anwendung. Somit werde ich mich in weiterer Folge auf KI-Sprachmodelle beschränken, jedoch alle Formen, egal ob ChatGPT, DeepL oder anderes, miteinbeziehen.

Gemäß dem Technologieakzeptanzmodell prädisieren drei relevante Variablen maßgeblich die Intention, eine Technologie zu nutzen: wahrgenommene Benutzungsfreundlichkeit, wahrgenommene Nützlichkeit und die Einstellung zu einer Technologie (Davis, 1989). Dabei beeinflusst die wahrgenommene Benutzungsfreundlichkeit den wahrgenommenen Nutzen einer Technologie. Beide Variablen haben einen Effekt auf die Einstellung zu einer Technologie und die Einstellung beeinflusst die Nutzungsabsicht. In

weiteren Studien wurden zusätzliche Prädiktoren, wie digitale Kompetenzen (Wong et al., 2012; Antonietti et al., 2022) auch bei einer Stichprobe von Lehrkräften (Antonietti et al., 2022) nachgewiesen. Aus dieser Ergebnislage ergeben sich folgende Hypothesen:

*H1: Die digitale Kompetenz (DK) hat einen positiven Einfluss auf die wahrgenommene Nützlichkeit (PU) der KI-Sprachmodelle.*

*H2: Die digitale Kompetenz (DK) hat einen positiven Einfluss auf die wahrgenommene Benutzungsfreundlichkeit (PEU) der KI-Sprachmodelle.*

*H3: Die wahrgenommene Benutzungsfreundlichkeit (PEU) hat einen positiven Einfluss auf die wahrgenommene Nützlichkeit (PU) der KI-Sprachmodelle.*

Aufgrund der Aktualität und Komplexität der KI-Sprachmodelle wurde die Methode der sozialen Repräsentationen als Einstellungsvariable im Technologieakzeptanzmodell ausgewählt. Dadurch, dass bei dieser Methode keine Auswahlmöglichkeit zum Antworten zur Verfügung steht, sondern Proband:innen frei nennen, welche Worte sie mit KI-Sprachmodellen verbinden, wird eine größere Bandbreite an Informationen gewonnen. Die Teilnehmenden bewerten im Anschluss ihre genannten Wortassoziationen von negativ bis positiv, wodurch eine Gesamtbewertung, die sogenannte Polarität, berechnet wird. Die vierte Hypothese vereint die vorigen Variablen und testet ihre Beziehung zu der Polarität von KI-Sprachmodellen:

*H4: Digitale Kompetenz (DK), wahrgenommene Nützlichkeit (PU) und wahrgenommene Benutzungsfreundlichkeit (PEU) haben einen direkten Effekt auf die Polarität der KI-Sprachmodelle.*

Obwohl in manchen Studien des Technologieakzeptanzmodells keine signifikante Beziehung zwischen der Einstellung und der Nutzungsintention festgestellt werden konnte (Masrom, 2007), konnte der Effekt in anderen belegt werden (Davis, 1989). Aufgrund der inkonsistenten Ergebnislage wird die fünfte Hypothese den Zusammenhang zwischen der Polarität und der Nutzungsintention von KI-Sprachmodellen abdecken:

*H5: Die Polarität der KI-Sprachmodelle korreliert positiv mit der Nutzungsintention (BI).*


Ein Ziel dieser Arbeit ist es, detailliertere Informationen über die soziale Repräsentation von KI-Sprachmodellen zu erhalten. Die Wortassoziationen werden somit sowohl in der Gesamtstichprobe als auch in verschiedenen Gruppenvergleichen beleuchtet. Somit können die Assoziationen der ausgewählten Gruppen hervorgehoben und gegenübergestellt werden. Verglichen werden einerseits Geschlechterunterschiede und andererseits MINT-Schulfächer (Mathematik, Informatik, Naturwissenschaften und Technik) und digitale Grundbildung mit den übrigen Unterrichtsgegenständen.

In vergangenen Studien wurden bereits Geschlechterunterschiede im Zugang zu Technologien festgestellt (Schumacher & Morahan-Martin, 2001). Ein Begriff, der diesen Kontrast beschreibt, ist *gender digital gap*. Gender digital gap beschreibt unterschiedliche Zugänge von Männern und Frauen in Entwicklung und Nutzung von Technologien (Lott, 2023). Um potenzielle Unterschiede in den sozialen Repräsentationen zu visualisieren, wird der Gruppenvergleich in Bezug auf Frauen und Männer durchgeführt.

Zusätzlich werden die Wortassoziationen von Lehrer:innen, die wissenschaftliche Schulfächer (MINT und/oder digitale Grundbildung) unterrichten, mit denen der Lehrkräfte der übrigen Unterrichtsfächer gegenübergestellt. Da die MINT-Fachgebiete, auch in der Berufswelt, mehr mit Technologien verbunden werden als Unterrichtsgegenstände wie Ethik und diverse Sprachen, soll veranschaulicht werden, ob die assoziierten Begriffe und ihre Bewertung sich in den beiden Gruppen unterscheiden.

### Abbildung 1

Grafische Darstellung der aufgestellten Hypothesen



*Anmerkung.* DK = digitale Kompetenz; PU = wahrgenommene Nützlichkeit; PEU = wahrgenommene Benutzungsfreundlichkeit; BI = Nutzungsintention

## 3 Methode

### 3.1 Durchführung

Die Daten wurden über die Online-Umfrageplattform SoSci-Survey erhoben. Die Datenerhebung fand in zwei Zeitfenstern statt. Der erste Durchlauf war von 3. November 2023 bis 15. Dezember 2023, der zweite wurde aufgrund unzureichender Stichprobengröße von 5. März bis 6. Mai 2024 durchgeführt. Teilnehmer:innen wurden mittels sozialer Medien, sowie durch das Bildungsministerium, dem Netzwerk „Teach for Austria“ und kontaktierten Schuldirektor:innen rekrutiert.

### 3.2 Erhebungsinstrumente

#### ***Digitale Kompetenz***

Die digitale Kompetenz wurde mit den 29 Items von Quast und Kolleginnen (2023) gemessen. Zwei Beispielitems sind *Wie kompetent fühlen Sie sich darin, digitale Medien im Unterricht zur Lernkontrolle und Leistungsbeurteilung zu verwenden?* und *Wie kompetent fühlen Sie sich darin, digitale Medien zu nutzen, um Schüler:innen im Unterricht gezielt Beratung und Unterstützung anzubieten?*. Die Items wurden auf einer 5-Punkte-Skala bewertet, die von 1 (gar nicht kompetent) bis 5 (sehr kompetent) reichte. Die vorliegende Analyse ergab ein Cronbachs Alpha von .96 und ein Omega von .96.

#### ***Wahrgenommene Benutzungsfreundlichkeit***

Die wahrgenommene Benutzungsfreundlichkeit wurde anhand der deutschen Übersetzung (Pletz & Zinn, 2021) der englischen Items des Technologieakzeptanzmodells (Venkatesh et al., 2003) erhoben. Die 4 Items wurden dahingehend angepasst, dass statt Begriffen wie Technologie oder VR der Begriff KI-Sprachmodelle abgefragt wurde. Zwei Beispielitems wären *Es wäre leicht für mich, die Bedienung von KI-Sprachmodellen zu erlernen* und *Der Umgang mit KI-Sprachmodellen wäre für mich klar und verständlich*. Auf einer 5-Punkte-Skala wurde von 1 (stimme gar nicht zu) bis 5 (stimme voll und ganz zu) angegeben, inwiefern Teilnehmer:innen den Aussagen zustimmen. In der Literatur wird ein Cronbach Alpha von .92 angegeben (Pletz & Zinn, 2021). Die vorliegende Analyse ergab ein Cronbachs Alpha von .93 und ein Omega von .94.

#### ***Wahrgenommene Nützlichkeit***

Die wahrgenommene Nützlichkeit wurde ebenfalls mit der deutschen Übersetzung (Pletz & Zinn, 2021) der englischen Originalitems von Venkatesh und Kollegen (2003) abgefragt und die Formulierung der einzelnen Items an die KI-Sprachmodelle angepasst (sechs Items; Beispielitems: *Durch die Nutzung von KI-Sprachmodellen könnte ich meine Aufgaben schneller erledigen*; *KI-Sprachmodelle wären nützlich für meine Arbeit*). Die Zustimmung der Lehrer:innen zu den sechs Aussagen wurde mittels einer 5-Punkte-Skala (1 = „stimme gar nicht zu“; 5 = „stimme voll und ganz zu“) ermittelt. Pletz und Zinn (2021) berichten ein Cronbachs Alpha von .92, die Untersuchung zeigt ein Cronbachs Alpha von .91 und ein Omega von .89.

#### ***Nutzungsintention***

Die Nutzungsintention von KI-Sprachmodell wurde mittels eines Items abgefragt: *Ich habe vor, KI-Sprachmodelle für meinen Unterricht zu verwenden*. Dieses Item wurde

ebenfalls aus der Studie von Pletz und Zinn (2021) bezogen und basiert auf den englischen Originalitems des TAM (Venkatesh et al., 2003). Die Formulierung wurde wieder an die Verwendung von KI-Sprachmodellen angepasst. Ursprünglich besteht die Skala der Nutzungsintention aus 3 Items. Da die zwei weiteren Items synonym zu dem ausgewählten formuliert waren, wurde auf sie verzichtet. Lehrkräfte gaben anhand einer 5-Punkte-Skala (1 = „stimme gar nicht zu“; 5 = „stimme voll und ganz zu“) an, wie sehr sie der Aussagen zustimmten. Die ursprüngliche Reliabilität aller Items wurde mittels eines Cronbachs Alpha von .91 berichtet (Pletz & Zinn, 2021).

### **3.3 Soziale Repräsentationen zu KI-Sprachmodelle**

Für die Ermittlung der sozialen Repräsentationen wurden die teilnehmenden Lehrer:innen nach Begriffen, die sie mit KI-Sprachmodellen verbinden, gefragt. Sie konnten drei bis 10 Wörter nennen und wurden aufgefordert nur einzelne Wörter in die vorgesehenen Zeilen zu schreiben. Diese genannten Begriffe dienen zur semantischen Auswertung.

