

www.iu.de

IU DISCUSSION

PAPERS

BUSINESS & MANAGEMENT

KI-Impact-Scoring als Entscheidungsinstrument:
Eine Priorisierungsmatrix zur Bewertung beliebiger KI-
Anwendungen entwickelt am Use Case User Experience
in Onlineshops

NICO LANGE
MARCEL DULGERIDIS
JENS CORNELSEN

IU Internationale Hochschule

Main Campus: Erfurt

Juri-Gagarin-Ring 152

99084 Erfurt

Telefon: +49 421.166985.23

Fax: +49 2224.9605.115

Kontakt/Contact: kerstin.janson@iu.org

Autorenkontakt/Contact to the author(s):

Prof. Dr. Marcel Dulgeridis

ORCID-ID: 0009-0009-4248-3067 (Open Researcher und Contributor ID)

E-Mail: marcel.dulgeridis@iu.org

IU Internationale Hochschule - Campus Regensburg

Johanna-Kinkel-Straße 3+4

93049 Regensburg

IU Discussion Papers, Reihe: Human Resources, Vol. 7, No. 14 (JUL 2026)

ISSN: 2750-0721

<https://doi.org/10.56250/4140>

Website: <https://repository.iu.org>

KI-IMPACT-SCORING ALS ENTSCHEIDUNGSINSTRUMENT: EINE PRIORISIERUNGSMATRIX ZUR BEWERTUNG BELIEBIGER KI- ANWENDUNGEN - ENTWICKELT AM USE CASE USER EXPERIENCE IN ONLINESHOPS

NICO LANGE

MARCEL DULGERIDIS

JENS CORNELSEN

ABSTRACT

Artificial intelligence applications increasingly promise efficiency gains, personalization, automation and improved user experiences. For medium-sized companies, however, the challenge is less the existence of potential use cases than the ability to prioritize them under resource constraints, heterogeneous data maturity and regulatory uncertainty. Building on a bachelor thesis on AI-supported user experience in online shops, this discussion paper reframes the developed prioritization matrix as a generic AI Impact Scoring Tool that can be applied to virtually any AI initiative.

The proposed tool combines a value axis, a feasibility axis and a scenario-based sensitivity analysis. It draws on user-experience theory, technology acceptance, stimulus-organism-response reasoning, multi-criteria utility analysis and design-oriented model development. The e-commerce use case serves as a blueprint: AI-generated product imagery, personalized product recommendations and AI-based interaction systems are assessed to illustrate how different AI applications can be positioned as quick wins, strategic investments, experimental options or deprioritized initiatives.

The central contribution lies in making AI investment decisions more transparent, comparable and adaptable. Rather than providing a one-time ranking, the model offers a reusable governance and decision framework for management teams that need to evaluate changing AI opportunities over time.

KEYWORDS:

Artificial Intelligence; AI Governance; User Experience; E-Commerce; Prioritization Matrix; Utility Analysis; Sensitivity Analysis; Medium-Sized Enterprises

AUTOREN



Nico Lange studiert E-Commerce an der IU Internationalen Hochschule. Seine fachlichen Schwerpunkte liegen in den Bereichen Künstliche Intelligenz, E-Commerce, User Experience und Digital Marketing. Beruflich ist er im Performance Marketing tätig. Im Rahmen seiner Bachelorarbeit entwickelte er eine Priorisierungsmatrix zur Bewertung von KI-Anwendungen im E-Commerce.



Prof. Dr. Marcel Dulgeridis ist Professor für Betriebswirtschaftslehre am Standort Regensburg sowie Gründer und CFO. Nach zehn Jahren in führenden Positionen bei Banken und Big-Four-Gesellschaften bringt er zudem umfangreiche Erfahrung aus Wirtschaftsprüfung, Beratung und Finanzwirtschaft mit.



Prof. Dr. Jens Cornelsen ist Professor für Betriebswirtschaftslehre an der IU Internationale Hochschule (Standort Nürnberg). Neben seinen umfangreichen Erfahrungen in akademischer Lehre & wissenschaftlicher Forschung berät er nationale und internationale Kunden zu Themen wie Market Intelligence, Big Data und Nachhaltigkeit. Für seine Dissertation „Kundenwertanalysen im Beziehungsmarketing“ wurde er mit dem Wissenschaftspreis des deutschen Marketing-Verbandes ausgezeichnet. Jens ist Beirat der Nachhaltigkeitsorganisation blue life, Hamburg, und zudem Vizepräsident des Marketing Excellence Centers (MEX) in Nürnberg.

Einleitung: Von KI-Potenzialen zu belastbaren Entscheidungen

Der Diskurs über künstliche Intelligenz in Unternehmen ist stark von Potenzialbeschreibungen geprägt. KI kann Inhalte generieren, Empfehlungen personalisieren, Serviceprozesse automatisieren, Entscheidungen vorbereiten und Interaktionen mit Kund:innen dynamischer gestalten. Gerade im E-Commerce ist diese Entwicklung besonders sichtbar, weil digitale Touchpoints datenreich, messbar und häufig unmittelbar mit betriebswirtschaftlichen Kennzahlen wie Conversion Rate, Warenkorbwert, Wiederkaufswahrscheinlichkeit oder Supportkosten verbunden sind (Gast, 2018, S. 47-48; Harwardt & Köhler, 2023; Savastano, 2025, S. 2074-2093). Für mittelständische Unternehmen entsteht daraus jedoch nicht automatisch ein Investitionspfad. Vielmehr wächst mit jeder neuen Anwendung die Frage, welche KI tatsächlich Wert stiftet, welche organisatorisch beherrschbar ist und welche Risiken eine Einführung begrenzen.

