

Vorgehen in KI- und ML-Projekten und Gründe für ihr Scheitern

Analyse phasenspezifischer Herausforderungen

Andreas Duschik, Matthias Goeken - Hochschule der Deutschen Bundesbank

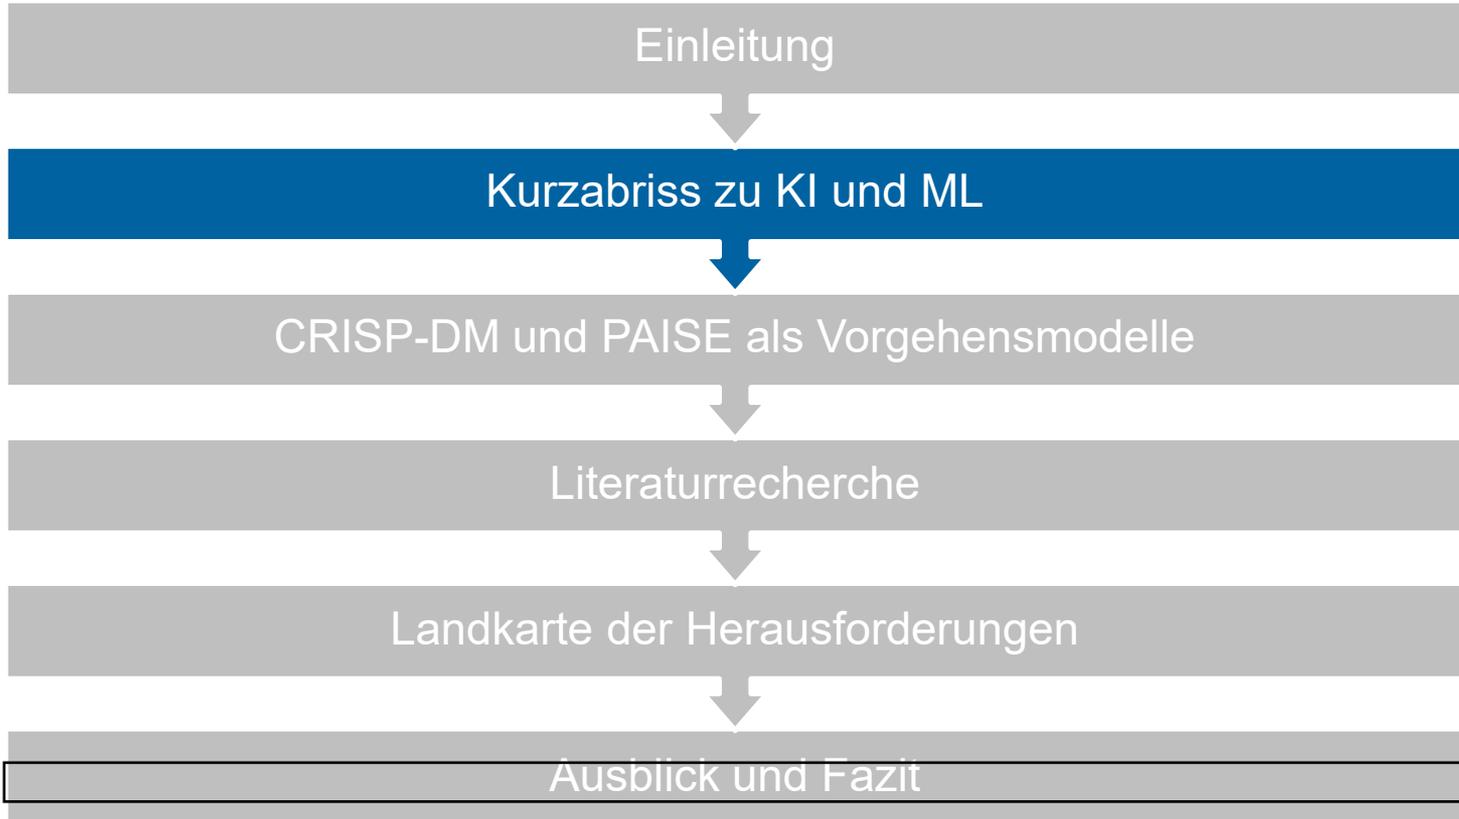
Agenda



Einleitung

- Beeindruckender **Anstieg des Reifegrades** von Machine-Learning (ML) und KI-Methoden und -Algorithmen in den letzten Dekaden (ChatGPT als allgemein verfügbares, populäres Beispiel)
- Gleichzeitig ist ein relativ **häufiges Scheitern von KI-/ML-Projekten** beobachtbar, wobei weniger die technische Machbarkeit im Vordergrund steht, sondern **viele Gründe für das Scheitern aus dem Bereich des Vorgehens- und/oder im Projektmanagements stammen** [St+21]
- De-facto-Standard CRISP-DM (Cross Industry Standard Process for Data Mining) stellt seit über 20 Jahren ein Vorgehensmodell für die Entwicklung von ML- und KI-Anwendungen dar
 - Es ist jedoch zu vermuten, dass CRISP-DM und alternative **Vorgehensmodelle nicht alle relevanten Hemmnisse und Herausforderungen adäquat adressieren**
- Ziel der Arbeit: **Identifikation von Ansatzpunkten für eine Weiterentwicklung und Verbesserung von Vorgehensmodellen** → Interpretation der Gründe für das Scheitern als relevante Ansatzpunkte im Sinne der Erklärenden Designtheorie

