

Universität Siegen
Philosophische Fakultät

Kumulative Dissertationsschrift
zur Erlangung des akademischen Grades Dr. phil. im Promotionsfach Digital Public
Health

KI-basierte Entscheidungsunterstützungssysteme für die Antibiotikatherapie im Krankenhaus

Determinanten für die Implementierung aus Perspektive
beteiligter Versorgungsakteure

Vorgelegt von:
Pinar Tokgöz (M.Sc. Public Health)

Erstgutachter: Prof. Dr. Christoph Dockweiler
Zweitgutachter: Prof. Dr. Christoph Strünck

Siegen
April 2026

Gendererklärung

Zugunsten einer besseren Lesbarkeit wird in der vorliegenden Arbeit auf eine Differenzierung geschlechtsspezifischer Personenbezeichnungen verzichtet. Dies betrifft auch Komposita, wie zum Beispiel „Patientenversorgung“, bei dem das Gendern den Lesefluss erheblich beeinträchtigen würde. Sämtliche personenbezogene Bezeichnungen sind geschlechtsneutral zu verstehen.

Inhaltsverzeichnis

Gendererklärung	II
Tabellenverzeichnis	V
Abbildungsverzeichnis	V
Abkürzungsverzeichnis	VI
Publikationsverzeichnis der kumulativen Dissertation	VII
Ausweisung des Eigenanteils der kumulativen Dissertation*	VIII
Zusammenfassung	X
Abstract	XI
1. Einleitung	1
1.1 Problemhintergrund und Public-Health-Relevanz	1
1.2 Zielsetzung und Fragestellungen	2
1.3 Struktur der Arbeit	4
2. Theoretische Kontextualisierung bedarfsgerechter Antibiotikatherapien durch KI- basierte Entscheidungsunterstützungssysteme	5
2.1 Bedeutung bedarfsgerechter Antibiotikatherapien in deutschen Krankenhäusern	5
2.2 KI-basierte Entscheidungsunterstützungssysteme in der gesundheitlichen Versorgung	6
2.3 Krankenhäuser im Kontext der Implementierung von Versorgunginnovationen	9
3. Konklusion zum Forschungsdesiderat	12
4. Material und Methoden	13
5. Ergebnisse	16
5.1 Evidenzbasierte Systematisierung fördernder und hemmender Faktoren der Implementierung KI-basierter Entscheidungsunterstützungssysteme	16
5.2 Perspektiven des ärztlichen Fachpersonals zur Förderung und Hinderung der Implementierung KI-basierter Entscheidungsunterstützungssysteme	17
5.3 Perspektiven der Krankenhausdirektoren zur Förderung und Hinderung der Implementierung KI-basierter Entscheidungsunterstützungssysteme	19
5.4 Konsolidierte Bewertung der Implementierungsanforderungen von KI-basierten Entscheidungsunterstützungssystemen	20
5.5 Ergebnissynthese: Determinanten und Anforderungen der Implementierung KI- basierter Entscheidungsunterstützungssysteme für die Antibiotikatherapie im Krankenhaus	22
6. Diskussion	26
6.1 Inhaltliche Diskussion	26
6.2 Methodologische Stärken und Limitationen	30

7. Implikationen.....	34
7.1 Implikationen für Forschung	34
7.1.1 (Weiter-)Entwicklung evidenzbasierter Ansätze für die Implementierung von KI-Systemen.....	35
7.1.2 Einbezug weiterer Zielgruppen in die Forschung und Durchführung longitudinaler Studien	37
7.1.3 Forschung im Kontext tradierter Berufspraktiken und Routinen.....	38
7.2 Implikationen für Praxis und Politik	39
7.2.1 Nutzerorientierte und kontextsensitive Technologiegestaltung.....	40
7.2.2 Institutionalisierung KI-basierter Entscheidungsunterstützungssystemen.	43
7.2.3 Förderung der Interaktionsbeziehung zwischen Nutzern und KI-basierten Entscheidungsunterstützungssystemen	45
8. Fazit	47
Literaturverzeichnis	48

Tabellenverzeichnis

Tab. 1: Übersicht der Forschungsmethoden 13

Tab. 2: Übersicht zentraler Determinanten und abgeleiteter Anforderungen..... 22

Abbildungsverzeichnis

Abb. 1: Das Human-Organization-Technology (HOT)-fit-Modell 11

Abb. 2: Informationsstand der Teilnehmenden zu KI-basierten
Entscheidungsunterstützungssystemen (prozentualer Anteil) 19

Abb. 3: Einstellung der Teilnehmenden gegenüber dem Einsatz von KI-basierten
Entscheidungsunterstützungssystemen (prozentualer Anteil) 20

Abb. 4: Bewertung der Vertrauensfaktoren in Bezug auf KI-basierte
Entscheidungsunterstützungssysteme (prozentualer Anteil) 21

Abb. 5: Schematische Darstellung der Determinanten für die Implementierung 27

Abb. 6: Zukünftige Forschungsbedarfe für die Implementierung von KI-basierten
Entscheidungsunterstützungssystemen 35

Abb. 7: Zentrale Implikationen für die erfolgreiche Implementierung von KI-basierten
Entscheidungsunterstützungssystemen 40

Abkürzungsverzeichnis

ABS	Antibiotic Stewardship	KIS	Krankenhausinformations- system
AI-Act	Artificial Intelligence Act		
AIMDP	Artificial Intelligence Modern Data Platform	KI-VO	Künstliche Intelligenz- Verordnung
AMR	Antimikrobielle Resistenzen	MDR	Medizinprodukteverordnung
ARS	Antibiotika-Resistenz- Surveillance	ML	Maschinelles Lernen
AVS	Antibiotika-Verbrauchs- Surveillance	MMAT	Mixed Methods Appraisal Tool
AWMF	Arbeitsgemeinschaft der Wissenschaftlichen Medizinischen Fachgesellschaften e. V.	NAASS	Nonadoption, Abandonment, Scale-up, Spread and Sustainability
DART	Deutsche Antibiotika- Resistenzstrategie	NET	Novice to Expert Theory
DOI	Diffusion of Innovation Theory	OECD	Organisation for Economic Co-operation and Development
DSS	Decision Support Systems	PRISMA	Preferred Reporting Items for Systematic reviews and Meta-Analyses
ePA	elektronische Patientenakte	PRISMA-SR	PRISMA- Statements for Systematic Reviews
EU	Europäische Union	RK-I	Robert Koch-Institut
EUS	Entscheidungs- unterstützungssysteme	TAM	Technology Acceptance Model
GDNG	Gesundheitsdatennutzung- gesetz	UTAUT	Unified Theory of Acceptance and Use of Technology
IfSG	Infektionsschutzgesetz	WHO	World Health Organization
IVD	In-Vitro-Diagnostik		
KI	Künstliche Intelligenz		

Publikationsverzeichnis der kumulativen Dissertation

Die vorliegende kumulative Dissertation beinhaltet vier Fachzeitschriftenbeiträge, die in drei internationalen und einer national anerkannten, begutachteten (peer-reviewed) Fachzeitschrift(en) veröffentlicht sind. Die Veröffentlichungen werden in der nachfolgend dargestellten Arbeit als *Studie I, II, III, IV* bezeichnet.

Studie I: **Tokgöz, P;** Hafner, J & Dockweiler, C (2023). Factors influencing the implementation of decision support systems for antibiotic prescription in a hospital: a systematic review. [Einflussfaktoren für die Implementierung von Entscheidungsunterstützungssystemen zur Vorhersage wirksamer Antibiotikatherapien in der stationären Versorgung: eine systematische Übersicht]. BMC Medical Informatics and Decision Making, 23 (27): 1-12. doi: 10.1186/s12911-023-02124-4.

Studie II: **Tokgöz, P;** Hafner, J & Dockweiler, C (2023). Faktoren für die Implementierung von KI-basierten Entscheidungsunterstützungssystemen zur Antibiotikavorhersage im Krankenhaus- eine qualitative Analyse aus der Perspektive von ärztlichem Personal. Das Gesundheitswesen. 85(12): 1220-1228. doi: 10.1055/a-2098-3108.

Studie III: **Tokgöz, P;** Krayter, S; Hafner, J & Dockweiler, C (2024). Decision support systems for antibiotic prescription in hospitals: A survey with hospital managers on factors for implementation. [Entscheidungsunterstützungssysteme für die Verordnung von Antibiotikatherapien in Krankenhäusern: Eine Umfrage unter Vertreter*innen der Krankenhaudirektorien zu Faktoren der Implementierung]. BMC Medical Informatics and Decision Making, 24(96). doi: 10.1186/s12911-024-02490-7.

Studie IV: **Tokgöz, P;** Albrecht, J & Dockweiler, C (2025). Implementation of Artificial intelligence-based decision support systems for antibiotic prescribing in hospitals: A Delphi study [Implementierung von KI-basierten Entscheidungsunterstützungssystemen für die Verordnung von Antibiotika in Krankenhäusern: Eine Delphi-Studie.]. Front. Digit. Health 7:1555042. doi: 10.3389/fdgth.2025.1555042.

Ausweisung des Eigenanteils der kumulativen Dissertation*

Studie	Veröffentlichung	Eigenanteil der Verfasserin (inhaltlich)	Eigenanteil (prozentual)
Studie I	Tokgöz, P; Hafner, J & Dockweiler, C (2023). Factors influencing the implementation of decision support systems for antibiotic prescription in a hospital: a systematic review. [Einflussfaktoren für die Implementierung von Entscheidungsunterstützungssystemen zur Vorhersage wirksamer Antibiotikatherapien in der stationären Versorgung: eine systematische Übersicht]. BMC Medical Informatics and Decision Making, 23 (27): 1-12. doi: 10.1186/s12911-023-02124-4.	Erstautorin; zentraler Beitrag zur Konzeption, methodischen Umsetzung, Datenauswertung sowie maßgebliche Erstellung und Überarbeitung des Manuskripts	Ca. 80%
Studie II	Tokgöz, P; Hafner, J & Dockweiler, C (2023). Faktoren für die Implementierung von KI-basierten Entscheidungsunterstützungssystemen zur Antibiotikavorhersage im Krankenhaus- eine qualitative Analyse aus der Perspektive von ärztlichem Personal. Das Gesundheitswesen. 85(12): 1220-1228. doi: 10.1055/a-2098-3108.	Erstautorin; federführend in der Konzeption und Entwicklung des Studiendesigns, Durchführung der Analysen, Interpretation der Ergebnisse, Hauptverantwortung für die Verschriftlichung	Ca. 70%
Studie III	Tokgöz, P; Krayter, S; Hafner, J & Dockweiler, C (2024). Decision support systems for antibiotic prescription in hospitals: A survey with hospital managers on factors for implementation. [Entscheidungsunterstützungssysteme für die Verordnung von Antibiotikatherapien in Krankenhäusern: Eine Umfrage unter Vertreter*innen der Krankenhaudirektorien zu Faktoren der Implementierung]. BMC Medical Informatics and Decision Making, 24(96). doi: 10.1186/s12911-024-02490-7.	Erstautorin; überwiegender Beitrag in allen Phasen des Forschungsprozesses (Konzeption, Analyse, Interpretation und Manuskripterstellung sowie Revision)	Ca. 80%

<i>Studie IV</i>	Tokgöz, P; Albrecht, J & Dockweiler, C (2025). Implementation of Artificial intelligence-based decision support systems for antibiotic prescribing in hospitals: A Delphi study [Implementierung von KI-basierten Entscheidungsunterstützungssystemen für die Verordnung von Antibiotika in Krankenhäusern: Eine Delphi-Studie.]. Front. Digit. Health 7:1555042. doi: 10.3389/fdgth.2025.1555042.	Erstautorin; federführend in der inhaltlichen und methodischen Konzeption der Studie, Koordination des Forschungsprozesses, Durchführung der Analysen sowie Hauptverantwortung für die Verschriftlichung und Revision des Manuskripts.	Ca. 80%
------------------	--	--	---------

*Entsprechend § 4 Abs. 4 der Promotionsordnung der Philosophischen Fakultät vom 15.03.2023 mit Änderungen vom 08.10.2025.

Zusammenfassung

Hintergrund: Das Potenzial Künstlicher Intelligenz (KI) und darauf basierender Systeme für die gesundheitliche Versorgung ist in den letzten Jahren stetig gewachsen. KI-basierte Entscheidungsunterstützungssysteme (EUS) ermöglichen es, in großen Datenmengen schnell Zusammenhänge zu erkennen und fundierte Vorhersagen für die klinische Entscheidungsfindung zu treffen – auch im Kontext der Antibiotikatherapie. Jedoch nutzen Krankenhäuser in Deutschland KI-basierte EUS derzeit kaum, da u. a. ihre Implementierung komplex ist. **Ziel und Methoden:** Ziel ist die Erfassung von Implementierungsanforderungen KI-basierter EUS im Kontext der Antibiotikatherapie im Krankenhaus aus Perspektive beteiligter Versorgungsakteure sowie die Ableitung künftiger Forschungs- und Handlungsbedarfe. Vier Einzelstudien untersuchten dabei Determinanten der Implementierung mit quantitativen und qualitativen Forschungsmethoden. Alle Peer-Review-Veröffentlichungen rekurrieren auf das Human-Organization-Technology(HOT)-fit-Modell und explizieren systematisch Förderfaktoren und Barrieren, die den Implementierungsprozess KI-basierter EUS determinieren. **Ergebnisse:** Die Implementierung KI-basierter EUS umfasst organisationale, nutzer- und technologiebezogene Maßnahmen, wobei die Eigenschaften der Systeme selbst determinierende Faktoren sind. Insbesondere Bedienbarkeit, Interoperabilität, Empfehlungsqualität und Systemtransparenz stellen die Weichen einer erfolgreichen Implementierung. Auf organisationaler Ebene sind Echtzeit-Infrastrukturen, organisationale Veränderungsbereitschaft, Ressourcen sowie politische und regulative Rahmenbedingungen in Bezug auf Bildung, Verantwortung und Finanzierung zentrale Anforderungen. Eine geringe Veränderungsbereitschaft hängt häufig mit situativen Faktoren zusammen, wie einem fehlenden wahrgenommenen Bedarf oder der als zu hoch eingeschätzten Komplexität neuer Technologien. Auch sind auf der nutzerbezogenen Ebene Ängste, Überforderung, Haltung, Wissen und die Wahrnehmung des klinischen Nutzens entscheidend. Zudem erfordert die Abgrenzung zwischen Entscheidungsassistenz und -übernahme spezifische KI-Kompetenzen sowie die Berücksichtigung normativer und berufsethischer Fragen. **Schlussfolgerungen:** Die erfolgreiche Implementierung KI-basierter EUS entscheidet nicht die Nutzungsabsicht einzelner Personen. Implementierungsprozesse müssen die Organisationsstrukturen, kulturellen und beruflichen Normen sowie soziale und politische Rahmenbedingungen wie Richtlinien, Gesetze und Vorschriften berücksichtigen. Inter- und transdisziplinäre Ansätze sind dabei notwendig, um Problembereiche frühzeitig zu erkennen und praktische sowie ethische Herausforderungen zu antizipieren.

Abstract

Background: The potential of artificial intelligence (AI) and AI-based systems for healthcare has steadily increased in recent years. AI-based clinical decision support systems (CDSS) make it possible to rapidly identify patterns within large datasets and generate robust predictions to support clinical decision-making – including in the context of antibiotic therapy. However, hospitals in Germany currently make little use of AI-based CDSS, partly because their implementation is complex. **Objective and methods:** The aim is to examine the requirements for successful implementation of AI-based CDSS for antibiotic therapy in hospitals from the perspective of healthcare stakeholders, and to derive future research and action needs. Four studies examined determinants of implementation using both quantitative and qualitative research methods. All peer-reviewed publications draw on the structuring elements of the Human–Organization–Technology(HOT)-fit model and to systematically outline facilitators and barriers that determine the implementation process of AI-based CDSS. **Results:** The implementation of AI-based CDSS involves organizational, user-related, and technology-related measures, with the characteristics of the systems themselves representing key determining factors. In particular, usability, interoperability, recommendation quality, and system transparency set the course for successful implementation. At the organizational level, real-time-capable infrastructures, readiness for change, resources, as well as political and regulatory frameworks concerning education, responsibility, and financing constitute central requirements. Insufficient readiness for change often results from situational factors, including a perceived lack of need or the complexity of new technologies being considered too high. This may also reflect underlying fears or feelings of being overwhelmed. In addition, the attitudes, knowledge, and perceived clinical benefit among potential users are crucial. At the same time, the boundary between decision support and decision-making requires AI-specific competencies and an ongoing discourse on normative and professional-ethical issues. **Conclusion:** Implementation processes must take into account organizational structures, cultural and professional norms, as well as social and political factors such as guidelines, laws, and regulations. Interdisciplinary and transdisciplinary approaches are necessary to identify problem areas at an early stage and to anticipate practical as well as ethical challenges.

1. Einleitung

1.1 Problemhintergrund und Public-Health-Relevanz

Antibiotikaresistenzen (AMR)¹ stellen eine globale Gesundheitsbedrohung dar. Im Jahr 2021 waren laut einer systematischen Analyse weltweit 4,71 Millionen Todesfälle mit bakteriellen Infektionen assoziiert, bei denen AMR nachgewiesen wurden; in 1,14 Millionen Fällen waren AMR die unmittelbare Todesursache [1]. Prognosen zufolge könnten bis 2050 jährlich bis zu zehn Millionen Menschen an Infektionen infolge eingeschränkter antibiotischer Wirksamkeit versterben [1, 2]. In Deutschland erkrankten jährlich rund 54.500 Menschen an Infektionen mit antibiotikaresistenten Erregern; etwa 2.400 davon mit tödlichem Verlauf [3, 4]. Nach Rückgang der Infektionszahlen mit antibiotikaresistenten Erregern im Zuge der Covid-19-Pandemie ist erneut ein Anstieg auf präpandemisches Niveau zu verzeichnen [5, 6]. Mit steigenden Resistenzraten stehen zunehmend weniger wirksame therapeutische Optionen zur Behandlung bakterieller Infektionserkrankungen zur Verfügung [7]. Die Entstehung und Verbreitung von AMR sind multifaktoriell bedingt, wobei der Antibiotikaeinsatz in der Human- bzw. Veterinärmedizin eine zentrale Rolle spielt [8, 9]. Besonders hohe Selektionsdrücke gehen von Antibiotikaproduktionsstätten und Gesundheitseinrichtungen, respektive Krankenhäusern aus, in denen vulnerable Patientengruppen und unzureichend eingehaltene Hygienestandards die Ausbreitung resistenter Erreger begünstigen können [10]. Darüber hinaus tragen inadäquate Verordnungspraktiken – einschließlich der Anwendung bei viralen Infektionen, der Einsatz nicht erregerspezifischer Wirkstoffe oder fehlerhafte Dosierungs- und Einnahmeregime – wesentlich zur Entstehung und Verbreitung von AMR bei [11, 12]. Diese Versorgungsprobleme können zu einer verminderten Lebensqualität der Betroffenen sowie zu verlängerten Krankenhausaufenthalten führen [13]. Damit stellen AMR eine gesamtgesellschaftliche Herausforderung dar, für die umfassende Lösungsansätze erforderlich sind. Zur Förderung einer rationalen Antibiotikaaanwendung in deutschen Krankenhäusern wurden zahlreiche Maßnahmen² initiiert [7, 14]. Eine praxisintegrierte Strategie ist die Antibiotic Stewardship Initiative (ABS), die neben der Infektionsprävention und -kontrolle zu den wichtigsten Maßnahmen zur Eindämmung von AMR gehört [15]. Ergänzend hierzu wurde die S3-Leitlinie „Strategien zur Sicherung rationaler Antibiotika-Anwendung im Krankenhaus“ der Arbeitsgemeinschaft der Wissenschaftlichen Medizinischen Fachgesellschaften e. V. (AWMF) erarbeitet, um die Verordnungsqualität von Antibiotika zu optimieren [16].

¹ Es wird die auch im internationalen Gebrauch übliche Abkürzung „AMR“ (Antimikrobielle Resistenzen) verwendet, wobei Antibiotikaresistenzen bei bakteriellen Erregern gemeint ist. Gleichsam bezieht sich in dieser Arbeit der Begriff „Antibiotika“ nur auf antibakterielle Wirkstoffe.

² Im Jahr 2008 wurde die erste Deutsche Antibiotika-Resistenzstrategie (DART) und im Jahr 2015 die Nachfolgestrategie (DART 2020) im Bundeskabinett verabschiedet, die in Zusammenarbeit des Bundesministeriums für Gesundheit, des Bundesministeriums für Ernährung, Landwirtschaft und Verbraucherschutz und des Bundesministeriums für Bildung und Forschung entstanden ist [7].

Parallel zu den Maßnahmen zur AMR-Kontrolle ist die stationäre Versorgung in Deutschland zunehmend durch gesundheitspolitische Entwicklungen und ökonomische Rahmenbedingungen geprägt [17], die Arbeitsbedingungen und Anforderungen, insbesondere für ärztliches Personal, verändern und verdichten [18]. Die ärztliche Tätigkeit erfordert Entscheidungen, die verantwortungsbewusst und gewissenhaft getroffen werden müssen, weil sie eine bedeutende Tragweite für die Patientenversorgung haben können. Die Fülle an medizinischen Informationen führt dazu, dass sich Ärzte in hohem Maße mit dem Problem des Interpretierens von Testergebnissen auseinandersetzen müssen [19]. Oftmals fehlt es an Konzepten und Methoden, um mit der Informationsflut umzugehen, die zu suboptimalen Entscheidungen führen können [19]. Neben medizinischen Gesichtspunkten wird die ärztliche Entscheidungsfindung maßgeblich durch komplexe organisationale Prozesse innerhalb der hochgradig arbeitsteiligen Institution Krankenhaus geprägt, die potenziell das Risiko für Fehlentscheidungen erhöhen können [20].

Zur Unterstützung wiederkehrender Entscheidungen werden zunehmend Softwaresysteme eingesetzt [21] – sogenannte Decision Support Systems (DSS), respektive Entscheidungsunterstützungssysteme (EUS) [22]. Angesichts technologischer Fortschritte sowie wachsender Arbeitsforderungen des medizinischen Personals gewinnen sie zunehmend an Bedeutung [23]. EUS sind eine wichtige Anwendungsform künstlicher Intelligenz (KI) in der gesundheitlichen Versorgung, die der Komplexität und Größenordnung gesundheitsbezogener Daten gerecht werden [24]. Im Bereich der AMR-Kontrolle hat KI bereits Potenzial gezeigt: Sie unterstützt die Erstellung von Antibiotogrammen, die Entwicklung individualisierter Prognosemodelle auf Basis von maschinellem Lernen (ML) und die Überwachung von AMR-Trends [25, 26]. Dadurch können Ärzte eine bedarfsgerechtere Antibiotikatherapie initiieren [27–29]. Ungeachtet dieser Potenziale wird der Digitalisierungsrückstand im deutschen Gesundheitssystem weiterhin evident. Der Einsatz KI-basierter EUS bleibt bislang hinter den Erwartungen zurück, was insbesondere auf eine defizitäre Integration in bestehende Arbeitsprozesse sowie eine unzureichende Partizipation relevanter Nutzergruppen zurückzuführen ist [30, 31].

1.2 Zielsetzung und Fragestellungen

Im Fokus der folgenden Ausführungen stehen KI-basierte EUS zur Optimierung der Antibiotikatherapie im Krankenhaus. Begründungen hierfür sind zusammenfassend betrachtet die gesellschaftliche Bedeutung des Themas (insbesondere Entstehung und Verbreitung von AMR sowie vermeidbare Todesfälle) und die Potenziale zur Verbesserung der Versorgungsqualität und Wirtschaftlichkeit in Krankenhäusern hervorzuheben. Aufbauend auf dem dargelegten Problemhintergrund und der Public-Health-Relevanz wird analysiert, welche Faktoren die Implementierung KI-basierter EUS aus Perspektive der an der Versorgung beteiligten Akteure determinieren. Bisher liegt unzureichende empirische Evidenz darüber vor, inwieweit KI-

basierte EUS in Deutschland zur Verbesserung der Antibiotikatherapie sowie zur Eindämmung von AMR beitragen. Es wird angenommen, dass ihr Einsatz die klinische Entscheidungsfindung unterstützen, die Therapiesicherheit erhöhen und die Versorgungsqualität verbessern kann. Die empirische Prüfung dieser These ist jedoch durch die fehlende flächendeckende Implementierung eingeschränkt. Vor dem Hintergrund des bestehenden Digitalisierungsrückstandes in der deutschen Krankenhauslandschaft sowie des Bedarfs an evidenzbasierter Versorgung fokussiert die vorliegende kumulative Dissertation Determinanten einer erfolgreichen Implementierung KI-basierter EUS. Grundlage der Arbeit bilden vier peer-reviewte Publikationen (s. Publikationsverzeichnis, S. VII), die in Koautorenschaft verfasst wurden und unterschiedliche qualitative und quantitative Schwerpunkte aufweisen. Gemäß den Anforderungen der Promotionsordnung der Philosophischen Fakultät wird der eigene Anteil an den jeweiligen Publikationen transparent und detailliert dargestellt (s. Ausweisung des Eigenanteils, S. VIII ff.). Der eigene Beitrag zeigt sich in der federführenden Erstautorenschaft der eingeschlossenen Publikationen. Dieser umfasst insbesondere die Konzeption der Studien, einschließlich der methodischen Umsetzung, der Datenanalyse und -interpretation sowie die maßgeblichen Erstellung und Überarbeitung der Manuskripte. In allen Studien stellt der eigene Beitrag den maßgeblichen Anteil der wissenschaftlichen Leistung dar.

Entlang der übergeordneten Forschungsfrage wurden Anforderungen an eine zielgerichtete Implementierung KI-basierter EUS zusammengeführt und Handlungsempfehlungen abgeleitet:

Welche Faktoren determinieren die Implementierung KI-basierter EUS zur Optimierung der Antibiotikatherapie im Krankenhaus aus der Perspektive beteiligter Versorgungsakteure?

Folgende Teilfragestellungen waren dabei handlungsleitend:

1. Welche fördernden und hemmenden Determinanten der Implementierung von KI-basierten EUS zur Antibiotikatherapie im Krankenhaus können unter Berücksichtigung und Bewertung der Übertragbarkeit von internationalen Forschungsergebnissen identifiziert werden? (*Studie I*)
2. Welche personellen, strukturellen und kulturellen Bedingungen müssen in der stationären Versorgung aus der Perspektive von Versorgungsakteuren der operativen und strategischen Ebene vorhanden sein, um den Innovationstransfer KI-basierter EUS zu fördern? (*Studie II und Studie III*)
3. Wie werden Determinanten der Implementierung von KI-basierten EUS zur Antibiotikatherapie im Krankenhaus bewertet und welche Anforderungen lassen sich für künftige Implementierungen ableiten? (*Studie IV*)

Zur Beantwortung der forschungsleitenden Fragestellungen wurden in Chronologie folgende Studien umgesetzt: ein Systematisches Literaturreview (*Studie I*), eine qualitative Interviewstudie mit ärztlichem Personal (*Studie II*), eine quantitative Studie mit Vertretern der Krankenhausdirektorien (*Studie III*) sowie eine mehrstufige Delphi-Studie mit an der Antibiotikatherapie im Krankenhaus beteiligten Akteuren (*Studie IV*). Der Aufbau der Studien orientiert sich am Human-Organization-Technology(HOT)-fit-Modell von Yusof et al. [32], wodurch die personellen, organisationalen und technologischen Faktoren systematisch, erfasst, eingeordnet und bewertet werden konnten.

