



Bachelorarbeit
im Bachelorstudiengang
Wirtschaftsingenieurwesen/Logistik
an der Hochschule für angewandte Wissenschaften Neu-Ulm

Vergleich von KI-Technologien und traditionellen Methoden in der Logistik

Erstkorrektor/-in: Prof. Dr. Carsten Prenzler

Verfasser/-in: Alexander Jersch (Matrikel-Nr.: 276228)

Thema erhalten: 06.12.2023

Arbeit abgegeben: 08.04.2024

LOSE BEILAGEN
(ggfls.)

1 CD, 1 Faltblatt, 2 Flyer etc.

Inhaltsverzeichnis

1 Einleitung

1.1 Problemstellung

1.2 Relevanz für Praxis

1.3 Zielsetzung und Aufbau der Arbeit

2 Traditionelle Methoden und Künstliche Intelligenz-Technologien in der Logistik

2.1 Bedeutung und Erklärung von Schlüsselbegriffen

2.2 Traditionelle Methoden in der Logistik

2.3 Künstliche Intelligenz Technologien

3. Methodik

3.1 Vergleich der Effizienz und Effektivität von Künstliche Intelligenz-Technologien und traditionellen Methoden

3.2 Fallstudien

3.2.1 Einsatzgebiete der Künstlichen Intelligenz in der Logistik - Fraunhofer IML

3.2.2 Intelligente Routenoptimierung und fortschrittliche Simulationsalgorithmen

4. Fazit

4.1 Zusammenfassung der wichtigsten Erkenntnisse

4.2 Beantwortung der Forschungsfrage

4.3 Ausblick

Literaturverzeichnis

1 Einleitung

1.1 Problemstellung

Die Analyse der aktuellen Entwicklungen und Bedürfnisse im Logistiksektor hat gezeigt, wie wichtig es ist, zu untersuchen, wie Technologien der künstlichen Intelligenz (KI) die Effizienz und Effektivität im Vergleich zu traditionellen Ansätzen steigern können. Somit lautet die Forschungsfrage: Wie können KI-Technologien die Effizienz und Effektivität in der Logistik im Vergleich zu traditionellen Methoden verbessern? Die Wahl der Forschungsfrage zu diesem Thema ist von hoher Relevanz, da die Logistik eine Kernfunktion in weltweiten Handelsnetzen und Lieferketten einnimmt. Ein effektiver und produktiver Betrieb von Logistikprozessen ist nicht nur entscheidend für den Kostenrahmen von Unternehmen, sondern auch für die Erfüllung steigender Kundenanforderungen und den Erhalt der Wettbewerbsfähigkeit in einer sich wandelnden Wettbewerbslandschaft (vgl. Wamba-Taguimdje et al., 2020, S. 1893-1906).

Die Bereitstellung einer eingehenden Analyse zur Beantwortung dieser Forschungsfrage ist von Bedeutung, da sie greifbare Perspektiven für die voraussichtlichen Vorteile bietet, die Technologien der KI für Logistikbetriebe bietet. Der Zugang zu fundierten Erkenntnissen ermöglicht es Unternehmen, Entscheidungen zu treffen, wenn es darum geht, Ressourcen in KI-Lösungen zu investieren und Logistikabläufe zu optimieren. Da die Liefernetzwerke immer größer und komplexer werden, die Kundenerwartungen steigen und Echtzeitüberwachung und -transparenz immer wichtiger werden, ist der Einsatz von KI ein Ansatz zur Bewältigung dieser sich wandelnden Anforderungen (vgl. Helo & Hao, 2022, S. 1573-1590). Traditionelle Strategien waren regelmäßig von manuellen Formen und stationären Arbeitsstandards abhängig, doch KI-Fortschritte haben die Fähigkeit, Informationen konsequent zu nutzen und sich durch informationsgesteuerte Entscheidungen, vorausschauende Prüfungen und computerisierte Formen an sich verändernde Bedingungen anzupassen. Diese fortschrittlichen Innovationen schlüsseln enorme Mengen an Informationen aus zahlreichen Quellen auf, um Beispiele zu erkennen und Prognosen zu erstellen. Auf diese Weise treffen sie fundiertere Entscheidungen und gestalten die Aufgaben produktiver als herkömmliche, von statischen Leitlinien abhängige Systeme. Während herkömmliche Strategien lediglich vordefinierten Standards folgen, kann KI neue Beispiele und Umstände erkennen und entsprechend reagieren, was zu einer Anpassungsfähigkeit und Leistungssteigerung in komplexen Betriebsabläufen führt (vgl. Ribeiro & Björkman, 2018, S. 3816-3825).

1.2 Relevanz für Praxis

Der Einsatz von KI-Technologien in der Logistik birgt ein großes Potenzial für Effizienz- und Produktivitätssteigerungen in vielerlei Hinsicht. Ein Bereich, der erheblich davon profitieren wird, ist die Routenoptimierung für den Gütertransport. Herkömmliche Methoden beruhen in der Regel auf festen Routenplänen und der Vertrautheit der Fahrer mit den regelmäßigen Routen. KI kann jedoch Echtzeitinformationen wie Verkehrsströme, Wettermuster und Auftragsprioritäten nutzen, um dynamische Routen im laufenden Betrieb zu erstellen. Diese adaptiven Routen zielen darauf ab, sowohl die Reisezeiten als auch die Kosten zu reduzieren und gleichzeitig unvorhersehbare reale Variablen wie Verkehrsstaus oder Straßenbaustellen zu berücksichtigen. Durch eine strategischere Routenplanung, die sich an den aktuellen Bedingungen orientiert, können Lieferungen schneller eintreffen. Gleichzeitig wird der Kraftstoffverbrauch minimiert und der Füllungsgrad der Fahrzeuge durch die Konsolidierung der Ladung maximiert. Auch die Umweltbelastung wird durch den geringeren Kraftstoffverbrauch reduziert (vgl. Heinbach et al., 2022, S. 807–820).

Lagerhaltung und Bestandsverwaltung sind wichtige Unternehmensfunktionen, die traditionell auf ineffizienten manuellen Verfahren beruhten. Herkömmliche Methoden zur Verfolgung von Lagerbeständen und zum Auffüllen von Bestellungen waren mit zeitaufwändigem Papierkram und menschlichen Fehlern verbunden. Die Fortschritte im Bereich der KI ermöglichen jetzt jedoch hoch optimierte Lösungen. KI-Technologien überwachen die Lagerbestände rund um die Uhr, indem sie umfangreiche Datenströme untersuchen. Anstatt darauf zu warten, dass ein Manager schwindende Vorräte bemerkt, erkennen automatisierte Systeme sofort den Nachschubbedarf. Darüber hinaus geht die KI über die reaktive Auffüllung hinaus, indem sie komplexe Prognosen erstellt. Ausgefeilte Algorithmen berücksichtigen Variablen wie Jahreszeiten, Trends, historische Verkaufszahlen und unvorhersehbare Faktoren wie Naturkatastrophen. Dadurch erhalten Lagerhäuser einen nie dagewesenen Einblick in die Nachfragemuster. Die Vorhersage antizipiert Nachfragespitzen und -flauten und verhindert so Fehlbestände und Verschwendung gleichermaßen. Durch die engere Verzahnung von Produktion, Lagerhaltung und Vertrieb können die Kunden mit höchster Effizienz bedient werden. Da KI für optimale Lagerbestände sorgt, sparen Unternehmen Geld, während die Kunden einen schnellen und zuverlässigen Service erhalten. Die automatisierte Bestandsverwaltung ist daher ein Beispiel für die technologische Aufwertung ehemals arbeitsintensiver Prozesse. KI bringt neue Intelligenz selbst in unsere grundlegendsten Liefer- und Logistikfunktionen (vgl. Khan, 2023, S. 43–60) (vgl. Kern, 2021, S. 45-60).

1.3 Zielsetzung und Aufbau der Arbeit

Es gibt zwar Forschungsarbeiten, die sich mit den potenziellen Auswirkungen von KI auf den Logistikbetrieb befassen, aber es sind noch umfangreiche Analysen erforderlich, um die Auswirkungen im Vergleich zu herkömmlichen Methoden in verschiedenen Anwendungsfällen vollständig zu quantifizieren. Insbesondere haben nur wenige Studien differenziert untersucht, wie maschinelles Lernen und fortschrittliche Algorithmen die Routenplanung, den Lagerbetrieb, die Bestandsverfolgung und den Frachttransport im Vergleich zu herkömmlichen Ansätzen erweitern oder verbessern können. Um die Effizienz zu maximieren und aufkommende Technologien in vollem Umfang zu nutzen, benötigen Logistiker tiefer gehende Untersuchungsberichte, die sich auf bestimmte Anwendungen wie die Optimierung von Lieferwegen, die Rationalisierung von Lagerverfahren, die Aufrechterhaltung optimaler Lagerbestände und die Beschleunigung von Frachtbewegungen konzentrieren.

Auch wenn KI-Technologien vielversprechend sind, wenn es darum geht, die Produktivität zu steigern, Kosten zu senken und die Kundenzufriedenheit in verschiedenen Branchen zu erhöhen, gibt es nur wenige Studien, die den tatsächlichen Nutzen des Einsatzes von künstlicher Intelligenz in diesen Bereichen genau gemessen und gegenübergestellt haben. Es mangelt nach wie vor an greifbaren Beweisen und gründlichen Fallstudien, die zeigen, wie maschinelles Lernen, Deep Learning und andere Berechnungsansätze die Unternehmensziele substantiell fördern. Es sind noch weitere eingehende Untersuchungen erforderlich, um die Auswirkungen von KI auf wichtige Leistungskennzahlen im Vergleich zu Alternativen zu quantifizieren. Solche Untersuchungen geben Unternehmen eine klarere Orientierung, welche KI-Lösungen für Anwendungsfälle den größten Nutzen bieten. Ebenso würden umfassende Fallstudien, die komplette KI-Einsätze von Anfang bis Ende dokumentieren, hilfreiche Einblicke in bewährte Verfahren, zu vermeidende Fallstricke und gelernte Lektionen bieten, die anderen helfen, diese fortschrittlichen Technologien erfolgreich einzusetzen.

Die Untersuchung dieser Arbeit stützt sich auf einen umfassenden Überblick über die bestehende Forschung, die verschiedene Ansätze, Strategien und Instrumente einsetzt, um die in Kapitel 1.1 erläuterte Fragestellung zu bearbeiten. Zunächst werden einschlägige Arbeiten durch eine gründliche Suche in digitalen wissenschaftlichen Bibliotheken, Fachzeitschriften, Konferenzberichten und anderen einschlägigen Materialien ermittelt. Es wurde darauf geachtet, alle verfügbaren akademischen Artikel und Veröffentlichungen zu

berücksichtigen, die sich mit der Anwendung von Methoden der künstlichen Intelligenz im Logistikmanagement befassen. Die Suche war umfangreich, um ein vollständiges Bild des Themas zu erhalten. Anschließend wurde die Literatur analysiert, um Trends, Lücken und neue Ideen zu ermitteln. Es wurden Muster in den aus der vorhandenen Literatur herausgearbeitet. Anschließend wurden die relevantesten und einflussreichsten Arbeiten eingehend geprüft, um das Verständnis zu vertiefen. Auf diese Weise wird schließlich ermittelt, wie der aktuelle Forschungsstand aus der Literatur neues Wissen beiträgt und aussagekräftige Ergebnisse liefert. Eine detaillierte Analyse von Fallstudien, die erfolgreich Technologien der künstlichen Intelligenz in ihre Logistikabläufe integriert haben, wird durchgeführt. Durch die Untersuchung von Beispielen aus der Praxis werden konkrete Erkenntnisse darüber gewonnen, wie KI in der Praxis zur Verbesserung von Logistikabläufen eingesetzt wurde. Diese Fallstudien dienen als Grundlage für die Ableitung wertvoller Empfehlungen und Schlussfolgerungen. Die Erkenntnisse aus der Überprüfung früherer Implementierungen von KI-Systemen für das Management von Lieferketten, Transport, Inventar und Lagerhaltung werden sowohl die besten Praktiken als auch die Herausforderungen und die daraus gezogenen Lehren hervorheben. Die praktischen Erfahrungen von Unternehmen, die KI bereits in ihre Logistikprozesse integriert haben, liefern greifbare Beispiele für erzielte Ergebnisse, die anderen, die ähnliche Initiativen in Erwägung ziehen, als Orientierung dienen.

2 Traditionelle Methoden und Künstliche Intelligenz-Technologien in der Logistik

2.1 Bedeutung und Erklärung von Schlüsselbegriffen

Um die Nuancen und Feinheiten der Verwaltung von Logistikabläufen zu verstehen, muss man mit den wichtigsten Konzepten und der Terminologie in diesem Bereich vertraut sein. Konventionelle Ansätze in der Logistik beziehen sich auf langjährige Praktiken, die seit vielen Jahren angewendet werden und regelmäßig auf manuellen Verfahren beruhen. Zu diesen Techniken gehören das manuelle Zeichnen von Transportrouten, die Verwendung von Papierakten und die Bearbeitung von Aufträgen durch körperliche Arbeit. Diese Verfahren sind zwar robust und vertrauenswürdig, da sie den Test der Zeit überdauern, aber ihre manuellen Eigenschaften nehmen viel Zeit in Anspruch und erhöhen auch die Wahrscheinlichkeit menschlicher Fehler. Traditionelle Methoden, die sich über Generationen von Logistikern bewährt haben, haben ihre Berechtigung. Die Nutzung technologischer Fortschritte trägt jedoch dazu bei, einige der Unzulänglichkeiten älterer

Paradigmen zu beheben, indem die Kommunikation rationalisiert und eine dynamischere Optimierung der Ressourcen als Reaktion auf sich ändernde Prioritäten oder Störungen ermöglicht wird (vgl. Santhi&Muthuswamy, 2022, S. 5-17).

