



Hochschule für Angewandte Wissenschaften Hamburg
Fakultät Life Sciences

**Zusammenhang zwischen der Akzeptanz klinischer
Entscheidungsunterstützungssysteme und den Kon-
strukten der Unified Theory of Acceptance and Use of
Technology:
Eine quantitative Analyse unter pflegerischem und
therapeutischem Personal**

Bachelorarbeit

Studiengang Gesundheitswissenschaften (B.Sc.)

vorgelegt von:

Michelle Matejek



Hamburg
am 29.09.2025

Erstgutachter: Herr Prof. Dr. Dr. Walter Leal (HAW Hamburg)

Zweitgutachter: Herr Prof. Dr. Dr. Michael Haufs (HAW Hamburg)

Zusammenfassung

Hintergrund: Die Digitalisierung im Krankenhauskontext nimmt weiter zu und soll dabei helfen medizinisches Personal zu entlasten. Klinische Entscheidungsunterstützungssysteme (CDSS) können medizinische Entscheidungen erleichtern, die Patientensicherheit erhöhen sowie Effizienz und Versorgungsqualität verbessern. Die Einführung neuer Technologien hängt maßgeblich von der Akzeptanz der Nutzenden ab. Das Ziel dieser Arbeit bestand darin, zu untersuchen, welche Variablen mit der Akzeptanz von CDSS zusammenhängen.

Methoden: Eine quantitative Online-Befragung wurde unter pflegerischem und therapeutischem Personal am BG Klinikum Hamburg gGmbH durchgeführt ($n=67$). Die Akzeptanz von CDSS wurde mithilfe der Unified Theory of Acceptance and Use of Technology erfasst. Die Datenanalyse umfasste deskriptive Analysen, punktbiseriale und Spearman Korrelationen sowie einfache und multiple lineare Regressionsmodelle.

Ergebnisse: In der Stichprobe zeigte die *Nutzungsabsicht* (NA) von CDSS signifikante positive Zusammenhänge mit *Leistungserwartung* (LE) ($r_s=0,754$; $p<0,001$), *Aufwandserwartung* (AA) ($r_s=0,684$; $p<0,001$) und *Vertrauen* (VT) ($r_s=0,530$; $p<0,001$). Männer wiesen eine höhere NA auf als Frauen ($r_{pb}=-0,295$; $p=0,019$). Ein multiples Regressionsmodell erklärte 69,5 % der Varianz der NA, wobei LE ($B=0,560$; $p<0,001$) und AA ($B=0,380$; $p=0,002$) signifikant blieben. VT ($B=0,116$; $p=0,319$) war nicht signifikant. In einem Regressionsmodell inklusive Moderatoren blieb AA signifikant ($B=0,410$; $p=0,011$). Interaktionseffekte von *Geschlecht*, *Alter*, *Berufsgruppe* und *Berufserfahrung* konnten nicht nachgewiesen werden.

Schlussfolgerung: Die Ergebnisse deuten darauf hin, dass LE und AA zentrale Faktoren für die Akzeptanz von CDSS darstellen. VT und Geschlecht lieferten Hinweise auf mögliche Zusammenhänge. *Sozialer Einfluss* und weitere soziodemografische Variablen zeigten keinen Zusammenhang. Die Befunde liefern erste Einblicke in Akzeptanzfaktoren am BGKH und bilden eine Grundlage für die zielgerichtete Implementierung von CDSS.

Schlüsselwörter: CDSS, Akzeptanz, UTAUT, BG Klinikum Hamburg, Digitalisierung

Inhaltsverzeichnis

Zusammenfassung	I
Abbildungsverzeichnis.....	IV
Tabellenverzeichnis	V
Abkürzungsverzeichnis	VI
1. Einleitung.....	1
2. Theoretischer Hintergrund.....	2
2.1 BG Klinikum Hamburg gGmbH (BGKH)	3
2.2 Klinische Entscheidungsunterstützungssysteme (CDSS).....	4
2.2.1 Klassifikation	5
2.2.2 Funktionen und Vorteile	6
2.2.3 Herausforderungen und Nachteile	9
2.3 Akzeptanz	11
2.3.1 Technology Acceptance Model (TAM)	12
2.3.2 Unified Theory of Acceptance and Use of Technology (UTAUT).....	13
2.4 Forschungsstand	15
3. Ziele und Hypothesen	19
4. Methodik	21
4.1 Datenerhebung und Stichprobe	21
4.2 Messinstrumente.....	22
4.2.1 Unabhängige Variablen	23
4.2.2 Abhängige Variable	26
4.3 Datenanalyse	26
4.4.1 Deskriptive Analyse	26
4.4.2 Bivariate Analyse.....	27
4.3.3 Multivariate Analyse	28
5. Ergebnisse	30
5.1 Stichprobenbeschreibung	30
5.2 Bivariate Analyse	32

5.3 Multivariate Analyse	37
6. Diskussion	40
6.1 Zusammenfassung der Ergebnisse	41
6.2 Einordnung in den Forschungskontext	41
6.3 Limitationen	43
6.4 Stärken	47
7. Fazit und Ausblick	48
8. Literaturverzeichnis	49
Eidesstaatliche Erklärung	55
Anhang	56
Anhang A: Fragebogen	56
Anhang B: Befragungs-Flyer.....	59
Anhang C: Prüfung der Voraussetzungen der Korrelationen.....	60
Anhang D: Prüfung der Voraussetzungen der linearen Regressionsmodelle.....	64

Abbildungsverzeichnis

Abbildung 1: Zentrale Interaktionen von wissensbasierten und nicht-wissensbasierten klinischen Entscheidungsunterstützungssystemen (CDSS), Quelle: Sutton et al., 2020, S. 2.	5
Abbildung 2: Technology Acceptance Model (TAM), Quelle: Davis et al., 1989, S. 985.	13
Abbildung 3: Unified Theory of Acceptance and Use of Technology (UTAUT). Quelle: Venkatesh et al., 2003, S. 447.	14
Abbildung 4: Histogramm der Nutzungsabsicht (NA), eigene Darstellung.	32

Tabellenverzeichnis

Tabelle 1: Ergebnisse der Korrelation der unabhängigen Variablen und der Nutzungsabsicht (NA), eigene Darstellung.....	33
Tabelle 2: Ergebnisse Korrelation der unabhängigen Variablen und der Leistungserwartung (LE), eigene Darstellung.	34
Tabelle 3: Ergebnisse Korrelation der unabhängigen Variablen und der Aufwandserwartung (AA), eigene Darstellung.....	35
Tabelle 4: Ergebnisse Korrelation der unabhängigen Variablen und dem Vertrauen (VT), eigene Darstellung.	36
Tabelle 5: Ergebnisse der einfachen linearen Regressionsmodelle der Leistungserwartung (LE), Aufwandserwartung (AA) und Vertrauen (VT) zur Erklärung der Nutzungsabsicht (NA), eigene Darstellung.....	37
Tabelle 6: Ergebnisse der multiplen linearen Regression des Grundmodells zur Erklärung der Nutzungsabsicht (NA), eigene Darstellung.....	38
Tabelle 7: Ergebnisse der multiplen linearen Regression des Moderatorenmodells zur Erklärung der Nutzungsabsicht (NA), eigene Darstellung	39

Abkürzungsverzeichnis

AA	Aufwandserwartung
AIR	Anästhesie, Intensiv-, Rettungs- und Schmerzmedizin
BGKH	BG Klinikum Hamburg gGmbH
BVI	Brandverletztenintensivstation
BVO	Brandverletztenstation
CDSS	Clinical Decision Support Systems (Klinische Entscheidungsunterstützungssysteme)
CPOE	Computerized Physician Order Entry (Computergestützte Verordnungssysteme)
DDSS	Diagnostic Decision Support Systems
EBP	Evidenzbasierte Pflege
ePA	Elektronische Patientenakte
FB	Förderliche Bedingungen
HPMC	Hand-, Plastische- und Mikrochirurgie
ICD	International Classification of Diseases
INT	Intensivstation
KI	Künstliche Intelligenz
LE	Leistungserwartung
NA	Nutzungsabsicht
NZ	Neurozentrum
PHR	Personal Health Records
PRISMA	Preferred Reporting Items for Systematic Reviews and Meta-Analyses
QZ	Querschnittsgelähmten-Zentrum
RG	Referenzgruppe
SI	Sozialer Einfluss
SUO	Septische Unfallchirurgie und Orthopädie

TAM	Technology Acceptance Model
UOS	Unfallchirurgie, Orthopädie und Sporttraumatologie
UTAUT	Unified Theory of Acceptance and Use of Technology
VCH	Allgemein- und Viszeralchirurgie
VT	Vertrauen
ZNA	Zentralambulanz
ZRH	Zentrum für Rehabilitationsmedizin

1. Einleitung

Die Digitalisierung prägt weltweit zunehmend die Arbeitswelt (IMD, 2023, S. 49–49). Auch in Deutschland zeigt sich eine derartige Entwicklung. Der Digitalisierungsindex ist im Jahr 2024 im Vergleich zum Vorjahr um 14 % gestiegen ist (Büchel et al., 2025, S. 1). Diese Entwicklung macht auch vor dem Gesundheitswesen nicht halt. Eine Umfrage aus Deutschland zeigt, dass 89 % der Befragten die Digitalisierung im Gesundheitswesen für sinnvoll erachteten ($n = 1140$) (Bitkom, 2024, o.S.).

Klinische Entscheidungsunterstützungssysteme (CDSS) gehören zu den zentralen Instrumenten, die im Rahmen der Krankenhausstrukturfonds-Verordnung (KHSFV) § 19 gefördert werden und stellen ein aktuelles Thema in der medizinischen Versorgung dar. CDSS sind Computerprogramme, die medizinisches Personal unmittelbar bei klinischen Entscheidungsprozessen unterstützen sollen (Sim et al., 2001, S. 528; Elhaddad & Hamam, 2024, S. 1). Sie bieten das Potenzial, die Patientensicherheit zu erhöhen, die Versorgungsqualität zu verbessern und Prozesse effizienter zu gestalten (Sutton et al., 2020, S. 2–6).

Trotz dieser Chancen sind CDSS in Deutschland bislang nur begrenzt im Einsatz. Gründe hierfür könnte die schleppende digitale Transformation vor allem im Gesundheitswesen sein (Stachwitz & Debatin, 2023, S. 105). Ein entscheidender Faktor für die erfolgreiche Implementierung neuer Technologien ist die Perspektive der Nutzenden. Die Akzeptanz der Nutzenden stellt hierbei einen zentralen Einflussfaktor der tatsächlichen Nutzung dar (Venkatesh et al., 2003, S. 447). Aktuell existieren nur wenige Studien, die die Akzeptanz von CDSS in Deutschland untersuchen. Zudem konzentrieren sich viele Studien auf ärztliches Personal, während pflegerisches und therapeutisches Personal bislang wenig Beachtung findet (Dingel et al., 2024, S. 6–7).

Das BG Klinikum Hamburg gGmbH (BGKH) gehört zu den größten Krankenhäusern Norddeutschlands und fokussiert sich sowohl auf Akutversorgung als auch auf die Rehabilitation von berufserkrankten und schwerstverletzten Menschen (BGKH, o.J. c). Am BGKH sind derzeit noch keine CDSS implementiert. Dennoch wird deren Einführung zunehmend diskutiert und sie gelten als relevantes zukünftiges Thema in der Krankenhausentwicklung. Vor diesem Hintergrund ist es entscheidend, die Einstellungen potenzieller Nutzender zu erfassen. Zudem müssen die Faktoren identifiziert werden, die die Akzeptanz beeinflussen, um eine erfolgreiche Implementierung von CDSS zu ermöglichen.

Vor diesem Hintergrund lautet die zentrale Forschungsfrage dieser Arbeit: „*Welche Faktoren stehen in Zusammenhang mit der Akzeptanz von CDSS unter pflegerischem und therapeutischem Personal am BGKH?*“.

Zur Beantwortung der Forschungsfrage ist die Arbeit wie folgt gegliedert. Im theoretischen Hintergrund wird zunächst der Kontext der Arbeit erläutert und die Kernelemente der Forschungsfrage betrachtet. Dabei wird das BGKH als Setting vorgestellt. Im darauffolgenden Kapitel wird der Begriff CDSS definiert, verschiedene Klassifikationen dargestellt und die Funktionen sowie die damit verbundenen Vorteile erläutert. In der Arbeit wird vor allem die Anwenderseite betrachtet, während die technischen Details der Systementwicklung nur in Grundzügen erläutert werden. Ebenso werden die potenziellen Herausforderungen und Nachteile von CDSS diskutiert. Anschließend wird der Begriff „Akzeptanz“ definiert und es werden relevante wissenschaftliche Akzeptanzmodelle vorgestellt. Anschließend wird der aktuelle Forschungsstand zur Akzeptanz von CDSS anhand ausgewählter Studien zusammengefasst. Im darauffolgenden Kapitel werden die konkreten Ziele der Arbeit formuliert und darauf basierend Hypothesen aufgestellt. Die Methodik beschreibt die Vorgehensweise zur Beantwortung der Forschungsfrage einschließlich der Datenerhebung, der Stichprobe und der eingesetzten Messinstrumente. Dabei werden sowohl die abhängigen als auch die unabhängigen Variablen vorgestellt. Zudem wird die statistische Vorgehensweise erläutert, die in eine deskriptive, bivariate und multivariate Analyse unterteilt ist. Es folgen die Ergebnisse, die eine Beschreibung der Stichprobe, die Resultate der Korrelationstests sowie die Analysen der einfachen und multiplen linearen Regression umfassen. Die Ergebnisse werden im darauffolgenden Kapitel diskutiert. Diese werden zusammengefasst, kritisch im Forschungskontext eingordnet und mit der bestehenden Literatur verglichen. Zudem werden die Limitationen und Stärken der Arbeit reflektiert. Abschließend werden die zentralen Erkenntnisse im Fazit zusammengefasst und ein Ausblick auf mögliche Implikationen für Forschung und Praxis gegeben.

2. Theoretischer Hintergrund

Zunächst wird im folgenden Kapitel das BGKH als Untersuchungssetting der Arbeit vorgestellt. Anschließend werden CDSS in Bezug auf Definition, Historie, Klassifikation, Funktionsweise sowie Chancen und Herausforderungen erläutert. Abschließend wird die Akzeptanz behandelt, wobei Definitionen sowie zwei zentrale Modelle der Akzeptanzforschung vorgestellt werden.

2.1 BG Klinikum Hamburg gGmbH (BGKH)

Im folgenden Kapitel wird die Einrichtung des BGKH näher beschrieben. Das BGKH wurde im Jahr 1959 unter dem Namen „Unfallnachbehandlungskrankenhaus“ in Hamburg in den Boberger Dünen eröffnet (BGKH, o.J. g). In den folgenden Jahrzehnten hat sich die Einrichtung kontinuierlich weiterentwickelt. Heute liegt der Schwerpunkt des Behandlungsangebots auf der Akutversorgung sowie der Rehabilitation von berufserkrankten und schwerstverletzten Menschen, mit dem Ziel einer ganzheitlichen medizinischen Betreuung (BGKH, o.J. c).

Das BGKH ist eines von neun Akutkrankenhäusern im bundesweiten Klinikverbund der BG Kliniken mit einem Hauptsitz in Berlin (BGKH, o.J. a). Insgesamt umfasst der Klinikverbund 13 Einrichtungen, darunter neben den neun Akuthäusern auch eine Spezialklinik für Berufskrankheiten, eine Rehaklinik sowie zwei ambulante Kliniken (BGKH, o.J. b). Mit mehr als 18.000 Mitarbeitenden behandeln die BG Kliniken jährlich über eine halbe Million Patient:innen und sind damit der größte öffentlich-rechtliche Krankenhauskonzern in Deutschland (BG Kliniken o.J.). Die Träger des Klinikums sind die gewerblichen Berufsgenossenschaften und mehrere Unfallkassen. Das BGKH ist somit Teil der gesetzlichen Unfallversicherung in Deutschland (BGKH, o.J. f). Ihre Hauptaufgabe liegt dabei in der Verhütung arbeitsbedingter Risiken sowie der umfassenden Betreuung nach Arbeitsunfällen oder Berufskrankheiten. Ziel ist es, Betroffene medizinisch, beruflich und sozial so zu unterstützen, dass sie möglichst wieder aktiv am Leben und am Arbeitsleben teilhaben können (BGKH, o.J. a).

Am Standort Hamburg sind über 2.500 Beschäftigte tätig (BGKH, o.J. e). Darunter befinden sich über 800 Mitarbeitende aus der Pflege. Sie stellen die größte Berufsgruppe im BGKH dar (BGKH, o.J. h). Das Personal der Therapiebereiche umfasst etwa 350 Mitarbeitende. Als zertifiziertes überregionales Traumazentrum übernimmt das BGKH eine zentrale Rolle in der Notfallversorgung in ganz Norddeutschland. Zu den weiteren medizinischen Schwerpunkten zählt unter anderem die Behandlung querschnittgelähmter Menschen im Querschnittsgelähmten-Zentrum (QZ), die Versorgung von schweren Brandverletzungen sowie die neurochirurgische und septische Chirurgie (BGKH, o.J. c; BGKH, o.J. d). Die enge Verbindung von Akutmedizin und Rehabilitation ermöglicht eine durchgehende Betreuung der Patient:innen. Diese reicht von der Erstversorgung am Unfallort bis zur Wiedereingliederung ins Berufsleben. Neben den Patient:innen der Berufsgenossenschaft übernimmt das Klinikum einen allgemeinen Versorgungsauftrag und behandelt auch gesetzlich und privat versicherte Patient:innen. (BGKH, o.J. f).

2.2 Klinische Entscheidungsunterstützungssysteme (CDSS)

Zunächst wird definiert, was unter CDSS zu verstehen ist und welche Ziele mit ihrem Einsatz verfolgt werden. Anschließend wird der Unterschied zwischen wissensbasierten und nicht-wissensbasierten CDSS erläutert. Auf dieser Grundlage werden die zentralen Funktionen sowie die Vor- und Nachteile von CDSS dargestellt. Abschließend werden praxisnahe Anwendungsbeispiele vorgestellt.

Für CDSS existiert bislang keine einheitliche Definition. Im Allgemeinen werden sie jedoch als Computerprogramme beschrieben, die medizinisches Personal unmittelbar bei klinischen Entscheidungen bzw. in der Entscheidungsfindung unterstützen sollen (Sim et al., 2001, S. 528; Elhaddad & Hamam, 2024, S. 1). Grundlage dieser Systeme ist ein Wissenssystem, das aus medizinischem Wissen, Algorithmen und Patientendaten besteht (Elhaddad & Hamam, 2024, S. 1). Durch den Abgleich der jeweiligen Patientendaten mit dieser Wissensbasis wird eine fallbezogene medizinische Einschätzung generiert (Shahsavarani et al., 2015, S. 302). Das Ziel von CDSS besteht darin, das medizinische Personal in der Behandlungssituation durch umsetzbare Einsichten, evidenzbasierte Empfehlungen und patientenspezifische Informationen bestmöglich zu unterstützen. Damit sollen vor allem die diagnostische Genauigkeit erhöht, die Behandlungseffektivität gesteigert und die Patientensicherheit verbessert werden (Elhaddad & Hamam, 2024, S. 1). Insgesamt lässt sich festhalten, dass CDSS einen zentralen Bestandteil des Wissens- und Informationsmanagements im Gesundheitswesen darstellen (Wasylewicz & Scheepers-Hoeks, 2018, S. 153; Shahsavarani et al., 2015, S. 302).

Die ersten Ansätze von CDSS lassen sich auf das Ende der 1950er Jahre zurückführen. In einem Artikel beschrieben Ledley und Lusted (1959) die Idee, Computer als unterstützende Werkzeuge für Ärzt:innen einzusetzen. Dabei sollten die Systeme Symptome und Befunde anhand von Eintrittswahrscheinlichkeiten und Leitlinien analysieren, um die wahrscheinlichste Diagnose zu ermitteln (Ledley & Lusted, 1959, S. 20–21). Dies begründete ein neues Forschungsfeld in der Medizin (Chen et al., 2023, S. 1).

In den 1970er Jahren wurden die ersten CDSS implementiert, darunter Systeme zur Unterstützung der Antibiotikawahl und zur Diagnose komplexer Krankheitsbilder. Diese frühen Systeme arbeiteten regelbasiert, indem medizinisches Wissen nach dem Ursache-Wirkungs-Prinzip kodiert wurde. Mit der zunehmenden Bedeutung der evidenzbasierten Medizin wurden CDSS zunehmend auf klinische Praxisempfehlungen und evidenzbasierte Leitlinien abgestützt (Chen et al., 2023, S. 1–2).

Ab den 2010er Jahren integrierten CDSS zunehmend KI und maschinelles Lernen. Durch die Verarbeitung großer Datensätze ist es möglich, personalisierte Empfehlungen für Patient:innen zu erstellen. Parallel dazu wurden mobile Gesundheitsanwendungen entwickelt, die CDSS integrieren und Patient:innen die Überwachung ihrer Gesundheitsdaten sowie deren Einbindung in die Versorgung ermöglichen (ebd., S. 1–2).

2.2.1 Klassifikation

Bei der Klassifikation von CDSS wird häufig zwischen wissensbasierten und nicht wissensbasierten Systemen unterschieden (s. Abbildung 1).

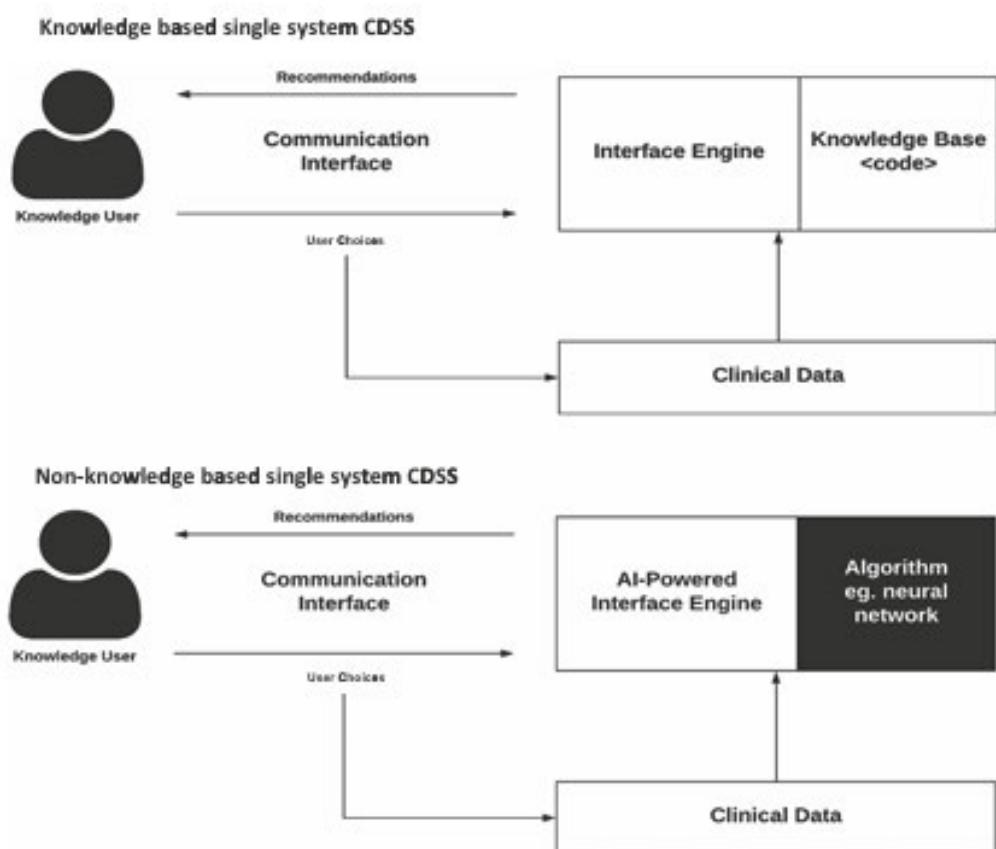


Abbildung 1: Zentrale Interaktionen von wissensbasierten und nicht-wissensbasierten klinischen Entscheidungsunterstützungssystemen (CDSS), Quelle: Sutton et al., 2020, S. 2.

Beide Klassifikationen sind vom Grundkonstrukt gleich aufgebaut. Die Nutzende Person kommuniziert mit dem CDSS über einen Kommunikationsmechanismus. Dieser bildet die Schnittstelle zwischen Nutzenden und dem System. Die Eingaben werden an die Verarbeitungseinheit des CDSS weitergegeben, die sich unterscheiden kann. Wissensbasierte CDSS bestehen im Kern aus zwei zentralen Komponenten, einer

Wissensbasis und einer Inferenzmaschine. Die Wissensbasis beinhaltet medizinisches Fachwissen in Form von Regeln, Vorschriften und Verknüpfungen. Dies wird in der Regel in Form einer Ursache-Wirkungs-Beziehung dargestellt. Die Inferenzmaschine verbindet die in der Wissensbasis formulierten Regeln mit den Patientendaten. Die generierten Ergebnisse werden schließlich über den Kommunikationsmechanismus den Nutzenden bereitgestellt (Shahsavarani et al., 2015, S. 304).

Bei nicht-wissensbasierten Systemen wird hingegen ohne festgelegte Wissensbasis gearbeitet. Sie nutzen stattdessen Verfahren des maschinellen Lernens, das eine Form der Künstlichen Intelligenz (KI) darstellt. Auf diese Weise können die Systeme aus vorhandenen Daten lernen oder wiederkehrende Muster in klinischen Informationen erkennen. Technisch gesehen basieren sie häufig auf künstlichen neuronalen Netzen (Shahsavarani et al., 2015, S. 304). Ein neuronales Netz ist schichtweise aufgebaut. Es verfügt über eine Eingabeschicht zur Aufnahme von Informationen sowie eine Ausgabeschicht zur Ausgabe der Ergebnisse. Dazwischen liegen versteckte Schichten, in denen die Daten verarbeitet werden. Jede Schicht besteht aus Neuronen, die über Kanten miteinander verbunden sind und so Informationen weiterleiten (Sonnet et al., 2022, S. 26).

2.2.2 Funktionen und Vorteile

Die Funktionsweisen von CDSS sind vielfältig und hängen stark davon ab, wie die Systeme für das jeweilige Einsatzgebiet konzipiert und programmiert werden. In diesem Kapitel werden die zentralen Funktionen zusammengefasst und anhand ausgewählter Praxisbeispiele veranschaulicht. In einem Review geben Sutton et al. (2020) einen Überblick über wesentliche Funktionen sowie Vor- und Nachteile von CDSS.

Ein wesentlicher Aspekt von CDSS ist die Verbesserung der Patientensicherheit, insbesondere durch die Verringerung von Medikationsfehlern (Sutton et al., 2020, S. 2). Eine dänische Studie zeigte, dass 63,60 % der Krankenhausaufnahmen mindestens einer möglichen Arzneimittelwechselwirkung ausgesetzt waren ($n = 2.886.227$) (Rodríguez et al., 2022, S. 635). Computergestützte Verordnungssysteme (CPOE) könnten dabei helfen, dieses Risiko zu reduzieren. Dafür werden Dosierungen überprüft, Doppelverordnungen verhindert und mögliche Wechselwirkungen erkannt. Warnmeldungen aus diesen Systemen zählen zu den am häufigsten eingesetzten CDSS, werden jedoch teilweise als störend empfunden (Sutton et al., 2020, S. 2).

