


KÜNSTLICHE INTELLIGENZ IN DER LOGISTIK

SSI SCHÄFER
Whitepaper

JULI
2018

Begriffe, Anwendungen und Perspektiven

ssi-schaefer.com



AI

SSI SCHÄFER

INHALT

1_ Einleitung

2_ Grundbegriffe der Künstlichen Intelligenz

2.1 Künstliche Intelligenz (Artificial Intelligence)

2.2 Maschinelles Lernen (Machine Learning)

2.2.1 Überwachtes Lernen (Supervised Learning)

2.2.2 Nicht überwachtes Lernen (Unsupervised Learning)

2.2.3 Teilüberwachtes Lernen (Semi-supervised Learning)

2.2.4 Verstärkendes Lernen (Reinforcement Learning)

2.3 Deep Learning in neuronalen Netzen

2.3.1 Neuronale Netze und Deep Learning:
grundlegende Prinzipien

2.4 Cognitive Computing

3_ Künstliche Intelligenz in der Logistik

3.1 Simulation

3.2 Optimierung

3.2.1 „H“ bei Hitachi: KI gibt Anweisungen für Lagerarbeiter

3.2.2 Zalando: Wegoptimierung mit Deep Learning

3.2.3 Künstliche Intelligenz und autonome Roboter

3.3 Predictive Analytics

3.3.1 Otto: Mehr als zwei Millionen Retouren weniger durch KI

3.3.2 Zalando: Ein persönlicher Shop für jeden Kunden


3.3.3 Künstliche Intelligenz in der Luft

3.4 Von Predictive Maintenance zu Prescriptive Maintenance

4_ Fazit: Wie Künstliche Intelligenz die Wertschöpfungskette verändert

5_ Der Ansatz von SSI Schäfer

Quellen



KANN EINE MASCHINE DENKEN?

Eine einfache Frage, die schwer zu beantworten ist. Denn bereits Begriffe wie „denken“ oder „Intelligenz“ werden von unterschiedlichen Forschern verschieden definiert. Dies ist nur eines der Probleme, auf die man stößt, wenn man sich näher mit Künstlicher Intelligenz beschäftigt.

Während KI-Systeme einerseits, im Gegensatz zum Menschen, eine ungleich größere Daten- und damit Informationsmenge verarbeiten können, haben sie bislang den Nachteil, nur aus bekannten Entscheidungsmöglichkeiten auswählen zu können. Das Alleinstellungsmerkmal des innovativen und kreativen Denkens bleibt dem Menschen weiterhin vorbehalten.

Klar ist: Aktuelle Fortschritte bei der Entwicklung von Algorithmen, verbunden mit hoher Rechenleistung und einem exponentiellen Wachstum an verfügbaren Daten, machen heute die Entwicklung von Systemen möglich, die Tätigkeiten ausführen können, welche bislang als die exklusive Domäne des Menschen angesehen wurden. Und mehr noch: Häufig üben sie diese Tätigkeiten mit einer höheren Genauigkeit aus-, und das gleichbleibender Verlässlichkeit ohne Pause rund um die Uhr.

Selbstlernende Systeme übernehmen den Kundenservice, verwalten Logistikprozesse, analysieren medizinische Daten oder schreiben Nachrichten und komponieren Musik. Deep Learning, eine Variante des maschinellen Lernens, nutzt neuronale Netzwerke mit vielen Schichten (daher die Bezeichnung „tief“), um die Möglichkeiten der KI für komplexere, erst durch mehrere Stufen berechenbare Aufgabenstellungen zu erweitern.

Maschinen können heute Objekte und Gesichter exakt und facettenreich erkennen, Menschen in herausfordernden Spielen wie Schach und Go schlagen, Lippenlesen und sogar natürliche Sprache erzeugen. Viele Unternehmen, darunter auch SSI SCHÄFER, sehen die Künstliche Intelligenz inzwischen als einen zentralen Bestandteil ihrer Strategie und entscheidenden Faktor für ihr zukünftiges Kerngeschäft an.

Auf der einen Seite kann Künstliche Intelligenz die Grundlage für enorme Produktivitätsgewinne und eine verbesserte Lebensqualität sein. Aber sie kann, wie alle neuen Technologien, auch zu einer radikalen Veränderung in der Arbeitswelt führen-, vergleichbar mit der Einführung des Fließbandes. Ganz zu schweigen von den ethischen und gesellschaftlichen Fragen, mit denen wir uns beschäftigen müssen, wenn Maschinen immer mehr intellektuelle Fähigkeiten erlangen. ■

Was einst Science-Fiction war, ist heute Realität. „Machine Learning“ nutzt das in Datenbanken und Data Warehouses implizit vorhandene Wissen, um nach einer Trainingsphase explizite Entscheidungsempfehlungen geben zu können.