Die KI in der Logistik das das Verständnis dafür, wie computergestützte Methoden die Abläufe in der Lieferkette erneuern, bereichern. Durch den Einsatz von Techniken wie maschinelles Lernen, prädiktive Analytik, Verarbeitung natürlicher Sprache und Robotik verfügen Unternehmen heutzutage über leistungsstarke Werkzeuge zur Analyse großer Datenmengen und erhalten so ungeahnte Einblicke in die Optimierung von Prozessen (vgl. König, 2021, S. 37–50). Diese Technologien ermöglichen Automatisierung und Optimierung in einem Umfang, der über menschliche Fähigkeiten hinausgeht. So werten beispielsweise Algorithmen für maschinelles Lernen auf intelligente Weise die Zahlen früherer Transportfahrten aus, um optimale Lkw-Routen zu berechnen, die Kraftstoffkosten, Verkehrsverzögerungen und Kohlendioxidemissionen minimieren (vgl. Reger, 2023, S. 273–280). Ebenso haben Vorhersagemodelle dazu beigetragen, die Nachfrage mit einer Granularität zu prognostizieren, die eine Just-in-Time-Fertigung ermöglicht und Überproduktionen vermeidet. Natürlichsprachliche Schnittstellen beschleunigen auch Zollpapiere, Lagertransaktionen und andere Dokumente durch intuitive Konversation. Am wichtigsten ist, dass KI Logistikleitern dabei hilft, Ineffizienzen zu erkennen und zu beheben, die früher fast unmöglich zu erkennen waren (vgl. Scholz-Reiter & Höhns, 2006, S. 745–760). Automatisierte Regalbestandsprüfungen zeigen auf, wo sich langsam bewegende Bestände reduziert werden müssen, während die Verfolgung der Nutzung verhindert, dass Geräte ungenutzt bleiben. Unbemannte Fahrzeuge transportieren Materialien autonom auf streng kontrollierten Routen innerhalb von Gebäuden. Durch den Wegfall menschlicher Fehler und die Nutzung massiver paralleler Verarbeitungsprozesse kann die Computervision sogar Pakete inspizieren und Fehler in hoher Geschwindigkeit erkennen (vgl. Wennker, 2020, S. 119–127).

KI-Technologien haben das Potenzial, den Logistikbetrieb durch die Automatisierung und Rationalisierung von Prozessen erheblich zu verbessern, um die Effizienz zu steigern und die Kosten zu senken. Wenn sie in das Logistiksystem eines Unternehmens integriert werden, tragen KI-Anwendungen und -Lösungen dazu bei, die Leistung bei jedem Schritt von der Beschaffung bis zum Vertrieb zu maximieren (vgl. Bach & Lindig, 2021, S. 311–318). So analysieren beispielsweise prädiktive Analysen und Algorithmen für maschinelles Lernen vergangene Nachfragemuster und aktuelle Markttrends, um die optimalen Lagerbestände und Transportrouten zu empfehlen. Dies hilft Logistikmanagern dabei,

fundierte Entscheidungen zu treffen, die Kosten zu minimieren und gleichzeitig die Kundenwünsche zu erfüllen. KI-gestützte Roboter und autonome Fahrzeuge verringern auch die Abhängigkeit von menschlichen Arbeitskräften bei sich wiederholenden oder gefährlichen Aufgaben, wodurch Personal für strategischere Aufgaben frei wird. Wenn KI Routineaufgaben in der Logistik übernimmt, reagieren Unternehmen besser auf sich ändernde Kundenwünsche. Sie passen Lieferungen individuell an und können Sendungen in Echtzeit verfolgen. Der Einsatz von KI verschafft Logistikunternehmen durch umfangreiche Datenerfassung und -auswertung sogar detaillierte Einblicke in Schwachstellen oder Engpässe. Mit diesen Erkenntnissen können die Abläufe kontinuierlich verbessert werden. Letztlich versetzt der Einsatz von KI die Logistikunternehmen in die Lage, durch Flexibilität und hervorragende Leistungen bei der Zustellung im harten Wettbewerb zu bestehen (vgl. Kolmykova, 2020, S. 299–308).

2.2 Traditionelle Methoden in der Logistik

Seit Generationen bilden bewährte Techniken in der Logistik den Grundstein für effektive Abläufe, die im Laufe der Zeit durch praktisches Lernen und Optimierung kultiviert wurden. Diese altherwürdigen Methoden finden in unzähligen Logistikbereichen Anwendung und helfen bei der Koordinierung von Transportwegen und der Planung von Lieferungen bis hin zur Überwachung von Lagerbeständen und der Paketüberwachung. Moderne Herausforderungen erfordern jedoch neue Perspektiven, die neue Technologien nutzen. Durch die Aktualisierung traditioneller Ansätze mit datengesteuerten Erkenntnissen und Automatisierung überwinden Logistikexperten die Beschränkungen früherer Praktiken, um eine noch nie dagewesene Effizienz in ihren durchgängigen Lieferketten zu erreichen. Die Innovationen von morgen werden aus der Synergie von analoger Erfahrung und digitaler Verbesserung entstehen und die nächste Phase des Fortschritts im Dienste der sich ständig verändernden Kundenbedürfnisse leiten (vgl. Ding et al., 2021, S. 323-345). In der Vergangenheit war die manuelle Planung von Transportrouten ein weit verbreiteter Prozess, bei dem Logistikadministratoren oder Disponenten auf der Grundlage ihres Verständnisses von Straßen, Bewegungsbeispielen und den Kundenbedürfnissen der Kurse für die Transportfahrzeuge aufzeichneten. Diese Entscheidungen wurden regelmäßig auf der Grundlage von der Erfahrung und der Intuition getroffen, was zu den ineffizienten Routen und den langwierigen Transportvorgängen führte. Die Erfahrung vermittelt zwar wertvolles Wissen, aber wenn man sich zu sehr auf die Vermutungen verlässt, kann es zu Versäumnissen und suboptimalen Ergebnissen kommen. Zu einer besseren Strategie gehört

es, die relevanten Informationen aufzuschlüsseln, z. B. den Straßenrahmen, normale Aktivitätsmuster, Fahrzeugfähigkeiten und Stapelgrenzen sowie Kundenbereiche und Anforderungsmuster. Zu diesem Zeitpunkt kann die Verwendung von Programmen zur Rationalisierung von Kursen alle Faktoren gleichzeitig zusammenführen, um die produktivsten Abläufe zu erstellen, die denkbar sind. Dies ermöglicht es Logistikunternehmen, Aufträge umso produktiver zu befördern, Kosten zu senken, Entladungen durch zusätzliche Kilometer zu verringern und die Kundenbetreuung durch schnellere Beförderungen zu verbessern. Während das individuelle Urteilsvermögen bei bestimmten Entscheidungen immer noch eine wichtige Rolle spielt, kann die technologiegestützte Disposition die Verfahren verbessern und gute Ergebnisse erzielen (vgl. Schröder & Wegner, 2019, S. 245-290).

Die manuelle Verwaltung der Bestände erforderte regelmäßige Vollinventuren, bei denen das Lagerpersonal jeden einzelnen Artikel im Bestand zählte und die ein- und ausgehenden Sendungen von Hand erfasste. Dieses Verfahren war sehr arbeitsaufwendig, aber auch fehleranfällig und uneinheitlich. Kleine Fehler beim Zählen der Bestände oder beim Erfassen von den Lieferungen und den Bestellungen konnten sich im Laufe der Zeit häufen und die genauen verfügbaren Mengen verfälschen. Arbeiter, die mit zahlreichen Aufgaben jonglierten, zählten oft versehentlich einen Artikel falsch, der in einem hohen Regal stand, oder sie vergaßen, einen einzelnen Karton auf einer Palette zu erfassen. Selbst bei den fleißigsten Mitarbeitern, die sich um Perfektion bemühten, garantierten menschliche Fehlbarkeit und Müdigkeit, dass sich ein gewisses Maß an Ungenauigkeit in die schriftlichen Aufzeichnungen einschleichen würde. Als die geschäftlichen Anforderungen wuchsen, wurde die manuelle Bestandsaufnahme immer ineffizienter und reichte nicht mehr aus, um die Anforderungen der betrieblichen Skalierung zu erfüllen. (vgl. Ross, 2015, S. 687–720).

Die Logistikunternehmen begannen mit der Modernisierung ihrer Lagerverwaltungssysteme und dem Wechsel zu den automatisierten Technologien, um den wachsenden Anforderungen und den Herausforderungen gerecht zu werden. Die Technologie, die in diesem Kontext immer wichtiger geworden ist, ist die automatische Identifikation und Datenerfassung (Auto ID). Die Verwendung der Barcodescanner, Radio Frequency Identification (RFID) Tags, anderen Auto ID Technologien führt zu der verbesserten Erfassung, Verfolgung und Verwaltung der Lagerbestände.

Bei den Barcodes handelt es sich um die maschinenlesbaren Codes, die auf den Waren oder Verpackungen angebracht sind und für jedes Produkt die eindeutige Kennnummer darstellen. Um den Barcode zu erfassen und die darin enthaltene Information zu entschlüsseln, können Barcode Scanner diese Codes mithilfe des Laserstrahls oder einer Kamera präzise einlesen. Daraufhin werden diese Daten in das Lagerverwaltungssystem des Unternehmens übertragen, wo sie für die Verfolgung und Verwaltung des Bestands genutzt werden. Die RFID Tags sind eine weitere Auto ID Technologie. Die RFID Tags sind elektronische Chips, die das drahtlose Senden und Empfangen der Informationen ermöglichen. Diese Tags lassen sich an den Produkten oder der Verpackungen anbringen und enthalten die Angaben zu dem Produkt, etwa zu der Seriennummer, zu dem Hersteller und zum Produktionsdatum. Diese Tags werden von den RFID Lesegeräten aus der Ferne gelesen, auch wenn sie nicht physisch erkennbar sind. Dies erlaubt es, die Waren während des gesamten logistischen Ablaufs, angefangen bei der Wareneingangskontrolle über die Lagerung bis hin zum Versand, automatisch zu identifizieren. Die Verwendung der Auto ID Technologien hat für die Logistikunternehmen Vorzüge. Das beinhaltet die Steigerung der Effizienz durch die beschleunigte und präzise Erfassung der Lagerbestände, die verbesserte Echtzeit Bestandsverfolgung, die Verringerung der Fehler durch die automatische Datenerfassung und die gesteigerte Transparenz in der gesamten Lieferkette. Die Barcode Scanner sind Geräte, die dazu dienen, die Barcodes auf den Produkten oder Verpackungen zu lesen und die darin enthaltenen Informationen zu erfassen. Diese Informationen können dann automatisch in das Lagerverwaltungssystem des Unternehmens eingetragen werden. Die Barcodes sind maschinenlesbare Codes, die eine eindeutige Identifikationsnummer für jedes Produkt darstellen. Sie werden auf die Etiketten oder Verpackungen angebracht und enthalten die Daten wie z.B. den Produktname, den Hersteller, die Seriennummer und den Preis.

Durch den Gebrauch von den Barcode Scannern ist es möglich, die Waren präzise zu erkennen. Die Angestellten in dem Lager müssen nur den Barcode des Artikels scannen, und die Daten werden direkt in das Lagerverwaltungssystem übermittelt. Die Genauigkeit der Bestandsdaten wird dadurch erhöht und die menschlichen Fehler, die bei der manuellen Dateneingabe auftreten können, minimiert. Die Barcode Technologie erlaubt außerdem die Echtzeitverfolgung und Überwachung der Bestände, was die Bestandsverwaltung ermöglicht.

Die Radio Frequency Identification (RFID), sind elektronische Tags, die über die Funkwellen die Daten übertragen und empfangen können. Die RFID Tags benötigen im Unterschied zu

den Barcodes keine physische Scannung, um identifiziert zu werden. Stattdessen ist es möglich, dass die RFID Lesegeräte die Tags von weitem lesen und die Informationen in ihnen abrufen. Dadurch ist es möglich, den Lagerbestand fortlaufend zu überwachen, da die RFID Tags automatisch identifiziert werden, wenn sie in die Reichweite des Lesegeräts liegen.

Die Anwendung von der RFID Technologie ermöglicht es den Unternehmen, ihren Lagerbestand in Echtzeit zu überwachen und sofort über die Veränderungen in dem Lagerbestand zu informieren. Dadurch haben die Lagermitarbeiter die Möglichkeit, schneller auf die Engpässe oder die Überbestände zu reagieren und die Lagerbestände effizient zu handhaben. Außerdem verfügen die RFID Tags über die zusätzlichen Eigenschaften wie den Diebstahlschutz und der Rückverfolgbarkeit, da sie es ermöglichen, die Streckenführung eines Produkts in der Lieferkette nachzuverfolgen.

2.3 Künstliche Intelligenz Technologien

KI hat den Logistiksektor verändert, indem sie ausgefeilte Techniken und Rechenprozesse nutzt, um komplizierte logistische Probleme zu lösen. Diese innovativen Technologien bieten vielfältige Lösungen, die die Produktivität und Leistung logistischer Abläufe optimieren. Durch die Analyse großer Mengen von Betriebsdaten mittels maschinellem Lernen sagen KI-Anwendungen Nachfragetrends genau vorher, optimierte Transportrouten empfehlen und Anomalien erkennen, um Verzögerungen zu vermeiden (vgl. Gleissner & Femerling, 2013, S. 189–223).