Elektronische Systeme zur Medikamentenausgabe und Barcodesysteme tragen dazu bei, dass die verabreichten Medikamente automatisch mit den Patientendaten abgeglichen werden. Dadurch können Fehler am Patientenbett deutlich reduziert werden.

Eine Studie hat gezeigt, dass sich durch derartige Systeme 41 % der Fehler bei der Medikamentenabgabe sowie 51 % potenzieller unerwünschter Arzneimittelwechselwirkungen reduzieren ließen ($n = 1726$) (Poon et al., 2010, S. 1701). Trotz nachgewiesener Wirksamkeit sind derartige CDSS bislang noch nicht flächendeckend implementiert wurden. Beweggründe hierfür sind unter anderem hohe Anschaffungs- und Technologieanforderungen (Sutton et al., 2020, S. 2).

Insgesamt können CDSS dazu beitragen, die Kosten im Gesundheitssystem effizient zu steuern. Dies gelingt beispielsweise durch kürzere Krankenhausaufenthalte, wirtschaftlichere Arzneimittelwahl und das Vermeiden von Doppeluntersuchungen (Sutton et al., 2020, S. 5). Ein Beispiel aus der Pädiatrie zeigt, dass die Begrenzung von Blut- und Gerinnungstests auf ein 24-Stunden-Intervall erfolgreich umgesetzt werden konnte. Dadurch konnten jährliche Kosten von rund 717.000 US-Dollar eingespart werden, ohne dass sich die Aufenthaltsdauer oder die Sterblichkeit der Patient:innen veränderten (Algaze et al., 2016, S. 1–4). Auch bei der Medikamentenumstellung in Deutschland haben CDSS Vorteile mitgebracht. Ein weiteres Beispiel ist ein am Heidelberger Krankenhaus entwickelter Algorithmus, der Verschreibungen automatisch überprüft und bei Bedarf die korrekte Alternative auswählt. So konnten über 90 % der Medikamentenumstellungen fehlerfrei durchgeführt werden. Dies hat zu einer Erhöhung der Patientensicherheit, einer Reduzierung des Arbeitsaufwandes und zu Kosteneinsparungen geführt (Pruszydlo et al., 2012, S. 6).

Ein weiterer Vorteil von CDSS besteht darin, dass sie die Einhaltung klinischer Leitlinien unterstützen. Dies ist besonders relevant, da Untersuchungen zeigen, dass medizinisches Personal Leitlinien und Behandlungspfade nur unzureichend umsetzt. Die Annahme, dass neue Leitlinien automatisch gelesen und angewendet werden, ist somit nicht zutreffend (Cabana et al., 1999, S. 1461–1462). Um dem entgegenzuwirken, könnten die Inhalte von Leitlinien direkt in ein CDSS integriert werden. Daraus ergeben sich beispielsweise standardisierte Verordnungssets für bestimmte Fälle, Hinweise zu spezifischen Behandlungsprotokollen oder Erinnerungen an notwendige Tests. CDSS können darüber hinaus die Durchführung von Forschungs- und Behandlungsprotokollen erleichtern, beispielsweise durch die Organisation und Nachverfolgung von Maßnahmen oder Überweisungen. Auch die Identifikation geeigneter Patient:innen für klinische Studien wird dadurch unterstützt (Sutton et al., 2020, S. 5).

Ein zentraler Aspekt von CDSS ist die patientenorientierte Entscheidungsunterstützung. Personal Health Records (PHR) ermöglichen es Patient:innen, ihre elektronische Patientenakte (ePA) einzusehen und teilweise selbst Änderungen vorzuneh-

men. Dadurch werden sie aktiv in die Versorgung eingebunden. Dies fördert eine informierte Teilhabe sowie die gemeinsame Entscheidungsfindung mit Ärzt:innen. PHR können webbasiert sein oder in die ePA integriert werden. Letzteres ermöglicht eine bidirektionale Kommunikation (Sutton et al., 2020, S. 6). Ein Beispiel hierfür ist „MyHealthAtVanderbilt“, das Informationen zu Krankheitsbildern sowie ein Grippe-Tool bereitstellt. Mithilfe dieses Tools können Patient:innen mit grippeähnlichen Symptomen die Dringlichkeit einer ärztlichen Konsultation einschätzen und passende Versorgungsoptionen wählen (Rosenbloom et al., 2012, S. 549–551). Gesundheitsgeräte und Wearables, wie beispielsweise Fitnessuhren oder Glukosemessgeräte, erweitern das PHR, indem sie kontinuierlich Daten erfassen. Diese können von Ärzt:innen für individuelle Empfehlungen genutzt werden. An der Stanford School of Medicine wurde ein Glukosemessgerät entwickelt, das die Daten eines Apple-Geräts automatisch über das HealthKit an die ePA überträgt. Über das Tool „MyChart“ war ein Austausch zwischen Patient:innen und Ärzt:innen über die Glukosetrends möglich (Kumar et al., 2016, S. 1–3). Dadurch konnten die Arbeitsabläufe, die Versorgungsqualität und die Kommunikation zwischen Ärzt:innen und Patient:innen verbessert werden (ebd., S. 4–5).

Zu den weiteren Funktionen von CDSS zählen administrative Aufgaben wie die Kodierung klinischer und diagnostischer Daten, die Anordnung von Tests oder die Unterstützung bei der Triage. Mithilfe von Algorithmen können CDSS Ärzt:innen Kodierungen nach der International Classification of Diseases (ICD) vorschlagen. Dies kann die Suche nach der passenden Kodierung erleichtern und Zeit sparen (Sutton et al., 2020, S. 5). Dieses Vorhaben wurde am Scripps Research Translational Institute in einer Notaufnahme erprobt. Dort standen den Ärzt:innen ein anatomographisches Interface zur Verfügung, das den menschlichen Körper visuell und interaktiv darstellt. Dadurch konnte die ICD-Kodierung schneller und präziser vorgenommen werden (Bell & Mensah, 2013, S. 3). Studien deuten darauf hin, dass CDSS die Qualität der Dokumentation im klinischen Alltag verbessern können (Sutton et al., 2020, S. 5).

Zur diagnostischen Unterstützung werden sogenannte Diagnostic Decision Support Systems (DDSS) eingesetzt. DDSS erstellen auf Basis eingegebener Daten oder Befunde eine Liste möglicher oder wahrscheinlicher Diagnosen (Sutton et al., 2020, S. 7). Zu Beginn waren DDSS durch negative Wahrnehmungen von Ärzt:innen, Datenlücken und mangelnde Integration in klinische Systeme eingeschränkt (Segal et al., 2017, S. 15–17). Moderne Systeme sind besser in die ePA integriert und nutzen standardisierte Vokabulare wie die SNOMED Clinical Terms. (Sutton et al., 2020, S. 7). In einer randomisierten Studie erzielten Allgemeinmediziner:innen mit dem

CDSS „DXplain“ eine diagnostische Genauigkeit von 82,4 %, während ohne das System eine Genauigkeit von 74,1 % erzielt wurde ($n = 87$) (Martinez-Franco et al., 2018, S. 4–5). DDSS können insbesondere in der Primärversorgung die klinische Expertise ergänzen und fehleranfällige Bereiche zu unterstützen (Sutton et al., 2020, S. 7).

Zusätzlich können CDSS Ärzt:innen bei der Anforderung und Auswertung bildgebender Verfahren unterstützen. Die Systeme prüfen beispielsweise, ob die gewählte Untersuchung angemessen ist, erinnern an Leitlinien und geben Hinweise auf mögliche Kontraindikationen (Georgiou et al., 2011, S. 337–338). Oft werden im Bereich der Radiologie KI-basierte CDSS verwendet zur Auswertung radiologische Bilder, erkennen Tumore und kombinieren Bilddaten, um die Diagnosegenauigkeit zu verbessern (Oakden-Rayner et al., 2017, S. 6–8).

2.2.3 Herausforderungen und Nachteile

Trotz der zahlreichen Funktionen und potenziellen Vorteile von CDSS können bei der Einführung und Nutzung unterschiedliche Herausforderungen auftreten. Diese werden im Folgenden dargestellt.

Ein Nachteil von CDSS besteht darin, dass sie Arbeitsabläufe stören können. Dies ist insbesondere dann der Fall, wenn die Systeme eigenständig arbeiten und Ärzt:innen zwischen mehreren Programmen wechseln müssen. Dies ist bei weniger entwickelten CDSS häufiger der Fall, da die Software nicht optimal in bestehende Prozesse integriert ist. Zudem sind CDSS oft nicht auf die menschliche Informationsverarbeitung abgestimmt, sodass ihre Funktionsweise für Nutzeden teilweise schwer nachvollziehbar ist. Dies kann zu Verzögerungen, erhöhter kognitiver Belastung und längeren Bearbeitungszeiten führen (Sutton et al., 2020, S. 6–7). Um diese Effekte zu minimieren, kommen in modernen Systemen Methoden wie Think-Aloud-Protokolle zum Einsatz. Diese evaluieren den Arbeitsprozess und verbessern die Benutzerfreundlichkeit (Kilsdonk et al., 2015, S. 17–18). Ein weiterer Kritikpunkt ist auch, dass CDSS die Interaktion mit Patient:innen verändern können, da ein größerer Anteil der Arbeit am Computer stattfindet. Dies reduziert den persönlichen Kontakt und beeinträchtigt möglicherweise die Kommunikation (Sutton et al., 2020, S. 7).

Ein weiterer wichtiger Aspekt ist die Anwenderkompetenz. Vor der Einführung von CDSS und CPOE lag die Verantwortung für die Überprüfung ärztlicher Anordnungen vollständig bei Apotheker:innen und dem medizinischen Personal. Durch CDSS kann jedoch der Eindruck für Nutzende entstehen, dass eine Gegenprüfung nicht mehr nötig sei, da das System die Arbeit übernimmt. Dies entspricht jedoch nicht der Realität (Ash et al., 2007, S. 27). Gleichzeitig besteht die Gefahr, dass Anwender:innen dem

System zu stark vertrauen und Entscheidungen nicht mehr kritisch hinterfragen (Goddard & Wyatt, 2011, S. 3–4). Dies kann problematisch werden, wenn CDSS nicht verfügbar sind, beispielsweise bei einem Arbeitsplatzwechsel oder einem Systemausfall (Sutton et al., 2020, S. 7).

Ein weiterer Aspekt betrifft die Finanzierung von CDSS. In einer Umfrage gaben 74 % der Nutzenden an, dass eine vollständige Finanzierung eine zentrale Herausforderung darstellt (Kabachinski, 2013, S. 434). Die Gründe hierfür sind die laufenden Kosten für kontinuierliche Schulungen und Systemaktualisierungen. Studien zu diesem Thema sind begrenzt und liefern teils widersprüchliche Ergebnisse. Da die Finanzierung stark von politischen und technologischen Rahmenbedingungen abhängt, besteht weiterer Forschungsbedarf (Sutton et al., 2020, S. 8).

Die Computerkompetenz der Nutzenden stellt eine weitere Herausforderung dar. Studien zeigen, dass mangelnde technologische Fähigkeiten die Nutzung von CDSS erschweren können. Die Kompetenz der Anwender:innen beeinflusst dabei, wie komplex die Systeme wahrgenommen werden (Devaraj et al., 2014, S. 41). Entwickler:innen sollten darauf achten, CDSS nahtlos an bestehende Systeme anzupassen. Darüber hinaus ist es wichtig, ausreichend Einarbeitungszeit einzuplanen und Schulungen sowie integrierte Anleitungen im System bereitzustellen, um eine effektive und sichere Nutzung zu gewährleisten (Sutton et al., 2020, S. 7).

Eine weitere Herausforderung bei der Nutzung von CDSS ist die sogenannte Alarmmüdigkeit. Diese entsteht durch häufige oder unnötige Alarrrmeldungen. Studien zeigten, dass bis zu 95 % der Alarre irrelevant sind, weshalb Ärzt:innen ihnen oft misstrauen oder ihre Dringlichkeit nicht einschätzen können. Um dieser Problematik entgegenzuwirken, sollten Alarre nur bei lebensbedrohlichen Situationen oder schwerwiegenden Kontraindikationen ausgelöst werden (Ash et al., 2007, S. 28). Ein zusätzliches Problem ist, dass Medikationsalarre stark vom Fachbereich und dem klinischen Kontext abhängen. So werden beispielsweise bei entzündlichen Darmerkrankungen wie Morbus Crohn oder Colitis ulcerosa bestimmte Medikamente sowohl oral als auch intravenös verabreicht, um die Wirkung zu verstärken. In solchen Fällen kann das CDSS fälschlicherweise eine Fehlermeldung erzeugen, obwohl die Therapie korrekt ist (ebd., S. 28).

Die Wartung von CDSS stellt ebenfalls eine zentrale Herausforderung dar. Dazu gehören technische Aufgaben wie die Aktualisierung von Anwendungen und Datenbanken, die für den Betrieb erforderlich sind. Hinzu kommt, dass sich medizinisches Wissen kontinuierlich weiterentwickelt, beispielsweise durch neue klinische Leitlinien. Ein

CDSS muss daher regelmäßig an den aktuellen Stand der Forschung angepasst werden, was selbst für fortschrittliche Einrichtungen eine erhebliche Belastung darstellt (Ash et al., 2007, S. 27).

Eine weitere Herausforderung für CDSS ist die fehlende Interoperabilität. Seit rund drei Jahrzehnten werden CDSS meist als eigenständige Systeme entwickelt, die nicht mit anderen Anwendungen verknüpft sind (Sutton et al., 2020, S. 7). Gründe hierfür sind die komplexen Programmierungen und die Vielzahl an Datenquellen (Sujansky, 2001, S. 288). Hinzu kommt der sensible Umgang mit Patientendaten, der strengen Datenschutzanforderungen unterliegt. In den letzten Jahren wurden jedoch Fortschritte erzielt, etwa durch die bereits implementierten und teilweise verpflichtend genutzten Fast Healthcare Interoperability Resources (Sutton et al., 2020, S. 7). Auch Cloud-Lösungen könnten zur Datensynchronisation und Softwareaktualisierung beitragen. Trotz verbreiteter Vorbehalte sind sie nicht unsicherer als serverbasierte Speicherungen, da sie denselben Risiken unterliegen und zugleich strenge Datenschutz- und Sicherheitsstandards wie die Datenschutz-Grundverordnung erfüllen (Rodrigues et al., 2013, S. 7).

Die Qualität der Daten ist eine zentrale Herausforderung bei der Implementierung von ePAs und CDSS. CDSS können zwar idealisierte Empfehlungen liefern, berücksichtigen jedoch häufig nicht praktische Faktoren, wie die Verfügbarkeit von Medikamenten (Ash et al., 2007, S. 28). Ein weiteres Beispiel sind Medikationslisten, anhand derer Ärzt:innen zwar erkennen können, dass ein Medikament abgegeben wurde, jedoch nicht, ob es von den Patient:innen tatsächlich eingenommen wurde (ebd., S. 28). Dies führt zu zusätzlichen Arbeitsschritten, anstatt die Prozesse zu vereinfachen. Systeme mit einer differenzierten Erfassung, wie sie in PHRs integriert sind, können hier Abhilfe schaffen (Sutton et al., 2020, S. 7). In schlecht konfigurierten Systemen entwickeln Nutzende häufig sogenannte „Workarounds“, indem sie die gewünschten Eingaben durch falsche Daten umgehen. Dadurch sinkt die Datenqualität weiter. Dies hat insbesondere bei nicht-wissensbasierten CDSS, die aus den Daten lernen, erhebliche Auswirkungen auf die Qualität der Empfehlungen (Ash et al., 2007, S. 28).

2.3 Akzeptanz

Der Begriff „Akzeptanz“ stammt vom lateinischen „acceptare“ und bedeutet etwas „annehmen“ oder „sich gefallen lassen“ (Brockhaus, 2006, S. 432). Unter der Akzeptanz wird „*die bejahende oder tolerierende Einstellung von Personen oder Gruppen gegenüber normativen Prinzipien oder Regelungen, im materiellen Bereich gegenüber der Entwicklung und Verbreitung neuer Techniken oder Konsumprodukte*“

(Brockhaus, 2006, S. 432) verstanden. Darunter lässt sich das freiwillige und aktive Annehmen, Billigen oder Anerkennen von etwas oder jemandem verstehen (Klosa, 2016, S. 72).

Der Ursprung der Akzeptanzforschung liegt in der Arbeitswissenschaft und der Betriebswirtschaftslehre. Heute wird sie als Teilgebiet der sozialwissenschaftlichen Begleitforschung verstanden. Im Mittelpunkt steht dabei die Anwenderperspektive im Hinblick auf Innovationen. Ziel ist es, Faktoren, Ursachen und Wirkungsketten zu identifizieren, die zur Annahme oder Ablehnung von Innovationen führen (ebd., S. 73). Die Forschung befasst sich mit materiellen Technologien wie Maschinen oder Geräten. Ebenso werden immaterielle Technologien wie digitale Plattformen oder Apps untersucht. Berücksichtigt werden dabei sowohl bereits am Markt etablierte als auch noch nicht eingeführte Technologien und Dienstleistungen (Scheuer, 2020, S. 25).

In der Akzeptanzforschung existieren verschiedene theoretische Modelle, die Faktoren identifizieren, die die Annahme von Technologien beeinflussen. Im Folgenden werden insbesondere das Technology Acceptance Model (TAM) und die Unified Theory of Acceptance and Use of Technology (UTAUT) vorgestellt, da diese zu den bekanntesten und am häufigsten verwendeten Modellen zählen.

2.3.1 Technology Acceptance Model (TAM)

In früherer Forschung wurden verschiedenste technologische, individuelle und organisatorische Aspekte in Zusammenhang mit der Akzeptanz zur Nutzung von neuen Systemen untersucht. Die Determinanten auf die Nutzerakzeptanz konnten augrund fehlender validierter Messinstrumente bedingt erforscht werden. Vor diesem Hintergrund entwickelte Davis (1989) das TAM, das darauf abzielt, die Akzeptanzbereitschaft von Nutzenden im Umgang mit neuen Technologien besser zu

erklären und vorherzusagen (S. 319–320) (s. Abbildung 2). Das TAM basiert auf der Theory of Reasoned Action nach Fishbein und Ajzen (1975).

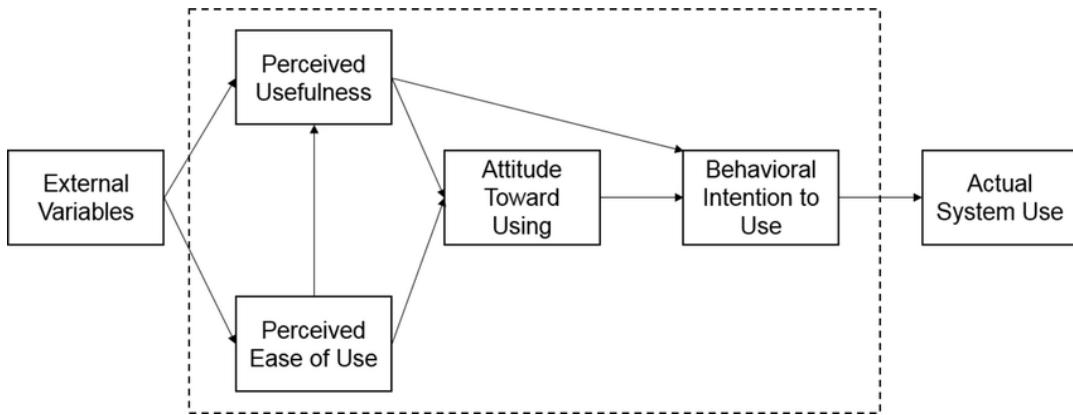


Abbildung 2: Technology Acceptance Model (TAM), Quelle: Davis et al., 1989, S. 985.

Das TAM hat die wahrgenommene Nützlichkeit und die wahrgenommene Benutzerfreundlichkeit als zentrale Determinanten identifiziert. Die wahrgenommene Nützlichkeit beschreibt die Verbesserung der Arbeitsleistung eines Individuums mithilfe neuer Technologien. Die wahrgenommene Benutzerfreundlichkeit bezieht sich dagegen darauf, wie einfach und ohne großen Aufwand ein System aus Sicht der Nutzenden bedient werden kann. Das TAM geht davon aus, dass je geringer der wahrgenommene Aufwand ist, desto höher ist die Wahrscheinlichkeit, dass ein System tatsächlich genutzt wird (ebd., S. 320). Diese Determinanten haben einen Einfluss auf die Einstellung gegenüber der Nutzung neuer Technologien. Definiert wird diese Entstellung als das Interesse der Nutzenden hinsichtlich der Nutzung der neuen Technologie (Wiprayoga & Widagda, 2023, S. 57). Die Einstellung gegenüber der Nutzung und die wahrgenommene Nützlichkeit wirken sich auf die Nutzungsabsicht (NA) aus, welche wiederum die den tatsächlichen Nutzen von neuen Systemen beeinflusst (Davis, 1989, S. 332–333).

2.3.2 Unified Theory of Acceptance and Use of Technology (UTAUT)

Venkatesh et al. (2003) betonten, dass es in der Forschung eine Vielzahl konkurrierender Modelle zur Erklärung der Technologieakzeptanz gab, die uneinheitlich angewendet wurden. Dadurch blieben potenziell relevante Einflussfaktoren auf die Akzeptanz unberücksichtigt. Vor diesem Hintergrund entwickelten sie das UTAUT-Modell. Dieses sollte ein einheitlicheres Verständnis der Nutzerakzeptanz ermöglichen und vorhersagen, ob Individuen neue Technologien annehmen oder ablehnen (Venkatesh et al., 2003, S. 426) (s. Abbildung 3).

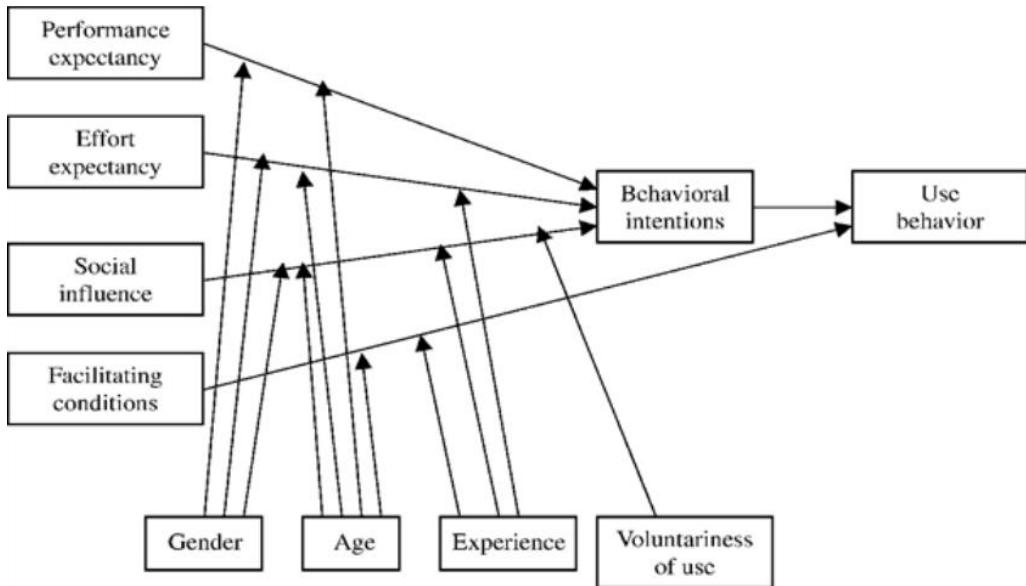


Abbildung 3: Unified Theory of Acceptance and Use of Technology (UTAUT).
Quelle: Venkatesh et al., 2003, S. 447.

Das UTAUT-Modell basiert auf der empirischen Überprüfung von acht theoretischen Modellen, aus denen vier zentrale Determinanten der NA und Nutzungsverhalten abgeleitet wurden. Leistungserwartung (LE), Aufwandserwartung (AA), sozialer Einfluss (SI) und förderliche Bedingungen (FB) stellen die zentralen Determinanten dar. Es wurden zudem vier Moderatoren der NA identifiziert. Dazu zählen Geschlecht, Alter, Erfahrung und die Freiwilligkeit der Nutzung (ebd., S. 446–448).

Die NA beschreibt, inwieweit eine Person plant, ein bestimmtes System in Zukunft zu verwenden. Sie ist ein zentraler Faktor für die Akzeptanz technischer Systeme und wird im UTAUT als Prädiktor des Nutzungsverhaltens verstanden. Das Nutzungsverhalten beschreibt die tatsächliche Nutzung einer Technologie (ebd., S. 447).

Die LE setzt sich aus fünf Konstrukten anderer Theorien zusammen, darunter auch die wahrgenommene Nützlichkeit aus dem TAM. Die LE als Maßstab beschrieben, inwieweit Personen glauben, dass die Nutzung eines Systems ihnen dabei hilft, ihre Leistung am Arbeitsplatz zu verbessern. Die Berechnungen ergaben, dass die LE den stärksten Prädiktor der NA und tatsächlichen Nutzung darstellen (ebd., S. 447).

Als weiteres Konstrukt beschreibt die AA, wie viel Aufwand Personen mit der Nutzung des Systems verbinden bzw. wie einfach sie dessen Bedienung einschätzen. Sie wurde aus den Konstrukten wahrgenommene Nützlichkeit, Komplexität und Benutzerfreundlichkeit verschiedener Modelle abgeleitet (ebd., S. 450).

Der SI hingegen bezieht sich darauf, inwieweit Personen den Eindruck haben, dass ihr soziales Umfeld erwartet, dass sie das neue System nutzen. Der SI vereint dabei die

Konstrukte subjektive Norm, soziale Faktoren und Image aus bestehenden Modellen (ebd., S. 451).

Als letzter direkter Einflussfaktor werden die FB beschrieben. Diese umfassen die Einschätzung von Personen, ob ausreichende organisatorische und technische Rahmenbedingungen vorhanden sind, die die Nutzung des Systems unterstützen. Diese wurden aus den Konstrukten wahrgenommene Verhaltenskontrolle, erleichternde Bedingungen und Kompatibilität abgeleitet (ebd., S. 453).

Empirische Tests zeigten, dass das UTAUT-Modell etwa 70 % der Varianz der NA und 50 % der Varianz des tatsächlichen Nutzungsverhaltens erklären konnte (ebd., S. 447).

2.4 Forschungsstand

Dieses Kapitel widmet sich dem aktuellen Forschungsstand zu CDSS sowie der Akzeptanz von Mitarbeitenden. Dazu werden sieben Studien hinsichtlich ihrer methodischen Ansätze und zentralen Ergebnisse vorgestellt.