GRUNDBEGRIFFE DER KÜNSTLICHEN INTELLIGENZ

2.1 KÜNSTLICHE INTELLIGENZ (ARTIFICIAL INTELLIGENCE)

KI ist ein Teilgebiet der Informatik, das sich mit der Automatisierung intelligenten Verhaltens befasst. KI ist der Versuch, einen Rechner so zu programmieren, dass er – ähnlich einem entsprechend geschulten Menschen – eigenständig Probleme bearbeiten kann. Problemlösung bedeutet, anhand von Daten aus unterschiedlichen Quellen (Datenbanken, Sensoren, Videokameras etc.) Entscheidungen zu treffen, die innerhalb der vorgegebenen Zeit eine angemessene Reaktion auf das zugrunde liegende Problem darstellen.

Konventionelle Softwareprogramme werden von Entwicklern mit spezifischen Anweisungen zu den Aufgaben codiert, die sie ausführen müssen.

Während dies in vielen sehr exakt definierbaren Situationen gut funktioniert, gibt es ab einem gewissen Komplexitätsgrad Einschränkungen. Der menschliche Programmierer kann in seinem Code nicht alle möglichen zukünftigen Anwendungsfälle berücksichtigen. Wenn sich die Umgebung ändert, können die Programme die angestrebten Ziele oder die gewünschte Performance unter den signifikant veränderten Rahmenbedingungen nicht mehr erreichen.

Um diesem Problem zu entgehen, kam es zur Entwicklung des maschinellen Lernens: **Es basiert auf adaptiven Algorithmen, die aus Daten lernen können, ohne auf eine regelbasierte Programmierung angewiesen zu sein.** Das System kann Muster erkennen, Assoziationen knüpfen und Einsichten aus den Daten gewinnen. Es handelt sich also um das Schaffen meist sinnvoller Verbindungen zwischen Input und Output durch eine künstliche Intelligenz.

Die Voraussetzungen für einen solchen Lernprozess sind eine hohe Rechenleistung sowie eine ausreichend große Datenmenge. Beides steht erst seit einigen Jahren durch Big Data zur Verfügung und so ist es nicht verwunderlich, dass auch das maschinelle Lernen in den letzten Jahren gewaltige Fortschritte gemacht hat. ▶

Bis vor etwa zehn Jahren war das Ziel der KI-Forschung, menschliche Intelligenz in Maschinen nachzubilden. Dabei traten eine Reihe von Problemen zutage, nicht zuletzt, was eigentlich unter dem Begriff „Intelligenz“ zu verstehen ist. Darunter werden mindestens die fünf folgenden Fähigkeiten subsumiert:

- **Wahrnehmen**
- **Schlussfolgern**
- **Lernen**
- **Problem lösen**
- **Linguistische Intelligenz**

Die menschliche Intelligenz ist natürlich weitaus differenzierter, aber die Konzentration auf fünf wichtige kognitive Fähigkeiten hat die KI-Forschung einen großen Schritt vorangebracht. Anstatt den Versuch zu unternehmen, eine „allgemeine Intelligenz“ wie die des Menschen zu programmieren, wurden nun exakt abgegrenzte Aufgabenstellungen in den Mittelpunkt gerückt.

Inzwischen ist Künstliche Intelligenz nicht mehr nur Grundlagenforschung, sondern hat in unseren Alltag Einzug gehalten. Ob Spracherkennungsalgorithmen wie bei Apples Siri und Amazons Alexa oder die Interpretation von Befunden im medizinischen Bereich, ob Gesichtserkennung in Videos oder in der pharmakologischen Forschung, KI-Technologien sind aus vielen Bereichen nicht mehr wegzudenken. ■

2.2 MASCHINELLES LERNEN (MACHINE LEARNING)

Maschinelles Lernen ist ein Sammelbegriff für verschiedene Verfahren zur Ermittlung eines unbekannten funktionalen Zusammenhangs zwischen Eingangs- und Ausgangsdaten. Darunter finden sich neben den weiterhin wichtigen klassischen Anwendungen wie beispielsweise Clusterbildung, Regressions-, Faktoren- und Zeitreihenanalysen auch komplexere Methoden wie neuronale Netze, evolutionäre Ansätze oder Support Vector Machines.


In seiner grundlegenden Form wird ein Machine-Learning-Algorithmus mit Informationen gefüttert, die er auf ein bestimmtes Ergebnis hin analysieren und erkennen muss. Ein Beispiel dafür ist die Klassifikation von Spam, wie sie bei nahezu allen großen E-Mail-Anbietern eingesetzt wird: Dem Programm werden Tausende von E-Mails präsentiert, die entweder als „Spam“ oder „Kein Spam“ klassifiziert sind. Der Algorithmus „lernt“ so, Spam zu identifizieren, indem er bestimmte Elemente identifiziert, deren Vorkommen Spam von legitimen E-Mails unterscheidet.

Die Algorithmen versuchen also, Muster in vorhandenen Datenbeständen zu erkennen, Daten zu klassifizieren oder Vorhersagen zu treffen.

Beispiele sind Musik- oder Kaufempfehlungen bei Online-Plattformen, die Optimierung von Marketingkampagnen oder der Kundenservice.