Im nächsten Schritt konnten die Proband:innen ihre Begriffe auf einer 5-Punkte-Skala (rot (1) = „negativ“; orange (2) = „eher negativ“; gelb (3) = „neutral“; hellgrün (4) = „eher positiv“; dunkelgrün (5) = „positiv“) bewerten. Anhand dieser individuellen, von den teilnehmenden Personen gewählten Bewertungen der Begriffe wurden Polaritäts- und Neutralitätsindizes berechnet (Kirchler, 1998). Unter Polarität wird die entweder positive oder negative Bewertung verstanden und unter Neutralität das Verhältnis neutraler Bewertungen zur Gesamtanzahl an Bewertungen. Die Indizes werden auf Ebene der Assoziationen und auf der individuellen Ebene der Teilnehmenden berechnet. Der Polaritätsindex (PI) kann Werte zwischen -1 und +1 annehmen und ergibt sich aus der Differenz der positiv bewerteten und den negativ bewerteten Wörtern, dividiert durch die Häufigkeit einer Nennung. Auf der Ebene der Assoziationen wird ein Polaritätsindex zwischen -1 und +1 berechnet, der das Verhältnis von positiven und negativen Bewertungen einer Assoziation in der gesamten Stichprobe beschreibt. Im Gegensatz zu den Indizes, die sich auf die Assoziationen beziehen, wird der Polaritätsindex auf Ebene der Teilnehmer:innen differenzierter berechnet. Da die Lehrer:innen auf einer 5-Stufen-Skala ihre genannten Begriffe bewerten konnten, wurden die Bewertungen von der 1 bis 5 Skala (rot (1) = „negativ“ bis dunkelgrün (5) = „positiv“) in eine -1 bis +1 Skala in 0.5 Schritten umkodiert (-1 = „negativ“; -0.5 = „eher negativ“; 0 = „neutral“; +0.5 = „eher positiv“; +1 = „positiv“). Aus diesen Werten wurde die Summe gebildet und durch die Anzahl der genannten Assoziationen einer Person dividiert. Der Neutralitätsindex (NI) einer Assoziation kann Werte zwischen 0 und 1 annehmen und wird anhand einer Division der Häufigkeit einer neutralen Nennung mit der absoluten Häufigkeit einer Nennung berechnet.

Der Neutralitätsindex auf Teilnehmer:innenebene wurde anhand einer Division der Anzahl neutraler Nennungen einer Person durch die Anzahl der gesamten Nennungen dieser Person dividiert.

Auf der individuellen Ebene der Proband:innen definiert Polarität das Verhältnis von genannten negativen zu positiven Begriffen einer Person. Auch hier nimmt die Polarität Werte zwischen -1 und +1 an. Die persönliche Neutralität, auch zwischen 0 und 1 liegend, sagt aus wie das Verhältnis neutral bewerteter Begriffe zu der Anzahl an Nennungen einer Person steht. Mit den Messgrößen, die auf Ebene der Assoziationen erhoben wurden, wurde eine lexikografische Analyse (Kulich et al., 2005) durchgeführt. Die persönliche Polarität und Neutralität wurden für die statistische Analyse der Hypothesentestung herangezogen.

Im letzten Schritt dieser Analyse konnten die Proband:innen ihre genannten Begriffe neu einstufen. Dabei ging es darum, die Begriffe von Platz 1 bis maximal Platz 10 zu ordnen (1 = „wird am meisten mit KI-Sprachmodellen assoziiert“). Somit konnten die Personen ihre genannten Wörter so einreihen, dass der Begriff, der am meisten mit KI-Sprachmodellen verbunden wird, den ersten Platz bekommt. Das genannte Wort, das am wenigsten mit KI-Sprachmodellen in Verbindung gebracht wird, wird auf den letzten Platz eingestuft. Somit wird der sogenannte *Bedeutungsrang* bewusst vergeben. Würde dieser Schritt nicht in der Analyse durchgeführt werden, hätte man statt dem Bedeutungsrang nur die Informationen des Erscheinungsrangs. Der Erscheinungsrang spiegelt die spontane Verfügbarkeit von Begriffen wider. Statt den Begriff zu nennen, den Personen am meisten mit KI-Sprachmodellen verbinden, würde ein Begriff genannt werden, der beispielsweise kürzlich gehört, gesehen oder erinnert wurde und deswegen präsent ist. Der Bedeutungsrang eignet sich durch die bewusste Vergabe nach Wichtigkeit besser für die weiterführenden Analysen (Dany et al., 2015).

### ***Lexikografische Analyse***

Die 110 Lehrer:innen schrieben insgesamt 433 Assoziationen ( $M=5.99$ ;  $SD=2.187$ ) zu dem vorgegebenen Begriff *KI-Sprachmodelle* auf. Vor der lexikographischen Analyse der sozialen Repräsentationen, wurden die genannten Begriffe bereinigt. Dies beinhaltete die Korrektur von Rechtschreibfehlern, die Vereinheitlichung von Plural und Singular und die Umwandlung von Sätzen in einzelne Wörter. Teilweise wurden von Proband:innen Formulierungen, wie ‚Texte verfassen‘, ‚Texte schreiben‘ oder ‚Gedichte schreiben‘ genannt. Begriffe, die wie in diesem Beispiel etwas sehr Ähnliches aussagen, wurden in ein Wort, beispielsweise ‚Texterstellung‘ umgeschrieben. Diese Zusammenführungen zu einem Begriff wurden teilweise mit ChatGPT abgeglichen, um sicherzustellen, eine geeignete

Formulierung ausgewählt zu haben.

Die *lexikografische Analyse* (Kulich et al., 2005), wird zur Untersuchung und Visualisierung der genannten Wort-Assoziationen zu KI-Sprachmodellen verwendet. Die Methode orientiert sich an der Kern-Peripherie Analyse von Vergés (1992; 1994 in Kulich et al., 2005). Kulich et al. (2005) schlagen den Erwartungswert als Kriterium für die Auswahl der Assoziationen vor, die in die lexikografische Analyse einfließen sollen. Der Erwartungswert wird berechnet, indem die Gesamtzahl der Assoziationen durch die Anzahl der verschiedenen Assoziationen geteilt wird. Assoziationen, die mit einer Häufigkeit, die über dem Erwartungswert liegt, vorkommen, werden in die Analyse aufgenommen. Anschließend werden die Daten in ein Koordinatensystem übertragen, welches auf der x-Achse den relativen mittleren Rang und auf der y-Achse die relative Häufigkeit abbildet. Diese beiden Werte werden in der lexikografischen Analyse berechnet.

Die relative Häufigkeit einer Repräsentation wird ermittelt, indem die absolute Häufigkeit einer Assoziation  $F(A_i)$  durch die Stichprobengröße  $n$  geteilt wird. Sie wird auch als Auftrittswahrscheinlichkeit bezeichnet. Die relative Häufigkeit kann Werte zwischen 0 und 1 annehmen. Je höher der Wert ist, desto größer ist die Auftrittswahrscheinlichkeit eines Wortes. Die Häufigkeit assoziierter Wörter folgt dabei Zipf's Law (Zipf, 1935, zitiert nach Kulich et al., 2005). Zipf's Law besagt, dass die Wahrscheinlichkeit, mit der eine Assoziation auftritt, einem exponentiellen Rückgang unterliegt: nur eine geringe Anzahl von Wörtern wird häufig, die Mehrheit jedoch selten genannt.

Der zweite zu berechnende Wert ist der relative mittlere Rang. Da Proband:innen zwischen 3 und 10 Assoziationen nennen konnten, ist nicht jede Assoziationskette gleich lang. Aus diesem Grund ist es notwendig, dies in der Berechnung des Ranges einzubeziehen, da sich dadurch die Bedeutung des jeweiligen Ranges verändert. Im ersten Schritt wird der relative Rang  $r$  der Assoziation einer Person  $j$  berechnet:  $r_j(A_i)$ . Er wird ermittelt, indem man den absoluten Rang  $R_j(A_i)$  durch die Länge der Assoziationskette, also die Anzahl der genannten Assoziationen einer Person, dividiert. Die summierten individuellen mittleren Rangplätze der Assoziation dienen der Berechnung des Mittelwerts des relativen Rangplatzes einer Assoziation. Dazu werden sie durch die Anzahl der Nennungen der Assoziation dividiert. Der relative mittlere Rang kann Werte zwischen 0 und 1 annehmen. Ein niedriger Rang indiziert eine höhere Relevanz, da er sich näher am Stimuluswort (in diesem Fall KI-Sprachmodelle) befindet. Folglich lassen sich Assoziationen, die eine hohe Anzahl an hohen Rängen aufweisen, in der Nähe des Stimuluswortes lokalisieren.

Das vertikale Trennkriterium in dem Koordinatensystem zwischen früher und später

Nennung liegt in der Mitte der Skala, bei  $r(Ai) = .5$ . Das horizontale Trennkriterium zwischen selten und häufig liegt bei  $f(Ai) = .10$ . Assoziationen, die eine relative Häufigkeit über .10 haben, wurden von mindestens 10 % der Stichprobe genannt. Der hier angeführte Wert basiert auf der Studie von Kulich et al. (2005), in der festgestellt wurde, dass die Nennungshäufigkeit hinter dem 10%-Kriterium rapide abfällt. Im Durchschnitt werden lediglich etwa 10 Wörter von mehr als 10 % aller Teilnehmenden genannt. Das 10-Prozent-Kriterium erweist sich somit als besonders bedeutsam für die nachfolgende Analyse, wobei insbesondere auf Assoziationen oberhalb dieser Linie geachtet wird. Die beiden Trennkriterien bilden die Unterteilung des Koordinatensystems in Kern- und periphere Zonen (Abbildung 2). Nach der Kern-Peripherie-Analyse (Abric, 1976, zitiert nach Moliner & Abric, 2015) liegen somit im Kern des Koordinatensystems die Wörter, die von Personen früh und häufig genannt werden. Die anderen Begriffe werden je nach Werten in Subkategorien der Peripherie eingeteilt.

## Abbildung 2

Zonen der lexikographischen Analyse (Dany et al., 2015)

|                     |        | Relativ mittlerer Rang |                |
|---------------------|--------|------------------------|----------------|
|                     |        | früh                   | spät           |
| Relative Häufigkeit | häufig | Kern                   | Peripherie 1.1 |
|                     | selten | Peripherie 1.2         | Peripherie 2   |

## 3.4 Datenanalyse

Zunächst wurde die Stichprobe mit Hilfe der Software IBM SPSS Statistics 29 hinsichtlich ihrer deskriptiven Statistik analysiert. Zur Prüfung der Zusammenhänge zwischen digitaler Kompetenz und wahrgenommener Nützlichkeit (H1), digitaler Kompetenz und wahrgenommener Benutzungsfreundlichkeit (H2) und wahrgenommener Benutzungsfreundlichkeit und wahrgenommener Nützlichkeit (H3) wurden einfache Regressionen durchgeführt. Um die vierte Hypothese zu überprüfen, wurde eine multiple Regression gerechnet. Hierbei wurden digitale Kompetenz, wahrgenommene Benutzungsfreundlichkeit und wahrgenommene Nützlichkeit als Prädiktoren und die Polarität von KI-Sprachmodellen als Kriterium festgelegt. Der Zusammenhang von Polarität der KI-Sprachmodellen und Nutzungsintention (H5) wurde ebenfalls mittels einer einfachen linearen

Regression überprüft. Die sozialen Repräsentationen wurden anhand der lexikografischen Analyse beleuchtet.