In einer Mixed-Methods-Querschnittsstudie von Berge et al. (2023) wurde in Norwegen ein CDSS für den Bereich Anästhesie während der frühen Implementierungsphase evaluiert (ebd., S. 2–5). Das System „Information System for Clinical Concept-based Search“ war ein Natural Language Processing-Tool zur Identifikation und Klassifikation von Allergien in der ePA. Ziel war es, die Bewertung durch Anwender:innen und den Zusammenhang mit der tatsächlichen Nutzung zu untersuchen (ebd., S. 2). Hierfür wurden Interviews und Fragebögen auf Basis des UTAUT-Modells durchgeführt, die Konstrukte mittels fünfstufiger Likert-Skala erfassten. Die Stichprobe bestand aus Ärzt:innen ($n = 8$) und Pflegekräften ($n = 44$) (ebd., S. 4–6). Die Analyse zeigte, dass LE sowohl mit der NA ($r_s = 0,466; p < 0,001$), als auch der tatsächlichen Nutzung ($r_s = 0,590; p < 0,001$) signifikant positiv korrelierte. Ebenso steht die AA in einem signifikanten positiven Zusammenhang mit der NA ($r_s = 0,544; p < 0,001$) sowie der tatsächlichen Nutzung ($r_s = 0,528; p < 0,001$). Auch der SI korreliert signifikant positiv mit der NA ($r_s = 0,361; p = 0,009$). Darüber hinaus korreliert die NA signifikant positiv mit der tatsächlichen Nutzung ($r_s = 0,487; p < 0,001$) (ebd., S. 9). Die FB, Geschlecht, Alter und Erfahrung zeigten keine signifikanten Zusammenhänge (ebd., S. 9–10). Die Studie zeigte, dass LE, AA und SI in der Implementierungsphase eine Rolle für die NA und die tatsächliche Nutzung spielen können.

Dingel et al. (2024) führten eine Meta-Analyse durch, in der der relative Beitrag der UTAUT-Prädiktoren sowie zusätzlicher Faktoren zur Erklärung der NA von KI-gestützten CDSS untersucht wurde (ebd., S. 5–6). Dazu wurde ein erweitertes UTAUT-Modell entwickelt, welches Variablen wie Einstellung, Vertrauen (VT), Risiko, Angst und persönliche Innovationskraft miteinbezog (ebd., S. 4). Die Zielgruppe umfasste medizinisches Personal ($n = 3871$) aus insgesamt 17 Studien, die nach den Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA)-Richtlinien identifiziert und ausgewertet wurden (ebd., S. 6–7). Die stichprobengrößeengewichteten und reliabilitätskorrigierten Korrelationen zeigten, dass LE ($r = 0,66$; 95%-KI: 0,59–0,73), AA ($r = 0,55$; 95%-KI: 0,43–0,67) und SI ($r = 0,66$; 95%-KI: 0,59–0,72) stark positiv mit der NA zusammenhängen. Ähnliche Zusammenhänge wurden für Einstellung ($r = 0,63$; 95%-KI: 0,52–0,73), VT ($r = 0,73$; 95%-KI: 0,63–0,82) und persönliche Innovationskraft ($r = 0,54$; 95%-KI: 0,43–0,64) beobachtet. Der Zusammenhang mit den FB ($r = 0,66$; 95%-KI: 0,42–0,90) bleibt aufgrund von weniger als zwei unabhängigen Datensätzen unklar (ebd., S. 8–9). Das multiple Regressionsmodell mit den Prädiktoren des UTAUT-Modells erklärte 49,8 % der Varianz der NA ($p < 0,001$), wobei die LE allein 31 % der Varianz beitrug. Erweiterte Modelle zeigten, dass VT einen besonders starken Einfluss ausübt und in allen drei Modellen zwischen 38 % und 42 % der Varianz der NA erklärt ($p < 0,001$) (ebd., S. 9–10). Ein Moderationseffekt bestand zwischen Alter und SI im Zusammenhang mit der NA ($p = 0,03$) (ebd., S. 11). Die Ergebnisse zeigten, dass LE, AA und SI sowie zusätzliche Faktoren wie VT, Einstellung und persönliche Innovationskraft die NA von KI-gestützten CDSS bei medizinischem Personal beeinflussen können.

Eine weitere Querschnittsstudie von Cornelissen et al. (2022) untersuchte die Einführung von KI-gestützten CDSS und die Faktoren, die deren Akzeptanz beeinflussen. Dafür wurde eine Behandlungspfadtechnologie entwickelt, die die Verwaltung chronischer Erkrankungen unterstützen soll. Hierfür wurde medizinisches Personal eines niederländischen Krankenhauses per Online-Umfrage befragt ($n = 111$) (ebd., S. 2). Neben den Konstrukten des UTAUT-Modells wurden auch wahrgenommenes VT, Angst, berufliche Identität und Innovationskraft als potenzielle Prädiktoren für die NA untersucht (ebd., S. 3). In dieser Studie wurde die LE in medizinische und nicht-medizinische LE unterteilt. Eine ähnliche Aufteilung zeigt sich bei der SI, bei der der Einfluss von Patient:innen und medizinischen Expert:innen erfasst wurde. Die Variablen wurden über eine fünfstufige Likert-Skala erfasst und mittels einer multiplen linearen Regression ausgewertet (ebd., S. 4). Das Signifikanzniveau wurde hierfür auf $p = 0,1$ festgelegt. Das Modell konnte 75,40 % der Varianz der Akzeptanz KI-gestützter Behandlungspfade des medizinischen Personals erklären ($p < 0,001$). Medizinische LE

($\beta = 0,465$; $p < 0,001$), das wahrgenommene VT ($\beta = 0,221$; $p = 0,007$), die nicht-medizinische LE ($\beta = 0,172$; $p = 0,08$) und die berufliche Identität ($\beta = 0,156$; $p = 0,06$;) zeigten signifikant positive Zusammenhänge mit der Akzeptanz. AA ($\beta = -0,215$; $p = 0,005$) und FB ($\beta = -0,160$; $p = 0,005$) zeigten negative Effekte mit der Akzeptanz (ebd., S. 6). Moderationseffekte von Alter, Erfahrung und Beruf konnten nicht nachgewiesen werden. Lediglich das Geschlecht zeigte im Zusammenhang mit den FB einen schwach positiven Einfluss auf die Akzeptanz ($\beta = 0,406$; $p = 0,09$) (ebd., S. 7). Die Befunde zeigten, dass LE, VT, berufliche Identität, AA und FB Faktoren sind, die mit der Akzeptanz von KI-gestützten CDSS zusammenhängen könnten.

Eine weitere Querschnittsstudie von Kücking et al. (2024) in München untersuchte, wie Faktoren der evidenzbasierten Pflege (EBP), dazu gehörend Wissen, VT und Praxis sowie die Konstrukte des UTAUT, die Nutzung von CDSS beeinflussen. Eingesetzt wurde das VARHealthcare an der München Klinik gGmbH, das als erweiterte Suchmaschine für pflegerisches Personal dient (ebd., S. 282). Dazu wurde eine quantitative Online-Befragung unter pflegerischem Personal durchgeführt ($n = 97$) (ebd., S. 282–284). Als abhängige Variable wurde die monatliche Nutzungsdauer des Systems in Stunden erhoben (ebd., S. 283). Die Items wurden mittels Likert-Skalen erfasst, aus denen jeweils Mittelwerte gebildet wurden. Zur Auswertung kamen multiple lineare Regressionsanalysen mit Bootstrapping zum Einsatz (ebd., S. 284). In einem ersten Modell wurden der Gesamtwert der EBP sowie die Faktoren Alter, Berufserfahrung und Geschlecht getestet. Das Gesamtmodell war nicht signifikant ($R^2 = 0,08$; $p = 0,125$). Es zeigte sich jedoch ein signifikanter Einfluss der EBP auf die Nutzungsdauer ($p = 0,027$) (ebd., S. 285). Das zweite Modell betrachtet nun die einzelnen EBP-Dimensionen. Dabei erwies sich das Wissen als signifikant ($p = 0,033$), während VT und Praxis keine Effekte aufzeigten. Außerdem war auch das Gesamtmodell nicht signifikant ($R^2 = 0,115$; $p = 0,110$). Das letzte Modell umfasste die einzelnen UTAUT-Konstrukte, Zufriedenheit, Alter, Geschlecht und Berufserfahrung und war insgesamt signifikant mit einer erklärten Varianz der Nutzungsdauer von 27,9 % ($p = 0,001$). Unter den Variablen erwiesen sich Zufriedenheit ($p = 0,026$) und LE ($p = 0,021$) als signifikant. Die AA ($p = 0,062$) deutete hingegen auf eine mögliche Signifikanz hin. Alter, Berufserfahrung und Geschlecht zeigten in keinem Modell einen signifikanten Effekt (ebd., S. 285–286). Insgesamt deuten die Studienergebnisse darauf hin, dass Wissen, LE und Zufriedenheit mit einer höheren Nutzung von CDSS verbunden sein könnten (ebd., S. 286).

In der Querschnittsstudie von Sultan et al. (2024) wurden die Faktoren untersucht, die die Akzeptanz von CDSS in Palästina beeinflussen. Die Studie wurde in drei Regierungskrankenhäusern im Westjordanland durchgeführt. Die Stichprobe umfasste Allgemeinmediziner:innen und Assistenzärzt:innen ($n = 124$) (ebd., S. 3). Als Messinstrument wurde ein modifiziertes UTAUT-Modell verwendet, bei dem die FB ausgeschlossen und dafür wahrgenommene Bedrohung, Computerselbstwirksamkeit sowie die Beteiligung an Entscheidungsprozessen berücksichtigt wurden. Die NA stellte hierbei die abhängige Variable dar (ebd., S. 4). Für jedes Konstrukt wurde eine fünfstufige Likert-Skala berechnet und pro Untersuchungseinheit ein Mittelwert gebildet (ebd., S. 5). Die Ergebnisse der Pearson Korrelationen zeigten, dass LE ($r = 0,469; p < 0,001$), AA ($r = 0,294; p < 0,001$), Computerselbstwirksamkeit ($r = 0,218; p = 0,015$), SI ($r = 0,179; p = 0,047$) sowie wahrgenommene Bedrohung ($r = -0,302; p = 0,001$) signifikant mit der NA zusammenhängen (ebd., S. 6). In einem generalisierten Regressionsmodell erwiesen sich jedoch lediglich LE ($B = 0,434; p < 0,001$) und wahrgenommene Bedrohung ($B = -0,216; p = 0,005$) als signifikante Prädiktoren für die NA von CDSS. Eine höhere LE war dabei mit einer stärkeren NA verbunden, während eine höhere wahrgenommene Bedrohung die NA verringerte. Die weiteren Variablen wiesen keine signifikanten Zusammenhänge mit der NA auf (ebd., S. 7). Zusammenfassend zeigten die Ergebnisse der Studie, dass LE und wahrgenommene Bedrohung die Akzeptanz von Nutzenden beeinflussten. Außerdem wiesen auch AA, SI und Computerselbstwirksamkeit auf eine mögliche Relevanz hin (ebd., S. 9).

Wang et al. (2025) führten in China eine Querschnittsstudie zu einem KI-gestützten CDSS durch, das medizinisches Personal bei der Prävention und Behandlung venöser Thromboembolien unterstützt. Ziel war es zu untersuchen, welche Faktoren die Nutzung und Akzeptanz dieses Systems beeinflussen (ebd., S. 2). Die Studie fand in drei tertiären Krankenhäusern in Shanxi statt, in denen das CDSS bereits eingeführt war oder kurz vor der Einführung stand. Die Zielgruppe umfasste medizinisches Personal ($n = 510$) (ebd., S. 4–5). Als Messinstrument diente ein erweitertes UTAUT-Modell, das das Information System Success Model mit den Dimensionen Systemqualität, Informationsqualität sowie die Unterstützung durch das Top-Management einbezog. Die FB wurden bei dieser Untersuchung ausgeschlossen (ebd., S. 3). Die Items wurden auf einer fünfstufigen Likert-Skala bewertet und anschließend zu Mittelwerten zusammengefasst (ebd., S. 5). Die Strukturgleichungsanalyse zeigte, dass die NA positiv von der LE ($\beta = 0,45; p < 0,001$), der AA ($\beta = 0,21; p < 0,001$), der Systemqualität ($\beta = 0,14; p < 0,001$) sowie der Unterstützung durch das Top-Management ($\beta = 0,30; p < 0,001$) beeinflusst wird. Das Gesamtmodell war ebenfalls signifikant ($p < 0,001$) (ebd., S. 6). Eine separate Analyse hat Unterschiede zwischen dem

ärztlichen und dem pflegerischen Personal aufgezeigt. Beim Pflegepersonal zeigte der SI keinen signifikanten Zusammenhang mit der NA ($\beta = 0,06; p = 0,376$), während bei Ärzt:innen ein leicht negativer und signifikanter Zusammenhang bestand ($\beta = -0,19; p < 0,001$) (ebd., S. 8–9). Insgesamt zeigten sich die Unterstützung durch das Top-Management und die Erwartungen an Leistung und Aufwand als positive Einflussfaktoren der NA von KI-gestützten CDSS unter medizinischem Personal (ebd., S. 10).

Die Querschnittsstudie von Eiskjær et al. (2023) aus Dänemark untersuchte das KI-gestützte CDSS „PROPOSE“, welches ärztliches Personal bei der Auswahl geeigneter Behandlungsoptionen für Wirbelsäulenerkrankungen unterstützen soll. Ziel war es, Faktoren zu identifizieren, die die Nutzung von PROPOSE fördern oder hemmen (ebd., S. 2). Dafür nutzte die Forschungsgruppe ein theoretisches Modell, das auf den UTAUT-Konstrukten basiert und um die Dimensionen VT, wahrgenommenes Risiko sowie Widerstandsbias erweitert wurde, um die NA zu erklären (ebd., S. 4). Die Konstrukte wurden mithilfe einer siebenstufigen Likert-Skala erhoben. An der Online-Befragung nahmen Fachärzt:innen und Wirbelsäulenchirurg:innen teil ($n = 62$) (ebd., S. 2–6). Im Verlauf der Studie wurden die FB aufgrund fehlender Validität sowie das wahrgenommene Risiko wegen unzureichender Indikatorladungen ($< 0,40$) ausgeschlossen (ebd., S. 6). In einem Strukturgleichungsmodell wurden AA, SI, VT und LE mitaufgenommen. Insgesamt konnte eine erklärte Varianz der NA von 62,70 % erreicht werden. Die AA ($\beta = 0,439; p < 0,001$) und LE ($\beta = 0,212; p < 0,05$) konnten signifikante Zusammenhänge mit der NA aufweisen. Der SI ($\beta = 0,155$) und das VT ($\beta = 0,141$) wiesen keine signifikanten Ergebnisse auf (ebd., S.7). Die Ergebnisse deuteten darauf hin, dass insbesondere die AA und die LE einen Einfluss auf die NA von PROPOSE haben könnten (ebd., S. 7)

Die Studien zeigen, dass das UTAUT-Modell häufig zur Untersuchung der Akzeptanz von CDSS eingesetzt wird. Dabei erweist sich die LE durchgängig als zentraler Prädiktor der NA, während auch die AA, die SI und die VT wiederholt signifikante Zusammenhänge aufweisen. Die Befunde zu den FB sind hingegen uneinheitlich, sodass ihre Relevanz für die Akzeptanz unklar bleibt.

3. Ziele und Hypothesen

Das Ziel dieser Bachelorarbeit besteht darin, die Faktoren zu untersuchen, die mit der Akzeptanz von CDSS bei pflegerischem und therapeutischem Personal am BGKH zusammenhängen. Ein untergeordnetes Ziel besteht darin, zu ermitteln, welche der

erhobenen Variablen mit der NA sowie den einzelnen UTAUT-Konstrukten korrelieren. Auf Grundlage dieser Zielsetzung wurden folgende Hypothesen formuliert:

- **H0₁:** *Es besteht kein signifikanter Zusammenhang zwischen der NA von CDSS und den unabhängigen Variablen*
- **H1₁:** *Es besteht ein signifikanter Zusammenhang zwischen der NA von CDSS und den unabhängigen Variablen*
- **H0_{2,3,4,5}:** *Es besteht kein signifikanter Zusammenhang zwischen den soziodemographischen Variablen und der LE (H0₂), AA (H0₃), SI (H0₄) und VT (H0₅)*
- **H1_{2,3,4,5}:** *Es besteht kein signifikanter Zusammenhang zwischen den soziodemographischen Variablen und der LE (H1₂), AA (H1₃), SI (H1₄) und VT (H1₅)*

Im nächsten Schritt soll in einfachen Regressionsmodellen untersucht werden, inwieweit die in der bivariaten Analyse als potenzielle Prädiktoren identifizierten Variablen einzeln die Varianz der NA von CDSS erklären können. Hierfür wurden die folgenden Hypothesen abgeleitet:

- **H0_{6,7,8}:** *Die LE (H0₆), AA (H0₇) und VT (H0₈) erklären keinen signifikanten Anteil der Varianz der NA von CDSS*
- **H1_{6,7,8}:** *Die LE (H1₆), AA (H1₇) und VT (H1₈) erklären einen signifikanten Anteil der Varianz der NA von CDSS*

Abschließend wird in multiplen Regressionsmodellen geprüft, inwieweit die potenziellen Prädiktoren die NA von CDSS vorhersagen. Das erste Modell die direkten Effekte der Prädiktoren in einem gemeinsamen Modell und wird im Folgenden als „Grundmodell“ bezeichnet. In einem erweiterten Modell werden zusätzlich potenzielle Moderatoren berücksichtigt. Dieses Modell wird im Folgenden als „Moderatorenmodell“ bezeichnet. Auf Grundlage dieser Modelle wurden die folgenden Hypothesen formuliert:

- **H0₉:** *Die Prädiktoren im Grundmodell erklären keinen signifikanten Anteil der Varianz der NA von CDSS*
- **H1₉:** *Die Prädiktoren im Grundmodell erklären einen signifikanten Anteil der Varianz der NA von CDSS*
- **H0₁₀:** *Die Prädiktoren im Moderatorenmodell erklären keinen signifikanten Anteil der Varianz der NA von CDSS*
- **H1₁₀:** *Die Prädiktoren im Moderatorenmodell erklären einen signifikanten Anteil der Varianz der NA von CDSS*

Die in diesem Kapitel formulierten Hypothesen bilden die Grundlage für die Methodik in Kapitel 4. Dort werden sowohl die Datenerhebung als auch die Analyse beschrieben, mit der die Hypothesen überprüft und die Forschungsfrage beantwortet werden.

4. Methodik

In diesem Kapitel wird die methodische Vorgehensweise zur Beantwortung der Forschungsfrage beschrieben. Zunächst werden die Datenerhebung und die Zusammensetzung der Stichprobe erläutert. Im Anschluss werden die eingesetzten Messinstrumente sowie die untersuchten Variablen vorgestellt. Abschließend wird das Vorgehen bei der Datenanalyse beschrieben.

4.1 Datenerhebung und Stichprobe

Zur Untersuchung der Akzeptanz von CDSS unter den Mitarbeitenden des BGKH wurde eine quantitative Querschnittsstudie durchgeführt. Im Rahmen eines Praktikums im Qualitäts- und Risikomanagement ergab sich die Möglichkeit die Bachelorarbeit in diesem Unternehmen zu verfassen. Die Datenerhebung erfolgte über die Software EvaSys (Version 9.0) mittels eines Online-Fragebogens. Im Folgenden werden Studiendesign, Erhebungsinstrument sowie Stichprobengewinnung und -rekrutierung erläutert.

Querschnittsstudien erfassen Daten zu einem einzigen Zeitpunkt und liefern so eine Momentaufnahme der Akzeptanz des pflegerischen und therapeutischen Personals gegenüber CDSS (Döring, 2023, S. 212). Dabei wurde ein quantitatives Forschungsdesign gewählt, das standardisierte Messwerte basierend auf theoretischen Modellen erhebt und mit statistischen Verfahren auswertet (ebd., S. 15). Als Zielgruppe wurde das pflegerische und therapeutische Personal an allen Abteilungen und Standorten des BGKH festgelegt. Die Online-Befragung ermöglichte eine zeit- und ortsunabhängige Teilnahme (ebd., S. 395).

Vor der Fertigstellung des Fragebogens wurde ein Pretest durchgeführt, um potenzielle Schwierigkeiten der Zielgruppe beim Ausfüllen zu identifizieren und das Erhebungsinstrument entsprechend zu überarbeiten (ebd., S. 406). Dabei handelte es sich um einen Beobachtungspretest, bei dem der Fragebogen unter realen Bedingungen getestet wurde (Häder, 2019, S. 413–414). Fünf Studierende der Hochschule für Angewandte Wissenschaften Hamburg überprüften den Fragebogen. Auf Basis ihrer Rückmeldungen wurden sprachliche Anpassungen vorgenommen und ein einleiten-

der Informationstext zu CDSS ergänzt. Zwei demografische Fragen zum Beschäftigungsumfang und zur Beschäftigungsart wurden aufgrund des Umfangs des Fragebogens entfernt.

Der Zugang erfolgte über einen Flyer, der sowohl einen QR-Code als auch einen Link zur Befragung enthielt (s. Anhang B). In dem Flyer wurden die Teilnehmenden über die Zielsetzung der Studie, den Ablauf sowie die freiwillige und anonyme Teilnahme informiert. Die Zustimmung zur Befragung wurde vom Betriebsrat des BGKH erteilt und der Befragungszeitraum erstreckte sich vom 28. Mai bis zum 18. Juni 2025.

Die Stichprobe wurde bewusst ausgewählt und folgt damit einem nicht-probabilistischen Vorgehensweise (Kromrey et al., 2016, S. 268). Dieses Vorgehen wurde gewählt, da sich die Fragestellung spezifisch auf die Akzeptanz von CDSS im Kontext des BGKH bezieht und bislang keine praktischen Erfahrungen mit CDSS vorliegen. Eingeschlossen wurden Personen ab 18 Jahren, die im Bereich Pflege oder Therapie am BGKH tätig sind und über ausreichende Deutschkenntnisse verfügen, da die Befragung auf Deutsch durchgeführt wurde. Voraussetzung war zudem der Zugang zu einem internetfähigen Gerät (z. B. Smartphone, Tablet oder Laptop). Ausgeschlossen wurden Personen unter 18 Jahren sowie Mitarbeitende anderer Berufsgruppen und Mitarbeitende von Fremdfirmen.

Die Rekrutierung der Zielgruppe erfolgte im BGKH über mehrere Kanäle. Zu Beginn wurden Flyer auf den Stationen ausgelegt und das Personal im Rahmen einer internen Veranstaltung persönlich angesprochen. Aufgrund zunächst geringer Rücklaufquoten wurden anschließend die Bereichsleitungen gebeten, die Umfrage per E-Mail an die Mitarbeitenden weiterzuleiten. Ergänzend wurde die Befragung im Intranet veröffentlicht. Insgesamt konnte eine Stichprobe von 67 Teilnehmenden erzielt werden.

4.2 Messinstrumente

Als Erhebungsinstrument wurde ein Online-Fragebogen eingesetzt, der insgesamt drei Themenblöcke mit 25 Fragen umfasst (s. Anhang A). Grundlage für die Erfassung der Akzeptanz von CDSS war das UTAUT-Modell von Venkatesh et al. (2003). Dieses Modell wurde in aktuellen Studien häufig herangezogen, wie bereits im Kapitel 2.4 Forschungsstand beschrieben.

Der erste Teil des Fragebogens erhob soziodemografische Angaben. *Geschlecht*, *Alter*, *Berufserfahrung* und *Erfahrung* mit CDSS wurden aufgenommen, da sie im UTAUT-Modell als Moderatoren vorgesehen sind und bereits in früheren Studien geprüft wurden. Trotz fehlender signifikanter Ergebnisse im Zusammenhang mit der NA

werden sie in dieser Arbeit berücksichtigt, um die theoretische Modellstruktur abzubilden (Berge et al., 2023, S. 9–10; Dingel et al., 2024, S. 11; Kücking et al., 2024, S. 285–286). Zusätzlich wurden *Berufsgruppe*, *Abteilung* und *Bildungsabschluss* erfasst, um deren potenzielle Rolle als Moderatoren zu prüfen, auch wenn diese Variablen im UTAUT-Modell nicht vorgesehen sind.

Der zweite Teil des Fragebogens widmete sich den UTAUT-Konstrukten. Die Formulierung der Frageitems orientierte sich am UTAUT-Modell und wurde auf Basis der Originalliteratur sowie aktueller Studien entwickelt (Venkatesh et al., 2003, S. 448–452; Eiskjær et al., 2023, S. 5; Kücking et al., 2024, S. 284). Sämtliche Items wurden an das Untersuchungssetting des BGKH angepasst. Aufgrund des Untersuchungssettings und unter Berücksichtigung der bisherigen Studienergebnisse wurden in dieser Bachelorarbeit nicht alle Konstrukte erhoben. Dabei wurde auf die Erhebung der FB verzichtet. Einige Studien haben vollständig auf die Erhebung von FB verzichtet (Sultan et al., 2024, S. 4; Wang et al., 2025, S. 3). Die Untersuchung von Berge et al. (2023) wiederum erhob FB, konnte jedoch keine signifikanten Zusammenhänge mit der NA feststellen (S. 10). Ebenso wurde der Moderator „Freiwilligkeit“ nicht berücksichtigt. Eine Befragung hat gezeigt, dass lediglich 15 % der Beschäftigten bei der Einführung neuer Technologien umfassend einbezogen werden (Fehér et al., 2019, S. 34). Es ist daher davon auszugehen, dass die Nutzung der Technologien für die Mitarbeitenden verpflichtend ist. Da am BGKH derzeit keine CDSS genutzt werden, ist eine Messung des tatsächlichen Nutzungsverhaltens nicht möglich. Entsprechend konzentriert sich die Untersuchung, wie in der Forschungsfrage beschrieben, ausschließlich auf die Akzeptanz der Mitarbeitenden. Daher wurden die *LE*, *AA* und *SI* als Konstrukte sowie die bereits erwähnten Moderatoren *Geschlecht*, *Alter*, *Berufserfahrung* und *Erfahrung* für das UTAUT-Modell erhoben.

Der letzte Teil des Fragebogens enthält Items zum *VT* gegenüber der *NA* von CDSS. In mehreren Studien konnte nachgewiesen werden, dass *VT* und *NA* direkt miteinander zusammenhängen (Dingel et al., 2024, S. 4; Cornelissen et al., 2022, S. 6). Dementsprechend wurde diese Variable ebenso wie die Konstrukte des UTAUT-Modells in dieser Analyse betrachtet.

4.2.1 Unabhängige Variablen

Im folgenden Abschnitt werden die unabhängigen Variablen und ihre Einbindung in die statistische Analyse beschrieben. Bei allen Fragen bestand außerdem die Möglichkeit „keine Angabe“ zu wählen. Diese Antwortmöglichkeit wird im weiteren Verlauf aus Gründen der Übersichtlichkeit nicht mehr gesondert berücksichtigt.

Geschlecht

Die Teilnehmenden hatten für die Variable *Geschlecht* die Möglichkeit „männlich“, „weiblich“ oder „divers“ anzugeben. Für die Ausprägung „divers“ gab es keine Antworten, weshalb diese Ausprägung in dieser Arbeit nicht betrachtet werden konnte. Somit wurde das *Geschlecht* als nominale Variable mit dichotomer Ausprägung in die folgenden Analysen einbezogen. Die männlichen Teilnehmenden sind hierbei mit „1“ kodiert und weiblichen Teilnehmenden mit „2“.

Alter

Das *Alter* wurde in Kategorien erhoben. Die Ausprägungen beinhalteten „unter 30 Jahre“, „30-45 Jahre“ und „ab 46 Jahre“. Für die weitere statistische Vorgehensweise wird das *Alter* mit ordinalen Datenniveau und drei Ausprägungen behandelt. Hierbei wird „unter 30 Jahren“ als „1“ kodiert, „30–45 Jahre“ als „2“ und „ab 46 Jahre“ mit „3“.