Die Ausgangsproblematik lässt sich daher präziser als Bewertungsproblem fassen. Mittelständische Onlineshop-Betreiber stehen unter Wettbewerbsdruck, verfügen aber häufig nicht über die Ressourcen großer Plattformunternehmen. Produkte, Preise und Lieferoptionen werden zunehmend vergleichbar, sodass die User Experience als Differenzierungsfaktor an Bedeutung gewinnt (Gast, 2018, S. 13-16; Pröpsting, 2022, S. 321; Rock, 2022a, S. 47-64). Gleichzeitig ist KI-Einsatz kein Selbstzweck. Eine Anwendung kann technisch beeindruckend sein, aber an Datenqualität, Integration, Datenschutz, Akzeptanz, Kosten oder fehlender Prozessreife scheitern (Aichele, 2022a; Müller, 2022; Ulrich & Bachlechner, 2020, S. 53-58). Damit verschiebt sich die Managementfrage von „Welche KI ist möglich?“ zu „Welche KI ist unter unseren Zielen, Ressourcen und Risiken zuerst sinnvoll?“

Die zugrunde liegende Abschlussarbeit adressiert diese Lücke durch eine literaturbasierte und flexibel gewichtbare Priorisierungsmatrix, die KI-Anwendungen nach Nutzen und Realisierbarkeit bewertet. Sie zeigt am Beispiel von drei E-Commerce-Anwendungsfällen, dass eine kriterienbasierte Bewertung nicht nur Quick Wins sichtbar macht, sondern auch strategische Investitionen von intuitiven Bauchentscheidungen trennt (Lange, 2026). Das vorliegende Discussion Paper greift diesen Ansatz auf und schärft den zentralen USP: Die Matrix ist nicht nur ein Modell für Onlineshops, sondern ein generisches KI-Impact-Scoring-Tool, das grundsätzlich auf beliebige KI-Anwendungen übertragen werden kann, sofern Bewertungskriterien, Gewichtungen und Szenarien explizit definiert werden.

Kernaussage

Der Beitrag des Papers liegt nicht in der isolierten Bewertung von Nano Banana, Stylitics oder Cognigy. Diese Beispiele dienen nur als Demonstrator. Der eigentliche Beitrag ist ein übertragbares Bewertungsinstrument für KI-Entscheidungen: Wertbeitrag x Umsetzbarkeit x Szenariorobustheit.

Die Forschungsfrage lautet daher: Wie kann ein generisches, wissenschaftlich fundiertes KI-Impact-Scoring-Tool gestaltet werden, mit dem Unternehmen beliebige KI-Anwendungen systematisch bewerten, priorisieren und mithilfe von Sensitivitätsanalysen unter unterschiedlichen Zielsetzungen robust einordnen können? Der E-Commerce-Use-Case dient als Blaupause, weil sich dort der Zusammenhang zwischen Nutzererlebnis, ökonomischem Wert und technischer Umsetzbarkeit besonders gut operationalisieren lässt (Davis, 1989; Thüring & Mahlke, 2007; Kühnapfel, 2021).

Theoretischer Bezugsrahmen: Wert, Akzeptanz und Entscheidungslogik

Die Bewertung von KI-Anwendungen erfordert eine Verbindung mehrerer theoretischer Perspektiven. Für den E-Commerce-Use-Case bildet die User Experience den Ausgangspunkt. UX beschreibt nicht nur funktionale Bedienbarkeit, sondern das gesamte Erleben einer Person während der Interaktion mit einem digitalen System. Neben Effektivität und Effizienz sind ästhetische, emotionale und vertrauensbezogene Aspekte relevant (Gast, 2018, S. 13-22; Thüring & Mahlke, 2007, S. 253-264). Genau daraus ergibt sich eine erste Bewertungsdimension: Eine KI-Anwendung ist nicht allein danach zu beurteilen, ob sie technisch funktioniert, sondern ob sie die aufgabenbezogene und nicht-aufgabenbezogene Qualität der Interaktion verbessert.

Das Components-of-User-Experience-Modell von Thüring und Mahlke trennt pragmatische Qualitäten, hedonische Qualitäten und emotionale Reaktionen (Thüring & Mahlke, 2007, S. 255). Für eine Priorisierung von KI-Anwendungen ist diese Unterscheidung besonders relevant: Empfehlungssysteme können die Zielerreichung verbessern, weil sie passende Produkte schneller sichtbar machen; KI-generierte Produktbilder können hedonische Qualität und Inspiration erhöhen; Chatbots oder Agentic-AI-Systeme können Unsicherheit reduzieren, wenn sie schnell, zuverlässig und verständlich unterstützen. Der strategische Wert einer KI-Anwendung sollte daher sowohl funktionale Effekte als auch Erlebnis- und Vertrauenseffekte abbilden (Gast, 2018; Hu & Lee, 2026; Tanase et al., 2025).