### 3.5 Stichprobenbeschreibung

Die Online-Umfrage wurde von 152 Personen ausgefüllt. Nach Ausschluss von Personen, die die Umfrage unzureichend ausgefüllt hatten, sowie von Volksschullehrer:innen und Lehramtstudent:innen, die noch nicht als Lehrkraft arbeiten, wurde eine Stichprobe von 110 Personen für die Datenanalyse gewonnen. Die Studienteilnehmer:innen benötigten durchschnittlich 7.52 Minuten für das Ausfüllen des Fragebogens (SD = 2.22 Minuten).

55 der Teilnehmenden waren weiblich (50% der Gesamtstichprobe), 54 männlich (49.1% der Gesamtstichprobe), und 1 Person ohne Angabe (.9 % der Gesamtstichprobe). 100% (N=110) der Lehrer:innen kamen aus Österreich. Das Durchschnittsalter der Proband:innen betrug 45.61 Jahre (SD=10.55), wobei die jüngste Person 26 und die älteste 64 Jahre alt war. Die Mittelwerte der verwendeten Skalen befinden sich in Tabelle 1. Tabelle 2 veranschaulicht die Schultypen, in denen die befragten Lehrer:innen unterrichteten und Tabelle 3 demonstriert die unterrichteten Fächer. Tabelle 4 zeigt die Interkorrelationen zwischen den Skalen.

**Tabelle 1**

#### Deskriptivstatistik

|                    | <b>DK</b> | <b>PU</b> | <b>PEU</b> | <b>BI</b> | <b>Polarität</b> | <b>Neutralität</b> |
|--------------------|-----------|-----------|------------|-----------|------------------|--------------------|
| N                  | 110       | 110       | 110        | 109       | 109              | 110                |
| Fehlend            | 0         | 0         | 0          | 1         | 1                | 0                  |
| Mittelwert         | 3.99      | 3.09      | 4.07       | 3.18      | 0.26             | 0.23               |
| Median             | 4.03      | 3         | 4.25       | 4         | 0.25             | 0                  |
| Standardabweichung | 0.68      | 1.01      | 0.92       | 1.36      | 0.52             | 0.32               |
| Minimum            | 2.34      | 1         | 1          | 1         | -1               | 0                  |
| Maximum            | 5         | 5         | 5          | 5         | 1                | 1                  |

*Anmerkung.* DK = digitale Kompetenz; PU = wahrgenommene Nützlichkeit; PEU = wahrgenommene Benutzungsfreundlichkeit; BI = Nutzungsintention

**Tabelle 2**

Schultypen in der Gesamtstichprobe

| Schultyp                            | N  |
|-------------------------------------|----|
| Mittelschule                        | 13 |
| Sonderschule (inklusive Unterricht) | 4  |
| AHS                                 | 21 |
| Berufsschule                        | 13 |
| Berufsbildende mittlere Schulen     | 17 |
| Berufsbildende höhere Schulen       | 55 |
| Sonstiges                           | 5  |

**Tabelle 3**

Unterrichtsfächer in der Gesamtstichprobe

| Unterrichtete Fächer         | N  |
|------------------------------|----|
| Deutsch                      | 21 |
| Fremdsprachen                | 23 |
| MINT                         | 48 |
| Gesellschaftswissenschaften  | 16 |
| Musische Fächer              | 8  |
| Religion, Philosophie, Ethik | 10 |
| Sport                        | 11 |
| Digitale Grundbildung        | 16 |
| Sonstiges                    | 37 |

**Tabelle 4**

Korrelationsmatrix der Skalen

|           |             | DK     | PU     | PEU    | BI     | Polarität |
|-----------|-------------|--------|--------|--------|--------|-----------|
| DK        | Pearson's r | -      |        |        |        |           |
|           | p-Wert      | -      |        |        |        |           |
|           | N           | -      |        |        |        |           |
| PU        | Pearson's r | .206*  | -      |        |        |           |
|           | p-Wert      | .031   | -      |        |        |           |
|           | N           | 110    | -      |        |        |           |
| PEU       | Pearson's r | .513** | .334** | -      |        |           |
|           | p-Wert      | <.001  | <.001  | -      |        |           |
|           | N           | 110    | 110    | -      |        |           |
| BI        | Pearson's r | .268** | .606** | .436** | -      |           |
|           | p-Wert      | .005   | <.001  | <.001  | -      |           |
|           | N           | 109    | 109    | 109    | -      |           |
| Polarität | Pearson's r | .328** | .451** | .508** | .437** | -         |
|           | p-Wert      | <.001  | <.001  | <.001  | <.001  | -         |
|           | N           | 109    | 109    | 109    | 109    | -         |

Anmerkung. \*\* $\alpha \leq 0.01$ , \* $\alpha \leq 0.05$ ; DK = digitale Kompetenz, PU = wahrgenommene Nützlichkeit, PEU = wahrgenommene Benutzungsfreundlichkeit, BI = Nutzungsintention

## 4 Ergebnisse

Im Folgenden werden die Ergebnisse der Datenanalyse dargestellt. Zu Beginn werden die Ergebnisse der aufgestellten Hypothesen zur Prüfung der Zusammenhänge zwischen

digitaler Kompetenz und den Variablen des Technologieakzeptanzmodells berichtet. Hierbei wurden für die Prüfung der Beziehung zwischen digitaler Kompetenz und wahrgenommener Nützlichkeit (H1), digitaler Kompetenz und wahrgenommener Benutzungsfreundlichkeit (H2) und wahrgenommener Benutzungsfreundlichkeit und wahrgenommener Nützlichkeit (H3) einfache Regressionen gerechnet. Die Ermittlung eines Zusammenhangs zwischen den Prädiktoren digitale Kompetenz, wahrgenommene Benutzungsfreundlichkeit und wahrgenommene Nützlichkeit als Prädiktoren und dem Kriterium Polarität von KI-Sprachmodellen (H4) wurde mittels einer multiplen Regression durchgeführt. Die Beziehung von Polarität der KI-Sprachmodellen und Nutzungsintention (H5) wurde ebenfalls mit Hilfe einer einfachen linearen Regression überprüft. Anschließend werden die Ergebnisse der lexikografischen Analyse der sozialen Repräsentationen berichtet.

#### 4.1 Ergebnisse der statistischen Datenanalyse

Alle fünf Hypothesentestungen wurden mittels dem Statistik Programm SPSS Statistics 29 durchgeführt. Die Voraussetzungsprüfungen zu Ausreißern, Annahmen der Linearität und Homoskedastizität wurden getätigt und zeigten keine kritischen Verletzungen.

Die ersten drei Hypothesen wurden mittels einfacher linearer Regressionen berechnet. Hierbei wurde der Zusammenhang einzelner Variablen ermittelt.

Die erste Hypothese postulierte einen Zusammenhang der Variable der digitalen Kompetenz und wahrgenommener Nützlichkeit von KI-Sprachmodellen. Aus diesem Grund wurde die Variable digitale Kompetenz (DK) als UV und die Variable wahrgenommene Nützlichkeit (PU) als AV festgelegt. Das Modell zeigte mit einem  $R^2 = .04$  (korrigiertes  $R^2 = .03$ ) eine geringe Anpassungsgüte (Cohen, 1988). Der Prädiktor DK steht der AV wahrgenommene Nützlichkeit mit einer statistischen Signifikanz von  $p = .031$  die in Zusammenhang,  $F(1,108) = 4,765$ ,  $p < .05$ .

Anhand der zweiten Hypothese wurde die Beziehung der Variablen digitale Kompetenz und wahrgenommene Benutzungsfreundlichkeit von KI-Sprachmodellen untersucht. Als Prädiktor wurde digitale Kompetenz (DK) und als AV wahrgenommene Benutzungsfreundlichkeit (PEU) bestimmt. Die Regression zeigt, dass DK statistisch signifikant PEU voraussagt ( $p < .001$ ). Mit einem  $R^2 = .26$  (korrigiertes  $R^2 = .26$ ) zeigt das Modell eine hohe Anpassung (Cohen, 1988).

Die dritte Hypothese wurde ebenfalls mit einer einfachen linearen Regression überprüft. Da der Zusammenhang der wahrgenommenen Benutzungsfreundlichkeit und der wahrgenommenen Nützlichkeit von KI-Sprachmodellen getestet wurde, wurde als UV die wahrgenommene Benutzungsfreundlichkeit (PEU) und als AV die wahrgenommene

Nützlichkeit (PU) festgelegt. Mit einem  $R^2 = .11$  (korrigiertes  $R^2 = .10$ ) zeigt das Modell eine geringe bis mittlere Anpassungsgüte (Cohen, 1988). PEU steht statistisch signifikant mit dem Kriterium PU in Beziehung,  $F(1,108) = 13,55$ ,  $p < .001$ .

Um die vierte Hypothese zu testen, wurde eine multiple lineare Regression durchgeführt. Die Beziehung mehrerer Variablen, digitale Kompetenz, wahrgenommene Nützlichkeit und wahrgenommene Benutzungsfreundlichkeit mit der Variable der Polarität wurde ermittelt. Digitale Kompetenz (DK), wahrgenommene Nützlichkeit (PU) und wahrgenommene Benutzungsfreundlichkeit (PEU) wurden als UVs und die Polarität der KI-Sprachmodellen als AV festgelegt. Das Modell erwies mit einem korrigierten  $R^2 = .33$  eine hohe Anpassungsgüte (Cohen, 1988). Einzeln betrachtet waren die Pfade der Prädiktoren wahrgenommene Benutzungsfreundlichkeit (PEU) und wahrgenommene Nützlichkeit (PU) im Regressionsmodell auf die AV Polarität statistisch signifikant ( $p < .001$ ). Der Pfad von digitaler Kompetenz (DK) zeigte sich als einzelner Koeffizient nicht signifikant ( $p = .406$ ) (Tabelle 5).

