



Mittelstand-Digital
**Zentrum
Hamburg**

LEITFADEN



MASCHINELLES LERNEN NUTZEN

SUPPLY-CHAIN-RISIKOMANAGEMENT
EFFIZIENT GESTALTEN

Mittelstand-
Digital 

Gefördert durch:



Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

MASCHINELLES LERNEN NUTZEN

SUPPLY-CHAIN-RISIKOMANAGEMENT EFFIZIENT GESTALTEN

Liebe Leserinnen und Leser,

nutzen Sie in Ihrem Unternehmen schon maschinelles Lernen? Schrecken Sie davor nicht zurück! Auch wenn Sie vielleicht Sorge haben, weil Sie unbekanntes Terrain betreten, sollten Sie sich diesem Thema stellen. In vielen Fällen scheitert der Einsatz von maschinellem Lernen an fehlenden Kompetenzen oder mangelnder Akzeptanz. Doch das muss nicht sein.

Theoretische Modelle bieten oft nur sehr allgemein gehaltene Handlungsempfehlungen an. Doch aktuelle Ereignisse wie die Coronapandemie haben gezeigt, dass viele Lieferketten (auch Supply Chains genannt) unerwartete Risiken kaum meistern können. Wie ist damit umzugehen? Ein Frühwarnsystem, das auf künstlicher Intelligenz bzw. maschinellen Lernalgorithmen basiert, könnte Abhilfe schaffen.

Dieser Leitfaden bietet Ihnen daher einen theoretisch fundierten, aber praxisbezogenen Einstieg in das Themenfeld künstliche Intelligenz im Bereich des Supply-Chain-Risikomanagements. Erfahren Sie mithilfe eines Vorgehensmodells, wie Sie maschinelles Lernen im Supply-Chain-Risikomanagement schrittweise implementieren und diese zukunftssträchtige Technologie erfolgreich einsetzen können. Die Lektüre eignet sich für Sie, wenn Sie für Ihr Unternehmen einen praktischen und einfachen Einstieg in das Thema suchen oder bisher genutzte Vorgehensmodelle für die Implementierung von maschinellem Lernen hinterfragen möchten.

Prof. Dr. Dr. h. c. Wolfgang Kersten, Martin Brylowski M. Sc.,
Prof. Dr. Meike Schröder, Florian Dörries M. Sc., Lennard Gast M. Sc.

INHALTSVERZEICHNIS

EINS	Einleitung	04
ZWEI	WAS – bedeutet Implementierung von maschinellem Lernen im Supply-Chain-Risikomanagement?	05
DREI	WIE – lässt sich maschinelles Lernen im Supply-Chain-Risikomanagement implementieren?	08
	3.1 Impulsphase	09
	3.2 Planungsphase	10
	3.3 Evaluationsphase	16
	3.4 Realisierungsphase	22
	3.5 Implementierungsphase	27
VIER	WARUM – lohnt sich der Einsatz von maschinellem Lernen im Supply-Chain-Risikomanagement?	31
FÜNF	Literatur	32
SECHS	Mittelstand-Digital Zentrum Hamburg	38
SIEBEN	Impressum	39

EINS

EINLEITUNG

Steigende Bedürfnisse der Kundschaft und der damit verbundene Wettbewerbsdruck führen seit vielen Jahren dazu, dass Unternehmen am Weltmarkt partizipieren und diverse Vorteile für sich nutzbar machen [1]. Unternehmen vernetzen sich mehr und mehr zu globalen Wertschöpfungsnetzwerken. Somit entstehen komplexe Strukturen und externe Einflüsse können große Implikationen für alle beteiligten Wertschöpfungspartner mit sich bringen [2]. Dies wurde mit dem Ausbruch des Erregers SARS-CoV-2 deutlich. Um eine weitere Verbreitung des Virus einzudämmen, leiteten Regierungen in großen Teilen der Welt restriktive Maßnahmen ein. Das hatte unmittelbare Auswirkung auf den weltweiten Güterhandel [3]. Die Krise hat gezeigt: Widerstandsfähige Wertschöpfungsketten sind ein Schlüsselfaktor für den nachhaltigen Unternehmenserfolg.

Um Unsicherheiten abzubauen und die Wertschöpfungskette zu stärken, ist die Integration eines Supply-Chain-Risikomanagements (SCRM) sinnvoll [2]. Obgleich der Potenziale, die so realisiert werden können, betreiben nur wenige Unternehmen ein ganzheitliches SCRM. Dabei bietet die digitale Transformation viele Möglichkeiten, um Hindernisse zu überwinden [4]. Gerade die zunehmende Menge an verfügbaren Daten in Kombination mit Methoden der künstlichen Intelligenz wie beispielsweise maschinellem Lernen kann hier einen wichtigen Beitrag leisten.

Was künstliche Intelligenz, SCRM und Implementierung überhaupt bedeuten und wie ein schrittweises Vorgehensmodell für die Einführung von maschinellem Lernen in Ihrem Unternehmen aussehen kann, erfahren Sie auf den folgenden Seiten.

ZWEI

WAS – BEDEUTET IMPLEMENTIERUNG VON MASCHINELLEM LERNEN IM SUPPLY-CHAIN-RISIKOMANAGEMENT?

Was ist künstliche Intelligenz bzw. maschinelles Lernen?

Künstliche Intelligenz (KI) ist ein Megatrend, der längst in unserer Gesellschaft und in den Unternehmen angekommen ist. Unter KI ist das Lösen konkreter Anwendungsprobleme auf Basis von Methoden aus der Mathematik und Informatik zu verstehen, wobei die entwickelten Systeme zur Selbstoptimierung fähig sind. Zudem hat sich das Konzept des maschinellen Lernens (ML) als Methode zur Lösung von spezifischen Problemen zu einem der Kernbereiche der KI entwickelt. ML umfasst Verfahren und Computer-Algorithmen, die sich aus Daten heraus ein möglichst optimales Verhalten antrainieren bzw. lernen können, ohne dass jeder Einzelfall explizit programmiert werden muss. Zum Aufschwung von ML, der bis heute deutlich anhält, trug die Etablierung des Internets und damit die signifikante Steigerung der Datenverfügbarkeit maßgeblich bei [5].

ML ist eine der Teildisziplinen der KI. Es ahmt die Lernleistung des Gehirns nach, wobei eine große Datenmenge für ein spezifisches Problem als Grundlage dient [6]. Im Bereich Business Analytics können so mithilfe von Lernprozessen ein Algorithmus trainiert sowie Muster und Zusammenhänge in großen Datenmengen erkannt werden. Daraus lassen sich Vorhersagen ableiten und Entscheidungen treffen [7]. Wesentlicher Unterschied zu klassischen statistischen Analysemethoden ist dabei der Lernprozess [8].

WAS GEHT MIT MASCHINELLEM LERNEN?

Google DeepMind's Deep Q-learning überzeugt bei Atari-Spiel „Breakout“
Mehr bei YouTube:



BUSINESS ANALYTICS:

Business Analytics (BA) meint die Fähigkeiten, Technologien und Methoden für die Untersuchung vergangener Unternehmensleistungen, um neue Erkenntnisse zu gewinnen [7].

SUPPLY-CHAIN-RESILIENZ:

Die Resilienz der Supply Chain ist die Fähigkeit eines Unternehmens, sich angesichts des stattfindenden Wandels anzupassen, zu verändern oder fortzubestehen [10].

Was ist Supply-Chain-Risikomanagement?

Im wissenschaftlichen Diskurs ist eine Vielzahl an Ansätzen zur Definition von SCRM präsent. Die **Ziele von SCRM** können zwei verschiedene Aspekte umfassen. Einerseits können **finanzielle Aspekte** und die **Sicherung des Cashflows** betrachtet werden. Andererseits stehen **resiliente Supply-Chain-Prozesse** sowie die **Sicherung der Lieferfähigkeit** im Fokus. Ein weit verbreiteter Ansatz wurde aus dem allgemeinen Risikomanagement-Prozess nach der ISO 31000 abgeleitet. Der Prozess umfasst die vier Phasen: (1) Risikoidentifikation, (2) Risikobewertung, (3) Risikosteuerung und (4) Risikoüberwachung [9].

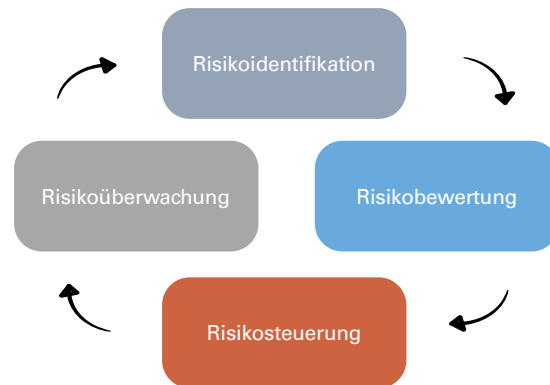


Abbildung 1: Vier Phasen des Risikomanagement-Prozesses

Der erste Schritt des SCRM-Prozesses ist (1) die **Risikoidentifikation**. Hier beschreiben Sie das Wertschöpfungsnetzwerk umfassend, stellen es gegebenenfalls visuell dar und analysieren es auf mögliche Störquellen [11]. Angestrebtes Resultat ist eine systematische Übersicht der identifizierten Risiken. Diese bildet die Grundlage für die weiteren SCRM-Prozess-

schritte [2]. Nachdem Sie einen Risikokatalog für die Supply Chain (SC) Ihres Unternehmens erstellt haben, erfolgt im zweiten Prozessschritt (2) die **Bewertung der Risiken**, die auf potenzielle Konsequenzen für die Supply Chain quantifiziert werden. Maßgeblich für die Bewertung sind in diesem Zusammenhang die Eintrittswahrscheinlichkeit des Risikos und die Höhe des potenziellen Schadens [12]. Wenn Sie die Risiken bewertet und priorisiert haben, bestimmen Sie im nächsten Schritt (3) eine geeignete Strategie zur Verminderung der Eintrittswahrscheinlichkeiten oder der Konsequenzen. Bei der **Risikosteuerung** ordnen Sie jeder Unsicherheit in Abhängigkeit vom Erwartungswert und der Art des Risikos eine geeignete Maßnahme zu [2]. Beispielhaft sollte bei hoher Versorgungsunsicherheit und niedriger Nachfrageunsicherheit in der SC das Risiko möglichst verteilt werden. Als letzter Schritt (4) des SCRM-Prozesses dient die **Risikoüberwachung** der Überprüfung im Hinblick auf die Effektivität der verwendeten Strategien zur Risikoverminderung [2]. Und stellen Sie hier auf jeden Fall eine kontinuierliche Berichterstattung sicher!