Dabei ist es besonders wichtig, die richtigen Muster aufzuspüren, denn es lassen sich in nahezu allen Datenquellen Muster finden und Relationen zu anderen Ereignissen herstellen. Ob diese allerdings sinnvoll bei der Lösung eines spezifischen Problems sind, ist eine andere Frage. ■

Üblicherweise wird zwischen vier verschiedenen Lernstrategien der Algorithmen unterschieden:



2.2.1 ÜBERWACHTES LERNEN (SUPERVISED LEARNING)

Beim mit Abstand am häufigsten vorkommenden überwachten Lernen wird dem Algorithmus ein Input (zum Beispiel Bilder) zusammen mit dem gewünschten Output (Label) präsentiert.


Beispiel: Soll ein Computer zwischen Bildern von Katzen und Hunden unterscheiden, werden ihm Hunderte von Katzen- und Hundebildern aus unterschiedlichsten Blickwinkeln präsentiert, jeweils mit dem entsprechenden Label „KATZE“ oder „HUND“. Auf diese Weise soll der Algorithmus eine Regel entwickeln, nach der er in Zukunft Hunde und Katzen klar unterscheiden kann. Der Lernalgorithmus muss also von den Trainingsdaten abstrahieren bzw. generalisieren können. „Overfitting“ besteht, wenn durch zu viele Daten das bestehende digitale Wissen möglicherweise wieder vernebelt wird. Diese Strategie findet schon seit Jahren Verwendung, wenn statt eines klassischen Laserscanners eine Kamera eingesetzt wird, um Barcodes oder Data-Matrix-Codes zu erfassen und auszuwerten. ■

2.2.2 NICHT- ÜBERWACHTES LERNEN (UNSUPERVISED LEARNING)

Das nicht-überwachte Lernen versucht, durch reine Betrachtung der Eingangsdaten entsprechende Muster zu erkennen und so die enorme Datenmenge in der realen Welt hinsichtlich der Dimensionen und Komplexität ohne auffällige Verluste zu reduzieren. Es ist klar, dass dies ohne Zielvorgabe eine komplexere Aufgabe ist. ■

2.2.3 TEILÜBERWACHTES LERNEN (SEMI-SUPERVISED LEARNING)

Das teilüberwachte Lernen ist eine Mischung aus den beiden oben beschriebenen Verfahren. Dies bedeutet, dass neben der Aufgabe der Erkennung von gelabelten Daten auch die gleichzeitige Aufgabe der Dimensionsreduktion zur rascheren, effizienteren und, eventuell sogar robusteren Erkennung ausgeführt wird. ■



2.2.4 VERSTÄRKENDES LERNEN (REINFORCEMENT LEARNING)

Beim verstärkenden Lernen erlernt ein Algorithmus selbstständig die beste Strategie, um ein in der Zukunft liegendes Ziel zu erreichen. Es wird zwar nicht das Ergebnis präsentiert, aber ein Hinweis (Reinforcement) gegeben, inwieweit sich der Algorithmus seinem Ziel genähert oder sich von ihm entfernt hat. Reinforcement-Learning-Algorithmen auf Basis von Deep Neural Networks („deep reinforcement learning“) haben sich dabei als besonders erfolgreich erwiesen.

Das neuronale Netz erkennt Muster in den Daten und entwickelt daraus ein Modell des Weltausschnitts, der von den Daten beschrieben wird. Die Trainingsdaten werden dem Algorithmus nicht präsentiert, sondern er erhält sie über Interaktion mit und Feedback aus der Umwelt. Diese Methode eignet sich besonders für Probleme der Klassifizierung, der Vorhersage und der Produktion. ►

Reinforcement Learning kommt dann zur Anwendung, wenn der Weg zum Ziel ebenfalls eine Rolle spielt und keine exakten Informationen über das Ergebnis vorliegen, sondern es in Relation zum bisherigen Wissensstand beurteilt wird.

Machine learning can help solve classification, prediction and generation problems

Klassifizierung	Bildhafte Objekte klassifizieren/kennzeichnen	Objekte, Gesichter in Bildern und Videos ermitteln
	Handschrift und Text klassifizieren/kennzeichnen	Buchstaben, Symbole und Wörter in einer Schriftprobe ermitteln
	Stimmen und Gesang klassifizieren/kennzeichnen	Lieder und hörbarer Text von Hörproben klassifizieren und kennzeichnen
	Clustern (Gruppieren) anderer Daten	Objekte in (z.B., Kunden, Produkteigenschaften) Kategorien und Cluster gliedern
	Verbindungen aufdecken	Erkennen, dass Leute, die bestimmte TV-Shows ansehen, auch bestimmte Bücher lesen
Vorhersage	Wahrscheinlichkeit von möglichen Ergebnissen vorhersagen	Wahrscheinlichkeit vorhersagen, dass ein Kunde sich für einen anderen Lieferanten entscheiden wird
	Prognose	Angelernt auf historischen Daten, Bedarf für ein Produkt vorhersagen
	Zielwertfunktionsabschätzung	Angelernt an tausenden gespielten Spielen, vorhersagen/schätzen von Belohnungen diverser Aktionen in zukünftigen Spielzuständen
Generierung	Visuelle Objekte erweitert reproduzieren	Angelernt anhand einer Reihe von Gemälden von Künstlern, ein neues Gemälde im selben Stil nachahmen
	Schrift und Text erweitert reproduzieren	Angelernt anhand von historischem Text, fehlende Teile einer einzelnen Seite rekonstruieren
	Audio erweitert reproduzieren	Eine neue potentielle Aufnahme im selben Stil/Genre generieren
	Andere Daten erweitert reproduzieren	Angelernt anhand von Wetterdaten bestimmter Länder, fehlende Datenpunkte für Länder mit niedriger Datenqualität extrapolieren