## Tabelle 5

Ergebnistabelle der multiplen Regressionsanalyse

| Kriterium: Polaritätsindex |       |      |         |       |      |        |       |
|----------------------------|-------|------|---------|-------|------|--------|-------|
| Prädiktoren                | b     | SE   | $\beta$ | T     | p    | 95% KI |       |
|                            |       |      |         |       |      | UG     | OG    |
| (Konstante)                | -1.30 | 0.26 |         | -5.04 | 0.00 | -1.81  | -0.79 |
| DK                         | 0.06  | 0.07 | 0.08    | 0.83  | 0.41 | -0.08  | 0.2   |
| PEU                        | 0.20  | 0.05 | 0.36    | 3.81  | 0.00 | 0.1    | 0.31  |
| PU                         | 0.16  | 0.04 | 0.31    | 3.75  | 0.00 | 0.08   | 0.24  |

Anmerkungen.  $N = 109$ ;  $R^2 = 0.351$ ; korr.  $R^2 = 0.333$ ;  $F(3,105) = 18,936$ ;  $p < 0.001$

Die fünfte Hypothese, bei der der Zusammenhang zwischen der Polarität und Nutzungsintention von KI-Sprachmodellen aufgezeigt werden sollte, wurde mittels einfacher linearer Regressionen durchgeführt. Es wurde die Variable Polarität als UV und die Variable Nutzungsintention (BI) als AV festgelegt. Das Modell hat mit einem  $R^2 = .19$  (korrigiertes  $R^2 = .18$ ) eine mittlere Anpassungsgüte (Cohen, 1988). Der Prädiktor Polaritätsindex sagt statistisch signifikant das Kriterium Nutzungsintention (BI) voraus,  $F(1,106) = 25,017$ ,  $p < .001$ .

## 4.2 Ergebnisse der Lexikografischen Analyse

Die Bereinigung der 434 Assoziationen ergab eine Gesamtzahl an 205 unterschiedlichen Begriffen der 110 teilnehmenden Personen. Der errechnete Erwartungswert lag bei 2.117 ( $\approx 2$ ), woraus folgt, dass alle Assoziationen, die mindestens zwei Mal genannt wurden, in die lexikografische Analyse miteinbezogen wurden. Dies traf auf 66 verschiedene Assoziationen zu, die insgesamt 294 Mal genannt wurden. Von diesen 294 Nennungen wurden 172 (58.5%) positiv, 60 (20.41%) negativ, und 62 (21.09%) neutral bewertet. Daraus ergab sich ein Polaritätsindex (PI) von .31 und ein Neutralitätsindex (NI) von .23 für die gesamte soziale Repräsentation. Da der Polaritätsindex Werte zwischen -1 und +1 annehmen kann, kann man bei einem Wert von .31 eine allgemein positive Bewertung der sozialen Repräsentation von KI-Sprachmodellen sehen. Der Neutralitätsindex, der zwischen 0 und 1 liegen kann, zeigt, dass circa 23% der Assoziationen als neutral bewertet wurden.


Die 66 unterschiedlichen Begriffe wurden in einem Koordinatensystem visualisiert, bei welchem auf der X-Achse der relative mittlere Rang und auf der Y-Achse die relative Häufigkeit angezeigt wird. Je höher der Wert der relativen Häufigkeit, desto öfter wurde ein Begriff in der Stichprobe genannt. Je näher der relative mittlere Rang an null ist, desto näher ist die Assoziation an dem Stimulus Wort *KI-Sprachmodelle*. Anders als bei der relativen Häufigkeit drücken hier kleine Werte eine größere Relevanz aus.

In Abbildung 3 sind die genannten Begriffe der Gesamtstichprobe zu dem Stimulus Begriff *KI-Sprachmodelle* in einem Koordinatensystem abgebildet. Die nach Kulich und Kolleg:innen (2005) definierte 10%-Trennlinie wurde hervorgehoben. Da lediglich 4 Begriffe über dieser Linie liegen, wurde zusätzlich die 5%-Trennlinie abgebildet. In Abbildung 4 werden die Assoziationen über dem 5%-Kriterium visualisiert. Der einzige Begriff der in der Gesamtstichprobe in der Kernzone (Dany et al., 2015) liegt, ist der Begriff *ChatGPT* mit einem PI von .70 und einem NI von .30. Das bedeutet, dass der Begriff über dem vertikalen Trennkriterium  $r(A_i) = .5$  des Koordinatensystems, das die Begriffe nach früher und später Nennung einordnet, liegt. Zusätzlich befindet sich der Begriff *ChatGPT* ebenfalls über dem horizontalen Trennkriterium  $f(A_i) = .10$ . Dieses Kriterium unterteilt das Koordinatensystem in selten und häufig genannte Assoziationen. Begriffe, die eine relative Häufigkeit über .10 haben, wurden von mindestens 10 % der Stichprobe genannt. Über der 10%-Trennlinie liegen in der Gesamtstichprobe sonst nur drei weitere Wörter: *Texterstellung*, *Übersetzungen* und *Unterstützung*. Diese Begriffe weisen zwar eine relative Häufigkeit von über 10% auf, allerdings ist der berechnete relative mittlere Rang größer als .5, womit sie in der peripheren Zone (Peripherie 1.1) des Koordinatensystems einzuordnen sind. In der Peripherie 1.2

befinden sich Wörter, die eine relative Häufigkeit von unter 10%, dafür einen relativ mittleren Rang von weniger als .5 aufweisen. In diese Zone werden die Begriffe Recherche, Zukunft, LLM und schummeln eingeordnet. Deutlich zu sehen ist, dass die Mehrheit der genannten Begriffe eine geringere relative Häufigkeit als 5% aufweisen. Die meisten Begriffe befinden sich unter der .05-Linie und liegen somit in der Peripherie.


### Abbildung 3

Assoziationen zu KI-Sprachmodellen der Gesamtstichprobe



## Abbildung 4

Assoziationen zu KI-Sprachmodellen der Gesamtstichprobe über der 5%-Häufigkeitsgrenze



## Ergebnisse im Gruppenvergleich

### MINT vs. kein MINT

Von den 110 teilnehmenden Personen unterrichten 57 ein MINT-Fach oder digitale Grundbildung (Gruppe 1). 53 Lehrer:innen unterrichten keines der beiden Fächer (Gruppe 2). Für beide Gruppen wurde eine lexikografische Analyse durchgeführt. In Gruppe 1 lag die Anzahl an Nennungen bei 235 und es wurden 154 verschiedene Assoziationen genannt. Der Erwartungswert lag bei 1.53 ( $\approx 2$ ) und es befanden sich 40 verschiedene Assoziationen über diesem Wert. In Gruppe 2 lag die Anzahl der Nennungen bei 198 in 99 verschiedene Assoziationskategorien. 35 verschiedene Assoziationen lagen über dem Erwartungswert 2.


In Abbildung 5 sind alle Begriffe aus Gruppe 1 (MINT oder digitale Grundbildung, kurz: MINT) und Gruppe 2 (kein MINT und keine digitale Grundbildung, kurz: kein MINT) abgebildet, die sich über dem 10%-Trennkriterium befinden.

In Gruppe 1 (MINT) liegen 3 Begriffe über dem 10%-Trennkriterium. Besonders relevant sind die Begriffe ChatGPT und Texterstellung, da diese im linken Quadranten liegen, und somit einen relativen mittleren Rang von unter .5 haben. Der Polaritätsindex bei Gruppe 1 liegt bei  $PI = .40$  und der Neutralitätsindex bei  $NI = .23$ . In Gruppe 2 (kein MINT) liegen 7 Begriffe über dem Trennkriterium. Die Begriffe ChatGPT, Recherche und Zukunft

liegen im linken Quadranten. Der Polaritätsindex bei Gruppe 2 liegt bei  $PI = .21$  und der Neutralitätsindex bei  $NI = .23$ . Zum Vergleich der Polarität beider Gruppen wurde explorativ ein Mann-Whitney-U-Test durchgeführt. Das Ergebnis war nicht signifikant:  $U=1282$ ,  $Z = -1.39$ ,  $p = .163$ .

### Abbildung 5

Assoziationen im Gruppenvergleich MINT



### Geschlecht


55 der 110 Personen waren weiblich, 54 männlich und eine Person machte keine Angabe zu ihrem Geschlecht. Um mögliche Geschlechtsunterschiede in den Assoziationen zu KI-Sprachmodellen darzustellen, wurden 2 Gruppen gebildet: Frauen und Männer. Für beide Gruppen wurde eine lexikografische Analyse durchgeführt. In Gruppe 1 (Frauen) lag die Anzahl an Nennungen bei 211 und es wurden 116 verschiedene Assoziationen genannt. Der Erwartungswert lag bei 1.82 ( $\approx 2$ ) und es lagen 35 verschiedene Assoziationen über diesem Wert. In Gruppe 2 (Männer) lag die Anzahl der Nennungen bei 221, wobei 134 unterschiedliche Assoziationen waren. Der Erwartungswert lag bei 1.65 ( $\approx 2$ ) und es befanden sich 35 verschiedene Assoziationen über diesem Wert. In Abbildung 6 sind alle Begriffe aus Gruppe 1 (Frauen) und Gruppe 2 (Männer) abgebildet, die sich über dem 10%-Trennkriterium befinden.

In Gruppe 1 (Frauen) liegen 6 Begriffe über dem 10%-Trennkriterium. Besonders relevant sind die Begriffe ChatGPT und Zukunft, da diese im linken Quadranten liegen, und

somit einen relativen mittleren Rang von unter .5 haben. Der Polaritätsindex bei Gruppe 1 liegt bei  $PI = .29$  und der Neutralitätsindex bei  $NI = .21$ . In Gruppe 2 (Männer) liegen 5 Begriffe über dem Trennkriterium. Die Begriffe ChatGPT, Recherche und LLM liegen im linken Quadranten. Der Polaritätsindex bei Gruppe 2 liegt bei  $PI = .33$  und der Neutralitätsindex bei  $NI = .23$ . Der Mann-Whitney-U-Test zeigt im explorativen Vergleich keinen signifikanten Unterschied:  $U=1440$ ,  $Z = -.29$ ,  $p = .781$ .

### Abbildung 6

#### Assoziationen im Gruppenvergleich Geschlecht



## 5 Diskussion

In der vorliegenden Studie wurden die sozialen Repräsentationen zu KI-Sprachmodellen und möglichen Prädiktoren von ebendiesen bei Lehrer:innen untersucht. Anhand der lexikografischen Analyse wurden die Wort-Assoziationen visualisiert. Der Zusammenhang der Variablen digitale Kompetenz, wahrgenommene Benutzungsfreundlichkeit, wahrgenommene Nützlichkeit und Nutzungsintention mit den Assoziationen zu KI-Sprachmodellen wurde überprüft. Die Ergebnisse der Analysen werden in den folgenden Absätzen diskutiert.