Was ist Implementierung?

Der Begriff Implementierung ist bei der Einführung von computergestützten Informationssystemen elementar [13]. Sie umfasst den Systementwicklungsprozess von der Programmierung bis zum anschließenden Systemtest. Mit der technischen geht außerdem die organisatorische Implementierung einher, bei der die Abläufe im Fokus stehen, die zum Erfolg des reibungslosen Übergangs zum neuen System beitragen [14]. So sind mit der Implementierung aus betriebswirtschaftlicher Perspektive unternehmerische Veränderungsaktivitäten verbunden [15].

**NEUES WAGEN!**

Erfahren Sie mehr im Leitfaden „Change Management – Wie Unternehmen den Veränderungsprozess aktiv gestalten können“.



DREI

WIE – LÄSST SICH MASCHINELLES LERNEN IM SUPPLY-CHAIN-RISIKOMANAGEMENT IMPLEMENTIEREN?

Nutzen Sie für Ihr Unternehmen ein Vorgehensmodell, um maschinelles Lernen im SCRM zu implementieren. Dabei durchlaufen Sie – beim hier aufgeführten Modell – fünf übergeordnete Phasen (s. Abb. 1), die zum Teil in kleinere Prozessschritte aufgegliedert sind.

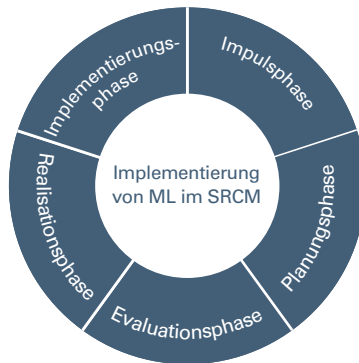


Abbildung 2: Vorgehensmodell für die Implementierung von maschinellem Lernen im Supply-Chain-Risikomanagement

Die Phasen des Modells sind als Kreislauf aufgebaut, da es ein kontinuierlicher Prozess ist. Die ersten drei Phasen (Impuls-, Planungs- und Evaluationsphase) umfassen die Planung der Implementierung. In den letzten beiden Phasen (Realisations- und Implementierungsphase) folgt die Umsetzung in die Praxis.

3.1 Impulsphase

Am Anfang des Vorgehensmodells steht die Impulsphase (s. Abb. 2). Impulse sind im Wesentlichen externe Informationen, Bedürfnisse oder Möglichkeiten, die z. B. durch Mitarbeitende aufgenommen oder herangetragen werden. Dabei ist zwischen **proaktiven** und **reaktiven Impulsen** zu unterscheiden, wobei letztere den Beginn des Implementierungsprozesses markieren.

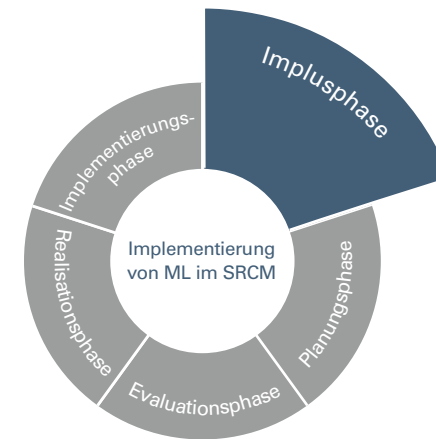


Abbildung 3: Impulsphase des Vorgehensmodells

Als **proaktiv** werden **Impulse** definiert, die eine Folge aus langfristigen und kontinuierlichen Bemühungen des Unternehmens sind. Ziel des Unternehmens ist hierbei etwa die Erweiterung des Wissens und der Fähigkeiten des Personals, ohne dass ein explizites Problem vorliegt. Ein Beispiel ist die Akquise von neuen Mitarbeitenden, die spezifisches Know-how einbringen und historisch gewachsene Strukturen hinterfragen. Darüber hinaus sollten Mitarbeitende und leitende Führungskräfte die Impulse unterstützen. Ein weiterer treibender Faktor ist der Fokus auf kundenorientiertes Handeln. Innovationen zu identifizieren und zu implementieren, die den Service verbessern, kann zur Bindung der Kundschaft beitragen [16].

Reaktive Impulse beziehen sich auf konkrete Problemsituationen, die kurz- oder mittelfristig den Bedarf an Erneuerung oder Restrukturierung aufzeigen. Wertschöpfungs-

netzwerke sind inzwischen sehr umfangreich und komplex, sie umfassen sehr viele Wertschöpfungsstufen und Beteiligte [17]. Disruptive Ereignisse wie Naturkatastrophen, Terrorangriffe und die Coronapandemie haben gezeigt, dass dadurch der Bedarf der Kundenschaft nicht immer bedient werden kann [10]. Die Bewahrung der Wettbewerbsfähigkeit durch die Gewährleistung von resilienten Supply Chains ist somit ein wesentlicher Impuls für die Nutzung von ML im SCRM [18].

Durch den Einsatz von ML lassen sich Effizienz und Produktivität bei zugleich geringerer Kostenbasis steigern [16]. **Die Vorteile:** Ein hoher Automatisierungsgrad und wertschöpfende Analysen von großen und komplexen Datenmengen bei gleichzeitig geringeren personellen Ressourcen [19]. Die ständige **Überwachung der Lieferketten** unter sich stetig ändernden und komplexeren Bedingungen ist ohne maschinelles Lernen personell und finanziell extrem aufwendig. Aber die disruptiven Ereignisse der letzten Jahre haben gezeigt, dass dieser Aufwand für ein effizientes SCRM notwendig ist. Der **Einsatz von maschinellem Lernen** ist für die **Resilienz der Supply Chains** sehr vielversprechend [20].

Als Ergebnis der Impulsphase arbeiten Sie eine Idee aus, die Sie in den folgenden Phasen sukzessiv weiterentwickeln. Dies umfasst hier noch keine Entscheidung hinsichtlich Budgetierung oder konkreter Lösungsansätze [21].

3.2 Planungsphase

In der Planungsphase überführen Sie die Idee aus der Impulsphase in ein **konkretes Projekt**. Hierbei wird ein Top-down-Ansatz verfolgt. Ein Projektteam konkretisiert die grobe Idee, um am Ende der Phase einen oder mehrere Anwendungsfälle für maschinelles Lernen im SCRM zu entwickeln (s. Abb. 3). Ein Anwendungsfall wird auf Basis eines Risikos in der Supply Chain gebildet, dem mithilfe von Techniken des maschinellen Lernens entgegengewirkt werden kann. Insgesamt ist die Phase untergliedert in vier Prozessschritte: Teamerstellung (A), Supply-Chain-Analyse (B), Risikobewertung (C) und Anwendungsfallentwicklung (D).

TEAMERSTELLUNG (A)

Starten Sie die Planungsphase mit dem Aufbau eines Projektteams. Dabei ist die Zusammensetzung des Teams relevant für die folgenden Phasen. Denn die Integration von SCRM und ML ist eine interdisziplinäre Aufgabe, die sich auch in der Gestaltung Ihres

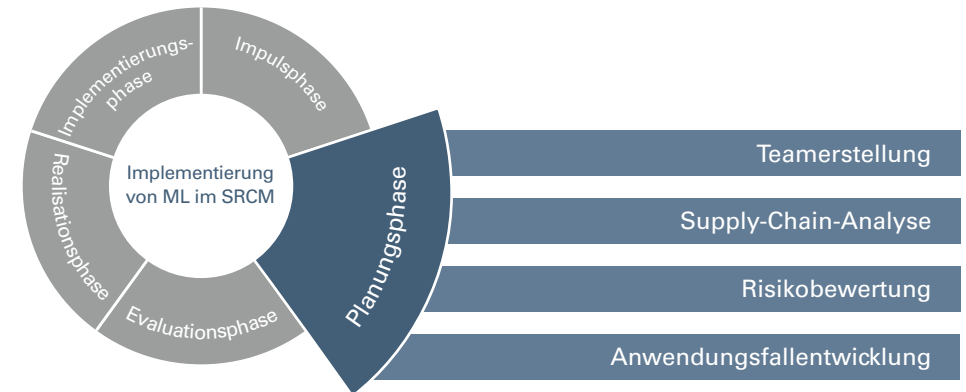


Abbildung 4: Planungsphase des Vorgehensmodells

Teams widerspiegelt. Sie benötigen Fachkräfte aus den folgenden Bereichen: Risikomanagement, Supply-Chain-Funktionen, IT und ML[22].

Die **Risikomanagement-Fachkräfte** führen das Projektteam durch den Prozess. Sie bringen die richtigen Methoden zur Identifikation und Bewertung von Risiken in der Supply Chain ein und haben die verschiedenen Perspektiven der Funktionsbereiche im Sinne des Projekterfolgs im Blick. Als Schnittstelle zum Top-Management sollten sie eine vereinheitlichte, gezielte und regelmäßige Kommunikation mit dem Führungsteam pflegen, auch um Bedarf an finanziellen, technischen und personellen Ressourcen während der einzelnen Projektphasen aufzuzeigen. Idealerweise sollte das Top-Management die Risikomanagement-Fachkräfte bei der Teamgestaltung einbeziehen. Eine gute Zusammenarbeit dieser beiden Gruppen ist ein bedeutender Erfolgsfaktor bei der Implementierung von maschinellem Lernen.

Die **Mitarbeitenden** aus dem betrachteten **Supply-Chain-Funktionsbereich** sind durch ihre operative Tätigkeit mit wiederkehrenden Herausforderungen und Problemen vertraut. Diese Erfahrung ist speziell bei der Analyse der Lieferkette und der damit einhergehenden Identifizierung von Risiken von hohem Wert. Weiterhin sind sie bei der externen Kommunikation mit Supply-Chain-Partnern eingebunden, indem sie den richtigen Kontakt herstellen und das gegenseitige Verständnis für das Projekt durch den Bezug auf aktuelle Problemstellungen fördern. Ihr fachspezifisches Wissen ist auch wichtig für die Zieldefinition im Rahmen der Anwendungsfallentwicklung sowie für die Bewertung des Ergebnisses.

Die **technische Perspektive** ist vertreten durch IT- und ML-Fachkräfte. Bereits in der Planungsphase können **IT-Fachkräfte** ihr Know-how mit der Bereitstellung der richtigen Daten einbringen. Sie bewerten außerdem die technischen Umsetzungsvoraussetzungen in der Evaluationsphase und nutzen ihr Wissen über die gesamte IT-Architektur und bestehende Systeme (z. B. ERP/Enterprise Resource Planning). Sie bauen eine IT-Infrastruktur auf, um einen standardisierten Übertragungsprozess einzurichten für externe Daten, die von Supply-Chain-Partnern stammen.