Ergänzend erklärt das Technologieakzeptanzmodell, warum objektiver Nutzen allein nicht ausreicht. Nach Davis hängen Akzeptanz und Nutzungsintention insbesondere von wahrgenommener Nützlichkeit und wahrgenommener Benutzerfreundlichkeit ab (Davis, 1989, S. 319-340). Auf KI-Anwendungen übertragen bedeutet dies: Eine Lösung kann eine hohe technische Leistungsfähigkeit besitzen, aber geringe Akzeptanz erzeugen, wenn sie als intransparent, kompliziert, invasiv oder schwer kontrollierbar wahrgenommen wird. Für das Scoring-Tool wird der TAM-Gedanke daher erweitert: Neben „perceived usefulness“ und „perceived ease of use“ ist für Unternehmen vor allem eine operative „ease of integration“ entscheidend, also die Frage, wie gut sich eine KI in bestehende Daten, Systeme, Prozesse und Kompetenzen integrieren lässt (Ulrich & Bachlechner, 2020; Müller, 2022).

Als verbindendes Erklärungsmodell eignet sich zudem die Stimulus-Organism-Response-Logik. KI-Anwendungen wirken als Stimuli, die Wahrnehmungen, Emotionen und Vertrauen auf Nutzerseite beeinflussen; diese inneren Reaktionen prägen anschließend Verhalten wie Kaufabsicht, Conversion, Loyalität oder Abbruch (Woodworth, 1929; Hu & Lee, 2026). Für ein generisches KI-Scoring ist diese Logik auch außerhalb des E-Commerce nutzbar: In HR-Systemen, Controlling-Prozessen, Kundenservice, Produktentwicklung oder Compliance erzeugt KI einen Stimulus, verändert Wahrnehmungen und Arbeitsweisen und führt zu organisationalen Outcomes. Die Matrix kann deshalb branchenübergreifend verwendet werden, wenn die Wertdimension je Kontext angepasst wird.

Die methodische Entscheidung für eine multikriterielle Nutzwertanalyse folgt aus der Heterogenität der Bewertungskriterien. KI-Initiativen lassen sich selten anhand einer einzigen Kennzahl vergleichen, weil monetärer Nutzen, UX-Effekt, Datenverfügbarkeit, technische Integrationsfähigkeit, rechtliche Risiken und strategische Skalierbarkeit unterschiedliche Bewertungslogiken besitzen (Kühnapfel, 2021; Ulrich

& Bachlechner, 2020). Die Nutzwertanalyse übersetzt diese Kriterien in vergleichbare Punktwerte und erlaubt Gewichtungen. Dadurch wird nicht behauptet, dass komplexe Managemententscheidungen vollständig objektiv wären; vielmehr werden Annahmen explizit gemacht und dadurch diskutierbar.

Ebene	Leitfrage	Theoretischer Bezug	Übertragung in das Tool
Wertbeitrag	Welche Wirkung erzeugt die KI?	CUE-Modell, UX-Forschung, S-O-R	Strategischer Wert, Kundennutzen, Effizienz, Differenzierung
Akzeptanz	Wird die Anwendung angenommen und verständlich genutzt?	TAM	Nützlichkeit, Bedienbarkeit, Transparenz, Vertrauen
Umsetzbarkeit	Kann die Anwendung integriert und betrieben werden?	Wirtschaftliche KI-Bewertung, Mittelsstandsforschung	Datenreife, Systemintegration, Know-how, Kosten, Betrieb
Risiko	Welche Nebenfolgen entstehen?	Governance-, Datenschutz- und Ethikperspektiven	Datenschutz, Bias, Haftung, Abhängigkeit, Kontrollierbarkeit
Robustheit	Bleibt die Priorisierung bei anderen Zielsetzungen stabil?	Sensitivitätsanalyse, Nutzwertanalyse	Szenarien, Gewichtungsvariation, Ranking-Stabilität

Tab. 1: Konzeptioneller Bezugsrahmen des KI-Impact-Scoring-Tools. Quelle: eigene Darstellung in Anlehnung an Davis (1989), Thüring & Mahlke (2007), Woodworth (1929), Kühnapfel (2021) und Ulrich & Bachlechner (2020).

Für die Entwicklung eines solchen Instruments ist ein designorientierter Forschungszugang passend. Design Science Research zielt darauf ab, ein Artefakt zu entwickeln, das ein praktisches Problem löst und zugleich theoretisch begründet ist (Carstensen & Bernhard, 2019; Takeda et al., 1990). Das KI-Impact-Scoring-Tool ist ein solches Artefakt: Es ist kein rein deskriptives Modell, sondern eine anwendbare Entscheidungslogik, die Unternehmen bei Priorisierung, Governance und Ressourcenzuteilung unterstützt.

Methodik und Artefakt: Das generische KI-Impact-Scoring-Tool

Das Paper entwickelt die bestehende Priorisierungsmatrix zu einem generischen KI-Impact-Scoring-Tool weiter. Der methodische Kern besteht aus vier Schritten: erstens der Beschreibung des KI-Anwendungsfalls, zweitens der Kriterienbewertung, drittens der Positionierung in einer Priorisierungsmatrix und viertens der Sensitivitätsanalyse. Dieses Vorgehen entspricht dem in der Abschlussarbeit dokumentierten Ablauf von Literaturrecherche, Kriterien- und Modellentwicklung, Anwendung/Bewertung und Ableitung von Handlungsempfehlungen (Lange, 2026).