Berufsgruppe

Für die *Berufsgruppe* hatten die Teilnehmenden die Optionen „Pflegerischer Dienst“ und „Therapeutischer Dienst“ zur Auswahl. Die Variable *Berufsgruppe* wurde in den weiteren Analysen als nominale Variable mit dichotomer Ausprägung betrachtet. Die Kodierung „1“ wurde für den Pflegerischen Dienst verwendet und „2“ für den Therapeutischen Dienst.

Abteilung

Bei der Zugehörigkeit der *Abteilung* wurden den Teilnehmenden folgende Antwortmöglichkeiten zur Verfügung gestellt: „AIR / INT / BVI / ZNA“, „QZ“, „HPMC / BVO“, „NZ“, „SUO / UOS / VCH“, „ZRH“ und „sonstiges“. Bei den Abteilungen wurden intern geltende Abkürzungen verwendet, die im BGKH gelten. Bei der Zusammenstellung dieser Abteilungsgruppen wurde darauf geachtet, dass die Abteilungen ein ähnliches Tätigkeitsfeld und Arbeitsstrukturen vorweisen. Zudem konnte aufgrund der Vielzahl an Abteilungen nicht alle geschlossen werden. Für diesen Fall wurde die Option „sonstiges“ mitangegeben. Die Variable besitzt ein nominales Datenniveau und wird in der deskriptiven Analyse beschrieben. Aufgrund der geringen Anzahl an Ausprägungsgruppen wird auf die bivariate und multivariate Analyse der Abteilungen verzichtet. Hierbei stand die Kodierung „1“ für die „AIR / INT / BVI / ZNA“ Mitarbeitenden, „2“ für „QZ“, „3“ für „HPMC / BVO“, „4“ für „NZ“, „5“ für „SUO / UOS / VCH“, „6“ für „ZRH“ und „7“ für „sonstiges“.

Berufserfahrung

Die *Berufserfahrung* wurde mittels vier Kategorien gemessen. Die Teilnehmenden konnten „weniger als 3 Jahre“, „3 bis unter 10 Jahre“, „10 bis unter 25 Jahre“ und „25

Jahre oder mehr“ als Antwortmöglichkeiten auswählen. Für die weitere statistische Analyse kann die *Berufserfahrung* mit ordinalem Datenniveau einbezogen werden. Eine *Berufserfahrung* von weniger als drei Jahren ist mit „1“ kodiert, bei drei bis unter zehn Jahren ist mit „2“, bei zehn bis unter 25 Jahren mit „3“ und bei 25 Jahren und mehr mit „4“.

Bildungsabschluss

Den Teilnehmenden standen zur Variable *Bildungsabschluss* „keinen Abschluss“, „Hauptschulabschluss“, „Realschulabschluss“, „(Fach-)Abitur“, „Berufsausbildung“, „Diplom / Bachelor / Master“ und „Promotion“ zur Auswahl. Da keine der Teilnehmenden keinen Abschluss besaß, wurde diese Antwortmöglichkeit in der weiteren Analyse ausgeschlossen. Der *Bildungsabschluss* weist ein ordinales Datenniveau auf und kann für die weiteren Analysen verwendet werden. Die Kodierung „1“ steht für Teilnehmende ohne Abschluss, „2“ für Hauptschulabsolvent:innen, „3“ für Realschulabsolvent:innen, „4“ für einen (Fach-)Abiturabschluss, „5“ für eine abgeschlossene „Berufsausbildung“, „6“ für einen Diplom-, Bachelor- oder Masterabschluss und „7“ für einen Promotionsabschluss.

Erfahrung

Die *Erfahrung* mit CDSS wurde mittels der Antwortmöglichkeiten „ja“, „nein“ und „weiß ich nicht“ gemessen. Diese nominale Variable wurde in der deskriptiven Analyse beschrieben. Aufgrund der geringen Antworten der Teilnehmenden in der Ausprägung „weiß ich nicht“ wurde diese Antwortkategorie für die darauffolgende bivariate und multivariate Analyse ausgeschlossen. Somit wurde die *Erfahrung* mit CDSS als dichotome betrachtet und für die weitere bivariate und multivariate Berechnung verwendet. Die Antwortmöglichkeit „ja“ ist mit „1“ kodiert, „nein“ mit „2“ und „weiß ich nicht“ mit „3“.

Leistungserwartung (LE), Aufwandserwartung (AA), sozialer Einfluss (SI) und Vertrauen (VT)

Die Items der *LE*, *AA*, *SI* und *VT* wurden mithilfe einer fünfstufigen Likert-Skala erhoben, wie sie auch in anderen Studien zu diesem Thema wurde (Berge et al., 2023, S. 4; Cornelissen et al., 2022, S. 4; Sultan et al., 2024, S. 5; Wang et al., 2025, S. 5). Die Antwortkategorien reichten von 1 = „Stimme überhaupt nicht zu“ bis 5 = „Stimme voll und ganz zu“. Es wurden fünf Items für die *LE*, vier Items für die *AA* sowie jeweils drei Items für den *SI* und das *VT* erhoben. Aus den Items jeder Variablen wurde für jede Untersuchungseinheit ein Mittelwert gebildet. Die Variablen blieben für die Analysen metrisch und wurden in den deskriptiven, bivariaten und multivariaten Analysen

unverändert verwendet. Zur interpretativen Einordnung der Skalenwerte wurden die Mittelwerte in drei gleich große Intervalle eingeteilt, wobei 1 bis 2,33 als gering, 2,34 bis 3,66 als mittel und 3,67 bis 5 als hoch gelten. Diese Einteilung dient ausschließlich der besseren Anschaulichkeit und lässt die metrische Skalierung der Daten unberührt.

4.2.2 Abhängige Variable

In dieser Arbeit wurde die Akzeptanz von CDSS über die *NA* des UTAUT-Modells erfasst. Die *NA* dient somit als operationalisierte Form der Akzeptanz und stellt die abhängige Variable dieser Untersuchung dar. Hierzu wurden drei Items formuliert, die mittels einer fünfstufigen Likert-Skala erhoben wurden (1 = „Stimme überhaupt nicht zu“; 5 = „Stimme voll und ganz zu“). Im Anschluss wurde aus den drei Items je ein Mittelwert je Untersuchungseinheit gebildet. Die Interpretation der Skalenwerte erfolgt, wie im vorherigen Kapitel beschrieben, sodass Werte von 1 bis 2,33 eine geringe, 2,34 bis 3,66 eine mittlere und 3,67 bis 5 eine hohe *NA* von CDSS darstellen. Die abhängige Variable bleibt für die statistische Analyse weiterhin metrisch.

4.3 Datenanalyse

In diesem Kapitel wird das Vorgehen der Datenanalyse dargestellt, das zur Beantwortung der Forschungsfrage und der zugrundeliegenden Hypothesen dient. Die Auswertung erfolgte in mehreren Schritten und umfasste deskriptive, bivariate sowie multivariate Verfahren.

Zunächst wurde der Datensatz aus EvaSys nach Excel exportiert und dort bereinigt. Fehlende Werte wurden einheitlich mit „–99“ kodiert. Anschließend wurde der Datensatz in RStudio (Version 4.5.1) importiert. Für alle statistischen Berechnungen wurde ein Signifikanzniveau von $p = 0,05$ festgelegt.

4.4.1 Deskriptive Analyse

Zur Beschreibung der Datenverteilung wurde eine deskriptive Analyse durchgeführt. Abhängig vom Skalenniveau der Variablen wurden unterschiedliche statistische Kennwerte berechnet. Bei nominal skalierten Variablen wurden absolute und relative Häufigkeiten ermittelt und die Ergebnisse in Form von Balkendiagrammen dargestellt (Wirtz & Nachtigall, 2012, S. 63). Für ordinal skalierte Variablen wurden ebenfalls absolute und relative Häufigkeiten berechnet und zusätzlich der Median angegeben (ebd., S. 56). Die Verteilungen wurden mithilfe von Boxplots visualisiert. Bei metrischen Variablen wurde der Mittelwert und die Standardabweichung angegeben sowie das Minimum und das Maximum dargestellt (Eckey et al., 2008, S. 55–57). Die Darstellung der Verteilungen erfolgte über Histogramme (ebd., S. 43).

4.4.2 Bivariate Analyse

Die bivariate Analyse dieser Arbeit gliedert sich in zwei Teile. Im ersten Teil wird die abhängige Variable mit allen unabhängigen Variablen auf Zusammenhänge mittels Korrelationsanalysen geprüft (Kuckartz et al., 2010, S. 189). Die abhängige Variable ist hierbei metrisch verteilt. Bei unabhängigen Variablen mit dichotomen Ausprägungen werden punktbiseriale Korrelationen berechnet. Das Ergebnis wird in Form des Korrelationskoeffizienten (r_{pb}) dargestellt, welcher von -1 bis $+1$ reichen kann (Bortz & Schuster, 2010, S.171). Dabei steht $r = +1$ für einen perfekten positiven, $r = -1$ für einen perfekten negativen linearen Zusammenhang (ebd., S. 157). Für die Interpretation der Effektstärke wird die Einteilung nach Cohen (1988) verwendet. Alle berechneten Korrelationskoeffizienten werden wie folgt interpretiert: $r = 0,10$ gilt dabei als kleiner, $r = 0,30$ als mittlerer und $r = 0,50$ als starker Effekt (Cohen, 1988, S. 79–80).

Für unabhängige Variablen mit metrischem Datenniveau wird die Pearson Korrelation berechnet (Kuckartz et al., 2010, S. 194). Dieses Verfahren setzt eine Normalverteilung beider Variablen voraus (ebd., S. 198). Zur Überprüfung der Normalverteilung werden QQ-Plots und der Shapiro-Wilk-Test herangezogen. Zudem wird mithilfe eines Streudiagramms überprüft, ob ein annähernd linearer Zusammenhang zwischen den Variablen besteht (ebd., S. 196). Als Ergebnis resultiert der Korrelationskoeffizient (r) mit einem Wartebereich von -1 bis $+1$ (ebd., S. 194). Liegen keine normalverteilten Daten vor oder sind die unabhängigen Variablen ordinalskaliert, wird die Spearman-Korrelation berechnet (ebd., S. 198). Der zugehörige Korrelationskoeffizient (r_s) kann ebenfalls Werte zwischen -1 und $+1$ annehmen (Bortz & Schuster, 2010, S. 178). Bei allen Korrelationsergebnissen werden sowohl der p-Wert als auch der entsprechende Korrelationskoeffizient dargestellt.

Der erste Teil der bivariaten Analyse dient zunächst dazu, einen allgemeinen Überblick darüber zu gewinnen, welche der untersuchten unabhängigen Variablen mit der abhängigen Variable zusammenhängen (Wentura & Pospeschill, 2015, S. 34). Besonderes Augenmerk liegt dabei auf den in früheren Studien und im UTAUT-Modell als relevant beschriebenen Variablen (*LE, AA, SI und VT*), deren Zusammenhang mit der *NA* in der vorliegenden Stichprobe überprüft wird. Hierbei werden ausschließlich Variablen in die weitere Analyse einbezogen, die entweder signifikante Zusammenhänge aufweisen oder eine mittlere Effektstärke von mindestens $r = 0,30$ erreichen. Diese ausgewählten Variablen werden anschließend als potenzielle Prädiktoren in das multivariate Modell aufgenommen.

Im zweiten Analyseschritt werden die im ersten Schritt identifizierten relevanten Variablen, die einen Zusammenhang mit der abhängigen Variable aufweisen, einzeln in

Bezug zu den soziodemografischen Merkmalen untersucht. Zur Prüfung dieser Zusammenhänge werden ebenfalls Korrelationstests eingesetzt. Potenziell moderierende Effekte werden angenommen, wenn zwischen den demografischen Merkmalen und den potenziellen Prädikoren signifikante Zusammenhänge bestehen oder mindestens eine mittlere Effektstärke ($r = 0,30$) erreicht wird. Die so identifizierten Variablen fließen als potenzielle Moderatoren in die multivariate Analyse ein.

4.3.3 Multivariate Analyse

Mithilfe einer linearen Regressionsanalyse wird im Rahmen des multivariaten Verfahrens untersucht, ob und in welchem Ausmaß die potenziellen Prädiktoren statistisch mit der abhängigen Variable zusammenhängen und wie viel Varianz dadurch erklärt werden kann (Wentura & Pospeschill, 2015, S. 11–12). Zunächst werden die in der bivariaten Analyse identifizierten potenziellen Prädiktoren jeweils in einfachen linearen Regressionsmodellen betrachtet, um festzustellen, ob ein Zusammenhang mit der NA besteht und welcher Anteil der Varianz dadurch aufgeklärt werden kann (Frost, 2017, S. 5). Anschließend werden die potenziellen Prädiktoren gemeinsam in einem multiplen linearen Regressionsmodell berücksichtigt, um zu prüfen, wie sich die Prädiktoren im Zusammenspiel verhalten, ob die zuvor beobachteten Zusammenhänge bestehen bleiben und wie sich die erklärte Varianz in diesem Modell darstellt (Wentura & Pospeschill, 2015, S. 38). Dieses Modell wird im Folgenden als „Grundmodell“ bezeichnet. In einem weiteren Schritt wird eine moderierte multiple Regression durchgeführt, in die potenzielle Moderatoren einbezogen werden, um mögliche Interaktionseffekte zu analysieren. Dabei wird geprüft, ob eine Moderatorvariable den Zusammenhang zwischen einem Prädiktor und der abhängigen Variablen verändert (Bortz & Schuster, 2010, S. 357). Dieses Modell wird für diese Arbeit „Moderatorenmodell“ genannt. Im Anschluss werden die multiplen Regressionsmodelle hinsichtlich der Modellgüte verglichen.

Für die Durchführung linearer Regressionsanalysen müssen bestimmte Voraussetzungen erfüllt sein. Zunächst muss die abhängige Variable metrisch skaliert sein, während die unabhängigen Variablen metrisch oder kategorial verteilt sein können. Bei einfachen Regressionsmodellen müssen die potenziellen Prädiktoren ebenfalls metrisch verteilt sein (Frost, 2017, S. 3). Kategoriale Variablen werden dichotomisiert und als sogenannte „Dummy-Variablen“ in das Modell aufgenommen, welche in der Regel mit „0“ und „1“ kodiert werden (Bortz & Schuster, 2010, S. 342). Zudem sollte eine Unabhängigkeit der Beobachtungen vorliegen (Wentura & Pospeschill, 2015, S. 29).

Eine weitere zentrale Annahme der linearen Regression ist, dass keine Multikollinearität vorliegen darf. Dabei darf die Anzahl der getesteten Prädiktoren den Stichprobenumfang nicht überschreiten und zwischen den Prädiktoren sollten keine perfekten ($r = 1$) oder nahezu perfekten linearen Zusammenhänge bestehen (Bortz & Schuster, 2010, S. 354–356). Zur Überprüfung der Multikollinearität werden Korrelationstests und der Varianzinflationsfaktor herangezogen. Varianzinflationsfaktorwerte die größer als 10 gelten als Hinweis auf eine problematische Multikollinearität, welche die Schätzung der Regressionskoeffizienten verzerren könnte (Kutner et al., 2005, S. 409).

Ein weiterer Bestandteil der Modellvoraussetzungen ist die Homoskedastizität, also die Annahme konstanter Varianz der Residuen (Bortz & Schuster, 2010, S. 348). Dies lässt sich mithilfe eines Residuenplots visuell überprüfen. Zeigen die Residuen eine gleichmäßige Streuung um die x-Achse, kann von Homoskedastizität ausgegangen werden. Zeigen sie jedoch ein Muster, beispielsweise eine trichterförmige Punktwolke, deutet dies auf eine Heteroskedastizität hin (Frost, 2017, S. 13–14).

Als weitere Voraussetzung muss die Normalverteilung der Residuen gegeben sein. Dies ist von Bedeutung, da die Vorhersagefehler bei jeder festen Kombination von Prädiktorwerten normalverteilt sein müssen (Bortz & Schuster, 2010, S. 348). Dies wird visuell mittels QQ-Plots überprüft. Liegen die Punkte annähernd entlang der Winkelhalbierenden, kann von einer Normalverteilung ausgegangen werden (Frost, 2017, S. 16). Da es sich um eine kleine Stichprobe handelt, kann zusätzlich der Shapiro-Wilk-Test eingesetzt werden (Witte, 2019, S. 34).

Die Linearitätsannahme besagt, dass ein linearer Zusammenhang zwischen den metrischen Prädiktoren und der abhängigen Variable besteht (Wentura & Pospeschill, 2015, S. 29). Dies lässt sich mithilfe von Streudiagrammen mit LOESS-Trendlinien überprüfen (Frost, 2017, S. 3). Bei multiplen Prädiktoren kann die Linearität zusätzlich über Residuenplots mit Regressionslinien geprüft werden.

Schließlich sollten die Extremwerte der getesteten Prädiktoren überprüft werden, da diese die Schätzung der Regressionskoeffizienten stark beeinflussen können (Wentura & Pospeschill, 2015, S. 50). Hierzu wird ein Einflussplot erstellt, das die Cook's Distance abbildet. Die Cook's Distance zeigt Fälle, die das Regressionsmodell stark beeinflussen. Höhere Werte deuten auf einen größeren Einfluss hin, während Werte unter 1 als gering gelten (Weisberg, 2013, S. 220–221).

5. Ergebnisse

In diesem Kapitel werden die Ergebnisse präsentiert. Zunächst wird die Stichprobe beschrieben. Im Anschluss werden die Zusammenhänge zwischen der NA und den unabhängigen Variablen sowie zwischen den Konstrukten (LE, AA, SI, VT) und den soziodemografischen Merkmalen dargestellt. Abschließend werden die zentralen Erkenntnisse der Regressionsanalysen präsentiert.

5.1 Stichprobenbeschreibung

Im folgenden Abschnitt wird die Stichprobe anhand statistischer Kennwerte beschrieben. Diese Beschreibung basiert auf den Angaben der 67 Teilnehmenden.

Geschlecht

Die Stichprobe setzt sich überwiegend aus weiblichen Teilnehmenden zusammen, die 71,64 % ($n = 48$) ausmachen. Männliche Teilnehmende sind mit 28,36 % ($n = 19$) in der Stichprobe vertreten.

Alter

Zur Altersverteilung der Teilnehmenden lässt sich sagen, dass jeweils 39,89 % ($n = 26$) angaben, unter 30 Jahre oder zwischen 30 und 45 Jahre alt zu sein. Mit 21,21 % ($n = 14$) sind Teilnehmende ab 46 Jahren in der Stichprobe vertreten. Das mediane Alter liegt in der Kategorie „30 bis 45 Jahre“. Dies bedeutet, dass 50 % der Teilnehmenden 30 bis 45 Jahre alt oder älter sind und umgekehrt 50 % der Teilnehmenden 30 bis 45 Jahre alt oder jünger sind.

Berufsgruppe

An der Befragung nahmen mit 72 % ($n = 46$) überwiegend Mitarbeitende des pflegerischen Personals teil. Das therapeutische Personal hingegen macht 28 % ($n = 18$) der Stichprobe aus.

Abteilung

Die Teilnehmenden sind in verschiedenen Abteilungen tätig. Die Abteilungen, aus denen die meisten Teilnehmenden kamen, sind mit jeweils 19,67 % ($n = 12$) das QZ und die Bereiche SUO, UOS oder VCH. 16,39 % ($n = 10$) arbeiten in der ZRH und ebenso viele sind in sonstigen Abteilungen tätig. Jeweils 13,11 % ($n = 8$) arbeiten in der HPMC oder auf der BVO, 8,20 % ($n = 5$) in der AIR, INT, BVI oder ZNA und 6,60 % ($n = 4$) im NZ.

Berufserfahrung

Bezogen auf die *Berufserfahrung* gaben 19,40 % ($n = 13$) der Teilnehmenden an, weniger als drei Jahre *Berufserfahrung* zu haben. 37,31 % ($n = 25$) verfügen über drei bis unter zehn Jahre, 26,87 % ($n = 18$) über zehn bis unter 25 Jahre und 16,42 % ($n = 11$) über 25 Jahre oder mehr *Berufserfahrung*. Die mediane *Berufserfahrung* liegt bei drei bis unter zehn Jahren, was bedeutet, dass 50 % der Teilnehmenden drei bis unter zehn Jahre oder weniger *Berufserfahrung* besitzen und andersrum, dass 50 % der Teilnehmenden drei bis unter zehn Jahre oder mehr *Berufserfahrung* besitzen.

Bildungsabschluss

Von den Teilnehmenden, die eine Angabe zu ihrem *Bildungsabschluss* gemacht haben, gaben alle an, einen *Bildungsabschluss* zu besitzen ($n = 66$). Eine Person (1,52 %) verfügt über einen Hauptschulabschluss, 10,61 % ($n = 7$) haben einen Realschulabschluss, 16,67 % ($n = 11$) das (Fach-)Abitur. 46,97 % ($n = 31$) verfügen über eine Berufsausbildung als höchsten *Bildungsabschluss*, 22,73 % ($n = 15$) über einen Diplom-, Bachelor- oder Masterabschluss. Eine Person (1,52 %) hat eine Promotion als höchsten *Bildungsabschluss* angegeben. Der Median des höchsten Bildungsabschlusses liegt bei der Ausprägung „Berufsausbildung“. Das bedeutet, dass 50 % der Teilnehmenden eine Berufsausbildung oder einen niedrigeren Abschluss besitzen und andersherum 50 % eine Berufsausbildung oder einen höheren Abschluss erworben haben.

Erfahrung

Hinsichtlich der *Erfahrung* gaben 23,88 % ($n = 16$) der Teilnehmenden an, bereits praktische Erfahrungen mit CDSS gesammelt zu haben. Demgegenüber teilten 70,15 % ($n = 47$) mit, keine praktische Erfahrung in diesem Bereich gesammelt zu haben. 5,97 % ($n = 4$) der Teilnehmenden gaben an, unsicher zu sein, ob sie bereits mit CDSS gearbeitet haben.

Leistungserwartung (LE)

Für die *LE* von CDSS wurde ein Mittelwert der Skalenwerte von 3,74 ($SD = 0,89$, $n = 64$) festgestellt, was einer eher hohen *LE* in der Stichprobe entspricht. Die Skalenwerte reichten von 1,40 bis 5,00.

Aufwandserwartung (AA)

Für die *AA* von CDSS konnte ein durchschnittlicher Skalenwert von 3,55 ($SD = 0,83$; $n = 64$) ermittelt werden. Demnach lässt sich eine mittlere *AA* feststellen. Die Skalenwerte für diese Variable reichten von 1,25 bis 5,00.

Sozialer Einfluss (SI)

Für den *SI* auf die Nutzung von CDSS wurde ein Mittelwert von 3,40 ($SD = 0,67$; $n = 61$) ermittelt. Dies entspricht einem mittleren *SI* in der Stichprobe. Die Skalenwerte reichten in der Stichprobe von 2,00 bis 5,00.

Vertrauen (VT)

Für das *VT* in CDSS konnte ein durchschnittlicher Skalenwert von 3,17 ($SD = 0,85$; $n = 65$) ermittelt werden. Dies lässt sich als ein mittleres *VT* von CDSS einstufen. Die Skalenwerte in der Stichprobe reichten von 1,33 bis 5,00.

Nutzungsabsicht (NA)

Für die *NA* von CDSS konnte ein durchschnittlicher Skalenwert von 3,89 ($SD = 0,96$; $n = 63$) ermittelt werden. Dies entspricht einer hohen *NA* in der Stichprobe. Die Skalenwerte für die abhängige Variable reichten von 1,67 bis 5,00. Die Verteilung der *NA* im Histogramm ist eher linksschief, welches zeigt, dass höhere Werte der *NA* häufiger vorkamen.

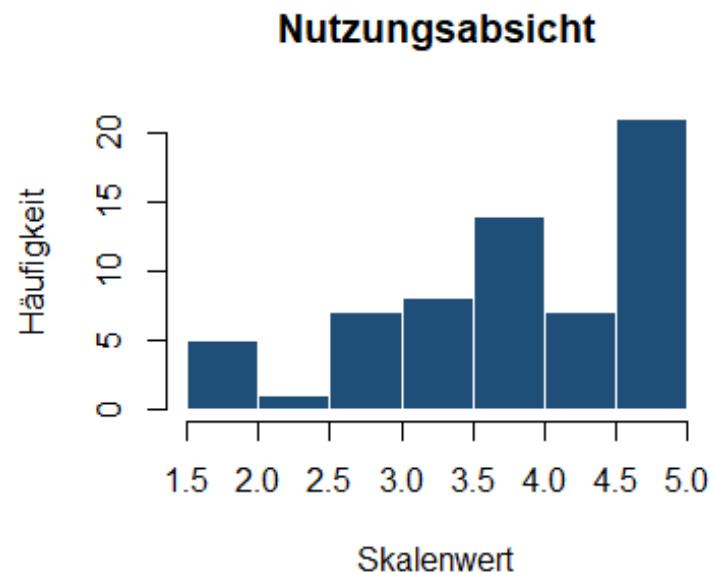


Abbildung 4: Histogramm der Nutzungsabsicht (NA), eigene Darstellung.

5.2 Bivariate Analyse

Im Folgenden werden die Ergebnisse der Korrelationsanalysen dargestellt. Zunächst werden die Zusammenhänge zwischen der *NA* und den unabhängigen Variablen berichtet. Anschließend werden die Korrelationen zwischen den Konstrukten (*LE*, *AA*, *SI*, *VT*) und den soziodemographischen Variablen dargestellt.

Die Voraussetzungen für die Korrelationsanalysen wurden im Vorfeld geprüft (s. Anhang C). Da die Daten überwiegend nicht normalverteilt waren, wurden keine Pearson Korrelationen berechnet. Stattdessen kamen Spearman Korrelationen zum Einsatz. In Tabelle 1 sind die Ergebnisse der Korrelationstests zwischen der NA und den unabhängigen Variablen dargestellt.

Tabelle 1: Ergebnisse der Korrelation der unabhängigen Variablen und der Nutzungsabsicht (NA), eigene Darstellung.

Variable	Korrelationsverfahren	Effekt	p-Wert
Geschlecht	Punktbiseriale Korrelation	-0,295	0,019
Alter	Spearman Korrelation	-0,206	0,105
Berufsgruppe	Punktbiseriale Korrelation	0,201	0,121
Berufserfahrung	Spearman Korrelation	-0,169	0,186
Bildungsabschluss	Spearman Korrelation	0,075	0,561
Erfahrung	Punktbiseriale Korrelation	-0,099	0,450
LE	Spearman Korrelation	0,754	<0,001
AA	Spearman Korrelation	0,684	<0,001
SI	Spearman Korrelation	0,144	0,277
VT	Spearman Korrelation	0,530	<0,001

Zwischen dem *Geschlecht* und der *NA* konnte ein signifikanter negativer Zusammenhang mit einer schwachen bis mittleren Effektstärke festgestellt werden ($r_{pb} = -0,295$; $p = 0,019$). Dies bedeutet, dass männliche Teilnehmende eine höhere *NA* besitzen als weibliche Teilnehmende. Für das Alter konnte kein signifikanter Zusammenhang mit der *NA* festgestellt werden, wobei sich ein schwacher negativer Effekt zeigte ($r_s = -0,206$; $p = 0,105$). Für die *Berufsgruppe* ($r_{pb} = 0,201$; $p = 0,121$), die *Berufserfahrung* ($r_s = -0,169$; $p = 0,186$), dem *Bildungsabschluss* ($r_s = 0,075$; $p = 0,561$) sowie der *Erfahrung* ($r_{pb} = -0,099$; $p = 0,450$) mit CDSS wurden schwach positive Zusammenhänge gefunden, die nicht signifikant waren.