Agenda



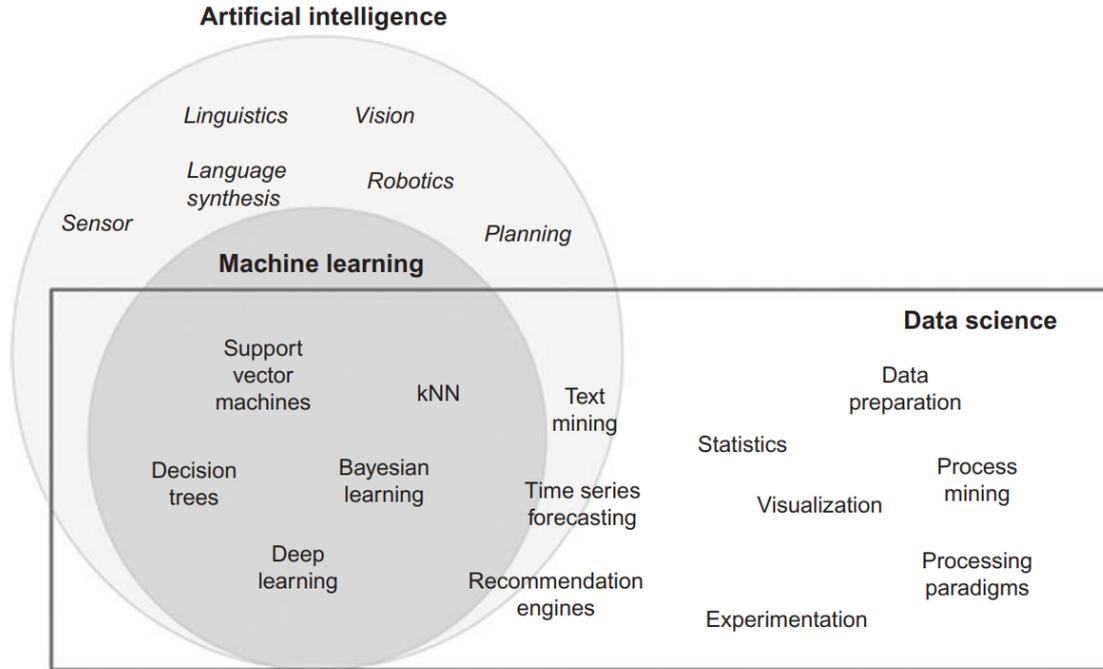
KI

“Die Simulation kognitiver, intelligenter Fähigkeiten mit Hilfe technischer Hilfsmittel.”

ML

“Die Fähigkeit von Maschinen, anhand von Trainingsdaten und mathematisch-statistischen Methoden unabhängige Vorhersagen zu treffen”.

Abgrenzungsversuch AI, ML und DS



[KD19, S. 3]

Agenda



Vorgehensmodelle

Da **kein systematischer Review** durchgeführt wurde (hierzu bsplw. Kutzias et al. mit “Comparative Analysis of Process Models for Data Science Projects”), wurden **zwei Vorgehensmodelle für ML bzw. KI** gewählt, die ein **mögliches Spektrum** aufzeigen:

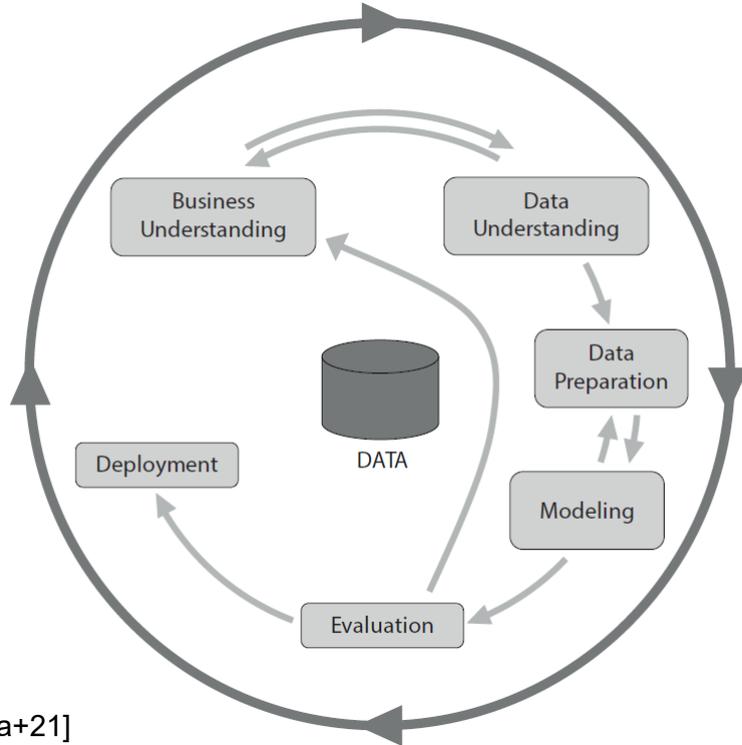
CRISP-DM/-ML

- Hat neben dem Prozess des Knowledge Discovery in Database (KDD) von Fayyad et al. die weiteste Verbreitung
- „de facto standard“ (u.a. Studer et al. 21)
- für ML adaptiert
- Focus auf ML und Data Science