Auf diese Weise wird die menschliche Entscheidungsfindung unterstützt, indem verborgene Muster und Erkenntnisse aufgedeckt werden, die für den Menschen allein nur schwer zu erkennen wären. Da die KI weiterhin in exponentiellem Tempo voranschreitet, wird ihre Integration in das Lieferkettenmanagement die Koordinierung über riesige Logistiknetze hinweg rationalisieren und Just-in-Time-Lieferpläne erleichtern. Während solche Technologien zweifellos Logistikmanagern dabei helfen die Koordination über riesige Logistiknetze hinweg zu rationalisieren und Just in Time Lieferpläne zu erleichtern ist es wichtig zu beachten, dass die Integration von KI in das Lieferkettenmanagement auch Herausforderungen mit sich bringt. Eine davon ist die Notwendigkeit der Datenqualität und -verfügbarkeit. KI Systeme sind stark auf qualitativ hochwertige und aktuelle Daten angewiesen, um genaue Vorhersagen und Entscheidungen zutreffen. Daher müssen Unternehmen sicherstellen das ihre Dateninfrastruktur robust ist und eine kontinuierliche Datenqualitätskontrolle gewährleistet ist (vgl. Straßer & Axmann, 2021, S. 2-7). Außerdem

ermöglichen Innovationen im Bereich der KI die Mechanisierung von Tätigkeiten, die in der Vergangenheit manuell oder halbmechanisch ausgeführt wurden. Dazu gehören zum Beispiel die spontane Organisation von Transportabläufen und die Rationalisierung von Lagerbeständen. Durch die Computerisierung können Unternehmen ihre Arbeitskosten senken, die Leistungsfähigkeit erhöhen und Engpässe im Bestandsnetz verringern. KI-Innovationen schlüsseln Informationsmengen aus verschiedenen Quellen auf, z. B. Geschäftsunterlagen, Lagerbestände und Transportdaten. Diese Untersuchungen sehen Beispiele erkennen und zukünftige Muster vorher, so dass Unternehmen ihre Koordination verbessern. So können KI-Frameworks beispielsweise künftige Anfragen vorhersehen, die von vergangenen Geschäftsentwicklungen und aktuellen Marktmustern abhängen. Auf diese Weise verbessern Unternehmen ihre Schätzungsmethoden und Anforderungspraktiken, um sicherzustellen, dass sie stets über einen ausreichenden Bestand verfügen, ohne zu viele Anfragen zu stellen. Die Mechanisierung von Führungsaufgaben, z. B. die Koordinierung von Transporten und die Überwachung von Lagerbeständen, sparen Unternehmen Zeit und Geld (vgl. Murrenhoff et al., 2021, S. 4-10). KI-Technologien helfen bei der Vorhersage und Vermeidung von Unterbrechungen in der Versorgungskette. Durch die Untersuchung von Live-Informationen erkennen computergestützte Systeme potenzielle Probleme, bevor sie auftreten, und können geeignete Gegenmaßnahmen einleiten, um die Auswirkungen auf die Beförderungspläne zu begrenzen. Auf diese Weise werden die Transporte pünktlich und zuverlässig durchgeführt, während gleichzeitig die Kundenbedürfnisse produktiver berücksichtigt werden. Durch das Aufschlüsseln von Mustern in den laufenden Informationen von Lieferanten, Montagelinien, Transport und Geschäften können scharfe Berechnungen Bestands- oder Grenzdefizite, klimabedingte Verschiebungen oder andere potenzielle Entgleisungen vorhersehen. Die frühzeitige Erkennung von Problemen ermöglicht dynamische Antworten, z. B. die Suche nach Ersatzlieferanten, das Überdenken von Transportwegen oder die Eröffnung zusätzlicher Lagerbestände. In diesem Sinne ermöglicht die KI-gestützte Prüfung der Lieferkette den Unternehmen, einen strategischen Abstand zu Verschiebungen und Rückforderungen zu wahren und die Kundenzufriedenheit hoch zu halten. Die Fähigkeit, Störungen vorherzusehen und ihnen vorzubeugen, bevor sie eintreten, ist ein Einsatz von computergestützter Intelligenz, um die Komplexität des ständig wachsenden Lagernetzwerks zu bewältigen (vgl. Grosse, 2022, S. 10–20).

3. Methodik

3.1 Vergleich der Effizienz¹ und Effektivität² von Künstliche Intelligenz-Technologien und traditionellen Methoden

Die Trainingsdatenqualität und -verfügbarkeit bestimmen die Wirksamkeit des maschinellen Lernens (ML). Die wertvollen und gut identifizierten Daten sind für die ML Algorithmen unerlässlich, um die bestmöglichen Ergebnisse zu erzielen. Wenn die Informationen unvollständig, ungenau oder nicht repräsentativ sind, kann dies die Leistung der Modelle beeinträchtigen. Deshalb erfordert die Vorbereitung und Verarbeitung der Daten, um sicherzustellen, dass sie für das Training geeignet sind, viel Zeit. Es ist zeitaufwändig, die ML Modelle zu trainieren, wenn komplexe Algorithmen und die tiefen neuronalen Netzwerke eingesetzt werden. Für diese Modelle kann es notwendig sein, eine Vielzahl der Parameter wie z.B. Lernrate, Batch-Größe und Anzahl der Epochen während des Trainings zu verbessern. Dafür sind eine große Menge an der Rechenleistung und Speicherressourcen erforderlich. Dies führt zu der Verlängerung des Trainings und zu den höheren Ausgaben, insbesondere wenn die Ausstattungsgegenstände wie die Grafikkarten oder Cloud Ressourcen benötigt werden müssen (vgl. Garbin et al., 2020, S. 12777–12810).

Die Effizienz von den ML Modellen zeigt sich darin, dass sie in der Lage sind, in den Daten wie z.B. Textdaten, Bild und Videodaten und Zeitreihendaten die Muster zu identifizieren und die Vorhersagen wie z.B. Lieferzeitvorhersagen, Bestandsvorhersage und Kundenbedarfsvorhersage zu treffen. Diese Modelle können auf unterschiedliche Weise verwendet werden und stellen komplexe nichtlineare Beziehungen zwischen Variablen dar. Das bedeutet, dass sie in der Lage sind, Muster zu identifizieren, die für herkömmliche lineare Verfahren häufig nicht zu erkennen sind. Diese Modelle können Datenstrukturen erfassen, die nicht nur linear sind, und können deshalb nicht durch herkömmliche lineare Modelle repräsentiert werden. Die Modelle können sich an unterschiedliche Datenkontexte anpassen und präzise Vorhersagen treffen, auch wenn die Variablenbeziehungen nicht linear sind, aufgrund dieser Anpassungsfähigkeit. Ihre Kompetenz ist es, in den Daten komplexe Muster zu erkennen. Auf diese Art und Weise ist es ihnen möglich, wichtige Erkenntnisse und Vorhersagen zu machen, die für die Optimierung von Unternehmensabläufen von entscheidender Bedeutung sind. Diese Erkenntnisse können

¹Die Effizienz bezeichnet die Fähigkeit, Ressourcen wie Zeit, Geld und Arbeitskraft optimal zu nutzen, um eine bestimmte Aufgabe zu erledigen.

²Die Effektivität bezeichnet die Fähigkeit einer Methode oder Technologie, die beabsichtigten Ziele oder Ergebnisse zu erreichen. Es geht darum, ob die angewendete Lösung tatsächlich die gewünschten Ergebnisse liefert und ob diese Ergebnisse den Anforderungen und Erwartungen im Logistikunternehmen entsprechen.

verschiedene Aspekte beinhalten, wie zum Beispiel die Steigerung der Produktqualität, die Analyse von Kundenverhaltensmustern, die Steigerung der Effizienz in der Lieferkette, die Risikominderung und die Identifizierung von Wachstumschancen. Unternehmen können mithilfe dieser Erkenntnisse gut informierte Entscheidungen treffen, Risiken reduzieren und ihre Geschäftsabläufe verbessern. Die Effektivität von den Machine Learning Modellen ist nicht nur von der Datenmenge abhängig, sondern auch von der Trainingsqualität. Ein wesentlicher Bestandteil dieses Prozesses ist die Gestaltung der dem Modell vorgestellten Funktionen oder Eigenschaften. Die Qualität des Trainingsprozesses hängt davon ab, wie die Trainingsdaten dem Modell zur Vorbereitung auf die bestimmte Aufgabe zugeführt werden. Dazu zählen die Prozesse wie die Auswahl und Erstellung der Trainingsdaten, die Wahl des passenden Algorithmus und die Verbesserung der Hyperparameter. Ein durchdachter Trainingsprozess kann gewährleisten, dass das Modell die relevanten Muster in den Daten identifiziert und wirksame Prognosen entwickelt (vgl. Choi et al., 2018, S. 1868-1880).

Die Variablen oder Attribute, die dem Modell vorgestellt werden, um die Muster zu identifizieren und Prognosen zu erstellen, werden als relevante Merkmale oder Features bezeichnet. Die Transportzeit, der Lagerbestand, die Lieferantenleistung, die Routenoptimierung, die Kundenaufträge und die Wetterbedingungen sind einige der Merkmale, die in der Logistik eines Unternehmens relevant sind. Es ist wichtig, die passenden Merkmale auszuwählen, um die Leistung des Modells zu optimieren. Es ist auch entscheidend, die neuen Datenquellen einzubeziehen, um die Merkmale zu identifizieren, die die Zielvariable am stärksten erklären können. Dabei handelt es sich z.B., um die Einbindung von IoT Sensoren, um in Echtzeit die Daten zum Zustand der Waren zu erhalten. Die Unternehmen können mithilfe dieser neuen Datenquellen eine präzise Prognose erstellen und ihre Logistikabläufe weiter verbessern. Es ist entscheidend, dass der Trainingsprozess gut geplant ist, damit das Modell die relevanten Muster in den Daten erkennt und die genauen Vorhersagen macht. Dies schließt den Einsatz der Methoden wie die Kreuzvalidierung, Hyperparameter-Optimierung und die Modellvalidierung ein, um sicherzustellen, dass das Modell weder über noch unterangepasst wird. Indem die Machine Learning Modelle die Daten aus den verschiedenen Quellen wie den Transportzeiten, Lagerbeständen, Lieferantenleistung und Kundenbestellungen analysieren, können sie die nützlichen Erkenntnisse über die komplexen Logistikprozesse gewinnen. Beispielsweise können sie die Muster und Trends erkennen, die dem menschlichen Auge nicht bewusst sind, und dadurch frühzeitig die Lieferkettenengpässe erkennen. Ein bedeutender Nutzen

von den Modellen des maschinellen Lernens ist die Vermeidung von Engpässen und die Steigerung der Effizienz der gesamten Lieferkette. Durch die Verarbeitung großer Datenmengen und die Erkennung von Mustern können sie etwa Engpässe in der Produktion oder im Versand vorhersehen und rechtzeitig handeln, um diese zu vermeiden oder zu mildern. Außerdem können sie durch die Verbesserung der Nachfrageprognosen zur Optimierung der Lagerbestände beitragen, was zu einer Verringerung der Überbestände führt. Ein weiterer wichtiger Gesichtspunkt ist, dass die Machine Learning Modelle die Fähigkeit besitzen, fortlaufend aus den neuen Daten zu lernen und sich an die verändernden Umstände anzupassen. Dadurch können sie sich an die veränderten Marktbedingungen, das Verhalten der Lieferanten oder die Vorlieben der Kunden anpassen und entsprechende Anpassungen vornehmen. Dadurch entwickeln sie sich zu einem effektiven Werkzeug für datenbasierte Logistikkentscheidungen und vorhersagen. Dieses hilft den Unternehmen, ihre Wettbewerbsfähigkeit zu bewahren und sich schnell neuen Herausforderungen anzupassen (vgl. Esmaeili et al., 2023, S. 293–310).

Die NLP Algorithmen sind effizient, wenn sie die natürliche Sprache schnell und genau verarbeiten können. Die modernen NLP Modelle, vor allem diejenigen, die auf den tiefen neuronalen Netzwerken basieren, haben die Geschwindigkeit der Textdatenverarbeitung deutlich erhöht. Die Verwendung der Methoden wie Parallelverarbeitung und spezieller Hardware wie die Grafikkarten ermöglichen die effiziente Verarbeitung der umfangreichen Textdatenmengen. Dadurch wird die Entwicklung der NLP Anwendungen vorangetrieben. Zum Beispiel haben die Chatbots die Möglichkeit, Kundenanfragen in Echtzeit zu bearbeiten, ohne dass die menschliche Intervention nötig ist. Dies führt zu einer Einsparung von der Zeit und Ressourcen für die Unternehmen sowie zu einer Steigerung der Kundenerfahrung. Außerdem erlaubt die effiziente Verarbeitung von natürlicher Sprache mithilfe von den NLP Modellen eine schnelle Analyse der umfangreichen Textkorpora. Dies ist hilfreich für die Tätigkeiten wie die Sentimentanalyse, die die Analyse der umfangreichen Textmengen erfordert, um die Stimmungsschwankungen festzustellen. Die Wirksamkeit von den NLP Algorithmen manifestiert sich darin, dass sie in der Lage sind, die semantische Bedeutungen und Zusammenhänge in der natürlichen Sprache zu interpretieren. Die modernen NLP Modelle sind in der Lage die komplexen Sprachstrukturen zu identifizieren und zu deuten. Dies steigert die Leistungsfähigkeit bei den verschiedenen Tätigkeiten wie der Chatbots, Named Entity Recognition, Sentimentanalyse und der automatischen Übersetzung. Die Qualität der trainierten Modelle spielt eine Rolle bei der Wirksamkeit von dem NLP. Dies beinhaltet die Entscheidung für die passenden Architektur sowie die

Verbesserung der Hyperparameter während des Trainings. Es ist von Bedeutung, dass die Trainingsdaten mit den Labels vorliegen. Die NLP Modelle brauchen eine große Menge an Daten, um effizient zu lernen und die genauen Vorhersagen zu machen. Ein weiterer Gesichtspunkt der Wirksamkeit von dem NLP ist die Fähigkeit des Modells, sich an die bestimmten Aufgaben wie z.B. Automatische Zusammenfassung, Textanalyse und Sentimentanalyse und Automatische Übersetzung anzupassen (vgl. Rezaeenour et al., 2023, S. 17883–17900).