Mit der **Zielsetzung** fördernde und hemmende Determinanten der Implementierung KI-basierter EUS im Kontext der Antibiotikatherapie zu identifizieren, wurde in *Studie I* zunächst der internationale Forschungsstand systematisch exploriert sowie die identifizierten Determinanten strukturiert und kategorisiert. Darauf aufbauend verfolgte *Studie II* das Ziel, eine vertiefende Analyse der individuellen Perspektiven des direkt in die Versorgung involvierten ärztlichen Fachpersonals vorzunehmen. Dabei wurden Handlungen, subjektiven Wahrnehmungen sowie Erwartungen und Einstellungen erfasst, um zu verstehen, welche personellen, strukturellen und kulturellen Bedingungen im Krankenhaus für eine erfolgreiche Implementierung KI-basierter EUS erforderlich sind. Um darüber hinaus organisatorische und strategische Rahmenbedingungen für die Implementierung KI-basierter EUS zu identifizieren, zielte *Studie III* darauf ab, Determinanten auf der Ebene von Krankenhausdirektorien zu erfassen und Anforderungen an die Implementierung abzuleiten. Darauf aufbauend verfolgte *Studie IV* die Absicht, die abgeleiteten Anforderungen an die Implementierung in einer Delphi-Studie von am Versorgungsprozess beteiligten Experten bewerten zu lassen. Dadurch konnte die Relevanz und Umsetzbarkeit der Faktoren validiert und eine fundierte Grundlage für Handlungsempfehlungen geschaffen werden.

1.3 Struktur der Arbeit

Die Zielsetzungen und Fragestellungen der Dissertationsschrift verlangen eine theoretische Kontextualisierung der zu eruiierenden Sachverhalte: Nach Darlegung der Relevanz einer bedarfsgerechten Antibiotikatherapie in Kapitel 2.1 erfolgt die Abhandlung unterschiedlicher Erscheinungsformen KI-basierter EUS in Kapitel 2.2 sowie daran anknüpfend die Besonderheiten der Implementierung von Innovationen in Krankenhäusern (Kapitel 2.3). Das bestehende Forschungsdesiderat wird im dritten Kapitel konkludiert. Darauf aufbauend wird in Kapitel 4 das methodische Vorgehen der Einzelstudien zur Schließung dieses Forschungsdesiderats erläutert. Kapitel 5 bildet mit den veröffentlichten Fachartikeln zur *Studie I-IV* kumulativ den Ergebnisteil (Kapitel 5.1 bis 5.4) sowie eine Zusammenfassung der Kernergebnisse in Kapitel 5.5. Hieran anknüpfend werden im sechsten Kapitel die Ergebnisse inhaltlich (Kapitel 6.1) und

methodisch (Kapitel 6.2) diskutiert. Daraus folgen theoretische und praktische Implikationen (Kapitel 7). Die Forschungsarbeit schließt in Kapitel 8 mit einem Fazit.

2. Theoretische Kontextualisierung bedarfsgerechter Antibiotikatherapien durch KI-basierte Entscheidungsunterstützungssysteme

Einführend werden zunächst die Bedeutung eines bedarfsgerechten Antibiotikaeinsatzes im Krankenhauskontext sowie relevante Initiativen dargestellt (Kapitel 2.1). Anknüpfend werden zentrale Begriffe, Einsatzgebiete und rechtliche Bestimmungen in Zusammenhang mit KI-basierten EUS skizziert (Kapitel 2.2). Abschließend behandelt Kapitel 2.3 die Besonderheiten der Implementierung von Versorgungsinnovationen in Krankenhäusern sowie das dieser Arbeit zugrunde liegende theoretische Rahmenwerk.

2.1 Bedeutung bedarfsgerechter Antibiotikatherapien in deutschen Krankenhäusern

Antibiotika werden zur Behandlung einer Reihe von Infektionen eingesetzt, die durch Bakterien verursacht werden. Ihre Wirksamkeit ist für die Aufrechterhaltung der individuellen und gesamtgesellschaftlichen Gesundheit von entscheidender Bedeutung [33]. Die Weltgesundheitsorganisation (World Health Organization [WHO]) versteht unter einem angemessenen und rationalen Antibiotikaeinsatz die wirtschaftliche Anwendung antimikrobieller Mittel mit dem Ziel, eine maximale therapeutische Wirksamkeit zu erzielen und zugleich arzneimittelbedingte Nebenwirkungen sowie die Entstehung von AMR zu begrenzen [34]. AMR in der stationären Krankenhausversorgung werden durch eine Vielzahl von Faktoren verursacht, einschließlich, aber nicht beschränkt durch einen übermäßigen Einsatz von sogenannten Breitbandantibiotika³ sowie eine unzureichende Infektionskontrolle [36]. In etwa 20 % bis 50 % der Antibiotikaverordnungen in Krankenhäusern sind entweder nicht notwendig oder werden unsachgemäß verabreicht [37, 38]. Zudem bestehen Unterschiede im Handlungswissen und der -sicherheit bei Ärzten sowie Variabilität in der Verordnungspraxis [39, 40]. Auch tragen Defizite in der Umsetzung klinischer Leitlinien, der Infrastruktur und Forschung zur Entstehung und Ausbreitung von AMR bei [11]. Folglich sind wirksame Maßnahmen zur Optimierung der Antibiotikatherapie notwendig [41, 42].

Nach der Neufassung des §23 Abs. 4 im Infektionsschutzgesetz (IfSG) sind in Deutschland Krankenhäuser und Einrichtungen für ambulant Operieren verpflichtet, den Antibiotikaverbrauch kontinuierlich und systematisch zu überwachen. Dabei empfiehlt die S3-Leitlinie der

³ Breitbandantibiotika sind antimikrobielle Wirkstoffe mit Wirksamkeit gegen ein breites Spektrum von Bakterien (insb. grampositive und gramnegative Bakterien). Ihr Einsatz erfolgt häufig empirisch, wenn der spezifische Krankheitserreger noch nicht identifiziert wurde oder bei Verdacht auf Mischinfektionen, wobei ihr breites Wirkspektrum auch das Risiko der Resistenzentwicklung erhöhen kann [35]

AWMF die Teilnahme an nicht kommerziellen Surveillance-Systemen [16]. Seit 2008 und 2014 sind mit der Antibiotika-Resistenz-Surveillance (ARS) [43] und der Antibiotika-Verbrauchs-Surveillance (AVS) [44] zwei Surveillance-Systeme⁴ am Robert Koch-Institut [RKI] etabliert. Inwieweit der Antibiotikaverbrauch die Resistenzsituation tatsächlich beeinflusst, wurde 2021 im Rahmen des vom Bundesministerium für Gesundheit (BMG) geförderten Projektes „Antibiotika-Resistenz und -Verbrauch-Integrierte Analyse“ (ARVIA)⁵ in einer Pilotphase mit sechs Krankenhäusern analysiert. Dabei wurden die Daten aus der ARS und AVS in Bezug zueinander ausgewertet [46]. In fünf Krankenhäusern konnte ein signifikanter Zusammenhang zwischen dem Antibiotikaverbrauch und der Entstehung von AMR nachgewiesen werden [47].

Angesichts der bestehenden und zunehmenden Resistenzproblematik wurden Aktionspläne und Strategien auf (inter-)nationaler Ebene erarbeitet mit dem übergeordneten Ziel, die Therapierbarkeit von Infektionskrankheiten bei Mensch und Tier zu erhalten [48, 49]. Im Zuge dessen sind für Deutschland die notwendigen Maßnahmen zur Bekämpfung von AMR in der Deutschen Antibiotika-Resistenzstrategie (DART) zusammengefasst. Sowohl die DART als auch der Aktionsplan der WHO unterstreichen die Bedeutung von Aktivitäten zum ABS⁶ in dem Bemühen, den Antibiotikaeinsatz zu optimieren und den dramatischen Anstieg von AMR einzudämmen [34]. Die im Rahmen der Surveillance erfassten Daten ermöglichen zwar eine Einschätzung mit Blick auf die Verbrauchssituation in Krankenhäusern oder auch um Problembereiche zu identifizieren, eignen sich aber nicht dazu, um die Qualität der Antibiotikaverordnung, bspw. mit Blick auf Substanzwahl, Dosierung oder Therapiezyklen zu beurteilen [51, 52]. Die zunehmende Komplexität patientenbezogener Verordnungsentscheidungen macht eine gezielte Analyse und Unterstützung erforderlich. Insbesondere Fortschritte im Bereich von KI eröffnen hierfür neue Möglichkeiten, etwa durch den Einsatz KI-basierter EUS.

2.2 KI-basierte Entscheidungsunterstützungssysteme in der gesundheitlichen Versorgung

KI findet in der Gesundheitsversorgung zunehmend Anwendung [53, 54]. Als eine spezifische Anwendungsform bieten EUS eine wirksame Unterstützung in Diagnostik und Therapie [55, 56]. Unter EUS werden im Allgemeinen Softwaresysteme verstanden, die Informationen zusammentragen, aufbereiten und präsentieren, um diese als Grundlage für operative oder strategische Entscheidungen bereitzustellen [57]. EUS in der gesundheitlichen Versorgung

⁴ ARS und AVS sind zwei unabhängig voneinander arbeitende Systeme mit unterschiedlichen Teilnehmenden; diese sind bei ARS Labore und bei AVS Krankenhäuser [45].

⁵ Das Projekt „ARVIA“ ist der Frage nachgegangen, ob eine Änderung des Antibiotikaverbrauchs auch zu einer Änderung der Resistenzlage im Krankenhaus führt. Eine mögliche Assoziation zwischen Veränderungen des Verbrauchs und der Resistenz wurde mittels statistischer Methoden untersucht und festgestellt [44].

⁶ ABS kann als ein Bündel von koordinierten, interdisziplinär abgestimmten Maßnahmen betrachtet werden, die darauf ausgerichtet sind, den angemessenen Einsatz von Antibiotika in einer medizinischen Einrichtung unter Berücksichtigung der aktuellen Evidenz zu optimieren [50].

umfassen Softwaresysteme, die Daten als zielgerichtetes und entscheidungsrelevantes Wissen aufbereiten sowie strukturiert zur Verfügung stellen und somit die klinische Entscheidungsfindung vorbereiten [58]. EUS lassen sich danach kategorisieren, ob es sich um wissensbasierte Systeme oder nicht-wissensbasierte Systeme handelt [23]. **Wissensbasierte Systeme** bestehen aus drei Teilen: die Wissensbasis, die Schlussfolgerungsmaschine (Inferenz⁷) und die Benutzerschnittstelle. An der Benutzerschnittstelle wird der Informationsfluss zwischen Input (z. B. patientenrelevante Daten) und Output (z. B. Therapieversuch) durch einen Kommunikationsmechanismus vermittelt. Die Inferenzmaschine verknüpft dabei den Input mit den in der Wissensbasis gespeicherten Daten und Fakten nach einem logischen Schema zur Generierung des Outputs [59]. Allen wissensbasierten Systemen ist gemeinsam, dass ein Experte medizinisches Wissen explizit und direkt in das System einbringt, damit Schlussfolgerungen abgeleitet werden können [60]. Im Gegensatz dazu arbeiten **nicht-wissensbasierte (datengetriebene) Systeme** v. a. auf Grundlage von KI bzw. ML, wodurch sie in der Lage sind, aus früheren Beispielen oder bekannten Mustern zu lernen [23]. Mithilfe von verschiedenen algorithmischen und statistischen Methoden können Gesetzmäßigkeiten in Datensätzen erkannt und hieraus neue Informationen generiert werden, die in einem iterativen Prozess und durch schrittweise Optimierung die Ableitung von Schlussfolgerungen und Lösungen ermöglichen [59, 61]. Die Wahl des Algorithmus richtet sich sowohl nach der Art des zu lösenden Problems als auch nach dem Modell, das sich am besten zur Bearbeitung dieses Problems eignet [62].

Die datenintensive Natur von Krankenhäusern macht sie zu einem der vielversprechendsten Bereiche für die Anwendung KI-basierter EUS – auch vor dem Hintergrund, dass das schnelllebige Gesundheitssystem Ärzte dazu zwingt, in immer kürzerer Zeit zunehmend komplexere Entscheidungen zu treffen [63], oftmals auch unter Unsicherheit [17, 64]. Entscheidungsprozesse sind zudem in organisationale Kontexte eingebettet, die u. a. durch Vorgaben zu Personalschlüsseln, Bettenauslastung und oft herausfordernde Arbeitsbedingungen geprägt sind [65, 66]. Folglich haben EUS das Potenzial, verschiedene Handlungsfelder der Gesundheitsversorgung, wie Diagnose, Behandlung, Prävention und Administration nachhaltig zu verändern [67]. Studien zeigen, dass KI-basierte Systeme in zahlreichen Anwendungsfällen der medizinischen Bildgebung erfolgreich sind, z. B. bei der Erkennung von bösartigen Veränderungen in histologischen Bildern von Brustkrebs [68], bei der Klassifizierung von Hautkrebs mit der Genauigkeit eines Dermatologen [69], bei der Diagnose von diabetischer Retinopathie [70] sowie bei der Vorhersage von kardiovaskulären Risikofaktoren [71] und zur Risikostratifizierung und Vorhersage von Schlaganfällen [72]. Darüber hinaus können KI-basierte EUS den Prozess von Arzneimittelverordnungen rationalisieren und optimieren [73], sowie klinische Fehler reduzieren, indem sie auf potenzielle Wechselwirkungen, Kontraindikationen von

⁷ Inferenz bezeichnet die Verwendung eines trainierten Modells, um neuartige Schlüsse aus den Daten ziehen zu können [23].

Arzneimitteln und andere klinische Risiken hinweisen [74]. Ebenso gewinnen sie als Unterstützungsinstrument im Kontext von Antibiotikatherapien zunehmend an Bedeutung [75, 76], etwa zur Zeit- und Kostenersparnis von Antibiotikatherapien sowie zur Reduktion von Krankenhausaufenthalten [77–79]. Zudem können EUS den Verordnungsprozess durch Echtzeit-Feedback unterstützen, die Einhaltung von Leitlinien fördern und so unangemessene Verordnungen verringern [77, 80].

Gleichzeitig bergen EUS auch Risiken, da sie eine neue Quellen für Ungenauigkeiten und Fehlentscheidungen sein können. Angesichts der zunehmenden Bedeutung für die gesundheitliche Versorgung wird die Einführung klarer Entwicklungsstandards und einheitlicher Nutzungsnormen immer dringlicher [81]. Im August 2024 trat die Verordnung der Europäischen Union (EU) zur KI (KI-Verordnung [KI-VO] respektive „AI-Act“) in Kraft. Dieses rechtsverbindliche Instrument legt gemeinsame Leitlinien und Regeln für die Entwicklung, Implementierung und Wartung von KI-Systemen in der EU fest [82]. Für das Gesundheitswesen ist die KI-VO besonders wichtig, da andere bestehende Harmonisierungsvorschriften, wie die In-Vitro-Diagnostik (IVD)⁸ oder Medizinprodukteverordnung (MDR)⁹ medizinische KI-Systeme nicht explizit regulieren. Umgekehrt fallen nicht alle KI-Systeme in den Anwendungsbereich der IVD oder MDR [82]. Wie die MDR verfolgt auch die KI-VO einen risikobasierten Ansatz, wobei in Hinblick auf die Vorschriften keine gesonderten sektoralen Differenzierungen gemacht werden [82, 85]. Je mehr Risiken mit einem KI-System verbunden sind, umso strenger wird sie reglementiert, während KI-Systeme, die keine oder minimale Risiken aufweisen, von der KI-VO kaum betroffen sind [86]. Dabei ist zu berücksichtigen, dass die Einhaltung der Vorgaben der KI-VO nicht automatisch die Einhaltung weiterer Harmonisierungsvorschriften der EU ausschließt. So ist in der MDR geregelt, dass KI-basierte Medizinprodukte der Risikoklasse IIa oder höher, die für medizinische Zwecke, wie Diagnose, Prognose, Monitoring, Vorhersage oder Behandlung eingesetzt werden, neben der Konformitätsbewertung zusätzlich die Anforderungen der KI-VO erfüllen müssen [84]. Dieses vielschichtige Regulierungssystem für KI-basierte Systeme soll sowohl die Sicherheit, die Gesundheit und die Grundrechte der Nutzer schützen als auch Innovationen fördern. Obwohl die Ziele und Harmonisierung positiv zu bewerten sind, bleibt offen, wie die Mitgliedstaaten die technischen Anforderungen tatsächlich umsetzen [87].

⁸ Mit IVD sind Medizinprodukte gemeint, mit denen Proben analysiert werden, die aus dem menschlichen Körper stammen und werden in die Klassen A (geringes Risiko, z. B. Laborbedarf, wie Instrumente oder Probenbehälter) bis D (hohes Risiko, wie z. B. Produkte zum Nachweis hochansteckender Erreger, wie Ebola) eingeteilt [83].

⁹ Die Einstufung von Medizinprodukten erfolgt nach Art der Anwendung und dem sich hieraus ableitenden Risiko. Die Risikoklassen reichen von Klasse I (geringes Risiko, wie z. B. Verbandsmaterialien) über IIa (z. B. Hörgeräte) und IIb (wie Dialysegeräte) bis Klasse III (hohes Risiko, wie z. B. Herzschrittmacher) [84].

2.3 Krankenhäuser im Kontext der Implementierung von Versorgungsinnovationen

Krankenhäuser bilden einen zentralen Pfeiler des deutschen Gesundheitssystems und lassen sich traditionell in drei Bereiche unterteilen: ärztliches, pflegerisches und verwaltendes Personal [88]. Sie sind pluralistische und heterogene Organisationen, in denen Veränderungen oft umstritten und konfliktbehaftet sind und durch individuelle, technische, normative, ökonomische sowie politische Faktoren beeinflusst werden [88]. Divergierende Interessen und daraus resultierende Zielkonflikte machen die Implementierung von technologischen Innovationen zu einer komplexen Herausforderung [89]. So können Ziele, die v. a. auf ökonomischen Kennzahlen basieren die Adaptionfähigkeit gegenüber dynamischen Veränderungen im medizinischen oder gesellschaftlichen Umfeld einschränken. Eine einseitige Fokussierung auf monetäre Größen kann dazu führen, dass relevante Entwicklungen nicht hinreichend oder nicht rechtzeitig in die strategische Ausrichtung integriert werden. In der Konsequenz kann dies die Bereitschaft zentraler Akteursgruppen verringern, notwendige Ressourcen bereitzustellen, so dass Krankenhäuser ihre Leistungsaufträge nicht vollumfänglich erfüllen können [90]. Zusätzlich wirken sich externe politische Entscheidungen, wie Reformen der Krankenhausfinanzierung oder geplante Standortreduzierungen, auf interne Veränderungsprozesse aus und können politisch motivierte Konflikte in Krankenhäusern verstärken. Unterschiedliche Interessen von Politik, Kostenträgern und Krankenhausleitungen führen zu heterogenen Erwartungshaltungen, die in innerorganisationalen Auseinandersetzungen sichtbar werden [91].

Vor diesem Hintergrund beeinflussen sowohl interne Zielkonflikte als auch externe Rahmenbedingungen nicht nur die Leistungsfähigkeit von Krankenhäusern, sondern auch ihre Fähigkeit, technologische Innovationen zu adaptieren. Dabei treffen unterschiedliche Berufsgruppen, Fachrichtungen und Hierarchieebenen aufeinander; und Rahmenbedingungen, wie etwa Infrastruktur, Leitlinien, organisatorische sowie politische Regelungen und verfügbare Ressourcen konvergieren mit technologischen Innovationen [92]. Während bereits etablierte technologische Innovationen, wie elektronische Dokumentationssysteme, Operationsroboter oder auch Wearable-Computing-Technologien zur Datenübermittlung, wie bei EKG-Messungen Einzug in den Klinikalltag gefunden haben, werden KI-basierte Technologien bislang nur sporadisch eingesetzt [93]. Im internationalen Vergleich schöpft Deutschland das Digitalisierungspotenzial nur unzureichend aus [94]. Eine Analyse zum Digitalisierungsstand der Gesundheitssysteme innerhalb von 17 EU- und OECD-Ländern zeigt, dass Estland über das am weitesten fortgeschrittene digitale System verfügt, gefolgt von Kanada, Dänemark und Spanien. Deutschland nimmt hingegen den vorletzten Platz ein [94], was auch Befunde weiterer Studien stützen [95, 96]. Als mögliche Gründe für den Digitalisierungsrückstand im deutschen Gesundheitssystem werden Interessenskonflikte zwischen Akteursgruppen [97], strenge Auslegungen der Datenschutzvorschriften [98], Vorbehalte und ungenügender Nutzen für die

Versorgungsakteure [99] sowie hohe bürokratische und finanzielle Hürden [100] angeführt. Obwohl das Interesse an KI im Krankenhausbereich in den letzten Jahren deutlich zugenommen hat, bestehen weiterhin Defizite in Bezug auf das Wissen, das für eine erfolgreiche Gestaltung und Steuerung des Implementierungsprozesses erforderlich ist [101].

Der Implementierungsprozess ist daher der Ausprägung und dem (möglichen) Zusammenspiel einzelner Determinanten anzupassen. Zu der weit gefassten Bezeichnung „Determinanten der Implementierung“ (häufig auch Barrieren und Förderfaktoren genannt) wird eine Vielzahl von Aspekten zugeordnet, die in einem spezifischen Kontext Einfluss auf den Implementierungsprozess haben können [102]. Für die Implementierungsforschung bedeutet Kontext (im Folgenden als Organisation bezeichnet) die Menge von Umständen oder Faktoren, die die Rahmenbedingung für ein bestimmtes Implementierungsvorhaben setzen [103]. Untersuchungen zeigen, dass der Erfolg von Implementierungsaktivitäten davon abhängig ist, wie gut die Organisation, die Personen und die Technologie sich gegenseitig unterstützen und aufeinander abgestimmt sind [104, 105]. Personen sind in Organisationen eingebettet und institutionalisiert, die ihrerseits ein Kollektiv bilden, um bestimmte Ziele durch kollaboratives Handeln zu erreichen; gleichzeitig sind die menschlichen Verhaltensweisen eine treibende Kraft von Organisationen [106]. Organisationen, inklusive der Strukturen, Strategien, Richtlinien und Vorschriften haben einen direkten Einfluss auf die Einstellungen und Verhaltensweisen der eingebetteten Personen [107]. Was das Zusammenwirken von Organisation und Technologie betrifft, so sind sie als sozio-materielle Einheit miteinander verwoben. Dabei trägt die Technologie mit neuen Arbeitsweisen, Prozessverbesserungen und strukturellen Veränderungen dazu bei, die Wettbewerbsvorteile und Leistungsfähigkeit von Organisationen zu erhalten [108]. Auch im Zusammenspiel von Mensch und Technologie kommt es zu gegenseitigen Einflüssen. Diese umfassen nicht nur die Akzeptanz oder Ablehnung der Technologie durch die Personen, sondern auch die Veränderung der Handlungsweisen und Prozesse durch Technologien [107].

Auf Grundlage des Erfolgsmodells für Informationssysteme von DeLone und McLean [109] sowie des IT-Organization-fit-Modells [110] und der Annahme eines bidirektionalen Zusammenspiels der Konstrukte *Mensch*, *Organisation* und *Technologie* [111] entwickelten Yusof et al. [32] das Human-Organization-Technology-(HOT)fit-Modell (s. Abb. 1). Das Modell wurde bereits vielfach eingesetzt, um die Implementierung von elektronischen Patientenakten (ePA) in Krankenhäusern [112, 113] sowie von Krankenhausinformationssystemen (KIS) [114, 115] zu evaluieren. Es ermöglicht eine ganzheitliche Perspektive auf die elementaren Aspekte der Technologieimplementierung im Krankenhauskontext einzunehmen [116], anstatt die Implementierung auf fragmentierte Weise zu untersuchen, wie es in früheren Studien der Fall war [117]. Das Modell umfasst drei Hauptdomänen mit insgesamt sieben zentralen Konstrukten.

Der „*fit*“ beschreibt die Passung bzw. Kompatibilität zwischen den Domänen Mensch, Organisation und Technologie, um die Vorzüge in realen Nutzen ummünzen zu können [32].




Abb. 1: Das Human-Organization-Technology (HOT)-fit-Modell (Modifizierte und eigene Darstellung angelehnt an Yusof et al. [93])

Es lassen sich drei zentrale Passungsdimensionen unterscheiden. Die Mensch-Technologie-Passung beschreibt den „*fit*“ zwischen Technologie und Nutzer und ist bspw. dann gegeben, wenn diese die Arbeitsaufgaben der Nutzer wirksam unterstützt. Die Passung zwischen Nutzern und organisationalem Kontext liegt hingegen vor, wenn etwa das Management die Nutzung aktiv unterstützt und Nutzern angemessene Rahmenbedingungen geschaffen werden. Bei dem „*fit*“ Technologie-Organisation geht es um die Passung zwischen Technologie und organisationalen Strukturen, wie bspw. dem Vorhandensein von organisationalen Ressourcen und der Infrastruktur [32]. Der Grad der Passung wird durch die entsprechenden Konstrukte (wie z. B. der Systemqualität oder der Anwenderzufriedenheit) beeinflusst. Zusätzlich können sich diese Konstrukte gegenseitig beeinflussen, wodurch dynamische Rückkopplungen entstehen (bspw. Nutzung → höhere Zufriedenheit → wahrgenommener Nutzen und mehr Nutzung) [118]. Je besser die Domänen aufeinander abgestimmt sind, desto höher ist die Wahrscheinlichkeit für eine erfolgreiche Nutzung und positive Systemeffekte [118]. Zusammenfassend betrachtet gilt die Implementierung als erfolgreich, wenn die Technologie zu den Aufgaben und Arbeitsprozessen passt, die Organisation die Nutzung unterstützt und die Nutzer die Fähigkeiten und Motivation zur Nutzung haben.

3. Konklusion zum Forschungsdesiderat

Die Analyse des aktuellen Forschungsstands zeigt, dass Antibiotikaverordnungen im Krankenhaus sowohl hinsichtlich ihrer Notwendigkeit als auch in Bezug auf Dosierung, Substanzwahl und Therapiedauer häufig variieren. Trotz bestehender Surveillance-Systeme wie ARS und AVS können die erfassten Daten lediglich die Verbrauchssituation abbilden, nicht jedoch die Qualität klinischer Entscheidungen oder die Determinanten des Verordnungsverhaltens [51, 52]. Die klinische Entscheidungsfindung ist ein Kernelement der ärztlichen Tätigkeit und eine wesentliche Voraussetzung für eine adäquate Antibiotikatherapie. Gleichzeitig nimmt die Komplexität ärztlicher Entscheidungen zu: Ärzte müssen zunehmend zeitkritische und komplexe Entscheidungen treffen, die in dynamische organisationale und regulatorische Kontexte eingebettet sind [119]. Vor diesem Hintergrund wird der Einsatz KI-basierter EUS als vielversprechender Ansatz zur Unterstützung klinischer Entscheidungsprozesse bewertet. Die theoretische Kontextualisierung bedarfsgerechter Antibiotikatherapien mithilfe KI-basierter EUS zeigt, dass ihr Einsatz in deutschen Krankenhäusern bislang gering ist, obwohl ihre Potenziale – wie in Kapitel 2.2 dargestellt – gut belegt sind. Während die technische Leistungsfähigkeit von KI-basierten EUS gut dokumentiert ist, bestehen nach wie vor erhebliche Evidenzlücken in Bezug auf die Implementierung und kontextabhängige Nutzung [63–67]. Eine zentrale Herausforderung besteht zudem in der unzureichenden Berücksichtigung der Nutzerperspektive bei der Gestaltung und Integration von EUS, wodurch eine flächendeckende Implementierung bislang ausbleibt [120, 121]. Vor diesem Hintergrund ergibt sich ein **Forschungsdesiderat**, das die Entwicklung einer empirisch fundierten, kontextsensitiven Analyse der Determinanten für die Implementierung KI-basierter EUS in Krankenhäusern erfordert. Um dieses Forschungsdesiderat aufzuarbeiten, verfolgt die vorliegende Arbeit das Ziel, das Zusammenspiel von technologischen Eigenschaften, organisationalen Strukturen und individuellen Sichtweisen systematisch zu analysieren und darauf basierend Anforderungen an die Implementierung KI-basierter EUS¹⁰ für die Antibiotikatherapie im Krankenhaus aus der Perspektive beteiligter Versorgungsakteure abzuleiten.