PAISE

- Betrachtet die Entwicklung und den Betrieb von KI-basierten Systemlösungen
- Kombiniert Vorgehensweisen des klassischen System Engineerings und der datengetriebenen Modellbildung
- Focus auf Modularität

CRISP-DM/-ML

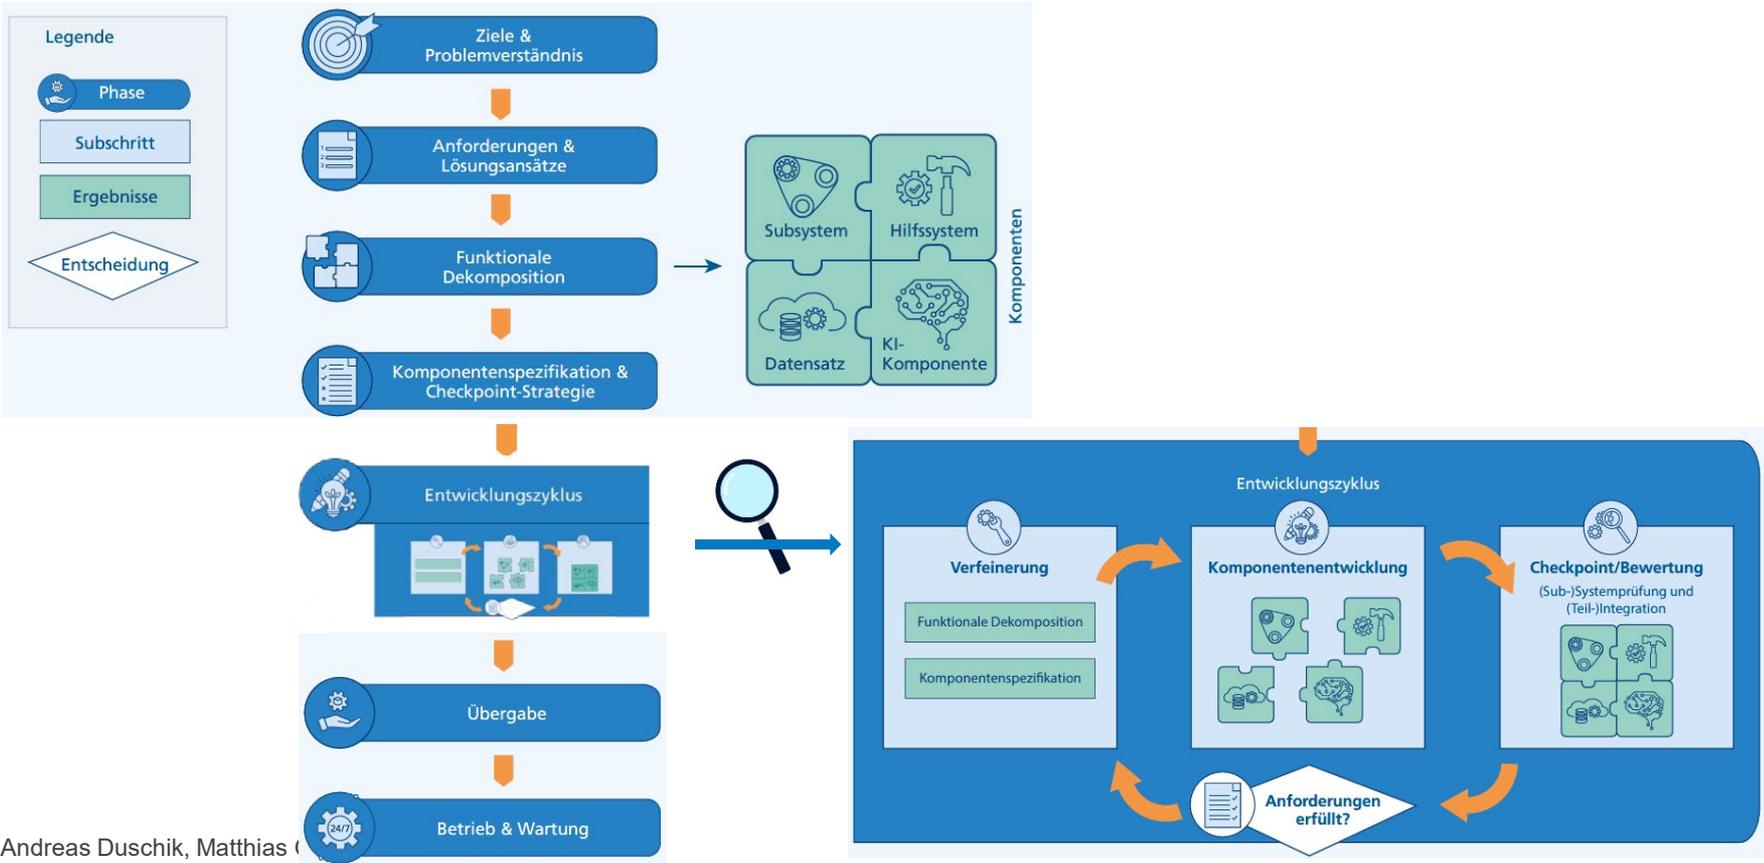


[Ha+21]