Die erste Achse des Tools misst den Wertbeitrag. Im E-Commerce bedeutet dies insbesondere UX-Verbesserung, Conversion-Potenzial, Warenkorbbeffekt, Kundenbindung und Differenzierung (Gast, 2018; Savastano, 2025; Tanase et al., 2025). In anderen Bereichen kann die gleiche Achse anders operationalisiert werden: In der Rechnungslegung könnte sie etwa Fehlerreduktion, Abschlussbeschleunigung und regulatorische Qualität abbilden; im HR-Kontext könnten Candidate Experience, Passungsqualität, Time-to-Hire und Fairness im Vordergrund stehen; im Kundenservice wären First Contact Resolution, Wartezeitreduktion und Zufriedenheit relevant. Die Matrix ist damit domänenoffen, solange der strategische Wert kontextspezifisch definiert wird.

Die zweite Achse misst Umsetzbarkeit und Risikoprofil. Sie bündelt Kriterien wie Datenverfügbarkeit, Datenqualität, Systemintegration, Prozessreife, internes Know-how, Investitionsaufwand, rechtliche Anforderungen und organisatorische Akzeptanz (Aichele, 2022a; Müller, 2022; Ulrich & Bachlechner, 2020). Gerade diese Achse ist für mittelständische Unternehmen zentral, weil nicht die technologische Komplexität allein über Priorisierung entscheidet, sondern die operative Anschlussfähigkeit. Ein Tool mit mittlerem Nutzen, aber sehr hoher Integrationsfähigkeit kann als Quick Win strategisch wertvoller sein als ein Tool mit maximalem Nutzenversprechen, aber sehr hoher Implementierungshürde.

Die Bewertung erfolgt auf einer fünfstufigen Skala. Dabei werden Kriterien nicht nur addiert, sondern gewichtet. Eine Standardgewichtung kann als Ausgangspunkt dienen; sie muss jedoch an Strategie, Ressourcenlage und Risikobereitschaft des jeweiligen Unternehmens angepasst werden. Diese Flexibilität ist kein methodischer Schwachpunkt, sondern Teil des Designs: Das Modell soll nicht eine objektive Wahrheit simulieren, sondern Managementannahmen transparent machen (Kühnapfel, 2021; Döring & Bortz, 2016).

	Hohe Umsetzbarkeit / geringes Risiko	Niedrige Umsetzbarkeit / hohes Risiko
Hoher Wertbeitrag	QUICK WINS Schnell starten, Wirkung messen, salie- ren.	STRATEGISCHE INVESTITIONEN Business Case, Governance, Pilotierung und Roadmap.
Niedriger Wertbei- trag	OPTIONALE EFFIZIENZ- ODER LERN- FELDER Nur testen, wenn Lernnutzen oder Sy- nergien bestehen.	DEPRIORISIEREN Zurückstellen, beobachten oder durch Al- ternativen ersetzen.

Tab. 2: Entscheidungslogik der Matrix. Quelle: eigene Darstellung.

Die Sensitivitätsanalyse ist der eigentliche Robustheitsmechanismus. Sie beantwortet die Frage, ob eine Priorisierung nur unter einer bestimmten Gewichtung gilt oder auch dann stabil bleibt, wenn das Unternehmen andere Zielsetzungen setzt. Ein Sicherheits-Szenario kann Datenschutz, rechtliche Risiken und Kontrollierbarkeit stark gewichten. Ein Effizienz-Szenario kann Wirtschaftlichkeit, schnelle Umsetzung und Automatisierung priorisieren. Ein Wachstums-Szenario kann Conversion-Potenzial, Skalierbarkeit und Differenzierung stärker betonen. Bleibt die Einordnung einer KI-Anwendung über mehrere Szenarien stabil, steigt die Entscheidungssicherheit; kippt das Ranking, wird sichtbar, dass die Entscheidung strategisch abhängig ist.

Blaupause E-Commerce: Anwendung auf drei KI-Anwendungsfälle

Der E-Commerce-Use-Case eignet sich als Blaupause, weil KI-Anwendungen entlang der Customer Journey unterschiedliche Wirkmechanismen entfalten. Generative KI kann visuelle Produktdarstellungen erzeugen und dadurch Content-Produktion beschleunigen. Predictive AI kann Produktempfehlungen personalisieren und Cross-Selling-Potenziale erhöhen. Agentic AI bzw. KI-basierte Assistenzsysteme können Interaktionen automatisieren, Fragen beantworten und Serviceprozesse entlasten (Harwardt & Köhler, 2023; Hu & Lee, 2026; Pfliegl, 2025). Die Abschlussarbeit wendet die Matrix exemplarisch auf KI-gestützte Produktbildgenerierung, personalisierte Produktempfehlungen und KI-basierte Interaktionssysteme an (Lange, 2026).