¹⁰ Im Rahmen der vorliegenden Arbeit werden – ausgehend von der Grundannahme der selbstständigen Problemlösung – KI-basierte EUS als Dachbegriff für datengetriebene Softwaresysteme verstanden, die auf ML-Verfahren basieren und Muster sowie Zusammenhänge in medizinischen Datensätzen erkennen, um ärztliche Entscheidungsprozesse zu unterstützen. Voraussetzung ist, dass das Systemmodell mit relevanten Daten „gefüttert“ wird und ein entsprechender Algorithmus vorgegeben ist. KI-basierte EUS treffen dabei keine eigenständigen klinischen Entscheidungen, sondern stellen auf Basis der analysierten Daten Empfehlungen, Prognosen oder Hinweise bereit. Der Mensch bleibt insofern integraler Bestandteil des Systems, indem relevante Daten ausgewählt, Modelle definiert und die Ergebnisse im klinischen Kontext interpretiert und verantwortet werden [122].

4. Material und Methoden

Handlungsleitend durch die in Kapitel 1.2 dargelegten Forschungsfragen wurde zur Schließung des Forschungsdesiderats ein Mixed-Methods-Design mit sequentiellem explorativem Vorgehen [123, 124] umgesetzt (s. Tab. 1):

Tab. 1: Übersicht der Forschungsmethoden (Eigene Darstellung)

Wie?	Wer?	Wann?	Was?
Systematisches Review in Anlehnung an Higgins et al. [125]	/	05/21 und Aktualisierung 11/21	Recherche zum aktuellen Stand und Systematisierung der Literatur (<i>Studie I</i>)
Leitfadengestützte problemzentrierte Einzelinterviews angelehnt an Witzel [126]	14 Versorgungsakteure der operativen Ebene verschiedener Fachrichtungen	06/21 bis 12/21	Explorative Erfassung von fördernden und hemmenden Determinanten der Implementierung KI-basierter EUS (<i>Studie II</i>)
Online-Umfrage via Limesurvey mit geschlossenen und offenen Fragen	181 Vertreter von Krankenhausdirektoren bundesweit	12/22 bis 05/23	Bewertung der identifizierten Determinanten und Ergänzungen aus Perspektive von Krankenhausdirektoren (<i>Studie III</i>)
Onlinebasierte Delphi-Befragung mit geschlossenen und offenen Fragen	77 bzw. 36 Experten aus Wissenschaft und Praxis	07/24 bis 10/24	Konsolidierung der zuvor identifizierten Determinanten mit Experten (<i>Studie IV</i>)

Der vorliegenden Dissertationsschrift liegen somit die vier nachfolgend betrachteten peer-reviewte Studien zugrunde, die mit unterschiedlichen methodischen Verfahren und Stichproben ein umfassendes Verständnis des Forschungsgegenstandes generieren konnten:

Studie I: Tokgöz, P; Hafner, J & Dockweiler, C (2023). Factors influencing the implementation of decision support systems for antibiotic prescription in a hospital: a systematic review. *BMC Medical Informatics and Decision Making*, 23 (27): 1-12. doi: 10.1186/s12911-023-02124-4.

Die systematische Recherche wurde in den Fachdatenbanken PubMed, The Cochrane Library und Web of Science durchgeführt. Zunächst wurden die Publikationen gemäß den Ein- und Ausschlusskriterien auf Titel und Abstract überprüft. Eingeschlossen wurden alle Primärstudien, deren Intervention EUS für die Antibiotikatherapie im Krankenhaus beinhalteten und über Implementierungsfaktoren berichteten. Es wurde jedwedes Studiendesign berücksichtigt, wobei Publikationen in deutscher und englischer Sprache eingeschlossen wurden, die in den Jahren 2011 bis 2021 veröffentlicht wurden. Ausgeschlossen wurden Studien, in denen EUS

ohne direkten Versorgungsbezug (bspw. im administrativen Bereich) eingesetzt wurden, die Ergebnisse sich ausschließlich auf klinische Outcomes bezogen sowie Studien, die über die semantische Entwicklung von EUS berichteten. Die in den Studien identifizierten Faktoren wurden entlang des HOT-fit-Modells [32] extrahiert und fokussierten dabei innerhalb eines modularen Aufbaus insbesondere Facetten der technologiebezogenen, organisationsbezogenen und nutzerbezogenen Domänen. 14 Publikationen zu zwölf Studien entsprachen den Einschlusskriterien und wurden in die Ergebnisauswertung einbezogen.

Studie II: Tokgöz, P; Hafner, J & Dockweiler, C (2023). Faktoren für die Implementierung von KI-basierten Entscheidungsunterstützungssystemen zur Antibiotikavorhersage im Krankenhaus - eine qualitative Analyse aus der Perspektive von ärztlichem Personal. *Das Gesundheitswesen*. 85(12): 1220-1228. doi: 10.1055/a-2098-3108.

Darauf aufbauend wurden im zweiten methodischen Teilschritt leitfadengestützte problemzentrierte Einzelinterviews mit ärztlichem Personal durchgeführt, das in der stationären Versorgung tätig ist und grundlegende Kenntnisse über Antibiotikaverordnungen sowie über Krankenhausabläufe hat und folglich eine zentrale Perspektive auf den Einsatz und die Implementierung von KI-basierten EUS vertritt. Als Zielgruppe wurde dabei die operative Ebene der Leistungserbringenden verschiedener Fachrichtungen und Hierarchieebenen adressiert. Zur theoretischen Orientierung wurden deduktiv Elemente aus dem HOT-fit-Modell [32] als konstituierend-strukturierende Elemente in den Leitfaden integriert. Der angelehnt an die SPSS-Methode nach Helfferich [127] entwickelte halb-strukturierte Leitfaden umfasste drei inhaltliche Komplexe. Zu Beginn erfolgte ein allgemeiner Einstieg in das Themenfeld, um notwendige Begrifflichkeiten zu klären. Der zweite Komplex rekurrierte auf den Domänen des HOT-fit-Modells und beinhaltete insgesamt 12 Hauptfragen sowie zusätzlich untergeordnete Fragestellungen zur Implementierung KI-basierter EUS für die Antibiotikatherapie im Krankenhaus. Der dritte Komplex diente exmanenten und immanenten Nachfragen und einer offenen Ausstiegsfrage, um zusätzliche Aspekte zu erörtern, welche im Rahmen des Interviews nicht vorstrukturiert thematisiert wurden. Es nahmen insgesamt elf Männer und drei Frauen an den problemzentrierten Interviews teil. Die durchschnittlich 30-minütigen Interviews wurden jeweils auf Tonband aufgezeichnet. Das erhobene qualitative Material wurde transkribiert und inhaltsanalytisch nach Kuckartz [128] ausgewertet.

Studie III: Tokgöz, P; Krayter, S; Hafner, J & Dockweiler, C (2024). Decision support systems for antibiotic prescription in hospitals: A survey with hospital managers on factors for implementation. *BMC Medical Informatics and Decision Making*, 24(96). doi: 10.1186/s12911-024-02490-7.

Neben Perspektiven der operativen Ebene (s. *Studie II*) fokussierte *Studie III* die innerbetriebliche Organisation des übergeordneten Führungsgremiums. Dieses setzt sich üblicherweise aus der ärztlichen Direktion, der Pflegedirektion und Verwaltungsdirektion zusammen und bildet gemeinsam das Krankenhausdirektorium. Diese Perspektive ist von wesentlichem Interesse, da bislang nur wenige Erkenntnisse zur Rolle dieser Strukturen bei der Implementierung KI-basierter EUS im Krankenhaus vorliegen. Über das Verzeichnis der Krankenhäuser und Vorsorge- und Rehabilitationseinrichtungen des Statistischen Bundesamtes [129] wurden die verantwortlichen Person(en) der Einrichtungen sowie die allgemeinen Kontaktdaten recherchiert. Die Auswahl der Teilnehmenden erfolgte als Vollerhebung, bei der alle identifizierten Krankenhäuser sowie auf Grundlage öffentlich zugänglicher Kontaktdaten recherchierten Ansprechpartner zur Teilnahme an der Befragung eingeladen wurden. Es wurden insgesamt 1.416 Personen über ein persönliches Anschreiben zu der geschlossenen Online-Umfrage eingeladen, von denen 181 die Umfrage vollständig ausfüllten. Den inhaltlichen Einstieg ebnete eine Priorisierung von Versorgungsproblemen in Bezug auf Antibiotikaverordnungen im Krankenhaus, die sowohl aus der Literatur als auch aus den vorangegangenen problemzentrierten Einzelinterviews extrahiert wurden. Zusätzlich wurde eine Definition KI-basierter EUS vorgestellt, um den Teilnehmenden eine Orientierung hinsichtlich des Forschungsgegenstands zu geben. Anschließend rekurrten die Fragen entlang der Domänen des HOT-fit-Modells [32]. Die Ergebnisse der Online-Erhebung wurden zur Beschreibung der prozentualen Häufigkeiten und Verteilung in den einzelnen Items deskriptiv analysiert und aufbereitet.

Studie IV: Tokgöz, P; Albrecht, J & Dockweiler, C (2025). Implementation of Artificial intelligence-based decision support systems for antibiotic prescribing in hospitals: A Delphi study. *Front. Digit. Health* 7:1555042. doi: 10.3389/fdgth.2025.1555042.

Um schließlich die aus den *Studien I-III* identifizierten Determinanten und daraus abgeleiteten Anforderungen einer erfolgreichen Implementierung KI-basierter EUS im Kontext der Antibiotikatherapie im Krankenhaus aus Expertenperspektive konsolidiert einschätzen zu lassen, wurde in *Studie IV* eine Delphi-Befragung umgesetzt. Im Rahmen eines mehrstufigen Verfahrens wurde ein heterogen zusammengesetztes Panel von Experten aus Forschung und Praxis zur Implementierung KI-basierter EUS eingeladen, um unabhängig voneinander ihre Einschätzungen bzw. ihre Zustimmung oder Einwände gegenüber den formulierten Anforderung zu äußern. Die Antworten jeder Runde wurden gepoolt, mittels qualitativer Inhaltsanalyse untersucht und den Teilnehmenden anschließend erneut vorgelegt [130]. Spezifische Kenntnisse zu KI-basierten EUS waren nicht erforderlich; der Begriff *KI-basierte EUS* wurde bereits in der Einladung zur Befragung erläutert. Die Ergebnisse aus den *Studien I-III* dienten als inhaltliche Grundlage für die erste Delphi-Runde. Entlang der Domänen des HOT-fit-Modells [32] wurden Argumente in Bezug auf die Determinanten als Anforderung formuliert und auf einer

fünfstufigen Likert-Skala bewertet; ergänzende Kommentare konnten in offenen Textfeldern angegeben werden. In der zweiten Runde bewerteten die Experten die aggregierten Ergebnisse, priorisierten die Anforderungen nach Relevanz für die Implementierung und schätzten deren Umsetzbarkeit in der klinischen Praxis ein. Determinanten ohne Konsens wurden in einer weiteren Runde erneut vorgelegt. Die Auswertung erfolgte mittels deskriptiver Statistik, Mann-Whitney-U-Tests sowie der Henry-Garret-Ranking-Methode [131]. An der ersten Runde nahmen 77 von 511 eingeladenen Experten (15%) teil, von denen 36 (47%) auch die zweite Runde abschlossen.

5. Ergebnisse

Die vorliegende Dissertation analysiert Determinanten, die aus der Perspektive der an der Versorgung beteiligten Akteure eine zielgerichtete Implementierung KI-basierter EUS zur Antibiotikatherapie im Krankenhaus beeinflussen. Kapitel 5.1 bis 5.4 bilden mit den publizierten Fachartikeln kumulativ den Ergebnisteil, die entlang der in Kapitel 1.2 definierten Fragestellungen zusammengefasst werden. In Kapitel 5.5 werden die Determinanten und daraus abgeleiteten Anforderungen abstrahiert und in einen konzeptionellen Rahmen entlang der Dreiteilung des HOT-fit-Modells eingeordnet, um die übergeordnete Fragestellung dieser Arbeit zu adressieren.

5.1 Evidenzbasierte Systematisierung fördernder und hemmender Faktoren der Implementierung KI-basierter Entscheidungsunterstützungssysteme

Im Rahmen der **ersten Fragestellung** wurden Determinanten von fördernden und hemmenden Bedingungen der Implementierung KI-basierter EUS zur Antibiotikatherapie unter Berücksichtigung und Bewertung der Übertragbarkeit von internationalen Forschungsergebnissen identifiziert und kategorisiert. Faktoren, die die Implementierung KI-basierter EUS beeinflussen, wurden durch Textanalyse identifiziert sowie in Anlehnung an die Domänen des HOT-fit-Modells [32] kategorisiert und unterschieden in fördernde (d. h. Faktoren, die in den Studien als positive Aspekte für die Implementierung angesehen werden) und hemmende Faktoren (d. h. Faktoren, die die Implementierung behindern bzw. negativ beeinflussen). Es wurden 25 Faktoren identifiziert, die der technologiebezogenen Domäne zuzuordnen sind und v. a. auf die Systemattribute sowie die Eigenschaften der generierten Empfehlungen rekurren [132]. Hierbei wurden die Aspekte der Interoperabilität und des Zugangs als bedeutsam herausgearbeitet. Des Weiteren sind eine einfache Bedienung sowie die Anpassungsfähigkeit an den Kontext und individuelle Gegebenheiten als implementierungsrelevante Determinanten hervorzuheben. Nicht zuletzt gelten die Nachvollziehbarkeit der Empfehlung und die Offenlegung der Evidenzbasis als Erfolgsfaktoren für die Implementierung KI-basierter EUS, während sich

restriktive Formulierungen mit wenig Spielraum für Abweichungen als hinderlich für die Implementierung herausgestellt haben [132]. In der organisationalen Domäne wurden 15 Faktoren identifiziert, darunter die Integration der Nutzer in die Planungs-, Entwicklungs- und Implementierungsphase sowie strukturelle und prozessuale Rahmenbedingungen, wie bspw. die Verfügbarkeit von Schulungs- und Weiterbildungsangeboten oder die physische Infrastruktur. Mit Bezug auf die nutzerbezogene Domäne, der elf Faktoren zugeordnet wurden, determiniert die Art und Weise der Interaktion zwischen den Nutzern und KI-basierten EUS den Implementierungserfolg. Dies ist u. a. durch die vorliegenden Wissensbestände und Kompetenzen sowie der Einstellung und Haltung der Nutzer charakterisiert. Somit kann bspw. fehlendes Wissen in Bezug auf die Funktionsweise von KI-basierten EUS eine Herausforderung für die Implementierung darstellen, während die Wahrnehmung über ausreichende Kompetenzen positiv mit einer Implementierung assoziiert ist [132].

5.2 Perspektiven des ärztlichen Fachpersonals zur Förderung und Hinderung der Implementierung KI-basierter Entscheidungsunterstützungssysteme

Die Beantwortung der **zweiten Fragestellung** erfolgte auf Grundlage einer Bestandsaufnahme aus Perspektive von Leistungserbringenden der operativen Ebene verschiedener Fachdisziplinen sowie unter Einsatz problemzentrierter Einzelinterviews. Dabei wurden sowohl Einschätzungen zum aktuellen Stellenwert, zu bestehenden Bedarfen und möglichen Hemmnissen für eine Implementierung im eigenen Berufsumfeld als auch zur zukünftigen Integration KI-basierter EUS im Kontext der Antibiotikatherapie im Krankenhaus erhoben. Auf Ebene der Technologie wurden eine niedrigschwellige und intuitive Bedienbarkeit von den befragten Personen als förderlich für die Implementierung angesehen. Gleichzeitig wurde der Wunsch geäußert, dass ein Großteil der für die Empfehlungen relevanten Daten automatisiert aus bereits vorhandenen Systemen, wie dem KIS einfließen sollte. Hierfür sei Kompatibilität elementar. Dabei betonten sie auch eine notwendige Kompatibilität mit allen bestehenden Systemen des Krankenhauses, sodass alle Abteilungen miteinander vernetzt sind [133]. Optimalerweise sollte die Ausführung des EUS auf sämtlichen mobilen Endgeräten des Krankenhauses und somit unmittelbar am Behandlungsort möglich sein. Die Präsentation der Ergebnisse sollte strukturiert und nachvollziehbar sein, wobei ein Scroll-Down-Menü und eine minimale Anzahl an Schaltflächen gewünscht wurden, um eine effiziente und benutzerfreundliche Bedienung zu erreichen. Ferner wurde die Vollständigkeit und Nachvollziehbarkeit von Empfehlungen sowie die Verfügbarkeit einer gleichwertigen Alternativbehandlung als wichtig erachtet, um bspw. bei Unverträglichkeiten und Allergien agieren zu können. Damit zusammenhängend sollten datenschutzrechtliche Bestimmungen eingehalten werden und transparent sein, auf welcher Evidenzbasis die Empfehlungen rekurren [133].

Ergänzend dazu erweist es sich als notwendig, über einen Ansatz hinauszugehen, der lediglich die Attribute KI-basierter EUS und ihre Nutzbarkeit fokussiert. Es sollten gleichermaßen die sozialen und institutionellen Einflüsse berücksichtigt werden, die sich auf die Implementierung auswirken können. Inwiefern eine nachhaltige Implementierung KI-basierter EUS realisierbar ist, hinge zusätzlich von der Veränderungsbereitschaft der Organisation und dessen Mitgliedern sowie von hierarchischen Strukturen und einrichtungsspezifischen Standards ab [133]. Umfangreiche Investitionen in Krankenhäusern, in denen Widerstand und Zögern vorherrschen, seien weder effizient noch kosteneffektiv. Ein entsprechender Wertewandel in den Organisationen hin zu einer interdisziplinären Zusammenarbeit zur Förderung eines Innovations-transfers sei zum gegenwärtigen Zeitpunkt unzureichend realisiert. Insbesondere die Unterstützung durch die institutionelle Leitungen ist aus Sicht der Befragten bedeutsam für die Implementierung. Ein entscheidender Schritt zur Förderung der Implementierung bestehe außerdem darin, den rechtlichen Rahmen zu klären, der der Einführung zugrunde liegt, sowie Anleitung und Unterstützung für den Umgang mit Schwierigkeiten und Problemen anzubieten. Die Sensibilisierung angehender Ärzte und weiterem medizinischen Personal durch die curriculare Einbindung von KI-Inhalten wurde außerdem als eine wichtige Determinante hervorgehoben. Daran anknüpfend wurden eine als ausreichend wahrgenommene Technikkompetenz sowie vorherige Erfahrungen mit KI-basierten EUS und eine grundsätzliche offene Haltung gegenüber der Nutzung förderlich für die Implementierung angesehen [133]. Ein weiterer zentraler Schlüsselfaktor ist das Vertrauen in die Empfehlungen KI-basierter EUS, das durch transparente Darlegung der Funktionsweise und Logik des Systems gefördert werden könne. Die Befragten wiesen zudem darauf hin, dass die Implementierung eines KI-basierten EUS, das von allen Ärzten in der klinischen Versorgung genutzt werden kann, schwierig sei, da deren Ausbildung und Erfahrungen in der Verordnung antimikrobieller Mittel variieren könne. Dennoch betonten die Befragten, dass die Implementierung KI-basierter EUS im Kontext der Antibiotikatherapie eine Arbeitserleichterung und Orientierungshilfe bieten könne; insbesondere für Ärzte mit weniger Erfahrung im Umgang mit Antibiotika. Gleichzeitig wäre es wichtig, Bewusstsein darüber zu schaffen, dass KI-basierte EUS lediglich eine Unterstützung darstellen und die Therapieentscheidung und -verantwortung schlussendlich dem ärztlichen Personal obliegt. Darüber hinaus wurde betont, dass das Alter eine bedeutende Rolle für die Implementierung spielt, da ältere Personen technologischen Entwicklungen tendenziell skeptischer gegenüberstehen würden als jüngere. Zusätzlich wurde der Berufserfahrung eine zentrale Bedeutung zugeschrieben, wobei angenommen wird, dass mit zunehmender Berufserfahrung die Skepsis gegenüber dem Einsatz von KI-basierten EUS wächst [133].

5.3 Perspektiven der Krankenhausdirektorien zur Förderung und Hinderung der Implementierung KI-basierter Entscheidungsunterstützungssysteme

Die dritte Studie erweitert die vorliegende Arbeit im Kontext der Determinanten für die Implementierung KI-basierter EUS zur Antibiotikatherapie um die bisher unzureichend erforschte Perspektive der strategischen Ebene in Krankenhäusern. Die Ergebnisse, die ebenfalls zur Beantwortung der **zweiten Forschungsfrage** hinzugezogen wurden, zeigen in Übereinstimmung mit den Ergebnissen aus den Einzelinterviews, dass die Handhabbarkeit von EUS, Kompatibilität mit bestehenden Systemen sowie die Vereinbarkeit mit Arbeitsabläufen zu berücksichtigen sind, um Implementierungsbarrieren zu überwinden, die sich u. a. aus der mangelnden Integration und der Zugänglichkeit ergeben können. Ebenso sind die Nachvollziehbarkeit und Anpassungsmöglichkeit der generierten Empfehlung als implementierungsrelevante Faktoren auf Ebene der Technologie hervorzuheben [134]. Die kontinuierliche Motivation und Schulung relevanter Nutzergruppen seien dringend erforderlich. Dies steht in engem Zusammenhang mit den Aspekten, dass deren Beteiligung an der Planungs-, Entwicklungs- und Implementierungsphase sowie der Neugestaltung organisationaler Abläufe und Strukturen mehr Aufmerksamkeit geschenkt werden sollten. Aus Perspektive der befragten Personen ist das insofern wichtig, dass durch die Kompetenzvermittlung und Partizipationsmöglichkeiten der Mehrwert KI-basierter EUS für die Berufspraxis eher wahrgenommen wird und dadurch Vorbehalte und Unsicherheiten abgebaut werden können [134]. Der Großteil der Befragten fühlt sich nach eigener Einschätzung „eher schlecht“ bzw. „schlecht“ über unterschiedliche Aspekte KI-basierter EUS, wie etwa Funktionsweise, Einsatzmöglichkeiten, Wirksamkeit sowie rechtliche Rahmenbedingungen und ethische Konsequenzen informiert (s. Abb. 2).




Abb. 2: Informationsstand der Teilnehmenden zu KI-basierten Entscheidungsunterstützungssystemen (prozentualer Anteil) [134]

Gleichwohl ist – vor dem Hintergrund des als eher gering wahrgenommenen Informationsstandes – die grundlegende positive Einstellung der Befragten gegenüber KI-basierter EUS nennenswert (s. Abb. 3).




Abb. 3: Einstellung der Teilnehmenden gegenüber dem Einsatz von KI-basierten Entscheidungsunterstützungssystemen (prozentualer Anteil) [134]

Hier gaben ca. 92% der Befragten an, dass sie einer Implementierung KI-basierter EUS „eher offen“ oder „offen“ gegenüberstehen. Weiterhin äußerten die Befragten in hohem Maße, dass diese einen zusätzlichen Nutzen für Ärzte und Patienten bringen können.

5.4 Konsolidierte Bewertung der Implementierungsanforderungen von KI-basierten Entscheidungsunterstützungssystemen

Abschließend wurden in *Studie IV* die Einschätzung und das Wissen von Experten aus Forschung und Praxis systematisch über mehrere Runden erfasst. Das Ziel war es, die aus den Determinanten abgeleiteten Anforderungen für künftige Implementierungen bewerten zu lassen (**Fragestellung 3**). Insgesamt konnten 34 Implementierungsanforderungen konsolidiert werden: 15 auf der technologiebezogenen, elf auf der organisationalen und acht in Bezug auf die nutzerbezogenen Ebene [135]. Bei deren Priorisierung zeigte sich, dass in der technologiebezogenen Domäne dem Systemzugang und der Systemintegration sowie einer intuitiven Benutzeroberfläche eine hohe Bedeutung beigemessen wurde. Die Teilnehmenden befürworteten einheitlich den Aspekt, dass für die Implementierung KI-basierter EUS Daten in ausreichender Qualität vorliegen und deren regelmäßige Pflege erfolgen sollte. Darüber hinaus erwarteten sie eine unkomplizierte und einfache Anwendung und dass die Empfehlungen klar und verständlich dargestellt werden. Ebenfalls sind die Unterstützung in technischen Fragen und die Wartung des Systems für eine erfolgreiche Implementierung hervorzuheben [135]. Um die Fähigkeiten im Umgang mit KI-basierten EUS zu verbessern, sollten auf organisationaler

Ebene den Nutzern ausreichende Schulungsmöglichkeiten und eine kontinuierliche Einarbeitung geboten werden. Darüber hinaus sollten KI-basierte EUS derart in bestehende Arbeitsabläufe integriert werden, dass sie diese effektiv unterstützen. Die Befragten waren sich zudem einig, dass die Bereitschaft der Krankenhäuser, neue Technologien in die Versorgung zu integrieren, die Unterstützung durch die institutionelle Leitung sowie die Sicherstellung der technischen Infrastruktur implementierungsrelevant sind. Uneindeutig ist hingegen, ob finanzielle Anreize für Krankenhäuser die Entscheidung zur Implementierung KI-basierter EUS fördern [135]. Die Experten betonten einheitlich, dass KI-basierte EUS dann erfolgreich implementiert werden können, wenn die Nutzer einen Mehrwert erkennen und spürbar davon profitieren. Zwar besteht Konsens darüber, dass frühere Erfahrungen mit KI-basierten EUS die Implementierung erleichtern können, jedoch müsse berücksichtigt werden, inwieweit diese Erfahrungen von den Nutzern als positiv wahrgenommen werden. Hingegen zeichnet sich kein eindeutiges Bild ab, ob langjährige Berufserfahrung der Nutzer ein Hindernis für die Implementierung darstellen könnte. Hier stimmten 38,9 % der Teilnehmenden eher nicht bzw. 8,3 % nicht der Aussage zu, dass Skepsis gegenüber KI-basierten EUS umso größer ist, je mehr Berufserfahrung die Nutzer haben, während 19,4 % der Teilnehmenden der Aussage zustimmten und 30,6 % eher zustimmten [135].

Die Ergebnisse der Delphi-Befragung zeigen, dass die Förderung von Fähigkeiten im Umgang mit KI-basierten EUS, die Offenheit gegenüber dem Einsatz und das Vertrauen sich unterstützend auf die Implementierung auswirken [135]. Die Teilnehmenden teilten ihre Ansichten darüber, wie Vertrauen in KI-basierte EUS aufgebaut werden kann (s. Abb. 4).