CRISP-ML(Q)	CRISP-DM
Business and Data Understanding	Business Understanding Data Understanding
Data Preparation	Data Preparation
Modeling Evaluation Deployment <u>Monitoring & Maintenance</u>	Modeling Evaluation Deployment -

[St+21]

Sequenzieller Ablauf von PAISE



Agenda



Literaturrecherche

	Baier et al.	Bauer et al.	Jöhnk et al.	Hamm et al.
Jahr	2019	2020	2021	2021
Focus	ML-Projektdurchführung, grober Ablauf und Kategorisierung	Relevanz der Faktoren in Abhängigkeit von der Größe eines Unternehmens	Bereitschaftsfaktoren von Unternehmen in Bezug auf KI	Strukturierung der positiv / negativ korrelierten Faktoren nach dem TOE-Framework
Datenquellen	Elf halbstrukturierte Interviews mit ML-Praktikern	Siebzehn Studien mit insgesamt 32300 Befragten	Halbstrukturierte Interviews mit 25 KI-Experten	Systematische Literaturrecherche mit 13 Studien im Endergebnis

Literaturrecherche

	Miller	Westenberger et al.	Merhi
Jahr	2022	2022	2023
Focus	Untersuchung von Erfolgsfaktoren hinsichtlich konkreter Aspekte des ethischen Verhaltens	Trennung der Gründe für das Scheitern von bloßen Herausforderungen + Kategorisierung	Gewichtung der Faktoren untereinander + Kategorisierung
Datenquellen	Systematische Literaturrecherche mit 55 Studien im Endergebnis	Drei erstgenannte Studien und neue Expertenbefragungen	Abgleich von sechs Studien und vier Praxisberichten

Reasons for the failure of AI projects and challenges

Organisation

Prozess

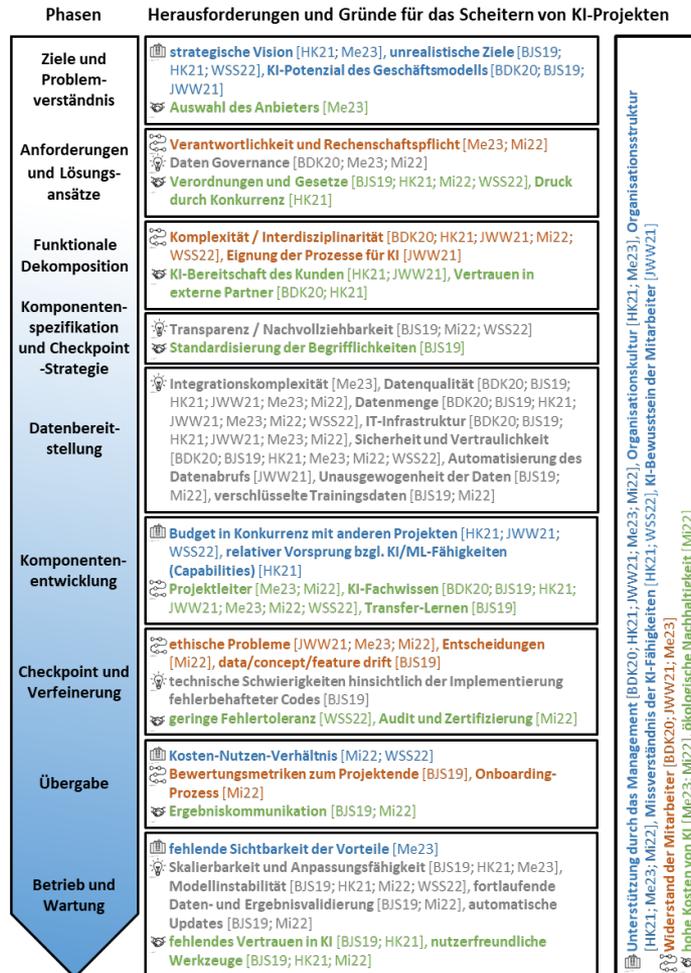
<p>Strategische Vision, unrealistische Ziele, KI-Potenzial des Geschäftsmodells, Budget in Konkurrenz mit anderen Projekten, relativer Vorsprung bzgl. KI/ML-Fähigkeiten (Capabilities), Kosten-Nutzen-Verhältnis, fehlende Sichtbarkeit der Vorteile, Unterstützung durch das Management, Organisationskultur, Organisationsstruktur, Missverständnis der KI-Fähigkeiten, KI-Bewusstsein der Mitarbeiter</p>	<p>Verantwortlichkeit und Rechenschaftspflicht, Komplexität / Interdisziplinarität, Eignung der Prozesse für KI, Projektleiter, KI-Fachwissen, Transfer-Lernen, ethische Probleme, Entscheidungen, data/concept/feature drift, Bewertungsmetriken zum Projektende, Onboarding-Prozess, Widerstand der Mitarbeiter</p>
<p>Governance, Transparenz / Nachvollziehbarkeit, Integrationskomplexität, Datenqualität, Datenmenge, IT-Infrastruktur, Sicherheit und Vertraulichkeit, Automatisierung des Datenabrufs, Unausgewogenheit der Daten, verschlüsselte Trainingsdaten, technische Schwierigkeiten hinsichtlich der Implementierung fehlerbehafteter Codes, Skalierbarkeit und Anpassungsfähigkeit, Modellinstabilität, fortlaufende Daten- und Ergebnisvalidierung, automatische Updates</p>	<p>Auswahl des Anbieters, Verordnungen und Gesetze, Druck durch Konkurrenz, KI-Bereitschaft des Kunden, Vertrauen in externe Partner, Standardisierung der Begrifflichkeiten, Projektleiter, KI-Fachwissen, Transfer-Lernen, geringe Fehlertoleranz, Audit und Zertifizierung, Ergebniskommunikation, fehlendes Vertrauen in KI, nutzerfreundliche Werkzeuge, hohe Kosten von KI, ökologische Nachhaltigkeit</p>