## 5.1 Diskussion der Datenanalyse

Das Ziel der vorliegenden Studie war es, den Zusammenhang zwischen digitalen Kompetenzen, den TAM-Variablen und den sozialen Repräsentationen von KI-Sprachmodellen zu untersuchen. Die erwartete positive und signifikante Beziehung zwischen digitalen Kompetenzen und wahrgenommener Nützlichkeit (H1) wurde gezeigt. In früheren Studien wurde der Zusammenhang zwischen den beiden Variablen marginal festgestellt (Antonietti et al., 2022). In der vorliegenden Studie konnte die Beziehung ebenfalls mit einem geringen Effekt nachgewiesen werden. Der Zusammenhang zwischen digitaler Kompetenz und wahrgenommener Benutzungsfreundlichkeit (H2) wurde ebenfalls überprüft und konnte, konsistent mit der Literatur (Antonietti et al., 2022) mit einem großen Effekt nachgewiesen werden. Das bedeutet, dass Personen, die sich selbst als digital kompetenter einschätzen, KI-Sprachmodelle als einfacher zu nutzen wahrnehmen. Dies entspricht der Definition von digitaler Kompetenz, die sie als Basis für die Nutzung von Technologien beschreibt (Markus et al., o.D.). Je sicherer man sich in der Handhabung digitaler Medien fühlt, desto einfacher findet man es, sie zu nutzen.

Der Zusammenhang zwischen wahrgenommener Benutzungsfreundlichkeit und wahrgenommener Nützlichkeit (H3) wurde in vergangenen Studien sowohl bezüglich Technologien im Allgemeinen als auch Virtual Reality gezeigt (Pletz & Zinn, 2021; Antonietti et al., 2022). Auch in dieser Studie konnte die Beziehung der beiden Variablen, bezogen auf KI-Sprachmodelle, statistisch signifikant nachgewiesen werden. Lehrer:innen, die ein KI-Sprachmodell, beispielsweise ChatGPT, angenehm und einfach zu benutzen finden, empfinden dieses Sprachmodell auch als nützlicher. In der Praxis lässt sich das insofern argumentieren, als, dass ein neues Medium, das sehr kompliziert in der Anwendung ist, keine Arbeitserleichterung darstellt und sich somit auch kein Mehrwert in der Nutzung zeigt. Es scheint, als würde die erlebte Kosten-Nutzen-Rechnung nicht aufgehen und die Kosten (das Erlernen der Handhabung der Technologie) den Nutzen (potenzielle Arbeitserleichterung) nicht rechtfertigen. Somit werden Technologien, die einfach in der Handhabung sind, bevorzugt.

Ein zentrales Ziel der Studie war es, die Beziehung zwischen digitaler Kompetenz, wahrgenommener Benutzungsfreundlichkeit, wahrgenommener Nützlichkeit und den geteilten Vorstellungen zu KI-Sprachmodellen (H4) darzulegen. Das Modell zeigte sich statistisch signifikant, was bedeutet, dass die drei Variablen sehr stark mit der Polarität der Assoziationen zusammenhängen. Im Einzelnen wurde deutlich, dass wahrgenommene Benutzungsfreundlichkeit und wahrgenommene Nützlichkeit von KI-Sprachmodellen hoch

signifikant mit der Polarität einhergehen. Entgegen Studien, die die Variable der Einstellung aufgrund unzureichender Signifikanz ausschlossen (Venkatesh & Davis, 1996), impliziert das Ergebnis dieser Studie, dass, Lehrer:innen ihre mit KI-Sprachmodellen assoziierten Begriffe positiver bewerteten, je nützlicher und einfacher ein KI-Sprachmodell zu nutzen empfunden wird. Die Variable der digitalen Kompetenz war in dieser Testung nicht signifikant. Auch in einer explorativen Untersuchung mit schrittweisem Einschluss einer multiplen linearen Regression wurde die digitale Kompetenz nicht aufgenommen. Um in das Modell eingeschlossen zu werden, korrelierte es zu wenig mit der Polarität der KI-Sprachmodellen. In weiterer Folge bedeutet dies, dass nicht gezeigt werden konnte, dass Lehrer:innen, die sich als digital kompetenter einschätzen, positiverer Begriffe in Verbindung zu KI-Sprachmodellen nennen. In einer vorigen Hypothesentestung konnte demonstriert werden, dass digitale Kompetenz stark mit wahrgenommener Benutzungsfreundlichkeit zusammenhängt. Auch besteht eine Beziehung zwischen digitaler Kompetenz und wahrgenommener Nützlichkeit. Diese Ergebnisse zeigen, dass digitale Kompetenz keinen direkten, aber dafür einen indirekten Effekt auf die Polarität von KI-Sprachmodellen hat und die Variable vor allem in wahrgenommener Benutzungsfreundlichkeit abgebildet ist. Folglich empfinden Lehrkräfte, die sich digital kompetenter einschätzen, KI-Sprachmodelle einfacher zu nutzen. Zusätzlich zeigt sich, dass sie umso positivere Begriffe mit ihnen assoziieren, je benutzungsfreundlicher sie KI-Sprachmodelle empfinden.

Die letzte Hypothese testete den Zusammenhang der Polarität von KI-Sprachmodellen und der Intention, KI-Sprachmodelle zu nutzen (H5). In der aktuellen Stichprobe zeigte sich eine signifikante Beziehung zwischen den beiden Variablen. Lehrer:innen, die eine positivere Polarität bei der Nennung von Assoziationen aufwiesen, zeigten sich eher dazu bereit, KI-Sprachmodelle zu nutzen.

## **5.2 Diskussion der sozialen Repräsentationen von KI-Sprachmodellen**

Die vorliegende Studie konzentrierte sich neben der quantitativen Hypothesentestung ebenfalls darauf, die Ergebnisse der lexikografischen Analyse der KI-Assoziationen zu visualisieren und in verschiedenen Gruppen zu beleuchten. In der Analyse der Gesamtstichprobe ist *ChatGPT* der einzige Begriff, der in der Kernzone (Dany et al., 2015) liegt. Dieser Begriff wurde in der Gesamtstichprobe, sowie in allen Gruppenvergleichen mit Abstand am häufigsten genannt. Dies deutet daraufhin, dass die meisten Lehrer:innen ChatGPT mit KI-Sprachmodellen verbinden. ChatGPT ist seit seiner Veröffentlichung im Jahr 2022 sehr präsent in den Berichterstattungen der Medien vertreten. Es ist mit eines der bekanntesten KI-Sprachmodelle, weshalb es nicht überrascht, dass viele Personen den Begriff

mit dem Stimuluswort assoziieren. Interessant ist jedoch, dass von 110 Lehrer:innen und 434 Wortnennungen nur der eine Begriff in der Kernzone repräsentiert ist. Eine Möglichkeit dies zu interpretieren wäre, das KI sehr vielfältig und komplex ist. Dazu kommt, dass sie erst seit wenigen Jahren von den meisten Personen praktisch eingesetzt wird. Lange war KI nicht so einfach für die Öffentlichkeit zugänglich und von einem Tag auf den anderen konnte jede Person, die wollte, darauf zugreifen und sie selbst anwenden. KI ist ein neues Konstrukt in unserer Gesellschaft, zu dem jede Person andere Worte assoziiert. Es gibt die Möglichkeit, Begriffe, die auf das Können von Sprachmodellen bezogen sind, zu nennen. Aber auch Gefühle oder die Funktionsweise können damit verbunden werden. ChatGPT ist offensichtlich der einzige Begriff, den knapp ein Viertel der Proband:innen mit dem Stimuluswort assoziiert. Die Komplexität der Thematik KI lässt sich zusätzlich in einer anderen Messgröße erkennen. Um nur relevante Begriffe in die lexikografische Analyse miteinzubeziehen, wird ein Erwartungswert berechnet. Dieser entspricht dem Verhältnis der absoluten Häufigkeit der Nennungen zu der Anzahl der verschiedenen Nennungen. Für jede lexikografische Analyse wurde ein eigener Erwartungswert berechnet, der gerundet immer 2 ergab. Das bedeutet, dass, sobald in der Stichprobe ein Wort zweimal genannt worden war, es schon in die Analyse mit aufgenommen wurde. Das verdeutlicht die Vielfältigkeit der genannten Begriffe und bestärkt die Tatsache, dass, bis auf ChatGPT und wenige andere Assoziationen, sehr diverse Begriffe mit KI-Sprachmodellen verbunden werden.

Da ChatGPT sich in der Kernzone der visuellen Darstellung befindet bedeutet dies nicht nur, dass er von über 10% der Personen genannt wurde, sondern auch, dass die relative Rangberechnung ergab, dass ihm im Schnitt eine niedrige Rangplatzierung gegeben wurde. Die Teilnehmenden hatten nach der Möglichkeit ihre Begriffe zu nennen und diese zu bewerten die Option, ihre selbst genannten Begriffe zu hierarchisieren (Platz 1 = der Begriff, den man am meisten mit KI-Sprachmodellen verbindet, usw.). Folglich stuften Proband:innen bei der Hierarchisierung der Begriffe, die sie am meisten mit KI-Sprachmodellen verbinden, ChatGPT als einen der wichtigsten Begriffe ein. Das bedeutet, dass, wenn der Begriff „KI-Sprachmodelle“ genannt wird, die meisten Personen an ChatGPT denken. Zu der Häufigkeit der Nennung und der niedrigen Platzierung kommt, dass der Begriff durchweg in allen Gruppen und in der Gesamtstichprobe mehr positiv als negativ bewertet wurde und somit eines der bekanntesten KI-Sprachmodelle positiv behaftet ist. In der Stichprobe der Lehrer:innen ist dies insofern interessant, als das häufig in den Medien oder im Volksmund die Schattenseiten, beziehungsweise die unvermeidlichen Veränderungen im Bildungssystem, mit dem Begriff „ChatGPT“ einhergehen. Dass ChatGPT positiv bewertet wurde zeigt auf,

dass Lehrer:innen neben den Veränderungen und Möglichkeiten des Schummelns, eher die Vorteile in KI-Sprachmodellen sehen.