Klassifizierungsprobleme erfordern beispielsweise die Identifikation von Objekten (Fotos, Videos, Texte, Töne) und deren Verbindung miteinander oder mit anderen Datenquellen. Ein Anwendungsbeispiel ist das Clustering von Kunden in verschiedene Kategorien. Die Herstellung von Zusammenhängen zwischen Objekten/Daten ist auch eine Voraussetzung für Prognosen sowie für die Produktion von Texten und Bildern, wie die Erzeugung eines fehlenden Frames in einem Video. ■

2.3 DEEP LEARNING IN NEURONALEN NETZEN

Aufgabenstellungen, die selbst für Kinder kein Problem darstellen, waren für Maschinen lange Zeit eine Hürde, beispielsweise das Erkennen von Bildinhalten oder die Spracherkennung.

Dank Deep Learning, eines auf der Technik von neuronalen Netzen basierenden Ansatzes, hat sich das in den letzten Jahren geändert. Der Begriff „deep“ bezieht sich dabei auf die Anzahl verborgener Schichten der Netze – neuronale Netzwerke, die auf Deep Residual Learning basieren, der derzeit komplexesten Methode zur Objekterkennung, können tausend oder mehr solcher Schichten enthalten. ■

2.3.1 NEURONALE NETZE UND DEEP LEARNING: GRUNDLEGENDE PRINZIPIEN

Neuronale Netze sind an das Vorbild des menschlichen Gehirns angelehnt und haben das Ziel, Probleme auf eine ähnliche Art zu lösen wie Menschen.

Es handelt sich dabei um Netzwerke von eng miteinander verbundenen Verarbeitungselementen, den Neuronen, die auch als Knoten oder Nodes bezeichnet werden. Sie nehmen Informationen aus der Umwelt oder von anderen Neuronen auf, bearbeiten sie und leiten sie an andere Nodes oder die Umwelt weiter.


Dem Beobachter direkt zugänglich sind dabei nur die äußeren Schichten, also der Input Layer und der Output Layer. Was im Inneren des Netzes geschieht, ist unsichtbar und oft nicht mehr einfach für Validierungs- und Verifikationszwecke zu plausibilisieren.

Die künstlichen Neuronen werden in vielen Schichten hintereinander bzw. übereinander modelliert und angeordnet. Jede Ebene des Netzwerks liefert dazu einen Beitrag zur Erreichung des (hoffentlich) korrekten Outputs. Diese Extraktion von Merkmalen findet innerhalb der einzelnen Ebenen eigenständig statt. Die Ausgabe der einzelnen Schichten dient dann wiederum als Eingabe für die nächste Ebene. Durch große Mengen qualitativ hochwertiger Trainingsdaten lernt das Netzwerk, bestimmte Aufgaben zu erledigen.

Neuronale Netze bestehen aus drei grundlegenden Schichten:

- dem **Input Layer**,
- (eventuell) einem oder mehreren **Hidden Layers** sowie
- dem **Output Layer**.


Beispiel: Es ist für einen Computer schwierig, die Bedeutung eines Fotos auf den ersten Blick zu erfassen, so wie wir Menschen es können. Aus einer Gruppe von Pixeln eine sinnvolle Gestalt herauszulesen, ist eine hochkomplexe Aufgabe, deren direkte Umsetzung nahezu unmöglich ist.



Beim Deep Learning bricht das neuronale Netz das Bild in eine Vielzahl von Teilabbildungen auf, die von jeweils einem Layer bearbeitet werden, beispielsweise Kanten, Ecken, Konturen etc. So könnte der erste Hidden Layer beispielsweise Kanten durch einen Helligkeitsabgleich benachbarter Pixel ermitteln und diese Information an den zweiten Hidden Layer weitergeben, der dann nach Ecken oder Konturen sucht, die ja nichts anderes sind als eine Gruppe von Kanten. Aufgrund dieser Informationen sucht der dritte Hidden Layer dann nach Gruppen von Ecken und Konturen, die für ein spezifisches Objekt typisch sind etc., bis schließlich ein bestimmtes Objekt identifiziert wird. ►

Mit jeder Verbindung zwischen den Nodes ist eine Gewichtung verknüpft, die während des Lernvorgangs modifiziert wird. Ein positives Gewicht bedeutet, dass ein Neuron auf ein anderes Neuron einen exzitatorischen, erregenden Einfluss ausübt, ein negatives Gewicht, dass der Einfluss inhibitorisch, also hemmender Natur ist. Bei einem Gewicht von Null übt ein Neuron auf ein anderes Neuron keinen Einfluss aus. Wie im täglichen Leben, wenn wir einen Mückenstich oder Zeckenbiss nicht bemerken, braucht es auch bei den neuronalen Netzen eine sogenannte Aktivierungsfunktion, welche Kleinstwerte eliminiert und sich auf die wirklich wichtigen Zusammenhänge konzentriert.