Für die erfolgreiche Umsetzung von ML sind die **ML-Fachkräfte** verantwortlich. Neben der praktischen Modellierung ist ihr Fachwissen bereits in der Entwicklung des Anwendungsfalls notwendig. Die Vereinbarung der technischen und organisatorischen Zielsetzungen muss vor der Implementierungsphase hinreichend ausgearbeitet werden. Dies gilt speziell, um eine realistische Erwartungshaltung über die Potenziale von ML zu vermitteln. ML Fachkräfte stehen daher im engen Austausch mit den IT-Teammitgliedern, um die Anforderungen an die IT-Architektur und Datenqualität zu evaluieren und zu kommunizieren.

Die überlegte Zusammenstellung Ihres Teams steht an erster Stelle, da das Projekt von dessen Wissen und Fähigkeiten abhängig ist. Um den Kommunikations- und personellen Aufwand zu reduzieren, können Sie ein Kernteam und ein erweitertes Projektteam bilden. Das Kernteam begleitet das gesamte Projekt. Je nach Arbeitspaket werden in den einzelnen Projektphasen weitere Mitarbeitende involviert. Sind die erforderlichen Ressourcen unternehmensintern nicht verfügbar, sollten Sie vor Beginn der Planungsphase entsprechende externe Ressourcen akquirieren.

SUPPLY-CHAIN-ANALYSE (B)

Als Nächstes steht die Supply-Chain-Analyse an. Dieser Prozessschritt umfasst die **Kartierung** der direkten und indirekten Supply Chain sowie die **Identifizierung von Supply-Chain-Risiken**.

Zu Beginn werden der **Ist-Zustand analysiert** und das gesamte **Problemfeld erfasst** [21]. Die Verbesserung der Supply-Chain-Transparenz ist elementar: Während die Beteiligten der nächstliegenden Wertschöpfungsstufe zumeist bekannt sind, nimmt das Wissen über die beteiligten Akteure mit Zunahme der Komplexität stark ab [23]. Gerade die gegenseitigen Abhängigkeiten und Netzwerkeffekte sind aber im SCRM besonders bedeutsam. Zuerst sollten Güter-, Finanz- und Informationsflüsse aus der Perspektive des fokalen Unternehmens kartiert werden. Für die erweiterte Supply Chain ist die Ko-



operation und Kommunikation mit beteiligten Unternehmen wichtig. Informieren Sie diese bereits jetzt und heben Sie die Relevanz der Kooperation hervor. Dies ist aus zwei Gründen sinnvoll. Zum einen ist die erfolgreiche Umsetzung des Projekts von den bereitgestellten Daten abhängig, da externe Daten im Wertschöpfungsnetzwerk mindestens gleichbedeutend mit internen Daten sind. Zum anderen können Sie so verhindern, dass sich Asymmetrien zwischen Beteiligten negativ auf den SCRM-Prozess auswirken [24]. Wenn Sie die notwendigen Daten zusammengetragen haben, lässt sich die Komplexität der Wertschöpfungsketten durch Visualisierungstechniken reduzieren [22].

Nachdem alle Beteiligten und Wertströme in der Supply Chain erfasst sind, gilt es potenzielle **Risiken zu identifizieren**. Hierzu gibt es verschiedene qualitative und quantitative Methoden. Anschließend erfolgt eine Risikoklassifizierung, die sie um die MLPerspektive erweitern. Als Orientierung bietet die Einteilung nach Klassifizierungs- oder Regressionsproblemen (überwachtes Lernen) einen ersten Ansatz, um die Probleme unter Berücksichtigung von ML-Techniken vorläufig einzuordnen. So lassen sich strukturell ähnliche Probleme zusammenfassen und Sie können weitestgehend generell anwendbare ML-Modelle entwickeln. Der Ressourcenaufwand bleibt somit gering. Auch die Übertrag-

barkeit des ML-Modells auf gleichartige Probleme in anderen Teilen des Unternehmens wird durch dieses Vorgehen forciert.

Als Ergebnis der Ist-Analyse erhalten Sie also eine systematische Übersicht der Supply Chain und der identifizierten Risiken aus der Perspektive des fokalen Unternehmens.

RISIKOBEWERTUNG (C)

Durch die **Bewertung** der Risiken können Sie eine **Priorisierung** vornehmen, was insbesondere für die Implementierung von ML sinnvoll ist. Wenn Sie ML erstmals nutzen möchten, sollten Sie Anwendungsfälle priorisieren, welche die Profitabilität des Unternehmens betreffen. Wie hoch der Einfluss eines Anwendungsfalls ist, lässt sich beispielsweise durch die Multiplikation der Kriterien Eintrittswahrscheinlichkeit und Höhe des potenziellen Schadens quantifizieren [12]. Die Risiken bewerten Sie gemäß den bekannten Methoden des SCRM (z. B. FMEA).

Im Kontext der angestrebten Implementierung von ML bietet es sich ebenfalls an, das Automatisierungspotenzial zu berücksichtigen, da ansonsten eine hohe Ressourcenauslastung – aufgrund der fehlenden Automatisierung von SCRM – droht [26]. Dies stellt eine mögliche Barriere für die erfolgreiche Umsetzung von SCRM dar [4]. Sofern Sie in Ihrem Unternehmen bereits ein SCRM-Konzept etabliert haben, sollten Sie auch den Personalaufwand anteilig in die Risikobewertung einbeziehen. Dadurch kann sich die Priorisierung deutlich verändern und Risiken mit einem nicht zu vernachlässigenden Erwartungswert und hohem Personalaufwand rücken in den Fokus. Das ist besonders relevant, wenn sich

FEHLERMÖGLICHKEITS- UND EINFLUSSANALYSE (FMEA):

Die Fehlermöglichkeits- und Einflussanalyse, kurz FMEA, ist eine bewährte Methode zur Analyse und Bewertung von Risiken. Anhand verschiedener Kategorien wird in einem mehrstufigen Ablauf ein Risikowert berechnet [25].

der personelle Aufwand zur Steuerung und Kontrolle für jedes Risiko unterscheidet – etwa wenn risikobezogene Informationen aus vielfältigen Quellen manuell zusammengetragen und aufbereitet werden müssen.

Ein weiterer Vorteil der Risikobewertung: Der quantifizierte Nutzen kann als Diskussionsgrundlage für die Verhandlungen mit dem Top-Management herangezogen werden, um die Budgethöhe und die Allokation von Ressourcen für die ML-Implementierung zu bestimmen.

Das Ergebnis dieses Prozessschritts ist eine Priorisierungsreihenfolge der Risiken anhand der Höhe des ermittelten Gesamtnutzwerts.

ANWENDUNGSFALLENTWICKLUNG (D)

Nachdem Sie die relevanten Risiken identifiziert, erste Lösungskonzepte zugeordnet sowie Risiken bewertet und priorisiert haben, folgt die Entwicklung der Anwendungsfälle als letzter Schritt der Planungsphase. Ziel ist es, ein **konkretisiertes Rahmenwerk für ML-Anwendungsfälle** im SCRM-Kontext auf Basis der vorliegenden Ergebnisse zu **entwickeln**. Dieser Schritt ist Hauptteil der Planungsphase. Mit der konzeptionellen Anwendungsfallentwicklung können Sie Nutzen, Funktionalität, Wirtschaftlichkeit und etwaige negative Folgen der Lösungen valide bewerten [21]. Nun entscheiden Sie über den weiteren Projektverlauf und welche Lösungsansätze Sie weiterverfolgen möchten. Ziehen Sie hierbei die Perspektiven aller beteiligten Anspruchsgruppen mit ein. Bei einer positiven Bewertung folgt die Überführung in explizite Anwendungsfälle und die detaillierte Prüfung der Umsetzungsvoraussetzungen in der anschließenden Evaluationsphase.

Um den Nutzen, die Funktionalität und Wirtschaftlichkeit zu bewerten, gilt es angemessene Kriterien aus der SCRM-, ML- und Unternehmensperspektive aufzustellen.

Die Definition des **Nutzens** ist ein kritischer Punkt im Implementierungsprozess. Zum einen sollte hier aus organisatorischer Perspektive verdeutlicht werden, worin das grundlegende Problem besteht. Hierfür können Fachkräfte aus dem jeweiligen Supply-Chain-Bereich einbezogen werden. Zum anderen ist das konkrete Ziel zu definieren und die Erwartungshaltung der Nutzenden hinsichtlich der Umsetzung im realen Umfeld zu bestimmen. So beugen Sie Missverständnissen in der Kommunikation zwischen dem Projektteam und dem Management vor [27].

Im Hinblick auf die **Funktionalität** kann z. B. eine Problemlösungsmatrix helfen. Zeigen Sie in der ersten Dimension die ML-Funktionen und in der zweiten Dimension die Risiken auf. So lassen sich anschließend in den einzelnen Zellen Probleme und Lösungen gegenüber-

stellen [28]. Mit der Zuordnung von Problemen zu Lösungen geht die Prüfung der technischen Umsetzung durch ML einher. Sollte sich herausstellen, dass ein Problem zu komplex ist und ML nicht zu dessen Lösung beitragen kann, verwerfen Sie den Ansatz. Zu komplexe Probleme entstehen, wenn ein hohes Maß an implizitem Wissen von Fachkräften gefordert ist oder eine Vielzahl an Restriktionen die Umsetzung mit ML erschweren [29].

Weiterhin sollte neben dem Kernteam auch das Top-Management entscheiden, ob der jeweilige Anwendungsfall aus wirtschaftlicher Sicht weiterverfolgt wird. Für die **Wirtschaftlichkeit** kann beispielsweise ein Schwellenwert gesetzt werden. Dieser definiert den Punkt, ab dem mittel- bis langfristig ein positives wirtschaftliches Verhältnis zum Aufwand für die Implementierung von ML besteht. Entsprechend verfolgen Sie nur Risiken weiter, deren Nutzwert über dem Schwellenwert liegen. Relevante Faktoren sind unter anderem die Investitionen für die Anschaffung der Technologie, Kosten für die Akquirierung von externem Fachwissen und/oder die Schulung der eigenen Mitarbeitenden.