Abb. 4: Bewertung der Vertrauensfaktoren in Bezug auf KI-basierte Entscheidungsunterstützungssysteme (prozentualer Anteil) [135]

Fast die Hälfte der Befragten gab an, dass KI-basierte EUS derart funktionieren sollten, dass sachlich genaue, moralisch und nicht schädliche Ergebnisse generiert werden, damit das Vertrauen in die Empfehlungen eher erhöht wird. Ca. 60% der Befragten gab an, dass die ausschließliche Verwendung hochwertiger Inhalte für das Training KI-basierter EUS, und dass das Training des Modells auf hochgradig kohärente und reproduzierbare Ergebnisse das Vertrauen stark erhöhen würde. Die Datenbasis sei ebenfalls wichtig, insofern dass für mehr als 60% der Befragten die Angabe von Datenquellen das Vertrauen stark erhöhen würde [135].

5.5 Ergebnissynthese: Determinanten und Anforderungen der Implementierung KI-basierter Entscheidungsunterstützungssysteme für die Antibiotikatherapie im Krankenhaus

Aus den Ergebnissen der Studien zu Determinanten für die Implementierung KI-basierter EUS im Kontext der Antibiotikatherapie im Krankenhaus (Kapitel 5.2 bis 5.4) lassen sich Anforderungen an die Implementierung ableiten (s. Tab. 2).

Tab. 2: Übersicht zentraler Determinanten und abgeleiteter Anforderungen (Eigene Darstellung)

Zentrale Determinanten und abgeleitete Anforderungen der Implementierung KI-basierter EUS	
Technologie	
Zentrale Determinanten	Anforderungen
Interoperabilität/ (technischer) Zugang	- Niedrigschwelliger Zugang zum System - Integration in vorliegende IT-Strukturen
Datenqualität/-sicherheit	- Datenschutzkonforme Nutzung von Gesundheitsdaten
Nachvollziehbarkeit/ Transparenz	- Datenbasierte, nachvollziehbare, eindeutige und durch Experten kuratierte Entscheidungsunterstützung
Anpassungsfähigkeit/ Kontextualisierung	- Lösungen zu spezifischen Behandlungsfällen - Vorhandensein von Alternativvorschlägen
Intuitive Benutzeroberfläche und Navigation	- Übersichtliche Aufbereitung und Darstellung von Inhalten/ Empfehlungen - Spezifische Warnfunktionen - Möglichkeit manueller Dateneingabe
Wissens-/ Datenbasis	- Regelmäßiges Monitoring/ Aktualisierung der Daten bzw. des Algorithmus

Zentrale Determinanten und abgeleitete Anforderungen der Implementierung KI-basierter EUS	
Organisation	
Zentrale Determinante	Anforderungen
Aus- und Weiterbildung	- Ausreichende Qualifikationsmöglichkeiten für Nutzer sowie eine fortwährende Einarbeitung - Curriculare Verankerung von KI-Kompetenzen/ Bildungsinitiativen
Finanzierung/ Investition	- Investition in die physische Ausstattung und in organisationale Ressourcen
Reglementierung/ Gesetzgebung	- Klärung und Konkretisierung der gesetzlichen Vorschriften - Notwendige Rechtssicherheit im Umgang mit KI/ Algorithmen - Etablierung von Mechanismen zur Überwachung der Einhaltung von Vorschriften
Institutionelle Leitung	- Engagement der Führungskräfte, um eine „top-down-Unterstützung“ bei der Implementierung sicherzustellen - Vorhandensein einer Vision/Strategie
Hierarchische Strukturen/ Organisationskultur	- Institutionelle Veränderungsbereitschaft in Strukturen und Prozessen - Ausrichtung der Organisation auf die Implementierung von KI-basierten EUS
Soziale Netzwerke, Partizipation und Kommunikation	- Positive Kooperationsbeziehungen mit gleichberechtigter Rollenverteilung - Abbau von Widerständen und Vorbehalten
Nutzer	
Zentrale Determinante	Anforderungen
Wissen/ Kompetenzen	- Potenziale und Grenzen KI-basierter EUS verstehen können - Fähigkeiten, um KI-basierte EUS in der Versorgungspraxis anwenden zu können
Alter der Nutzer	- Relevanz altersbezogener Unterschiede in Bezug auf die Einstellung gegenüber KI-basierten EUS berücksichtigen
Wahrnehmbarer Nutzen	- Unterstützung von bestehenden Versorgungsprozessen und der ärztlichen Tätigkeiten - Erleichterung der klinischen Arbeitsabläufen - Sicherheitsgefühl in medizinischen Entscheidungsprozessen
Lernbereitschaft/ Offenheit	- Aufbau und Aktualisierung von KI-bezogenen Wissensinhalten und Kompetenzen - Zusammenarbeit mit verschiedenen Disziplinen und Bereitschaft, die Komfortzone zu verlassen

Zentrale Determinanten und abgeleitete Anforderungen der Implementierung KI-basierter EUS	
Nutzer	
Zentrale Determinante	Anforderungen
Vertrauen/ Vertrautheit	- Kongruenz der Empfehlungen und bestehender Behandlungspraktiken, Moralvorstellungen und Werten - Transparenz hinsichtlich der Funktionsweise und der Empfehlungen - Vorherige Erfahrung mit KI-basierten EUS
Berufliches Rollenverständnis	- Relevanz von Berufserfahrung und professioneller Expertise - Entscheidungsautonomie und (tradierte) Verhaltensgewohnheiten/ Handlungsroutinen

In dieser Arbeit wurde auf **technologiebezogener Ebene** Interoperabilität als zentrale Determinante für die Implementierung KI-basierter EUS identifiziert. Aus Sicht der befragten Personen führt mangelnde Interoperabilität zu Ineffizienzen in den Arbeitsabläufen. Dies wird u. a. auf den zum Zeitpunkt der Befragung vorliegenden unvollständigen und dezentralisierten Einsatz der ePA sowie die grundsätzlich fragmentierte digitale Gesundheitsinfrastruktur in Deutschland zurückgeführt. Dies behindere die nahtlose Integration und den Datenaustausch und zwingt medizinisches Personal dazu, zwischen mehreren Plattformen zu wechseln, was den Arbeitsablauf stört und die kognitive Belastung erhöht. Darüber hinaus sind die Systemeigenschaften und mit ihr die Rückführung der Komplexität von KI-basierten EUS als soziotechnische Systeme in Richtung Einfachheit, Verständlichkeit, Bedienbarkeit und Überschaubarkeit zentral für den Implementierungserfolg. Dabei besteht innerhalb dieses Themenkomplexes ein Zielkonflikt zwischen der Entwicklung von intuitiv bedienbaren Systemen mit einem niedrigschwelligen Zugang und dem Interesse der Nutzer nach integrierten Funktionen, die Lösungen zu komplexen Fragestellungen und individuellen Patientenfällen liefern. Daran gekoppelt sind die Forderung nach Nachvollziehbarkeit und Transparenz der generierten Empfehlungen sowie die Sicherstellung und Einhaltung der Datensicherheit.

Über die verfügbare Infrastruktur hinaus ist auf **organisationaler Ebene** der technische Zugang, d. h. die vorhandene und zugängliche Hardware (wie bspw. Computer, Tablet, Smartphone) zentral, welches die Implementierung fördern kann. Ein nicht vorhandener oder eingeschränkter Zugang zur technischen Ausstattung, respektive eine unzureichende Investition in die physische Infrastruktur zeigt sich als Hindernis für den nachhaltigen Einsatz KI-basierter EUS, da sie bspw. den personellen Bedarf erhöhen können (z. B. durch erforderliche Doppel-dokumentationen bei unzureichender Integration). Darüber hinaus sind Kommunikation und Partizipation wesentliche Bestandteile des Implementierungsprozesses, die die Nutzer zunächst für die bevorstehende Veränderung und dessen möglichen Auswirkungen auf die

Berufspraxis sensibilisieren. Damit zusammenhängend kommt Führungskräften eine entscheidende Rolle zu, die bei der Bewältigung des organisationalen Wandels proaktiv vorgehen und sicherstellen müssen, dass sich Organisationsmitglieder auf allen Ebenen während des gesamten Prozesses unterstützt und involviert fühlen. Ein eingeschränktes Verständnis der Bedürfnisse und Perspektiven der Nutzer kann zu Vorbehalten und Widerständen führen, die der Entwicklung von konstruktiven Partnerschaften entgegenwirken. Die Partizipation der Nutzer und die damit verbundene Integration klinischen Fachwissens in den Implementierungsprozess KI-basierter EUS erfordern zeitliche und finanzielle Ressourcen, die nicht in allen Krankenhäusern in ausreichendem Maße vorhanden sind. Ein erhöhter personeller Aufwand durch bspw. Freistellung von medizinischem Personal für die Weiterbildung sowie die Kosten für Schulungen sind u. a. wesentliche Determinanten der Implementierung. Konsequenterweise kann die Implementierung KI-basierter EUS für Krankenhäuser kostspielig sein und ist oftmals mit Unsicherheiten hinsichtlich der Rentabilität verbunden. Die Ergebnisse der vorliegenden Arbeit zeigen, dass dies in erster Linie darauf zurückzuführen ist, dass es an belastbarer Evidenz hinsichtlich eines eindeutigen Mehrwerts für die Gesundheitsversorgung mangelt. Zusätzlich wurde die Besorgnis darüber geäußert, wer haftbar oder verantwortlich ist, wenn Entscheidungen, die auf Empfehlungen von KI-basierten EUS fußen, zu einer Verschlechterung der Versorgungssituation führen. In diesem Zusammenhang wird gefordert, auf organisationaler und rechtlicher Ebene zu konkretisieren, in welchem Umfang Ärzte als Nutzer die Empfehlungen KI-basierter EUS umsetzen sollen. Ebenso ist zu klären, inwieweit sie selbst oder die Krankenhäuser haftbar gemacht werden können, wenn entsprechende Empfehlungen nicht berücksichtigt werden und daraus ein Schaden entsteht. Unklare Grenzen der beruflichen Haftung und ein Mangel an Instrumenten zum Selbstschutz von Ärzten sind folglich Barrieren für die Implementierung KI-basierter EUS.

Auf **Ebene der Nutzer** deuten die Ergebnisse der vorliegenden Arbeit darauf hin, dass die Versorgungsakteure den potenziellen Mehrwert KI-basierter EUS für die gesundheitliche Versorgung grundsätzlich anerkennen. Diese werden als bedeutende Werkzeuge für die tägliche klinische Entscheidungsfindung wahrgenommen, die u. a. Orientierungshilfe für die Wahl der Antibiotikatherapie geben, die Behandlungssicherheit erhöhen und die Behandlungsverläufe verbessern können. Diese Vorteile kommen dann zum Tragen, wenn KI-basierte EUS optimal in die klinischen Arbeitsabläufe und Routinen integriert sind, die die Bedürfnisse der Nutzer erfüllen und qualitativ hochwertige Ergebnisse liefern. Gleichzeitig bringt das Potenzial KI-basierter EUS, die Rolle von Ärzten erweitern oder erheblich verändern zu können, zahlreiche Bedenken mit sich. Dies umfasst die Besorgnisse hinsichtlich Arbeitsplatzsicherheit und der Abwertung ärztlicher Expertise und des Erfahrungswissens. Die Ergebnisse offenbaren, dass Ärzte KI-basierten EUS misstrauen können, wenn die Empfehlungen den eigenen intuitiven Schlussfolgerungen widersprechen, insbesondere wenn diese Personen über eine

umfangreiche professionelle Qualifizierung und langjährige Berufserfahrung verfügen. Insbesondere bei kritischen Entscheidungen müssen sich Nutzer auf die Ergebnisse der EUS verlassen können, um eine fundierte Entscheidung zu treffen. Daran gekoppelt wird der Wahrung der professionellen Entscheidungsautonomie ein zentraler Stellenwert beigemessen. Ungeachtet der Potenziale KI-basierter EUS für die Entscheidungsfindung sehen die in der vorliegenden Arbeit befragten Versorgungsakteure die endgültige Verantwortung für die Patientenversorgung weiterhin bei den behandelnden Ärzten. Daher ist es wichtig, bewusst von den KI-Empfehlungen abweichen zu können, wie es bspw. auch bei klinischen Leitlinien der Fall ist. Außerdem werden etablierte Standards und bewährte klinische Praktiken überwiegend fortgeführt, was die Implementierung neuer, innovativer Behandlungsansätze erschwert. Fundamentale Veränderungen bestehender Verhaltensmuster und Handlungsrouinen in Krankenhäusern lassen sich daher nur schwer realisieren. Dieser Aspekt steht in Zusammenhang mit dem Einfluss hierarchischer Strukturen. Ebenso ist entscheidend, wie Nutzer mit KI-basierten EUS interagieren und wie die hieraus resultierende Interaktionsbeziehung wahrgenommen wird. Die Erfolgsaussichten der Implementierung KI-basierter EUS sind geringer, wenn Nutzer sie als Bedrohung ihrer professionellen Identität und Autonomie empfinden. Schließlich verdeutlichen die Ergebnisse, dass eine erfolgreiche Implementierung wesentlich davon abhängt, inwieweit die Nutzerwahrnehmung positiv gestaltet werden kann und die Nutzer die erforderliche Lernbereitschaft sowie Offenheit gegenüber KI-basierten EUS aufbringen.

6. Diskussion

Die dargestellten Ergebnisse werden nachfolgend kritisch diskutiert und in den aktuellen Forschungsstand eingeordnet. Es erfolgt zunächst die inhaltliche Diskussion der identifizierten Determinanten und abgeleiteten Anforderungen (Kapitel 6.1), anschließend werden die Stärken und Limitationen der einzelnen Studien sowie der Dissertation dargelegt (Kapitel 6.2).

6.1 Inhaltliche Diskussion

Insgesamt offenbaren die Ergebnisse der vorliegenden Arbeit ein breites Spektrum an Determinanten für die Implementierung KI-basierter EUS im Kontext der Antibiotikatherapie im Krankenhaus (s. Abb 5). Zwar beziehen sich die zugrundeliegenden Studien und bearbeiteten Forschungsfragen auf ein beschriebenes Themenfeld und Kontext (in dieser Dissertation KI-basierte EUS für die Antibiotikatherapie im Krankenhaus), jedoch stehen die Determinanten in einer Reihe mit Ergebnissen aus anderen Versorgungsbereichen und -kontexten, in denen KI-basierte EUS eingesetzt wurden. Hierzu gehören bspw. Forschungen in der Radiologie [136–138], Onkologie [139, 140], Notfallversorgung [141–143], psychiatrischen Versorgung [121,

144] sowie hausärztlichen Versorgung [145, 146]. Eine Generalisierung bzw. Übertragbarkeit der hier identifizierten Determinanten auf andere Versorgungsbereiche ist, wenn auch eingeschränkt, möglich. Folglich können diese als Grundlage dafür dienen, um die grundsätzliche Implementierung KI-basierter EUS für die Gesundheitsversorgung zu reflektieren bzw. mögliche Barrieren zu erkennen, zu überwinden und förderliche Determinanten gezielt zu nutzen.




Abb. 5: Schematische Darstellung der Determinanten für die Implementierung
(Eigene Darstellung)

Die involvierten Zielgruppen der zugrundeliegenden Studien haben die zunehmende Bedeutung KI-basierter EUS zum Ausdruck gebracht und es wird erwartet, dass diese zukünftig präsenter im klinischen Arbeitsalltag sein werden. Auch wenn – übereinstimmend mit vergleichbaren empirischen Untersuchungen [147, 148] – technologiebezogenen Faktoren ein hoher Stellenwert zugeschrieben wird, ist die einseitige Konzentration auf die technische Realisierung nicht zielführend für eine erfolgreiche Implementierung. Damit zusammenhängend weisen Cabitza et al. auf den Kontrast zwischen dem Diskurs über die Potenziale und Effizienz KI-basierter EUS und der Realität schwer transformierbarer Sektoren, wie die des Gesundheitswesens hin [149]. Die Implementierung steht stark in Verbindung mit spezifischen Struktur- und Prozessgegebenheiten der Organisation *Krankenhaus*. Außerdem scheinen einige nutzerbezogene Determinanten die Interaktionsbeziehung mit KI-basierten EUS zu bedingen, wie z. B. die Offenheit von Nutzern und die wahrgenommenen KI-Kompetenzen, während andere Determinanten die Auswirkungen der Interaktion zu sein scheinen, wie bspw. der

wahrgenommene Mehrwert für die Berufspraxis sowie das Vertrauen in die Entscheidungsfindung. Dies steht in Einklang mit Befunden von Felmingham et al. [150].

Zudem erachteten die in den Studien befragten Zielgruppen das Wissen und Verständnis der Nutzer über die Funktionsweise von KI-basierten EUS sowie die entsprechenden Kompetenzen für deren Anwendung als zentrale Determinanten für eine erfolgreiche Implementierung. Die Ergebnisse zeigen, dass sie ihr eigenes Wissen über KI-basierte EUS zwar als begrenzt einschätzten, jedoch einer Implementierung grundsätzlich offen gegenüberstehen (*Studie II und III*). Der geringe Wissensstand, gepaart mit einer großen Offenheit für das Thema bietet eine ideale Grundlage für Schulungsmaßnahmen [151, 152]. Damit übereinstimmend nannten Khairat et al. das technologische Fachwissen, die Anpassungsfähigkeit an den Arbeitsablauf sowie eine allgemein optimistische Einstellung der Nutzer als wichtige Faktoren für eine erfolgreiche Implementierung [153].

Eine hohe klinische Fachkompetenz scheint die Kooperationsbereitschaft bei der Implementierung von KI-Systemen zu beeinflussen [150], wobei die zugrunde liegenden Mechanismen bislang unklar sind. Möglicherweise hängt dies mit einem geringeren Vertrauen in EUS, einer Tendenz zu übermäßigem Selbstvertrauen oder der Überzeugung zusammen, dass EUS unpräzisere Empfehlungen generieren als erfahrene Ärzte. Neben fachwissenschaftlichen Kompetenzen, die im Studium erworben und kontinuierlich erweitert werden, entwickeln Ärzte personales Wissen, das stark von ihrer klinischen Erfahrung geprägt ist. Vergleichbare Studien zeigen, dass Vorbehalte gegenüber neuen Technologien mit zunehmender Berufserfahrung größer sind [154, 155]. Laut den Annahmen der Novice to Expert Theory (NET)¹¹ [156] wird das Verhalten von medizinischem Fachpersonal mit zunehmender Berufserfahrung stärker durch automatisierte, impulsbasierte Entscheidungen gesteuert. Übertragen auf den vorliegenden Forschungsgegenstand kann angenommen werden, dass weniger erfahrene Ärzte stärker auf Empfehlungen von KI-basierten EUS rekurren würden, während erfahrenere Ärzte diese eher ergänzend nutzen oder ganz darauf verzichten. Auch wenn in *Studie IV* nicht konsentiert wurde, dass erfahrenere Ärzte der Implementierung KI-basierter EUS kritischer gegenüberstehen, kann Berufserfahrung eine relevante Determinante für gewohnheitsmäßiges Verhalten sein [157] und sollte in zukünftigen Untersuchungen zur Implementierung KI-basierter dezidierter betrachtet werden.

Vertrauen spielt in der Interaktion zwischen KI-basierten EUS und den Nutzern eine wichtige Rolle, wobei Herausforderungen hinsichtlich des Vertrauensaufbaus im Kontext von KI-Systemen in bereits zahlreichen Untersuchungen breit thematisiert wurden [158–160]. Die Ergebnisse der vorliegenden Arbeit legen nahe, dass Determinanten wie Erklärbarkeit und

¹¹ Die Theorie beschreibt den Übergang vom bewussten, regelgeleiteten Handeln eines Anfängers zum intuitiven, erfahrungsbasierten Handeln eines Experten [156].

Transparenz der Funktionsweise von KI-basierten EUS das Misstrauen gegenüber den Entscheidungsprozessen und Unsicherheiten in Bezug auf die Zuverlässigkeit der Empfehlungen verringern können. Dies kann zu der Wahrnehmung führen, dass Vertrauen hauptsächlich durch Systemtransparenz beeinflusst wird. Aktuelle Forschungsergebnisse unterstützen die Annahme, dass die Bereitstellung nachvollziehbarer Erklärungen zu den generierten Empfehlungen das Vertrauen in KI-basierte EUS erhöht und eine positivere Einstellung der Nutzer gegenüber deren Implementierung fördert [161, 162]. Dennoch scheint die Systemtransparenz keinen direkten signifikanten Einfluss auf das wahrgenommene Vertrauensniveau zu haben [163, 164]. Weiterhin kann übermäßiges Vertrauen zu Gewöhnungseffekten führen und die menschliche Expertise in den Hintergrund rücken – insbesondere bei jüngeren Ärzten, die sich möglicherweise zu sehr auf die Empfehlungen von KI-basierten EUS verlassen oder ihnen zu viel Vertrauen entgegenbringen, was in Einklang mit weiteren Befunden ist [165]. Die Ergebnisse der vorliegenden Arbeit weisen auf eine generationsbedingte Kluft in der Einstellung gegenüber KI-basierten EUS hin: Jüngere Ärzte sind tendenziell offener für die Implementierung, während ältere und erfahrenere Ärzte Veränderungen gegenüber eher kritisch gegenüberstehen. Ferner kann der reflektierte Einsatz KI-basierter EUS Lerneffekte fördern, wodurch Nutzer metakognitives Wissen erlangen können. Die Ergebnisse unterstützen damit die Befunde von Rieckert et al. [166]. Die aktuelle Forschungslage liefert hierzu teils widersprüchliche Befunde, wobei einige Studien eine höhere Akzeptanz bei jüngeren Nutzern zeigen [167, 168], andere jedoch keinen signifikanten Einfluss des Alters auf die Nutzungsabsicht feststellen [169].

Die Erkenntnisse sollten zudem im Kontext organisationaler Machtdynamiken betrachtet werden. Im Krankenhausumfeld neigen Ärzte, die in einem kooperativen Arbeitsumfeld tätig sind, dazu, das Verhalten und die Routine von Vorgesetzten und Kollegen zu internalisieren [170]. Die dieser Arbeit zugrundeliegenden Studien zeigen, dass Vorgesetzte und Personen in Leitungsfunktionen den Implementierungsprozess KI-basierter EUS determinieren können. Bernardi und Exworthy betonen unterstützend, dass Ärzte mit hybriden Rollen – d. h. diejenigen, die sowohl klinische als auch leitende Aufgaben inne haben – ihre Position nicht nur dazu nutzen können, Innovationen voranzutreiben, sondern auch, um Spannungen und Bedenken bezüglich beruflicher Grenzen auszuhandeln und so die wahrgenommene Verletzlichkeit gegenüber neuen Innovationen zu verringern [171]. Gleichzeitig ist es möglich, dass diese Personen ihre Position als Vertreter der medizinischen Profession nur dann einsetzen, um Kollegen vom Wert einer Innovation zu überzeugen, wenn sie selbst deren Legitimität und Nutzen für die klinische Praxis anerkennen [171].

Die vorliegenden Befunde deuten darauf hin, dass neue Arbeitsabläufe oder neue Tätigkeitsprofile, die durch die Implementierung KI-basierter EUS entstehen, möglicherweise das berufliche Ansehen und die berufliche Identität von Ärzten beeinflussen können, die sich mit

Ergebnissen weiterer Arbeiten decken [172–174]. Die Einführung neuer Technologien erfordert daher mehr als reine Bewusstseinsbildung: Sie setzt einen kollektiven Lernprozess innerhalb der Organisation voraus, in dem sowohl kognitive als auch zwischenmenschliche Mechanismen eine Rolle spielen. In diesem Zusammenhang betonen Warner und Wäger, dass das sogenannte „Verlernen“ bestehender Praktiken und Routinen als eine wichtige Fähigkeit dient, um effektiv mit weiteren Akteuren bei der Implementierung technologischer Innovationen zu interagieren [175]. Gleichzeitig können disziplinäre Abgrenzungen und Eigeninteressen die Implementierung KI-basierter EUS erschweren. Elish weist darauf hin, dass fehlendes technisches Wissen und mangelndes Bewusstsein für KI-spezifische Herausforderungen die Zusammenarbeit zwischen Entwicklern von KI-Systemen und Ärzten als potenzielle Nutzer erschweren können. Dabei bestehen potenzielle Rollenkonflikte und kognitive Dissonanzen zwischen den Berufsgruppen hinsichtlich praktischer und technischer Umsetzung als auch bezüglich der Auswirkungen der KI-Nutzung in der klinischen Praxis [176]. Vor diesem Hintergrund erfordern tief verwurzelte Einstellungs- und Verhaltensbarrieren eine differenzierte Betrachtung, die auch kulturelle Veränderungen und mögliche Rollenverschiebungen berücksichtigt.

6.2 Methodologische Stärken und Limitationen

Wie in Kapitel 4 (s. S. 13) beschrieben, liegt der vorliegenden Dissertation ein sequentielles exploratives Mixed-Methods-Design zugrunde, welches nachfolgend entlang der verwendeten Methoden diskutiert wird.

Die systematische Übersichtsarbeit (*Studie I*) wurde in Übereinstimmung mit den Standards des von Higgins et al. skizzierten methodischen Ansatzes [125] und in Übereinstimmung mit den Berichtslinien der PRISMA-SR-Checkliste [177] durchgeführt. Dennoch liegen der systematischen Übersichtsarbeit Limitationen zugrunde, die bei der Interpretation der Ergebnisse zu berücksichtigen sind. In Anlehnung an die Empfehlungen von Higgins et al. wurde ein Protokoll erstellt, um den Review-Prozess nachvollziehbar und transparent zu gestalten sowie Reporting-Bias zu minimieren [125]. Das Protokoll beinhaltet die Kriterien, nach denen die Reviewer die Studien ein- bzw. ausgeschlossen haben, relevante Daten auswählten, extrahierten und darstellten. Die Literaturrecherche wurde in einschlägigen Fachdatenbanken und Fachbibliotheken durchgeführt. Ergänzend zu der Datenbankrecherche wurde ein Screening der Referenzlisten durchgeführt, sodass weitere thematisch relevante Veröffentlichungen eingeschlossen werden konnten [178]. Die identifizierten Studien wurden von zwei unabhängigen Reviewern anhand der formulierten Ein- und Ausschlusskriterien auf Eignung und Aufnahme in die Übersichtsarbeit überprüft. Hierbei ist anzumerken, dass bereits geringfügige Unterschiede in der Formulierung oder der Beurteilung der Kriterien zu anderen Ergebnissen führen können [179]. Durch das Vier-Augen-Prinzip wurden die Studien zunächst unabhängig

begutachtet. In der anschließenden Zusammenführung und Diskussion konnten Konflikte gelöst und die Qualität der Übersichtsarbeit erhöht werden. Dennoch kann auch durch das Vier-Augen-Prinzip nicht ausgeschlossen werden, dass im gesamten Review-Prozess Informationen übersehen oder fehlinterpretiert wurden. Die Auswertung der eingeschlossenen Studien erfolgte tabellarisch, auf dessen Grundlage die Ergebnisse strukturiert und narrativ zusammengefasst wurden. Zur Bewertung der methodischen Qualität der Studien wurde das Mixed Methods Appraisal Tool (MMAT) [180] verwendet. Das Instrument erlaubt eine systematische Beurteilung qualitativer, quantitativer und Mixed-Methods-Studien in 15 Kategorien [181]. Ein Vorteil des Instruments liegt in seiner einfachen Anwendbarkeit, da sechs dichotom skalierte Kriterien bewertet werden müssen. Gleichzeitig geht die einfache Handhabung zulasten einer differenzierten Beurteilung der Studienqualität. Die methodische Qualität der Studien hatte keinen Einfluss auf ihren Einschluss in die Übersichtsarbeit und wurde ausschließlich zur Kontextualisierung und der Interpretation der Ergebnisse berücksichtigt. Insgesamt wurde das in Kapitel 1.2 definierte Ziel durch das systematische Review erreicht. Die gewählte Methode ermöglichte eine zusammenfassende Übersicht über die aktuelle Evidenz zu fördernden und hemmenden Determinanten der Implementierung KI-basierter EUS im Kontext von Antibiotikatherapien im Krankenhaus. Trotz der genannten Limitationen kann die Durchführung des Reviews als erfolgreich bewertet werden.