Die Nutzung der Grafikprozessoren (GPUs) und der Chips wie dem Tensor Processing Units (TPUs) trägt zu der Hardwarebeschleunigung und parallelen Verarbeitung bei. Diese sorgen dafür, dass die visuellen Daten durch die parallelen Berechnungen auf die Tausenden von den Kernen gleichzeitig schneller verarbeitet werden können. Dies bringt die bedeutenden Geschwindigkeitsvorteile mit sich. Die Leistungsfähigkeit von der Computer Vision wird auch maßgeblich von der Verbesserung der Algorithmen beeinflusst. Die Verbesserungen bei den zugrundeliegenden Algorithmen wie dem Convolutional Neural Networks (CNNs) und dem Transfer Learning wurden durch die Forschungsergebnisse von Ates & Gorgularslan (2023) bewirkt (vgl. Abts et al., 2020, S. 145-158). Um die Topologieoptimierungsstrukturen mit der hohen Auflösung (256×256) vorherzusagen, wurde in der Studie von Ates & Gorgularslan (2023) ein tiefes Convolutional Encoder Decoder Netzwerk entwickelt, das auf U Net basiert. Mit dieser Technik wurden Transfer Learning und Feinabstimmung eingesetzt, um die Modelleistung zu optimieren. Das VGG16 Netzwerk, das zuvor auf dem ImageNet trainiert wurde, diente als der Encoder für das Transfer Learning. Das Netzwerk konnte die Fähigkeit zu der Merkmalsextraktion verbessern und von den umfangreichen visuellen Informationen aus dem ImageNet Datensatz profitieren, indem es das vortrainierte Modell verwendete. Daraufhin erfolgte die Feinabstimmung des Netzwerks auf, um die Leistungsfähigkeit gezielt den Anforderungen der Topologieoptimierung anzupassen. Durch diese Vorgehensweise konnte das Netzwerk genaue und hochauflösende Prognosen über verbesserte Strukturen erstellen. Dies stellt einen wichtigen Fortschritt bei der Anwendung von Deep Learning Techniken zur Topologieoptimierung dar (vgl. 4440–4450).

In der Untersuchung von Kaur & Gandhi (2020) wurden Transfer Learning basierte Deep Convolutional Neural Networks (DCNNs) zu der Klassifizierung von den pathologischen Gehirnbildern eingesetzt. Diese Vorgehensweise erlaubte es den Modellen, die Leistung zu steigern, indem sie von den Netzwerken profitierten, die bereits auf den Datensätzen trainiert wurden, und diese an die spezifische Aufgabe der Gehirnbildklassifizierung angepasst. In der Untersuchung wurden verschiedene vortrainierte DCNNs wie AlexNet,

ResNet50, GoogLeNet, VGG 16, ResNet101, VGG 19, InceptionV3 und InceptionResNetV2 verwendet. Die Verwendung der unterschiedlichen Modelle ermöglichte es den Forschern, die Leistungsfähigkeit der verschiedenen Architekturen zu vergleichen und diejenigen zu ermitteln, die für die Einordnung der pathologischen Gehirnbilder am besten geeignet sind. Dieser Ansatz verdeutlicht die Möglichkeiten des Transfer Learnings in der medizinischen Bildgebung und hilft dabei, die Diagnose und Therapie von Hirnerkrankungen zu optimieren (vgl. 5–17).

Dies ermöglicht das Training von den Modellen mit den geringeren Rechenressourcen, ohne dass sich dies auf die Leistung auswirkt. Durch die fortlaufende Verbesserung der Algorithmen wird die Effizienz von den Computer Vision (CV) Modellen weiter verbessert. Darüber hinaus ist die Vorverarbeitung und Augmentierung der Daten von Bedeutung. Die Vorbereitung und die Erweiterung der Trainingsdaten, wie die Rauschentfernung, Normalisierung von Bildern und Generierung synthetischer Daten, erhöht die Wirksamkeit der Modelle deutlich. Durch den Einsatz von Methoden wie dem Transfer Learning ist es möglich, bereits ausgebildete Modelle für neue Aufgaben einzusetzen, wodurch die Notwendigkeit des Trainings verringert wird. Die Verbesserung der Inferenzzeit ist von Bedeutung. Die Effizienz von den Computer Vision Modellen hängt nicht nur vom Training ab, sondern auch von der Zeit, die für die Vorhersagen auf die neuen Daten erforderlich ist. Die Inferenzzeit wird durch die Methoden wie die Quantisierung, die Verkleinerung der Modellgröße und die Optimierung der Berechnungen deutlich abnehmen. Dies kommt insbesondere in den Echtzeit Anwendungen wie dem autonomen Fahren zum Tragen, in denen die Entscheidungen notwendig sind. Diese Faktoren tragen insgesamt dazu bei, die Effizienz von der Computer Vision zu steigern und die schnelleren sowie genaueren Analysen von den Bilddaten zu ermöglichen. Die effektiven CV Modelle sind dadurch gekennzeichnet, dass sie in der Lage sind, visuelle Informationen aus den Bildern oder Videos genau zu interpretieren und komplexe Aufgaben wie die Objekterkennung, Gesichtserkennung and Bildsegmentierung und visuelle Klassifizierung zu bewältigen (vgl. Oyelade & Ezugwu, 2022, S. 4-12).

Ein Schlüsselement für die Wirksamkeit von den CV Modellen ist die Präzision der Resultate. Es gibt mehrere Faktoren, die diese Genauigkeit beeinflussen: die Qualität der Trainingsdate, die Wahl des passenden Algorithmus und die sorgfältige Optimierung der Hyperparameter während des Trainings. Um eine korrekte Interpretation eines breiten Spektrums der visuellen Muster und Objekte zu gewährleisten, sind die qualitativ hochwertigen und ausgewogenen Trainingsdaten von Bedeutung. Die Präzision der

Prognosen wird in hohem Maße durch die Wahl des geeigneten Algorithmus und die Abstimmung der Hyperparameter beeinflusst. Bei der Modellierung und Prognose sind diese Entscheidungen von Bedeutung, um die bestmöglichen Ergebnisse zu erzielen. Die Wahl des Algorithmus ist abhängig von der Art der zu lösenden Daten und dem Problem. Die verschiedenen Algorithmen weisen sowohl die positiven als auch die negativen Eigenschaften auf, und die Auswahl des passenden Algorithmus beeinflusst die Leistung des Modells. Die Anpassung der Hyperparameter wie die Lernrate, Batch Größe und die Regularisierungsterme sind für die Leistung und Wirksamkeit von den Machine Learning Modellen von Wichtigkeit. Die Lernrate beeinflusst, wie schnell oder langsam das Modell konvergiert und ob es ein lokales Minimum erreicht oder in einem Plateau stecken bleibt, da sie die Größe der Schritte bestimmt, die das Modell während des Trainings entlang der Verlustoberfläche durchführt. Zu hohe Lerngeschwindigkeiten können führen, dazu dass das Modell das Minimum überschreitet, während eine zu geringe Lerngeschwindigkeit dazu führt, dass das Modell nur sehr langsam oder überhaupt nicht konvergiert (vgl. Shrestha & Mahmood, 2019, S. 53045-53060).

Die Menge der Trainingsbeispiele, die gleichzeitig in jeder Trainingsiteration verwendet werden, wird durch die Batch Größe festgelegt. Eine höhere Batch Größe kann das Training beschleunigen, indem die Beispiele gleichzeitig verarbeitet werden. Sie kann jedoch auch Speicherprobleme verursachen und die Konvergenz des Modells beeinträchtigen. Es besteht die Möglichkeit, dass eine geringere Batch Größe eine stabile Konvergenz bewirkt, aber zusätzlich längere Trainingszeiten. Die Regularisierungsterme werden genutzt, um das Overfitting zu vermeiden. Sie regulieren die Komplexität des Modells und beschränken die Gewichte der Modelle auf einen passenden Bereich. Jedoch kann eine übermäßige Regularisierung dazu führen, dass das Modell zu stark vereinfacht wird und die zugrunde liegenden Datenmuster nicht erfassen. Im Gegensatz dazu kann eine übermäßige Regularisierung zu Overfitting führen, bei dem das Modell die Trainingsdaten zu stark anpasst und auf die neuen Daten nicht genau generalisieren. Die Flexibilität und die Anpassungsfähigkeit von den CV Modellen sind weitere bedeutende Faktoren. Die effektiven Modelle müssen fähig sein, sich an die unterschiedlichen Situationen, Lichtverhältnisse und Umgebungen anzupassen. Das erfordert ein umfassendes Verständnis der visuellen Muster, die dahinter stecken, sowie eine robuste Struktur, die dem Modell die Bewältigung der Situationen ermöglicht. Die Anwendbarkeit des CV Modells in die praktischen Situationen, wie zum Beispiel bei der Überwachung in den dynamischen Umgebungen oder der Navigation der autonomen Fahrzeuge, hängt von der Flexibilität ab.

Ebenso ist die Skalierbarkeit von den CV Modellen für ihre Wirksamkeit von Bedeutung. Die effektiven Modelle müssen fähig sein, mit dem steigenden Datenvolumen und der zunehmenden Komplexität umzugehen, ohne dabei die Leistung zu beeinträchtigen. Um die notwendigen Berechnungen effizient durchzuführen, müssen die leistungsstarken Hardware Ressourcen und die optimierten Algorithmen verwendet werden. Die skalierbaren CV Modelle eignen sich für die Anwendungen wie die industrielle Qualitätskontrolle, da sie die großen Datenmengen in kurzer Zeit verarbeiten können (vgl. Sarferaz, 2023, S. 585–601). Die Lineare Regression ist hinsichtlich ihrer Wirksamkeit dafür bekannt, dass sie nur eine geringe Menge an Anforderungen an die Rechenressourcen und die Trainingszeit stellt. Die Koeffizienten werden schnell berechnet, vor allem, wenn der Datensatz nur wenige Variablen enthält. Damit ist die Lineare Regression eine preiswerte und zeitsparende Option für die Probleme, bei denen die Variablen eine einfache Struktur und klare lineare Beziehungen aufweisen. Vor allem bei kleinen bis mittleren Datensätzen und einfachen linearen Beziehungen dauert das Training verhältnismäßig kurz und erfordert lediglich geringe Rechenkapazitäten. Auf diese Weise eignet sich die Lineare Regression besonders gut für Anwendungen, die schnelle Ergebnisse wünschen oder Ressourcenknappheit haben. Die KI Technologien wie Natural Language Processing (NLP) und Deep Learning benötigen im Vergleich zu den herkömmlichen Verfahren wie Linearen Regressionen, Entscheidungsbäumen und Heuristiken deutlich mehr Rechenressourcen und Trainingszeit, da sie nicht auf festgelegten Algorithmen basieren (vgl. Terstegen et al., 2023, S. 57–68). Dafür sind die komplexen Strukturen dieser Technologien verantwortlich, die eine Datenverarbeitung und Modelloptimierung erforderlich machen. Das Training von NLP und Deep Learning Modellen kann, insbesondere bei den umfangreichen Datensätzen und komplexen Modellen, sehr zeitaufwändig sein und umfangreiche Ressourcen wie leistungsstarke GPUs oder verteilte Rechencluster erfordern. Bei diesen Modellen werden die großen Datenmengen gesammelt und verschiedene Parameter optimiert, um eine bestmögliche Leistung zu erzielen. Diese wiederholten Optimierungsprozesse können viel Zeit in Anspruch nehmen und benötigen mehrere Durchläufe, um die angestrebten Resultate zu erreichen (vgl. Ng et al., 2020, S. 161–170).