Den Abschluss dieses Prozessschritts bildet die **Gesamtbewertung der Konzepte**. Darüber hinaus sollten Sie mögliche Probleme einbeziehen, die während der Analyse aufgedeckt wurden, etwa zu komplexen Problemstellungen des Anwendungsfalls. Mit einer positiven Bewertung geben alle an der Entscheidung beteiligten Anspruchsgruppen (auch Stakeholder genannt) ihre Zustimmung für die Überführung des konzeptionellen Anwendungsfalls in die Evaluationsphase. In dieser Phase überprüfen Sie die hier formulierten Umsetzungsvoraussetzungen detailliert und auf Machbarkeit. Liegt eine negative Gesamtbewertung vor, verwerfen Sie den Anwendungsfall. Sinnvoll ist es, mehr als einen Anwendungsfall parallel zu bewerten, um am Ende der Planungsphase gleich mehrere Anwendungsfälle vorliegen zu haben. Bei hoher Ressourcenkapazität ist ebenso die gleichzeitige Durchführung mehrerer Projekte denkbar. Ansonsten können Sie Anwendungsfälle zurückstellen, um später auf diese zurückzukommen.

3.3 Evaluationsphase

Die Evaluationsphase ist die letzte Phase der Planung. Die folgenden Schritte sind für jeden einzelnen zuvor entwickelten Anwendungsfall durchzuführen, wobei Sie auch hier mehrere Fälle parallel bearbeiten können.

Überprüfen Sie für jeden Anwendungsfall, ob die Umsetzungsvoraussetzungen erfüllt sind. Dazu dient das zuvor entwickelte Konzept für den Anwendungsfall (siehe

Abschnitt 3.2, Seite 15) als Leitlinie. Hierfür können Sie beispielsweise das **TOE-Modell als Grundlage zur Strukturierung** nutzen [28], das eine Fragestellung aus technologischer (T), organisationaler (O) und umweltbezogener Perspektive (E = engl. Environment) betrachtet. Beispiele zur Konkretisierung: Die technologische Perspektive umfasst Aspekte, wie die IT-Architektur oder die Datenqualität. Aus organisatorischer Perspektive besteht der Fokus primär auf den vorhandenen Kompetenzen, die notwendig für die erfolgreiche Implementierung von ML sind. Ethische und regulatorische Aspekte sind Teil der umweltbezogenen Perspektive und sollten ebenfalls einer umfassenden Prüfung unterzogen werden [28]. Für die adäquate Prüfung können Sie entsprechende Fragenkataloge entwickeln. Dafür bietet es sich z. B. an, gemeinsam mit allen Projektbeteiligten Workshops durchzuführen.



Abbildung 5: Evaluationsphase des Vorgehensmodells

Die TOE-Perspektiven bzw. die folgenden drei Prozessschritte finden parallel zueinander statt (s. Abb. 4) – alle Schritte besitzen die gleiche Relevanz. Anschließend folgt eine weitere Evaluation bezüglich der Fortführung des Projekts. Fällt diese positiv aus und alle Umsetzungsvoraussetzungen sind erfüllt, erstellen Sie einen Projektplan für die Realisierung des Anwendungsfalls (siehe Seite 20). Anderenfalls verwerfen Sie den aktuellen Fall und greifen einen weiteren Anwendungsfall aus der Planungsphase auf.

TECHNOLOGISCHE PERSPEKTIVE

In dieser Perspektive prüfen Sie die Umsetzungsvoraussetzungen für die Bereiche Daten, IT-Infrastruktur und Kompatibilität. Dabei sind u. a. die Verfügbarkeit, Qualität, Quantität und Relevanz der zugrundeliegenden Daten kritische Aspekte, um ML-Projekte zu realisieren. Im Zusammenhang mit SCRM kann es sich hierbei um Lieferanten-, Transport-, Produktions- oder Verkaufsdaten handeln. Auch externe Quellen bzw. Daten wie Nachrichten, Wetterberichte oder Beiträge aus sozialen Medien können Sie mithilfe von ML nutzbar machen [30]. Aufgrund der unternehmensübergreifenden Charakteristik von SCRM sollte der Fokus auf dem Datenaustausch mit den an der Lieferkette Beteiligten liegen, da die Bereitschaft, Informationen und Daten zu teilen, wesentlich für ein erfolgreiches SCRM ist [31]. Mit der Überprüfung der Datenverfügbarkeit stellen Sie sicher, dass in der Realisierungsphase keine ungeplanten Verzögerungen drohen [32].

In Hinblick auf die Datenqualität sind die Aspekte **Konsistenz** und **Vollständigkeit** wichtig [33]. Fehlerhafte und unzureichend strukturierte Daten resultieren in Mehraufwand, der sich über die Implementierung hinaus als Störfaktor etablieren kann. Außerdem muss eine ausreichende Menge an Daten zur Verfügung stehen, um den ML-Algorithmus zu trainieren [34]. Dieser Aspekt ist von besonders hoher Bedeutung für die Umsetzung des Anwendungsfalls [35]. Es ist nicht erforderlich, dass die verfügbaren Daten den Vorgaben des SCRM-Anwendungsfalls ausnahmslos entsprechen. Vielmehr sollten Sie die Daten als Ausgangspunkt nutzen und den Umfang des Anwendungsfalls entsprechend anpassen. Sie können jederzeit ergänzende und wertschöpfende Daten miteinbeziehen und das ML-Modell stetig verbessern [30].

Die vorhandene IT-Infrastruktur hat sowohl Auswirkungen auf die Höhe der Investitionskosten als auch auf die langfristige Effizienz des Prozesses [36]. Zum Datenaustausch sollten Sie den Supply-Chain-Partnern einen standardisierten Prozess kommunizieren und implementieren. So können Sie sicherstellen, dass die richtigen Daten in der richtigen Quantität und Qualität zum richtigen Zeitpunkt empfangen werden. Gerade bei interorganisationalen Strukturen sind besonders die Speicherung und Verarbeitung der Daten in Bezug auf Datensicherheitsaspekte zu überprüfen [32]. Hierfür können Sie z. B. ein **Risk Data Warehouse** aufbauen, das diese Funktionen übernimmt oder Clouds für den Austausch und die Verarbeitung der Daten nutzen [22] [37].

Schließlich sollte die Kompatibilität des Anwendungsfalls zur angestrebten ML-Lösung überprüft werden. So vermeiden Sie Verzögerungen aufgrund von unvorhergesehenen Restriktionen während der Realisierungsphase. Klären Sie die Grundvoraussetzungen

am Einsatzort bezüglich der geplanten Interaktion mit dem ML-Modell. Hier sollten notwendige Kapazitäten für die Visualisierungsinstrumente verfügbar sein. Dies können z. B. entsprechende IT-Infrastruktur-Fachkräfte prüfen und damit bestimmen, welche Voraussetzungen benötigt werden. So vermeiden Sie unter- bzw. überperformante Lösungen und in deren Folge unnötige Kosten [38].

ORGANISATIONALE PERSPEKTIVE

Hier liegt der Schwerpunkt auf den vorhandenen Fähigkeiten, dem Wissen sowie dem Engagement der beteiligten Stakeholder. Weiterhin ist zu prüfen, wie der SCRM-Prozess im Rahmen der Implementierung im organisatorischen Kontext eingeordnet wird.

Die Fähigkeiten und das Wissen der am Prozess beteiligten Personen sind ein weiterer kritischer Einflussfaktor für die erfolgreiche Umsetzung von ML im SCRM. Es gilt zu überprüfen, ob das Projekt durch die **Fähigkeiten der Mitarbeitenden** umgesetzt werden kann. Besonders bei der Implementierung von ML kann sich eine Partnerschaft mit auf KI spezialisierten Unternehmen empfehlen, da die Modellierung von Algorithmen und der damit einhergehende organisatorische Wandel zumeist nicht zu den Kernkompetenzen der umsetzenden Unternehmen gehören [38]. Daher ist es umso wichtiger, dass Sie **alle betroffenen Stakeholder in den Implementierungs- bzw. Veränderungsprozess einbeziehen** und so ein Bewusstsein für die neuen Prozessabläufe schaffen [39]. Dies gilt ebenfalls für die Führungskräfte, die den Prozess im Anschluss

RISK DATA WAREHOUSE:

Unter einem Risk Data Warehouse ist eine Datenbank zu verstehen, die ausgewählte Information zu den relevanten Risiken beinhaltet [22].

an das Projekt betreuen. Das Verständnis für fortgeschrittene datenorientierte Analysen ist daher besonders zu fördern [40]. Weiterhin sollten Sie die Unterstützung des Top-Managements sowie der beteiligten Supply-Chain-Partner sicherstellen und für die Möglichkeiten von ML sensibilisieren. Darüber hinaus bedarf es zwingend der Unterstützung und Akzeptanz auf Ebene der Mitarbeitenden [23].

Bezüglich der Umsetzung sollten Sie Themen wie **Budget** und **Ziele** umfangreich diskutieren. Bereits vor Beginn der Umsetzung ist festzulegen, wie die neuen Prozesse in der Organisationsstruktur etabliert werden. Daher sollten Supply-Chain-Risiken nicht unabhängig von anderen risikobezogenen Unternehmensfunktionen betrachtet werden [41]. Richten Sie am besten eine zentrale Stabs- oder Leitstelle ein, um die Kommunikation zu zentralisieren [42].

UMWELTBEZOGENE PERSPEKTIVE

Schließlich prüfen Sie die externen Voraussetzungen, wobei Sie sowohl die Umwelt bzw. die **äußerlichen Rahmenbedingungen** des Unternehmens als auch soziale Faktoren mit einbeziehen.

Zunächst ist zu überprüfen, ob das ML-Projekt im Konflikt mit den lokalen Gesetzen der Region steht. Welche **Richtlinien** bestehen vor Ort zur Speicherung von Daten? Mit der Klärung dieser Frage beugen Sie unter anderem Zweckentfremdungen und schadhafte Verwendungen vor [38]. Auch die zu berücksichtigenden Rahmenbedingungen für die **Zusammenarbeit mit Supply-Chain-Partnern** sollten Sie intensiv betrachten, um mögliche Konflikte zu vermeiden. In Bezug auf die ethischen Anforderungen sind Unternehmensintegrität und Diversität/Inklusion wichtige Aspekte. Dabei spielen insbesondere diejenigen Daten der Kundschaft und Lieferanten eine treibende Rolle, die von dem ML-Modell verwendet werden. Beispielhaft ist der sogenannte **Black-Box-Effekt** von ML-Algorithmen zu nennen. Da die Rechenoperationen eines ML-Modells aufgrund der Komplexität des Problems nicht immer vollständig von Menschen nachvollzogen werden können, besteht die Gefahr von diskriminierenden Entscheidungen. Die Empfehlungen des ML-Modells sind daher zwingend durch Mitarbeitende zu prüfen [43]. Sofern der Schritt zur Automatisierung zu einer Reduktion des Personalbestands oder einem deutlichen Einschnitt des Tätigkeitsbereichs führt, sollten Sie die aufkommende **Veränderung** frühzeitig **kommunizieren** und dafür sensibilisieren. Resultierende Vertrauensverluste der Mitarbeitenden können negative Auswirkungen auf die gesamte Nutzungsbereitschaft der Endnutzenden haben [44].