Kein anderer Begriff wurde so oft und als so essenziell in Verbindung mit KI-Sprachmodellen gebracht wie ChatGPT. Über dem Trennkriterium der relativen Häufigkeit von 10% befinden sich in der Gesamtstichprobe sonst nur drei weitere Wörter: Texterstellungen, Übersetzungen und Unterstützung. Diese Begriffe wurden in der Gesamtstichprobe zwar häufig genannt, ihr relativer mittlerer Rang liegt allerdings hinter der 0.5 Linie, somit liegen sie in der peripheren Zone (Peripherie 1.1). Die Rangplatzierung lässt schließen, dass viele Teilnehmende die Begriffe Texterstellungen, Übersetzungen und Unterstützung mit KI-Sprachmodellen assoziieren, sie jedoch nicht die Begriffe sind, an die sie sofort denken, wenn sie das Stimuluswort hören. Alle drei Wörter sind im Durchschnitt von den teilnehmenden Lehrer:innen positiv bewertet worden. Sie beschreiben die Aufgaben, die KI-Sprachmodelle übernehmen und dadurch unterstützen können und deuten darauf hin, dass im Schulkontext viele Lehrkräfte anwendungsbezogene Begriffe mit KI-Sprachmodellen verbinden.

Knapp unter der 10%-Linie, dafür bei der relativ mittleren Rangplatzierung vor dem 0.5-Trennkriterium befinden sich in der Gesamtstichprobe die Begriffe Recherche, Zukunft, LLM und schummeln. Durch die niedrigere relative Häufigkeit kann man sehen, dass weniger Leute diese Begriffe in Verbindung mit KI-Sprachmodellen nannten. Jedoch, wenn sie genannt wurden, wurden sie als sehr wichtig in Bezug auf das Stimuluswort gewertet. Sie liegen somit ebenfalls in einer peripheren Zone (Peripherie 1.2). Die Teilnehmenden beurteilten Recherche, Zukunft und LLM als positiv, schummeln war negativ behaftet. In der Gesamtstichprobe lassen sich somit fast durchweg positive Repräsentationen mit KI-Sprachmodellen beobachten.

### **MINT vs. kein MINT**

In den Gruppenvergleichen wurden jeweils zwei Gruppen von Teilnehmenden gegenübergestellt und ihre sozialen Repräsentationen explorativ betrachtet. Im ersten Gruppenvergleich wurden die Begriffe von Lehrer:innen, die MINT-Fächer oder das Fach digitale Grundbildung unterrichten (Gruppe 1, kurz: *MINT*) mit Lehrkräften, die kein wissenschaftliches Fach unterrichten (Gruppe 2, kurz: *kein MINT*) verglichen. In der lexikografischen Analyse der Wortassoziationen zeigte sich, dass sich bei Gruppe 2 mehr Wörter im Kern des Koordinatensystems befanden als bei der MINT-Gruppe.

Der Begriff ChatGPT wurde, wie in der Gesamtstichprobe in beiden Gruppen mit Abstand am häufigsten genannt. Mehr als 26% der MINT-Lehrer:innen führten den Begriff

an, bei den anderen Lehrkräften waren es im Vergleich knapp 23%. ChatGPT war in beiden Gruppen positiv behaftet, was bedeutet, dass alle Lehrer:innen der Stichprobe diesen Begriff am meisten mit KI-Sprachmodellen verbinden und diesen auch als positiv empfinden.

In der Gruppe der *kein MINT*-Lehrer:innen lagen die Begriffe Zukunft und Recherche ebenfalls im Kern der Analyse. Beide Begriffe waren positiv bewertet. Im Gegensatz dazu kamen die Begriffe bei *MINT*-Lehrkräften nicht im Kern des Koordinatensystems vor, dafür aber der Begriff Texterstellungen, welcher ebenfalls positiv bewertet wurde. Gruppe 1, die Lehrkräfte aus wissenschaftlichen Bereichen bildeten, zeigte in der qualitativen Analyse keinen Unterschied zu Lehrer:innen, die andere Schulfächer unterrichteten. Texterstellungen und Recherche sind beides Funktionen für die KI-Sprachmodelle eingesetzt werden können und zeigen somit die Anwendungsgebiete von KI-Sprachmodellen auf. Somit ist anzunehmen, dass die Thematik KI in beiden Gruppen von Lehrkräften ähnlich behaftet ist.

## **Geschlecht**

Bei der Gegenüberstellung von Männern und Frauen wurde deutlich, dass wieder der Begriff ChatGPT am häufigsten genannt wurde (ungefähr 22% der Frauen und 28% der Männer). Bei den Frauen lagen im Kern der Analyse ebenfalls der Begriff Zukunft, welcher positiv behaftet war. Bei Männern befanden sich im Kern die Begriffe Recherche und LLM, welche auch beide positiv bewertet wurden. Eine Möglichkeit diese Worte zu interpretieren könnten die unterschiedlichen Zugangsweisen von Männern und Frauen in Bezug zu Technologien sein. Schiersmann beschrieb 1987 (zitiert nach Dahlmann et al., 2008), dass Frauen eine andere Herangehensweise an Computer hätten als Männer. Im Gegensatz zu der Funktionsweise und technischen Aspekten, zeigen sie mehr Interesse an den gesellschaftlichen Wirkungen von Technologien.

Interessant war zu sehen, dass Frauen in der Peripherie 1.1 einige Begriffe nannten: Texterstellungen, Unterstützung, Hilfreich und Kritikfähigkeit. Diese Begriffe wurden von über 10% aller teilnehmenden Frauen genannt, aber eher weniger relevant bei der Rangplatzierung eingeschätzt. Bis auf den Begriff Kritikfähigkeit, der ausgewogen positiv und negativ bewertet wurde, wurden die Begriffe positiv konnotiert. Mit Ausnahme von dem Begriff Texterstellungen, der sich auf ein Anwendungsgebiet von KI-Sprachmodellen bezieht und auf die Arbeit mit KI bezogen ist, sind die anderen oft genannten Begriffe emotionaler Herkunft. Unterstützung und Hilfreich beschreiben Effekte von KI auf Menschen oder Handlungen und Kritikfähigkeit bezieht sich vermutlich auf eine Kompetenz, die wichtig in Verbindung mit der Nutzung von KI scheint. In der Welt der Technologien sind Stereotype von Frauen und Männern in Bezug auf ihre Herangehensweise an Technologien sehr präsent.

Der männliche Zugang wird als rationaler beschrieben während Frauen bei Technologien eine menschenorientierte Herangehensweise haben (Lott, 2023). Die genannten Begriffe zielen auf interaktive Handlungen ab: Welche Auswirkungen hat KI auf mich und was brauche ich, um sie anzuwenden. Im Gegensatz dazu nannten Männer häufig die Begriffe Daten und Übersetzungen, welche die Funktionsweisen und Anwendungsbereiche von KI beschreiben und rationaler Natur sind. Diese Interpretation stützt erneut die Aussage von Schiersmann (1987, zitiert nach Dahlmann et al., 2008), die verschiedenen Zugänge von Männern und Frauen an Technologien beschreibt. Auch, wenn statistisch kein signifikanter Unterschied in der emotionalen Bewertung von KI-Sprachmodellen aufzuzeigen war, scheint es doch einen inhaltlichen Unterschied an der Art der genannten Assoziationen mit KI-Sprachmodellen zwischen Männern und Frauen zu geben.

## 6 Limitationen

Diese Studie wurde im Rahmen eines Querschnittsdesigns durchgeführt und weist daher eine Momentaufnahme der Daten auf. Durch den fehlenden zeitlichen Vergleich kann keine Kausalität, sondern lediglich ein Zusammenhang der Variablen interpretiert werden. Weiteres wurden aufgrund der relativ kleinen Stichprobe mittels Regressionen die Beziehungen der unterschiedlichen Variablen ermittelt. Um das Technologieakzeptanzmodell als Ganzes, anhand eines Strukturgleichungsmodells, zu testen, wäre eine größere Anzahl an Proband:innen notwendig. Hierbei könnten mehr Informationen aus den erhobenen Daten gewonnen und komplexe Zusammenhänge der einzelnen Variablen sichtbar gemacht werden. Insgesamt bestand die Stichprobe aus Lehrkräften unterschiedlicher Schultypen, die eine große Altersspanne aufwiesen und verschiedene Schulfächer unterrichten. Trotz dessen handelt es sich in dieser Studie um eine Convenience-Stichprobe, da die Lehrer:innen größtenteils über die von mir kontaktierten Direktionen angeregt wurden, an der Umfrage teilzunehmen. Es besteht die Möglichkeit, dass einige Direktor:innen ihre Lehrkräfte stärker motivierten als andere. Um auf die Gesamtheit der Lehrer:innenschaft schließen zu können, wäre eine größere, noch differenziertere Stichprobe sinnvoll.

Die genannten Assoziationen der Teilnehmer:innen wurden zu Beginn der lexikografischen Analyse bereinigt. Zusätzlich zu den Rechtsschreibkorrekturen wurden einige Begriffe umgeschrieben, da Proband:innen teilweise Wörter oder Sätze mit gleicher Bedeutung nannten. Das Vereinheitlichen synonyme Begriffe diente dazu, die Begriffe in die lexikografische Analyse aufzunehmen, da nur Begriffe integriert wurden, die mindestens zwei Mal in der Stichprobe genannt wurden. Somit konnten Informationen gewonnen werden. Es wurde darauf geachtet, den Sinngehalt der genannten Begriffe und Sätze nicht zu verändern.

Um passende Überbegriffe zu finden, die die Wörter bestmöglich vereinheitlichen, wurde teilweise mit ChatGPT gearbeitet. Allerdings kann trotzdem nicht davon ausgegangen werden, dass die Bearbeitung dieser qualitativen Daten, keine Auswirkungen auf die Analyse hatte.

## **7 Konklusion und Ausblick**

Sowohl die Limitationen der Studie als auch das Interesse an Erkenntnis über vertiefende Information über KI-Sprachmodelle geben Motivation für weiterführende Untersuchung. Dabei könnten die bereits erhobenen Assoziationen in mehr Gruppenvergleichen gegenübergestellt und analysiert werden. Die vorliegenden Analysen der Kern- und Peripheriebereiche zeigen auf, dass eine sehr differenzierte Menge an Assoziationen genannt wurde. Diese unterschiedlichen Begriffe, vor allem in den Peripheriebereichen, könnten intensiver diskutiert und beleuchtet werden. Interessant wäre ebenfalls die Gegenüberstellungen von Assoziationen der Lehrer:innen mit denen der Schüler:innen oder anderer Berufsgruppen. Somit könnte durch weiterführende Studien ermittelt werden, welche allgemeinen Assoziationen zum Diskurs über KI-Sprachmodelle beitragen und ob sich die Assoziationen und ihre emotionale Bewertung unterscheiden.