Im Beispiel rechts entspricht beispielsweise der „Pixelwert“ des Bildes (input value) dem Kategoriewert „Person“ (output value). Wenn der vom neuronalen Netz generierte Outputwert nicht dem Kategoriewert entspricht, wird ein Signal mit einer Fehlermeldung zurück ins Netz gesendet. Als Folge ändern sich die Werte der Gewichtungen und es wird ein neuer Versuch unternommen. Im Laufe der Zeit summieren sich diese kleinen Veränderungen bei den Gewichtungen so, dass das Netzwerk lernt, einen präsentierten Pixelwert korrekt in den richtigen Kategoriewert zu übersetzen. ■



2.4 COGNITIVE COMPUTING

Manche Autoren führen noch eine weitere Variante von KI auf: Cognitive Computing.

Darunter werden Systeme verstanden, die als Assistent oder anstelle von Menschen bestimmte Aufgaben übernehmen oder Entscheidungen treffen, beispielsweise beim Schadenfall-Management einer Versicherung oder bei der Diagnostik im Krankenhaus. Diese Systeme können mit Ambiguität und Unschärfe umgehen und verfügen innerhalb ihres Wissensbereiches über einen hohen Grad an Autonomie. ■



KÜNSTLICHE INETLLIGENZ IN DER LOGISTIK


In einer Studie der Crisp Research AG unter IT-Entscheidern aus dem Jahre 2016 liegt die Logistikbranche mit an der Spitze der Unternehmen, die bereits aktiv Machine-Learning-Verfahren im Alltag einsetzen.

Status der Branchen bei der Einführung von Machine Learning (n=168)

Branche	In Evaluierung/ Planung	Erste Erfahrungen & Prototypen	Nutzung in ausge- wählten Einsatzbe- reichen	Einsatz im Produk- tivbetrieb in weiten Teilen des Unter- nehmens
Automobil und Autozulieferer	60 %	20 %	0 %	20 %
Maschinen- und Anlagenbau	52,9 %	17,7 %	29,4 %	0 %
Chemische Industrie	30 %	40 %	30 %	0 %
Metallverarbeitende Industrie	38,5 %	46,2 %	15,4 %	0 %
Konsumgüter und Handel	18,8 %	43,8 %	25 %	12,5 %
Logistik und Verkehr	16,7 %	41,7 %	41,7 %	0 %
Banken und Versicherungen	28,6 %	33,3 %	28,6 %	9,5 %
Professionelle Dienstleistungen	38,5 %	23,1 %	30,8 %	7,7 %
Pharma und Gesundheitswesen	22,2 %	55,6 %	22,2 %	0 %
IT, Telekommunikation und Media	11,8 %	47,1 %	26,5 %	14,7 %
Öffentlicher Sektor und Bildung	27,8 %	44,4 %	27,8 %	0 %



Dies liegt vielleicht auch daran, dass die Veränderung der Rahmenbedingungen durch die geänderten Anforderungen (z. B. E-Commerce) und damit verbundene rasante Digitalisierung wie die darauf aufbauenden neuen Geschäftsmodelle in der wettbewerbsintensiven Logistik früher spürbar geworden sind als in anderen Branchen. Logistik ist der zunehmend entscheidende Wettbewerbsfaktor und schon seit Jahren mit zahlreichen neuen Herausforderungen konfrontiert. Diese werden noch verstärkt durch die immer weitergehenden Versprechen der Online-Anbieter und die darauf aufbauenden gestiegenen Erwartungen von Endverbrauchern, zum Beispiel Same-day-delivery und ständige Warenverfügbarkeit auch im stationären Handel. Hinzu kommt die wachsende Zahl an kleinen Bestellmengen in höherer Frequenz.



Die genannten Entwicklungen erfordern die Neuorganisation der bestehenden Geschäftsmodelle und Strategien von Logistikunternehmen. Eine Antwort darauf ist die weitgehende Automatisierung aller logistischen Prozesse und ihre Integration und Steuerung durch eine einheitliche IT. Diese basiert allerdings immer noch auf den Eingaben menschlicher Bediener, wenn auch einzelne Prozessschritte durch die Einbindung von Sensoren oder ähnliche schon weitgehend autonom laufen.

Hier greift der sogenannte Curse of Dimension: Mit zunehmender Größe und Komplexität logistischer Operationen oder der Notwendigkeit an zeitkritischen Entscheidungen versagen auch bisher etablierte mathematische Optimierungsalgorithmen. Der Zeitraum für eine Entscheidung wird immer kürzer und die Problemgröße gleichzeitig immer höher.