Sind alle Perspektiven hinreichend betrachtet und geprüft, erfolgt eine **abschließende Bewertung der Ausgangssituation**. Nun entscheidet sich, ob ein Anwendungsfall in die Realisationsplanung überführt wird oder nicht. Mit einer positiven Bewertung wird die Realisierung des Anwendungsfalls fortgesetzt, fällt sie negativ aus, wird er verworfen. Sollte Letzteres der Fall sein, lohnt sich der Blick auf zuvor zurückgestellte Anwendungsfälle aus der Planungsphase. Dann initiieren Sie wiederum die Evaluationsphase und prüfen den neuen Anwendungsfall anhand der TOE-Perspektiven.

REALISATIONSPLANUNG

Mit der Entscheidung zur Umsetzung des ML-Anwendungsfalls folgt als letzter Schritt der Evaluationsphase die **Erarbeitung eines Projektplans** [45]. Dieser umfasst die einzelnen Entwicklungsstufen des ML-Modells. Bestimmen Sie für jede Stufe die vorgesehene Dauer, die verwendeten Instrumente und mögliche Risiken. Beachten Sie bei ML-Implementierungsprojekten besonders Verzögerungen im Projektablauf, da zu Beginn nicht exakt definiert werden kann, wie viel Zeit die jeweiligen Entwicklungsstufen in Anspruch nehmen werden. Daher bietet es sich an, proaktive Maßnahmen im Falle von Verzögerungen vorab zu bestimmen, um weiteren ungeplanten Aufwand zu reduzieren. Der Projektplan dient außerdem zur Überprüfung des Fortschritts. Hierzu könnten Meilensteine definiert werden, die in regelmäßigen Abständen aktualisiert und kontrolliert werden. Alternativ können Sie ML-Projekte mithilfe von agilen Projektmanagementmethoden steuern. Unter Zuhilfenahme von sogenannten „Sprints“ werden

BLACK-BOX-EFFEKT:

Black-Box-Effekt meint, dass gewisse Entscheidungen eines ML-Algorithmus für den Menschen nicht immer in Gänze nachvollzogen werden können. Daher gewinnt die Richtigkeit der ML-basierten Entscheidungen stark an Bedeutung, damit Mitarbeitende eine solide Vertrauensbasis aufbauen können [43].

kleine Arbeitspakete für wenige Wochen oder sogar Tage geschnürt. Anschließend findet im Rahmen von „Sprint Reviews“ eine erneute Bewertung der Ist-Situation statt und der nächste Sprint wird initiiert.

3.4 Realisationsphase

Die Realisationsphase beginnt, wenn alle Voraussetzungen zur Implementierung erfüllt sind. Während die Investitionen in die IT-Architektur parallel zur Entwicklung des ML-Modells erfolgen können, ist die Bereitstellung der notwendigen Software und Hardware eine weitere Bedingung für die Entwicklungsaktivitäten. Alternativ können Sie für die Entwicklung des ML-Modells das Know-how eines spezialisierten Dienstleistungsunternehmens nutzen. Gleiches gilt für das Design der IT-Architektur. Hier besteht die Möglichkeit, dass Sie die Architektur auf Basis Ihrer Wünsche entwickeln lassen oder aber Sie nutzen bestehende IT-Lösungen (z. B. Cloud), die als marktreife Produkte vertrieben werden [23].

Der Fokus der Realisationsphase liegt auf der **Entwicklung des ML-Modells**, das basierend auf den Ergebnissen der Planungsphase gestaltet wird. Um das ML-Modell technisch zu entwickeln, bietet sich beispielsweise das in Forschung und Praxis etablierte CRISP-DM-Modell an [45]. In diesem Zusammenhang lauten die weiteren Prozessschritte: Datenauswahl, Datenvorbereitung, Modellentwicklung und Modellvalidierung (s. Abb. 5).



TIPP:

Mehr zu agilen Methoden erfahren Sie im Leitfaden „Projektmanagement für KMU in Zeiten der Digitalisierung“

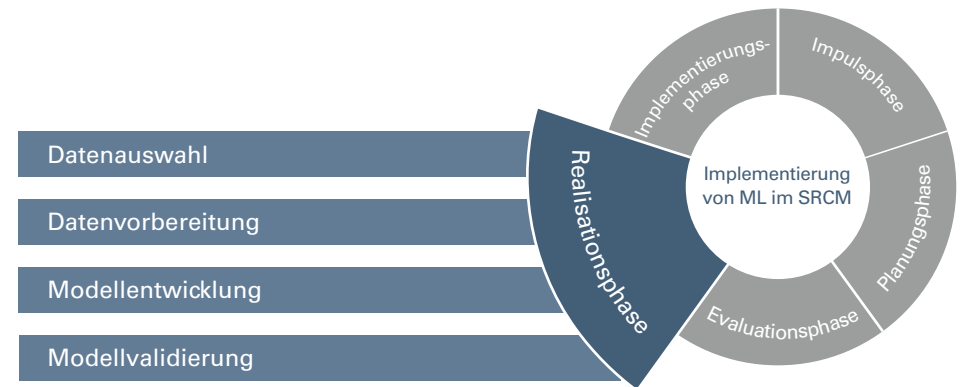


Abbildung 6: Realisationsphase des Vorgehensmodells

DATENAUSWAHL

Die Datenauswahl fokussiert auf die Selektion der richtigen Daten, um die Zielsetzung des Anwendungsfalls zu erreichen. Folgende Punkte sind bereits aus der Evaluationsphase bekannt: Welche Daten verwendet werden, ob die notwendigen Daten in ausreichender Qualität und Quantität vorliegen und welche Daten in Zukunft erfasst werden müssen, um das ML-Modell zu verbessern. Dennoch ist eine weitere Selektion der Daten für die Entwicklung des Modells erforderlich – Struktur und Bedeutung der Daten können sich unterscheiden, da sie aus externen und internen Quellen zusammengetragen werden.

Eine nicht einheitliche Struktur der Daten könnte bereits dadurch bedingt sein, dass Unternehmen einer Supply Chain unterschiedliche (ERP-)Systeme nutzen. Auch wenn langfristig das Ziel ist, einen Standard für das Datenformat zu kommunizieren, ist das bei der erstmaligen Implementierung meist nicht gegeben. An dieser Stelle ist es notwendig zu bestimmen, wie die Attribute in den verschiedenen Datensets definiert sind. Beispielfähig kann sich in einer Bestellübersicht von Make-to-Order-Produkten die Definition eines Attributs wie „Lieferzeit in Tagen“ deutlich unterscheiden. Während z. B. Unternehmen A zur Lieferzeit auch die Durchlaufzeit der Produktion addiert, könnte sich Unternehmen B nur auf die Lieferzeit vom Lager zum Bestimmungsort beziehen und die Durchlaufzeit der Produktion separat abbilden – der Datensatz wäre nachträglich anzupassen. Hierfür empfiehlt es sich, das Know-how der SupplyChain-Mitarbeitenden der entsprechenden Funktionsbereiche in die Datenauswahl einzubinden. Besonders vor dem Hintergrund der

Supply-Chain-Komplexität durch Abhängigkeiten und Restriktionen ist Fachwissen zur richtigen Bewertung der Daten unabdingbar. Ein weiterer Faktor ist der bereits erwähnte Black-Box-Effekt, der u. a. zu diskriminierenden Entscheidungen führen kann. Ein Beispiel hierfür ist die Auswahl des betrachteten Zeitraums. Wenn der Algorithmus ausschließlich auf Basis von Daten eines Zeitraums trainiert wird, in dem ein Lieferant eine unterdurchschnittliche Liefertreue aufwies, kann das reale Bild verzerrt werden [30]. Diese Situation kann Ihr Team mit der richtigen Auswahl und dem richtigen Verständnis für die Daten vorbeugen [44]. Fachspezifische Kenntnisse sind also zwingend notwendig, um die entsprechende Grundlage für die Datenanalyse zu schaffen.

DATENVORBEREITUNG

Der zweite Prozessschritt beschreibt die Aufbereitung und Zusammenführung der Datensätze, um diese für das Training des Algorithmus und die Datenanalyse zu nutzen. Dieser Prozessschritt umfasst etwa die Bereinigung der Daten, die Konstruktion von Attributen und Einträgen, die Integration der Datensätze und ihre abschließende Formatierung [46].

Mit der Bereinigung der vorhandenen Daten soll ein kompakter und vertrauenswürdiger Datensatz kreiert werden. Daher widmen Sie sich zunächst der Prüfung und Bereinigung von inkonsistenten und unvollständigen Einträgen. Fehlende Einträge lassen sich durch Schätzungen oder Annahmen vervollständigen, sodass die Datenqualität erhöht wird [46]. Die Konstruktion von neuen Daten, auch Feature Engineering genannt, hat das Ziel, die Aussagekraft des Datensets zu verbessern. Hierzu werden aus den vorhandenen Attributen neue Attribute abgeleitet [30]. In Bezug auf das aufgezeigte Beispiel des Attributs „Lieferzeit in Tagen“ wäre die Addition der Werte „Lieferzeit“ und „Durchlaufzeit“ aus dem Datensatz des Unternehmens B ein Beispiel für Feature Engineering. Somit werden die Datensätze der Unternehmen A und B angeglichen und die Anzahl der Attribute im aggregierten Datensatz reduziert sowie anschließend zusammengeführt und formatiert. Durch die Formatierung wird die Gesamtheit der Daten in ein für den Algorithmus verständliches Format gebracht, ohne deren Aussage zu ändern [46].