Für die *LE* ergab sich ein signifikanter stark positiver Zusammenhang mit der *NA* ($r_s = 0,754$; $p < 0,001$). Dies deutet darauf hin, dass eine höhere *LE* mit einer höheren *NA* einhergeht und eine höhere *NA* mit einer höheren *LE* verbunden ist. Zwischen der *AA* und der *NA* zeigte sich ebenfalls ein signifikanter Zusammenhang mit einem stark positiven Effekt ($r_s = 0,684$; $p < 0,001$). Somit lässt sich sagen, dass je höher die *AA* ist, desto höher ist die *NA* und andersrum, je höher die *NA* ist, desto höher ist die *AA*. Bei dem Korrelationstest zwischen dem *SI* und der *NA* konnte ein nicht signifikanter Zusammenhang mit einem schwachen positiven Effekt festgestellt werden ($r_s = 0,144$;

$p = 0,277$). Beim letzten Korrelationstest zwischen dem *VT* und der *NA* konnte ein signifikanter Zusammenhang mit einem starken positiven Effekt beobachtet werden ($r_s = 0,53; p < 0,001$). Somit lässt sich sagen, dass je höher das *VT* in CDSS ist, desto höher ist die *NA* und andersrum, je höher die *NA* ist, desto höher ist das *VT*.

Zusammenfassend lässt sich festhalten, dass *Geschlecht*, *LE*, *AA* und *VT* wahrscheinlich mit der *NA* zusammenhängen. Für diese Variablen kann die Nullhypothese ($H0_1$) verworfen und die Alternativhypothese ($H1_1$) beibehalten werden. Für *Alter*, *Berufsgruppe*, *Berufserfahrung*, *Bildungsabschluss*, *Erfahrung* und *SI* konnte hingegen kein Zusammenhang festgestellt werden, sodass hier die Alternativhypothese ($H1_1$) verworfen und die Nullhypothese ($H0_1$) beibehalten wird.

Für die weitere Analyse wurden die Variablen *LE*, *AA* und *VT* als potenzielle Prädiktoren der *NA* berücksichtigt. Der *SI* wurde aufgrund des nicht signifikanten und schwachen Zusammenhangs mit der abhängigen Variable aus der weiteren statistischen Analyse ausgeschlossen, sodass die Nullhypothese ($H0_4$) und die Alternativhypothese ($H1_4$) in dieser Arbeit unbeantwortet bleiben. Nachfolgend werden die Ergebnisse der Korrelationstest zwischen den soziodemographischen und *LE* in Tabelle 2 zusammengefasst.

Tabelle 2: Ergebnisse Korrelation der unabhängigen Variablen und der Leistungserwartung (*LE*), eigene Darstellung.

Variable	Verfahren	Effekt	p-Wert
Geschlecht	Punktbiseriale Korrelation	-0,433	<0,001
Alter	Spearman Korrelation	-0,353	0,004
Berufsgruppe	Punktbiseriale Korrelation	0,268	0,036
Berufserfahrung	Spearman Korrelation	0,349	0,005
Bildungsabschluss	Spearman Korrelation	0,183	0,150
Erfahrung	Punktbiseriale Korrelation	0,023	0,863

Im Zusammenhang zwischen dem *Geschlecht* und der *LE* konnte ein signifikanter Zusammenhang mit mittelstarkem negativem Effekt festgestellt werden ($r_{pb} = -0,433; p < 0,001$). Männliche Teilnehmende haben demnach eine höhere *LE* als weibliche Teilnehmende. Beim Korrelationstest mit dem *Alter* zeigte sich ebenfalls ein signifikanter Zusammenhang ($r_s = -0,353; p = 0,004$). Der mittlere negative Effekt weist darauf hin, dass je höher das *Alter* der Teilnehmenden ist, desto niedriger fällt die *LE* aus und andersherum, je jünger die Teilnehmenden sind, desto höher ist die *LE*. Der Zusammenhangstest mit der *Berufsgruppe* ergab einen signifikanten Zusammen-

hang mit einer mittleren Effektstärke ($r_{pb} = 0,268; p = 0,036$). Mitarbeitende des therapeutischen Personals haben demnach eine höhere *LE* als das pflegerische Personal. Bei der *Berufserfahrung* konnte ebenfalls ein signifikanter Zusammenhang mit einem mittleren positiven Effekt festgestellt werden ($r_s = 0,349; p = 0,005$). Dies bedeutet, dass je mehr *Berufserfahrung* die Teilnehmenden besitzen, desto höher ist die *LE* und andersherum, je weniger Berufserfahrung vorliegt, desto niedriger ist die *LE*. Somit wird die Nullhypothese ($H0_2$) für das *Geschlecht*, das *Alter*, die *Berufsgruppe* und die *Berufserfahrung* verworfen und die Alternativhypothese ($H1_2$), dass ein Zusammenhang mit der *LE* besteht, wird beibehalten. Demzufolge werden diese Variablen bei den folgenden Berechnungen als potenzielle Moderatoren der *LE* betrachtet.

Der *Bildungsabschluss* ($r_s = 0,183; p = 0,150$) und die *Erfahrung* mit CDSS ($r_{pb} = 0,023; p = 0,863$) zeigten schwache und keine signifikanten Effekte im Zusammenhang mit der *LE*. Daher wird die Alternativhypothese ($H1_2$) verworfen, während die Nullhypothese ($H0_2$), die von keinem Zusammenhang mit dem *LE* ausgeht, bestehen bleibt. Dementsprechend wurden diese Variablen als Moderatoren der *LE* für die folgenden Berechnungen ausgeschlossen.

Im Folgenden sind die Ergebnisse der Korrelationstests zwischen den soziodemografischen Variablen und der AA in Tabelle 3 zusammengefasst.

Tabelle 3: Ergebnisse Korrelation der unabhängigen Variablen und der Aufwandserwartung (AA), eigene Darstellung.

Variable	Verfahren	Effekt	p-Wert
Geschlecht	Punktbiseriale Korrelation	-0,154	0,224
Alter	Spearman Korrelation	-0,039	0,759
Berufsgruppe	Punktbiseriale Korrelation	0,193	0,133
Berufserfahrung	Spearman Korrelation	-0,012	0,923
Bildungsabschluss	Spearman Korrelation	0,075	0,560
Erfahrung	Punktbiseriale Korrelation	-0,074	0,574

Für die Korrelationstests der AA konnten keine signifikanten Zusammenhänge oder mindestens mittelstarke Effekte mit den Variablen *Geschlecht* ($r_{pb} = -0,154; p = 0,224$), *Alter* ($r_s = -0,039; p = 0,759$), *Berufsgruppe* ($r_{pb} = 0,193; p = 0,133$) *Berufserfahrung* ($r_s = -0,012; p = 0,923$), *Bildungsabschluss* ($r_s = 0,075; p = 0,560$) oder *Erfahrung* ($r_{pb} = -0,074; p = 0,574$) festgestellt werden. Somit wird die Alternativhypothese ($H1_3$) verworfen und die Nullhypothese ($H0_3$) beibehalten, dass kein Zusammenhang besteht.

menhang zwischen den soziodemographischen Variablen und der AA besteht. Folglich wurden keine der Variablen als Moderatoren der AA in die multivariate Analyse aufgenommen.

Die Ergebnisse der Korrelationen zwischen den soziodemografischen Variablen und dem VT sind in Tabelle 4 dargestellt.

Tabelle 4: Ergebnisse Korrelation der unabhängigen Variablen und dem Vertrauen (VT), eigene Darstellung.

Variable	Verfahren	Effekt	p-Wert
Geschlecht	Punktbiseriale Korrelation	-0,498	<0,001
Alter	Spearman Korrelation	-0,051	0,686
Berufsgruppe	Punktbiseriale Korrelation	0,126	0,327
Berufserfahrung	Spearman Korrelation	-0,031	0,805
Bildungsabschluss	Spearman Korrelation	-0,018	0,889
Erfahrung	Punktbiseriale Korrelation	-0,173	0,182

Anschließend wurden Zusammenhangstests mit dem VT in CDSS durchgeführt. Dabei konnte ein signifikanter mittlerer bis starker Zusammenhang mit dem *Geschlecht* festgestellt werden ($r_{pb} = -0,498; p < 0,001$). Männliche Teilnehmende wiesen ein höheres VT auf als weibliche Teilnehmende. Für diesen Zusammenhang wird die Nullhypothese ($H0_5$) verworfen und die Alternativhypothese ($H1_5$), die einen Zusammenhang zwischen *Geschlecht* und VT annimmt, beibehalten. Demnach wird das *Geschlecht* für die folgenden Berechnungen als potenziellen Moderator des VT betrachtet.

Für das *Alter* ($r_s = -0,051; p = 0,686$), die *Berufsgruppe* ($r_{pb} = 0,126; p = 0,327$), die *Berufserfahrung* ($r_s = -0,031; p = 0,805$), den *Bildungsabschluss* ($r_s = -0,018; p = 0,889$) und die *Erfahrung* ($r_{pb} = -0,173; p = 0,182$) wurden keine signifikanten Zusammenhänge mit dem VT festgestellt. Außerdem wurden ausschließlich schwache Effektstärken beobachtet. Daher wird für diese Variablen die Alternativhypothese ($H1_5$) verworfen und die Nullhypothese ($H0_5$), die keinen Zusammenhang mit dem VT annimmt, beibehalten. Folglich werden diese Variablen in den multivariaten Analysen als Moderatoren des VT ausgeschlossen.

5.3 Multivariate Analyse

In diesem Kapitel wird untersucht, ob die Prädiktoren mit der NA zusammenhängen und die Varianz erklären können. Die Ergebnisse der linearen und multiplen linearen Regressionsmodelle werden im Folgenden dargestellt.

Die Voraussetzungen der linearen Regressionsmodelle wurden im Vorfeld überprüft (s. Anhang D). Da alle Bedingungen erfüllt sind, konnten die Regressionsmodelle berechnet werden. In der folgenden Tabelle 5 sind die Ergebnisse der einfachen linearen Regressionsmodelle der *LE*, *AA* und *VT* in Zusammenhang mit der *NA* dargestellt.

Tabelle 5: Ergebnisse der einfachen linearen Regressionsmodelle der Leistungserwartung (*LE*), Aufwandserwartung (*AA*) und Vertrauen (*VT*) zur Erklärung der Nutzungsabsicht (*NA*), eigene Darstellung.

Modell	Variablen	B	SE	p-Wert	95%-KI
LE	Konstante	0,908	0,333	0,008	0,242–1,573
	LE	0,801	0,086	<0,001	0,629–0,973
	Modellgüte: $R^2 = 0,591$; $R^2\text{-adjustiert} = 0,584$; $F = 86,71$; $p < 0,001$				
AA	Konstante	0,913	0,376	0,018	0,162–1,665
	AA	0,834	0,103	<0,001	0,629–1,040
	Modellgüte: $R^2 = 0,524$; $R^2\text{-adjustiert} = 0,516$; $F = 66,080$; $p < 0,001$				
VT	Konstante	1,522	0,371	<0,001	0,781–2,263
	VT	0,738	0,112	<0,001	0,514–0,962
	Modellgüte: $R^2 = 0,417$; $R^2\text{-adjustiert} = 0,407$; $F = 43,54$; $p < 0,001$				

Im einfachen Regressionsmodell erklärt die *LE* 58,40 % der Varianz der *NA* in der Stichprobe ($R^2\text{-adjustiert} = 0,584$). Eine Erhöhung des Skalenwertes der *LE* um eine Einheit geht mit einem Anstieg der vorhergesagten *NA* im Mittel um 0,801 Skalenpunkte einher (95%-KI: 0,629–0,973). Das Modell wies mit einem *F*-Wert von 86,71 und $p < 0,001$ ein signifikantes Ergebnis auf. Somit wird die Nullhypothese (H_0) verworfen und die Alternativhypothese (H_1) beibehalten wird, die davon ausgeht, dass die *LE* die *NA* vorhersagen kann und mit dieser in Zusammenhang steht.

Im Modell der *AA* wird die Varianz der *NA* der Stichprobe zu 51,6 % durch die *AA* erklärt ($R^2\text{-adjustiert} = 0,516$). Mit jeder Zunahme des Skalenwertes der *AA* um eine Einheit steigt die *NA* im Mittel um 0,834 Punkte (95%-KI: 0,629–1,040). Mit einem *F*-Wert von 66,080 und einem *p*-Wert von < 0,001 ist das Modell signifikant. Demnach

wird die Alternativhypothese (H_{17}) beibehalten, dass die AA und die NA zusammenhängen und die Nullhypothese (H_{07}) verworfen.

Das letzte einfache Regressionsmodell erklärt 40,70 % der Varianz der NA der Stichprobe durch das VT ($R^2\text{-adjustiert} = 0,407$). Steigt der Skalenwert des VT um eine Einheit, so steigt die NA im Mittel um 0,738 Punkte (95 %-KI: 0,514–0,962). Das Modell ist mit einem F-Wert von 43,54 und $p < 0,001$ signifikant. Somit wird die Nullhypothese (H_{08}) verworfen und die Alternativhypothese (H_{18}) beibehalten, die einen Zusammenhang zwischen VT und NA annimmt.

Im nächsten Schritt wurde in einem multiplen linearen Regressionsmodell untersucht, wie sich LE, AA und VT in einem gemeinsamen Modell mit der NA verhalten. Die Ergebnisse des Grundmodells sind in Tabelle 6 dargestellt.

Tabelle 6: Ergebnisse der multiplen linearen Regression des Grundmodells zur Erklärung der Nutzungsabsicht (NA), eigene Darstellung.

Variablen	B	SE	p-Wert	95%-KI
Konstante	0,088	0,335	0,794	-0,582–0758
LE	0,560	0,095	<0,001	0,370–0,749
AA	0,380	0,116	0,002	0,149–0,611
VT	0,116	0,115	0,319	-0,115–0,346
Modellgüte: $R^2 = 0,710$; $R^2\text{-adjustiert} = 0,695$; $F = 46,55$; $p < 0,001$				

Im Grundmodell erklären die LE, AA und VT 69,50 % der Varianz der NA der Stichprobe ($R^2\text{ adjustiert} = 0,695$). Bei einer Zunahme des Skalenwertes der LE um eine Einheit steigt die NA der Stichprobe im Mittel um 0,560, wenn AA und VT konstant bleiben (95%-KI: 0,370–0,749; $p < 0,001$). Wenn die AA um einen Skalenwert zunimmt und LE sowie VT konstant bleiben, nimmt die NA der Stichprobe im Mittel um 0,380 zu (95%-KI: 0,149–0,611; $p = 0,002$). Der Schätzer von VT ist mit 0,116 und einem großen SE von 0,115 nicht signifikant (95%-KI: -0,115–0,346; $p = 0,319$). Hinzu kommt, dass das 95 %-Konfidenzintervall die 0 miteinschließt, sodass das Modell keinen Hinweis auf einen Zusammenhang zwischen VT und NA liefert.

Das Gesamtmodell ist mit einem F-Wert von 46,55 und einem p-Wert von $< 0,001$ signifikant, sodass angenommen werden kann, dass die getesteten Prädiktoren einen Anteil der NA erklären und miteinander zusammenhängen. Demnach wird die Alternativhypothese (H_{19}) beibehalten und die Nullhypothese (H_{09}) verworfen. Auf Ebene der Einzelprädiktoren zeigen LE und AA signifikante Zusammenhänge mit der NA, während für das VT kein Zusammenhang nachgewiesen werden konnte.

Für die Berechnung der multiplen Regression mit den potenziellen Moderatoren mussten zunächst das *Alter* und die *Berufserfahrung* zu Dummy-Variablen umkodiert werden. Dabei wurde das *Alter* in „unter 30 Jahre“ zu „1“ und „ab 30 Jahre“ zu „2“ eingeteilt. Die *Berufserfahrung* wurde in „unter 10 Jahre“ zu „1“ und „10 Jahre oder mehr“ zu „2“ kodiert. Anschließend werden die Ergebnisse des multiplen linearen Regressionsmodells inklusive potenzieller Moderatoren präsentiert (s. Tabelle 7).

Tabelle 7: Ergebnisse der multiplen linearen Regression des Moderatorenmodells zur Erklärung der Nutzungsabsicht (NA), eigene Darstellung

Variablen	B	SE	p-Wert	95%-KI
Konstante	-0,923	1,395	0,511	-3,732–1,886
LE	0,492	0,263	0,068	-0,038–1,023
AA	0,410	0,155	0,011	0,098–0,723
VT	0,396	0,245	0,113	-0,097–0,889
Geschlecht (RG: männlich)	0,351	1,263	0,782	-2,192–2,895
Alter (RG: unter 30 Jahre)	0,167	1,376	0,904	-2,604–2,937
Berufsgruppe (RG: Pflegerischer Dienst)	0,121	0,703	0,865	-1,296–1,537
Berufserfahrung (RG: unter 10 Jahre)	0,777	1,265	0,542	-1,770–3,323
LE * Geschlecht (RG: männlich)	0,297	0,240	0,222	-0,186–0,781
LE * Alter (RG: unter 30 Jahre)	-0,100	0,362	0,783	-0,829–0,628
LE * Berufsgruppe (RG: Pflegerischer Dienst)	0,001	0,174	0,996	-0,350–0,352
LE * Berufserfahrung (RG: unter 10 Jahre)	-0,120	0,345	0,729	-0,816–0,575
VT * Geschlecht (RG: männlich)	-0,392	0,292	0,186	-0,981–0,197
Modellgüte: R ² = 0,743; R ² -adjustiert = 0,675; F = 10,86; p < 0,001				

Das Moderatorenmodell erklärt 67,5 % der Varianz der NA der Stichprobe und ist insgesamt signifikant ($R^2\text{-adjustiert} = 0,675$; $F = 10,86$; $p < 0,001$). Bei einer Erhöhung des Skalenwertes der *LE* um eine Einheit und die weiteren Variablen konstant bleiben steigt die *NA* der Stichprobe im Mittel um 0,492 Punkte. Dieses Ergebnis ist nicht

jedoch signifikant und weist mit einem relativ hohen *SE* von 0,263 auf eine unsichere Schätzung hin ($p = 0,068$). Das 95 %-Konfidenzintervall schließt die 0 mit ein und stützt damit die vorherige Annahme (95%-KI: $-0,038\text{--}1,023$). Ein ebenfalls nicht signifikantes Ergebnis lässt sich beim *VT* entnehmen ($p = 0,113$). Hier liegt der Schätzer bei 0,396 mit einem hohen *SE* von 0,245 (95%-KI: $-0,097\text{--}0,889$). Demzufolge ist davon auszugehen, dass das *VT* die *NA* weder vorhersagen kann noch mit ihr in Zusammenhang steht. Wenn die *AA* um einen Skalenwert zunimmt und die restlichen Variablen konstant bleiben, nimmt die *NA* der Stichprobe im Mittel um 0,410 zu (95%-KI: $0,098\text{--}0,723$). Dieser Zusammenhang weist einen kleinen *SE* von 0,155 auf und ist signifikant ($p = 0,011$). Daraus lässt sich schließen, dass die *AA* die *NA* vorhersagen kann.

Bei Betrachtung der Moderatoren *Geschlecht*, *Alter*, *Berufsgruppe* und *Berufserfahrung* im Modell zeigt sich, dass keine signifikanten Effekte durch die getesteten Moderatoren gibt. Die *SE* sind für jede Variable größer als der dazugehörige Schätzer und die 95 %-Konfidenzintervalle schließen allesamt die 0 mit ein. Demnach lassen sich keine Gruppenunterschiede der Moderatoren hinsichtlich der *NA* feststellen. Die Interaktionseffekte für den Zusammenhang zwischen *NA* und *LE* sowie den Variablen *Geschlecht*, *Alter*, *Berufsgruppe* und *Berufserfahrung* sind nicht signifikant. Die *SE* sind größer als die Schätzer und die 95 %-Konfidenzintervalle schließen 0 ein. Die Schätzer sind insgesamt gering, wobei der Effekt für *Geschlecht* mit einem Schätzer von 0,297 am größten ist. Demnach lassen sich keine Unterschiede zwischen den Gruppen hinsichtlich des Zusammenhangs zwischen *LE* und *NA* feststellen.

Da das Gesamtmodell signifikant ist, kann davon ausgegangen werden, dass die getesteten Prädiktoren und Moderatoren die Varianz der *NA* erklären können ($p < 0,001$). Demzufolge wird die Nullhypothese (H_{010}) verworfen und die Alternativhypothese beibehalten (H_{110}), die besagt, dass die im Moderatorenmodell getesteten Variablen einen Anteil der Varianz erklären können. Auf Ebene der Einzelprädiktoren zeigt sich lediglich für die *AA* ein signifikanter Zusammenhang mit der *NA*. Die weiteren Prädiktoren und Moderatoren weisen große *SE* auf und liefern keine Hinweise auf Zusammenhänge oder die Vorhersage der *NA*.

6. Diskussion

In diesem Kapitel wird die Bachelorarbeit diskutiert. Zu Beginn werden die zentralen Ergebnisse zusammengefasst und anhand aktueller Studien abgeglichen. Zudem werden die Limitationen und Stärken dieser Arbeit beleuchtet.

6.1 Zusammenfassung der Ergebnisse

Die bivariaten Ergebnisse zeigen, dass die *LE* ($r_s = 0,754$), die *AA* ($r_s = 0,684$) und das *VT* ($r_s = 0,530$) signifikant und stark positiv mit der *NA* zusammenhängen ($p < 0,001$). Zudem zeigt sich ein negativer Zusammenhang mit dem *Geschlecht* ($r_{pb} = -0,295$; $p = 0,019$). Demnach weisen Männer eine höhere *NA* auf als Frauen. *Alter*, *Berufserfahrung*, *Berufsgruppe*, *Bildungsabschluss* und *SI* zeigen hingegen keine signifikanten Korrelationen mit der *NA*. Die einfachen linearen Regressionsmodelle der *LE* ($B = 0,801$), der *AA* ($B = 0,834$) und des *VT* ($B = 0,738$) zeigen, dass diese jeweils signifikante Einzelprädiktoren der *NA* darstellen ($p < 0,001$). Die erklärte Varianz der Stichprobe war bei der *LE* mit 58,40 % am stärksten vertreten, gefolgt von der *AA* mit 51,60 % und am niedrigsten beim *VT* mit 40,70 %. Im Grundmodell konnten 69,50 % der Varianz der *NA* der Stichprobe erklärt werden ($p < 0,001$). Dabei blieben die *LE* ($B = 0,560$, $p < 0,001$) und die *AA* ($B = 0,380$, $p = 0,002$) als signifikante Prädiktoren der *NA* erhalten. Das *VT* konnte kein signifikantes Ergebnis aufweisen, was auf Überlappungen mit der *LE* und *AA* hindeutet ($B = 0,116$, $p = 0,319$). Im Moderatorenmodell konnte mit 67,50 % der Varianz der *NA* der Stichprobe etwas weniger erklärt werden als im Grundmodell ($p < 0,001$). Hierbei zeigen keine der getesteten Moderatorvariablen signifikante Haupteffekte oder Interaktionseffekte. Die *AA* blieb als einziger Prädiktor der *NA* auch in diesem Modell signifikant ($B = 0,410$; $p = 0,011$). Die *LE* zeigte einen hohen Schätzer, blieb jedoch nicht signifikant ($B = 0,492$; $p = 0,068$). Das *VT* konnte in diesem Modell ebenfalls kein signifikantes Ergebnis erzielen ($B = 0,396$, $p = 0,113$).

Die Ergebnisse zeigen, dass insbesondere die *LE* und die *AA* in den berechneten Analysen relevante Faktoren für die *NA* zu sein scheinen. Zudem lassen sich Hinweise auf Zusammenhänge für das *VT* und *Geschlecht* erkennen, während die weiteren untersuchten Variablen auf keine Zusammenhänge hindeuten.

6.2 Einordnung in den Forschungskontext

Die Ergebnisse dieser Untersuchung lassen sich im Kontext bestehender Forschung wie folgt einordnen. Für die *LE* zeigt sich, dass mehrere Studien mithilfe von Korrelationstests zeigen konnten, dass ein mittlerer bis starker Zusammenhang mit der *NA* besteht (Sultan et al., 2024, S. 6; Dingel et al., 2024, S. 8-9; Berge et al., 2023, S. 9). In der vorliegenden Untersuchung zeigte sich sogar ein noch stärkerer Effekt im Zusammenhang mit der *NA* ($r_s = 0,754$; $p < 0,001$). Auch im einfachen Regressionsmodell sowie im Grundmodell erwies sich die *LE* als signifikanter Prädiktor der *NA*. Ver-

gleichbare Ergebnisse berichten auch andere Studien (Dingel et al., 2024, S. 9; Sultan et al., 2024, S. 7; Wang et al., 2025, S. 6; Eiskjær et al., 2023, S. 7). In der Studie von Sultan et al. (2024) wurde die *LE* im Regressionsmodell als stärkster Prädiktor der *NA* identifiziert ($B = 0,434$; $p < 0,001$) (S. 7). Das berechnete Moderatorenmodell dieser Bachelorarbeit zeigt hingegen, dass *LE* die Varianz der *NA* nicht signifikant erklären kann.

Hinsichtlich der *AA* bestätigen frühere Studien einen signifikanten Zusammenhang mit der *NA* in bivariaten Analysen (Berge et al., 2023, S. 9; Dingel et al., 2024, S. 8-9; Sultan et al., 2024, S. 6). Dieses Ergebnis bestätigt sich in der vorliegenden Untersuchung ($r_s = 0,684$; $p < 0,001$). Darüber hinaus erwies sich die *AA* in allen getesteten Modellen als einziger signifikanter Prädiktor der *NA* und deckt sich damit mit den Befunden anderer Studien (Eiskjær et al., 2023, S. 7; Wang et al., 2025, S. 6). Abweichend davon fanden Kücking et al. (2024) in ihrer multiplen Regressionsanalyse jedoch keine signifikanten Hinweise auf einen Zusammenhang oder eine Vorhersage der *NA* durch *AA* (S. 285–286).

In Bezug auf das *VT* zeigen sich in der Forschung teils gegensätzliche Ergebnisse. Während die Studie von Cornelissen et al. (2022, S. 6) und die Metaanalyse von Dingel et al. (2024, S. 8-9) belegen, dass das *VT* zu den wichtigsten Prädiktoren der *NA* gehört, kommt die Studie von Eiskjær et al. (2023, S. 7) zu dem Ergebnis, dass das *VT* keinen Einfluss besitzt. Wie in der Literatur zeigen sich auch bei den Befunden dieser Studie uneinheitliche Ergebnisse. Die Korrelationstests und das einfache Regressionsmodell zeigen zwar einen starken Zusammenhang mit der *NA*. Im Grund- und Moderatorenmodell zeigen sich jedoch keine signifikanten Ergebnisse.

In dieser Bachelorarbeit konnte der *SI* bereits in der bivariaten Analyse einen schwachen, nicht signifikanten Zusammenhang mit der *NA* berichten. Dies wurde auch in der Studie von Eiskjær et al. (2023) festgestellt (S. 7). Dies steht jedoch im Widerspruch zu Befunden, die nahelegen, dass der *SI* für die *NA* relevant ist (Berge et al., 2023, S. 9; Dingel et al., 2024, S. 8-9; Sultan et al., 2024, S. 6).