Die Interviews in *Studie II* gewährten vertiefende Perspektiven auf die Implementierung KI-basierter EUS zur Antibiotikatherapie im Krankenhaus. Aufgrund der Stichprobengröße ($n = 14$) und der gezielten Fallauswahl ist die Repräsentativität jedoch eingeschränkt. Die Fallauswahl erfolgte bis zur theoretischen Sättigung nach dem „theoretical sampling“ von Strauss & Corbin [182], wobei auf möglichst kontrastierende soziodemografische Merkmale der Teilnehmenden geachtet wurde. Die demografische Struktur der ärztlichen Grundgesamtheit in Deutschland ist durch eine starke Repräsentanz des mittleren Alters gekennzeichnet: Fast die Hälfte der berufstätigen Ärzte ist zwischen 35 und 54 Jahre alt, während lediglich rund ein Fünftel jünger als 35 Jahre ist und etwa ein Drittel zur Altersgruppe 55 plus gehört [183]. Zudem ist die Geschlechterverteilung in der Ärzteschaft annähernd ausgeglichen, wobei ein leichter Männeranteil vorherrscht [184]. Vor diesem Hintergrund kann die vorliegende Stichprobe teilnehmender Ärzten mit einem Großteil im Alter zwischen 30 und 50 Jahren und überwiegend männlichem Geschlecht als in etwa repräsentativ für die Grundgesamtheit dieser Zielgruppe angesehen werden. Einblicke in die Perspektiven von Personen, die KI-basierte EUS zur Antibiotikatherapie strikt ablehnen, konnten kaum gewonnen werden, da etwa 65 % der Befragten eine mittlere Technikaffinität aufwiesen. Im Hinblick auf das Sampling ist zudem zu berücksichtigen, dass die Ergebnisse potenziell eine gewisse Einseitigkeit aufweisen, da u. a. die befragten Personen aus einem Bundesland bzw. aus drei Kliniken eines Standortes stammten. Für zukünftige Studien wäre es sinnvoll, das Kontrastieren zwischen Befragten zu erweitern – etwa durch die

Einbeziehung von Ärzten aus weiteren Kliniken und Bundesländern. Ebenso könnte eine systematische Vorauswahl der Teilnehmenden erfolgen, bspw. basierend auf deren Vorerfahrung mit KI-basierten EUS oder der beruflichen Erfahrung. Zudem ist zu berücksichtigen, dass die Ergebnisse einer möglichen Selbstselektion unterliegen, da sich die teilnehmenden Ärzte möglicherweise von jenen unterscheiden, die eine Teilnahme abgelehnt haben. Zusammenfassend stellen die Ergebnisse eine Bestandsaufnahme des aktuellen Stellenwerts sowie der förderlichen und hemmenden Determinanten für die Implementierung im beruflichen Kontext der befragten Personen dar. Die Befunde der problemzentrierten Einzelinterviews bieten mit den o. g. Einschränkungen wertvolle Anhaltspunkte für eine zielgerichtete Implementierung KI-basierter EUS für die Antibiotikatherapie im Krankenhaus.

Eine Stärke der Online-Erhebung in *Studie III* liegt in ihrer Einbindung in ein Mixed-Methods-Design, da die entwickelten Items auf den Ergebnissen der vorherigen methodischen Schritten basieren. Durch die Online-Erhebung konnte das Verständnis der Implementierung KI-basierter EUS erweitert werden, indem der Forschungsgegenstand aus einer neuen Perspektive beleuchtet wurde. Bislang wurde in Deutschland die Ebene der Krankenhausdirektorien in Bezug auf Determinanten der Implementierung KI-basierter EUS zur Antibiotikatherapie nicht untersucht, während international lediglich vereinzelte vergleichbare Studien hierzu vorliegen [185, 186]. *Studie III* adressiert zentrale Themen der Forschung zu KI-basierten EUS, die sowohl aus dem bestehenden Wissensfundus [186] als auch aus den vorangegangenen Teilstudien abgeleitet wurden. Eine wesentliche Einschränkung der Erhebung ist die geringe Stichprobengröße. Trotz intensiver Rekrutierungsbemühungen wurde eine Stichprobe von 118 Personen erreicht, was einer Rücklaufquote von etwa 13 % entspricht. Eine a priori Power-Berechnung wurde nicht durchgeführt, da aufgrund der unzureichenden Evidenzgrundlage keine Annahmen zu Effektgrößen getroffen werden konnten. Somit sind die Ergebnisse dieser Studie nur eingeschränkt verallgemeinerbar. Zudem ist in der Stichprobe, wie auch in der Grundgesamtheit der ärztlichen Krankenhausdirektoren, eine Überrepräsentation von Männern festzustellen. Der Männeranteil in der Position des ärztlichen Direktors liegt bei etwa 85 % [187]. Weiterhin gaben lediglich 5 % der Befragten an, dass in den Krankenhaus, in dem sie tätig sind, ein KI-basiertes EUS im Versorgungsalltag bereits im Einsatz ist. Daher können die Einschätzungen möglicher Determinanten je nach Vorhandensein eines EUS variieren, was bei der Interpretation der Ergebnisse berücksichtigt werden sollte. Obwohl die Validität des Fragebogens nicht statistisch überprüft wurde, wurden kognitive Pretests durchgeführt, um die Verständlichkeit der Items und Antwortmöglichkeiten zu bewerten. Verzerrungen durch das Phänomen der sozialen Erwünschtheit [188] sind zwar weniger wahrscheinlich, aber nicht auszuschließen. Trotz der zugesicherten Anonymität könnte eine Tendenz zu sozial erwünschten Antwortoptionen bestehen. Unter Berücksichtigung der Stichprobengröße und -zusammensetzung sollten die Ergebnisse daher nicht als repräsentativ betrachtet werden. Sie spiegeln vielmehr Trends in

den Einstellungsmustern von überwiegend männlichen ärztlichen Direktoren im Alter von 51 bis 60 Jahren wider, die eine Berufserfahrung von 11 bis 20 Jahren aufweisen.

Im Rahmen von *Studie IV* wurde systematisch ermittelt, welche Anforderungen bei der Implementierung KI-basierter EUS im Krankenhaus aus Sicht von Experten im Bereich der Antibiotikatherapie und/oder KI-basierter EUS berücksichtigt werden sollten. Auch wenn die Delphi-Methode in der wissenschaftlichen Gemeinschaft anerkannt ist, unterliegt die Umsetzung den Limitationen qualitativer Methoden. Die Ergebnisse spiegeln trotz des Anspruchs an Konsentierung subjektive Einschätzungen wider. Zudem bleibt eine gewisse Unsicherheit bezüglich der aktuellen und zukünftigen Entwicklungen. Die Bewertung der Determinanten basiert auf den Erwartungen der Stichprobe und ist daher nicht repräsentativ [189]. Die Schwierigkeit, forschungs- und anwendungsbezogene Experten im Bereich KI-basierter EUS in der gesundheitlichen Versorgung zu rekrutieren, deutet darauf hin, dass es in diesem Feld noch wenige Spezialisten gibt. Daher spiegeln die Umfrageergebnisse v. a. die Einschätzung von ABS-Mitgliedern in Krankenhäusern wider, die mit etwa 78 % überrepräsentiert sind. Ein ausgewogeneres Panel, das die Vielfalt der Perspektiven besser abbildet, wäre wünschenswert. Die Rücklaufquoten von 15 % in der ersten und 47 % in der zweiten Runde legen nahe, dass das zweistufige Verfahren möglicherweise zu zeitintensiv und der Fragebogen zu umfangreich waren. Allerdings war die ausführliche Erhebung notwendig, um die vielfältigen Anforderungen an die Implementierung zu erschließen. Positiv hervorzuheben ist der hohe Kenntnisstand der Stichprobe zur Antibiotikatherapie im Krankenhaus. Eine Einschränkung stellt jedoch die eher begrenzte Expertise im Bereich KI-basierter EUS dar. Dennoch bieten die Ergebnisse aus kontextbezogener Sicht wertvolle Einblicke in die Implementierungsanforderungen.

Obwohl das HOT-fit-Modell, welches als theoretischer Rahmen für diese Arbeit diente, hilfreich war, um die Erkenntnisse zur Implementierung KI-basierter EUS im Krankenhaus zu systematisieren, war dessen Anwendung illustrativ – es hätten auch alternative Rahmenwerke verwendet werden können, um die Ergebnisse zu interpretieren. Die Anwendung war jedoch zielführend, da es mit seiner Dreiteilung die für die Implementierung relevanten Bereiche und die potenziellen Interdependenzen gut abbildet. Zusammenfassend konnten die identifizierten Determinanten den Domänen und Konstrukten des HOT-fit-Modells zugeordnet werden, was darauf hindeutet, dass es Überschneidungen zwischen den Determinanten der Implementierung von KI-Systemen und anderen digitalen Technologien gibt. Dabei ist jedoch zu beachten, dass die Definition der Domänen bzw. Konstrukten einen gewissen Interpretationsspielraum zulassen. Außerdem werden im Rahmen dieser Arbeit Schlussfolgerungen zum Einsatz KI-basierter EUS zur Antibiotikatherapie im Krankenhaus dadurch eingeschränkt, dass die Versorgungsakteure nicht explizit zur Implementierung eines bestimmten KI-basierten EUS befragt wurden, sondern die Fragen sich allgemein auf den entsprechenden Einsatz bezogen. Daher können

die Einschätzungen aufgrund von unterschiedlichen Arbeitsumgebungen sowie durch Erfahrungen mit verschiedenen KI-basierten EUS variieren. Darüber hinaus beschränkten sich die Stichproben in den empirischen Untersuchungen auf an der Versorgung beteiligte Akteure, was angesichts der zunehmenden Relevanz auf den unmittelbaren Versorgungsbezug gerechtfertigt erscheint. Der Fokus der Exploration lag dabei explizit auf der Identifikation implementierungsrelevanter Determinanten, wobei primär die Sichtweisen der direkt sowie indirekt involvierten klinischen Akteure – ärztliches Fachpersonal, Krankenhausdirektoren sowie Experten im Implementierungsprozess – berücksichtigt wurden. Diese Perspektiven wurden bewusst gewählt, um die Komplexität der klinischen Implementierung KI-basierter EUS gezielt analysieren zu können. Andere Stakeholder, wie die Industrie oder IT-Unternehmen, sowie die Perspektive der Patienten wurden in dieser Arbeit nicht einbezogen. Daher könnte der Dissertation mangelnde Patientenzentrierung vorgehalten werden. Dem lässt sich jedoch entgegen, dass die Optimierung der Antibiotikatherapie aus Sicht der Versorgungsakteure als im Interesse der Patienten liegend betrachtet werden kann. Die hier gewonnenen Erkenntnisse bieten zudem eine Grundlage, auf der Folgeforschung andere Stakeholder-Perspektiven oder patientenzentrierte Aspekte einbeziehen kann. Abschließend wurden im Rahmen dieser Arbeit Versorgungsakteure im deutschen Gesundheitssystem befragt, das spezifische Herausforderungen aufweist, wie z. B. eine geringe Digitalisierung im Gesundheitswesen [190], strenge Vorschriften zum Umgang mit Daten [191] und einen gravierenden Mangel an Ärzten [192]. Daher sollte die Übertragbarkeit der Ergebnisse auf andere Gesundheitssysteme kritisch betrachtet werden.

7. Implikationen

Das Setting Krankenhaus stellt mehrere besondere Herausforderungen an die Implementierung KI-basierter EUS im Kontext der Antibiotikatherapie im Krankenhaus (s. Kapitel 2, S. 6 ff.). Auf Grundlage der gewonnenen Erkenntnisse und der Beantwortung der Forschungsfragen werden nachfolgend weiterführende Perspektiven und Implikationen für zukünftige Forschung (Kapitel 7.1) sowie für die Praxis und Politik (Kapitel 7.2) aufgezeigt. Die im Rahmen dieser Arbeit identifizierten Determinanten (s. Tab. 2, S. 22 ff.) wurden den Implikationen subsumiert, wobei mögliche Abhängigkeiten sowie Wechselwirkungen der Ebenen zu berücksichtigen sind.

7.1 Implikationen für Forschung

Auf der Forschungsebene lassen sich vor dem Hintergrund der bisherigen Studien und der empirischen Erkenntnisse der vorliegenden Arbeit, Handlungsbedarfe v. a. für die theoretische

Fundierung der Implementationsforschung im Kontext von KI-Systemen und die stärkere Fokussierung des organisationalen Kontextes ableiten (s. Abb. 6).




Abb. 6: Zukünftige Forschungsbedarfe für die Implementierung von KI-basierten Entscheidungssystemen (Eigene Darstellung)

7.1.1 (Weiter-)Entwicklung evidenzbasierter Ansätze für die Implementierung von KI-Systemen

Anknüpfend an der Vorarbeit der vorliegenden Dissertation zu Determinanten einer erfolgreichen Implementierung KI-basierter EUS im Kontext der Antibiotikatherapie im Krankenhaus zeigt sich Forschungsbedarf in der **Entwicklung und Validierung eines praxisnahen Modells, dass auf die KI-Implementierung** im Gesundheitswesen prozesshaft abgestimmt ist. Obwohl es bereits eine Vielzahl von Rahmenwerken und Modellen zur Implementierung von Gesundheitstechnologien gibt, die u. a. von Greenhalgh et al. [193] oder Moullin et al. [194] systematisiert wurden, bleibt es schwierig, ein einziges, allumfassendes Modell zu finden, das alle relevanten Aspekte der Technologieimplementierung in Gesundheitsorganisationen abdeckt, wie auch Greenes et al. [195] betonten. Dies gilt insbesondere auch im Kontext von KI-Systemen. Zudem basieren vorliegende Arbeiten zur KI-Implementierung auf Modellen, die primär die individuelle Perspektive fokussieren, wie bspw. die Unified Theory of Acceptance and Use of Technology (UTAUT) [196–198] oder das Technology Acceptance Model (TAM) [199, 200]. Diese Modelle bieten zwar wertvolle Einsichten zur Nutzerakzeptanz,

berücksichtigen jedoch nicht die breiteren organisationalen und umgebungsbezogenen Faktoren, die die Implementierung von KI-Systemen im Gesundheitswesen determinieren können. Weitere Modelle wie die Diffusion of Innovation Theory (DOI) [201], das Nonadoption, Abandonment, Scale-up, Spread and Sustainability (NAASS)-Framework [202] oder auch das HOT-fit-Modell [32], das in dieser Arbeit verwendet wurde, ermöglichen einen ganzheitlicheren Ansatz, indem sie institutionelle und kontextuelle Elemente einbeziehen. Obwohl diese Modelle und Rahmenwerke wertvolle Hinweise für die Implementierung bieten, impliziert die spezifische Natur von KI neue Komplexitätsebenen und zusätzliche Herausforderungen [203]. Im Vergleich zu anderen Gesundheitstechnologien zeichnet sich KI durch ihr Potenzial aus, die Arbeit von medizinischem Personal zu ergänzen oder einzuschränken. Auch die im Rahmen dieser Arbeit identifizierten Determinanten, wie menschliche Aufsicht und Entscheidungsautonomie, sind für KI relevanter oder potenziell problematischer als andere digitale Gesundheitstechnologien. Diese Unterschiede lenken den Fokus hin zum Verständnis der Interaktion zwischen medizinischem Personal und KI, um einen Mehrwert für die Nutzer zu schaffen. In diesem Sinne befindet sich KI am komplexeren Ende dessen, was bislang von der Implementierungsforschung untersucht wurde, die in der Regel klar definierte und begrenzte Interventionen umfasst.

Fernando et al. identifizierten in einem Scoping Review diejenigen Publikationen, die Rahmenwerke, Modelle und Theorien zur Implementierung von EUS im Krankenhaus und in verschiedenen Versorgungskontexten einsetzten [204]. Die Übersichtsarbeit zeigte, dass die einbezogenen Studien v. a. auf Theorien und Modellen der Implementierungsforschung sowie auf den Bereich der Qualitätsverbesserung rekurrieren, wobei Prozessmodelle, wie der Plan-Do-Study-Act-Zyklus am häufigsten zum Einsatz kamen [204]. Diese Modelle unterteilen den Implementierungsprozess in kleinere Schritte, was sie besonders in komplexen Umgebungen wie Krankenhäusern nützlich macht. Allerdings ermöglichen sie weder eine detaillierte Analyse der kausalen Mechanismen der Implementierung KI-basierter EUS noch eine systematische Untersuchung relevanter Determinanten [205]. Die Übersicht lässt vermuten, dass es zwar erste Bemühungen zur theoretischen Fundierung der Implementierung KI-basierter EUS gibt, diese jedoch unzureichend mit bestehenden Erkenntnissen der Implementierungsforschung verknüpft werden, um praxisrelevante Fragen zur realen Nutzung zu beantworten. Ferner fehlen konsolidierte und standardisierte Berichte, die Implementierungsansätze für KI-basierte EUS detailliert beschreiben. Eine solche Berichterstattung könnte von einer breiteren Anwendung bestehender Leitlinien, wie den „Standards for Reporting Implementation Studies“ profitieren [206]. Eine weitere relevante Fragestellung ist, ob eine spezifische „Implementierungswissenschaft“ für KI-basierte Systeme entwickelt werden kann, etwa durch die Charakterisierung von Merkmalen erfolgreicher (oder gescheiterter) Implementierung. Zukünftig sollte daher eine KI-spezifische Evidenzbasis zur Implementierung aufgebaut und das Wissen in

entsprechende Modelle und Rahmenwerke überführt werden, um auch den Wert von KI-basierten EUS in der Praxis realisieren zu können.

7.1.2 Einbezug weiterer Zielgruppen in die Forschung und Durchführung longitudinaler Studien

Die vorliegende Arbeit trägt zur Evidenz im Bereich KI-basierter EUS im Kontext der Antibiotikatherapie bei, indem sie die Perspektive der an der Versorgung beteiligten Akteuren einbezieht, die im deutschen Versorgungskontext bislang nur rudimentär berücksichtigt wurde [207–209]. Damit reagierte diese Arbeit auf die Forderung von Laka et al. nach Forschung zur effektiven Integration KI-basierter EUS in Gesundheitsorganisationen unter Berücksichtigung der Nutzerperspektive [210], was auch das Hauptanliegen dieser Dissertation darstellt. Eine Erkenntnis dieser Arbeit ist, dass die Heterogenität des ärztlichen Personals sowie die komplexen Interaktionen im Krankenhausumfeld ein umfassendes Verständnis erfordern, um die spezifischen Anforderungen an die Implementierung adäquat zu adressieren. Zukünftige Forschung sollte daher auch Unterschiede in den Beziehungen zwischen medizinischem Personal in verschiedenen Bereichen oder Funktionen untersuchen, um die Bedingungen besser zu verstehen, die die Wechselwirkungen zwischen verschiedenen Determinanten beeinflussen können. Darüber hinaus sollten zukünftige Bemühungen verstärkt auch weitere relevante Zielgruppen einbeziehen, wie z. B. Pflegepersonal, Patienten, Medizinproduktehersteller, IT-Personal im Krankenhaus, Ethik- und Rechtsexperten, um gruppenspezifische Bedarfe und Bedürfnisse hinsichtlich einer erfolgreichen Implementierung ableiten zu können.

Die in dieser Arbeit untersuchten Determinanten zeigen, dass die Implementierung KI-basierter EUS nicht durch isolierte Einzelaspekte bestimmt wird, sondern vielmehr dynamische und multidirektionale Interaktionen zwischen den nutzerbezogenen Determinanten, den technologischen Eigenschaften und dem jeweiligen Kontext vorliegen. Dies ist besonders relevant, da individuelle, soziale und umweltbezogene Einflusssebenen berücksichtigt werden und somit eine ganzheitliche Perspektive auf die Implementierung eingenommen wird. Im Hinblick auf die Wechselwirkungen und Stärke der Determinanten besteht in vergleichbaren Arbeiten noch Unschärfe [201] und in Bezug auf den deutschen Versorgungskontext weiterer Forschungsbedarf.

Zusätzlich stützt sich bisherige Forschung zur Implementierung KI-basierter EUS in erster Linie auf Querschnittsstudien [196, 211, 212], die jedoch die Analyse kausaler Zusammenhänge einschränken. Daher ist es notwendig, zukünftige Studien im Längsschnittdesign durchzuführen, um robustere Belege für Kausalitäten zu erhalten. Längsschnittstudien können außerdem dazu beitragen, die Entwicklung der Nutzungsabsicht und die Bedeutung relevanter Determinanten im Zeitverlauf zu analysieren. So könnte bspw. anfängliches Vertrauen in KI-Systeme

in der frühen Implementierungsphase eine große Rolle spielen, während es an Bedeutung verliert, wenn diese erfolgreich etabliert wurden. Zudem sollten die vorliegenden Erkenntnisse in weiteren quantitativen Studien vertieft untersucht sowie spezifische Ansätze für die Entwicklung konkreter Implementierungsstrategien detaillierter erforscht werden. Ein weiterer Forschungsbedarf besteht in umfassenden Kosten-Nutzen-Analysen, die die langfristige Machbarkeit der Implementierung KI-basierter EUS im Krankenhaus bewerten [213]. Dazu gehören die Analyse der finanziellen Nachhaltigkeit sowie der potenziellen Auswirkungen auf die Behandlungsergebnisse und Effizienz in der gesundheitlichen Versorgung.

7.1.3 Forschung im Kontext tradierter Berufspraktiken und Routinen

Auf einer abstrakteren Ebene leistet diese Dissertation einen Beitrag zum tieferen Verständnis der Implementierung KI-basierter EUS in Krankenhäusern. Sie zeigt auf, welche spezifischen Kontextbedingungen die Implementierung beeinflussen und welche prozessualen sowie situativen Faktoren für eine erfolgreiche Implementierung entscheidend sein können. Ein zentrales Ergebnis dieser Arbeit ist, dass die Interaktion mit KI-basierten EUS das Rollenverständnis von Ärzten als potenzielle Nutzer verändern bzw. weiterentwickeln kann, wodurch eine Neubewertung der beruflichen Identität erforderlich wird. Während die vorliegende Evidenzbasis vereinzelt auf einen möglichen Einfluss der beruflichen Identität auf die Einführung KI-basierter Systeme hinweist [214], besteht weiterhin Forschungsbedarf, insbesondere im Hinblick auf das Zusammenspiel zwischen beruflicher Identität und der Einstellung gegenüber der Implementierung KI-basierter EUS. Die Ergebnisse dieser Arbeit zeigen auch, dass die Fähigkeit einer Person, sich an Herausforderungen oder Veränderungen anzupassen, respektive die individuelle Resilienz, sowie die Rolle von Verhaltensnormen und Erwartungen innerhalb eines Krankenhauses für die Implementierung KI-basierter EUS wesentlich sind und bislang unzureichend berücksichtigt wurden [215]. Darüber hinaus haben organisationale Resilienzfaktoren, wie bspw. die Veränderungsbereitschaft, die Führungs- und Organisationskultur im Kontext der Implementierung KI-basierter EUS bisher ungenügend Beachtung gefunden. Ein zukünftiger Forschungsbereich besteht daher darin, zu analysieren, inwiefern Resilienzfaktoren den Implementierungsprozess KI-basierter EUS beeinflussen können.

Die Ergebnisse dieser Arbeit legen nahe, dass ein vertieftes Verständnis der Faktoren, welche die Entstehung routinierter Handlungen im Krankenhauskontext beeinflussen, zur Entwicklung neuer Implementierungsansätze beitragen könnte. In diesem Zusammenhang erscheint es zentral zu untersuchen, ob Handlungen vermehrt zu Routinen werden, wenn sie in einem Kontext stattfinden, der durch klare Normen und Vorschriften geprägt ist. Umgekehrt sollte analysiert werden, inwiefern sich der Kontext gezielt so gestalten lässt, dass die Reproduktion hinderlicher Routinen vermieden wird – bspw. durch Anpassungen bestehender Normen und

Vorschriften. Empirische Befunde deuten darauf hin, dass die Wahrscheinlichkeit, Routinen im Gesundheitssystem zu etablieren oder zu verändern, in einem Umfeld psychologischer Sicherheit zunimmt [216–219]. Dies impliziert, dass Organisationsmitglieder bei Vorliegen von psychologischer Sicherheit eine positivere Grundhaltung einnehmen und eher bereit sind, neue Handlungsmöglichkeiten zu explorieren, da sie keine negativen Konsequenzen befürchten. Übertragen auf das vorliegende Forschungsinteresse erscheint es daher aussichtsreich, künftig zu analysieren, ob und inwieweit potenzielle Nutzer der Implementierung KI-basierter EUS offener gegenüberstehen, wenn dieser Prozess in einem Kontext erfolgt, der durch konsistente Normen und Vorschriften geprägt ist und welchen Einfluss die psychologische Sicherheit darauf ausübt. Darüber hinaus stellt sich die Frage, ob individuelle Handlungen eher umgesetzt werden, wenn sie durch einen gemeinsam entwickelten Aktionsplan sowie einen kollektiven Reflexionsprozess begleitet werden, in dessen Rahmen neue Routinen unter Berücksichtigung der Rollen und Verantwortlichkeiten aller Beteiligten definiert und weiterentwickelt werden.

Nicht zuletzt ist für den Implementierungserfolg KI-basierter EUS belastbare Evidenz über deren klinischen Nutzen entscheidend. Eine rein statistische Validierung KI-basierter EUS reicht nicht aus; der Mehrwert muss in realen Anwendungskontexten nachgewiesen werden, etwa durch pragmatische und ökologische Validierungen in klinischen Umgebungen [149]. Um Vertrauen zu schaffen und den nachhaltigen Einsatz zu sichern, sind umfassende Studien und Bewertungen des Nutzen in klinischer, betrieblicher und finanzieller Hinsicht erforderlich, um zu evaluieren, ob KI-basierte EUS wie vorgesehen funktionieren und (kurzfristige) Auswirkungen auf messbare Ergebnisse hinsichtlich ihres klinischen Werts, ihrer betrieblichen Effizienz und Kosten erfassen.

7.2 Implikationen für Praxis und Politik

Neben forschungsrelevanten Implikationen lassen sich aufbauend auf der Einordnung der eigenen Ergebnisse und Reflexion des aktuellen Forschungsstands sowie angelehnt an die Dreiteilung des HOT-fit-Modells zentrale Implikationen auf Ebene der Praxis und Politik für die Implementierung KI-basierter EUS im Krankenhaus ableiten (s. Abb. 7).




Abb. 7: Zentrale Implikationen für die erfolgreiche Implementierung von KI-basierten Entscheidungsunterstützungssystemen (Eigene Darstellung)

Bei Betrachtung der Implikationen aus der Perspektive praxis- und politik-gestaltender Akteure steht die Frage im Mittelpunkt, inwieweit KI-basierte EUS zu einem festen, regulierten, akzeptierten und strukturell verankerten Bestandteil von Krankenhäuser werden können. Gleichzeitig muss die Frage relativiert werden, denn Implementierungsprozesse sind im höchsten Maße geprägt durch spezifische Kontexteigenschaften.