Technologie

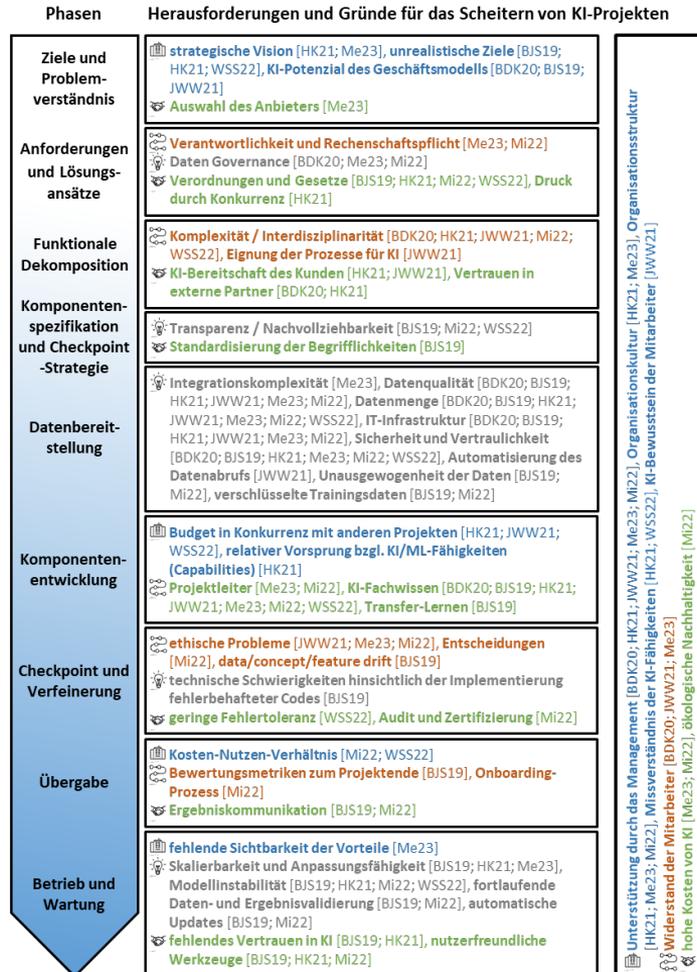
Umfeld

Agenda





Entwicklungszyklus



📄 Unterstützung durch das Management [BDK20; HK21; JWW21; Me23; Mi22], Organisationskultur [HK21; Me23], Organisationsstruktur [HK21; Me23; Mi22], Missverständnis der KI-Fähigkeiten [HK21; WSS22], KI-Bewusstsein der Mitarbeiter [JWW21]

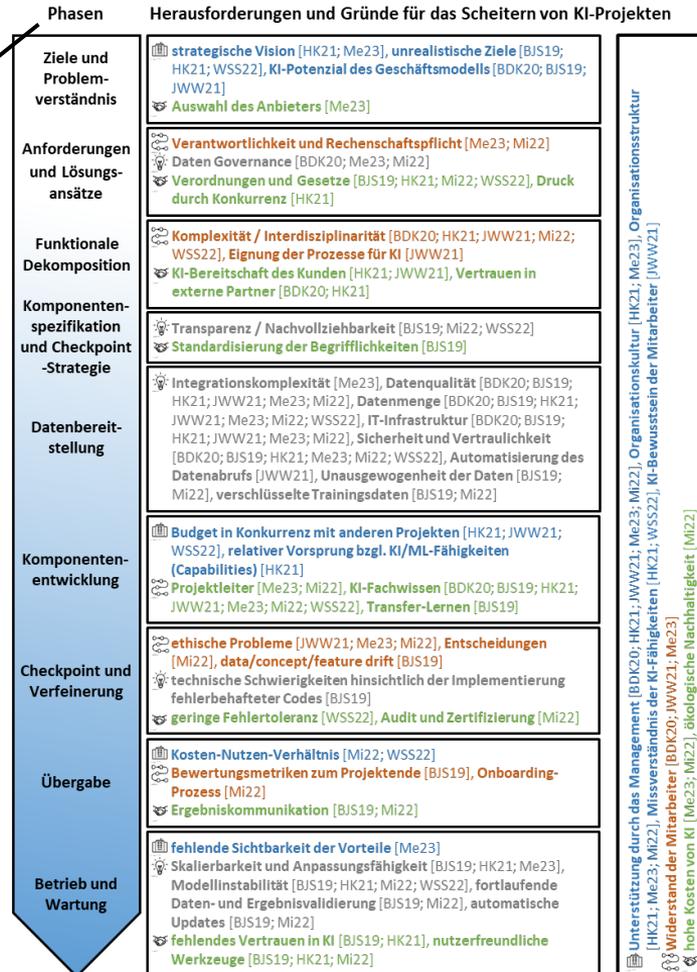
👤 **Widerstand der Mitarbeiter** [BDK20; JWW21; Me23]