Für die Moderatoren konnten in dieser Studie keine signifikanten Interaktionseffekte nachgewiesen werden. Ähnliche Ergebnisse zeigen auch andere Studien (Berge et al., 2023, S. 9-10; Dingel et al., 2024, S. 11; Kücking et al., 2024, S. 285–286). In der bivariaten Analyse zeigte sich ein signifikant schwächer bis moderater Zusammenhang zwischen *Geschlecht* und *NA*. Einen vergleichbaren leichten Effekt konnte Cornelissen et al. (2022) ebenfalls beobachten (S. 7). Im Moderatorenmodell zeigte das *Geschlecht* jedoch weder als Einzelprädiktor noch in Interaktion mit *LE* und *NA* einen signifikanten Einfluss.

Die Ergebnisse dieser Untersuchung stimmen größtenteils mit den Befunden der bisherigen Forschung überein, insbesondere hinsichtlich der *LE* und *AA* für die *NA*. Abweichungen zeigen sich dagegen beim *VT* und dem *SI*, deren Zusammenhang mit der *NA* in dieser Studie uneinheitlich bzw. nur schwach ausgeprägt war.

6.3 Limitationen

Zu Beginn ist festzuhalten, dass im Rahmen dieser Bachelorarbeit keine Kausalitäten bzw. Einflussfaktoren nachgewiesen werden können. Dafür wäre ein randomisiert kontrolliertes Studiendesign erforderlich gewesen, nicht jedoch das querschnittliche Vorgehen dieser Untersuchung (Kreienbrock et al., 2012, S. 107). Korrelationstests dienen dazu, Zusammenhänge zwischen zwei Variablen nachzuweisen und sind lediglich eine Voraussetzung, um Kausalitäten nachzuweisen (Bortz & Schuster, 2010, S. 160). Die in den berechneten Regressionsmodellen einbezogenen Prädiktoren dienten dazu, einen Teil der Varianz der *NA* zu erklären und statistische Zusammenhänge zwischen den Variablen darzustellen (ebd., S. 184). Dabei lassen sich jedoch keine Einflüsse im Sinne von Kausalwirkungen nachweisen. Auf Grundlage des UTAUT-Modells kann zwar theoretisch von solchen Einflüssen ausgegangen werden, in dieser Arbeit wird jedoch ausschließlich auf statistische Zusammenhänge Bezug genommen (Venkatesh et al., 2003, S. 446–448).

Des Weiteren waren die Rahmenbedingungen der Untersuchung methodisch herausfordernd. Die Befragung bezog sich auf eine hypothetische Einführung von CDSS, weshalb es den Mitarbeitenden aus den Bereichen Pflege und Therapie möglicherweise schwerfiel, eine fundierte Einstellung zum Thema zu entwickeln. In anderen Studien wurde die Akzeptanz hingegen in frühen oder späteren Implementierungsphasen untersucht (Berge et al., 2023, S. 2; Wang et al., 2025, S. 4). Dort konnten die Befragten ihre Einschätzungen auf konkrete Nutzungserfahrungen stützen, was in dieser Arbeit nicht gegeben war. Gleichzeitig liegt jedoch ein Mehrwert darin, die Perspektiven der Mitarbeitenden vor der Einführung zu erfassen, um potenzielle Barrieren und förderliche Faktoren frühzeitig zu identifizieren.

Eine weitere Limitation ergibt sich aus dem allgemeinen Fokus auf CDSS. Es wurde nicht zwischen unterschiedlichen Funktionen oder Arten von CDSS, wie beispielsweise KI-basierten oder leitlinienbasierten Systemen, unterschieden. Zwar wurden im Flyer Beispiele genannt, dennoch konnten nicht alle denkbaren Funktionen abgebildet werden, sodass nur ein allgemeines Bild vermittelt wurde. Zudem hatte die Zielgruppe wenig praktische Erfahrung mit derartigen Systemen, wodurch die konkrete

Einschätzung der Nützlichkeit und Anwendbarkeit eingeschränkt war. Dies betrifft auch die Bewertung der Konstrukte *LE*, *AA* und *SE*.

Das Messinstrument stellt eine weitere Einschränkung dar. Die Fragen basierten auf den Konstrukten des UTAUT-Modells und aktueller Literatur, dennoch bleibt unklar, ob alle relevanten Aspekte erfasst wurden. In früheren Studien variierte zudem die Anzahl der Items pro Konstrukt, sodass potenziell wichtige Informationen nicht berücksichtigt sein könnten (Eiskjær et al., 2023, S. 5; Kücking et al., 2024, S. 284). Die Konstrukte „Freiwilligkeit“ und „FB“ des UTAUT-Modells wurden nicht einbezogen, da Entscheidungen über Geräte und Systeme in Krankenhäusern überwiegend von der Unternehmensführung getroffen werden und Mitarbeitende nur begrenzt in die Entscheidungsprozesse eingebunden sind. Die hierarchische Struktur von Einliniensystemen sowie die Anwendung von Top-down-Ansätze wie dem Business Process Reengineering verdeutlichen, dass Mitarbeitende in kritischen Situationen keine Wahlmöglichkeiten hinsichtlich der Nutzung haben (Ampofo, 2016, S. 20–24). Zudem existieren am BGKH derzeit noch keine CDSS, weshalb Aussagen zu freiwilliger Nutzung oder FB nur eingeschränkt möglich waren. Durch den Ausschluss dieser Konstrukte kann es sein, dass für die Akzeptanz im untersuchten Kontext relevante Informationen nicht erfasst wurden.

Als weitere Einschränkung lässt sich diskutieren, ob in dieser Bachelorarbeit das *Geschlecht* als Prädiktor statt als Moderator berücksichtigt werden sollte. Es zeigte sich ein schwacher bis mittlerer signifikanter Zusammenhang mit der NA, der darauf hindeutet, dass *Geschlecht* potenziell direkt mit der NA in Verbindung steht und weniger einen moderierenden Effekt besitzt ($r_{pb} = -0,295$; $p = 0,019$). Ein weiterer Hinweis darauf liefert, dass das *Geschlecht* im Moderatorenmodell nicht als signifikanter Moderator der NA identifiziert werden konnte. Eine Aufnahme als Prädiktor hätte möglicherweise weiterführende Erkenntnisse geliefert, stünde jedoch im Widerspruch zum theoretischen Rahmen des UTAUT-Modells, wodurch potenziell relevante Effekte unberücksichtigt bleiben könnten (Venkatesh et al., 2003, S. 447).

Hinsichtlich des SI konnten keine signifikanten Zusammenhänge festgestellt werden. Dies kann sowohl auf die Formulierung der Items als auch auf das theoretische Setting zurückzuführen sein. Die abgefragten Items bezogen sich darauf, ob Kolleg:innen oder Vorgesetzte die Nutzung von CDSS erwarten oder begrüßen würden. Solche Einschätzungen sind grundsätzlich schwer zu treffen, insbesondere ohne ein tatsächlich verfügbares CDSS. Unter diesen Bedingungen bleibt die Beurteilung des SI im Zusammenhang mit der NA unklar.

In dieser Arbeit wurde das UTAUT-Modell anstelle des aktuelleren UTAUT2 verwendet. Diese Entscheidung ergab sich aus dem spezifischen Setting sowie aus den begrenzten zeitlichen und personellen Ressourcen. Darüber hinaus hätten die drei zusätzlichen Einflussfaktoren im Rahmen der Befragung nicht realistisch abgebildet werden können. Die hedonistische Motivation und die Gewohnheit wurden daher nicht abgebildet, da bislang keine CDSS am BGKH implementiert sind und die Befragten dies daher nur schwer hätten einschätzen können. Auch das Preis-Leistungs-Verhältnis wurde nicht berücksichtigt, da die Kosten für Anschaffung und Implementierung von CDSS überwiegend von den Institutionen, den jeweiligen Bundesländern sowie den Versicherungen getragen werden und somit für die Endnutzenden lediglich eine geringe Relevanz besitzen (Ampofo, 2016, S. 74–75). Die im UTAUT2 ergänzten Konstrukte hätten möglicherweise zusätzliche Erkenntnisse für das Verständnis der Akzeptanz von CDSS liefern können (Venkatesh et al., 2012, S. 158-162). Mit dem UTAUT2-Modell konnten 74 % der Varianz die NA erklären und 52 % des Nutzungsverhalens. Im Vergleich zum ursprünglichen UTAUT-Modell kann UTAUT2 einen größeren Anteil der Varianz sowohl der NA als auch des tatsächlichen Nutzungsverhaltens erklären (ebd., S. 171).

Eine weitere Limitation stellt der Ausschluss der Allgemeinen Selbstwirksamkeit Kurzskala von Beierlein et al. (2014) dar. Zwar wurde die Skala im Rahmen dieser Erhebung erfasst, jedoch zeigte sich in der bivariaten Analyse ein sehr schwacher und nicht signifikanter Zusammenhang mit der NA. Darüber hinaus legt die vorhandene Literatur nahe, dass Selbstwirksamkeit vermutlich kein Prädiktor der Akzeptanz von CDSS ist (Tetri & Juujärvi, 2022, S. 298; Sultan et al., 2024, S. 7). Aus diesen Gründen wurde die Skala in dieser Untersuchung nicht berücksichtigt.

Der Zugang zur Zielgruppe gestaltete sich schwierig, da während des Praktikums im Qualitäts- und Risikomanagement keine direkte Beziehung zu den Mitarbeitenden aufgebaut werden konnte. Schichtdienste, begrenzte Zeitressourcen sowie organisatorische Einschränkungen erschwerten den persönlichen Kontakt zusätzlich. Da die Rekrutierung der Teilnehmenden nicht auf einer randomisierten Auswahl basierte, sondern hauptsächlich über Flyer, Intranetbeiträge, persönliche Kontakte und Veranstaltungen erfolgte, besteht die Möglichkeit eines Selektionsbias in dieser Bachelorarbeit (Kreienbrock, 2012, S. 64). Es wurde bewusst eine nicht-zufällige Auswahlmethode gewählt, bei der die Teilnehmenden bestimmte Einschlusskriterien erfüllen mussten. Hintergrund dieser Entscheidung war, dass sowohl bei der Forscherin als auch bei der Zielgruppe nur begrenzte Zeitressourcen zur Verfügung standen (Löffler

& Von der Heyde, 2013, S. 19-20). Mit dieser Vorgehensweise wurde zudem eine höhere Rücklaufquote als bei einer randomisierten Zufallsstichprobe erwartet.

Von der Gesamtpopulation von etwa 1.150 Mitarbeitenden konnten 67 Teilnehmende rekrutiert werden, was einer Rücklaufquote von 5,83 % entspricht. Eine Studie von Baruch und Holtom (2008) untersuchte die Rücklaufquoten verschiedener Befragungstypen und zeigte, dass die durchschnittliche Rücklaufquote der 223 untersuchten Studien im Jahr 2020 bei 65 % lag ($SD = 25$) (S. 1570). Die Rücklaufquote dieser Untersuchung ist demnach als niedrig einzustufen. Dies erschwert die Repräsentativität der Grundgesamtheit von etwa 1.150 Mitarbeitenden. Dies steht im Widerspruch zu Friedrichs' (1982) Anforderungen an Stichproben, nach denen diese ein kleineres Abbild der Grundgesamtheit darstellen sollten (S. 125). Ein möglicher Grund für die geringe Stichprobe ist, dass der Fragebogen ausschließlich in deutscher Sprache vorlag. Dadurch ist es möglich, dass einige Mitarbeitende aufgrund der Sprachbarriere nicht teilnehmen konnten. Da im BGKH regelmäßig internationale Pflegekräfte eingesetzt werden, konnte ihre Perspektive in der Untersuchung nicht ausreichend berücksichtigt werden. Dies ist vor dem Hintergrund zu betrachten, dass das BGKH ein spezielles Programm für internationale Pflegekräfte anbietet und sich aktiv für deren Integration einsetzt (BGKH, o.J. i)

Darüber hinaus ist eine ungleiche Verteilung der Berufsgruppen zu erkennen, weshalb Unterschiede zwischen dem pflegerischen Personal ($n = 46$) und dem therapeutischen Personal ($n = 18$) nicht mit Unterschiedstests berücksichtigt werden konnten. Die unterschiedlichen Gruppengrößen lassen sich unter anderem durch die Zielgruppengrößen erklären. Beim pflegerischen Personal ($N \approx 850$) sind etwa dreimal so viele Mitarbeitende beschäftigt wie beim therapeutischen Personal ($N \approx 300$). Ein Teil des therapeutischen Personals arbeitet am RehaZentrum HafenCity, das aus organisatorischen Gründen nicht besucht werden konnte, weshalb die Zugangsinformationen zu dem Flyer nur digital verbreitet wurden. Dadurch ist es möglich, dass nicht alle therapeutischen Mitarbeitenden erreicht wurden. Rückblickend wäre es sinnvoller gewesen, den Fokus auf eine einzelne Berufsgruppe zu legen, da sich die Ergebnisse dadurch besser interpretieren ließen. Eine ausgewogene Übertragung auf beide Berufsgruppe ist daher nur eingeschränkt möglich.

Insgesamt zeigen die genannten Limitationen, dass die Ergebnisse dieser Bachelorarbeit nur bedingt auf die Gesamtpopulation übertragbar sind und daher überwiegend für die erhobene Stichprobe gelten.

6.4 Stärken

Neben den Limitationen weist die vorliegende Arbeit auch mehrere Stärken auf, die im Folgenden dargestellt werden.

Ein zentrales methodisches Fundament bildet das UTAUT-Modell, das in zahlreichen Studien zur Technologieakzeptanz eingesetzt wurde und in der Literatur als theoretisch fundierter Ansatz gilt. Es ermöglicht die Erfassung und Abbildung zentraler Prädiktoren und Moderatoren der NA (Venkatesh et al., 2003, S. 447). Damit stellte das Modell einen anerkannten Bezugsrahmen dar, der sowohl die Auswahl der Variablen als auch die Hypothesenbildung theoriegeleitet strukturierte. Zugleich ließ es sich an den spezifischen Kontext anpassen, sodass die Operationalisierung der Konstrukte auf die Bedingungen des BGKH zugeschnitten werden konnte.

Zur Sicherung der Datenqualität wurde der Fragebogen vorab in einem Pretest erprobt. Auf diese Weise konnten unklare oder missverständliche Formulierungen identifiziert und angepasst werden. Dadurch wurde sowohl die Verständlichkeit der Items erhöht als auch die Anpassung des Instruments an das konkrete Setting verbessert.

Darüber hinaus basieren die Analysen auf Individualdaten, sodass die Ergebnisse den einzelnen Untersuchungseinheiten zugeordnet werden konnten. Dadurch war der Einsatz differenzierter statistischer Verfahren wie Korrelationstests und linearer Regressionen möglich. Durch diese Vorgehensweise war es möglich, potenzielle Störfaktoren statistisch zu kontrollieren und Moderationseffekte über Interaktionsterme zu prüfen. Somit war eine differenziertere Analyse der Zusammenhänge zwischen den Variablen und der Akzeptanz von CDSS möglich. Dieser Ansatz entspricht dem methodischen Vorgehen vergleichbarer Studie. Auch wenn keine Kausalitäten nachgewiesen werden können, erlaubt dieses Vorgehen eine robuste und differenzierte Be trachtung der Zusammenhänge.

Die Nutzung des Befragungstools „EvaSys“, brachte weitere Vorteile mit sich. Da die Zielgruppe die Plattform bereits aus wiederkehrenden Befragungen kannte, war eine gewisse Vertrautheit mit der Anwendung gegeben. Zudem ermöglichte die digitale Durchführung eine orts- und zeitunabhängige Teilnahme. Die Teilnehmenden konnten somit frei entscheiden, ob sie den Fragebogen während der Arbeitszeit oder in ihrer Freizeit bearbeiten wollten.

Eine weitere Stärke ergibt sich aus der Einbettung der Untersuchung in das Praktikum im Qualitäts- und Risikomanagement. Dadurch bestand die Möglichkeit, die Strukturen und Abläufe im BGKH näher kennenzulernen und die Befragung gezielt auf die Zielgruppe zuzuschneiden. Trotz der beschriebenen Schwierigkeiten beim Zugang

zum pflegerischen und therapeutischen Personal konnte eine Stichprobe von 67 Mitarbeitenden gewonnen werden. Zudem deutet die erzielte Rücklaufquote darauf hin, dass die Mitarbeitenden ein gewisses Interesse am Thema haben und die Fragestellung als relevant wahrnehmen.

7. Fazit und Ausblick

Die Untersuchung zeigt hinsichtlich der Beantwortung der Leitfrage, dass insbesondere die *LE* und *AA* signifikant mit der *NA* von CDSS zusammenhängen. Die Zusammenhänge von *VT* und *Geschlecht* sollten in weiteren Studien vertieft untersucht werden. Weder direkte Zusammenhänge noch Interaktionseffekte konnten für *SI* sowie die demografischen Variablen nachgewiesen werden. Das Grundmodell mit *LE*, *AA* und *VT* erklärte 69,5 % der Varianz der *NA*. Zu beachten ist, dass in dieser Arbeit ausschließlich der Akzeptanz von CDSS erfasst wurde. Rückschlüsse auf die tatsächliche Nutzung lassen sich daher nicht ziehen. Auf Basis des UTAUT-Modells und der Ergebnisse vergleichbarer Studien kann jedoch ein theoretischer Zusammenhang zwischen Akzeptanz und Nutzung angenommen werden.

Die Ergebnisse beziehen sich ausschließlich auf die Stichprobe dieser Untersuchung am BGKH und lassen sich daher nur bedingt auf alle Mitarbeitenden der Pflege- und Therapiebereiche der Einrichtung übertragen. Vor dem Hintergrund der zunehmenden Digitalisierung und der Einführung KI-gestützter Systeme liefert diese Arbeit erste Einblicke in die Faktoren, die die Akzeptanz von CDSS beeinflussen. Für zukünftige Studien wäre es sinnvoll, sowohl die tatsächliche Nutzung als auch die Akzeptanz in größeren Stichproben zu untersuchen.

Ein vertieftes Verständnis dieser Faktoren kann dazu beitragen, Implementierungsprozesse neuer Technologien gezielter zu gestalten. Dabei sollte insbesondere auf die Förderung der möglichen Leistung sowie die Minimierung des wahrgenommenen Aufwands geachtet werden. Dies kann beispielsweise durch gezielte Schulungen und eine aktive Einbindung der Mitarbeitenden erreicht werden. So lassen sich die potentiellen Vorteile von CDSS, wie Kosteneffizienz, erhöhte Patientensicherheit und Qualität der Versorgung, besser nutzen, während gleichzeitig Herausforderungen wie Abhängigkeit von Systemen, Datenschutz- und Sicherheitsrisiken berücksichtigt werden müssen.

8. Literaturverzeichnis

- Algaze, C. A., Wood, M., Pageler, N. M., Sharek, P. J., Longhurst, C. A., & Shin, A. Y. (2016). Use of a Checklist and Clinical Decision Support Tool Reduces Laboratory Use and Improves Cost. *Pediatrics*, 137(1), 10.1542/peds.2014-3019. <https://doi.org/10.1542/peds.2014-3019>
- Ampofo, A. (2016). Betriebswirtschaftliche Grundlagen für Mediziner und medizinisches Fachpersonal. In *Springer eBooks*. <https://doi.org/10.1007/978-3-658-10470-2>
- Ash, J. S., Sittig, D. F., Campbell, E. M., Guappone, K. P., & Dykstra, R. H. (2007). Some unintended consequences of clinical decision support systems. *AMIA ... Annual Symposium proceedings. AMIA Symposium, 2007*, (S. 26–30).
- Baruch, Y. & Holtom, B. C. (2008). Survey response rate levels and trends in organizational research. *Human Relations*, 61(8), (S. 1139–1160). <https://doi.org/10.1177/0018726708094863>
- Beierlein, C., Kovaleva, A., Kemper, C. J., & Rammstedt, B. (2014). Allgemeine Selbstwirksamkeit Kurzskala (ASKU). Zusammenstellung sozialwissenschaftlicher Items und Skalen (ZIS). <https://doi.org/10.6102/zis35>
- Bell, C. M., Jalali, A., & Mensah, E. (2013). A Decision Support Tool for Using an ICD-10 Anatomographer to Address Admission Coding Inaccuracies: A Commentary. *Online journal of public health informatics*, 5(2), 222. <https://doi.org/10.5210/ojphi.v5i2.4813>
- Berge, G. T., Granmo, O. C., Tveit, T. O., Munkvold, B. E., Ruthjersen, A. L. & Sharma, J. (2023). Machine learning-driven clinical decision support system for concept-based searching: a field trial in a Norwegian hospital. *BMC Medical Informatics And Decision Making*, 23(1). <https://doi.org/10.1186/s12911-023-02101-x>
- BG Kliniken (o.J.). Das Unternehmen. URL: <https://www.bg-kliniken.de/ueber-uns/das-unternehmen/> [Letzter Zugriff am 10.09.2025].
- BG Klinikum Hamburg (BGKH) (o.J. a). BG Klinikum Hamburg – Organisation. URL: <https://www.bg-kliniken.de/klinikum-hamburg/ueber-uns/bg-klinikum-hamburg/organisation/> [Letzter Zugriff am 10.09.2025].
- BG Klinikum Hamburg (BGKH) (o.J. b). BG Klinikum Hamburg – Standorte. URL: <https://www.bg-kliniken.de/klinikum-hamburg/standorte/> [Letzter Zugriff am 10.09.2025].
- BG Klinikum Hamburg (BGKH) (o.J. c). BG Klinikum Hamburg – Über uns. URL: <https://www.bg-kliniken.de/klinikum-hamburg/ueber-uns/bg-klinikum-hamburg/> [Letzter Zugriff am 10.09.2025].

- BG Klinikum Hamburg (BGKH) (o.J. d). BG Klinikum Hamburg. URL: <https://www.bg-kliniken.de/klinikum-hamburg/fachbereiche/> [Letzter Zugriff am 10.09.2025].
- BG Klinikum Hamburg (BGKH) (o.J. e). Klinikmanagement – Ressort Personal. URL: <https://www.bg-kliniken.de/klinikum-hamburg/ueber-uns/bg-klinikum-hamburg/organisation/verwaltung/personal/> [Letzter Zugriff am 10.09.2025].
- BG Klinikum Hamburg (BGKH) (o.J. f). Organisation – Gesellschafter. URL: <https://www.bg-kliniken.de/klinikum-hamburg/ueber-uns/bg-klinikum-hamburg/organisation/gesellschafter/> [Letzter Zugriff am 10.09.2025].
- BG Klinikum Hamburg (BGKH) (o.J. g). Unsere Geschichte: Eine Klinik in den Dünen. URL: <https://www.bg-kliniken.de/klinikum-hamburg/ueber-uns/bg-klinikum-hamburg/unsere-geschichte/> [Letzter Zugriff am 10.09.2025].
- BG Klinikum Hamburg (BGKH) (o.J. h). Fachbereiche – Pflege. URL: <https://www.bg-kliniken.de/klinikum-hamburg/fachbereiche/detail/pflege/#:~:text=Mit%20%C3%BCber%20800%20Mitarbeiter%20sind,Ebenso%20erg%C3%A4nzen%20das%20Pflegeteam> [Letzter Zugriff am 10.09.2025].
- BG Klinikum Hamburg (BGKH) (o.J. i). Aktuelles – Integration internationaler Pflegekräfte. URL: <https://www.bg-kliniken.de/klinikum-hamburg/ueber-uns/bg-klinikum-hamburg/aktuelles/detail/integration-internationaler-pflegekraefte/> [Letzter Zugriff am 10.09.2025].
- Bitkom (2024). Deutsche wollen die Digitalisierung des Gesundheitswesens – aber die Hälfte fühlt sich überfordert. URL: <https://www.bitkom.org/Presse/Presseinformation/Deutsche-wollen-Digitalisierung-Gesundheitswesen-Haelfte-ueberfordert> [Letzter Zugriff am: 11.09.2025].
- Bortz, J., & Schuster, C. (2010). *Statistik für Human- und Sozialwissenschaftler* (7. Aufl.). Springer. <https://doi.org/10.1007/978-3-642-12770-0>
- Brockhaus. (2006). Akzeptanz. In Brockhaus-Enzyklopädie in 30 Bänden. Band 1 (S. 341). Leipzig u.a.: Brockhaus.
- Büchel, J., Scheufen, M., & Engels, B. (2025). *Digitalisation of the economy in Germany. Digitalisation Index 2024. Summary of the Digitalisation Index results in the project “Development and Measurement of the Digitalisation of the Economy in Germany”*. Institut der deutschen Wirtschaft.
- Cabana, M. D., Rand, C. S., Powe, N. R., Wu, A. W., Wilson, M. H., Abboud, P. A., & Rubin, H. R. (1999). Why don't physicians follow clinical practice guidelines? A framework for improvement. *JAMA*, 282(15), 1458–1465. <https://doi.org/10.1001/jama.282.15.1458>
- Chen, Z., Liang, N., Zhang, H., Li, H., Yang, Y., Zong, X., Chen, Y., Wang, Y., & Shi, N. (2023). Harnessing the power of clinical decision support systems: challenges and opportunities. *Open heart*, 10(2), e002432. <https://doi.org/10.1136/openhrt-2023-002432>
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2. Aufl.). Erlbaum.
- Cornelissen, L., Egger, C., Van Beek, V., Williamson, L. & Hommes, D. (2022). The Drivers of Acceptance of Artificial Intelligence-Powered Care Pathways Among

- Medical Professionals: Web-Based Survey Study. *JMIR Formative Research*, 6(6). <https://doi.org/10.2196/33368>
- Davis, F. D. (1989). Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *MIS Quarterly*, 13(3), (S. 319–340). <https://doi.org/10.2307/249008>
- Davis, F. D., Bagozzi, R. P., & Warshaw, P. R. (1989). User Acceptance of Computer Technology: A Comparison of Two Theoretical Models. *Management Science*, 35(8), (S. 982–1003). <http://www.jstor.org/stable/2632151>
- Devaraj, S., Sharma, S., Fausto, D., Viernes, S., & Kharrazi, H. (2014). Barriers and facilitators to clinical decision support systems adoption: A systematic review. *Journal of Business Administration Research*, 3(2), (S. 36–47). <https://doi.org/10.5430/jbar.v3n2p36>
- Dingel, J., Kleine, A., Cecil, J., Sigl, A., Lermer, E. & Gaube, S. (2024). Predictors of Healthcare Practitioners' Intention to Use AI-Enabled Clinical Decision Support Systems (AI-CDSSs): A Meta-Analysis Based on the Unified Theory of Acceptance and Use of Technology (UTAUT) (Preprint). *Journal Of Medical Internet Research*. <https://doi.org/10.2196/57224>
- Döring, N. (2023). *Forschungsmethoden und Evaluation in den Sozial- und Humanwissenschaften* (6. Aufl.). Springer. <https://doi.org/10.1007/978-3-662-64762-2>
- Eckey, H. F., Kosfeld, R., & Turck, M. (2008). *Deskriptive Statistik* (5. Aufl.). In Springer Gabler. <https://doi.org/10.1007/978-3-8349-8779-2>
- Eiskjær, S., Pedersen, C. F., Skov, S. T. & Andersen, M. Ø. (2023). Usability and performance expectancy govern spine surgeons' use of a clinical decision support system for shared decision-making on the choice of treatment of common lumbar degenerative disorders. *Frontiers in Digital Health*, 5. <https://doi.org/10.3389/fdgth.2023.1225540>
- Elhaddad, M. & Hamam, S. (2024). AI-Driven Clinical Decision Support Systems: An Ongoing Pursuit of Potential. *Cureus*. <https://doi.org/10.7759/cureus.57728>
- Fehér, K., Hutapea, L., Malanowski, N., & Ratajczak, A. (2019). *Arbeiten in der zukünftig vernetzten Klinik* (Working Paper Nr. 143). Hans-Böckler-Stiftung.
- Fishbein, M. & Ajzen, I. (1975). *Belief, Attitude, Intention and Behavior: An Introduction to Theory and Research*. Addison Wesley Publishing Company.
- Friedrichs, J. (1982). *Methoden empirischer Sozialforschung* (10. Aufl.). Springer-Verlag.
- Frost, I. (2017). *Einfache lineare Regression: Die Grundlage für komplexe Regressionsmodelle verstehen*. Springer Fachmedien.
- Georgiou, A., Prgomet, M., Markewycz, A., Adams, E., & Westbrook, J. I. (2011). The impact of computerized provider order entry systems on medical-imaging services: a systematic review. *Journal of the American Medical Informatics Association : JAMIA*, 18(3), (S. 335–340). <https://doi.org/10.1136/amiajnl-2010-000043>
- Goddard, K., Roudsari, A., & Wyatt, J. C. (2011). Automation bias - a hidden issue for clinical decision support system use. *Studies in health technology and informatics*, 164, (S. 17–22).