MODELLENTWICKLUNG

Nun wird der ML-Algorithmus auf Basis des vorbereiteten Datensatzes trainiert. Für die Modellentwicklung erfolgt zunächst eine Eingrenzung der Algorithmen, die auf das Szenario anwendbar sind. Richten Sie die Auswahl des Algorithmus im SCRM-Kontext nach dem Ziel des Risiko-Anwendungsfalls aus [30]. Es gibt für nahezu jedes SCRM-Problem



eine passende Modellierungstechnik [22]. So wird die Entwicklung eines Frühwarnsystems beispielsweise als **Vorhersageproblem** klassifiziert, für dessen Lösung Sie Regressionstechniken verwenden können [22]. Weiterhin sollten die ausgewählten Algorithmen dem neuesten Stand der Technik entsprechen [33]. Daher ist erforderlich, sich kontinuierlich über den aktuellen Stand der Technik in Bezug auf ML-Algorithmen zu informieren. Nachdem Sie eine oder mehrere Modellierungstechniken ausgewählt haben, folgt die Gestaltung des Testdesigns [45]. Bei einigen ML-Methoden ist es erforderlich, den bestehenden Datensatz in einen Trainings- und Testdatensatz aufzuteilen. So überprüfen Sie, ob der Algorithmus die richtigen Entscheidungen getroffen hat [46].

Den Schwerpunkt dieser Phase bilden die **Entwicklungsaktivitäten**. Hierzu wenden Sie die ausgewählten Algorithmen auf den Trainingsdatensatz an und evaluieren dies mithilfe von entsprechenden Messgrößen [46]. Die Auswahl der entsprechenden Messgröße hängt vom angewendeten Algorithmus ab [35]. Im Rahmen der Modellierung und Bewertung sollten Sie besonders die **Nachvollziehbarkeit der Rechenoperation** sowie **ethische Aspekte** berücksichtigen – beides sind kritische Faktoren für den Erfolg der

anschließenden Validierung des ML-Modells. Wenn die Ausgabe des Modells nicht nachvollziehbar ist, kann sich das negativ auf die Nutzungsbereitschaft Ihrer Stakeholder auswirken. Hinterfragen Sie zudem kritisch, wie das Modell auf Basis der Datenlage zum Ergebnis kommt, um diskriminierende Entscheidungen auszuschließen.



MODELLVALIDIERUNG

Anschließend validieren Sie das resultierende ML-Modell unter betriebswirtschaftlichen Faktoren. Ein Erfolgskriterium sind die Entscheidungen, die auf Grundlage der Ergebnisse des Modells getroffen werden können, um die Auswirkungen auf die Profitabilität des Unternehmens zu evaluieren. Die Validierung erfolgt in enger Abstimmung mit dem Top-Management, welches das Ergebnis aus betriebswirtschaftlicher Sicht bewertet – ML im SCRM wird schließlich zur Entscheidungsfindung in Situation verwendet, die bedeutend für den Geschäftserfolg sind. Die Beteiligung des Top-Managements schafft dementsprechend die notwendige Transparenz.

Mit Abschluss dieses Prozessschritts erfolgt die Bewertung des Gesamterfolges der Realisationsphase. Befürwortet das Top-Management das Ergebnis, folgt die Implementierung. Im Falle einer negativen Bewertung besteht zum einen die Möglichkeit, den Entwicklungsprozess erneut anzustoßen. Zum anderen kann die weitere Entwicklung an dieser Stelle abgebrochen und der Prozess erneut mit einem alternativen Anwendungsfall initiiert werden.

3.5 Implementierungsphase

Die letzte Phase des Vorgehensmodells beschreibt die Implementierung des zuvor entwickelten ML-Modells in die Unternehmensstrukturen. Sie hat die Evaluierung des Modells unter realen Einsatzbedingungen, die Nutzungseffizienz und -bereitschaft der Endnutzenden sowie das weitere Vorgehen nach der Implementierung zum Ziel (s. Abb. 6).

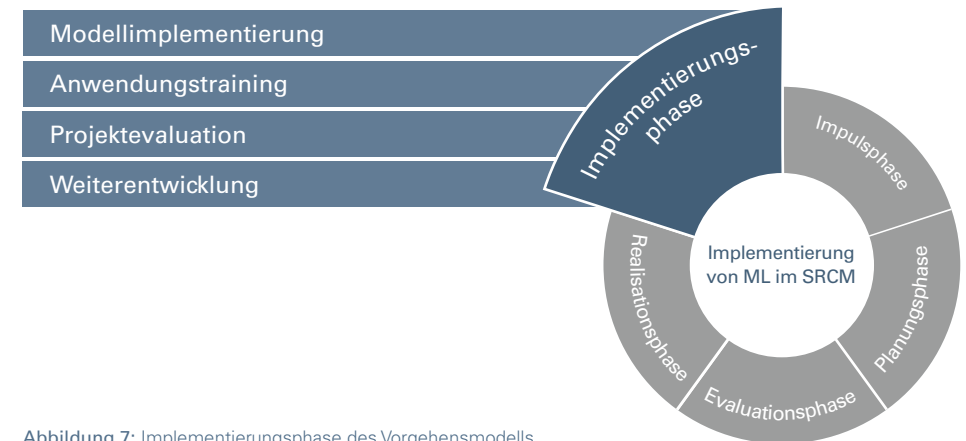


Abbildung 7: Implementierungsphase des Vorgehensmodells

MODELLIMPLEMENTIERUNG

Für die Implementierung des ML-Modells müssen die in der Evaluationsphase identifizierten Voraussetzungen erfüllt bzw. umgesetzt sein. Dies betrifft erstens die IT-Architektur, mit der interne und externe Daten in das ML-Modell überführt werden. Zweitens muss sowohl die notwendige Soft- als auch Hardware zur Verfügung stehen, um die Ausgabedaten des ML-Modells aussagekräftig darzustellen. Denn nur wenn Sie die resultierenden

Informationen in Ihr Berichtswesen integrieren und visualisieren, kann das ML-Modell zur Profitabilität Ihres Unternehmens beitragen [37]. Nun ist es so weit und das Projektteam startet den Test des ML-Modells mit anschließender Evaluierung.

In der vorherigen Phase haben Sie den Algorithmus des ML-Modells trainiert, unter Berücksichtigung der spezifischen Anwendungsfallziele, dem Wissen der Supply-Chain-Fachkräfte und anhand von historischen Daten die richtigen Entscheidungen zur Identifikation, Bewertung und Steuerung des Supply-Chain-Risikos zu treffen. Die Kontrolle des Risikos – im SCRM-Kreislauf der vierte Schritt – ist in diesem Fall der Ausgangspunkt für den ML-basierten **SCRM-Prozess**. Das ML-Modell wird in der SCRM-Phase **Risikokontrolle** stetig mit neuen Daten versorgt, die es bezüglich Unregelmäßigkeiten oder bekannter Muster analysiert. Deren Auffinden bzw. Identifikation entspricht der SCRM-Phase **Risikoidentifikation**. In Abhängigkeit vom Funktionsumfang des ML-Modells wird das identifizierte Risiko anschließend beurteilt (**Risikobewertung**). Daraufhin kann das ML-Modell in der **Risikosteuerung** basierend auf der Art des Risikos, dem vorhergesagten Erwartungswert des Schadens und historischen Erfahrungswerten die passenden Strategien zur Risikominderung empfehlen.



Die Ergebnisse bzw. empfohlenen Strategien des ML-Modells können Sie in den jeweiligen Supply-Chain-Funktionsbereichen nun als Entscheidungsunterstützung nutzen. Bevorzugt bezieht das Modell Mitarbeitende während des gesamten ML-basierten SCRM-Prozesses in Form von Feedbackschleifen mit ein. So kann der Mensch nach jeder SCRM-Phase eine Rückmeldung geben, ob das Modell die richtigen Entscheidungen getroffen hat. Positiver Nebeneffekt bei dieser Variante ist, dass der Algorithmus durch die menschliche Feedbackschleife trainiert wird und somit seine Genauigkeit kontinuierlich verbessert. Die Rückmeldung an das ML-Modell sollte durch Supply-Chain-Fachkräfte erfolgen – im Idealfall ergänzt durch eine Bewertung der beteiligten Supply-Chain-Partner. Das kann bei Partnerunternehmen auch einen positiven Effekt auf die Vertrauensbasis haben und somit die langfristige Zusammenarbeit fördern [24].

Nach der Implementierung des ML-Modells wird auf Grundlage der Bewertungsergebnisse aller beteiligten Stakeholder entschieden, ob das Modell dauerhaft zum Einsatz kommt. Wenn der Nutzen positiv ist und kein weiterer Handlungsbedarf durch die Entwickelnden besteht, können Sie das Modell in den Serienbetrieb überführen. Besteht Verbesserungsbedarf, empfiehlt es sich, die Realisationsphase erneut zu durchlaufen. Hierdurch können Sie mögliche Fehler im Entwicklungsprozess eliminieren.

ANWENDUNGSTRAINING

Das Verständnis und Vertrauen der Endnutzenden für ML im SCRM-Prozess sind für den langfristigen Erfolg der ML-Implementierung sehr wichtig. Beide Faktoren beeinflussen die Nutzungsbereitschaft und Effizienz des ML-Modells im großen Maße. Daher sollten Sie die Endnutzenden dahingehend schulen, dass sie die Ergebnisse des ML-Modells im SCRM-Kontext nachvollziehen und interpretieren können [19]. Beeinflusst wird die individuelle Nutzungsbereitschaft von innovativen Technologien maßgeblich durch die wahrgenommenen Vor- und Nachteile. Das theoretische Verständnis für ML und den SCRM-Prozess sind Aspekte, mit denen Sie das Verständnis und Vertrauen der Mitarbeitenden gezielt stärken können. Zudem sollten Sie die Vorteile der Technologie in den Vordergrund stellen und Maßnahmen ergreifen gegen Bedenken wie Jobverlust durch Automatisierung.

Zentraler Bestandteil des Anwendungstrainings ist die Durchführung von Workshops, die i. d. R. das Projektteam vorbereitet und moderiert. Ablauf und Umfang der Workshops werden dabei an die aktuellen Fähigkeiten, das vorhandene Wissen und die Bedenken der Mitarbeitenden gegenüber ML im SCRM angepasst. Es gilt, das Projektvorhaben ganzheitlich zu beschreiben und Potenzial und Grenzen aufzuzeigen und für ML im SCRM

zu sensibilisieren. So können Sie beispielsweise das Prozessverständnis von SCRM festigen und die Relevanz von proaktivem Handeln verdeutlichen. Machen Sie verständlich, was zwischen der Eingabe von Daten und der Ausgabe von Ergebnissen im ML-Modell passiert. Das Top-Management sollte zu einem gewissen Grad ebenfalls involviert sein, um den Mitarbeitenden die Intention des Projekts zu vermitteln und um eine langfristige Strategie aufzuzeigen. Transparenz bei Implementierungs- bzw. Transformationsprojekten reduziert die individuell wahrgenommenen Risiken durch die Technologieadoption [44].