👤 **hohe Kosten von KI** [Me23; Mi22], **ökologische Nachhaltigkeit** [Mi22]

Landkarte

Es gibt in jeder Phase Gründe für das Scheitern

Entwicklungszyklus



🏠 Unterstützung durch das Management [BDK20; HK21; JWW21; Me23; Mi22], Organisationskultur [HK21; Me23], Organisationsstruktur [HK21; Me23; Mi22], Missverständnis der KI-Fähigkeiten [HK21; WSS22], KI-Bewusstsein der Mitarbeiter [JWW21]

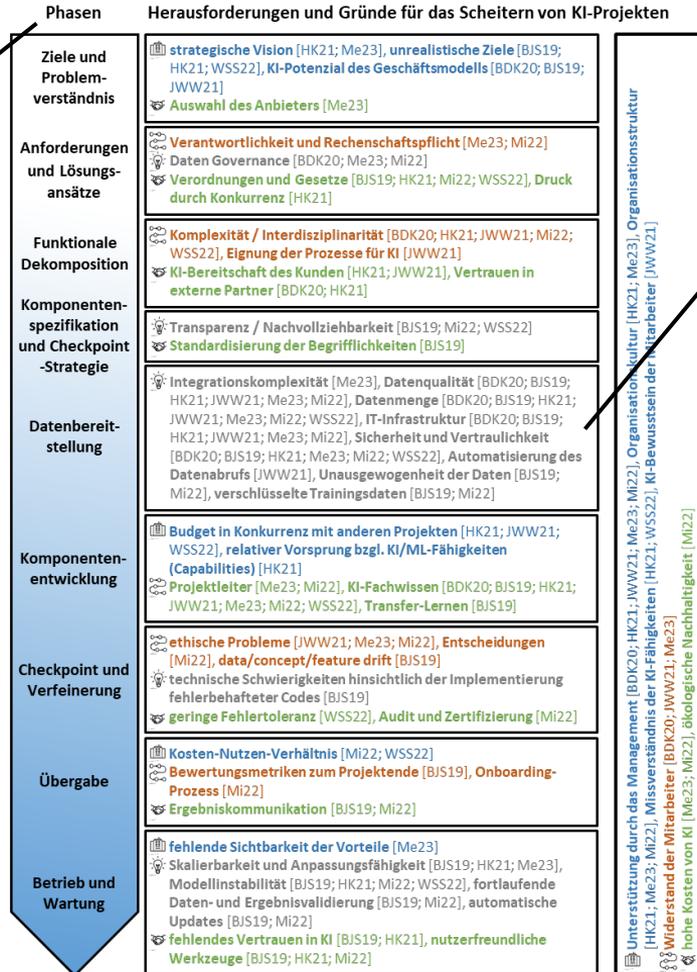
👤 **Widerstand der Mitarbeiter** [BDK20; JWW21; Me23]

👤 **hohe Kosten von KI** [Me23; Mi22], **ökologische Nachhaltigkeit** [Mi22]

Landkarte

Es gibt in jeder Phase Gründe für das Scheitern

Entwicklungszyklus



🏠 Unterstützung durch das Management [BDK20; HK21; JWW21; Me23; Mi22], **Organisationskultur** [HK21; Me23], **Organisationsstruktur** [HK21; Me23; Mi22], **Misverständnis der KI-Fähigkeiten** [HK21; WSS22], **KI-Bewusstsein der Mitarbeiter** [JWW21]

🏠 **Widerstand der Mitarbeiter** [BDK20; JWW21; Me23]

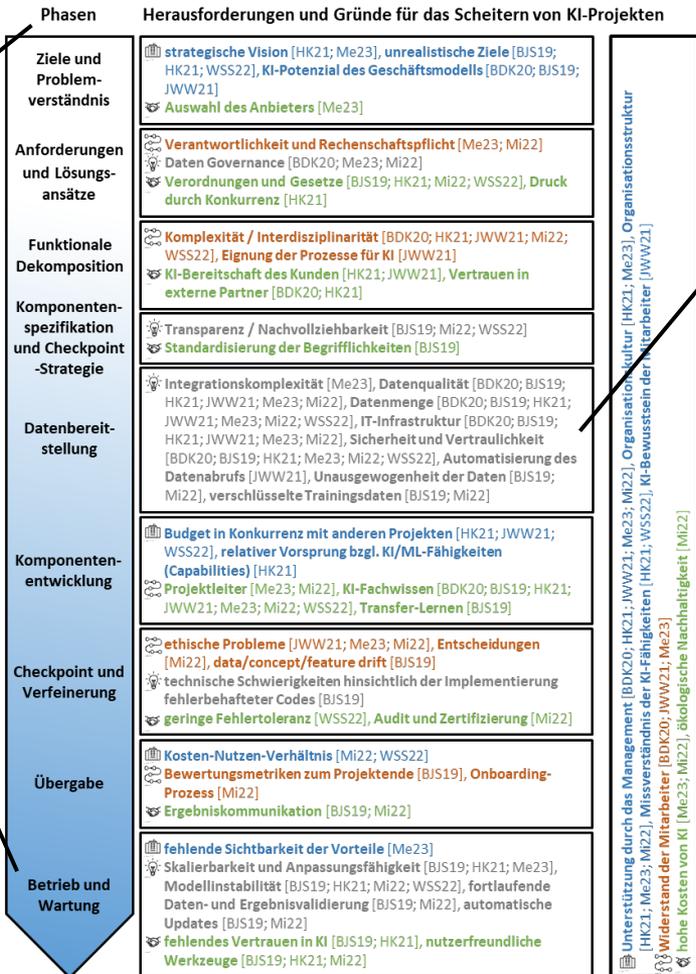
Datenbereitstellung beinhaltet die meisten und ausschließlich technische Faktoren