- Häder, M. (2019). *Empirische Sozialforschung: Eine Einführung* (4. Aufl.). Springer-Verlag. <https://doi.org/10.1007/978-3-658-26986-9>
- IMD. (2024). *Länderranking zur digitalen Wettbewerbsfähigkeit weltweit im Jahr 2024 [Graph]*. In Statista. <https://de.statista.com/statistik/daten/studie/1284906/umfrage/laenderranking-zur-digitalen-wettbewerbsfaehigkeit-weltweit/>
- Kabachinski J. (2013). A look at clinical decision support systems. *Biomedical instrumentation & technology*, 47(5), (S. 432–434). <https://doi.org/10.2345/0899-8205-47.5.432>
- Kilsdonk, E., Peute, L. W., Riezebos, R. J., Kremer, L. C., & Jaspers, M. W. (2016). Uncovering healthcare practitioners' information processing using the think-aloud method: From paper-based guideline to clinical decision support system. *International journal of medical informatics*, 86, (S. 10–19). <https://doi.org/10.1016/j.ijmedinf.2015.11.011>
- Klosa, O. (2016). *Online-Sehen: Qualität und Akzeptanz von Web-TV*. Springer Vie-weg. <https://doi.org/10.1007/978-3-658-15182-9>
- Kreienbrock, L., Pigeot, I., & Ahrens, W. (2012). *Epidemiologische Methoden* (5. Aufl.). Spektrum Akademischer Verlag.
- Kromrey, H., Roose, J., & Strübing, J. (2016). *Empirische Sozialforschung: Modelle und Methoden der standardisierten Datenerhebung und Datenauswertung*. <https://doi.org/10.36198/9783838586816>
- Kuckartz, U., Diker, S. R., Ebert, T., Schehl, J., & Radiker, S. (2010). *Statistik: Eine verständliche Einführung*. Vs Verlag Fur Sozialwissenschaften. <https://doi.org/10.1007/978-3-531-92033-7>
- Kücking, F., Zukunft, S., Schell, H., Birkner, C., Rotegård, A.-K., Hüser, J., & Hübner, U. H. (2024). What determines the use of clinical Decision Support Systems in nursing? Results of a multiple regression analysis. *Studies in Health Technology and Informatics*, 317, (S. 281–288). <https://doi.org/10.3233/SHTI240869>
- Kumar, R. B., Goren, N. D., Stark, D. E., Wall, D. P., & Longhurst, C. A. (2016). Automated integration of continuous glucose monitor data in the electronic health record using consumer technology. *Journal of the American Medical Informatics Association : JAMIA*, 23(3), (S. 532–537). <https://doi.org/10.1093/jamia/ocv206>
- Kutner, M. H., Nachtsheim, C. J., Neter, J., & Li, W. (2005). *Applied linear regression models* (5. Aufl.). McGraw-Hill.
- Leal Rodríguez, C., Kaas-Hansen, B. S., Eriksson, R., Biel, J. H., Belling, K. G., Andersen, S. E., & Brunak, S. (2022). Drug interactions in hospital prescriptions in Denmark: Prevalence and associations with adverse outcomes. *Pharmacoepidemiology and drug safety*, 31(6), (S. 632–642). <https://doi.org/10.1002/pds.5415>
- Ledley, R. S., & Lusted, L. B. (1959). Reasoning foundations of medical diagnosis; symbolic logic, probability, and value theory aid our understanding of how physicians reason. *Science (New York, N.Y.)*, 130(3366), (S. 9–21). <https://doi.org/10.1126/science.130.3366.9>
- Löffler, U., & von der Heyde, C. (2014). Ein Kurz-Überblick über die gebräuchlichsten Auswahl-Verfahren in der Marktforschung. In *Stichproben-Verfahren in der Umfrageforschung* (S. 19–24). Springer Fachmedien Wiesbaden. https://doi.org/10.1007/978-3-531-18882-9_1

- Martinez-Franco, A. I., Sanchez-Mendiola, M., Mazon-Ramirez, J. J., Hernandez-Torres, I., Rivero-Lopez, C., Spicer, T., & Martinez-Gonzalez, A. (2018). Diagnostic accuracy in Family Medicine residents using a clinical decision support system (DXplain): a randomized-controlled trial. *Diagnosis (Berlin, Germany)*, 5(2), (S. 71–76). <https://doi.org/10.1515/dx-2017-0045>
- Oakden-Rayner, L., Carneiro, G., Bessen, T., Nascimento, J. C., Bradley, A. P., & Palmer, L. J. (2017). Precision Radiology: Predicting longevity using feature engineering and deep learning methods in a radiomics framework. *Scientific reports*, 7(1), 1648. <https://doi.org/10.1038/s41598-017-01931-w>
- Poon, E. G., Keohane, C. A., Yoon, C. S., Ditmore, M., Bane, A., Levzion-Korach, O., Moniz, T., Rothschild, J. M., Kachalia, A. B., Hayes, J., Churchill, W. W., Lipsitz, S., Whittemore, A. D., Bates, D. W., & Gandhi, T. K. (2010). Effect of barcode technology on the safety of medication administration. *The New England journal of medicine*, 362(18), (S. 1698–1707). <https://doi.org/10.1056/NEJMsa0907115>
- Pruszydlo, M. G., Walk-Fritz, S. U., Hoppe-Tichy, T., Kaltschmidt, J. & Haefeli, W. E. (2012). Development and evaluation of a computerised clinical decision support system for switching drugs at the interface between primary and tertiary care. *BMC Medical Informatics And Decision Making*, 12(1). <https://doi.org/10.1186/1472-6947-12-137>
- Rodrigues, J. J., de la Torre, I., Fernández, G., & López-Coronado, M. (2013). Analysis of the security and privacy requirements of cloud-based electronic health records systems. *Journal of medical Internet research*, 15(8), e186. <https://doi.org/10.2196/jmir.2494>
- Rosenbloom, S. T., Daniels, T. L., Talbot, T. R., McClain, T., Hennes, R., Stenner, S., Muse, S., Jirjis, J., & Purcell Jackson, G. (2012). Triaging patients at risk of influenza using a patient portal. *Journal of the American Medical Informatics Association : JAMIA*, 19(4), (S. 549–554). <https://doi.org/10.1136/amiajnl-2011-000382>
- Scheuer, D. (2020). *Akzeptanz von künstlicher Intelligenz: Grundlagen intelligenter KI-Assistenten und deren vertrauensvolle Nutzung*. Springer-Verlag. <https://doi.org/10.1007/978-3-658-29526-4>
- Segal, M. M., Rahm, A. K., Hulse, N. C., Wood, G., Williams, J. L., Feldman, L., Moore, G. J., Gehrum, D., Yefko, M., Mayernick, S., Gildersleeve, R., Sunderland, M. C., Bleyl, S. B., Haug, P., & Williams, M. S. (2017). Experience with Integrating Diagnostic Decision Support Software with Electronic Health Records: Benefits versus Risks of Information Sharing. *EGEMS (Washington, DC)*, 5(1), 23. <https://doi.org/10.5334/egems.244>
- Shahsavari, A. M. , Azad Marz Abadi, E. , Hakimi Kalkhoran, M. , Jafari, S. and Qaranli, S. (2015). Clinical Decision Support Systems (CDSs): State of the art Review of Literature. *International Journal of Medical Reviews*, 2(4), (S. 299-308). <https://doi.org/10.1109/icit58056.2023.10226098>
- Sim, I., Gorman, P., Greenes, R. A., Haynes, R. B., Kaplan, B., Lehmann, H. & Tang, P. C. (2001). Clinical Decision Support Systems for the Practice of Evidence-based Medicine. *Journal Of The American Medical Informatics Association*, 8(6), (S. 527–534). <https://doi.org/10.1136/jamia.2001.0080527>
- Sonnet, D. (2022). *Neuronale Netze kompakt: Vom Perceptron zum Deep Learning*. Springer Vieweg. <https://doi.org/10.1007/978-3-658-29081-8>

- Stachwitz, P. & Debatin, J. F. (2023). Digitalisierung im Gesundheitswesen: heute und in Zukunft. *Bundesgesundheitsblatt - Gesundheitsforschung - Gesundheitsschutz*, 66(2), (S. 105–113). <https://doi.org/10.1007/s00103-022-03642-8>
- Sujansky W. (2001). Heterogeneous database integration in biomedicine. *Journal of biomedical informatics*, 34(4), (S. 285–298).
<https://doi.org/10.1006/jbin.2001.1024>
- Sultan, H., Najjar, S., Awartani, F., & Abu-Odah, H. (2024). The unmet needs of adopting clinical decision support system among physicians in Palestinian hospitals. *PloS One*, 19(12). <https://doi.org/10.1371/journal.pone.0310765>
- Sutton, R. T., Pincock, D., Baumgart, D. C., Sadowski, D. C., Fedorak, R. N. & Kroeker, K. I. (2020). An overview of clinical decision support systems: benefits, risks, and strategies for success. *Npj Digital Medicine*, 3(1).
<https://doi.org/10.1038/s41746-020-0221-y>
- Tetri, B. & Juujärvi, S. (2022). Self-Efficacy, Internet Self-Efficacy, and Proxy Efficacy as Predictors of the Use of Digital Social and Health Care Services Among Mental Health Service Users in Finland: A Cross-Sectional Study. *Psychology Research And Behavior Management, Volume 15*, (S. 291–303). <https://doi.org/10.2147/prbm.s340867>
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly*, 27(3), (S. 425–478). <https://doi.org/10.2307/30036540>
- Venkatesh, V., Thong, J. Y. L., & Xu, X. (2012). Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance and Use of Technology. *MIS Quarterly*, 36(1), (S. 157–178).
<https://doi.org/10.2307/41410412>
- Wang, J., Zhou, Y., Tan, K., Yu, Z. & Li, Y. (2025). Acceptance of artificial intelligence clinical assistant decision support system to prevent and control venous thromboembolism among healthcare workers: an extend Unified Theory of Acceptance and Use of Technology Model. *Frontiers in Medicine*, 12.
<https://doi.org/10.3389/fmed.2025.1475577>
- Wasylewicz, A. T. M., & Scheepers-Hoeks, A. M. J. W. (2019). Clinical Decision Support Systems. In *Fundamentals of Clinical Data Science* (S. 153–169). Springer International Publishing. https://doi.org/10.1007/978-3-319-99713-1_11
- Weisberg, S. (2013). *Applied Linear Regression* (4. Aufl.). John Wiley & Sons.
- Wentura, D., & Pospeschill, M. (2015). *Multivariate Datenanalyse: Eine kompakte Einführung*. Springer. <https://doi.org/10.1007/978-3-531-93435-8>
- Wiprayoga, P., & Widagda, K. I. G. (2023). The role of attitude toward using mediates the influence of perceived usefulness and perceived ease of use on behavioral intention to use. *Russian Journal of Agricultural and Socio-Economic Sciences*, 140(8), (S. 53–68). <https://doi.org/10.18551/rjoas.2023-08.06>
- Wirtz, M., & Nachtigall, C. (2012). *Deskriptive Statistik: Statistische Methoden für Psychologen Teil 1* (6. Aufl.). Juventa Verlag.
- Witte, K. (2019). *Angewandte Statistik in der Bewegungswissenschaft (Band 3)*. Springer Verlag. <https://doi.org/10.1007/978-3-662-58360-9>

Eidesstaatliche Erklärung

Hiermit versichere ich, dass ich die vorliegende Bachelorarbeit mit dem Titel:

„Zusammenhang zwischen der Akzeptanz klinischer Entscheidungsunterstützungssysteme und den Konstrukten der Unified Theory of Acceptance and Use of Technology: Eine quantitative Analyse unter pflegerischem und therapeutischem Personal“

selbstständig und ausschließlich unter Benutzung der angegebenen Hilfsmittel ohne Nutzung einer gKI-Anwendung (wie z.B. ChatGPT) angefertigt habe. Alle Stellen, die wörtlich oder sinngemäß aus veröffentlichten und nicht veröffentlichten Schriften entnommen wurden, sind als solche durch Anführungszeichen kenntlich gemacht und die Arbeit war in gleicher oder ähnlicher Fassung noch nicht Bestandteil einer Studien- oder Prüfungsleistung.

Datum

Unterschrift

Anhang

Anhang A: Fragebogen

MUSTER						
evasys	Akzeptanz klinischer Entscheidungsunterstützungssysteme	evasys				
						
Bitte so markieren: <input type="checkbox"/> <input checked="" type="checkbox"/> <input type="checkbox"/> <input type="checkbox"/> Bitte verwenden Sie einen Kugelschreiber oder nicht zu starken Filzstift. Dieser Fragebogen wird maschinell erfasst.						
Korrektur: <input type="checkbox"/> <input checked="" type="checkbox"/> <input type="checkbox"/> Bitte beachten Sie im Interesse einer optimalen Datenerfassung die links gegebenen Hinweise beim Ausfüllen.						
1. Soziodemographische Fragen						
1.1 Welchem Geschlecht fühlen Sie sich zugehörig?	<input type="checkbox"/> männlich	<input type="checkbox"/> weiblich				
	<input type="checkbox"/> keine Angabe	<input type="checkbox"/> divers				
1.2 Wie alt sind Sie?	<input type="checkbox"/> unter 30 Jahre	<input type="checkbox"/> 30-45 Jahre				
	<input type="checkbox"/> keine Angabe	<input type="checkbox"/> ab 46 Jahre				
1.3 Welcher Berufsgruppe gehören Sie an?	<input type="checkbox"/> Pflegerischer Dienst	<input type="checkbox"/> Therapeutischer Dienst				
	<input type="checkbox"/> keine Angabe					
1.4 In welcher Abteilung sind Sie überwiegend tätig?	<input type="checkbox"/> AIR/ INT/ BVI/ ZNA	<input type="checkbox"/> HPMC/ BVO				
	<input type="checkbox"/> QZ	<input type="checkbox"/> SUO/ UOS/ VCH				
	<input type="checkbox"/> sonstiges	<input type="checkbox"/> keine Angabe				
	<input type="checkbox"/> weniger als 3 Jahre	<input type="checkbox"/> 3 bis unter 10 Jahre				
	<input type="checkbox"/> 25 Jahre oder mehr	<input type="checkbox"/> 10 bis unter 25 Jahre				
1.5 Wie viele Jahre Berufserfahrung haben Sie in Ihrem aktuellen Berufsfeld? (ohne Ausbildungszeit)	<input type="checkbox"/> keine Angabe					
1.6 Was ist Ihr höchster Bildungsabschluss?	<input type="checkbox"/> Hauptschulabschluss	<input type="checkbox"/> Realschulabschluss				
	<input type="checkbox"/> Berufsausbildung	<input type="checkbox"/> Diplom/ Bachelor/ Master				
	<input type="checkbox"/> Promotion	<input type="checkbox"/> keine Angabe				
	<input type="checkbox"/> ja	<input type="checkbox"/> nein				
1.7 haben Sie bereits praktische Erfahrungen mit klinischen Entscheidungsunterstützungssystemen in anderen Einrichtungen des Gesundheitswesens gesammelt?	<input type="checkbox"/> keine Angabe	<input type="checkbox"/> weiß ich nicht				
2. Fragen zur Selbstwirksamkeit						
Bitte drehen Sie Ihr Smartphone ins Querformat, damit Sie die folgenden Fragen besser lesen und beantworten können. Die folgenden Aussagen können mehr oder weniger auf Sie zutreffen. Bitte geben Sie bei jeder Aussage an, inwieweit diese auf Sie persönlich zutrifft.						
2.1 In schwierigen Situationen kann ich mich auf meine Fähigkeiten verlassen	<input type="checkbox"/> stimme überhaupt nicht zu	<input type="checkbox"/> stimme eher nicht zu	<input type="checkbox"/> neutral	<input type="checkbox"/> stimme eher zu	<input type="checkbox"/> stimme voll und ganz zu	<input type="checkbox"/> keine Angabe
2.2 Die meisten Probleme kann ich aus eigener Kraft gut meistern	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
2.3 Auch anstrengende und komplizierte Aufgaben kann ich in der Regel gut lösen	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3. Fragen zur Akzeptanz						
Im Folgenden finden Sie Aussagen zur Akzeptanz klinischer Entscheidungsunterstützungssysteme. Bitte beachten Sie, dass sich die Aussagen nicht auf ein konkretes klinisches Entscheidungsunterstützungssystem beziehen, sondern allgemein auf derartige Systeme. Wählen Sie jeweils die Antwortmöglichkeit aus, die am ehesten auf Sie persönlich zutrifft.						

MUSTER

evasys	Akzeptanz klinischer Entscheidungsunterstützungssysteme	 evasys
--------	---	--

3. Fragen zur Akzeptanz [Fortsetzung]

	stimme überhaupt nicht zu	stimme eher nicht zu	stimme eher zu	stimme vor und ganz zu	keine Angabe
3.1 Ich glaube, dass die Nutzung klinischer Entscheidungsunterstützungssysteme meine Arbeitsleistung verbessern würde	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.2 Ich gehe davon aus, dass die Nutzung klinischer Entscheidungsunterstützungssysteme verständlich und nachvollziehbar ist	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.3 Ich glaube, dass Kolleg:innen von mir erwarten würden, klinische Entscheidungsunterstützungssysteme zu nutzen, wenn diese verfügbar wären	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.4 Ich glaube, dass ich mit klinischen Entscheidungsunterstützungssystemen meine Aufgaben schneller und zielgerichteter erledigen kann	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.5 Ich gehe nicht davon aus, dass Kolleg:innen Wert auf die Nutzung auf klinischen Entscheidungsunterstützungssystemen legen	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.6 Ich glaube, dass klinische Entscheidungsunterstützungssysteme meine Arbeitsprozesse verlangsamen würden	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.7 Ich stehe der Einführung klinischer Entscheidungsunterstützungssysteme an meinem Arbeitsplatz positiv gegenüber	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.8 Ich denke, dass klinische Entscheidungsunterstützungssysteme einfach zu bedienen wären	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.9 Ich denke, dass klinische Entscheidungsunterstützungssysteme mir helfen könnten, effizienter zu arbeiten	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.10 Ich plane klinische Entscheidungsunterstützungssysteme zu verwenden, sobald ich Zugang zu ihnen habe	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.11 Ich glaube, dass es schwierig wäre, den Umgang mit klinischen Entscheidungsunterstützungssystemen zu erlernen	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.12 Ich bin überzeugt, dass klinische Entscheidungsunterstützungssysteme meine Effektivität bei der Arbeit erhöhen würde	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.13 Ich denke, dass ich klinische Entscheidungsunterstützungssysteme problemlos steuern und kontrollieren kann	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3.14 Ich würde klinische Entscheidungsunterstützungssysteme nicht nutzen, selbst wenn sie an meinem Arbeitsplatz verfügbar wären	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

MUSTER

MUSTER

evasys	Akzeptanz klinischer Entscheidungsunterstützungssysteme	 evasys
--------	---	--

3. Fragen zur Akzeptanz [Fortsetzung]

- 3.15 Ich denke, dass meine Vorgesetzten es begrüßen würden, wenn ich klinische Entscheidungsunterstützungssysteme in meiner Arbeit einsetzen würde

4. Fragen zum Vertrauen in klinische Entscheidungsunterstützungssysteme

Die folgenden Aussagen können mehr oder weniger auf Sie zutreffen. Bitte geben Sie bei jeder Aussage an, inwieweit diese auf Sie persönlich zutrifft.

	stimme überhaupt nicht zu	stimme eher nicht zu	neutral	stimme eher zu	stimme voll und ganz zu	keine Angabe
4.1	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
4.2	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
4.3	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

MUSTER

Anhang B: Befragungs-Flyer

Wie stehen Sie zu Entscheidungsunterstützungssystemen im Klinikalltag?

Liebe Mitarbeitende aus dem Pflege- und Therapiebereich,

Haben Sie bereits von **klinischen Entscheidungsunterstützungssystemen** gehört? Dies sind **computergestützte Programme**, die medizinisches Personal dabei unterstützen, fundierte Entscheidungen im Behandlungsprozess zu treffen. Diese Systeme analysieren vorhandene Patientendaten (z. B. Vitalparameter, Laborwerte oder Diagnosen) und gleichen diese mit medizinischem Wissen (z. B. aus Leitlinien, Studien oder Erfahrungswerten) ab. Auf dieser Grundlage liefern sie konkrete Empfehlungen, Hinweise oder Warnungen. Beispiele hierfür sind **Frühwarn-, Sturzpräventions- oder Therapieplanungssysteme**.

Im Rahmen meiner Bachelorarbeit untersuche ich die **Akzeptanz klinischer Entscheidungsunterstützungssysteme unter pflegerischem und therapeutischem Personal**. Über den beigefügten QR-Code und Link gelangen Sie zu dem Fragebogen mit 28 Fragen, dessen Beantwortung **etwa 5–10 Minuten** in Anspruch nimmt. Bitte beachten Sie, dass für die Teilnahme an der Studie ein **Mindestalter von 18 Jahren** erforderlich ist. Durch das Scannen des **QR-Codes** oder das Aufrufen des **Links** erteilen Sie Ihr Einverständnis zur **Teilnahme an der Studie**. Eine Teilnahme ist bis zum **25. Juni 2025** möglich.

HINWEIS ZUR TEILNAHME: Die Umfrage ist **nicht über das „BGKH-Gast“ WLAN** aufrufbar. Bitte verwenden Sie **mobile Daten** oder ein **alternatives Netzwerk**.

jetzt scannen!



Alternativ finden Sie hier den Link zur Umfrage:

<https://umfrage.bgk-hamburg.de/evasys/online.php?p=8ZDDY>

Vielen Dank für Ihre Teilnahme!

Bei Fragen oder Anmerkungen können Sie sich gerne bei mir melden:
m.matejek@bgk-hamburg.de

 **BG Klinikum**
Hamburg

Anhang C: Prüfung der Voraussetzungen der Korrelationen

Leistungserwartung (LE)

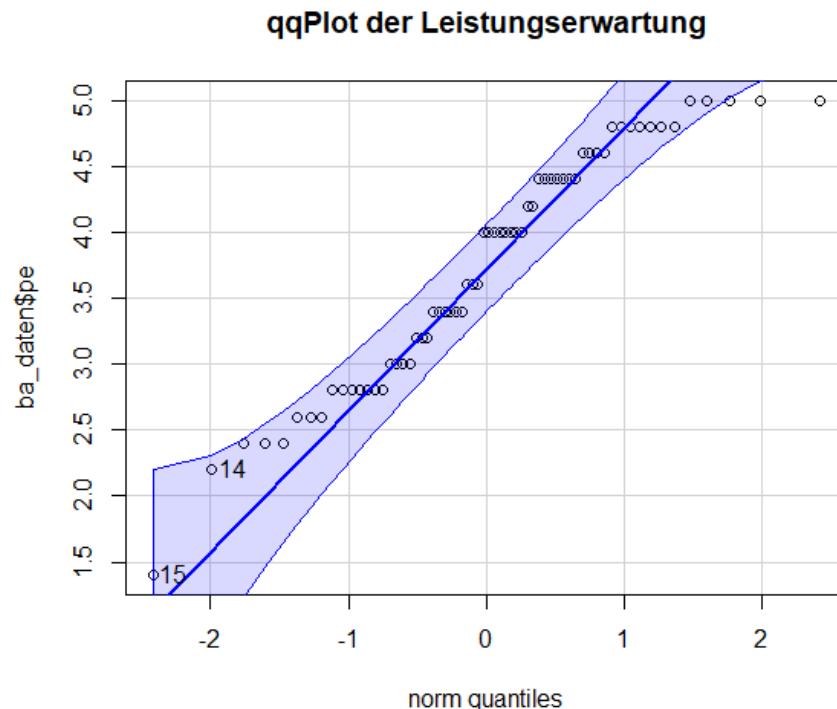


Abb. 1: QQ-Plot der Leistungserwartung (LE), eigene Darstellung.

```
> shapiro.test(ba_daten$pe)

Shapiro-Wilk normality test

data: ba_daten$pe
W = 0.94283, p-value = 0.005156
```

Aufwandserwartung (AA)

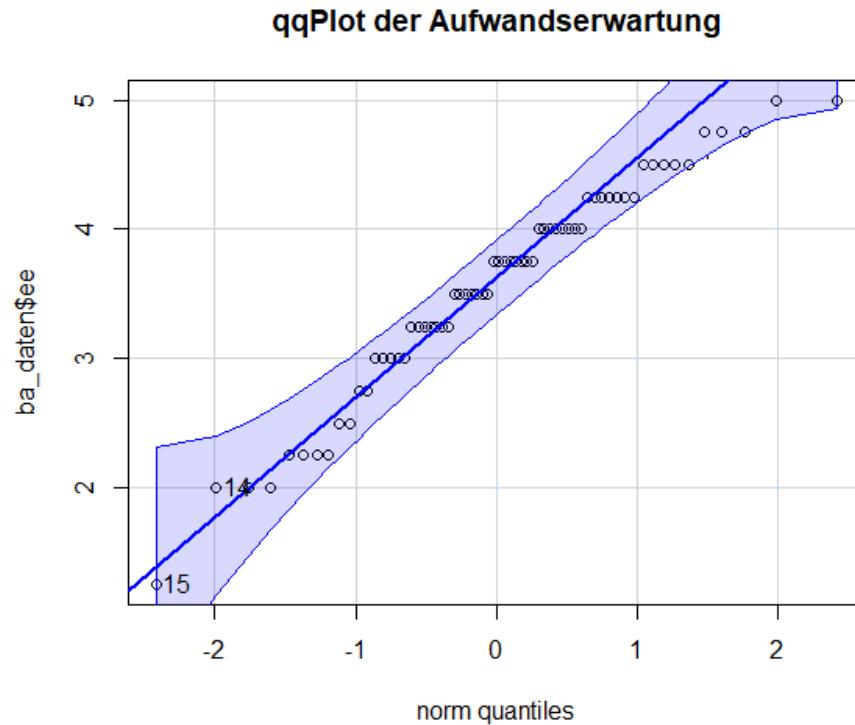


Abb. 2: QQ-Plot der Aufwandserwartung (AA), eigene Darstellung.

```
> shapiro.test(ba_daten$ee)  
Shapiro-Wilk normality test  
  
data: ba_daten$ee  
W = 0.96568, p-value = 0.07199
```