Die KI-gestützte Produktbildgenerierung wird im Use Case als Quick Win eingeordnet. Ihr Wertbeitrag liegt insbesondere in der schnellen Erstellung von Lifestyle-Kontexten, Varianten und visuellen Produktionsszenierungen. Sie kann Produktionsaufwand reduzieren und hedonische UX-Qualitäten stärken, ohne zwingend tief in Kernprozesse eingreifen zu müssen (Amazon Ads, 2023; Loth, 2024; Potoroom, 2026). Gleichzeitig bestehen rechtliche und markenbezogene Unsicherheiten, etwa hinsichtlich Authentizität, Urheberrecht und Kennzeichnung. Im Scoring erreicht der Use Case mit $Y = 4,28$ und $X = 4,19$ sowohl einen hohen Wertbeitrag als auch eine hohe Umsetzbarkeit (Lange, 2026).

Personalisierte Produktempfehlungen werden als strategische Investition eingeordnet. Ihr Nutzen kann stark sein, weil sie Relevanz, Inspiration, Cross-Selling und Kaufwahrscheinlichkeit beeinflussen. Forschung zu personalisierten Empfehlungen zeigt, dass KI-gestützte Personalisierung Kaufabsichten und impulsive Kaufneigung beeinflussen kann, wenn sie als nützlich und vertrauenswürdig wahrgenommen wird (Hu et al., 2025; Hu & Lee, 2026). Gleichzeitig ist die Umsetzbarkeit anspruchsvoller, weil Produktdaten, Verhaltensdaten, PIM-Strukturen, Schnittstellen und kontinuierliches Monitoring erforderlich sind. Die Bewertung $Y = 4,20$ und $X = 3,22$ zeigt: hoher strategischer Wert, aber relevante Implementierungshürde (Lange, 2026). KI-basierte Interaktions- und Assistenzsysteme werden ebenfalls als strategische Investition bewertet. Sie können 24/7-Verfügbarkeit ermöglichen, Supportanfragen vorqualifizieren, Beratungssituationen simulieren und Nutzer:innen in komplexen Kaufprozessen begleiten (Dittrich, 2025; Schultz & Brüggemann, 2022). Ihre Umsetzung ist jedoch abhängig von Wissensbasis, Prozessintegration, rechtlicher Absicherung, Qualitätskontrolle und der Fähigkeit, fehlerhafte Antworten zu begrenzen. Die Bewertung $Y = 4,00$ und $X = 3,39$ positioniert diesen Anwendungsfall als wirkungsstark, aber governance- und integrationsintensiv (Lange, 2026).




Abb. 1: Priorisierungsmatrix der untersuchten KI-Anwendungsfälle. Quelle: Eigene Darstellung.

Entscheidend ist, dass diese drei Anwendungen nicht als endgültige Marktanalyse verstanden werden. Sie demonstrieren vielmehr, wie jedes Unternehmen beliebige KI-Anwendungen in dieselbe Bewertungslogik überführen kann. Ein Industriebetrieb könnte Predictive Maintenance, KI-Qualitätsprüfung und Copilot-Systeme vergleichen; eine Bank könnte KI im Meldewesen, Kundenservice oder Risikomanagement bewerten; ein HR-Bereich könnte Recruiting-Automation, Learning Analytics und Mitarbeiter-Chatbots gegenüberstellen. Die Matrix bleibt gleich, nur die Kriterienausprägungen und Gewichtungen werden kontextspezifisch angepasst.

Sensitivitätsanalyse: Vom Ranking zur robusten Entscheidung

Die Sensitivitätsanalyse ist der entscheidende Schritt, der das Tool von einer einfachen Bewertungsmatrix zu einem belastbaren Managementinstrument macht. In der Praxis sind Gewichtungen nie neutral. Ein Unternehmen in einer Wachstumsphase wird Umsatz- und Differenzierungsbeiträge anders bewerten als ein Unternehmen mit hoher regulatorischer Exposition oder begrenzten IT-Ressourcen. Deshalb sollte jede KI-Priorisierung mindestens in drei Szenarien geprüft werden: Standard, Sicherheitsfokus und Effizienzfokus. Optional können weitere Szenarien wie Wachstum, Kundenerlebnis, Nachhaltigkeit oder Kostenreduktion ergänzt werden (Kühnapfel, 2021; Ulrich & Bachlechner, 2020).

Szenario	Gewichtungslogik	Typische Frage	Entscheidungsnutzen
Baseline	Ausgewogen zwischen Wert, Umsetzbarkeit und Risiko	Welche KI ist unter normalen Annahmen attraktiv?	Ausgangspunkt für Diskussion und Portfolioentscheidung
Sicherheit & Governance	Datenschutz, Nachvollziehbarkeit, Haftung und Kontrollierbarkeit erhalten höheres Gewicht	Welche KI bleibt vertretbar, wenn Risikoaversion steigt?	Vermeidung regulatorischer und reputativer Fehlentscheidungen
Effizienz & Geschwindigkeit	Wirtschaftlicher Nutzen, Automatisierung und schnelle Umsetzung erhalten höheres Gewicht	Welche KI bringt kurzfristig Wirkung?	Identifikation von Quick Wins und Ressourcenschonung
Wachstum & Differenzierung	Kundennutzen, Skalierbarkeit und Wettbewerbsvorteil erhalten höheres Gewicht	Welche KI kann strategische Positionierung stärken?	Priorisierung langfristiger Investitionen

Tabelle 3: Szenariologik für Sensitivitätsanalysen. Quelle: eigene Darstellung.