Landkarte

Es gibt in jeder Phase Gründe für das Scheitern

Entwicklungszyklus

Auch nach der Übergabe gibt es noch viele Herausforderungen → Besonderheit von ML-Projekten



🏠 Unterstützung durch das Management [BDK20; HK21; JWW21; Me23; Mi22], **Organisationskultur** [HK21; Me23], **Organisationsstruktur** [HK21; Me23; Mi22], **Missverständnis der KI-Fähigkeiten** [HK21; WSS22], **KI-Bewusstsein der Mitarbeiter** [JWW21]
 👤 **Widerstand der Mitarbeiter** [BDK20; JWW21; Me23]
 🏠 **hohe Kosten von KI** [Me23; Mi22], **ökologische Nachhaltigkeit** [Mi22]

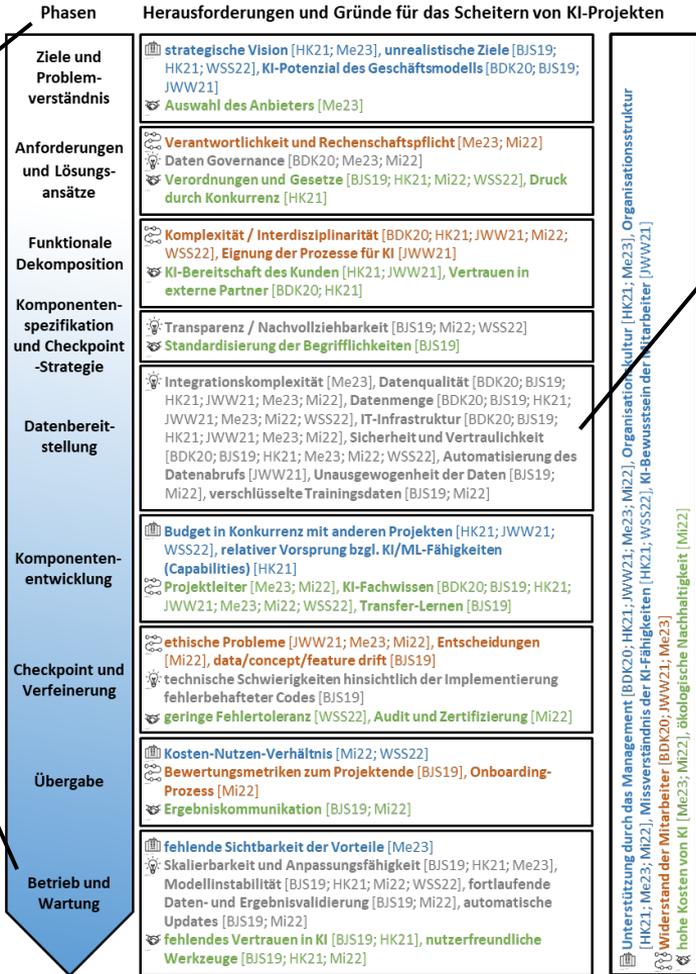
Datenbereitstellung beinhaltet die meisten und ausschließlich technische Faktoren

Landkarte

Es gibt in jeder Phase Gründe für das Scheitern

Entwicklungszyklus

Auch nach der Übergabe gibt es noch viele Herausforderungen → Besonderheit von ML-Projekten



Datenbereitstellung beinhaltet die meisten und ausschließlich technische Faktoren

Viele Faktoren lassen sich nicht einer bestimmten Phase zuordnen

Agenda



- **Limitationen**

- Selektive Literaturlauswahl bei den Gründen für das Scheitern
- Kein systematischer Abgleich, inwieweit vorhandene Vorgehensmodelle die identifizierten Faktoren bereits adressieren

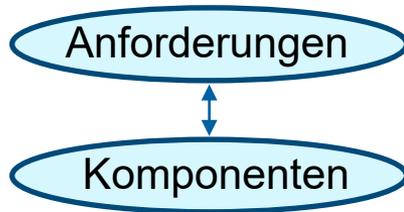
- **Anknüpfende Forschungsarbeiten**

- Aufgreifen der Ansatzpunkte für eine Weiterentwicklung von Vorgehensmodellen in der KI-/ML-Domäne → Gestaltungsorientierung
- Evaluation der im Folgenden skizzierten Vorgehensweise auf ihren praktischen Nutzen, die Forschungsmethodik und ihre Machbarkeit