7.2.1 Nutzerorientierte und kontextsensitive Technologiegestaltung

Eine Vielzahl von Forschungsergebnissen [146, 220, 221] zeigen in Einklang mit den Befunden dieser Arbeit, dass KI-basierte EUS und deren Eigenschaften für eine erfolgreiche Implementierung an die individuellen Bedürfnisse der Nutzer und dem eingebetteten Kontext angepasst werden sollten. Die Verfügbarkeit von strukturierten, maschinell lesbaren, interoperablen Daten und gut kuratierten Datensätzen sind entscheidend für die Entwicklung KI-basierter EUS, die präzise, vorausschauend sowie patientenorientiert und somit für die reale Anwendung geeignet sind. Die Grundlage für eine einheitlichere Datensammlung als Basis für die KI-Nutzung wird im Rahmen aktueller Gesetze weiter ausgebaut, wie z. B. dem

Gesundheitsdatennutzungsgesetz (GDNG)¹². Zudem muss beachtet werden, dass KI-basierte EUS für die Antibiotikatherapie in klinischen Arbeitsabläufen eingesetzt werden, in denen Echtzeitdaten wie bspw. Vitalparameter aus Patientenüberwachungsgeräten eine zentrale Rolle für die Vorhersagegenauigkeit der KI-Modelle spielen. Ärztliche Entscheidungen werden regelmäßig auf Grundlage der während der Behandlung erhobenen klinischen Daten angepasst. Vor diesem Hintergrund ist es entscheidend, dass KI-Modelle so konzipiert werden, dass sie Daten aus verschiedenen Modalitäten in Echtzeit integrieren und den Behandlungsverlauf abbilden, um fundierte Empfehlungen zu generieren. Gleichzeitig stellen Aspekte wie Datenverfügbarkeit, -zugänglichkeit, -umfang und -qualität implementierungsrelevante Herausforderungen dar, die durch eine umfassende Datenverwaltung und durch systematisches Datenmanagement, bspw. mittels Einführung einheitlicher Standards und Formate adressiert werden sollten. Selbst wenn rechtliche und organisatorische Hürden beim Zugang zu und der Nutzung von Gesundheitsdaten überwunden werden können, bleiben die dezentrale Speicherung sowie die Integration heterogener Datenquellen weiterhin problematisch. Unterschiedliche Datenformate und mangelnde Interoperabilität erschweren die Implementierung KI-basierter EUS, wie auch in dieser Arbeit dargestellt wurde. Darüber hinaus stellt die Integration KI-basierter EUS in bestehende Infrastrukturen, die nicht für KI-Anwendungen konzipiert wurden, eine erhebliche Herausforderung dar. Moderne Datenplattformen, wie die Artificial Intelligence Modern Data Platform (AIMDP), bieten hingegen Potenzial für die Verarbeitung und Analyse komplexer, aus unterschiedlichen Quellen stammenden Daten. Innerhalb eines Krankenhauses kann die Plattform bspw. aus unterschiedlichen Abteilungen, etwa Laborergebnisse und Patientenüberwachungsdaten, integrieren, wodurch sich die Behandlungsplanung optimieren lässt [223].

Parallel zur Entwicklung einer funktionierenden Pipeline von KI-basierten EUS ist für die erfolgreiche Implementierung eine echtzeitfähige IT-Infrastruktur im Krankenhaus, einschließlich der Hard- und Softwareeigenschaften erforderlich. Ein gut ausgestattetes Unterstützungssystem (wie z. B. die technische Ausstattung) und funktionierende Unterstützungsprozesse (wie z. B. Technikmanagement) sind entscheidend für eine zielgerichtete Implementierung. In Bezug auf die Softwareanforderung sollte sichergestellt werden, dass sie sowohl auf Desktop- als auch Mobilgeräten im unmittelbaren Behandlungskontext genutzt werden kann. Der Übergang zwischen verschiedenen Modalitäten sollte nahtlos erfolgen, so dass stets dieselben Informationen bereitgestellt werden. Neben der Verfügbarkeit am Behandlungsort ist der Wissenstransfer in Richtung der Nutzer entscheidend. Dies erfordert eine uneingeschränkte und verständliche Interaktion mit dem EUS, um die intrinsische Einstellung der Nutzer gegenüber dem System zu fördern. Eine nutzerfreundliche und intuitive Gestaltung der

¹² Das GDNG fördert die gemeindienliche Nutzung von Gesundheitsdaten, indem es kurzfristig die Grundlage für eine bessere Verfügbarkeit von Gesundheitsdaten für Forschung, Qualitätssicherung und Entwicklung schafft und den Weg für den Europäischen Gesundheitsdatenraum bereitet [222].

Benutzeroberfläche kann die Systeminteraktion vereinfachen und sicherstellen, dass Entscheidungsempfehlungen effizient und zielgerichtet interpretiert werden können, auch ohne umfassende technische Kenntnisse. Bei der Gestaltung der einzelnen Systemkomponenten sollte fokussiert werden, den kognitiven Aufwand für die Nutzer zu reduzieren. Da diese unterschiedliche Präferenzen haben können, sollte die Entwicklung KI-basierter EUS im Sinne von Co-Creation gemeinsam mit den Nutzern erfolgen, um ihre Bedarfe und Bedürfnisse sowie den spezifischen Kontext zu berücksichtigen. Hierdurch wird ein Gefühl von Mitverantwortung und kontinuierlicher Weiterentwicklung gefördert, die eine Kontextualisierung und schnelle Anpassung an Veränderungen ermöglichen. Hierfür sollten etablierte Designrichtlinien und Best-Practice-Beispiele aus unterschiedlichen Anwendungsbereichen herangezogen werden.

Neben infrastrukturellen Herausforderung ist davon auszugehen, dass der Einsatz KI-basierter EUS im Gesundheitsbereich insbesondere für Personen, die für finale Entscheidungen verantwortlich und rechtlich haftbar sind, angesichts einer Black-Box-Problematik mit erheblichen Vertrauenshürden verbunden ist. An der Stelle können Systemtransparenz und Erklärbarkeit als zentrale Instrumente der Kommunikation zwischen Entwicklern von KI-Systemen und den Nutzern ohne technisches Fachwissen dienen. Diese fördern ein gemeinsames Verständnis der Entscheidungsprozesse, ermöglichen eine realistische Erwartungshaltung der Nutzer hinsichtlich Anwendungsbereiche und Kontrollmöglichkeiten und tragen so zum Abbau von Vorbehalten gegenüber KI-basierten EUS bei. Gegenwärtig fehlt es an einer einheitlichen Definition relevanter Ebenen der Erklärbarkeit sowie an etablierten Standards zur Auswahl und Bewertung entsprechender Methoden zur Erklärbarkeit [224]. Grundsätzlich ist anzunehmen, dass die Verfügbarkeit lokaler und globaler Erklärungen¹³ rationaleres Entscheidungsverhalten begünstigt, da die Nutzer Entscheidungen auf einer fundierteren Informationsbasis treffen können, anstatt sich ausschließlich auf die „Black-Box-Entscheidung“ zu verlassen. Dies kann im psychologischen Sinne zur Reduktion von Unsicherheit beitragen. Gleichzeitig besteht die Gefahr, dass eine detaillierte Offenlegung von Trainings- und Entscheidungsprozessen zu kognitiver Überforderung und damit zu gegenteiligen Effekten führt [226]. Für eine vertrauensförderliche Interaktion und zugleich erfolgreiche Implementierung ist daher entscheidend, einen angemessenen Abstraktionsgrad zu wählen, auf dem die Ergebnisse entsprechend den Bedarfen und Bedürfnissen der Nutzer kommuniziert werden.

¹³ Vorhandene Ansätze zur Erklärbarkeit lassen sich anhand ihrer Schwerpunktsetzung grob in globale (d. h. Einsicht in die innere Funktionsweise eines Systems und des Trainingsprozesses) und lokale (d. h. Erklärung zu einzelnen Empfehlung, wie bspw. durch Visualisierung des Entscheidungsprozess, Darlegung der Eingabedaten etc.) Erklärungen unterscheiden [225]

7.2.2 *Institutionalisierung KI-basierter Entscheidungsunterstützungssystemen*

Die Implementierung KI-basierter EUS erfordert solide organisatorische Prozesse, die das Resultat gezielter Führungsstrategien und Governance sind. Ohne eine einheitliche institutionelle Vision gelingt es Krankenhäusern häufig nicht, KI-Initiativen mit klinischen und betrieblichen Zielen zu verknüpfen. Dies kann dazu führen, dass KI-basierte EUS nur fragmentiert und ohne systemweite Integration eingesetzt werden. Folglich ist v. a. in der Planungsphase eine klar formulierte Top-Down-Strategie erforderlich, die von der institutionellen Leitung getragen wird und sowohl strategische Organisationsziele, Ressourcenallokation sowie Maßnahmen für die Implementierung, zum Monitoring und zur Evaluation umfasst.

Klinische Führungskräfte nehmen hierbei eine Schlüsselrolle ein, da sie zwischen technologischer Entwicklung und klinischer Praxis vermitteln. Zur strategischen Steuerung der Implementierung sind multidisziplinäre Kompetenzen auf Führungsebene erforderlich, um angemessene Prioritäten zu setzen und fundierte Entscheidungen zu treffen. Führungskräfte sollten daher grundlegende Kenntnisse über die Funktionsweise KI-basierter EUS sowie über deren Chancen und Risiken für den klinischen Kontext besitzen. Die Einrichtung eines funktionsübergreifenden „*KI-Implementierungsteams*“ mit Vertretern unterschiedlicher Organisationseinheiten und Hierarchieebenen ermöglicht den Aufbau institutioneller Governance-Strukturen zur Koordination der Implementierung. In Zusammenarbeit mit der institutionellen Leitung und den Technikentwicklern kann dieses Team neue Arbeitsabläufe, erforderliche Infrastrukturen sowie klare Rollen und Verantwortlichkeiten definieren. Dies könnte durch die Erstellung von Plänen auf individueller Ebene und Teamebene im Sinne eines „*Implementation Mappings*“¹⁴ erreicht werden. Neben formeller Unterstützung scheint der Einsatz von Innovatoren, wie bspw. klinische Champions¹⁵ aussichtsreich. Eine Erweiterung dessen zu sogenannten „*KI-Champions*“ kann dazu beitragen, eine aufgeschlossener und innovationsfreundliche Organisationskultur zu etablieren und zugleich eine Feedback-Pipeline für künftige Implementierungsprozesse zu schaffen. Die in dieser Arbeit beschriebene Offenheit und positive Grundeinstellung jüngerer Ärzte qualifiziert sie als potenzielle KI-Champions und Multiplikatoren.

¹⁴ Mithilfe eines Implementation Mappings lässt sich planen, wie eine Intervention in der Realität umgesetzt, angewendet und nachhaltig verankert werden kann. Dies wird in einem schrittweise Prozess, bestehend aus einer Bedarfs-/Kontextanalyse, der Festlegung von Zielen und Strategien der Implementierung, Erstellung eines Implementierungsplans und dessen Evaluation erreicht [227].

¹⁵ Klinische Champions („clinical champions“) sind technisch versierte Mitglieder einer Organisation, die das Vertrauen ihrer Kollegen genießen, die die technischen und arbeitsorganisatorischen Herausforderungen ihrer Kollegen verstehen und die über starke zwischenmenschliche Fähigkeiten verfügen, die es ihnen ermöglichen, mit Konflikten, Skepsis oder Frustration umzugehen [228].

Insgesamt ist es wichtig, innerhalb der Organisation ein agiles¹⁶ und kooperatives Umfeld sowie eine Lern- und Unterstützungsgemeinschaft zu etablieren, in der die Implementierung KI-basierter EUS kontinuierlich reflektiert und iterativ optimiert wird. Ein zentraler Erfolgsfaktor besteht darin, Organisationsmitglieder durch fortlaufende Weiterbildungs- und Schulungsmaßnahmen gezielt auf die mit der Implementierung verbundenen Veränderungen vorzubereiten. Insbesondere auf Ärzte als potenzielle Nutzer zugeschnittene Informations- und Schulungsangebote sind notwendig, um das Bewusstsein des bereits ausgebildeten Personals für AMR zu schärfen, die nachhaltige Nutzung KI-basierter EUS zu fördern und die erforderlichen Kompetenzen zu vermitteln. Die Kompetenzen sollten sowohl den Umgang mit KI-basierten EUS als auch das Verständnis der generierten Empfehlungen im Kontext der Antibiotikatherapie unterstützen. Schulungen können sowohl im Rahmen individueller Qualifizierungsmaßnahmen, etwa bei der Einarbeitung neuer Mitarbeiter, als auch als Gruppenschulungen erfolgen, die die Diskussion bewährter Vorgehensweisen und einen Erfahrungsaustausch ermöglichen. Der Fokus sollte dabei nicht ausschließlich auf der kognitiven Wissensvermittlung liegen, sondern ebenso auf dem Abbau von Berührungängsten sowie der Schaffung von Erfahrungs- und Lernräumen. Die frühzeitige Partizipation der Nutzer in die Entwicklungsphase – wie im vorherigen Abschnitt zur nutzerorientierten und kontextsensitiven Technikentwicklung beschrieben – kann dazu beitragen, diese als Multiplikatoren für Schulungsaktivitäten zu gewinnen. Personen, die als Multiplikatoren fungieren, sollten nicht nur in der Handhabung der Hard- und Software geschult sein, sondern auch befähigt werden, den mit der Implementierung verbundenen organisatorischen Wandel an die Teams und die Nutzer zu vermitteln und so mögliche Vorbehalte zu adressieren. Da Weiterbildungs- und Schulungsaktivitäten häufig zeitlich begrenzt sind, kann der Aufbau eines organisationsinternen Unterstützungssystems diese sinnvoll ergänzen. Dazu zählen z. B. niedrigschwellige Anlaufstellen für (Rück-)Fragen an Mitglieder des KI-Implementierungsteams, regelmäßige Informationsveranstaltungen zur Diskussion von Stärken und Limitationen der Systemimplementierung sowie interne Kommunikationsformate, wie die Einrichtung von Social-Media-Kanälen, Intranet-Beiträgen oder Newsletter. Perspektivisch sollte der Einsatz KI-basierter EUS zudem auf weitere Berufsgruppen ausgeweitet werden, die im Behandlungskontext eine Rolle spielen – darunter die Pflege, Krankenhausapotheke und das Labor, um die neue Versorgungspraxis organisationsweit zu verankern.

Der Einsatz KI-basierter EUS ist schließlich mit erheblichen finanziellen, rechtlichen, regulatorischen und ethischen Herausforderungen verbunden. Insbesondere begrenzte Budgets in öffentlichen Krankenhäusern erschweren die Rechtfertigung der erforderlichen Investitionen,

¹⁶ Agile Managementstrategien fokussieren Flexibilität, aktive Entwicklung und Teamarbeit, die es Organisationen ermöglichen, sich an neue organisatorische Anforderungen anzupassen, anstatt sich auf die Prozesse zu verlassen, deren Zeitrahmen und Umfang starr festgelegt sind [229].

zumal klare Finanzierungs- und Erstattungsmechanismen häufig fehlen. Modelle wie Fundraising, öffentliche Partnerschaften oder Kooperationen mit Forschungseinrichtungen könnten zur finanziellen Nachhaltigkeit beitragen, sind jedoch bislang unzureichend untersucht. Die damit verbundenen Kosten schränken derzeit das Potenzial einer flächendeckenden Implementierung ein und bedürfen weiterer gesundheitspolitischer Diskussion. Zudem bestehen erhebliche rechtliche Unsicherheiten, insbesondere hinsichtlich der Haftung ärztlichen Personals bei der Nutzung KI-basierter EUS. Die gegenwärtigen regulativen Vorgaben der KI-VO fokussieren primär Sicherheits- und Qualitätsanforderungen des KI-Systems und verorten Rechenschaftspflichten hauptsächlich bei Anbietern und Vertreibern. Die Rolle weiterer Akteure, etwa Krankenhäuser respektive institutionelle Leitungen oder Ärzte als Nutzer sowie die Haftungsverteilung bei arbeitsteiligen Entwicklungs- und Implementierungsprozessen bleiben weitgehend ungeklärt. Zwar stellt die KI-VO einen wichtigen regulatorischen Rahmen für den Einsatz von KI dar, sein horizontaler Charakter erfordert jedoch eine stärkere sektorale Auslegung für den Gesundheitsbereich sowie zusätzliche Maßnahmen zur praktischen Umsetzung. Vor dem Hintergrund der zunehmenden Verbreitung von KI-Systemen ist daher eine interdisziplinäre Zusammenarbeit von Rechtsexperten, Entwicklern und Nutzern notwendig, um die Nuancen potenzieller Haftungsfragen zu definieren sowie rechtliche, ethische und soziale Implikationen angemessen zu adressieren.

7.2.3 Förderung der Interaktionsbeziehung zwischen Nutzern und KI-basierten Entscheidungsunterstützungssystemen

Neben der Etablierung einer offenen Lern- und Unterstützungskultur sind gezielte Maßnahmen zur Förderung von Kompetenzen im Umgang mit KI-basierten EUS erforderlich. Fähigkeitsbarrieren variieren je nach kognitiver Leistung und unterschiedlicher Kompetenzniveaus der potenziellen Nutzer. Maßnahmen zur Kompetenzförderung sollten daher an die Berufserfahrung angepasst werden: bspw. können Ärzte in den ersten Berufsjahren und geringen digitalen Kompetenzen eher von simulierten Umgebungen profitieren, während erfahrenere Personen durch konkrete Fall- und Anwendungsbeispiele ihr Wissen und ihre Fähigkeiten praktisch anwenden und vertiefen können. Langfristig ist es im bildungspolitischen Kontext erforderlich, die KI-Thematik in bestehende Aus- und Weiterbildungscurricula des Gesundheitsbereichs aufzunehmen, auch wenn die fehlende Standardisierung der erforderlichen Kompetenzen eine Herausforderung darstellt. Allgemeine Leitlinien zur Entwicklung grundlegender KI-Kompetenzen für medizinisches Fachpersonal könnten als Referenzrahmen für Lehrende dienen, um Schulungsprogramme zu gestalten, den Lernfortschritt zu evaluieren und Leistungskriterien festzulegen. Etablierte Ausbildungsprogramme renommierter Bildungsstätten, wie die der Stanford Universität [230] oder der Harvard Universität [231] bieten hierfür Best-Practice-Bespiele. Darüber hinaus erscheint es aussichtsreich zukünftige medizinische Studiengänge und

Weiterbildungsmaßnahmen (bspw. Zusatzqualifizierungen) um Inhalte an der Schnittstelle von KI, Medizin und Data Science zu erweitern. Hierdurch können sowohl das grundlegende Verständnis von KI-Systemen als auch fortgeschrittene statistische und informatische Fähigkeiten mit Anwendungsbezug frühzeitig vermittelt werden. Der Implementierungserfolg KI-basierter EUS hängt auch maßgeblich davon ab, inwieweit die Wahrnehmung der Nutzer positiv beeinflusst, ihre Veränderungsbereitschaft und Offenheit gefördert werden kann. Zentrale Voraussetzung ist hier die Transdisziplinarität: die Nutzer sollten bereit sein, sich menschlich und inhaltlich auf andere Fachbereiche einzulassen und die eigene Disziplin aus anderen Blickwinkeln zu betrachten. Zudem sollten sie ihre Rolle im Interaktionsprozess neu definieren und den Wert der gemeinsamen und komplementären Wertschöpfung mit weiteren Beteiligten erkennen. Durch eine offene und transparente Herangehensweise sowie partizipative Ansätze können Verständnis und Kompetenzen im Umgang mit KI-basierten EUS gestärkt sowie Motivation und eine positivere Grundhaltung gegenüber der Implementierung gefördert werden.

Mit der Implementierung KI-basierter EUS gehen Prozess- und Strukturanpassungen einher, die Unsicherheiten über die berufliche Rolle und Arbeitsanforderungen hervorrufen und schließlich zu einer Identitätskrise führen können [232]. Da Ärzte mit ihren Überzeugungen und ihrem Verhalten maßgeblich die Abläufe innerhalb von Krankenhäusern prägen können, ist die Berücksichtigung beruflicher Identitätsmechanismen für den Implementierungserfolg entscheidend. Insbesondere die Haltung von Ärzten mit Leitungsfunktionen determinieren den Implementierungsprozess [171]. Aussichtsreich ist daher ein Ansatz, der die Implementierung KI-basierter EUS mit einflussreichen, aufgeschlossenen Personen vorbereitet und so gestaltet, dass es von den Nutzern als „unauffällig“ wahrgenommen wird. Dies setzt voraus, dass sich der Prozess nahtlos in bestehende Arbeitsabläufe einfügt und bestehende Rollen und Funktionen möglichst wenig beeinträchtigt. Zusätzlich ist eine nutzerorientierte Teamführung zielführend, um die psychologische Sicherheit der Nutzer zu steigern und die Bildung von Routinen zu fördern. Unterstützend können kollektives Lernen sowie die Stärkung von Wissen und Kompetenzen im Umgang mit KI-basierten EUS dazu beitragen, Bedenken von Ärzten hinsichtlich Arbeitsplatzsicherheit, beruflicher Identität, Entscheidungsautonomie und Kontrolle über klinische Arbeitsabläufe zu reduzieren.

Eine direkte Interaktion mit KI-basierten EUS noch vor dem routinisierten Einsatz kann es den Nutzern ermöglichen im Sinne einer „Trial-and-Error-Phase“ den Umgang und praktischen Einsatz KI-basierter EUS unter realen Bedingungen sowie für einen spezifischen Anwendungskontext und -fall zu erproben, die klinischen Vorteile für den Arbeitsalltag und die Patienten zu erkennen und Vertrauen aufzubauen. Dabei sollte die Interaktion mit KI-basierten EUS so gestaltet werden, dass stets eine menschliche Plausibilitätsüberprüfung der generierten Empfehlungen in den Fokus gerückt wird. Hierdurch kann ein ganzheitliches Verständnis der

tatsächlichen Auswirkungen der KI-Implementierung auf den Versorgungskontext generiert und die Zuversicht der Nutzer in Bezug auf den Mehrwert gestärkt werden. Schließlich erscheint es notwendig, die bisherigen Erkenntnisse verstärkt in realitätsnahen Anwendungskontexten zu überprüfen. Insbesondere die Erprobung KI-basierter EUS in konkreten, abgegrenzten Anwendungsszenarien könnte dazu beitragen, praxisnahe Erkenntnisse über den Umgang mit Herausforderungen im Spannungsfeld zwischen Entscheidungsassistenz und partieller Entscheidungsübernahme zu gewinnen. Eine solche Realweltvalidierung würde nicht nur die empirische Evidenzbasis stärken, sondern zugleich den Diskurs über normative und berufsethische Fragestellungen im Kontext KI-gestützter Entscheidungsprozesse weiterentwickeln.

8. Fazit

Insgesamt wird deutlich, dass die Implementierung KI-basierter EUS für die Antibiotikatherapie in Krankenhäusern eine Vielfalt an organisationalen, nutzerbezogenen und technologischen Maßnahmen erfordert, die isoliert betrachtet nicht zielführend sind. Die Dissertation ergänzt die wachsende Evidenzlage, indem sie KI-basierte EUS als Bestandteil eines komplexen soziotechnischen Transformationsperspektive versteht, der über technologische Aspekte hinausgeht und zugleich menschliche, klinische, berufliche, organisatorische, gesellschaftspolitische, ökonomische, regulatorische, rechtliche, ethische und kulturelle Veränderungen umfasst. Die Implementierung ist kein komplett endogener Prozess, sondern wird auch von externen Rahmenbedingungen determiniert. Bedeutend sind die technische Machbarkeit, die Merkmale des Kontextes, in dem das System implementiert wird, und die vorgesehene Rolle der potenziellen Nutzer im Entscheidungsprozess.

Literaturverzeichnis

- [1] GBD 2021 Antimicrobial Resistance Collaborators. Global burden of bacterial antimicrobial resistance 1990–2021: a systematic analysis with forecasts to 2050. *Lancet* 2024; 404(10459): 1199–226. doi: 10.1016/S0140-6736(24)01867-1.
- [2] Interagency Coordination Group on Antimicrobial Resistance. No time to wait: Securing the future from drug-resistant infections; 2019 [Stand: 01.04.2026]. Verfügbar unter: https://www.who.int/antimicrobial-resistance/interagency-coordination-group/IACG_final_report_EN.pdf?ua=1.
- [3] Robert Koch Institut. Neue Zahlen zu Krankheits-last und Todes-fällen durch antibiotika-resistente Erreger in Europa; 2018 [Stand: 01.04.2026]. Verfügbar unter: https://www.rki.de/DE/Content/Infekt/Antibiotikaresistenz/Uebersichtsbeitraege/AMR_Europa.html.
- [4] Taylor A, Littmann J, Holzscheiter A, Voss M, Wieler L, Eckmanns T. Sustainable development levers are key in global response to antimicrobial resistance. *Lancet* 2019; 394(10214): 2050–1. doi: 10.1016/S0140-6736(19)32555-3.
- [5] Baum JHJ, Dörre A, Reichert F, *et al.* Changes in incidence and epidemiology of antimicrobial resistant pathogens before and during the COVID-19 pandemic in Germany, 2015–2022. *BMC Microbiol* 2025; 25(1): 51. doi: 10.1186/s12866-024-03723-5.
- [6] Pfennigwerth N, Cremanns M, Eisfeld J, Hans J, Anders A, Gattermann SG. Bericht des Nationalen Referenzzentrums für gramnegative Krankenhauserreger. *Epidemiologisches Bulletin* 2022; (27): 3–10. doi: 10.25646/11589.
- [7] Bundesministerium für Gesundheit. DART 2020: Antibiotika-Resistenzen bekämpfen zum Wohl von Mensch und Tier; 2019 [Stand: 01.04.2026]. Verfügbar unter: www.bundesgesundheitsministerium.de/fileadmin/Dateien/3_Downloads/D/DART_2020/BMG_DART_2020_Bericht_dt.pdf.
- [8] Holmes AH, Moore LSP, Sundsfjord A, *et al.* Understanding the mechanisms and drivers of antimicrobial resistance. *Lancet* 2016; 387(10014): 176–87. doi: 10.1016/S0140-6736(15)00473-0.
- [9] Laxminarayan R, Duse A, Wattal C, *et al.* Antibiotic resistance-the need for global solutions. *The Lancet Infectious diseases* 2013; 13(12): 1057–98. doi: 10.1016/S1473-3099(13)70318-9.
- [10] Hamprecht A, Rohde AM, Behnke M, *et al.* Colonization with third-generation cephalosporin-resistant Enterobacteriaceae on hospital admission: prevalence and risk factors. *J Antimicrob Chemother* 2016; 71(10): 2957–63. doi: 10.1093/jac/dkw216.
- [11] Kern WV. Rationale Antibiotikaverordnung in der Humanmedizin. *Bundesgesundheitsblatt Gesundheitsforschung Gesundheitsschutz* 2018; 61(5): 580–8. doi: 10.1007/s00103-018-2727-x.