Im vorliegenden E-Commerce-Use-Case bleibt die Priorisierung über die in den Kolloquiumsunterlagen gezeigten Szenarien stabil. Das Sicherheits-Szenario gewichtet Datenschutz und Governance stärker, während das Effizienz-Szenario wirtschaftlichen Nutzen und schnelle Umsetzung priorisiert. Die Stabilität des Rankings spricht dafür, dass die grundlegende Einordnung der drei untersuchten Anwendungen robust ist (Lange, 2026). Für Managemententscheidungen ist diese Information oft wichtiger als der exakte Punktwert, denn Punktwerte sind trotz Kriterienlogik immer von Annahmen geprägt.

Für die Anwendung in anderen Kontexten sollte die Sensitivitätsanalyse standardisiert dokumentiert werden. Zunächst wird eine Baseline-Gewichtung festgelegt. Anschließend werden zwei bis vier alternative Gewichtungssets definiert, die reale strategische Spannungsfelder abbilden. Danach wird geprüft, ob sich Rangfolge, Quadrantenzuordnung oder Investitionsentscheidung verändern. Wenn eine Anwendung in allen Szenarien hoch priorisiert bleibt, handelt es sich um einen robusten Kandidaten. Wenn sie nur in einem Szenario attraktiv ist, sollte die Entscheidung explizit an die jeweilige Strategiebedingung gekoppelt werden.

Diskussion und praktische Implikationen

Die Ergebnisse verdeutlichen, dass der eigentliche Engpass bei KI-Einführung nicht zwingend die Identifikation technologischer Möglichkeiten ist. Vielmehr fehlt häufig eine konsistente Bewertungs- und Entscheidungssprache. Unternehmen diskutieren dann über einzelne Tools, Anbieter oder Trendbegriffe, ohne zuvor zu definieren, welche Wirkung, welche Realisierbarkeit und welches Risiko relevant sind. Das KI-Impact-Scoring-Tool schafft hier eine gemeinsame Struktur. Es ersetzt keine Managemententscheidung, sondern macht sie nachvollziehbar (Ulrich & Bachlechner, 2020; Kühnapfel, 2021).

Phase	Ziel	Konkretes Vorgehen	Ergebnis
1. Use-Case-In-ventur	KI-Ideen vergleichbar machen	Alle KI-Ideen mit Ziel, Nutzergruppe, Prozess, Datenbasis und Risiken beschreiben.	Strukturiertes KI-Portfolio
2. Baseline-Scoring	Erste Priorisierung erzeugen	Wertbeitrag, Umsetzbarkeit und Risiko auf 1-5-Skala bewerten und gewichten.	Matrixposition je Use Case
3. Szenarien prüfen	Robustheit testen	Gewichtungen für Sicherheit, Effizienz, Wachstum oder UX variieren.	Stabiles oder strategieabhängiges Ranking
4. Roadmap ableiten	Umsetzung steuern	Quick Wins pilotieren, strategische Investitionen über Business Case und Governance vorbereiten.	KI-Roadmap mit Verantwortlichkeiten
5. Lernen und Nachjustieren	Modell aktuell halten	Bewertungen nach Pilotdaten, Nutzerfeedback und regulatorischen Entwicklungen aktualisieren.	Dynamisches Entscheidungsinstrument

Tab. 4: Anwendungsempfehlung für Unternehmen. Quelle: eigene Darstellung.

Für mittelständische Unternehmen ergibt sich daraus eine dreistufige Vorgehensweise. Erstens sollte ein KI-Use-Case-Portfolio aufgebaut werden, das nicht nur technische Ideen sammelt, sondern jede Initiative mit Ziel, Nutzergruppe, Datenbasis, Prozessbezug und erwarteter Wirkung beschreibt. Zweitens sollten diese Use Cases anhand des Scoring-Tools bewertet werden. Drittens sollte die Priorisierung in mindestens zwei alternativen Szenarien überprüft werden. Erst danach sollten Budget, Pilotumfang und Verantwortlichkeiten festgelegt werden. Diese Reihenfolge reduziert das Risiko, dass KI-Projekte aus Begeisterung begonnen, aber ohne Anschlussfähigkeit skaliert werden (Müller, 2022; Pinker, 2025).

Der E-Commerce-Use-Case zeigt zudem, dass Quick Wins und strategische Investitionen nicht gegeneinander ausgespielt werden sollten. KI-gestützte Produktbilder können schnell Wirkung erzeugen und Lernkurven schaffen. Personalisierung und Assistenzsysteme benötigen dagegen mehr Daten, Integration und Governance, können aber langfristig größere Differenzierungsbeiträge leisten. Eine gute KI-Roadmap kombiniert daher schnelle, risikoärmere Experimente mit langfristigen Infrastruktur- und Kompetenzaufbauten (Aichele, 2022b; Harwardt & Köhler, 2023).