Es besteht die Möglichkeit, dass die zusätzlichen Anforderungen an die Rechenressourcen und der Trainingszeit zu höheren Ausgaben führen, sowohl hinsichtlich der Hardware und Infrastrukturkosten als auch der für das Training der Modelle benötigten Zeit. Es ist daher von Bedeutung, die Anwendung von dem NLP und Deep Learning zu überdenken, vor allem dann, wenn die Zeit und Ressourcen eingeschränkt sind. Bei der Verarbeitung von den

unstrukturierten Daten wie der Texte, Bilder und dem Ton sind sie besonders wirksam. Sie sind in der Lage, komplexe nichtlineare Beziehungen zu erfassen, die herkömmliche Methoden nicht bewältigen können. Die Lineare Regression ist aufgrund ihrer Wirksamkeit für die Anwendungen in der Logistik besonders attraktiv, vor allem dann, wenn schnelle Resultate gewünscht werden müssen oder Ressourcen knapp sind. Oftmals bedarf es in der Logistikbranche einer Analyse und der Optimierung der komplexen Abläufe wie die Lagerhaltung, Routenoptimierung und Bestandsmanagement. Insbesondere wenn es darum geht, die logistischen Prozesse zu modellieren, die auf dem deutlichen linearen Beziehungen zwischen den Variablen basieren, stellt die Lineare Regression ein hilfreiches Instrument dar. Sie kann beispielsweise genutzt werden, um die Beziehung zwischen der Lagerkapazität und den Lagerkosten zu untersuchen oder um vorherzusagen, welche Auswirkungen die Veränderungen der Nachfrage auf den Bestand haben. Darüber hinaus erleichtert die Interpretation der Linearen Regression die Kommunikation der Logistikergebnisse. Die Logistikmanager haben durch die Auswertung der Koeffizienten³ die Möglichkeit, unmittelbare Einsichten in die Effekte unterschiedlicher Variablen auf die Logistikprozesse zu gewinnen. Durch die Verwendung von empirischen Daten⁴ können die Entscheidungen getroffen werden, was die Effizienz der Logistikoperationen steigert. Ein weiterer Pluspunkt der Linearen Regression in der Logistik ist die Fähigkeit, sich an die unterschiedlichen logistischen Anwendungen wie z.B. dem Bestandsmanagement, der Routenoptimierung und der Lagerhaltungsoptimierung anzupassen. Um die datengesteuerten Erkenntnisse zu gewinnen und fundierte Entscheidungen zu treffen, kann die lineare Regression in den verschiedenen logistischen Szenarien angewendet werden. Dies gilt zusätzlich für die Optimierung der Transportrouten, die Verwaltung von den Lagerbeständen oder die Minimierung der Lieferzeiten (vgl. Xing et al., 2013, S. 305-325). Es wird deutlich, dass die Lineare Regression im Vergleich zu den herkömmlichen Methoden der Linearen Regression, Entscheidungsbäume und Heuristiken als die effektivste Option betrachtet wird, vor allem hinsichtlich des Ressourcenverbrauchs und der Trainingszeit. Weil die die Entscheidungsbäume und Heuristiken im Allgemeinen weniger

³Die Koeffizienten in der Linearen Regression stehen für die Intensität und Ausrichtung der Beziehung zwischen den unabhängigen und der abhängigen Variablen. Die unabhängigen Variablen in der Logistik umfassen zum Beispiel Lagerkapazität, Transportkosten, Lieferzeiten, Bestellmengen oder Nachfragevolumen. Die abhängigen Variablen sind Faktoren wie Lagerhaltungskosten, Durchlaufzeit oder Liefergenauigkeit (vgl. Jena & Seth, 2016, S. 199-207).

⁴Durch den Einsatz von empirischen Daten in der Logistik ist es möglich, Entscheidungen anhand realer Beobachtungen und Messungen zu fällen. Das heißt, dass die Entscheidungen auf konkreten Daten basieren, die aus vergangenen oder aktuellen logistischen Prozessen gesammelt wurden, anstatt auf Annahmen oder theoretischen Überlegungen. Die Logistikmanager haben die Möglichkeit, die Leistung und Effizienz ihrer logistischen Operationen zu beurteilen und zu verbessern, indem sie diese empirischen Daten analysieren. So können sie beispielsweise anhand von Informationen zu Transportzeiten, Lagerbeständen, Liefergenauigkeit oder Rückläufen die Leistung bestimmter Bereiche der Lieferkette messen und ermitteln, welche Bereiche verbessert werden sollten (vgl. Wong et al., 2015, S. 688-701).

Rechenressourcen und Trainingszeit benötigen, ist dies der Grund dafür. Bei einem Datensatz mit wenigen Variablen ist die Berechnung der Koeffizienten für die Lineare Regression schnell. Bei Problemen, die einfache lineare Beziehungen und kleine bis mittlere Datensätze betreffen, dauert das Training kurz und erfordert lediglich geringe Rechenressourcen. Ein bedeutender Pluspunkt der Linearen Regression ist ihre Fähigkeit zur Modellierung und Quantifizierung der linearen Beziehungen zwischen den Variablen. Dadurch eignet sie sich es besonders gut für die Probleme, in denen die Auswirkungen einer oder mehrerer unabhängiger Variablen auf eine abhängige Variable untersucht werden. Die Lineare Regression kann präzise Vorhersagen liefern und wichtige Einblicke in das zugrunde liegende Phänomen bieten, wenn das Verhältnis zwischen den Variablen linear ist und klar definiert werden kann. Die Berechnung der linearen Regressionskoeffizienten ermöglicht außerdem die effiziente Modellanpassung und -validierung. In dynamischen Umgebungen, in denen Daten schnell zur Verfügung stehen und schnelle Entscheidungen notwendig ist, ist dies besonders nützlich. Die Anwender haben die Möglichkeit, das Modell schnell an die neuen Informationen anzupassen und es bei Bedarf zu aktualisieren oder zu verfeinern. Dadurch wird nicht nur der Prozess der Entscheidungsfindung beschleunigt, sondern es wird auch eine fortlaufende Verbesserung des Modells ermöglicht, damit es den sich wandelnden Anforderungen gerecht wird (vgl. Baum & Wally, 2003, S. 1107-1120).

Wenn die Entscheidungsbäume optimiert werden, können sie eine effiziente Funktionalität aufweisen. Eine effektive Optimierung ermöglicht es den Entscheidungsbäumen, die Entscheidungen schnell und genau zu treffen, wodurch sie für unterschiedliche Anwendungen eine attraktive Wahl werden. Die Entscheidungsbäume neigen jedoch dazu, im Gegensatz zu der Linearen Regression einen höheren Rechenaufwand auszugeben. Insbesondere bei großen Datensätzen oder tiefen Bäumen ist dies besonders stark. Um eine optimale Aufteilung zu finden, müssen Entscheidungsbäume den gesamten Datensatz durchlaufen und verschiedene Entscheidungsknoten betrachten. Dieser Vorgang kann viel Zeit in Anspruch nehmen, vor allem wenn der Datensatz groß ist oder die Entscheidungsstrukturen äußerst komplex sind. Daher kann es zeitaufwendig sein, Entscheidungsbäume zu berechnen und auszubilden, da es mehrere Iterationen braucht, um die optimalen Entscheidungsknoten und -regeln zu ermitteln. Die Heuristiken hingegen benötigen im Vergleich zu den komplexen KI Technologien wie Deep Learning geringere Rechenressourcen. Die Heuristiken beruhen auf regelbasierten Methoden, deren Entwicklung manuell durchgeführt werden muss. Das heißt, dass es Zeit und die menschliche Expertise braucht, um die wirksamen Regeln zu finden und umzusetzen.

Allerdings kann die manuelle Entwicklung zu längeren Entwicklungszeiten führen, vor allem bei komplexen Problemen oder Domains, die nur schwer formalisiert werden können. Die Heuristiken müssen normalerweise von Fachleuten entwickelt werden, die ein Verständnis des Problems haben, da sie auf bestimmte Problemgebiete zugeschnitten sind. Dieser wiederholende Vorgang, bei dem Heuristiken entwickelt und verfeinert werden, nimmt viel Zeit in Anspruch und erfordert eine intensive Kooperation zwischen Datenanalysten und Domänenexperten (vgl. Tsang et al., 2011, S. 64-75).

3.2 Fallstudien

3.2.1 Einsatzgebiete der Künstlichen Intelligenz in der Logistik - Fraunhofer IML

Die Integration von Künstlicher Intelligenz (KI) in die Logistik birgt die Möglichkeit, die Effizienz, Flexibilität und Genauigkeit logistischer Abläufe zu verbessern. Die Bedeutung, die Grundlagen, Entwicklungen und zukünftigen Einsatzfelder von KI in der Logistik wurden in einem Whitepaper des Fraunhofer Instituts für Materialfluss und Logistik (IML), einer führenden Forschungseinrichtung in Deutschland auf diesem Gebiet, erörtert.

Das ML hat in der Logistik eine wesentliche Bedeutung für die Aufgaben der Erkennung. Es dient der automatischen Identifikation der Objekte in den Videostreams oder der Bilder. Diese Einsatzmöglichkeiten sind vielfältig und umfassen die automatisierte Überwachung der Lagerbestände, die Erkennung der Warenschäden während des Transports sowie die Identifizierung der Kommissionierprodukte.

Ein Anwendungsbereich ist die automatisierte Überwachung der Lagerbestände. Die Bilder oder Videostreams aus den Lagerbereichen werden von den Bildverarbeitungsalgorithmen analysiert, die die vorhandenen Artikel und ihren aktuellen Bestandsstatus automatisch identifizieren. Dies führt zu einer Echtzeitaktualisierung der Lagerbestandsdatenbanken und ermöglicht es, die bevorstehenden Engpässe oder Überbestände frühzeitig zu identifizieren. Darüber hinaus erlaubt das ML die automatische Erkennung der Schäden an den Waren, die bei dem Transport entstehen. Die Algorithmen zu der Bilderkennung erkennen die Abweichungen oder Schäden an den Produkten. Dadurch können die Logistikunternehmen die beschädigten Waren erkennen und entsprechende Maßnahmen ergreifen. Beim Kommissionieren hilft das ML dabei, die Produkte zu erkennen. Indem die Produkte in den Regalen automatisch erfasst und lokalisiert werden, können die Fehler bei der Kommissionierung reduziert und der Ablauf beschleunigt werden. Um die korrekte Auswahl

der Artikel zu gewährleisten, vergleichen die Bilderkennungsalgorithmen die Etiketten oder Barcodes auf den Produkten mit der Datenbank.

Die Logistikunternehmen können durch die Anwendung von dem ML bei diesen Erkennungsaufgaben nicht nur ihre Effizienz erhöhen und ihre Ausgaben senken, sondern auch die Präzision und Verlässlichkeit der Abläufe steigern. Durch die automatisierte Datenerfassung und -analyse können Firmen auf die Veränderungen reagieren und in einem sich ständig verändernden Markt einen Wettbewerbsvorteil erlangen. Das ML ermöglicht es bei den Analyseaufgaben, umfangreiche Datenmengen zu analysieren und Muster oder Trends zu identifizieren, die für die Verbesserung logistischer Abläufe von Bedeutung sind. Dies umfasst die Auswertung der Lieferketten zur Identifizierung der Engpässe oder Flaschenhälse sowie die Prognose von den Veränderungen der Nachfrage anhand der historischen Daten.

Auf dem Gebiet der Planungs- und Entscheidungsprozesse ist ML in der Logistik von Bedeutung. Es hilft Unternehmen bei der Planung optimaler Lieferrouten, der Optimierung der Lagerbestände und der effizienten Nutzung von Personalressourcen. Diese Einsatzmöglichkeiten des ML sorgen dafür, dass sich die Bedingungen dynamisch anpassen und die verfügbaren Ressourcen besser genutzt werden können. Um die geeignete Route für jede Lieferung zu bestimmen, analysiert ML bei der Routenplanung für die Lieferungen der verschiedenen Parameter, darunter der Verkehrsbedingungen, Entfernung, Ladekapazität der Fahrzeuge und Lieferprioritäten. Dies beinhaltet die Einbeziehung der Echtzeitdaten, wie etwa der Verkehrsstaus oder Baustellen, um die Lieferungen pünktlich und wirtschaftlich zu realisieren. Die Verbesserung der Routen ermöglicht es den Unternehmen, die Kosten für die Zeit und den Kraftstoff zu senken und gleichzeitig die Lieferzeiten zu verkürzen.

Ein weiterer bedeutender Einsatzbereich des ML ist die Optimierung der Lagerbestände. Das maschinelle Lernen hilft Unternehmen bei der Bestandsplanung, indem es historische Daten zu Nachfrage, saisonalen Trends und Lieferzeiten analysiert und zukünftige Bedarfe prognostiziert. Um die Engpässe zu vermeiden und gleichzeitig die Lagerkosten zu minimieren, ist dies eine Möglichkeit, den Lagerbestand auf einem optimalen Niveau zu halten. Außerdem trägt ML dazu bei, die Nutzung des Lagerplatzes zu verbessern, indem es die Lagerung von Produkten auf der Grundlage ihrer Popularität und Zugriffshäufigkeit rationalisiert. Ein weiterer Anwendungsbereich des ML ist die effiziente Nutzung von Personalressourcen.

Durch die Auswertung der Arbeitszeiten, Mitarbeiterfähigkeiten und Arbeitsbelastung kann das ML dazu beitragen, die Arbeitspläne zu verbessern und sicherzustellen, dass die passenden Mitarbeiter zum richtigen Zeitpunkt an den richtigen Stellen eingesetzt werden. Dies hat zur Folge, dass die Arbeitskräfte besser genutzt werden und Überstunden oder Unterbeschäftigung verringert werden. Schließlich ist es möglich, dass maschinelles Lernen auch bei Ausführungsaufgaben in der Logistik Anwendung findet. Dies beinhaltet zum Beispiel die automatisierte Kontrolle von den Lagerrobotern, die selbstfahrende Navigation von den Fahrzeugen in den Lagern oder die automatische Sortierung von Paketen, die auf den Zielorten basieren. Die verschiedenen Qualifizierungsbedarfe müssen berücksichtigt werden, damit die Projekte mit dem ML erfolgreich umgesetzt werden können. Dazu gehören nicht nur die technischen Fähigkeiten im Bereich von KI, sondern auch die Kenntnisse über die Datenstrukturen und logistischen Prozesse, Projektmanagementfähigkeiten und die Einbindung von KI Systemen in die vorhandenen Infrastrukturen.