Durch den Einsatz von KI-Technologien können sich Logistikanbieter nicht nur vom Wettbewerb differenzieren, sondern auch ihren Ertrag erhöhen. Die intelligente Analyse der Datenmengen, die auf allen Stufen der Supply Chain anfallen, macht es möglich, bisher ungesehene Zusammenhänge zu erkennen, realistische Szenarios für die nahe Zukunft zu entwickeln und den Warenfluss insgesamt weit- aus agiler und weniger anfällig für Störungen zu gestalten.

Bereits heute gibt es eine Reihe von Einsatzgebieten, in denen KI-Technologien zur Anwendung kommen. Häufig sind es noch Insellösungen, aber der Trend geht eindeutig in Richtung Integration.

Manish Chandra und Anand Darvhe von Accenture Strategy meinen sogar, dass „der Einsatz von KI in der Supply Chain am Ende ein Ökosystem hervorbringen wird, in dem unterschiedliche Wertschöpfungsketten miteinander verknüpft sind und den nahtlosen Fluss von Produkten und Informationen von einem Ende zum anderen ermöglichen.“

Im Folgenden stellen wir einige der Felder vor, in denen Künstliche Intelligenz im Bereich Logistik derzeit eingesetzt wird. Die Beispiele beanspruchen keine Vollständigkeit, sondern sollen nur schlaglichtartig beleuchten, welche Möglichkeiten KI-Technologien bieten. ■

3.1 SIMULATION

Bei der Planung logistischer Anlagen und Prozesse spielen Simulationen schon seit vielen Jahren eine zentrale Rolle.

Simulationsmodelle ermitteln Ergebnisse über das dynamische Verhalten eines Systems für vorgegebene Parameter. Durch den häufig nicht vollständig ersichtlichen Zusammenhang zwischen Ergebnisgrößen und Parametern eines Logistiksystems ist eine manuelle Optimierung schwierig oder eben nur für den betrachteten Anwendungsfall ohne Anspruch auf Allgemeingültigkeit möglich.

Das Gebiet der Simulation erfährt mit dem „Digitalen Zwilling“ einen neuen Bedeutungsschub. Die fast deckungsgleiche Offline-Repräsentation eines betrachteten Systems ermöglicht mit entsprechend umfassendem Dateninput das Anlernen, Weiterlernen und Umlernen von KI-gestützten Algorithmen bei Änderungen im Logistikumfeld.

Die Möglichkeit, durch virtuelle Modelle eine KI unter der Voraussetzung der entsprechenden Modellqualität zu trainieren, verknüpft eine bestehende, ausgereifte und anerkannte Technologie als Enabler nun mit den erweiterten Möglichkeiten der Computational Science. Dabei stehen, je nach Aufgabenstellung, unterschiedliche Lösungsansätze zur Verfügung (FEM/CFD, ereignisorientiert, System Dynamics, agentenbasiert etc.). ■

Bei Herstellern intralogistischer Anlagen kann eine KI zudem auf die Daten vieler Aufgabenstellungen aus der Vergangenheit zurückgreifen, deren Parameter Ähnlichkeit mit denen der aktuellen Problemstellung aufweisen.

Auch hier gilt:
Eine entsprechend große, repräsentative Datenmenge, welche jedoch noch nicht in die Gefahr des Overfittings hineinfließt, ist eine Grundlage für den Lernerfolg.

3.2 OPTIMIERUNG

Ein Gebiet, in dem KI heute ebenfalls bereits Verwendung findet, ist die Optimierung logistischer Prozesse, damit sie sich selbstständig und dynamisch an die wandelnden Anforderungen des Marktes anpassen können.

Dazu gehören beispielsweise die Anpassung der Auftragsabwicklung abhängig von saisonalen Schwankungen, aber auch Muster beim Bestellverhalten, die sich einem menschlichen Analysten nicht auf den ersten Blick erschließen würden. Die „klassische“ Optimierung geht dabei immer von einem vorgegebenen und unveränderlichen Ziel (Zielfunktion) aus. Diese Einschränkung muss aber in der modernen Logistik aufgeweicht werden, da sich das Optimum mit dem Geschäft des Kunden verändert. ■

3.2.1 „H“ BEI HITACHI: KI GIBT ANWEISUNGEN FÜR LAGERARBEITER

Der japanische Elektronikkonzern Hitachi entwickelte eine KI-Technik namens „H“, die für verschiedene Anwendungszwecke adaptiert wurde. „H“ ist eine KI-Version von Kaizen, der kontinuierlichen Verbesserung von Arbeitsprozessen.

Die KI analysiert, wie die Mitarbeiter mit Problemen umgehen. Obwohl sie oftmals im eng gezogenen Rahmen klarer Anweisungen operieren, sind die Mitarbeiter immer wieder auf der Suche nach Verbesserungsmöglichkeiten ihres Workflows, auch wenn diese nur minimal sind. „H“ sammelt darüber Informationen und bewertet die Effizienz der einzelnen Ansätze. Trägt ein Lösungsweg dazu bei, die Effizienz zu steigern, wird er genauer analysiert und anschließend als Arbeitsanweisung an andere Mitarbeiter weitergegeben.