- [12] Sauskojus H, Wagner-Ahlf C, Razum O. Antibiotikaresistenz: In welchen Handlungsfeldern muss mehr getan werden? *Gesundheitswesen* 2019; 81(2): 88–91. doi: 10.1055/s-0042-123847.
- [13] Wieler LH, Broich K. Antibiotikaresistenzen: Große Herausforderungen erfordern komplexe Lösungen. *Bundesgesundheitsblatt Gesundheitsforschung Gesundheitsschutz* 2018; 61(5): 495–8. doi: 10.1007/s00103-018-2732-0.
- [14] Thern J, With K de, Strauss R, Steib-Bauert M, Weber N, Kern WV. Selection of hospital antimicrobial prescribing quality indicators: a consensus among German antibiotic stewardship (ABS) networkers. *Infection* 2014; 42(2): 351–62. doi: 10.1007/s15010-013-0559-z.
- [15] Charani E, Holmes A. Antibiotic Stewardship-Twenty Years in the Making. *Antibiotics (Basel)* 2019; 8(1). doi: 10.3390/antibiotics8010007.
- [16] With K de, Kern WV, Strauß R, *et al.* S3-Leitlinie Strategien zur Sicherung rationaler Antibiotika- Anwendung im Krankenhaus: Arbeitsgemeinschaft der Wissenschaftlichen Medizinischen Fachgesellschaften e. V. (AWMF); 2018 [Stand: 01.04.2026]. Verfügbar unter: 092–001I_S3_Strategien-zur-Sicherung-rationaler-Antibiotika-Anwendung-im-Krankenhaus_2020–02-abgelaufen.pdf.
- [17] Vogd W, Feißt M, Molzberger K, Ostermann A, Slotta J. Entscheidungsfindung im Krankenhausmanagement. Wiesbaden: Springer Fachmedien Wiesbaden 2018.
- [18] Schulz SE. Arbeiten im Krankenhaus: der Umgang von Beschäftigten mit der Ökonomisierung. *WSI* 2017; 70(3): 205–10. doi: 10.5771/0342-300X-2017-3-205.
- [19] Faller H, Meng K, Neuderth S, Richard M. Urteilsbildung und Entscheidung. In: Faller H, Mehnert-Theuerkauf A, editors. *Medizinische Psychologie und Soziologie*. Berlin, Heidelberg: Springer Berlin Heidelberg 2025; 277–85.
- [20] Vogd W. Ärztliche Entscheidungsfindung im Krankenhaus. *Zeitschrift für Soziologie* 2004; 33(1): 26–47. doi: 10.1515/zfsoz-2004-0102.
- [21] Weber J. Alle entscheidenden Konzepte, Steuerungssysteme und Instrumente. Weinheim: Wiley-VCH 2005.
- [22] Gluckowski P, Gabriel R, Dittmar C. *Management Support Systeme und Business Intelligence*. Berlin, Heidelberg: Springer Berlin Heidelberg 2008.
- [23] Berner ES, La Lande TJ. Overview of Clinical Decision Support Systems. In: Berner ES, editor. *Clinical Decision Support Systems*. Cham: Springer International Publishing 2016; 1–17.
- [24] Mankowitz S. *Clinical Informatics Board Review and Self Assessment*. Cham: Springer International Publishing 2018.
- [25] Lv J, Deng S, Le Zhang. A review of artificial intelligence applications for antimicrobial resistance. *Biosafety and Health* 2021; 3(1): 22–31. doi: 10.1016/j.bsheal.2020.08.003.

- [26] Baker M, Hobman JL, Dodd CER, Ramsden SJ, Stekel DJ. Mathematical modelling of antimicrobial resistance in agricultural waste highlights importance of gene transfer rate. *FEMS Microbiol Ecol* 2016; 92(4): fiw040. doi: 10.1093/femsec/fiw040.
- [27] Lau HJ, Lim CH, Foo SC, Tan HS. The role of artificial intelligence in the battle against antimicrobial-resistant bacteria. *Curr Genet* 2021; 67(3): 421–9. doi: 10.1007/s00294-021-01156-5.
- [28] Khoury MJ, Armstrong GL, Bunnell RE, Cyril J, Iademarco MF. The intersection of genomics and big data with public health: Opportunities for precision public health. *PLoS Med* 2020; 17(10): e1003373. doi: 10.1371/journal.pmed.1003373.
- [29] Boolchandani M, D'Souza AW, Dantas G. Sequencing-based methods and resources to study antimicrobial resistance. *Nat Rev Genet* 2019; 20(6): 356–70. doi: 10.1038/s41576-019-0108-4.
- [30] Rodríguez-González A, Zanin M, Menasalvas-Ruiz E. Public Health and Epidemiology Informatics: Can Artificial Intelligence Help Future Global Challenges? An Overview of Antimicrobial Resistance and Impact of Climate Change in Disease Epidemiology. *Yearb Med Inform* 2019; 28(1): 224–31. doi: 10.1055/s-0039-1677910.
- [31] Shortliffe EH, Sepúlveda MJ. Clinical Decision Support in the Era of Artificial Intelligence. *JAMA* 2018; 320(21): 2199–200. doi: 10.1001/jama.2018.17163.
- [32] Yusof MM, Papazafeiropoulou A, Paul RJ, Stergioulas LK. Investigating evaluation frameworks for health information systems. *Int J Med Inform* 2008; 77(6): 377–85. doi: 10.1016/j.ijmedinf.2007.08.004.
- [33] Prestinaci F, Pezzotti P, Pantosti A. Antimicrobial resistance: a global multifaceted phenomenon. *Pathog Glob Health* 2015; 109(7): 309–18. doi: 10.1179/2047773215Y.0000000030.
- [34] World Health Organization. Global action plan on antimicrobial resistance; 2015 [Stand: 01.04.2026]. Verfügbar unter: <http://www.who.int/iris/bitstream/10665/193736/>.
- [35] World Health Organization. Antimicrobial resistance; 2023 [Stand: 01.04.2026]. Verfügbar unter: <https://www.who.int/news-room/fact-sheets/detail/antimicrobial-resistance>.
- [36] Littmann J, Viens AM. The Ethical Significance of Antimicrobial Resistance. *Public Health Ethics* 2015; 8(3): 209–24. doi: 10.1093/phe/phv025.
- [37] Davey P, Marwick CA, Scott CL, *et al*. Interventions to improve antibiotic prescribing practices for hospital inpatients. *Cochrane Database Syst Rev* 2017; 2(2): CD003543. doi: 10.1002/14651858.CD003543.pub4.
- [38] Plachouras D, Kärki T, Hansen S, *et al*. Antimicrobial use in European acute care hospitals: results from the second point prevalence survey (PPS) of healthcare-associated infections and antimicrobial use, 2016 to 2017. *Euro Surveill* 2018; 23(46). doi: 10.2807/1560-7917.ES.23.46.1800393.

- [39] Laka M, Milazzo A, Merlin T. Inappropriate antibiotic prescribing: understanding clinicians' perceptions to enable changes in prescribing practices. *Aust Health Rev* 2022; 46(1): 21–7. doi: 10.1071/AH21197.
- [40] Kasse GE, Humphries J, Cosh SM, Islam MS. Factors contributing to the variation in antibiotic prescribing among primary health care physicians: a systematic review. *BMC Prim Care* 2024; 25(1): 8. doi: 10.1186/s12875-023-02223-1.
- [41] Aldeyab M, López-Lozano J-M, Gould IM. Global Antibiotics Use and Resistance. In: Barbar Z-U-D, editor. *Global Pharmaceutical Policy*. Singapore: Springer Singapore 2020; 331–44.
- [42] Jirjees F, Al-Obaidi H, Sartaj M, *et al.* Antibiotic use and resistance in hospitals: time-series analysis strategy for determining and prioritising interventions; 2020. [Stand: 01.04.2026]. Verfügbar unter: <https://hospitalpharmacyeurope.com/news/reviews-research/antibiotic-use-and-resistance-in-hospitals-time-series-analysis-strategy-for-determining-and-prioritising-interventions/>.
- [43] Robert Koch Institut. ARS – Antibiotika-Resistenz-Surveillance; 2019 [Stand: 01.04.2026]. Verfügbar unter: <https://ars.rki.de/>.
- [44] Robert Koch Institut. AVS – Antibiotika-Verbrauchs-Surveillance; 2019 [Stand: 01.04.2026]. Verfügbar unter: <https://avs.rki.de/>.
- [45] Robert Koch Institut. Surveillance von Antibiotikaresistenz und -verbrauch; 2025 [Stand: 01.04.2026]. Verfügbar unter: <https://amr.rki.de/Content/Common/Main.aspx>.
- [46] Hoffmann A, Schneider MJ, Zacher B, Krings A, Eckmanns T. ARVIA „ARS und AVS Integrierte Analyse“ – Ein neues Surveillance-Tool für Krankenhäuser zur Analyse von Antibiotika-Verbrauch und -Resistenz. *Epidemiologisches Bulletin* 2019; (6): 49–53. doi: 10.25646/5888.
- [47] Hoffmann A, Schneider MJ, Feig M, *et al.* ARVIA – Antibiotika-Resistenz- und Antibiotika-Verbrauchs-Surveillance gemeinsam auswerten. In: *ARVIA – Antibiotika-Resistenz- und Antibiotika-Verbrauchs-Surveillance gemeinsam auswerten*; 2019. Georg Thieme Verlag KG.
- [48] Cosgrove SE, Srinivasan A. Antibiotic Stewardship: A Decade of Progress. *Infect Dis Clin North Am* 2023; 37(4): 659–67. doi: 10.1016/j.idc.2023.06.003.
- [49] EU Guidelines for the prudent use of antimicrobials in human health; 2017 [Stand: 01.04.2026]. Verfügbar unter: [https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:52017XC0701\(01\)](https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:52017XC0701(01)).
- [50] With K de, Allerberger F, Amann S, *et al.* Strategies to enhance rational use of antibiotics in hospital: a guideline by the German Society for Infectious Diseases. *Infection* 2016; 44(3): 395–439. doi: 10.1007/s15010-016-0885-z.

- [51] Hood G, Hand KS, Cramp E, Howard P, Hopkins S, Ashiru-Oredope D. Measuring Appropriate Antibiotic Prescribing in Acute Hospitals: Development of a National Audit Tool Through a Delphi Consensus. *Antibiotics (Basel)* 2019; 8(2). doi: 10.3390/antibiotics8020049.
- [52] Monnier AA, Eisenstein BI, Hulscher ME, Gyssens IC. Towards a global definition of responsible antibiotic use: results of an international multidisciplinary consensus procedure. *J Antimicrob Chemother* 2018; 73(suppl_6): vi3-vi16. doi: 10.1093/jac/dky114.
- [53] Dwivedi YK, Hughes L, Ismagilova E, *et al.* Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management* 2021; 57: 101994. doi: 10.1016/j.ijinfomgt.2019.08.002.
- [54] Dua S, Acharya UR, Dua P. *Machine Learning in Healthcare Informatics*. Berlin, Heidelberg: Springer Berlin Heidelberg 2014.
- [55] Shafi I, Ansari S, Din S, Jeon G, Paul A. Artificial neural networks as clinical decision support systems. *Concurrency and Computation* 2021; 33(22). doi: 10.1002/cpe.6342.
- [56] Esteva A, Robicquet A, Ramsundar B, *et al.* A guide to deep learning in healthcare. *Nat Med* 2019; 25(1): 24–9. doi: 10.1038/s41591-018-0316-z.
- [57] Walterscheid H. Decision Support Systems. In: Walterscheid H, editor. *Effektivität computergestützter Management-Entscheidungsprozesse*. Wiesbaden: Deutscher Universitätsverlag 1996; 21–59.
- [58] Haefeli WE, Seidling HM. Elektronische Entscheidungsunterstützung zur Annäherung an eine sichere Arzneimitteltherapie. *Bundesgesundheitsblatt Gesundheitsforschung Gesundheitsschutz* 2018; 61(3): 271–7. doi: 10.1007/s00103-017-2685-8.
- [59] Spooner SA. Mathematical Foundations of Decision Support Systems. In: Berner ES, editor. *Clinical Decision Support Systems*. Cham: Springer International Publishing 2016; 19–43.
- [60] Middleton B, Sittig DF, Wright A. Clinical Decision Support: a 25 Year Retrospective and a 25 Year Vision. *Yearb Med Inform* 2016; Suppl 1(Suppl 1): 103-116. doi: 10.15265/IYS-2016-s034.
- [61] Samuel AL. Some studies in machine learning using the game of checkers. *IBM J. Res. & Dev.* 2000; 44(1.2): 206–26. doi: 10.1147/rd.441.0206.
- [62] Nayyar A, Gadhavi L, Zaman N. Machine learning in healthcare: review, opportunities and challenges. In: *Machine Learning and the Internet of Medical Things in Healthcare*. Elsevier 2021; 23–45.
- [63] Elrod JK, Fortenberry JL. Decision-Making in Health and Medicine. In: Elrod JK, Fortenberry JL, editors. *Organizational Behavior and Management in Health and Medicine*. Cham: Springer International Publishing 2024; 89–106.

- [64] Helou MA, DiazGranados D, Ryan MS, Cyrus JW. Uncertainty in Decision Making in Medicine: A Scoping Review and Thematic Analysis of Conceptual Models. *Acad Med* 2020; 95(1): 157–65. doi: 10.1097/ACM.0000000000002902.
- [65] Vogd W. Management im Krankenhaus – Eine Fallstudie zur Bearbeitung der Innen- und Außenspannungen unter den Bedingungen des deutschen DRG-Systems. *Berlin J Soziol* 2017; 27(1): 93–121. doi: 10.1007/s11609-017-0332-8.
- [66] Büchner S. Zum Verhältnis von Digitalisierung und Organisation. *Zeitschrift für Soziologie* 2018; 47(5): 332–48. doi: 10.1515/zfsoz-2018-0121.
- [67] Khosravi M, Zare Z, Mojtabaeian SM, Izadi R. Artificial Intelligence and Decision-Making in Healthcare: A Thematic Analysis of a Systematic Review of Reviews. *Health Serv Res Manag Epidemiol* 2024; 11: 23333928241234863. doi: 10.1177/23333928241234863.
- [68] Cireşan DC, Giusti A, Gambardella LM, Schmidhuber J. Mitosis detection in breast cancer histology images with deep neural networks. *Med Image Comput Comput Assist Interv* 2013; 16(2): 411–8. doi: 10.1007/978-3-642-40763-5_51.
- [69] Esteva A, Kuprel B, Novoa RA, *et al.* Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 2017; 542(7639): 115–8. doi: 10.1038/nature21056.
- [70] Gulshan V, Peng L, Coram M, *et al.* Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA* 2016; 316(22): 2402–10. doi: 10.1001/jama.2016.17216.
- [71] Poplin R, Varadarajan AV, Blumer K, *et al.* Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning. *Nat Biomed Eng* 2018; 2(3): 158–64. doi: 10.1038/s41551-018-0195-0.
- [72] Suri JS, Paul S, Maindarkar MA, *et al.* Cardiovascular/Stroke Risk Stratification in Parkinson's Disease Patients Using Atherosclerosis Pathway and Artificial Intelligence Paradigm: A Systematic Review. *Metabolites* 2022; 12(4). doi: 10.3390/metabo12040312.
- [73] Amin D, Garzón-Orjuela N, Garcia Pereira A, Parveen S, Vornhagen H, Vellinga A. Artificial Intelligence to Improve Antibiotic Prescribing: A Systematic Review. *Antibiotics (Basel)* 2023; 12(8). doi: 10.3390/antibiotics12081293.
- [74] Graafsma J, Murphy RM, van de Garde EMW, *et al.* The use of artificial intelligence to optimize medication alerts generated by clinical decision support systems: a scoping review. *J Am Med Inform Assoc* 2024; 31(6): 1411–22. doi: 10.1093/jamia/ocae076.
- [75] Holstiege J, Mathes T, Pieper D. Effects of computer-aided clinical decision support systems in improving antibiotic prescribing by primary care providers: a systematic review. *J Am Med Inform Assoc* 2015; 22(1): 236–42. doi: 10.1136/amiajnl-2014-002886.
- [76] Baysari MT, Lehnbohm EC, Li L, Hargreaves A, Day RO, Westbrook JI. The effectiveness of information technology to improve antimicrobial prescribing in hospitals: A systematic review and meta-analysis. *Int J Med Inform* 2016; 92: 15–34. doi: 10.1016/j.ijmedinf.2016.04.008.

- [77] Curtis CE, Al Bahar F, Marriott JF. The effectiveness of computerised decision support on antibiotic use in hospitals: A systematic review. *PLoS One* 2017; 12(8): e0183062. doi: 10.1371/journal.pone.0183062.
- [78] Kwan JL, Lo L, Ferguson J, *et al.* Computerised clinical decision support systems and absolute improvements in care: meta-analysis of controlled clinical trials. *BMJ* 2020; 370: m3216. doi: 10.1136/bmj.m3216.
- [79] Laka M, Milazzo A, Merlin T. Can evidence-based decision support tools transform antibiotic management? A systematic review and meta-analyses. *J Antimicrob Chemother* 2020; 75(5): 1099–111. doi: 10.1093/jac/dkz543.
- [80] Simões AS, Maia MR, Gregório J, *et al.* Participatory implementation of an antibiotic stewardship programme supported by an innovative surveillance and clinical decision-support system. *J Hosp Infect* 2018; 100(3): 257–64. doi: 10.1016/j.jhin.2018.07.034.
- [81] Mirbabaie M, Hofeditz L, Frick NRJ, Stieglitz S. Artificial intelligence in hospitals: providing a status quo of ethical considerations in academia to guide future research. *AI Soc* 2022; 37(4): 1361–82. doi: 10.1007/s00146-021-01239-4.
- [82] Artificial Intelligence Act; 2024 [Stand: 01.04.2026] Verfügbar unter: <https://eur-lex.europa.eu/legal-content/DE/TXT/?uri=CELEX:32024R1689>.
- [83] Verordnung über In-vitro-Diagnostika; 2017 [Stand 01.04.2026] Verfügbar unter: <https://eur-lex.europa.eu/legal-content/DE/TXT/PDF/?uri=CELEX:32017R0746>.
- [84] Verordnung über Medizinprodukte; 2017 [Stand: 01.04.2026] Verfügbar unter: <https://eur-lex.europa.eu/legal-content/DE/ALL/?uri=CELEX:32017R0745>.
- [85] Ladd ME. The Medical Device Regulation and its impact on device development and research in Germany. *Z Med Phys* 2023; 33(4): 459–61. doi: 10.1016/j.zemedi.2023.09.002.
- [86] Busch F, Kather JN, Johnner C, *et al.* Navigating the European Union Artificial Intelligence Act for Healthcare. *NPJ Digit Med* 2024; 7(1): 210. doi: 10.1038/s41746-024-01213-6.
- [87] Bak M, Madai VI, Fritzsche M-C, Mayrhofer MT, McLennan S. You Can't Have AI Both Ways: Balancing Health Data Privacy and Access Fairly. *Front Genet* 2022; 13: 929453. doi: 10.3389/fgene.2022.929453.
- [88] Bothe H. Aufbauorganisation. In: Goepfert A, Conrad CB, editors. *Unternehmen Krankenhaus*. Stuttgart: Georg Thieme Verlag 2013; 123-137.
- [89] Conrad CB. Organisation Krankenhaus – Balanceakt zwischen Spezialisierung und Koordination. In: Goepfert A, Conrad CB, editors. *Unternehmen Krankenhaus*. Stuttgart: Georg Thieme Verlag 2013; 107–22.
- [90] Schlenkrich K. Die wachsende Komplexität der Zielsysteme im Krankenhaus. In: Kümpe T, Schlenkrich K, Heupel T, editors. *Controlling & Innovation 2022*. Wiesbaden: Springer Fachmedien Wiesbaden 2022; 335–44.

- [91] Heller C. Herausforderungen einer Neustrukturierung aus Krankenhaussicht. In: Klauber J, Wasem J, Beivers A, Mostert C, Scheller-Kreinsen D, editors. Krankenhaus-Report 2024. Berlin, Heidelberg: Springer Berlin Heidelberg 2024; 177–93.
- [92] Bohnet-Joschko S, Korte L. Digitalisierung verändert den Krankenhausalltag. *Pflege Z* 2023; 76(4): 56–8. doi: 10.1007/s41906-023-2034-5.
- [93] Brönneke JB, Debatin JF. Digitalisierung im Gesundheitswesen und ihre Effekte auf die Qualität der Gesundheitsversorgung. *Bundesgesundheitsblatt Gesundheitsforschung Gesundheitsschutz* 2022; 65(3): 342–7. doi: 10.1007/s00103-022-03493-3.
- [94] Thiel R, Deimel L, Schmidtman D, *et al.* #SmarHealthSystems Digitalisierungsstrategien im internationalen Vergleich; 2018.
- [95] Gonçalves ASO, Bertram N, Amelung VE. European Scorecard zum Stand der Implementierung der elektronischen Patientenakte auf nationaler Ebene; 2018.
- [96] Deloitte Centre for Health Solutions. 2021 global health care outlook. Accelerating industry change; 2021.
- [97] Behm ME, Klenk T. Digitalisierung im Gesundheitssektor. In: Tanja Klenk, Frank Nullmeier und Göttrik Wewer, editor. *Handbuch Digitalisierung in Staat und Verwaltung*. Wiesbaden: Springer Fachmedien Wiesbaden 2020; 1–12.
- [98] Sachverständigenrat zur Begutachtung der Entwicklung im Gesundheitswesen. Digitalisierung für Gesundheit: Ziele und Rahmenbedingungen eines dynamisch lernenden Gesundheitssystems; 2021.
- [99] Ochmann R, der Heiden I an, Bernhard J. IHP-Survey Deutschland 2022. Berlin; 2023.
- [100] Deloitte Centre for Health Solutions. Digital transformation. Shaping the future of European healthcare; 2020.
- [101] Paranjape K, Schinkel M, Nanayakkara P. Short Keynote Paper: Mainstreaming Personalized Healthcare-Transforming Healthcare Through New Era of Artificial Intelligence. *IEEE J Biomed Health Inform* 2020; 24(7): 1860–3. doi: 10.1109/JBHI.2020.2970807.
- [102] Wensing M. Organisationsbezogene Versorgungsforschung – Implementierungsforschung. In: Kurscheid C, Balke-Karrenbauer N, Mollenhauer J, editors. *Gesundheitsökonomie und Versorgungswissenschaft*. Berlin, Heidelberg: Springer Berlin Heidelberg 2024; 1–6.
- [103] Squires JE, Graham ID, Santos WJ, Hutchinson AM. The Implementation in Context (ICON) Framework: A meta-framework of context domains, attributes and features in healthcare. *Health Res Policy Syst* 2023; 21(1): 81. doi: 10.1186/s12961-023-01028-z.
- [104] Karlton A. Developing HTO system's thinking for organizational and technological change; 2011.

- [105] Chatterjee S, Moody G, Lowry PB, Chakraborty S, Hardin A. Information Technology and organizational innovation: Harmonious information technology affordance and courage-based actualization. *The Journal of Strategic Information Systems* 2020; 29(1): 101596. doi: 10.1016/j.jsis.2020.101596.
- [106] Scott WR, Davis G. *Organizations and Organizing*. Routledge 2015.
- [107] Tolbert PS, Hall RH. *Organizations: Structures, Processes and Outcomes*. Routledge 2015.
- [108] Dwivedi YK, Wade MR, Schneberger SL. *Information Systems Theory*. New York, NY: Springer New York 2012.
- [109] DeLone WH, McLean ER. Measuring e-Commerce Success: Applying the DeLone & McLean Information Systems Success Model. *International Journal of Electronic Commerce* 2004; 9(1): 31–47. doi: 10.1080/10864415.2004.11044317.
- [110] Scott Morton MS. *The corporation of the 1990s: Information technology and organizational transformation*. New York: Oxford University Press 1990.
- [111] Xu J, Lu W. Developing a human-organization-technology fit model for information technology adoption in organizations. *Technology in Society* 2022; 70: 102010. doi: 10.1016/j.techsoc.2022.102010.
- [112] Erlirianto LM, Ali AHN, Herdiyanti A. The Implementation of the Human, Organization, and Technology–Fit (HOT–Fit) Framework to Evaluate the Electronic Medical Record (EMR) System in a Hospital. *Procedia Computer Science* 2015; 72: 580–7. doi: 10.1016/j.procs.2015.12.166.
- [113] Marques A, Oliveira T, Dias SS, Martins MFO. Medical Records System Adoption in European Hospitals. *The Electronic Journal Information Systems Evaluation* 2011; 14(1): 89–99.
- [114] Puspita SC, Supriyantoro, Hasyim. Analysis of Hospital Information System Implementation Using the Human-Organization-Technology (HOT) Fit Method: A Case Study Hospital in Indonesia. *EJBMR* 2020; 5(6). doi: 10.24018/ejbmr.2020.5.6.592.
- [115] TryWindy W, Sari FR, Chalidyanto D. Evaluation of Hospital Information System Using HOT-FIT Method in Hospital in Indonesia. *European Journal of Molecular & Clinical Medicine* 2020; 7(5): 429–33.
- [116] Ahmadi H, Nilashi M, Ibrahim O. Organizational decision to adopt hospital information system: an empirical investigation in the case of Malaysian public hospitals. *Int J Med Inform* 2015; 84(3): 166–88. doi: 10.1016/j.ijmedinf.2014.12.004.
- [117] Leidner DE, Gonzalez E, Koch H. An affordance perspective of enterprise social media and organizational socialization. *The Journal of Strategic Information Systems* 2018; 27(2): 117–38. doi: 10.1016/j.jsis.2018.03.003.

- [118] Mustafa NK, Ibrahim R, Aizuddin AN, Aljunid SM, Awang Z. Critical Success Factors and Acceptance of the Casemix System Implementation Within the Total Hospital Information System: Exploratory Factor Analysis of a Pilot Study. *JMIR Form Res* 2024; 8: e56898 doi: 10.2196/56898.
- [119] Berman S. Clinical decision making. In: *Berman's Pediatric Decision Making*. Elsevier 2011; 1–6.
- [120] Varonen H, Kortteisto T, Kaila M. What may help or hinder the implementation of computerized decision support systems (CDSSs): a focus group study with physicians. *Fam Pract* 2008; 25(3): 162–7. doi: 10.1093/fampra/cmn020.
- [121] Bertl M, Ross P, Draheim D. A survey on AI and decision support systems in psychiatry – Uncovering a dilemma. *Expert Systems with Applications* 2022; 202: 117464. doi: 10.1016/j.eswa.2022.117464.
- [122] Safdar S, Zafar S, Zafar N, Khan NF. Machine learning based decision support systems (DSS) for heart disease diagnosis: a review. *Artif Intell Rev* 2018; 50(4): 597–623. doi.org/10.1007/s10462-017-9552-8.
- [123] Creswell JW. Basic Characteristics of Mixed Methods Research. In: *Creswell John W. (Hg.) 2021 – A concise introduction to mixed*; 1–12.
- [124] Kuckartz U. Designs für die Mixed-Methods-Forschung. In: Kuckartz U, editor. *Mixed Methods*. Wiesbaden: Springer Fachmedien Wiesbaden 2014; 57–98.
- [125] Higgins JP, Thomas J, Chandler J, *et al.* *Cochrane Handbook for Systematic Reviews of Interventions*. Wiley 2019.
- [126] Witzel A. Das problemzentrierte Interview. *Forum Qualitative Sozialforschung* 2000; 1(1).
- [127] Helfferich Cornelia. *Die Qualität qualitativer Daten: Manual für die Durchführung qualitativer Interviews*. Wiesbaden: Verlag für Sozialwissenschaften, Springer Fachmedien 2011.
- [128] Kuckartz U. *Qualitative Inhaltsanalyse: Methoden, Praxis, Computerunterstützung*. Weinheim, Basel: Beltz Juventa 2016.
- [129] Das Statistische Bundesamt. Verzeichnis der Krankenhäuser und Vorsorge- oder Rehabilitationseinrichtungen in Deutschland; 2021 [Stand: 01.04.2026]. Verfügbar unter: https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Gesundheit/Krankenhäuser/_inhalt.html.
- [130] Niederberger M, Renn O. Das klassische Delphi-Verfahren: Konzept und Vorgehensweise. In: Niederberger M, Renn O, editors. *Das Gruppendelphi-Verfahren*. Wiesbaden: Springer Fachmedien Wiesbaden 2018; 7–25.
- [131] Garrett HE, Woodworth R. *Statistics in psychology and education*. Bombay: Vakils, Feffer and Simons Private Ltd 1973.