Die Einschätzung des Potenzials von KI in der Logistik auf 1,2 bis 2,0 Billionen US Dollar beruht auf der Analyse der unterschiedlichen Einsatzgebiete und der möglichen Steigerungen der Effizienz, die durch die Anwendung von KI Technologien erzielt werden können. Die Grundlage für diese Schätzung sind verschiedene Faktoren. Erstens ermöglicht KI in der Logistik eine Vielzahl von Einsatzmöglichkeiten, angefangen bei der Optimierung der Route bis hin zur vorausschauenden Instandhaltung. Durch die Anwendung von KI ist es möglich, die logistischen Abläufe zu automatisieren und zu verbessern. Zweitens können die Unternehmen durch die Anwendung von KI ihre logistischen Abläufe verbessern und die Engpässe reduzieren. Die automatische Auswertung der Datensätze ermöglicht eine präzisere Entscheidungsfindung, was zu einer gesteigerten Reaktionsfähigkeit führt. Drittens können die KI Technologien in den Anwendungsbereichen wie z.B. Marketing und Produktion eingesetzt werden, angefangen bei kleinen Unternehmen bis hin zu großen Konzernen. Sie sind skalierbar. Aufgrund der Bedeutung der Logistikindustrie für die globale Wirtschaft können auch geringfügige Effizienzsteigerungen erhebliche Folgen haben. Die fortlaufende Entwicklung von KI Technologien wird letztendlich einen Beitrag zur weiteren Verbesserung der Leistungsfähigkeit und Vielseitigkeit von KI Lösungen in der Logistik leisten.

In der fortschreitenden Untersuchung über die Anwendung von KI in verschiedenen Logistikbereichen wird deutlich, wie diese innovative Technologie eine transformative

Wirkung entfaltet. Insbesondere rücken die Schlüsselbereiche in den Fokus, die das Potenzial haben, die die Effizienz und Zuverlässigkeit der logistischen Prozesse steigern. Zunächst einmal ist es wichtig zu verstehen, dass die Predictive Maintenance auf einem umfassenden Datensatz basiert, der aus den verschiedenen Quellen wie z.B. Betriebsdaten und Sensorik stammt. Diese Daten umfassen die Informationen über die Maschinenleistung, Umgebungsbedingungen, Betriebsstunden, Wartungshistorie und weitere relevante Parameter. Durch die kontinuierliche Erfassung und Analyse dieser Daten können Muster und Anomalien identifiziert werden, die auf die potenziellen Probleme hinweisen könnten. Es könnte zum Beispiel auf Probleme hindeuten, wenn bestimmte Betriebszustände regelmäßig auftreten oder bestimmte Parameter vor einem Ausfall steigen. Die Echtzeitüberwachung von Sensordaten erlaubt es zugleich, die Abweichungen vom üblichen Betriebszustand zu erkennen. Wenn sich einige Parameter unerwartet stark unterscheiden oder außerhalb eines festgelegten Bereichs befinden, könnte dies auf mögliche Schwierigkeiten hindeuten. Durch die Verknüpfung der Mustererkennung und Abweichungserkennung können die Logistikunternehmen mögliche Schwierigkeiten frühzeitig identifizieren und aktiv darauf reagieren, bevor sie zu Produktionsausfällen oder Produktionsunterbrechungen führen können. Die Logistikunternehmen können durch eine fortlaufende Überwachung der Gesundheit ihrer Anlagen die Wartungsstrategien verbessern, Ausfallzeiten reduzieren und die Gesamtproduktivität erhöhen.

Ein entscheidender Schritt bei der Implementierung des Predictive Maintenance ist die Entwicklung und Schulung von KI Modellen, die in der Lage sind, diese Daten zu interpretieren und die Vorhersagen über den Zustand der Maschinen zu treffen. Hier kommen verschiedene Techniken des maschinellen Lernens zum Einsatz, wie zum Beispiel die regelbasierten Modelle, neuronale Netzwerke oder Support Vector Machines. Diese Modelle werden mit den historischen Daten trainiert und kontinuierlich verbessert, um die Vorhersagegenauigkeit zu erhöhen.

Ein weiterer Faktor ist, dass die Echtzeitdatenströme in das Predictive Maintenance System integriert werden. Die modernen Sensortechnologien erlauben die fortlaufende Echtzeitüberwachung der Parameter, wodurch die sofortige Reaktion auf sich entwickelnde Probleme möglich ist. Das System ist in der Lage, genauere Vorhersagen zu treffen und die möglichen Ausfälle noch genauer vorherzusagen, indem es die historischen Daten mit den Echtzeitinformationen kombiniert.

Die Predictive Maintenance bietet auch die Möglichkeit, die Wartungsressourcen und planung zu optimieren. Die Ressourcen können gezielt dort verwendet werden, wo sie am

dringendsten benötigt werden, anstelle eines regelmäßigen Wartens aller Maschinen. Dadurch wird die Personal und Materialnutzung effizienter und die Wartungskosten werden gesenkt. Ein weiteres Element ist die fortlaufende Weiterentwicklung und Optimierung des Predictive Maintenance Systems. Um eine noch genauere Vorhersage zu ermöglichen, ist es möglich, die KI Modelle durch die Auswertung von Rückmeldungen und Ergebnissen ständig zu verbessern. Dieser wiederholte Vorgang hilft dabei, das System im Laufe der Zeit weiter zu verbessern und den Nutzen für das Logistikunternehmen zu maximieren. Die Möglichkeit, die großen Datenmengen in Echtzeit zu analysieren, ist ein wichtiger Bestandteil der KI gestützten Qualitätskontrolle. Durch das fortlaufende Sammeln und Auswerten der Daten im gesamten Produktionsprozess ist es möglich, die möglichen Mängel oder Abweichungen zu identifizieren. Dadurch können die Logistikunternehmen sofort handeln, um die Schwierigkeiten zu beheben, bevor sie zu größeren Qualitätsproblemen oder Ausschussproblemen führen. Die KI gestützte Qualitätskontrolle zeichnet sich auch durch ihre Fähigkeit aus, in den Daten die komplexen Muster und die Zusammenhänge zu identifizieren, die für die menschlichen Analysten kaum zu erkennen wären. Die Anwendung der fortschrittlichen maschinellen Lernmethoden wie Deep Learning ermöglicht es den KI Systemen, selbstständig zu lernen und sich fortlaufend zu verbessern, indem sie aus den früheren Erfahrungen lernen und ihre Kenntnisse über die Qualitätsprobleme vertiefen.

Ein weiterer Gesichtspunkt besteht darin, die Bilderkennungstechnologien in die Qualitätskontrolle einzubringen. Die hochentwickelten Bildverarbeitungsalgorithmen ermöglichen es den KI Systemen, auf der visuellen Ebene die Fehler oder Unregelmäßigkeiten zu identifizieren und zu untersuchen. Dadurch ist es möglich, die Produktqualität objektiv zu bewerten, ohne die Rücksicht auf die menschlichen Interpretationen oder Vorurteile. Die KI gestützte Qualitätskontrolle bietet den wesentlichen Vorteil darin, dass sie in der Lage ist, die Ausschusskosten zu senken und die Gesamtqualität der Produkte zu erhöhen. Durch die Erkennung und Korrektur der möglichen Mängel können die Logistikunternehmen den Ausschuss vermeiden und gleichzeitig das Vertrauen der Kunden in ihre Produkte stärken. Dies hat zur Folge, dass nicht nur die Kosten gesenkt werden, sondern auch die Kundenzufriedenheit und die langfristige Kundenbindung gesteigert werden. Ein zusätzlicher Nutzen besteht darin, dass die Qualitätssicherungsprozesse automatisiert und optimiert werden können. Durch die Verwendung von der KI ist es den Logistikunternehmen möglich, ihre Prozesse zu der Qualitätskontrolle die Anzahl der manuellen Arbeitsprozesse zu verringern. Auf diese Weise

können die Angestellten ihre Aufmerksamkeit auf die Tätigkeiten lenken, etwa die Entwicklung der neuen Produkte oder die Verbesserung der Produktionsprozesse. Die Logistikunternehmen können mithilfe der KI gestützten Logistiksimulation die Szenarien im Produktionsablauf analysieren, mögliche Risiken abschätzen und fundierte Entscheidungen treffen, ohne dass sie ihre eigenen Ressourcen riskieren müssen. Diese Simulationen stützen sich auf die modernen KI Algorithmen und sind in der Lage, die Vielzahl der logistischen Szenarien darzustellen, von der Optimierung der Lieferketten bis hin zu der Planung der Transportwege.

Die Fähigkeit der KI gestützten Simulation, Entscheidungsszenarien zu modellieren und deren Auswirkungen auf die gesamte Logistikkette zu analysieren, ist ein Bestandteil davon. Die Logistikunternehmen können auf diese Weise die Strategien testen und bewerten, bevor sie in die Tat umgesetzt werden. Die Darstellung von „Was wäre wenn“ Szenarien ermöglicht es den Logistikunternehmen, die Risiken zu erkennen und die vorbeugenden Maßnahmen zu ergreifen, um die negativen Folgen zu reduzieren. Die KI gestützte Simulation bietet zusätzlich den Vorteil, dass sie in der Lage ist, die Folgen von den Unsicherheiten und unvorhergesehenen Ereignissen nachzubilden. Es ist von Bedeutung, diese Ungewissheiten in die Simulation mit einzubeziehen, da die Logistik von den äußeren Einflüssen wie Wetterverhältnissen, Verkehrsstörungen oder Problemen von den Lieferanten geprägt ist. Indem die Logistikunternehmen verschiedene Situationen wie z.B. Lieferkettenunterbrechung, Nachfrageschwankungen, Betriebsstörungen und Währungs- und Handelsrisiken in Betracht ziehen, können sie ihre Reaktionsfähigkeit steigern und die Risiken aktiv reduzieren. Die Anwendung der für die KI Anwendungen in der Logistik entwickelten Daten und Dienstleistungen eröffnet für die Anwendungen im Bereich des Smart Finance neue Chancen und Synergien wie z.B. die Optimierung der Handelsfinanzierung und die Verbesserte Investitionsanalyse. Die Smart Finance bezieht sich darauf, im Finanzsektor die Technologien wie KI, ML und Big Data Analyse zu nutzen, um die Finanzdienstleistungen mit der höheren Effizienz und der individuellen Gestaltung anzubieten. Die Unternehmen haben die Möglichkeit, durch den Austausch von Daten und Technologien zwischen der Logistik und Smart Finance die neuen Geschäftsmodelle zu entwickeln und sich in dem Wettbewerb zu behaupten.

Das Risikomanagement und die Kreditwürdigkeitsprüfung sind zwei Optionen. Um genauere Risikomanagement und Kreditwürdigkeitsprüfungsmodelle zu erstellen, können die Logistikdaten wie die Leistung der Lieferkette, die Lagerbestände und die Transportrouten analysiert werden. Die Einbindung der logistischen Daten in den

Finanzanalysen ermöglicht es den Finanzinstituten, informierte Entscheidungen zu treffen und das Kreditrisiko genauer zu bewerten (vgl. Abdelkafi et al., o.J., S. 12-21).

3.2.2 Intelligente Routenoptimierung und fortschrittliche Simulationsalgorithmen

Ein wesentlicher Bestandteil der modernen Logistik und Transportprozesse ist die intelligente Routenoptimierung. Diese beruht auf einer Vielzahl fortschrittlicher Algorithmen wie z.B. Dijkstra Algorithmus & Genetische Algorithmen und Technologien wie z.B. Telematiksysteme und Cloud Computing. Bei diesen Algorithmen werden verschiedene Variablen wie Verkehrsaufkommen, Wetterbedingungen, Lieferprioritäten und Fahrzeugkapazitäten ausgewertet. Indem diese Faktoren berücksichtigt werden, ist es ihnen möglich, die effektivsten Strecken für Fahrzeuge zu bestimmen, die Lieferungen ausführen müssen. Um während des Betriebs sofortige Anpassungen vorzunehmen, werden dabei ständig Echtzeitdaten integriert. Für die Logistikunternehmen sind die fortschrittlichen Simulationsalgorithmen wichtig, da sie in der Lage sind, die Szenarien vor den strategischen Entscheidungen zu modellieren und zu analysieren. Die Logistikunternehmen können mithilfe dieser Algorithmen wie genetische Algorithmen, Monte Carlo Simulationen oder agentenbasierte Modelle unterschiedliche potenzielle Entwicklungen und ihre Auswirkungen simulieren.

Mit diesen Algorithmen können Logistikunternehmen verschiedene Bereiche ihres Geschäfts untersuchen, etwa die Implementierung neuer Technologien, Veränderungen im Marktumfeld oder strategische Investitionen. Die Logistikunternehmen könnten zum Beispiel mithilfe von Simulationen die Folgen einer Investition in automatisierte Lagerhaltungssysteme für ihre Lagerkapazitäten, Arbeitskosten und Lieferzeiten erforschen. Um die möglichen Möglichkeiten und Gefahren abzuwägen, könnten sie auch die Auswirkungen einer Expansion in neue Märkte oder der Einführung neuer Produkte simulieren (vgl. Chowdhary & Kaur, 2018, S. 500-504).

Die Unternehmen in der Logistikbranche verwenden derartige Algorithmen, um die verschiedenen Änderungen zu bewerten, wie etwa die Implementierung neuer Lieferwege, die Einbindung zusätzlicher Standorte oder sogar die Anpassung der Fahrzeugflotte. Durch die verschiedenen Szenarien können die Unternehmen ein besseres Verständnis für die möglichen Risiken und Möglichkeiten gewinnen. Sie simulieren beispielsweise, welche Folgen die Implementierung neuer Lieferwege für die unterschiedliche Faktoren wie die Lieferzeiten, Kosten und Kundenzufriedenheit hätte. Ein Unternehmen in der Logistikbranche kann durch die Kombination von intelligenter Routenoptimierung und

modernen Simulationsalgorithmen einen erheblichen Wettbewerbsvorteil erlangen. Die Intelligente Routenoptimierung ermöglicht es dem Unternehmen, die geeigneten Routen für die Lieferfahrzeuge zu bestimmen. Dabei werden die Faktoren wie das Verkehrsaufkommen, Wetterverhältnisse, Lieferprioritäten und Fahrzeugkapazitäten in Betracht gezogen. Auf diese Weise ist es möglich, die Lieferzeiten zu verkürzen, die Kraftstoffkosten zu reduzieren und die Ressourcennutzung zu optimieren. Dies führt zu den unmittelbaren Kosteneinsparungen und der gesteigerten Kundenservicequalität. Die Fortschrittlichen Simulationsalgorithmen erlauben es dem Unternehmen auch, vor den strategischen Entscheidungen unterschiedliche Szenarien zu modellieren und zu analysieren (vgl. Issaoui et al., 2022, S. 6175-6186).