PROJEKTEVALUATION

Nach erfolgreicher Durchführung des Implementierungsprojekts verfasst das Projektteam einen entsprechenden Abschlussbericht und dokumentiert alle relevanten Informationen. So können positive und negative Erfahrungen sowie gewonnen Erkenntnisse reflektiert und für weitere Projekte festgehalten werden.

WEITERENTWICKLUNG

Der letzte Prozessschritt umfasst die Notwendigkeit der kontinuierlichen Verbesserung und Kontrolle des ML-Modells. Das Modell kann anhand von Echtzeitdaten im operativen Betrieb weiter trainiert werden [37]. Kontrollieren Sie dabei das Modell und dessen Resultate in regelmäßigen Abständen, auch nach dem Projektende – bestenfalls unterstützt durch Ihre ML-Fachkräfte. Benennen Sie im operativen Betrieb Verantwortliche im Supply-Chain-Team, die das notwendige Verständnis haben, Ergebnisse kritisch zu hinterfragen, Probleme zu identifizieren und diese adäquat zu adressieren. Diese helfen dabei, Ideen zur Verbesserung des ML-Modells zu sammeln und zu kommunizieren [47].

VIER

WARUM – LOHNT SICH DER EINSATZ VON MASCHINELLEM LERNEN IM SUPPLY-CHAIN-RISIKOMANAGEMENT?

Die Handlungsfähigkeit und Profitabilität von Lieferketten werden zunehmend durch Supply-Chain-Risiken beeinträchtigt. Besonders global agierende Unternehmen mit komplexen Wertschöpfungsnetzwerken spüren die negativen Auswirkungen. Zur Bewahrung der Wettbewerbsfähigkeit ist proaktives Handeln essenziell, um die Resilienz der Lieferketten zu stärken. Aus diesem Grund ist die Integration von SCRM vermehrt in den Fokus der Aufmerksamkeit von Unternehmen geraten [30]. Mithilfe eines effektiven SCRM-Prozesses lassen sich Risiken strukturiert identifizieren und bewerten. Anschließend können Unternehmen dem potenziellen Risiko eine geeignete Vermeidungsstrategie zuordnen, um die Eintrittswahrscheinlichkeit und somit den Schaden zu verringern.

Ungeachtet der Vorteile, die mit der Integration von SCRM verbunden sind, erschweren verschiedene Faktoren bis heute die Umsetzung in der Praxis. Hierzu zählen die mangelnde Transparenz, der eingeschränkte Informationsaustausch mit Supply-Chain-Partnern und eine hohe Ressourcenauslastung. Diesbezüglich eröffnen die Digitalisierung und Industrie 4.0 den Unternehmen neue Möglichkeiten [48]. Methoden der künstlichen Intelligenz haben großes Potenzial – so auch das ML. Ein wesentliches Merkmal von ML ist die Fähigkeit, umfangreiche Mengen an Daten auf erlernte Muster zu untersuchen und darauf basierend Vorhersagen zu treffen. Weiterhin lassen sich ML-Modelle automatisieren, wodurch Ressourcenaufwand und Kostenbasis gesenkt werden können. Zusammenfassend vereint die integrierte Umsetzung von ML und SCRM die jeweiligen Vorteile und kann Unternehmen zu proaktivem und vorausschauendem Handeln in der Supply Chain befähigen. Wagen Sie den ersten Schritt in Ihrem Unternehmen!

FÜNF

LITERATUR

QUELLEN ZUM WEITERLESEN

M. Brylowski, M. Schröder, W. Kersten, „*Machine Learning im Supply Chain Risk Management: Studie*“, 2021, <https://doi.org/10.15480/882.3875>.

T. Birgham, A. Tua, T. Mews, S. Nair, V. Gallo, M. Fouché, S. Soral, M. Lee, „*AI and risk management – Innovating with confidence*“, Deloitte, Centre for Regulatory Strategy EMEA, 2018.

P. Boucher, „*Artificial intelligence: How does it work, why does it matter, and what can we do about it?*“, EPRS – European Parliamentary Research Service, 2020, <https://doi.org/10.2861/44572>.

Allal-Cherif, O., Simon-Moya, V., Cuenca Ballester, A. C. (2021): „*Intelligent purchasing: How artificial intelligence can redefine the purchasing function*“, in: Journal of Business Research, Jg. 124, S. 69–76.

QUELLENVERZEICHNIS

- [1] I. Manuj und J. T. Mentzer, „Global Supply Chain Risk Management“ (en), *Journal of Business Logistics*, Jg. 29, Nr. 1, S. 133–155, 2008, doi: 10.1002/j.2158-1592.2008.tb00072.x.
- [2] W. Kersten, M. Schröder, M. Feser und M. Klotzbach, „Implementierung eines Supply Chain Risk Managements“ in 2013, S. 133–147.
- [3] A. Börsch, *COVID-19-Briefing: Auswirkungen auf den Welthandel: Deloitte Deutschland*. [Online]. Verfügbar unter: <https://www2.deloitte.com/de/de/blog/covid-19-briefings/2020/covid-19-briefing-auswirkungen-auf-den-welthandel.html>.
- [4] W. Kersten, M. Schröder und M. Indorf, „Potenziale der Digitalisierung für das Supply Chain Risikomanagement: Eine empirische Analyse“ in *ZfbF-Sonderheft, Betriebswirtschaftliche Aspekte von Industrie 4.0*, M. Seiter, L. Grünert und S. Berlin, Hg., Wiesbaden: Springer Fachmedien, 2017, S. 47–74, doi: 10.1007/978-3-658-18488-9_3.

- [5] J. A. Perez, F. Deligianni, D. Ravi und G.-Z. Yang, „Artificial Intelligence and Robotics“ (en), S. 57, 2017.
- [6] C. Bünte, „Mehr als eine einfache Definition – das ist Künstliche Intelligenz“ in *Die chinesische KI-Revolution: Konsumverhalten, Marketing und Handel: Wie China mit Künstlicher Intelligenz die Wirtschaftswelt verändert*, C. Bünte, Hg., Wiesbaden: Springer Fachmedien, 2020, S. 53–72, doi: 10.1007/978-3-658-29795-4_3.
- [7] P. Buxmann, *Künstliche Intelligenz: Mit Algorithmen zum wirtschaftlichen Erfolg*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2019. [Online]. Verfügbar unter: <http://link.springer.com/10.1007/978-3-662-57568-0>
- [8] F. Weber, „Künstliche Intelligenz“ in *Künstliche Intelligenz für Business Analytics: Algorithmen, Plattformen und Anwendungsszenarien*, F. Weber, Hg., Wiesbaden: Springer Fachmedien, 2020, S. 37–72, doi: 10.1007/978-3-658-29773-2_2.
- [9] Y. Fan und M. Stevenson, „A Review of Supply Chain Risk Management: Definition, Theory, and Research Agenda“ (en), *IJPDLM*, Jg. 48, Nr. 3, S. 205–230, 2018, doi: 10.1108/IJPDLM-01-2017-0043.
- [10] P. G. P. Gaspar, P. S. Ceryno, A. L. Ferrer und A. M. T. Thomé, „Phases and Tools for Supply Chain Risk Management: A Systematic Literature Review“, *Gest. Prod.*, Jg. 27, Nr. 3, e4227, 2020, doi: 10.1590/0104-530x4227-20.
- [11] A. Ziegenbein, *Supply Chain Risiken: Identifikation, Bewertung und Steuerung*, vdf Hochschulverlag AG, 2007.
- [12] W. Kersten, P. Hohrath, M. Boeger und C. Singer, „A Supply Chain Risk Management Process“ (en), *IJLSM*, Jg. 8, Nr. 2, S. 152, 2011, doi: 10.1504/IJLSM.2011.038600.
- [13] D. Seibt, „Implementierung, organisatorische“, *Handwörterbuch der Organisation*, Jg. 2, S. 853–862, 1980.
- [14] M. Wollnik, *Implementierung computergestützter Informationssysteme: Perspektive und Politik informationstechnologischer Gestaltung*. DE GRUYTER, 1986. [Online]. Verfügbar unter: <https://www.degruyter.com/document/doi/10.1515/9783110858495/html>
- [15] K. F. Heusler, *Implementierung von Supply Chain Management*. Wiesbaden: Deutscher Universitätsverlag, 2004. [Online]. Verfügbar unter: <http://link.springer.com/10.1007/978-3-322-95307-0>