Über den E-Commerce hinaus kann das Tool als Governance-Instrument genutzt werden. Es zwingt Fachbereiche, IT, Datenschutz, Controlling und Management dazu, Bewertungsannahmen offenzulegen. Dadurch entstehen anschlussfähige Diskussionen über Prioritäten, Risiken und Investitionslogik. Gerade bei KI ist diese Transparenz wichtig, weil Systeme nicht nur Effizienz erzeugen, sondern auch Vertrauen, Verantwortung und Kontrolle berühren (Endres, 2025; Zweig, 2025).

Limitationen, Ausblick und Fazit

Die entwickelte Bewertungslogik besitzt trotz ihres praktischen Nutzens Grenzen. Erstens beruht sie auf Kriterien und Gewichtungen, die zwar theoretisch begründet, aber in der konkreten Anwendung subjektiv sind. Zweitens ist die E-Commerce-Blaupause keine repräsentative Marktstudie, sondern eine exemplarische Anwendung auf drei heterogene KI-Use-Cases. Drittens können technologische Leistungsfähigkeit, Anbieterqualität, Kostenstrukturen und rechtliche Rahmenbedingungen dynamisch variieren, sodass Bewertungen regelmäßig aktualisiert werden müssen (Döring & Bortz, 2016; Lange, 2026).

Ein weiterer Limitationenpunkt betrifft die Messung tatsächlicher Wirkung. Das Tool bewertet erwarteten Nutzen und erwartete Umsetzbarkeit vor der Einführung oder im frühen Pilotstadium. Damit ersetzt es keine ex-post Evaluation. Unternehmen sollten daher nach Implementierung Kennzahlen definieren, etwa Conversion Rate, Supportentlastung, Prozessdauer, Nutzerzufriedenheit, Fehlerquoten oder Akzeptanzwerte, und diese mit der ursprünglichen Bewertung abgleichen. Auf diese Weise kann das Scoring-Tool über die Zeit kalibriert werden (Savastano, 2025; Ulrich & Bachlechner, 2020).

Für zukünftige Forschung bieten sich mehrere Ansatzpunkte an. Zum einen könnten größere empirische Studien prüfen, welche Kriterien in unterschiedlichen Branchen besonders entscheidungsrelevant sind. Zum anderen könnte das Tool in realen Unternehmen über mehrere KI-Projekte hinweg angewendet und mit tatsächlichen Projekterfolgen verglichen werden. Darüber hinaus wäre eine digitale Version denkbar, die Gewichtungen, Szenarien, Portfolios und historische Bewertungsdaten integriert. Gerade für mittelständische Unternehmen könnte ein solches Instrument den Übergang von punktuellen KI-Experimenten zu systematischer KI-Governance unterstützen.

Zusammenfassend beantwortet das Paper die Forschungsfrage dahingehend, dass ein generisches KI-Impact-Scoring-Tool drei Elemente benötigt: eine kontextspezifische Wertdimension, eine realistische Umsetzungs- und Risikodimension sowie eine Sensitivitätsanalyse, die Priorisierungen unter unterschiedlichen strategischen Zielsetzungen prüft. Der E-Commerce-Use-Case zeigt, wie diese Logik praktisch funktioniert. Der zentrale Mehrwert liegt jedoch in der Übertragbarkeit: Die Matrix macht KI-Entscheidungen nicht automatisch richtig, aber sie macht sie sichtbar, vergleichbar, begründbar und lernfähig.

Literaturverzeichnis

- Abich, V. (2022). Künstliche Intelligenz im ERP Umfeld. In C. Aichele & J. Herrmann (Hrsg.), Betriebswirtschaftliche KI-Anwendungen: Digitale Geschäftsmodelle auf Basis künstlicher Intelligenz (2. Aufl.). Springer Gabler.
- Aichele, C. (2022a). Künstliche Intelligenz für klein- und mittelständische Unternehmen. In C. Aichele & J. Herrmann (Hrsg.), Betriebswirtschaftliche KI-Anwendungen: Digitale Geschäftsmodelle auf Basis künstlicher Intelligenz (2. Aufl.). Springer Gabler.
- Aichele, C. (2022b). Vorgehensweise zur Anwendung Digitaler Geschäftsprozesse auf Basis von Künstlicher Intelligenz. In C. Aichele & J. Herrmann (Hrsg.), Betriebswirtschaftliche KI-Anwendungen: Digitale Geschäftsmodelle auf Basis künstlicher Intelligenz (2. Aufl.). Springer Gabler.
- Amazon Ads. (2023). unBoxed 2023: Amazon Ads führt KI-gestützte Bildgenerierung ein, um Marken dabei zu helfen, umfangreichere Werbemittel zu produzieren. <https://advertising.amazon.com/de-de/blog/ai-generated-image-creative>
- Carstensen, A. K., & Bernhard, J. (2019). Design science research - a powerful tool for improving methods in engineering education research. *European Journal of Engineering Education*, 44(1-2), 85-102.
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319-340. <https://doi.org/10.2307/249008>
- Dittrich, J. (2025). KI im Kundenservice: Wie Unternehmen skalierbare Lösungen implementieren können. In K. Winkler, S. Niedermeier & K. J. Yuan (Hrsg.), KI-Wissen für Führungskräfte: Entscheidungsgrundlagen und Insights für unternehmerischen Erfolg. Springer Gabler.
- Döring, N., & Bortz, J. (2016). Forschungsmethoden und Evaluation in den Sozial- und Humanwissenschaften (5. Aufl.). Springer. <https://doi.org/10.1007/978-3-642-41089-5>
- Endres, S. (2025). Eine Frage der Verantwortung: Ethische Perspektiven auf KI. In K. Winkler, S. Niedermeier & K. J. Yuan (Hrsg.), KI-Wissen für Führungskräfte: Entscheidungsgrundlagen und Insights für unternehmerischen Erfolg. Springer Gabler.
- Gast, O. (2018). User Experience im E-Commerce: Messung von Emotionen bei der Nutzung interaktiver Anwendungen. Springer Gabler. <https://doi.org/10.1007/978-3-658-22484-4>
- Harwardt, M., & Köhler, M. (2023). Künstliche Intelligenz entlang der Customer Journey: Einsatzpotenziale von KI im E-Commerce. Springer Gabler. <https://doi.org/10.1007/978-3-658-39109-6>
- Hu, J., & Lee, E. T. (2026). The Impact of Integrated AI and AR in E-Commerce: The Roles of Personalization, Immersion, and Trust in Influencing Continued Use. *Journal of Theoretical and Applied Electronic Commerce Research*, 21(1), 33. <https://doi.org/10.3390/jtaer21010033>
- Hu, S., Liu, J., Li, H., Yin, J., & Liu, X. (2025). Exploring the mechanism of AI-powered personalized product recommendation on Generation Z users' spontaneous buying intention on short-form video platforms.
- Kühnapfel, J. B. (2021). Scoring und Nutzwertanalysen: Ein Leitfaden für die Praxis. Springer Gabler. <https://doi.org/10.1007/978-3-658-34810-6>