Zum Beispiel ist es dem Logistikunternehmen möglich, die Betriebskosten durch die Implementierung der neuen Lieferwege oder die Einbindung der neuen Standorte zu simulieren. Diese Simulationen tragen dazu bei, dass das Logistikunternehmen ein besseres Verständnis für mögliche Risiken und Chancen gewinnt und gut informierte Entscheidungen trifft. Durch die Verknüpfung von intelligenter Routenoptimierung und modernen Simulationsalgorithmen kann das Logistikunternehmen eine gründliche Analyse durchführen. Diese berücksichtigt nicht nur die direkten Folgen von Betriebsveränderungen, sondern auch die möglichen langfristigen Folgen wie z.B. Umweltverträglichkeit und Verbesserte Kundenbindung. Durch intelligente Routenoptimierung können Unternehmen durch die Berücksichtigung verschiedener Faktoren wie das Verkehrsaufkommen, die Wetterbedingungen und die Lieferprioritäten die effektivsten Strecken für ihre Lieferfahrzeuge bestimmen. Dies hat zur Folge, dass die Lieferzeiten verkürzt werden und die Betriebskosten gesenkt werden, da weniger Treibstoff verwendet und die Ressourcennutzung verbessert wird. Diese Technologie wird durch moderne Simulationsalgorithmen erweitert. Diese ermöglichen es Unternehmen, unterschiedliche Szenarien wie z.B. die Wetterbedingungen und Lieferprioritäten zu modellieren und auszuwerten. Die Simulation ermöglicht es, die möglichen Risiken und Möglichkeiten zu erkennen, die sich aus den Veränderungen in den Betriebsabläufen ergeben, wie etwa durch die Implementierung neuer Lieferwege oder die Einbindung neuer Standorte (vgl. Barceló et al., 2007, S. 165-186).

Die Optimierung der Verteilung der Lasten ist ein Bestandteil der intelligenten Routenoptimierung im Bereich der Logistik. Die Logistikunternehmen können die Fahrzeuge optimal auslasten, indem sie die intelligente Routenoptimierung mit den modernen Lastverteilungsalgorithmen kombinieren. Diese Algorithmen untersuchen die Verteilung der

Fracht in den Fahrzeugen und entwerfen die Strecken, die eine gleichmäßige Gewichtsverteilung ermöglichen. So ist es den Logistikunternehmen möglich, nicht nur die Kraftstoffkosten zu reduzieren, sondern auch die Lebensdauer der Fahrzeuge zu verlängern, indem sie übermäßige Belastungen vermeiden. Bei der Planung der Routen müssen die Logistikunternehmen die Präferenzen der Kunden berücksichtigen, um die kundenorientierte Logistikstrategien zu entwickeln. Die Einbindung der Kundendaten in die Optimierungsalgorithmen ermöglicht es den Logistikunternehmen, nicht nur die Lieferadressen der Kunden zu erfassen, sondern auch die persönlichen Präferenzen wie den Lieferzeitfenster, die bevorzugten Lieferorte oder besondere Lieferanforderungen. Einige Kunden könnten beispielsweise frühmorgens eine Lieferung bevorzugen, während andere flexiblere Lieferzeiten brauchen. Einige Kunden mögen es zu bevorzugen, wenn die Lieferung kontaktlos erfolgt, während andere es vorziehen, sie persönlich zu bekommen. Durch die Berücksichtigung dieser Kundenpräferenzen in der Routenplanung können Logistikunternehmen nicht nur die Zufriedenheit der Kunden steigern, sondern auch die Bindung zu ihren Kunden festigen. Bei der Berücksichtigung der individuellen Bedürfnisse und Wünsche fühlen sich die Kunden geschätzt und gut betreut. Das führt dazu, dass die Kunden dem Logistikunternehmen treu gegenüberstehen und dessen Dienstleistungen öfter nutzen (vgl. Meng & Li, 2020, S. 205–207).

Durch die Einbindung der Blockchain Technologie in die modernen Simulationsalgorithmen kann die Sicherheit in den Lieferketten verbessert werden. Durch die Bereitstellung der dezentralen und unveränderlichen Aufzeichnung aller Transaktionen und Ereignisse entlang der Lieferkette lässt sich Blockchain eine transparentere und sicherere Verwaltung von den Lieferketten gewährleisten. Durch die Anwendung der Blockchain ist es den Logistikunternehmen möglich, die Waren in Echtzeit zu verfolgen und rückverfolgbar zu machen. Jeder Vorgang, der von der Produktion über die Lagerung bis zur Lieferung reicht, findet in einem unveränderlichen Block statt. Dadurch können Logistikunternehmen jederzeit den exakten Standort und Zustand der Waren nachverfolgen. Dies führt zu einer gesteigerten Transparenz und der Effizienz in der Lieferkette. Darüber hinaus gewährleistet die Blockchain eine gesteigerte Sicherheit in den Lieferketten, indem sie die kryptografische Sicherung der Daten in den Blöcken und den Schutz durch die dezentrale Netzwerkstruktur gewährleistet. Dadurch wird die Wahrscheinlichkeit von der Datenmanipulation, Betrug und Diebstahl entlang der Lieferkette deutlich verringert. Die Logistikunternehmen können sich darauf verlassen, dass ihre Lieferkettendaten unverändert bleiben, was zu der gesteigerten Zuverlässigkeit und Vertrauen führt. Die fortschrittliche Simulationsalgorithmen sind von

Bedeutung, da sie es den Logistikunternehmen ermöglichen, die Folgen von den Nachhaltigkeitsmaßnahmen ausführlich zu analysieren und zu bewerten (vgl. Chen, 2020, S. 4-10).

Diese Algorithmen bieten zunächst einmal die Möglichkeit, die Daten zu sammeln und auszuwerten. Sie haben die Möglichkeit, die unterschiedlichen Datenquellen zu integrieren, wie zum Beispiel die historischen Betriebsdaten, technische Spezifikationen von Fahrzeugen und Anlagen, Energieverbrauchsmuster sowie Markttrends und Umweltfaktoreninformationen. Danach werden auf Grundlage dieser Daten unterschiedliche Szenarien von den Algorithmen modelliert. Sie könnten beispielsweise nachbilden, welche Auswirkungen die Implementierung einer Elektrofahrzeugflotte auf die Betriebskosten, die Ladeinfrastruktur, die Fahrzeugreichweite und die Lieferzeiten hätte. Sie haben auch die Möglichkeit zu erforschen, wie die Einbindung der erneuerbaren Energien in die Logistikprozesse dazu beitragen könnte, die Abhängigkeit von fossilen Brennstoffen zu verringern und den ökologischen Fußabdruck zu verringern.

Die Algorithmen beurteilen die Leistung und die Resultate jedes Szenarios wie z.B. die Integration erneuerbarer Energien und Optimierung von Lieferwegen und -zeiten während der Simulation anhand vorab festgelegter Kriterien. Dazu zählen nicht nur wirtschaftliche Aspekte wie Betriebskosten, Investitionskosten und mögliche Einsparungen, sondern auch die Umweltaspekte wie die Treibhausgasemissionen, der Energieverbrauch und die Luftverschmutzung. Letztendlich führen die Algorithmen die ausführlichen Auswertungen und die Berichte über die Resultate der Simulationen aus. Die Vor und Nachteile der verschiedenen Nachhaltigkeitsinitiativen werden in diesen Berichten dargestellt, um die Unternehmen bei der Entscheidungsfindung zu unterstützen (vgl. Zhao, 2023, S. 3-7).

4. Fazit

4.1 Zusammenfassung der wichtigsten Erkenntnisse

Insgesamt wurde herausgefunden, dass durch die Einbindung von Predictive Maintenance, KI gestützter Qualitätskontrolle, intelligenten Routenoptimierungen und fortschrittlichen Simulationsalgorithmen in der Logistikbranche bedeutende Fortschritte erzielt werden können. Diese Technologien tragen dazu bei, dass Ressourcen effizient genutzt werden, Kosten gespart werden und die Kundenzufriedenheit steigt. Die Auswertung umfangreicher Datensätze in Echtzeit ermöglicht es Logistikunternehmen, die Defizite und Abweichungen frühzeitig zu identifizieren und zu korrigieren. Durch die Verknüpfung von der intelligenten Routenoptimierungen und modernen Simulationsalgorithmen können unterschiedliche

Szenarien modelliert und ihre Effekte analysiert werden, was zu gut informierten Entscheidungen führt.

Durch die Einbindung der Blockchain Technologie werden Sicherheit und Transparenz in den Lieferketten gesteigert. Diese Technologien ermöglichen insgesamt eine dauerhafte und effektive Logistik, die den Anforderungen der heutigen Welt gerecht wird und den Unternehmen einen Wettbewerbsvorteil verschafft.

Es stellt sich auch heraus, dass die Verwendung von KI und ML in der Logistik bedeutende Vorzüge mit sich bringt. Mit diesen Technologien können logistische Abläufe effizienter, flexibler und präziser gestaltet werden. Die KI und ML bieten vielfältige Anwendungsmöglichkeiten, insbesondere bei der Erkennung und Identifikation von den Objekten, Schäden und Kommissionierprodukten sowie bei der automatisierten Lagerbeständeüberwachung.

Die Auswertung großer Datenmengen ermöglicht es, die Muster und Trends zu erkennen. Dies führt zu der Optimierung der Entscheidungsprozesse und der Planung. Das beinhaltet die Verbesserung der Lieferwege, der Lagerbestände und der Personalaufwendungen. Durch die Auswertung der Arbeitszeiten, der Fähigkeiten der Mitarbeiter und der Arbeitsbelastungen wird eine effizientere Personalplanung und eine verbesserte Nutzung der Arbeitskräfte möglich. Darüber hinaus können KI und ML auch in der Logistik genutzt werden, um Ausführungsaufgaben zu automatisieren, etwa die Kontrolle von Lagerrobotern, die Navigation von den Fahrzeugen in Lagern oder die Paketsortierung. Außerdem kann festgehalten werden, dass die modernen Technologien wie tiefe neuronale Netze und moderne Hardware die Effizienz von NLP und CV Modellen deutlich erhöht haben.

Eine Vielzahl von Anwendungen wie Chatbots und Bilderkennungssystemen resultiert aus diesen Modellen, die eine schnelle und präzise Verarbeitung von natürlicher Sprache und visueller Information ermöglichen. Die Effektivität dieser Modelle ist allerdings maßgeblich von der Qualität der Trainingsdaten, der Auswahl passender Algorithmen und der sorgfältigen Verbesserung der Hyperparameter abhängig. Die Anwendung der Verfahren wie Transfer Learning ermöglicht die Reduzierung der Trainingszeit und die Steigerung der Leistung.

Die vorliegende Arbeit hat deutlich gemacht, dass die Logistikunternehmen vermehrt die automatisierten Technologien wie Barcodescanner und RFID Tags zur Modernisierung ihrer Lagerverwaltungssysteme nutzen. Durch diese Technologien können die Lagerbestände genau erfasst, verfolgt und verwaltet werden. Dies führt zu einer erhöhten Effizienz, der verbesserten Echtzeit-Bestandsverfolgung und der erhöhten Transparenz in der gesamten

Lieferkette. Es wurde auch herausgefunden, dass die KI den Bereich der Logistik durch den Einsatz von modernen Methoden wie z.B. Predictive Analytics und Rechenvorgänge transformiert, um Trends in der Nachfrage zu prognostizieren, Transportwege zu optimieren und Engpässe zu reduzieren. Durch die Einbindung von der KI in das Lieferkettenmanagement kann die Koordination über die umfangreichen Logistiknetze hinweg rationalisiert werden und die Realisierung von Just in Time Lieferplänen wird vereinfacht. Die Einführung von der KI erfordert jedoch eine hochwertige Dateninfrastruktur und eine genaue Einbindung in die vorhandenen Systeme.

4.2 Beantwortung der Forschungsfrage

In Kapitel 3.1 dieser Arbeit wurde untersucht, inwiefern KI Technologien (NLP, ML und CV) die Effizienz und Wirksamkeit in der Logistik im Vergleich zu den herkömmlichen Methoden (Lineare Regression, Entscheidungsbäume, Heuristikensteigern) können. Ein wichtiger Aspekt ist, dass die KI Systeme in der Lage sind, große Mengen an Betriebsdaten zu analysieren. Diese Systeme können mithilfe moderner Verfahren des ML komplexe Muster und Verbindungen in den Daten identifizieren. Diese sind entscheidend für die Prognose von Nachfragetrends und die Optimierung von Transportrouten. Die traditionelle Verfahren wie die Lineare Regression, Entscheidungsbäume, Heuristiken hingegen erfordern eine manuelle Analyse und Erfahrungswerte, die nicht die gleiche Präzision und Tiefe der Erkenntnisse liefern können. Ein weiterer Gesichtspunkt ist die genauere Vorhersage künftiger Vorkommnisse mithilfe von den Predictive Analytics. Die KI Systeme haben die Möglichkeit, die historischen Daten zu verwenden, um Trends zu erkennen und Modelle zu erarbeiten, die künftige Vorhersagen treffen können. Auf diese Weise können die Logistikunternehmen eine bessere Planung vornehmen und mögliche Engpässe oder Schwierigkeiten in der Lieferkette frühzeitig bewältigen. Die traditionelle Herangehensweisen hingegen stützen sich auf die einfacheren Modelle und Erfahrungswerte, die eine weniger genaue Vorhersage ermöglichen.