- [16] I. Anica-Popa, L. Anica-Popa, C. Radulescu und M. Vrancianu, „The Integration of Artificial Intelligence in Retail: Benefits, Challenges and a Dedicated Conceptual Framework“, *AE*, Jg. 23, Nr. 56, S. 120, 2021, doi: 10.24818/EA/2021/56/120.
- [17] L. V. Snyder, Z. Atan, P. Peng, Y. Rong, A. J. Schmitt und B. Sinsoysal, „OR/MS Models for Supply Chain Disruptions: A Review“, *IIE Transactions*, Jg. 48, Nr. 2, S. 89–109, 2016, doi: 10.1080/0740817X.2015.1067735.
- [18] S. AlSheibani, Y. Cheung und C. Messom, „Artificial Intelligence Adoption: AI-readiness at Firm-Level“ (en), S. 8, 2018.
- [19] R. Rana, M. Staron, J. Hansson, M. Nilsson und W. Meding, „A Framework for Adoption of Machine Learning in Industry for Software Defect Prediction“ in *9th International Conference on Software Engineering and Applications*, Vienna, Austria, 2014, S. 383–392, doi: 10.5220/0005099303830392.
- [20] M. Brylowski, M. Schröder und W. Kersten, „Machine Learning im Supply Chain Risk Management: Studie“ (de), 2021, doi: 10.15480/882.3875.
- [21] R. Haberfellner, O. de Weck, E. Fricke und S. Vössner, „Process Models: Systems Engineering and Others“ in *Systems Engineering: Fundamentals and Applications*, R. Haberfellner, O. de Weck, E. Fricke und S. Vössner, Hg., Cham: Springer International Publishing, 2019, S. 27–98, doi: 10.1007/978-3-030-13431-0_2.
- [22] M. Er Kara, S. Ü. Oktay Firat und A. Ghadge, „A Data Mining-based Framework for Supply Chain Risk Management“ (en), *Computers & Industrial Engineering*, Jg. 139, S. 105570, 2020, doi: 10.1016/j.cie.2018.12.017.
- [23] M. Brylowski, M. Schröder, S. Lodemann und W. Kersten, „Machine Learning in Supply Chain Management: A Scoping Review“ in *Proceedings of the Hamburg International Conference of Logistics, Bd. 31, Adapting to the Future: How Digitalization Shapes Sustainable Logistics and Resilient Supply Chain Management*, W. Kersten, C. M. Ringle und T. Blecker, Hg., 1. Aufl., Berlin: epubli GmbH, 2021.
- [24] H.-C. Pfohl, H. Köhler und D. Thomas, „State of the art in supply chain risk management research: empirical and conceptual findings and a roadmap for the implementation in practice“ (en), *Logist. Res.*, Jg. 2, Nr. 1, S. 33–44, 2010, doi: 10.1007/s12159-010-0023-8.
- [25] S. Curkovic, T. Scannell und B. Wagner, „Using FMEA for Supply Chain Risk Management“ (en), Jg. 1, Nr. 2, S. 16, 2013.
- [26] B. Kumari, J. Kaur und S. Swami, „System Dynamics Approach for Adoption of Artificial Intelligence in Finance“ in Singapore, 2021, S. 555–575, doi: 10.1007/978-981-15-8025-3_54.
- [27] S. A. Alsheibani, Y. Cheung und C. Messom, „Factors Inhibiting the Adoption of Artificial Intelligence at organizational-level: A Preliminary Investigation“ in *Twenty-fifth Americas Conference on Information Systems*, 2019, S. 10.
- [28] P. Hofmann et al., „Developing Purposeful AI Use Cases – A Structured Method and Its Application in Project Management“ in *WI2020 Zentrale Tracks*, GITO Verlag, 2020, S. 33–49. [Online]. Verfügbar unter: https://library.gito.de/oa_wi2020-a3.html
- [29] J. Zheng, Y. Kobayashi, Y. Takahashi, T. Yanagida, T. Sato und D. Hitaka, „MLCP: A Framework Integrating with Machine Learning and Optimization for Planning and Scheduling in Manufacturing and Services“ in *2020 IEEE 15th International Conference of System of Systems Engineering (SoSE)*, 2020, S. 123–128, doi: 10.1109/SoSE50414.2020.9130560.
- [30] G. Baryannis, S. Dani und G. Antoniou, „Predicting Supply Chain Risks Using Machine Learning: The Trade-off Between Performance and Interpretability“ (en), *Future Generation Computer Systems*, Jg. 101, S. 993–1004, 2019, doi: 10.1016/j.future.2019.07.059.
- [31] U. Jüttner, „Supply Chain Risk Management: Understanding the Business Requirements from a Practitioner Perspective“, *IJLM*, Jg. 16, Nr. 1, S. 120–141, 2005, doi: 10.1108/09574090510617385.
- [32] L. Pumplun, C. Tauchert und M. Heidt, „A New Organizational Chassis for Artificial Intelligence – Exploring Organizational Readiness Factors“ (en), S. 16, 2019.
- [33] B. Engelking, W. Buchholz und F. Köhne, „Design Principles for the Application of Machine Learning in Supply Chain Risk Management: An Action Design Research Approach“ in *Advanced Studies in Supply Management, Supply Management Research: Aktuelle Forschungsergebnisse 2020*, C. Bode, R. Bogaschewsky, M. Eßig, R. Lasch und W. Stölzle, Hg., Wiesbaden: Springer Fachmedien, 2020, S. 137–162, doi: 10.1007/978-3-658-31898-7_8.
- [34] M. Cubric, „Drivers, Barriers and Social Considerations for AI Adoption in Business and Management: A Tertiary Study“ (en), *Technology in Society*, Jg. 62, S. 101257, 2020, doi: 10.1016/j.techsoc.2020.101257.

- [35] G. Baryannis, S. Validi, S. Dani und G. Antoniou, „Supply chain risk management and artificial intelligence: state of the art and future research directions“ (en), *International Journal of Production Research*, Jg. 57, Nr. 7, S. 2179–2202, 2019, doi: 10.1080/00207543.2018.1530476.
- [36] M. I. Alghamdi, „Assessing Factors Affecting Intention to Adopt AI and ML: The Case of the Jordanian Retail Industry“, *mendel*, Jg. 26, Nr. 2, S. 39–44, 2020, doi: 10.13164/mendel.2020.2.039.
- [37] R. Welte, M. Estler und D. Lucke, „A Method for Implementation of Machine Learning Solutions for Predictive Maintenance in Small and Medium Sized Enterprises“ (en), *Procedia CIRP*, Jg. 93, S. 909–914, 2020, doi: 10.1016/j.procir.2020.04.052.
- [38] H. Chen, L. Li und Y. Chen, „Explore Success Factors That Impact Artificial Intelligence Adoption on Telecom Industry in China“ (en), *Journal of Management Analytics*, Jg. 8, Nr. 1, S. 36–68, 2021, doi: 10.1080/23270012.2020.1852895.
- [39] F. Dörries, L. Ladewig und A. Quiltsch, *Change Management: Wie Unternehmen den Veränderungsprozess aktiv gestalten können*, 1. Aufl., 2021.
- [40] J. Jöhnk, M. Weißert und K. Wyrski, „Ready or Not, AI Comes— An Interview Study of Organizational AI Readiness Factors“ (en), *Bus Inf Syst Eng*, Jg. 63, Nr. 1, S. 5–20, 2021, doi: 10.1007/s12599-020-00676-7.
- [41] M. Schröder, *Strukturierte Verbesserung des Supply Chain Risikomanagements*. Wiesbaden: Springer Fachmedien Wiesbaden, 2019.
- [42] M. F. Blos, M. Quaddus, H. M. Wee und K. Watanabe, „Supply Chain Risk Management (SCRM): A Case Study on the Automotive and Electronic Industries in Brazil“, *Supply Chain Management: An International Journal*, Jg. 14, Nr. 4, S. 247–252, 2009, doi: 10.1108/13598540910970072.
- [43] L. Baier, F. Jä und S. Seebacher, „Challenges in the Deployment and Operation of Machine Learning in Practice“ in *In Proceedings of the 27th European Conference on Information Systems (ECIS)*, Stockholm & Uppsala, Sweden, 2020, S. 16.
- [44] P. Bedué und A. Fritzsche, „Can We Trust AI? An Empirical Investigation of Trust Requirements and Guide to Successful AI Adoption“, *Journal of Enterprise Information Management*, ahead-of-print, ahead-of-print, 2021, doi: 10.1108/JEIM-06-2020-0233.
- [45] R. Wirth und J. Hipp, „CRISP-DM: Towards a Standard Process Model for Data Mining“ (en), S. 11.
- [46] P. Chapman *et al.*, „Step-by-step Data Mining Guide“ (en), S. 76, 1999.
- [47] A. Miklosik, M. Kuchta, N. Evans und S. Zak, „Towards the Adoption of Machine Learning-Based Analytical Tools in Digital Marketing“, *IEEE Access*, Jg. 7, S. 85705–85718, 2019, doi: 10.1109/ACCESS.2019.2924425.
- [48] M. Schroeder und S. Lodemann, „A Systematic Investigation of the Integration of Machine Learning into Supply Chain Risk Management“ (en), *Logistics*, Jg. 5, Nr. 3, S. 62, 2021, doi: 10.3390/logistics5030062.

SECHS

MITTELSTAND-DIGITAL ZENTRUM HAMBURG

Für kleine und mittlere Unternehmen bei Fragen und Herausforderungen der digitalen Transformation.

KONTAKT:

Mittelstand-Digital
Zentrum Hamburg
Handelskammer Hamburg

Adolphsplatz 1
20457 Hamburg
Tel.: +49 40 36138-443
kompetenzzentrum@hk24.de

WEITERE LEITFÄDEN
FINDEN SIE HIER:

QR-Code mit dem
Smartphone
abscannen



www.kompetenzzentrum-hamburg.digital
[www.linkedin.com/company/
mittelstand-digital-zentrum-hamburg](https://www.linkedin.com/company/mittelstand-digital-zentrum-hamburg)

PROJEKTPARTNER:

Konsortialführer des Mittelstand-Digital
Zentrum Hamburg und zentraler
Ansprechpartner für Unternehmen ist
die Handelskammer Hamburg.



Weitere Projektpartner im Mittelstand-
Digital Zentrum Hamburg sind:

Technische
Universität Hamburg



Hochschule für
Angewandte
Wissenschaften
Hamburg



Handwerks-
kammer
Hamburg



KOOPERATIONSPARTNER:

Helmut-Schmidt-
Universität Hamburg



LEITFADEN // MASCHINELLES LERNEN NUTZEN

SIEBEN

IMPRESSUM

HERAUSGEBER:

Prof. Dr. Dr. h. c. Wolfgang Kersten
Technische Universität Hamburg, Institut für Logistik und Unternehmensführung
Für das Mittelstand-Digital Zentrum Hamburg

AUTORIN:

Martin Brylowski M. Sc., PD Dr. Meike Schröder,
Florian Dörries M. Sc., Lennard Gast M. Sc.
Technische Universität Hamburg, Institut für Logistik und Unternehmensführung
Für das Mittelstand-Digital Zentrum Hamburg

LEKTORAT:

Katrin Meyer

GESTALTUNG:

www.lockvogel-hamburg.de

BILDNACHWEIS:

Parradee/stock.adobe.com (1), Gorodenkoff/stock.adobe.com (13, 25, 28),
Creative Wonder/stock.adobe.com (26)

AUFLAGE:

1. Auflage, 10/2023

Was ist Mittelstand-Digital?

Mittelstand-Digital informiert kleine und mittlere Unternehmen über die Chancen und Herausforderungen der Digitalisierung. Regionale Kompetenzzentren helfen vor Ort dem kleinen Einzelhändler genauso wie dem größeren Produktionsbetrieb mit Expertenwissen, Demonstrationszentren, Netzwerken zum Erfahrungsaustausch und praktischen Beispielen. Das Bundesministerium für Wirtschaft und Energie ermöglicht die kostenlose Nutzung aller Angebote von Mittelstand-Digital. Weitere Informationen finden Sie unter www.mittelstand-digital.de

www.kompetenzzentrum-hamburg.digital



MITTELSTAND-DIGITAL ZENTRUM HAMBURG

Adolphsplatz 1, 20457 Hamburg

Tel.: +49 40 36138-443, kompetenzzentrum@hk24.de