Gleichzeitig ist „H“ dazu in der Lage, auf kurzfristige Änderungen zu reagieren und Anweisungen für situativ entstehende Anlässe zu geben. Die KI kann Wetterdaten ebenso in ihre Analysen einbeziehen wie Nachfrageschwankungen. Eine Schlechtwetterperiode kann beispielsweise zu Verspätungen bei Ankunft und Abfahrt von Lkws führen; zugleich könnte die Nachfrage nach Regenbekleidung steigen.

„H“ operiert ohne vorherige Rückkopplung mit einem menschlichen Supervisor. Die KI gibt ihre Handlungsanweisungen direkt an die Mitarbeiter oder an angeschlossene Systeme heraus. So sind schnelle Reaktionen möglich und effizienzsteigernde Maßnahmen können ohne Verzögerung umgesetzt werden. Hitachi gibt an, die Produktivität im Vergleich zu ähnlichen Lagerhäusern ohne KI durch den Einsatz von „H“ um 8 Prozent gesteigert zu haben. ■




3.2.2 ZALANDO: WEGEOPTIMIERUNG MIT DEEP LEARNING

Ein zentrales Problem beim Kommissionieren in Lagern ist die Berechnung der optimalen Wege für die Kommissionierer. Bei Zalando wurde ein neuronales Netz trainiert, um die kürzesten Pickrouten zu ermitteln. Der KI-Algorithmus produzierte eine Lösung, die es ermöglichte, die Kommissionierungsarbeit besser zwischen den Mitarbeitern aufzuteilen und den Kommissionierprozess zu beschleunigen.


Grundannahme war ein simplifiziertes Lager, in dem die zu kommissionierenden Artikel in Regalen liegen, die parallel zueinander aufgebaut sind. Zwischen den Regalen befinden sich Längs- und Quergänge. Der Kommissionierer erhält eine Pickliste und geht mit einem Wagen an den Regalen entlang, um die geforderten Artikel aus den Regalen zu nehmen. Bei der Kombination aus Pickliste und Wegstrecke handelt es sich im Prinzip um eine komplexere Variante des Traveling-Salesman-Problems.

Der von den Zalando-IT-Fachleuten entwickelte OCaPi-Algorithmus (Optimal Cart Pick) berücksichtigt bei der Suche nach der kürzesten Route nicht nur die Wege der Mitarbeiter, sondern auch die der Wagen, die manchmal in einem Quergang abgestellt werden, während der Mitarbeiter die Artikel aus den Regalen holt. ►



Leider benötigt der OCaPi-Algorithmus mehrere Sekunden, um eine optimale Pickliste zu berechnen. Bei Tausenden von Bestellungen, die jede Stunde bei Zalando eingehen, ist das zu lange, um im Einsatz zu funktionieren. Um diese Zeit auf wenige Millisekunden zu reduzieren, wurden eine Million zufälliger Picklisten generiert und mit Hilfe von OCaPi mit der dafür errechneten Kommissionierzeit gelabelt. Diese Daten wurden dann in ein neuronales Netz eingespeist. So entwickelte sich eine Netzwerkarchitektur, deren Wegezeitenberechnung nur eine Fehlerrate von etwas über 32 Sekunden pro Stunde aufweist, ein zu vernachlässigender Wert.

Zum Testen der KI wurde ein einfacher Optimierungsalgorithmus geschrieben, der mit 40 Bestellungen zu je zwei Artikeln beginnt, die zufällig zwischen zwei Picklisten aufgeteilt werden. Für 40 Bestellungen existieren rund 69 Milliarden Möglichkeiten, die Artikel auf zwei Picklisten aufzuteilen. Die von der KI berechneten Wege führten zu einer Reduktion der Wegzeit pro gepicktem Artikel von 11 Prozent. ■



3.2.3 KI UND AUTONOME ROBOTER

Heute gibt es Lager, deren Operationsprinzipien von menschlichen Beobachtern nicht mehr verstanden werden – weil sie von einer Künstlichen Intelligenz gesteuert werden. Gemeinsames Merkmal sind zumeist Roboter, insbesondere Fahrerlose Transportsysteme (FTS). In diesen Lagern sind Produkte nicht mehr nach Kategorien gruppiert und sauber nebeneinander platziert, so wie wir es beispielsweise aus Supermärkten kennen, sondern scheinbar chaotisch in verschiedenen Regalen und Gängen verstaut. Was für einen menschlichen Kommissionierer unnötige Wege- und Suchzeiten bedeuten würde, ist für die autonomen Roboter kein Problem: **Kommt eine Bestellung herein, dann nimmt der erste verfügbare Roboter den Artikel auf, der seiner Position am nächsten gelagert ist, und befördert ihn zu den menschlichen Packern am Ende des Lagers.**

Die Roboter selbst sind dabei nicht besonders „intelligent“, das dahinterstehende KI-System schon. Es behandelt das Lager als eine ständig in Bewegung befindliche Menge mit sich ständig verändernden Parametern: Von der Nachfrage nach bestimmten Produkten bis hin zur aktuellen Position jedes Roboters. Kommen Roboter von KIVA Systems zum Einsatz, verändert sich auch die Geographie des Lagers ständig, denn diese bringen nicht einzelne Produkte zum Verpacker, sondern gleich das gesamte Regal.