Die Auswertung der quantitativen Analyse bestätigt die Annahmen der ursprünglichen TAM-Forschungen (Antonietti et al., 2022; Venkatesh et al., 2003), dass wahrgenommene Benutzungsfreundlichkeit und wahrgenommene Nützlichkeit einen Einfluss auf die Nutzungsintention einer Technologie, in diesem Fall KI-Sprachmodelle, haben. Die Wirkung über die Variable der Polarität der sozialen Repräsentation über die KI wurde ebenfalls bestätigt. Das impliziert die Bedeutung der emotionalen Bewertung der mit KI assoziierten Begriffe entgegen anderen TAM-Studien, die diese Variable aufgrund der unzureichenden Erkenntnislage einer Mediation (Antonietti et al., 2022; Venkatesh & Davis, 1996) ausschlossen. Die digitale Kompetenz als Prädiktor für wahrgenommene Benutzungsfreundlichkeit und wahrgenommene Nützlichkeit einer KI könnten in der Praxis als präventive Maßnahme angenommen werden. Das Näherbringen einer neutral kritischen Herangehensweise an die neue Art der Technologien an Schüler:innen, könnte durch die Sicherstellung einer (wahrgenommenen) digitalen Kompetenz der Lehrkräfte angestrebt werden.

## Literatur

- Ajzen, I., & Fishbein, M. (1975). A Bayesian analysis of attribution processes. *Psychological Bulletin*, 82(2), 261–277. <https://doi.org/10.1037/h0076477>
- Al-Emran, M., Elsherif, H. M., & Shaalan, K. (2016). Investigating attitudes towards the use of mobile learning in higher education. *Computers in Human Behavior*, 56, 93–102. <https://doi.org/10.1016/j.chb.2015.11.033>
- Andreouli, E., & Chryssochoou, X. (2015). Social representations of national identity in culturally diverse societies. *The Cambridge handbook of social representations*, 309. <https://doi.org/10.1017/CBO9781107323650.026>
- Antonietti, C., Cattaneo, A., & Amenduni, F. (2022). Can teachers' digital competence influence technology acceptance in vocational education?. *Computers in Human Behavior*, 132, 107266. <https://doi.org/10.1016/j.chb.2022.107266>
- Backfisch, I., Scherer, R., Siddiq, F., Lachner, A., & Scheiter, K. (2021). Teachers' technology use for teaching: Comparing two explanatory mechanisms. *Teaching and Teacher Education*, 104, 103390. <https://doi.org/10.1016/j.tate.2021.103>
- Beierlein, C., Kovaleva, A., Kemper, C. J., & Rammstedt, B. (2012). Ein Messinstrument zur Erfassung subjektiver Kompetenzerwartungen: Allgemeine Selbstwirksamkeit Kurzskala (ASKU).
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences (2nd ed.)*. Hillsdale, N.J.: L. Erlbaum Associates.
- Dahlmann, N., Elsner, M., Jeschke, S., Natho, N., & Schroder, C. (2008). Gender gap in technological disciplines: Societal causes and consequences. *2008 IEEE International Symposium on Technology and Society*, 1–7. <https://doi.org/10.1109/ISTAS.2008.4559761>
- Dany, L., Urdapilleta, I., & Lo Monaco, G. (2015). Free associations and social representations: some reflections on rank-frequency and importance-frequency methods. *Quality & Quantity*, 49(2), 489–507. <https://doi.org/10.1007/s11135-014-0005-z>

*Das österreichische Schulsystem.* (o.D.)

<https://www.bmbwf.gv.at/Themen/schule/schulsystem.html>

Davis, F. D. (1989). Technology acceptance model: TAM. *Al-Suqri, MN, Al-Aufi, AS: Information Seeking Behavior and Technology Adoption*, 205, 219.

*Digitale Grundbildung.* (o.D.). <https://www.bmbwf.gv.at/Themen/schule/zrp/dibi/dgb.html>

Drossel, K., & Eickelmann, B. (2017). Teachers' participation in professional development concerning the implementation of new technologies in class: A latent class analysis of teachers and the relationship with the use of computers, ICT selfefficacy and emphasis on teaching ICT skills. *Large-scale Assessments in Education*, 5(1), 1–13.  
<https://doi.org/10.1186/s40536-017-0053-7>

From, J. (2017). Pedagogical digital competence—between values, knowledge and skills. *Higher Education Studies*, 7(2), 43–50. <https://doi.org/10.5539/hes.v7n2p43>

Ghomi, M., & Redecker, C. (2019). Digital Competence of Educators (DigCompedu): Development and Evaluation of a Self-Assessment Instrument for teachers' Digital Competence. In H. Lane, S. Zvacek, & J. Uhomioibhi (Eds.), *Proceedings of the 11th International Conference on Computer Supported Education* (1<sup>st</sup> ed., pp. 541–548). Science and Technology Publications. <https://doi.org/10.5220/0007679005410548>.

Götz, T., Frenzel, A. C. & Pekrun, R. (2018). Psychologische Bildungsforschung. In R. Tippelt & B. Schmidt (Hrsg.), *Handbuch Bildungsforschung* (4. Aufl., S. 73 – 99).Springer. [https://doi.org/10.1007/978-3-531-19981-8\\_3](https://doi.org/10.1007/978-3-531-19981-8_3)

Guggemos, J., and S. Seufert. 2021. Teaching with and Teaching About Technology – Evidence for Professional Development of In-Service Teachers. *Computers in Human Behavior*, 115. <https://doi.org/10.1016/j.chb.2020.106613>.

Heddy, B. C., Danielson, R. W., Sinatra, G. M., & Graham, J. (2017). Modifying Knowledge, Emotions, and Attitudes Regarding Genetically Modified Foods. *The Journal of Experimental Education*, 85(3), 513–533.  
<https://doi.org/10.1080/00220973.2016.1260523>

Huwer, J., Irion, T., Kuntze, S., Schaal, S., & Thyssen, C. (2019). Von TPaCK zu DPaCK—Digitalisierung im Unterricht erfordert mehr als technisches Wissen. *MNU journal*, 72(5), 356–364.

- Kirchler, E. (1998). Differential representations of taxes: Analysis of free associations and judgments of five employment groups. *The Journal of Socio-Economics*, 27(1), 117–131. [https://doi.org/10.1016/S1053-5357\(99\)80080-8](https://doi.org/10.1016/S1053-5357(99)80080-8)
- Kulich, C., el Sehity, T., & Kirchler, E. (2005). Zur strukturellen Analyse sozialer Vorstellungen: Lexikographische Analyse von freien Assoziationen.
- Kullmann, S. (2023). Künstliche Intelligenz in der Informationswissenschaft. *Information–Wissenschaft & Praxis*, 74(2-3), 139-141. <https://doi.org/10.1515/iwp-2023-2015>
- Krumsvik, R. J. (2014). Teacher educators' Digital Competence. *Scandinavian Journal of Educational Research*, 58(3): 269–280. <https://doi.org/10.1080/00313831.2012.726273>.
- Krumsvik, R. J., Jones, L.Ø., Øfstegaard, M., & Eikeland, O. J. (2016). Upper secondary school teachers' digital competence: Analysed by demographic, personal and professional characteristics. *Nordic Journal of Digital Literacy*, 11, 143–164. <https://doi.org/10.18261/issn.1891-943x-2016-03-02>
- Lott, Y. (2023). Der Gender Digital Gap in Transformation? Verwendung digitaler Technologien und Einschätzung der Berufschancen in einem digitalisierten Arbeitsmarkt.
- Marangunić, N., & Granić, A. (2015). Technology acceptance model: a literature review from 1986 to 2013. *Universal access in the information society*, 14, 81-95. <https://doi.org/10.1007/s10209-014-0348-1>
- Markus, A., Wienrich, C. & Carolus, A. (o.D.). Digitale Kompetenzen. Bayrisches Forschungsinstitut für Digitale Transformation. <https://www.bidt.digital/glossar/digitale-kompetenzen/#:~:text=Definition,sowie%20digitalen%20Medien%20erforderlich%20sind.> (23.03.2024)
- Masrom, M. (2007). Technology acceptance model and e-learning. *Technology*, 21(24), 81.
- McCrae, R. R., & Costa, P. T. (1987). Validation of the Five-Factor Model of Personality Across Instruments and Observers. *Journal of Personality and Social Psychology*, 52(1), 81–90. <https://doi.org/10.1037/0022-3514.52.1.81>

*Medienbildung in der Volksschule.* (2024).

<https://www.saferinternet.at/zielgruppen/lehrende/medienbildung-in-der-volksschule>

Mester, B. A. (2012). Bildungsauftrag: Datenschutz als Aufgabe staatlicher Institutionen. *Datenschutz und Datensicherheit-DuD*, 36(2), 132-132.  
<https://doi.org/10.1007/s11623-012-0031-8>

Moliner, P., & Abric, J.-C. (2015). Central core theory. In G. Sammut, E. Andreouli, G. Gaskell, & J. Valsiner (Hrsg.), *The Cambridge Handbook of Social Representations* (1. Aufl., S. 83–95). Cambridge University Press.  
<https://doi.org/10.1017/CBO9781107323650.009>

Moliner, P., & Tafani, E. (1997). Attitudes and social representations: A theoretical and experimental approach. *European Journal of Social Psychology*, 27(6), 687–702.  
[https://doi.org/10.1002/\(SICI\)1099-0992\(199711/12\)27:6<687::AID-EJSP839>3.0.CO;2-7](https://doi.org/10.1002/(SICI)1099-0992(199711/12)27:6<687::AID-EJSP839>3.0.CO;2-7)

Moloney, G., & Walker, I. (Eds.). (2007). *Social representations and identity: Content, Process, and Power*. New York: Palgrave Macmillan.

Moscovici, S., & Duveen, G. (2000). Social representations: explorations in social psychology (1. publ.). Cambridge: Polity Press

Nattland, A., & Kerres, M. (2006). Computer im Unterricht, *Computerbasierte Medien im Unterricht*.

Pekrun, R. (2018). Emotion, lernen und leistung. *Bildung und emotion*, 215-231. Springer Fachmedien Wiesbaden. doi: 10.1007/978-3-658-18589-3\_12

Pletz, C. & Zinn, B. (2021). Technologieakzeptanz von virtuellen Lern- und Arbeitsumgebungen. *Journal of Technical Education (JOTED)*, 2018, 6(4), 86-105.

Quast, J., Rubach, C., & Porsch, R. (2023). Professional digital competence beliefs of student teachers, pre-service teachers and teachers: Validating an instrument based on the DigCompEdu framework. *European Journal of Teacher Education*, 1-24.  
<https://doi.org/10.1080/02619768.2023.2251663>

Redecker, C. (2017). European framework for the digital competence of educators: DigCompEdu. In Y. Punie (Ed.), *EUR 28775 EN*. Publications Office of the European Union. <https://doi.org/10.2760/159770>.