- Lange, N. (2026). Einsatz von künstlicher Intelligenz zur Verbesserung der User Experience in Onlineshops: Entwicklung einer Priorisierungsmatrix für mittelständische Unternehmen. Bachelorarbeit, IU Internationale Hochschule.
- Loth, A. (2024). KI für Content Creation: Texte, Bilder, Audio und Videos erstellen mit ChatGPT und Co. mitp Verlags GmbH & Co. KG.
- Müller, L. (2022). Digitale Transformation im Mittelstand. In C. Aichele & J. Herrmann (Hrsg.), Betriebswirtschaftliche KI-Anwendungen: Digitale Geschäftsmodelle auf Basis künstlicher Intelligenz (2. Aufl.). Springer Gabler.
- Photoroom. (2026). Photoroom: KI Foto Editor (Version 2026.08.01) [KI-gestützter Bild- und Hintergrund-Editor]. <https://www.photoroom.com/de>
- Pfliegl, K. (2025). Personalisierung neu definiert: KI-gestützte Strategien für den E-Commerce 2026. E-Commerce Magazin, 6, 31.
- Pinker, A. (2025). Sechs Schritte zur erfolgreichen KI-Implementierung. In K. Winkler, S. Niedermeier & K. J. Yuan (Hrsg.), KI-Wissen für Führungskräfte: Entscheidungsgrundlagen und Insights für unternehmerischen Erfolg. Springer Gabler.
- Pröpsting, S. (2022). Digitale Veränderung der klassischen Rollenverteilung im Handel. In M. Knoppe, S. Rock & M. Wild (Hrsg.), Der zukunftsfähige Handel: Neue online und offline Konzepte sowie digitale und KI-basierte Lösungen. Springer Gabler.
- Rock, S. (2022a). Digitalisierung und Erfolg. In M. Knoppe, S. Rock & M. Wild (Hrsg.), Der zukunftsfähige Handel: Neue online und offline Konzepte sowie digitale und KI-basierte Lösungen (S. 47-64). Springer Gabler.
- Savastano, M. (2025). The impact of e-commerce platforms' quality. The TQM Journal, 37(7), 2074-2093. <https://doi.org/10.1108/TQM-04-2024-0143>
- Schultz, C. D., & Brüggemann, P. (2022). Digitale Sprachassistenten zur Transaktionsanbahnung. Transfer: Zeitschrift für Kommunikation & Markenmanagement, 28(4), 324-337.
- Takeda, H., Veerkamp, P., Tomiyama, T., & Yoshikawa, H. (1990). Modeling design processes. AI Magazine, 11(4), 37-48.
- Tanase, I., Barbu, L. N., Munteanu, A. E., & Rusu, G. (2025). The Use of AI for a Better User Experience in E-Commerce Websites. Proceedings of the 19th International Conference on Business Excellence.
- Thüring, M., & Mahlke, S. (2007). Usability, aesthetics and emotion in human-technology interaction. International Journal of Psychology, 42(4), 253-264.
- Ulrich, M., & Bachlechner, D. (2020). Wirtschaftliche Bewertung von KI in der Praxis - Status quo, methodische Ansätze und Handlungsempfehlungen. HMD Praxis der Wirtschaftsinformatik, 57, 46-59. <https://doi.org/10.1365/s40702-019-00576-9>
- Woodworth, R. S. (1929). Psychology: A Study of Mental Life. H. Holt and Co.
- Zweig, K. A. (2025). Den Einsatz von KI-Systemen mit sozioinformatischen Analysen bewerten. SEMINAR, 31(2), 54-66. <https://doi.org/10.3278/SEM2502W005>