Sozialer Einfluss (SI)

qqPlot vom Sozialen Einfluss

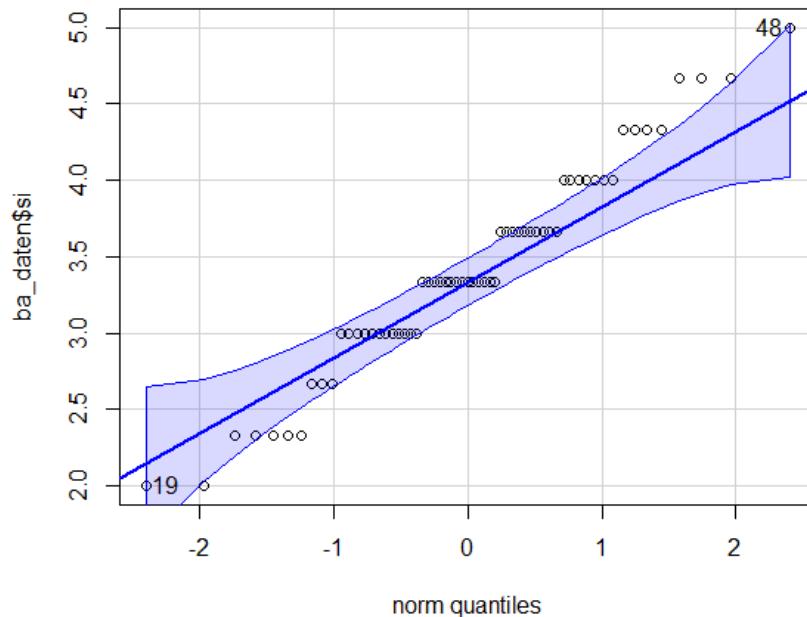


Abb. 3: QQ-Plot des sozialen Einflusses (SI), eigene Darstellung.

```
> shapiro.test(ba_daten$si)

Shapiro-Wilk normality test

data: ba_daten$si
W = 0.97008, p-value = 0.1406
```

Vertrauen (VT)

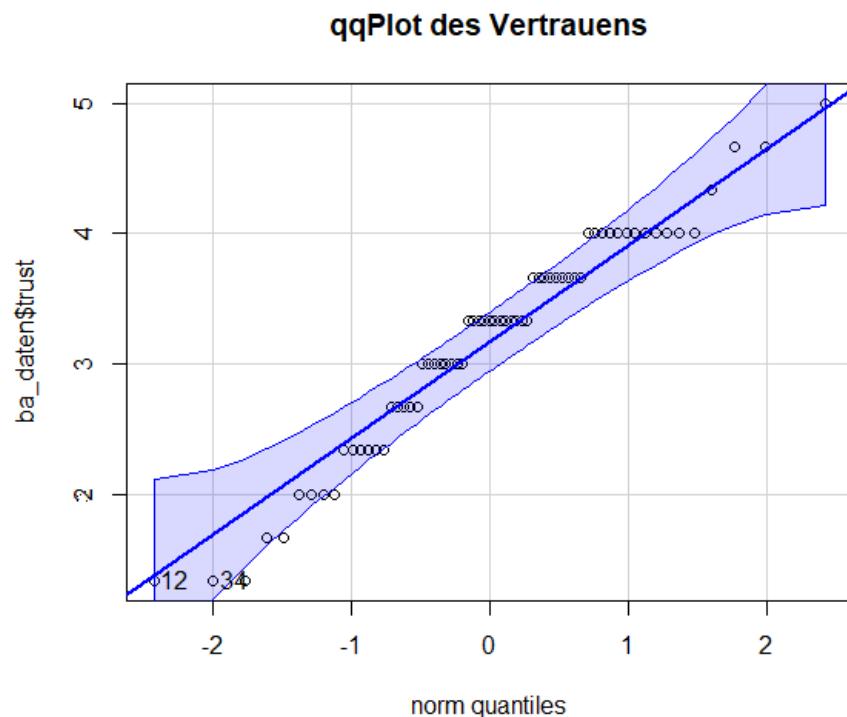


Abb. 4: QQ-Plot des Vertrauens (VT), eigene Darstellung.

```
> shapiro.test(ba_daten$trust)

Shapiro-Wilk normality test

data: ba_daten$trust
W = 0.96043, p-value = 0.03612
```

Nutzungsabsicht (NA)

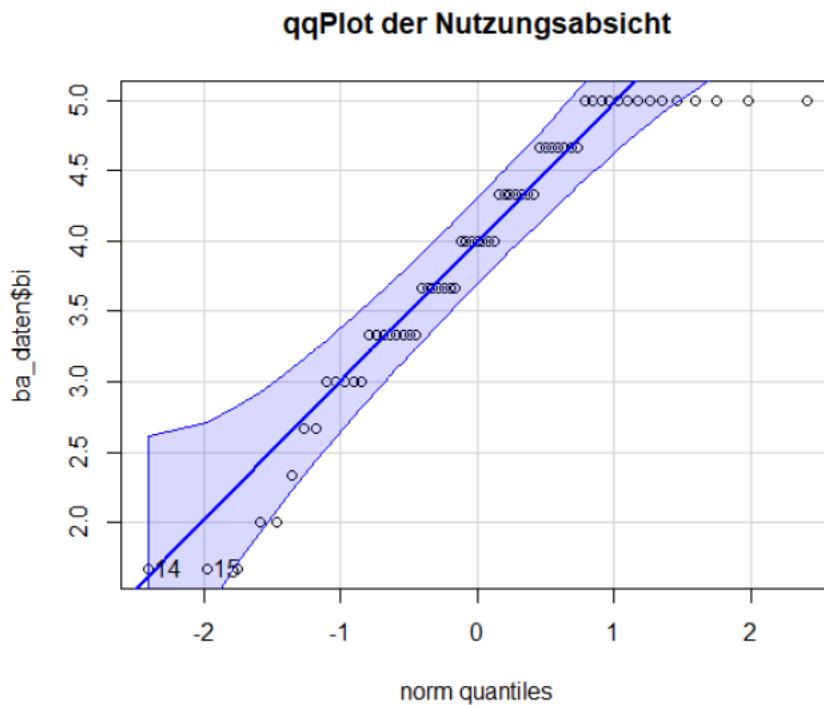


Abb. 5: QQ-Plot der Nutzungsabsicht (NA), eigene Darstellung.

```
> shapiro.test(ba_daten$bi)  
Shapiro-wilk normality test  
data: ba_daten$bi  
W = 0.91093, p-value = 0.0002381
```

Anhang D: Prüfung der Voraussetzungen der linearen Regressionsmodelle

Multikollinearität

Tab. 1: Ergebnisse der Spearman Korrelationen unter den unabhängigen Variablen, eigene Darstellung.

Variablen	rho	p-Wert
LE & AA	0,540	<0,001
LE & VT	0,538	<0,001
VT & AA	0,590	<0,001

Tab. 2: Ergebnisse der Multikollinearitätsprüfung im Grundmodell, eigene Darstellung.

Variable	VIF
LE	1,589
AA	2,042
VT	1,972

Tab. 3: Ergebnisse der Multikollinearitätsprüfung im Moderatorenmodell, eigene Darstellung.

Variable	GVIF	df	GVIF^(1/(2·df))
LE	86,209	9	1,281
AA	3,356	1	1,832
VT	127,450	3	2,243
Alter	72,067	3	2,040
Berufsgruppe	11,596	3	1,504
Berufserfahrung	98,378	3	2,149
Geschlecht	15,317	5	1,314

Linearität

Tab. 4: Quadratische Residuenkomponente im Grundmodell, eigene Darstellung.

Variable	Teststatistik	p-Wert
LE	-0,435	0,666
AA	0,226	0,822
VT	-0,470	0,640
Tukey-Test	-0,613	0,539

Tab. 5: Quadratische Residuenkomponente im Moderatorenmodell, eigene Darstellung.

Variable	Teststatistik	p-Wert
LE	-1,649	0,106
Geschlecht	–	–
Alter	–	–
Berufsgruppe	–	–
Berufserfahrung	–	–
AA	-0,687	0,496
VT	-1,241	0,221
Tukey-Test	-1,635	0,102

Extremwerte

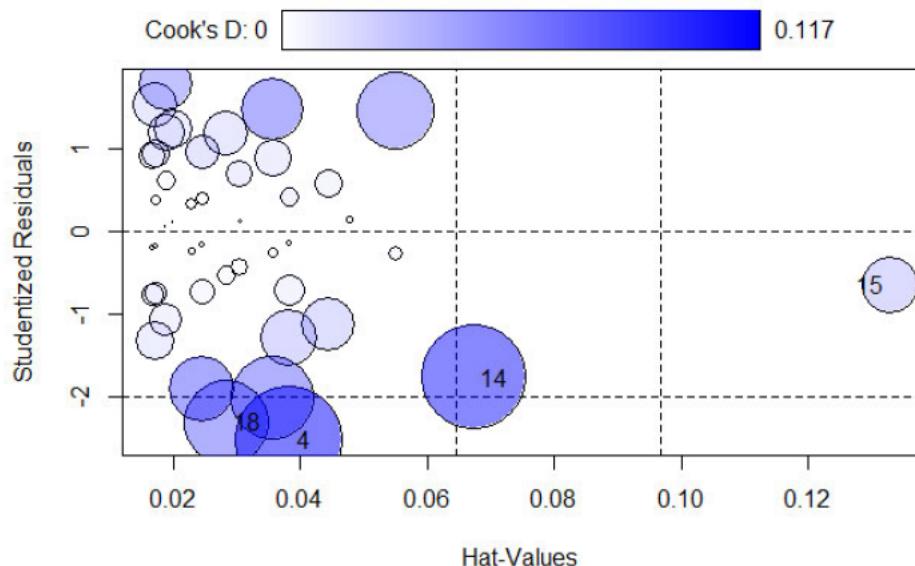


Abb. 6: Einflussplot zur Identifikation potenzieller Extremwerte im Modell der Leistungserwartung (LE), eigene Darstellung.

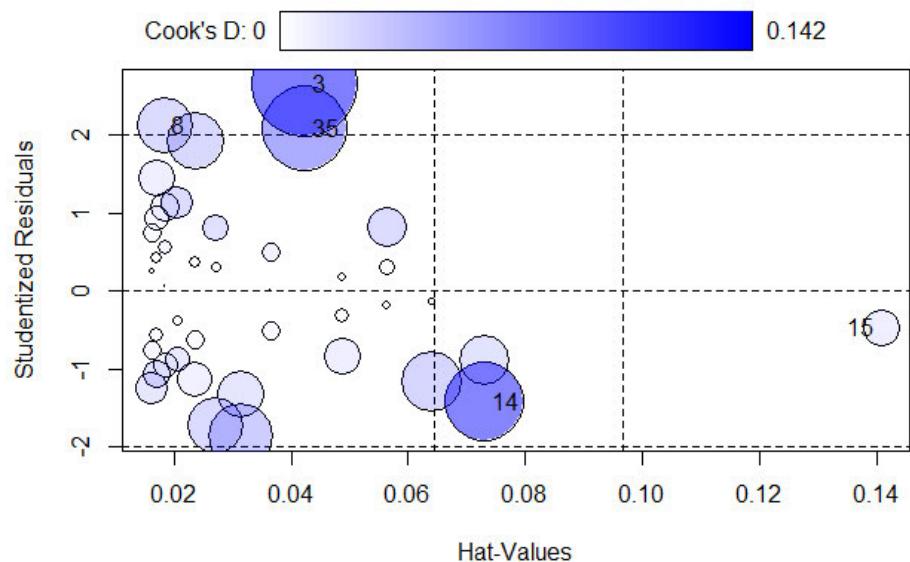


Abb. 7: Einflussplot zur Identifikation potenzieller Extremwerte im Modell der Aufwandserwartung (AA), eigene Darstellung.

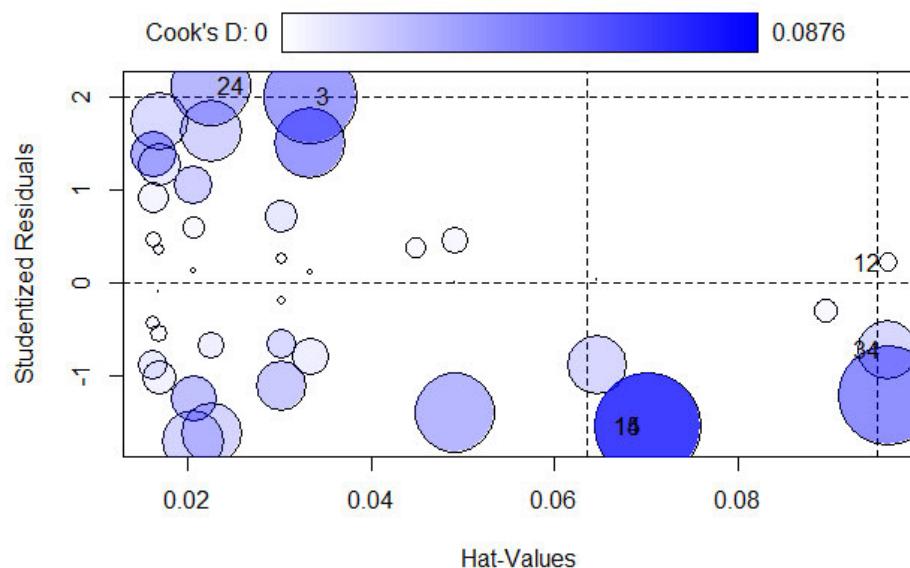


Abb. 8: Einflussplot zur Identifikation potenzieller Extremwerte im Modell des Vertrauens (VT), eigene Darstellung.

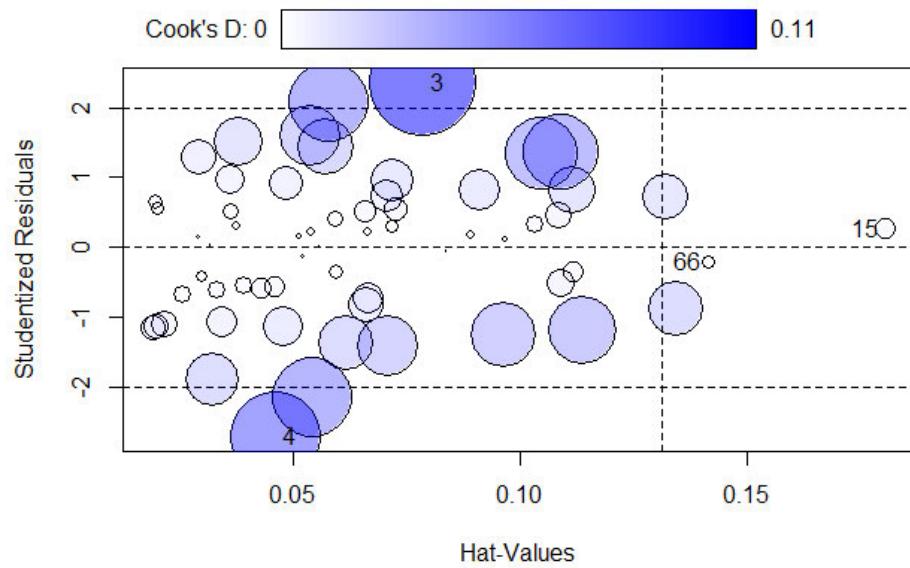


Abb. 9: Einflussplot zur Identifikation potenzieller Extremwerte im Grundmodell, eigene Darstellung.

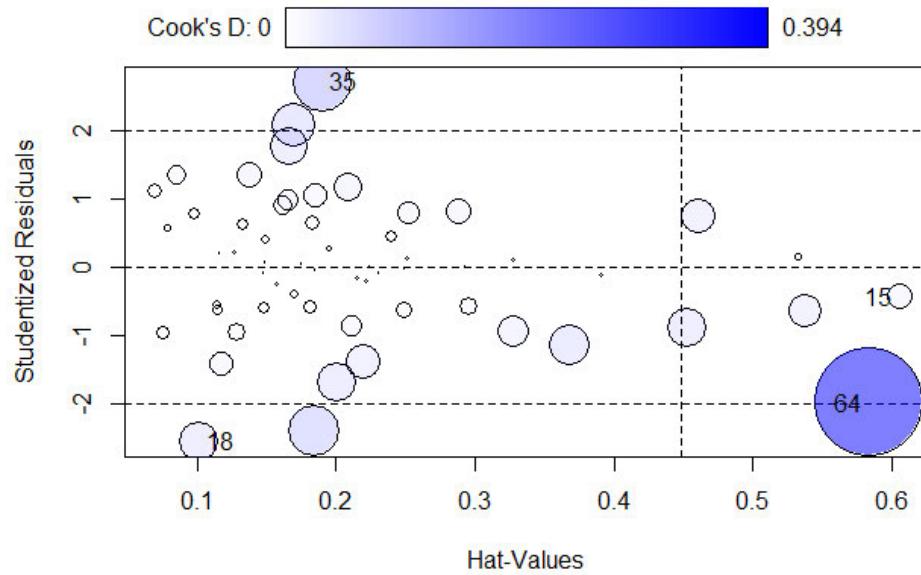


Abb. 10: Einflussplot zur Identifikation potenzieller Extremwerte im Moderatorenmodell, eigene Darstellung.

Statistische Voraussetzungen

QQ-Plot: Residuen des Modells der Leistungserwartung

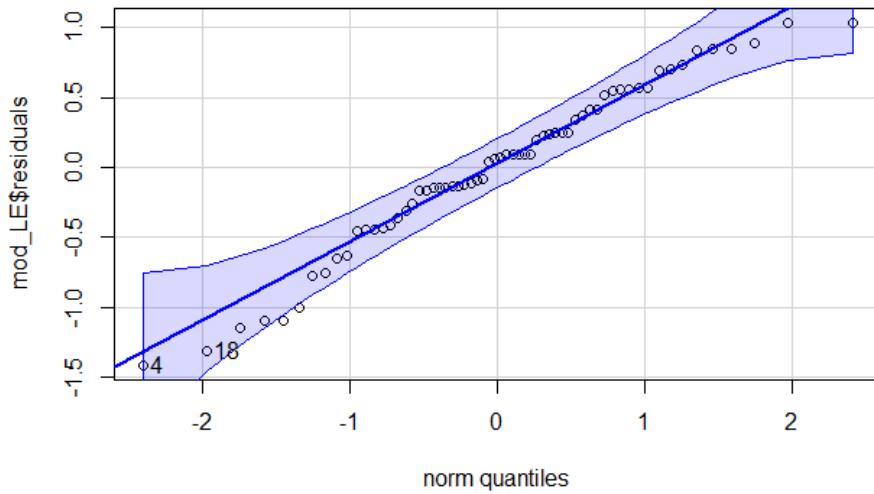


Abb. 11: QQ-Plot der Residuen des Modells der Leistungserwartung (LE), eigene Darstellung.

```
> shapiro.test(mod_LE$residuals)

shapiro-wilk normality test

data: mod_LE$residuals
W = 0.97236, p-value = 0.1747
```

QQ-Plot: Residuen des Modells der Aufwandserwartung

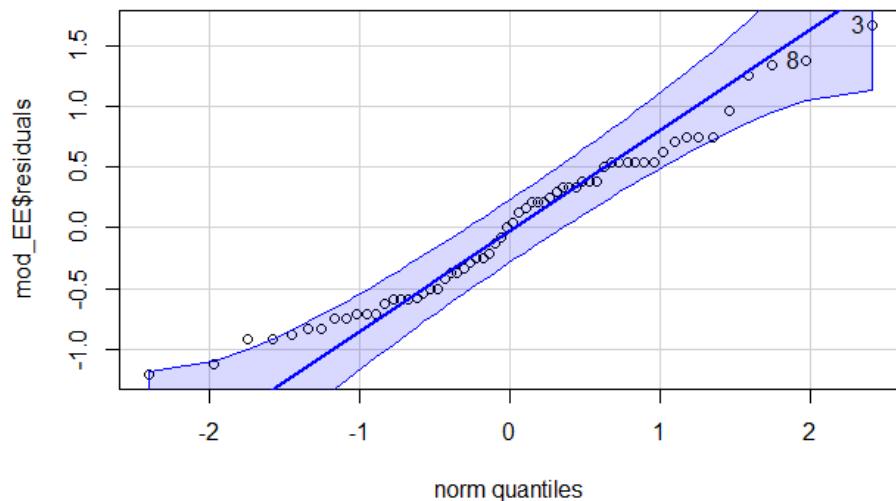


Abb. 12: QQ-Plot der Residuen des Modells der Aufwandserwartung (AA), eigene Darstellung.

```
> shapiro.test(mod_EE$residuals)

shapiro-wilk normality test

data: mod_EE$residuals
W = 0.96839, p-value = 0.1102
```

QQ-Plot: Residuen des Modells der Vertrauen

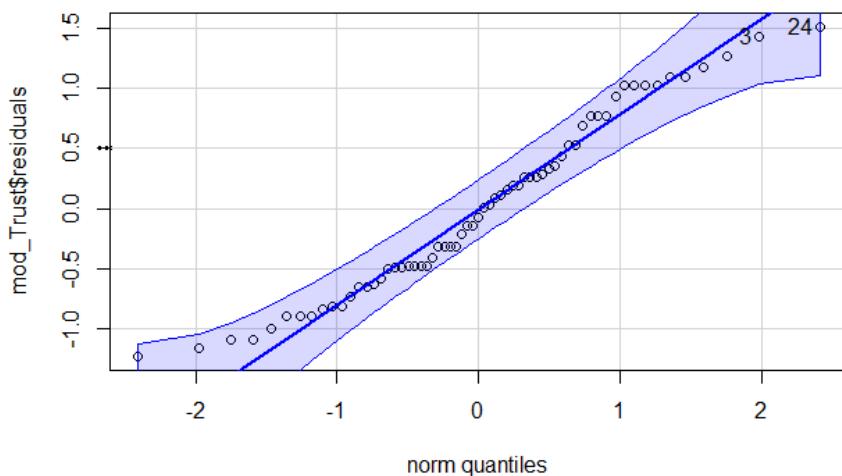


Abb. 13: QQ-Plot der Residuen des Modells des Vertrauens (VT), eigene Darstellung.

```
> shapiro.test(mod_Trust$residuals)

Shapiro-Wilk normality test

data: mod_Trust$residuals
W = 0.96046, p-value = 0.04106
```

QQ-Plot: Residuen des Grundmodells

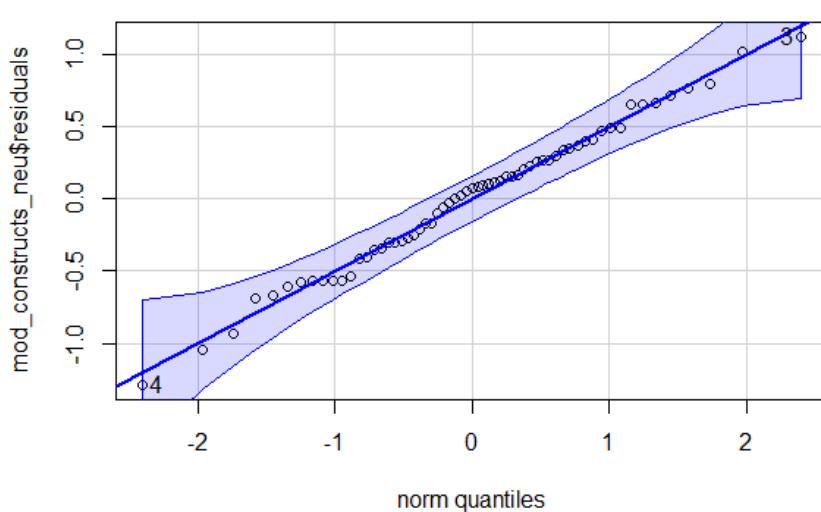


Abb. 14: QQ-Plot der Residuen des Grundmodells, eigene Darstellung.

```
> shapiro.test(mod_constructs_neu$residuals)

Shapiro-Wilk normality test

data: mod_constructs_neu$residuals
W = 0.99136, p-value = 0.9455
```

QQ-Plot: Residuen des Moderatorenmodells

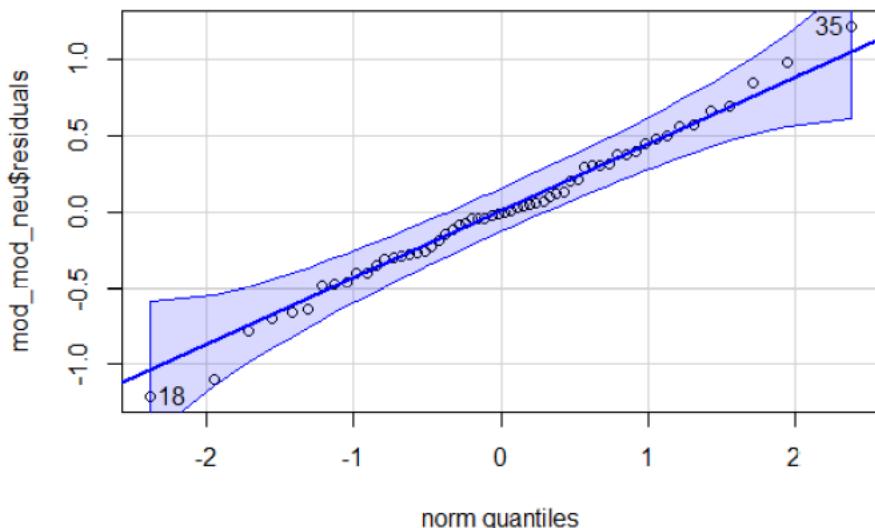


Abb. 15: QQ-Plot der Residuen des Moderatorenmodells, eigene Darstellung.

```
> shapiro.test(mod_mod_neu$residuals)

shapiro-wilk normality test

data: mod_mod_neu$residuals
W = 0.99167, p-value = 0.9611
```

Homoskedastizität

Tab. 6: Ergebnisse der Tests auf Homoskedastizität der Einzelmodelle (Leistungserwartung (LE), Aufwandserwartung (AA), Vertrauen (VT), eigene Darstellung.

Einfaches Modell	Chi ²	df	p-Wert
LE	0,958	1	0,328
AA	4,008	1	0,045
VT	2,682	1	0,102

Tab. 7: Ergebnisse des Tests auf Homoskedastizität im Grundmodell, eigene Darstellung.

Variable	Chi ²	df	p-Wert
LE	0,004	1	0,952
AA	2,593	1	0,107
VT	2,670	1	0,102
LE + AA + VT	5,201	3	0,158

Tab. 8: Ergebnisse des Tests auf Homoskedastizität im Moderatorenmodell, eigene Darstellung.

Variable	Chi ²	df	p-Wert
LE	0,008	1	0,929
AA	4,852	1	0,028
VT	3,798	1	0,051
Geschlecht	0,067	1	0,796
Berufserfahrung	0,015	1	0,903
Berufsgruppe	0,568	1	0,451
Alter	0,450	1	0,502
LE*Geschlecht + LE*Alter + LE*Berufsgruppe + LE*Berufserfahrung + VT*Geschlecht + AA	13,462	12	0,336