- Scherer, R., Howard, S. K., Tondeur, J., & Siddiq, F. (2021). Profiling teachers' readiness for online teaching and learning in higher education: Who's ready? *Computers in Human Behavior*, 118, 106675. <https://doi.org/10.1016/j.chb.2020.106675>
- Scherer, R., Siddiq, F., & Tondeur, J. (2019). The technology acceptance model (TAM): A meta-analytic structural equation modeling approach to explaining teachers' adoption of digital technology in education. *Computers & education*, 128, 13-35. <https://doi.org/10.1016/j.compedu.2018.09.009>
- Scherer, R., & Teo, T. (2019). Unpacking teachers' intentions to integrate technology: A meta-analysis. *Educational Research Review*, 27, 90-109. <https://doi.org/10.1016/j.edurev.2019.03.001>
- Schumacher, P., & Morahan-Martin, J. (2001). Gender, Internet and computer attitudes and experiences. *Computers in Human Behavior*, 17(1), 95–110. [https://doi.org/10.1016/S0747-5632\(00\)00032-7](https://doi.org/10.1016/S0747-5632(00)00032-7)
- Teo, T., Lee, C. B., & Chai, C. S. (2008). Understanding pre-service teachers' computer attitudes: applying and extending the technology acceptance model. *Journal of Computer Assisted Learning*, 24(2), 128–143. <https://doi.org/10.1111/j.1365-2729.2007.00247.x>
- Venkatesh, V., & Bala, H. (2008). Technology acceptance model 3 and a research agenda on interventions. *Decision Science*, 39(2), 273–312. <https://doi.org/10.1111/j.1540-5915.2008.00192.x>
- Venkatesh, V., & Davis, F. D. (1996). A Model of the Antecedents of Perceived Ease of Use: Development and Test. *Decision Sciences*, 27(3), 451–481. <https://doi.org/10.1111/j.1540-5915.1996.tb00860.x>
- Venkatesh, V., & Davis, F. D. (2000). A theoretical extension of the technology acceptance model: Four longitudinal field studies. *Management Science*, 46(2), 186–204. <https://doi.org/10.1287/mnsc.46.2.186.11926>
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS quarterly*, 425-478. <https://doi.org/10.2307/30036540>
- Was ist Künstliche Intelligenz?* (o.D.) <https://www.ibm.com/de-de/topics/artificial-intelligence>

Wong, K. T., Teo, T., & Russo, S. (2012). Influence of gender and computer teaching efficacy on computer acceptance among Malaysian student teachers: An extended technology acceptance model. *Australasian Journal of Educational Technology*, 28(7).  
<https://doi.org/10.14742/ajet.796>

Zhao, Y., Llorente, A. M. P., & Gómez, M. C. S. (2021). Digital competence in higher education research: A systematic literature review. *Computers & Education*, 104212.  
<https://doi.org/10.1016/j.compedu.2021.104212>

Zusätzlich: ChatGPT (direktes Zitat und Inspiration für Formulierungen) und DeepL (Übersetzungen)

## Anhang

### Anhang A - Digitale Kompetenz (Quast et al., 2023)

Quast, J., Rubach, C., & Porsch, R. (2023). Professional digital competence beliefs of student teachers, pre-service teachers and teachers: Validating an instrument based on the DigCompEdu framework. *European Journal of Teacher Education*, 1-24.  
<https://doi.org/10.1080/02619768.2023.2251663>

Antwortformat:

(1) gar nicht kompetent; (2) eher nicht kompetent, (3) neutral; (4) eher kompetent; (5) sehr kompetent

Wie kompetent fühlen Sie sich darin, ...

(Administration und Weiterbildung)

- a) ...digitale Medien zu nutzen, um als Lehrkraft die organisatorische Kommunikation mit anderen (z.B. Schüler:innen, Eltern und Kolleg:innen) zu verbessern?
- b) ...digitale Medien zu nutzen, um mit anderen Lehrkräften zusammenzuarbeiten (z.B. Erfahrungen und Materialien austauschen)?
- c) ...digitale Medien für Ihre berufliche Weiterbildung zu nutzen?
- d) ...selbstständig digitale Lehr- und Lernressourcen für Ihren Unterricht zu erstellen?
- e) ...vorhandene digitale Lehr- und Lernressourcen an Ihre berufsbezogenen Bedürfnisse als Lehrkraft anzupassen?
- f) ...relevante digitale Lehr- und Lernressourcen für Ihren Unterricht zu organisieren (z.B. in Ordern/Unterordnern auf einem Endgerät thematisch sortiert speichern)?
- g) ...anderen Akteur:innen in der Schule (Schüler:innen, Eltern und Kolleg:innen) digitale Lehr- und Lernressourcen zur Verfügung zu stellen?

(Unterrichtsplanung)

- a) ...den Einsatz digitaler Medien in Ihrem Unterricht mit Hinblick auf den didaktisch sinnvollen Einsatz zu reflektieren und selbstkritisch zu beurteilen?
- b) ...für Ihren Unterricht geeignete digitale Lehr- und Lernressourcen auszuwählen?
- c) ...den Einsatz von digitalen Medien im Unterricht didaktisch sinnvoll zu planen und zu gestalten?
- d) ...Unterrichtsmethoden mit Hilfe digitaler Medien angemessen im Unterricht umzusetzen?

(Lehren und Unterstützung von Schüler:innen)

- a) ...digitale Medien zu nutzen, um die Interaktion mit Schüler:innen im Unterricht zu verbessern?
- b) ...digitale Medien zu nutzen, um Schüler:innen im Unterricht gezielt Beratung und Unterstützung anzubieten?
- c) ...digitale Medien zu nutzen, um kollaborative Lernstrategien und -prozesse bei Schüler:innen im Unterricht zu fördern?
- d) ...digitale Technologien zu nutzen, um selbstgesteuerte Lernprozesse bei Schüler:innen im Unterricht zu unterstützen?

(Evaluation)

- a) ...digitale Medien im Unterricht zur Lernkontrolle und Leistungsbeurteilung zu verwenden?
- b) ...mit Hilfe digitaler Medien vielfältige Prüfungsformate im Unterricht einzusetzen?
- c) ...digitale Informationen zu Lernverhalten, Leistung und Lernfortschritt von Schüler:innen im Unterricht zu erheben und kritisch zu analysieren?

(Schüler:innenorientierung)

- a) ...zu gewährleisten, dass alle Schüler:innen (auch solche mit besonderen Bedürfnissen) Zugang zu den im Unterricht eingesetzten digitalen Medien und Lernaktivitäten haben?
- b) ...Vorkenntnisse und Fähigkeiten von Schüler:innen bei der Nutzung digitaler Medien im Unterricht zu berücksichtigen?
- c) ...Schüler:innen mit Hilfe digitaler Medien zu ermöglichen, im Unterricht ihr individuelles Lernziel in ihrem jeweils eigenen Tempo zu erreichen?
- d) ...digitale Medien zu nutzen, um die Auseinandersetzung von Schüler:innen mit einem Thema im Unterricht zu fördern?
- e) ...digitale Medien zu nutzen, um im Unterricht reale, lebensweltbezogene Lernkontexte zu schaffen?

(Förderung der digitalen Kompetenz der Schüler:innen)

- a) ...Aktivitäten in Ihren Unterricht zu integrieren, in denen Schüler:innen digitale Medien zur Suche von Informationen nutzen?
- b) ...Schüler:innen zu vermitteln, wie sie Informationen aus digitalen Medien kritisch bewerten können?
- c) ...Aktivitäten in Ihren Unterricht zu integrieren, durch die Schüler:innen lernen, digitale Medien verantwortungsbewusst zur Kommunikation und Zusammenarbeit zu nutzen?

d) ...Aktivitäten in Ihren Unterricht zu integrieren, in denen Schüler:innen selbst digitale Inhalte in verschiedenen Formaten (z.B. Videos, Präsentationen) erstellen?

(Datenschutz und Urheberrecht)

a) ...Datenschutz- und Urheberrechtsbestimmungen im berufsbezogenen Kontext korrekt anzuwenden?

b) ...Schüler:innen zu vermitteln, wie sie Lizenz- und Urheberrechtsbestimmungen bei der Erstellung digitaler Inhalte berücksichtigen?

## Anhang B – Variablen des TAM (Deutsch) (Pletz & Zinn, 2021)

Pletz, C. & Zinn, B. (2021). Technologieakzeptanz von virtuellen Lern- und Arbeitsumgebungen. *Journal of Technical Education (JOTED)*, 2018, 6(4), 86-105.

Antwortformat:

- (1) stimme gar nicht zu; (2) stimme eher nicht zu; (3) neutral; (4) stimme eher zu; (5) stimme voll und ganz zu

Wie sehr stimmen Sie folgenden Aussagen zu?

Wahrgenommene Benutzungsfreundlichkeit (perceived ease of use; PEU)

- a) Die Bedienung von KI-Sprachmodellen wäre leicht für mich.
- b) Es wäre leicht für mich, die Bedienung von KI-Sprachmodellen zu erlernen.
- c) Der Umgang mit KI-Sprachmodellen wäre für mich klar und verständlich.
- d) Es wäre einfach für mich, geschickt im Umgang mit KI-Sprachmodellen zu werden.


Wahrgenommene Nützlichkeit (perceived use; PU)

- a) Durch die Nutzung von KI-Sprachmodellen könnte ich meine Aufgaben schneller erledigen.
- b) Die Nutzung von KI-Sprachmodellen würde meine Aufgaben erleichtern.
- c) Die Nutzung von KI-Sprachmodellen würde meine Produktivität erhöhen.
- d) KI-Sprachmodelle wären nützlich für meine Arbeit.
- e) Der Einsatz von KI-Sprachmodellen würde sich positiv auf meine räumliche Flexibilität bei der Arbeit auswirken, z.B. indem ich flexibel bestimmen könnte, wo ich arbeite.
- f) Der Einsatz von KI-Sprachmodellen würde sich positiv auf meine zeitliche Flexibilität auswirken, z.B. indem ich flexibel bestimmen könnte, wann ich arbeite.


Nutzungsintention (behavioral intention; BI)

- a) Ich habe vor, KI-Sprachmodelle für meinen Unterricht zu verwenden.


## Anhang C – Lexikografische Analyse der Lehrer:innen, die MINT-Fächer oder digitale Grundbildung unterrichten



## Anhang D - Lexikografische Analyse der Lehrer:innen, die keine MINT-Fächer oder digitale Grundbildung unterrichten



# Anhang E – Lexikografische Analyse der Lehrerinnen (Frauen)



# Anhang F – Lexikografische Analyse der Lehrer (Männer)