Weiteres Vorgehen

- **Diskrepanz zwischen Realität und Wunschzustand**
 - Identifizierte Herausforderungen zeigen, dass es eine Diskrepanz hinsichtlich des gewünschten und dem tatsächlichen Zustand gibt
- **Übersetzung in Anforderungen**
 - Notwendigkeit, im Rahmen der Problemlösung Herausforderungen in Anforderungen für verbesserte Modelle zu übersetzen

- **Designtheorie-Grundlagen**



- „Anforderungen spezifizieren (und erklären) die Grundlagen der Komponenten. Komponenten werden durch die Anforderungen legitimiert“ [BP10, S. 263].

- **Anwenden der Designtheorie**

- Anforderungen an ein verbessertes Vorgehensmodell lassen sich durch „Design Guidelines“ (als allgemeine Komponente) legitimieren
- Erweiterung und Konkretisierung der Anforderungen samt Hinweis für die Gestaltung eines Artefakts (hier das Vorgehensmodell) sowie dessen Erreichung (Aktionen und Maßnahmen)
- Es ergibt sich folgende Kaskade:

Grund für das Scheitern → Anforderungen → Design Guidelines →
Lösungskomponenten

Weiteres Vorgehen – Demonstration der Kaskade

Grund für Scheitern / Herausforderung	Fehlende KI-Bereitschaft („AI Readiness“) – verstanden als die Fähigkeit einer Organisation zur Generierung von Wertbeiträgen aus KI sowie den Willen einer Organisation, die erforderlichen technischen, personellen und kulturellen Voraussetzungen zu schaffen, um KI-Technologien zu verstehen, zu implementieren und zu nutzen.
Allgemeine Anforderung	Eine Organisation sollte in einem angemessenen Maße über KI-Bereitschaft verfügen (wobei das „angemessene Maß“ von einer Vielzahl Faktoren determiniert wird – u.a. der Komplexität des geplanten KI-Vorhabens).
Design Guidelines als allgemeine Komponente	Ein Vorgehensmodell für ML und KI sollte (1) die Fähigkeit einer Organisation, KI erfolgreich einzusetzen und davon zu profitieren, evaluieren und bewerten; (2) die Komplexität eines geplanten KI-Vorhabens evaluieren und bewerten; (3) in einer Gap-Analyse die Ergebnisse von (1) und (2) gegenüberstellen.
Aktivitäten, Techniken, etc. in Vorgehensmodellen als konkrete (Lösungs-) Komponenten	Für die Evaluierung und Bewertung der KI-Bereitschaft einer Organisation und der Komplexität eines KI-Vorhabens lassen sich verschiedene Instrumente nutzen, mit denen entlang mehrerer Dimensionen bspw. die Reife/„Readiness“ einer Organisation als Reifegradmodell oder als „Scorecard for the AI readiness framework“ gemessen und dargestellt werden kann [Ho22].

„Ziel der Arbeit war es, Ansatzpunkte aufzuzeigen, ein mögliches Vorgehen zu skizzieren und diese Überlegungen zur **Diskussion** zu stellen.“

Quellen

- Baier, L.; Jöhren, F.; Seebacher, S.: Challenges in the Deployment and Operation of Machine Learning in Practice. In: 27th European Conference on Information Systems - Information Systems for a Sharing Society, ECIS 2019.
- Bauer, M.; van Dinther, C.; Kiefer, D.: Machine Learning in SME: An Empirical study on Enablers and Success Factors In: 26th Americas Conference on Information Systems, AMCIS 2020.
- Baskerville, R.; Pries-Heje, J.: Erklärende Designtheorie. In: Wirtschaftsinformatik 5/52, 2010, S. 259 - 271.
- CC-KING (Kompetenzzentrum KI-Engineering): PAISE Das Vorgehensmodell für KI-Engineering, Whitepaper, Online verfügbar unter: <https://www.ki-engineering.eu/de/wissen-tools/paise.html>, Zugriff am 10.04.2023.
- Goeken, Matthias: Künstliche Intelligenz, maschinelles Lernen und Data Science - ein Überblick über Grundlagen, Elemente und Governance-Herausforderungen, in: IT-Governance, Ausgabe 34/2021, S. 3 - 11.
- Haneke, Uwe et al.: Grundlagen, Architekturen und Anwendungen. Heidelberg, 2021.
- Jöhnk, J.; Weißert, M.; Wyrtki, K.: Ready or Not, AI Comes— An Interview Study of Organizational AI Readiness Factors. Business & Information Systems Engineering 1/63, 2021, S. 5 - 20.
- Kotu, V.; Deshpande, B.: Data science. Concepts and practice. Morgan Kaufmann Publishers, Cambridge, MA, 2019, S. 3.
- Merhi, M. I.: An evaluation of the critical success factors impacting artificial intelligence implementation. In: International Journal of Information Management 69, 2023.
- Westenberger, J.; Schuler, K.; Schlegel, D.: Failure of AI projects: understanding the critical factors. In: Procedia Computer Science 196, 2022, S. 69 - 76.