Die KI-Technologien ermöglichen es außerdem, die Transportrouten zu optimieren und die Lieferkettenengpässe mithilfe von den Optimierungsalgorithmen zu verringern. Diese Algorithmen sind in der Lage, die logistischen Probleme zu lösen und gleichzeitig die Ausgaben zu reduzieren und die Lieferzeiten zu optimieren. Die traditionellen Methoden hingegen weisen eine geringere Flexibilität auf und können bei der Bewältigung komplexer logistischer Probleme nicht mit derselben Wirksamkeit fertig werden. Ein zusätzlicher Nutzen von KI-Technologien ist ihre Fähigkeit, Anomalien zu erkennen. Die KI Systeme sind

in der Lage, Unterschiede zu üblichen Betriebsmustern zu erkennen und mögliche Schwierigkeiten frühzeitig zu identifizieren und zu beheben. Auf diese Weise ist es den Logistikunternehmen möglich, die Verzögerungen und Ausfälle in der Lieferkette zu verringern und die Zufriedenheit der Kunden zu steigern. Im Gegensatz dazu sind die traditionellen Methoden weniger widerstandsfähig und können Schwierigkeiten erst dann identifizieren, wenn sie schon einmal aufgetreten sind. Dies kann zu längeren Ausfallzeiten und einer verminderten Kundenzufriedenheit führen.

Literaturverzeichnis

Wamba-Taguimdje, S.-L., Fosso Wamba, S., Kala Kamdjoug, J.R. and Tchatchouang Wanko, C.E. (2020), "Influence of artificial intelligence (AI) on firm performance: the business value of AI-based transformation projects", *Business Process Management Journal*, Vol. 26 No. 7, pp. 1893-1924. <https://doi.org/10.1108/BPMJ-10-2019-0411>

Petri Helo & Yuqiuge Hao (2022) Artificial intelligence in operations management and supply chain management: an exploratory case study, *Production Planning & Control*, 33:16, p: 1573-1590, DOI: 10.1080/09537287.2021.1882690

L. Ribeiro and M. Björkman (2018). "Transitioning From Standard Automation Solutions to Cyber-Physical Production Systems: An Assessment of Critical Conceptual and Technical Challenges," in *IEEE Systems Journal*, vol. 12, no. 4, pp. 3816-3827, doi: 10.1109/JSYST.2017.2771139.

Heinbach, C., Beinke, J., Kammler, F. et al. (2022). Data-driven forwarding: a typology of digital platforms for road freight transport management. *Electron Markets* 32, p: 807–828 <https://doi.org/10.1007/s12525-022-00540-4>

Khan, A. (2023). Use of Technology in Warehouse Operations. *South Asian Journal of Operations and Logistics*, 2(2), p: 41–63. <https://doi.org/10.57044/SAJOL.2023.2.2.2307>

Kern, J. (2021). The Digital Transformation of Logistics. In *The Digital Transformation of Logistics* (eds M. Sullivan and J. Kern). <https://doi.org/10.1002/9781119646495.ch25>

Raja Santhi, Abirami & Padmakumar Muthuswamy. (2022). "Influence of Blockchain Technology in Manufacturing Supply Chain and Logistics" *Logistics* 6, no. 1: 15. <https://doi.org/10.3390/logistics6010015>

Wennker, P. (2020). Künstliche Intelligenz in Logistik, Lieferkette und Inventar Management. In: Künstliche Intelligenz in der Praxis. Springer Gabler, Wiesbaden. https://doi.org/10.1007/978-3-658-30480-5_8

Kolmykova, A. (2020). KI in der Logistik – Multiagentenbasierte Planung und Steuerung in der Transportlogistik. In: Buchkremer, R., Heupel, T., Koch, O. (eds) Künstliche Intelligenz in Wirtschaft & Gesellschaft. FOM-Edition. Springer Gabler, Wiesbaden. https://doi.org/10.1007/978-3-658-29550-9_16

König, M. (2021). Die digitale Transformation als reflexiver turn: Einführende Literatur zur digitalen Geschichte im Überblick. Neue Polit. Lit. <https://doi.org/10.1007/s42520-020-00322-2>

Reger, H. (2023). Digitalisierung und Einsatz von KI in der Lagerlogistik am Beispiel von Videomanagementsystemen. In: Voß, P.H. (eds) Die Neuerfindung der Logistik. Springer Gabler, Wiesbaden. https://doi.org/10.1007/978-3-658-41084-1_23

Bach, N. & Lindig, S. (2021). KI in der Intralogistik. In: Knappertsbusch, I., Gondlach, K. (eds) Arbeitswelt und KI 2030. Springer Gabler, Wiesbaden. https://doi.org/10.1007/978-3-658-35779-5_32

Scholz-Reiter, B. & Höhns, H. (2006). Selbststeuerung logistischer Prozesse mit Agentensystemen. In: Schuh, G. (eds) Produktionsplanung und -steuerung. VDI-Buch. Springer, Berlin, Heidelberg. https://doi.org/10.1007/3-540-33855-1_18

Meike Schröder & Kirsten Wegner (2019). Logistik im Wandel der Zeit – Von der Produktionssteuerung zu vernetzten Supply Chains, Springer Gabler Wiesbaden, <https://doi.org/10.1007/978-3-658-25412-4>

Ross, D.F. (2015). Transportation Management. In: Distribution Planning and Control. Springer, New York, NY. https://doi.org/10.1007/978-1-4899-7578-2_13

Yangke Ding, Mingzhou Jin, Sen Li & Dingzhong Feng (2021) Smart logistics based on the internet of things technology: an overview, *International Journal of Logistics Research and Applications*, 24:4, p: 323-345, DOI: 10.1080/13675567.2020.1757053

Gleissner, H. & Femerling, J.C. (2013). IT in Logistics. In: *Logistics. Springer Texts in Business and Economics*. Springer, Cham. https://doi.org/10.1007/978-3-319-01769-3_9

Straßer, T., & Axmann, B. (2021). Analyse und Bewertung von KI-Anwendungen in der Logistik. *Logistics Journal* Verfügbar unter: https://www.logistics-journal.de/archive/not-reviewed/2021/08/5358/strasser_2021.pdf (Abgerufen am 19.02.2024)

Anike Murrenhoff, Martin Friedrich & Dr. Markus Witthaut (2021). Future Challenges in Logistics and Supply Chain Management Künstliche Intelligenz in der Logistik, *Fraunhofer IML*, DOI: 10.24406/IML-N-462112

Grosse, E.H. (2023). Logistik 4.0: Stand der Forschung und Praxis. *HMD* 60, p: 6–20. <https://doi.org/10.1365/s40702-022-00931-3>

Ates, G.C., Gorgularslan, R.M. (2024). Convolutional encoder–decoder network using transfer learning for topology optimization. *Neural Comput & Applic* 36, 4435–4450, <https://doi.org/10.1007/s00521-023-09308-z>

Kaur, T., Gandhi, T.K. (2020). Deep convolutional neural networks with transfer learning for automated brain image classification. *Machine Vision and Applications* 31, 20 (2020). <https://doi.org/10.1007/s00138-020-01069-2>

Sarferaz, S. (2023). Skalierbarkeit und Performanz. In: ERP-Software: Funktionalität und Konzepte. Springer Vieweg, Wiesbaden. https://doi.org/10.1007/978-3-658-40499-4_35

Terstegen, S., Ramm, G.M., Harlacher, M. (2023). Klassifizierung von Künstlicher Intelligenz. In: Stowasser, S. (eds) Künstliche Intelligenz (KI) und Arbeit . ifaa-Edition. Springer Vieweg, Berlin, Heidelberg. https://doi.org/10.1007/978-3-662-67912-8_4

Ng, MF., Zhao, J., Yan, Q. et al. (2020). Predicting the state of charge and health of batteries using data-driven machine learning. *Nat Mach Intell* 2, p: 161–170, <https://doi.org/10.1038/s42256-020-0156-7>

Xing, Y., Li, L., Bi, Z., Wilamowska-Korsak, M. and Zhang, L. (2013), Operations Research (OR) in Service Industries: A Comprehensive Review. *Syst. Res.*, 30: 300-353. <https://doi.org/10.1002/sres.2185>

Robert Baum, J. & Wally, S. (2003), Strategic decision speed and firm performance. *Strat. Mgmt. J.*, p: 1107-1129. <https://doi.org/10.1002/smj.343>

S. Tsang, B. Kao, K. Y. Yip, W. -S. Ho and S. D. Lee, "Decision Trees for Uncertain Data," in *IEEE Transactions on Knowledge and Data Engineering*, vol. 23, no. 1, pp. 64-78, Jan. 2011, doi: 10.1109/TKDE.2009.175.

Abdelkafi, N., Döbel, I., Drzewiecki, J. D., Meironke, A., Niekler, A., & Ries, S. (o.J.). KÜNSTLICHE INTELLIGENZ (KI) IM UNTERNEHMENSKONTEXT. Fraunhofer-Zentrum für Internationales Management und Wissensökonomie IMW. Verfügbar unter https://www.imw.fraunhofer.de/content/dam/moez/de/documents/Working_Paper/190830_214_KI_in_Unternehmen_final_FM_öffentlich.pdf

Garbin, C., Zhu, X. & Marques, O. (2020). Dropout vs. batch normalization: an empirical study of their impact to deep learning. *Multimed Tools Appl* 79, 12777–12815, <https://doi.org/10.1007/s11042-019-08453-9>

Choi, T., Wallace, S. W., & Wang, Y. (2018). Big Data Analytics in Operations Management. *Production and Operations Management*, 27(10), p: 1868-1883. <https://doi.org/10.1111/poms.12838>

Esmaeili, F., Mafakheri, F., & Nasiri, F. (2023). Biomass supply chain resilience: integrating demand and availability predictions into routing decisions using machine learning. *Smart Science*, 11(2), p: 293–317. <https://doi.org/10.1080/23080477.2023.2176749>

Rezaeenour, J., Ahmadi, M., Jelodar, H. et al. (2023). Systematic review of content analysis algorithms based on deep neural networks. *Multimed Tools Appl* 82, p: 17879–17903, <https://doi.org/10.1007/s11042-022-14043-z>

D. Abts et al.,(2020). "Think Fast: A Tensor Streaming Processor (TSP) for Accelerating Deep Learning Workloads," 2020 ACM/IEEE 47th Annual International Symposium on Computer Architecture (ISCA), p: 145-158, doi: 10.1109/ISCA45697.2020.00023.

Oyelade, O.N. & Ezugwu, A.E. (2022). A novel wavelet decomposition and transformation convolutional neural network with data augmentation for breast cancer detection using digital mammogram., <https://doi.org/10.1038/s41598-022-09905-3>

A. Shrestha & A. Mahmood (2019). "Review of Deep Learning Algorithms and Architectures," in *IEEE Access*, vol. 7, p: 53040-53065, doi: 10.1109/ACCESS.2019.2912200.

Jena, N. & Seth, N. (2016), "Factors influencing logistics cost and service quality: a survey within the Indian steel sector", *Industrial and Commercial Training*, Vol. 48 No. 4, p: 199-207. <https://doi.org/10.1108/ICT-09-2015-0057>

Wong, W.P., Soh, K.L., Chong, C.L. and Karia, N. (2015), "Logistics firms performance: efficiency and effectiveness perspectives", *International Journal of Productivity and Performance Management*, Vol. 64 No. 5, p: 686-701. <https://doi.org/10.1108/IJPPM-12-2013-0205>

Chowdhary, N., Kaur, P.D. (2018). Dynamic Route Optimization Using Nature-Inspired Algorithms in IoV. In: Somani, A., Srivastava, S., Mundra, A., Rawat, S. (eds) *Proceedings of First International Conference on Smart System, Innovations and Computing. Smart Innovation, Systems and Technologies*, vol 79. Springer, Singapore. https://doi.org/10.1007/978-981-10-5828-8_47

Y. Issaoui, A. Khat, K. Haricha, A. Bahnasse and H. Ouajji, (2022). "An Advanced System to Enhance and Optimize Delivery Operations in a Smart Logistics Environment," in *IEEE Access*, vol. 10, pp. 6175-6193, doi: 10.1109/ACCESS.2022.3141311.

Barceló, J., Grzybowska, H., Pardo, S. (2007). Vehicle Routing And Scheduling Models, Simulation And City Logistics. In: Zeimpekis, V., Tarantilis, C.D., Giaglis, G.M., Minis, I. (eds) *Dynamic Fleet Management. Operations Research/Computer Science Interfaces Series*, vol 38. Springer, Boston, MA. https://doi.org/10.1007/978-0-387-71722-7_8

Xin Meng & Xuesong Li (2020). Research on Optimization of Port Logistics Distribution Path Planning Based on Intelligent Group Classification Algorithm. *Journal of Coastal Research*, p: 205–207. doi: <https://doi.org/10.2112/JCR-SI115-064.1>

Chen, Yh. (2020). Intelligent algorithms for cold chain logistics distribution optimization based on big data cloud computing analysis. *J Cloud Comp* 9, <https://doi.org/10.1186/s13677-020-00174-x>

Zhao G. (2023). Application of swarm intelligence optimization algorithm in logistics delivery path optimization under the background of big data. *Journal of Function Spaces.*, <https://www.proquest.com/scholarly-journals/application-swarm-intelligence-optimization/docview/2782826007/se-2>. doi: <https://doi.org/10.1155/2023/3476711>.