- [132] Tokgöz P, Hafner J, Dockweiler C. Factors influencing the implementation of decision support systems for antibiotic prescription in hospitals: a systematic review. *BMC Med Inform Decis Mak* 2023; 23(1): 27. doi: 10.1186/s12911-023-02124-4.
- [133] Tokgöz P, Hafner J, Dockweiler C. Faktoren für die Implementierung von KI-basierten Entscheidungsunterstützungssystemen zur Antibiotikavorhersage im Krankenhaus – eine qualitative Analyse aus der Perspektive von ärztlichem Personal. *Gesundheitswesen* 2023; 85(12): 1220–8. doi: 10.1055/a-2098-3108.
- [134] Tokgöz P, Krayter S, Hafner J, Dockweiler C. Decision support systems for antibiotic prescription in hospitals: a survey with hospital managers on factors for implementation. *BMC Med Inform Decis Mak* 2024; 24(1): 96. doi: 10.1186/s12911-024-02490-7.
- [135] Tokgöz P, Albrecht J, Dockweiler C. Implementation of artificial intelligence-based decision support systems for antibiotic prescribing in hospitals: a Delphi study. *Front Digit Health* 2025; 7: 1555042. doi: 10.3389/fdgth.2025.1555042.
- [136] Kroencke T, Dijk SW, Halfmann MC, *et al.* Challenges and insights from implementing clinical decision support systems for radiologic imaging: experience from the MIDAS trial. *Insights Imaging* 2025; 16(1): 152. doi: 10.1186/s13244-025-02027-0.
- [137] Strohm L, Hehakaya C, Ranschaert ER, Boon WPC, Moors EHM. Implementation of artificial intelligence (AI) applications in radiology: hindering and facilitating factors. *Eur Radiol* 2020; 30(10): 5525–32. doi: 10.1007/s00330-020-06946-y.
- [138] Shiang T, Garwood E, Debenedectis CM. Artificial intelligence-based decision support system (AI-DSS) implementation in radiology residency: Introducing residents to AI in the clinical setting. *Clin Imaging* 2022; 92: 32–7. doi: 10.1016/j.clinimag.2022.09.003.
- [139] Naderian S, Soleimanzadeh F, Nikniaz L, Sanaie S, Sadeghi-Ghyassi F, Samad-Soltani T. A Systematic Review of Artificial Intelligence-Based Clinical Decision Support Systems in Prostate Cancer Management. *Healthc Technol Lett* 2025; 12(1): e70026. doi: 10.1049/htl2.70026.
- [140] Rezaeian O, Bayrak AE, Asan O. Explainability and AI Confidence in Clinical Decision Support Systems: Effects on Trust, Diagnostic Performance, and Cognitive Load in Breast Cancer Care. *International Journal of Human–Computer Interaction* 2025: 1–21. doi: 10.1080/10447318.2025.2539458.
- [141] Fujimori R, Liu K, Soeno S, *et al.* Acceptance, Barriers, and Facilitators to Implementing Artificial Intelligence-Based Decision Support Systems in Emergency Departments: Quantitative and Qualitative Evaluation. *JMIR Form Res* 2022; 6(6): e36501. doi: 10.2196/36501.
- [142] Petitgand C, Motulsky A, Denis J-L, Régis C. Investigating the Barriers to Physician Adoption of an Artificial Intelligence- Based Decision Support System in Emergency Care: An Interpretative Qualitative Study. *Stud Health Technol Inform* 2020; 270: 1001–5. doi: 10.3233/SHTI200312.

- [143] Tay YX, Wee JCP, Ong MEH, *et al.* Optimising design of clinical decision support systems and implementation strategies to improve radiological imaging appropriateness - A qualitative study in the emergency department. *Int J Med Inform* 2025; 202: 105966. doi: 10.1016/j.ijmedinf.2025.105966.
- [144] Higgins O, Short BL, Chalup SK, Wilson RL. Artificial intelligence (AI) and machine learning (ML) based decision support systems in mental health: An integrative review. *Int J Ment Health Nurs* 2023; 32(4): 966–78. doi: 10.1111/inm.13114.
- [145] Romero-Brufau S, Wyatt KD, Boyum P, Mickelson M, Moore M, Cagnetta-Rieke C. A lesson in implementation: A pre-post study of providers' experience with artificial intelligence-based clinical decision support. *Int J Med Inform* 2020; 137: 104072. doi: 10.1016/j.ijmedinf.2019.104072.
- [146] Meunier P-Y, Raynaud C, Guimaraes E, Gueyffier F, Letrilliart L. Barriers and Facilitators to the Use of Clinical Decision Support Systems in Primary Care: A Mixed-Methods Systematic Review. *Ann Fam Med* 2023; 21(1): 57–69. doi: 10.1370/afm.2908.
- [147] Pumplun L, Fecho M, Wahl N, Peters F, Buxmann P. Adoption of Machine Learning Systems for Medical Diagnostics in Clinics: Qualitative Interview Study. *J Med Internet Res* 2021; 23(10): e29301. doi: 10.2196/29301.
- [148] Petersson L, Larsson I, Nygren JM, *et al.* Challenges to implementing artificial intelligence in healthcare: a qualitative interview study with healthcare leaders in Sweden. *BMC Health Serv Res* 2022; 22(1): 850. doi: 10.1186/s12913-022-08215-8.
- [149] Cabitza F, Campagner A, Balsano C. Bridging the "last mile" gap between AI implementation and operation: "data awareness" that matters. *Ann Transl Med* 2020; 8(7): 501. doi: 10.21037/atm.2020.03.63.
- [150] Felmingham CM, Adler NR, Ge Z, Morton RL, Janda M, Mar VJ. The Importance of Incorporating Human Factors in the Design and Implementation of Artificial Intelligence for Skin Cancer Diagnosis in the Real World. *Am J Clin Dermatol* 2021; 22(2): 233–42. doi: 10.1007/s40257-020-00574-4.
- [151] Chen M, Zhang B, Cai Z, *et al.* Acceptance of clinical artificial intelligence among physicians and medical students: A systematic review with cross-sectional survey. *Front Med (Lausanne)* 2022; 9: 990604. doi: 10.3389/fmed.2022.990604.
- [152] Vijayakumar S, Lee VV, Leong QY, Hong SJ, Blasiak A, Ho D. Physicians' Perspectives on AI in Clinical Decision Support Systems: Interview Study of the CURATE.AI Personalized Dose Optimization Platform. *JMIR Hum Factors* 2023; 10: e48476. doi: 10.2196/48476.
- [153] Khairat S, Marc D, Crosby W, Al Sanousi A. Reasons For Physicians Not Adopting Clinical Decision Support Systems: Critical Analysis. *JMIR Med Inform* 2018; 6(2): e24. doi: 10.2196/medinform.8912.
- [154] Chomutare T, Tejedor M, Svenning TO, *et al.* Artificial Intelligence Implementation in Healthcare: A Theory-Based Scoping Review of Barriers and Facilitators. *Int J Environ Res Public Health* 2022; 19(23). doi: 10.3390/ijerph192316359.

- [155] Knop M, Weber S, Mueller M, Niehaves B. Human Factors and Technological Characteristics Influencing the Interaction of Medical Professionals With Artificial Intelligence-Enabled Clinical Decision Support Systems: Literature Review. *JMIR Hum Factors* 2022; 9(1): e28639. doi: 10.2196/28639.
- [156] Benner P. From Novice to Expert. *The American Journal of Nursing* 1982; 82(3): 402 doi: 10.2307/3462928.
- [157] Presseau J, Johnston M, Heponiemi T, *et al.* Reflective and automatic processes in health care professional behaviour: a dual process model tested across multiple behaviours. *Ann Behav Med* 2014; 48(3): 347–58. doi: 10.1007/s12160-014-9609-8.
- [158] Chen M, Decary M. Artificial intelligence in healthcare: An essential guide for health leaders. *Healthc Manage Forum* 2020; 33(1): 10–8. doi: 10.1177/0840470419873123.
- [159] Lee D, Yoon SN. Application of Artificial Intelligence-Based Technologies in the Healthcare Industry: Opportunities and Challenges. *Int J Environ Res Public Health* 2021; 18(1). doi: 10.3390/ijerph18010271.
- [160] Shinnars L, Aggar C, Grace S, Smith S. Exploring healthcare professionals' understanding and experiences of artificial intelligence technology use in the delivery of healthcare: An integrative review. *Health Informatics J* 2020; 26(2): 1225–36. doi: 10.1177/1460458219874641.
- [161] Siala H, Wang Y. SHIFTing artificial intelligence to be responsible in healthcare: A systematic review. *Soc Sci Med* 2022; 296: 114782. doi: 10.1016/j.socscimed.2022.114782.
- [162] Wanner J, Herm L-V, Heinrich K, Janiesch C. The effect of transparency and trust on intelligent system acceptance: Evidence from a user-based study. *Electron Markets* 2022; 32(4): 2079–102. doi: 10.1007/s12525-022-00593-5.
- [163] Mualla Y, Tchappi I, Kampik T, *et al.* The quest of parsimonious XAI: A human-agent architecture for explanation formulation. *Artificial Intelligence* 2022; 302: 103573. doi: 10.1016/j.artint.2021.103573
- [164] Herm L-V, Heinrich K, Wanner J, Janiesch C. Stop ordering machine learning algorithms by their explainability! A user-centered investigation of performance and explainability. *International Journal of Information Management* 2023; 69: 102538. doi: 10.1016/j.ijinfo-mgt.2022.102538.
- [165] Choudhury A, Chaudhry Z. Large Language Models and User Trust: Consequence of Self-Referential Learning Loop and the Deskilling of Health Care Professionals. *J Med Internet Res* 2024; 26: e56764. doi: 10.2196/56764.
- [166] Rieckert A, Teichmann A-L, Drewelow E, *et al.* Reduction of inappropriate medication in older populations by electronic decision support (the PRIMA-eDS project): a survey of general practitioners' experiences. *J Am Med Inform Assoc* 2019; 26(11): 1323–32. doi: 10.1093/jamia/ocz104.

- [167] Hoff KA, Bashir M. Trust in automation: integrating empirical evidence on factors that influence trust. *Hum Factors* 2015; 57(3): 407–34. doi: 10.1177/0018720814547570.
- [168] Oksanen A, Savela N, Latikka R, Koivula A. Trust Toward Robots and Artificial Intelligence: An Experimental Approach to Human-Technology Interactions Online. *Front Psychol* 2020; 11: 568256. doi: 10.3389/fpsyg.2020.568256.
- [169] Choudhury A, Asan O. Impact of cognitive workload and situation awareness on clinicians' willingness to use an artificial intelligence system in clinical practice. *IJSE Transactions on Healthcare Systems Engineering* 2023; 13(2): 89–100. doi: 10.1080/24725579.2022.2127035.
- [170] Goh JM, Gao G, Agarwal R. Evolving Work Routines: Adaptive Routinization of Information Technology in Healthcare. *Information Systems Research* 2011; 22(3): 565–85. doi.org/10.1287/isre.1110.0365.
- [171] Bernardi R, Exworthy M. Clinical managers' identity at the crossroad of multiple institutional logics in it innovation: The case study of a health care organization in England. *Information Systems Journal* 2020; 30(3): 566–95. doi: 10.1111/isj.12267.
- [172] Gruetzemacher R, Paradise D, Lee KB. Forecasting extreme labor displacement: A survey of AI practitioners. *Technological Forecasting and Social Change* 2020; 161: 120323. doi: 10.1016/j.techfore.2020.120323.
- [173] Reis L, Maier C, Mattke J, Creutzenberg M, Weitzel T. Addressing User Resistance Would Have Prevented a Healthcare AI Project Failure. *MSQE* 2020: 279–96. doi: 10.17705/2msqe.00038.
- [174] Jain M, Goel A, Sinha S, Dhir S. Employability implications of artificial intelligence in healthcare ecosystem: responding with readiness. *FS* 2021; 23(1): 73–94. doi: 10.1108/FS-04-2020-0038.
- [175] Warner KS, Wäger M. Building dynamic capabilities for digital transformation: An ongoing process of strategic renewal. *Long Range Planning* 2019; 52(3): 326–49. doi: 10.1016/j.lrp.2018.12.001.
- [176] Elish MC. The Stakes of Uncertainty: Developing and Integrating Machine Learning in Clinical Care. *EPIC Proceedings* 2018; 1: 364–80.
- [177] Page MJ, McKenzie JE, Bossuyt PM, *et al.* The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ* 2021; 372: n71 doi: 10.1136/bmj.n71.
- [178] Wytrzens HK, Schauppenlehner-Kloyber E, Sieghardt M. *Wissenschaftliches Arbeiten: Ein Einführung.* Wien: Facultas 2023.
- [179] Sturma A, Ritschl V, Dennhardt S, Stamm Tanja Alexandra. Reviews. In: Ritschl V, Weigl R, Stamm Tanja Alexandra, editors. *Wissenschaftliches Arbeiten und Schreiben: Verstehen, Anwenden, Nutzen für die Praxis.* Berlin, Heidelberg: Springer-Verlag 2016; 208–20.

- [180] Hong QN, Fàbregues S, Bartlett G, *et al.* The Mixed Methods Appraisal Tool (MMAT) version 2018 for information professionals and researchers. *EFI* 2018; 34(4): 285–91. doi: 10.3233/EFI-180221.
- [181] Souto RQ, Khanassov V, Hong QN, Bush PL, Vedel I, Pluye P. Systematic mixed studies reviews: updating results on the reliability and efficiency of the Mixed Methods Appraisal Tool. *Int J Nurs Stud* 2015; 52(1): 500–1. doi: 10.1016/j.ijnurstu.2014.08.010.
- [182] Strauss AL, Corbin JM. *Grounded theory: Grundlagen qualitativer Sozialforschung*. Weinheim: Beltz Juventa 1996.
- [183] Statistisches Bundesamt. Ergebnisse des Mikrozensus 2023: Altersstruktur der Ärzteschaft in Deutschland.; 2024 [Stand: 01.04.2026]. Verfügbar unter: https://www.destatis.de/DE/Presse/Pressemitteilungen/2024/05/PD24_N022_12_21.html.
- [184] Hertling S, Kaiser M, Schleußner E, Loos FM, Eckhardt N, Graul I. Gender gap-Gender-specific development in the field of obstetrics and gynecology in Germany in the last 20 years. *Front Med (Lausanne)* 2023; 10: 1207388. doi: 10.3389/fmed.2023.1207388.
- [185] Carli-Ghabarou D, Seidling HM, Bonnabry P, Lovis C. A survey-based inventory of clinical decision support systems in computerised provider order entry in Swiss hospitals. *Swiss Med Wkly* 2013; 143: w13894. doi: 10.4414/smw.2013.13894.
- [186] Liberati EG, Ruggiero F, Galuppo L, *et al.* What hinders the uptake of computerized decision support systems in hospitals? A qualitative study and framework for implementation. *Implement Sci* 2017; 12(1): 113. doi: 10.1186/s13012-017-0644-2.
- [187] Wasem J, Blase N. Die Personalentwicklung im Krankenhaus seit 2000. In: Klauber J, Wasem J, Beivers A, Mostert C, editors. *Krankenhaus-Report 2023*. Berlin, Heidelberg: Springer Berlin Heidelberg 2023; 3–18.
- [188] Stocké Volker. Entstehungsbedingungen von Antwortverzerrungen durch soziale Erwünschtheit -Ein Vergleich der Prognosen der Rational-Choice Theorie und des Modells der Frame-Selektion. *Zeitschrift für Soziologie* 2004; 33(3): 303–20.
- [189] Niederberger M, Renn O. Das Gruppendelphi-Verfahren in den Sozial- und Gesundheitswissenschaften. In: Niederberger M, Renn O, editors. *Delphi-Verfahren in den Sozial- und Gesundheitswissenschaften*. Wiesbaden: Springer Fachmedien Wiesbaden 2019; 83–100.
- [190] Blase N, Diehl A, Wasem J. Digitalisierung im Krankenhaus. In: Klauber J, Wasem J, Beivers A, Mostert C, editors. *Krankenhaus-Report 2023*. Berlin, Heidelberg: Springer Berlin Heidelberg 2023; 165–78.
- [191] Verordnung zum Schutz natürlicher Personen bei der Verarbeitung personenbezogener Daten, zum freien Datenverkehr und zur Aufhebung der Richtlinie 95/46/EG; 2016 [Stand: 01.04.2026]. Verfügbar unter: <https://eur-lex.europa.eu/eli/reg/2016/679/oj?locale=de>.
- [192] Köppen J, Busse R. Die Personalsituation im Krankenhaus im internationalen Vergleich. In: Klauber J, Wasem J, Beivers A, Mostert C, editors. *Krankenhaus-Report 2023*. Berlin, Heidelberg: Springer Berlin Heidelberg 2023; 19–23.

- [193] Greenhalgh T, Robert G, Macfarlane F, Bate P, Kyriakidou O. Diffusion of innovations in service organizations: systematic review and recommendations. *Milbank Q* 2004; 82(4): 581–629. doi: 10.1111/j.0887-378X.2004.00325.x.
- [194] Moullin JC, Sabater-Hernández D, Fernandez-Llimos F, Benrimoj SI. A systematic review of implementation frameworks of innovations in healthcare and resulting generic implementation framework. *Health Res Policy Syst* 2015; 13: 16. doi: 10.1186/s12961-015-0005-z.
- [195] Greenes RA, Bates DW, Kawamoto K, Middleton B, Osheroff J, Shahar Y. Clinical decision support models and frameworks: Seeking to address research issues underlying implementation successes and failures. *J Biomed Inform* 2018; 78: 134–43. doi: 10.1016/j.jbi.2017.12.005.
- [196] Fan W, Liu J, Zhu S, Pardalos PM. Investigating the impacting factors for the healthcare professionals to adopt artificial intelligence-based medical diagnosis support system (AIM-DSS). *Ann Oper Res* 2020; 294(1-2): 567–92. doi: 10.1007/s10479-018-2818-y
- [197] Laka M, Milazzo A, Merlin T. Factors That Impact the Adoption of Clinical Decision Support Systems (CDSS) for Antibiotic Management. *Int J Environ Res Public Health* 2021; 18(4). doi: 10.3390/ijerph18041901.
- [198] Yang X, Man D, Yun K, zhang S, Han X. Factors influencing doctors' acceptance of artificial intelligence-enabled clinical decision support systems in tertiary hospitals in China 2023.
- [199] Choudhury A. Factors influencing clinicians' willingness to use an AI-based clinical decision support system. *Front Digit Health* 2022; 4: 920662. doi: 10.3389/fdgth.2022.920662.
- [200] Ghazali MT, Satibi, Fortwengel G. Adoption Intentions Toward AI-based Clinical Decision Support Tools: A Tam Study on Hospital Pharmacists 2025. doi: 10.25968/opus-3717.
- [201] Shwede F, Alzoubi HM. Artificial Intelligence (AI) Integration into the Decision Support Systems of Health Care Centers. In: Alzoubi HM, Cheng Ling T, El Khatib M, editors. *Innovative Dynamics in Management and Engineering (IDME)*. Cham: Springer Nature Switzerland 2025; 165–76.
- [202] Alami H, Lehoux P, Papoutsis C, Shaw SE, Fleet R, Fortin J-P. Understanding the integration of artificial intelligence in healthcare organisations and systems through the NASSS framework: a qualitative study in a leading Canadian academic centre. *BMC Health Serv Res* 2024; 24(1): 701. doi: 10.1186/s12913-024-11112-x.
- [203] Shaw J, Rudzicz F, Jamieson T, Goldfarb A. Artificial Intelligence and the Implementation Challenge. *J Med Internet Res* 2019; 21(7): e13659. doi: 10.2196/13659.
- [204] Fernando M, Abell B, Tyack Z, Donovan T, McPhail SM, Naicker S. Using Theories, Models, and Frameworks to Inform Implementation Cycles of Computerized Clinical Decision Support Systems in Tertiary Health Care Settings: Scoping Review. *J Med Internet Res* 2023; 25: e45163. doi: 10.2196/45163.

- [205] Nilsen P, Bernhardsson S. Context matters in implementation science: a scoping review of determinant frameworks that describe contextual determinants for implementation outcomes. *BMC Health Serv Res* 2019; 19(1): 189. doi: 10.1186/s12913-019-4015-3.
- [206] Pinnock H, Barwick M, Carpenter CR, *et al.* Standards for Reporting Implementation Studies (StaRI) Statement. *BMJ* 2017; 356: i6795. doi: 10.1136/bmj.i6795.
- [207] Queder A, Arnold C, Wensing M, Poß-Doering R. Contextual factors influencing physicians' perception of antibiotic prescribing in primary care in Germany - a prospective observational study. *BMC Health Serv Res* 2022; 22(1): 331. doi: 10.1186/s12913-022-07701-3.
- [208] Schaut M, Schaefer M, Trost U, Sander A. Integrated antibiotic clinical decision support system (CDSS) for appropriate choice and dosage: an analysis of retrospective data. *Germes* 2022; 12(2): 203–13. doi: 10.18683/germes.2022.1323.
- [209] Giebel GD, Raszke P, Nowak H, *et al.* Problems and Barriers Related to the Use of AI-Based Clinical Decision Support Systems: Interview Study. *J Med Internet Res* 2025; 27: e63377. doi: 10.2196/63377.
- [210] Laka M, Carter D, Milazzo A, Merlin T. Challenges and opportunities in implementing clinical decision support systems (CDSS) at scale: Interviews with Australian policymakers. *Health Policy and Technology* 2022; 11(3): 100652. doi: 10.1016/j.hlpt.2022.100652.
- [211] Wang Y, Fu W, Zhang Y, *et al.* Constructing and implementing a performance evaluation indicator set for artificial intelligence decision support systems in pediatric outpatient clinics: an observational study. *Sci Rep* 2024; 14(1): 14482. doi: 10.1038/s41598-024-64893-w.
- [212] Ahmad N, Du S, Ahmed F, ul Amin N, Yi X. Healthcare professionals satisfaction and AI-based clinical decision support system in public sector hospitals during health crises: a cross-sectional study. *Inf Technol Manag* 2025; 26(2): 205–17. doi: 10.1007/s10799-023-00407-w.
- [213] Lewkowicz D, Wohlbrandt A, Boettinger E. Economic impact of clinical decision support interventions based on electronic health records. *BMC Health Serv Res* 2020; 20(1): 871. doi: 10.1186/s12913-020-05688-3.
- [214] Cornett M, Palermo C, Ash S. Professional identity research in the health professions-a scoping review. *Adv Health Sci Educ Theory Pract* 2023; 28(2): 589–642. doi: 10.1007/s10459-022-10171-1.
- [215] Bernuzzi C, Sommovigo V, Setti I. The role of resilience in the work-life interface: A systematic review. *Work* 2022; 73(4): 1147–65. doi: 10.3233/WOR-205023.
- [216] Edmondson AC, Lei Z. Psychological Safety: The History, Renaissance, and Future of an Interpersonal Construct. *Annu. Rev. Organ. Psychol. Organ. Behav.* 2014; 1(1): 23–43. doi: 10.1146/annurev-orgpsych-031413-091305.

- [217] O'donovan R, Mcauliffe E. A systematic review of factors that enable psychological safety in healthcare teams. *Int J Qual Health Care* 2020; 32(4): 240–50. doi: 10.1093/intqhc/mzaa025.
- [218] Ito A, Sato K, Yumoto Y, Sasaki M, Ogata Y. A concept analysis of psychological safety: Further understanding for application to health care. *Nurs Open* 2022; 9(1): 467–89. doi: 10.1002/nop2.1086.
- [219] Patil R, Raheja DK, Nair L, Deshpande A, Mittal A. The Power of Psychological Safety: Investigating its Impact on Team Learning, Team Efficacy, and Team Productivity. *TOPSYJ* 2023; 16(1). doi: 10.2174/18743501-v16-230727-2023-36.
- [220] Bertl M, Ross P, Draheim D. Systematic AI Support for Decision-Making in the Healthcare Sector: Obstacles and Success Factors. *Health Policy and Technology* 2023; 12(3): 100748. doi: 10.1016/j.hlpt.2023.100748.
- [221] Kamel Rahimi A, Pienaar O, Ghadimi M, *et al.* Implementing AI in Hospitals to Achieve a Learning Health System: Systematic Review of Current Enablers and Barriers. *J Med Internet Res* 2024; 26: e49655. doi: 10.2196/49655.
- [222] Bundesministerium für Gesundheit. Gesundheitsdatennutzungsgesetz (GDNG); 2025 [Stand: 01.04.2026]. Verfügbar unter: <https://www.bundesgesundheitsministerium.de/ministerium/gesetze-und-verordnungen/guv-20-lp/gesundheitsdatennutzungsgesetz.html>.
- [223] Ortega-Calvo AS, Morcillo-Jimenez R, Fernandez-Basso C, Gutiérrez-Batista K, Vila M-A, Martin-Bautista MJ. AIMDP: An Artificial Intelligence Modern Data Platform. Use case for Spanish national health service data silo. *Future Generation Computer Systems* 2023; 143: 248–64. doi: 10.1016/j.future.2023.02.002.
- [224] Ghassemi M, Oakden-Rayner L, Beam AL. The false hope of current approaches to explainable artificial intelligence in health care. *Lancet Digit Health* 2021; 3(11): e745–e750. doi: 10.1016/S2589-7500(21)00208-9.
- [225] Mirzaei S, Mao H, Al-Nima RRO, Woo WL. Explainable AI Evaluation: A Top-Down Approach for Selecting Optimal Explanations for Black Box Models. *Information* 2024; 15(1): 4. doi: 10.3390/info15010004.
- [226] Amann J, Blasimme A, Vayena E, Frey D, Madai VI. Explainability for artificial intelligence in healthcare: a multidisciplinary perspective. *BMC Med Inform Decis Mak* 2020; 20(1): 310. doi: 10.1186/s12911-020-01332-6.
- [227] Fernandez ME, Hoor GA ten, van Lieshout S, *et al.* Implementation Mapping: Using Intervention Mapping to Develop Implementation Strategies. *Front Public Health* 2019; 7: 158. doi: 10.3389/fpubh.2019.00158.
- [228] Powell BJ, Waltz TJ, Chinman MJ, *et al.* A refined compilation of implementation strategies: results from the Expert Recommendations for Implementing Change (ERIC) project. *Implement Sci* 2015; 10: 21. doi: 10.1186/s13012-015-0209-1.

- [229] Wang J, Misra S, Jadeja R, Mittal M. Practical Approaches to Agile Project Management. IGI Global 2024.
- [230] Stanford University. Stanford center for professional development; 2025 [Stand: 01.04.2026]. Verfügbar unter: <https://online.stanford.edu/>.
- [231] Harvard University. Artificial Intelligence in Medicine Program; 2025 [Stand: 01.04.2026]. Verfügbar unter: <https://aim.hms.harvard.edu/>.
- [232] Shuster SM, Lubben N. The uneven consequences of rapid organizational change: COVID-19 and healthcare workers. Soc Sci Med 2022; 315: 115512. doi: 10.1016/j.socscimed.2022.115512.