Ein anderer Ansatz ist der Einsatz von intelligenten selbstfahrenden Fahrzeugen. Schwärme von FTS, die ihre Umgebung mithilfe von Laserscannern, Sensoren und RFID-Chips unabhängig voneinander wahrnehmen können, navigieren autonom zu ihren jeweiligen Zielen. Ohne zentrales Steuerungssystem regeln solche FTS die Verteilung eingehender Transportaufträge selbst, legen Regeln fest, um den richtigen Weg zu finden, und teilen sich gegenseitig ihre Position mit. Da jedes FTS die Informationen dezentral verarbeitet, ist die Steuerung praktisch auf mehrere Fahrzeuge verteilt. Treten Hindernisse oder Störungen auf, reagiert der Schwarm selbstständig und löst das Problem. ■



KI-gesteuerte KIVA-Roboter in Aktion

3.3 PREDICTIVE ANALYTICS

Big-Data-Technologien sind heute Elemente einer agilen Supply Chain. Erst durch den Einsatz dieser Technologien wird es möglich, die gigantischen Datenmengen, die beispielsweise durch Sensoren entstehen, zu verarbeiten, die reale Welt zeitnah abzubilden und Entscheidungen treffsicher zu fällen. Big-Data-Technologien ermöglichen Prognosen und ausgefeilte Szenarioanalysen und gestatten so eine präzise Kapazitätsplanung sowie Lieferketten- und Inventaroptimierung.

Predictive Analytics stützt sich zunächst auf Data Mining, ein klassisches Einsatzgebiet von Künstlicher Intelligenz. **Es geht um das Erkennen von Mustern in Datenmengen. Dabei finden statistische Berechnungen, eventuell Elemente der Spieltheorie, semantische Verfahren sowie Methoden des Operations Research Anwendung.**

Die Vorstufe von Predictive Analytics wird als Descriptive Analytics bezeichnet; die nachfolgende Stufe nennt sich Prescriptive Analytics, bei der die KI aufgrund der erkannten Zusammenhänge Handlungsempfehlungen gibt.


Voraussetzung für ein aussagekräftiges Resultat ist eine hohe Datenintegrität. Eine Vorhersage ist immer nur so gut, wie die dem System bereitgestellten Daten.

Dies ist nicht notwendigerweise gesichert. In zu vielen Fällen erfolgt die Dateneingabe nach wie vor manuell und, wenn auch ungewollt, entsprechend fehlerbehaftet. Insbesondere in der Logistik sind die kontinuierlich anfallenden Daten aber eine ausgezeichnete Grundlage, das System wiederkehrend den geänderten Umfeldbedingungen anzupassen.

Zwar können KI-Systeme bei großen Datenmengen einzelne Fehler gut kompensieren, aber wenn sich viele kleine Abweichungen summieren, besteht die Gefahr, falsche Ergebnisse zu erhalten. Es geht also nicht nur darum, Daten lediglich zu sammeln, sondern sie von Beginn an zu „verstehen“.

Ein banales Beispiel ist die Verwendung unterschiedlicher Maßangaben. Wenn einige Datensätze mit der Maßangabe „Meter“, andere aber mit der Maßangabe „Feet“ arbeiten, so muss sichergestellt sein, dass im Vorfeld eine Vereinheitlichung auf einen vorher festgelegten Maßeinheitenstandard stattfindet. Dazu werden entsprechend qualifizierte und erfahrene Data Scientists benötigt, ein relativ neues Berufsbild von Fachleuten, die mit riesigen Datenmengen umgehen und einen möglichst großen Nutzen daraus ziehen können. Sie verfügen über aktuelles IT-Wissen, haben fundierte Kenntnisse der mathematisch-statistischen Verfahren und besitzen genaue Kenntnis über das fachliche Umfeld des Auftraggebers.

Die Challenger-Katastrophe 1986 ist ein Musterbeispiel, wenn ein Problem nicht in der notwendigen umfassenden Gesamtheit analysiert und erkannt wird. Die reine Betrachtung der Ausfallmessungen des fraglichen O-Rings, der die Explosion ausgelöst hat, war nicht aussagekräftig genug, um die Gefahr des Shuttle-Starts unterhalb von 37° F korrekt einzuschätzen. Wären die Daten der Fehlschläge den Werten der erfolgreichen Tests gegenübergestellt worden, hätte durch die entsprechenden Gruppierung der schlechten Werte im unteren Temperaturbereich und die Gruppierung der Werte im oberen Temperaturbereich umgehend erkannt werden können, dass die Temperatur einen kritischen Faktor für dieses Bauteil darstellt. ■



3.3.1 OTTO: MEHR ALS ZWEI MILLIONEN RETOUREN WENIGER DURCH KI

Otto ist ein Multichannel-Unternehmen und in Deutschland einer der größten Online-Händler für Fashion und Lifestyle. 75 Prozent des Gesamtumsatzes erwirtschaftet der Konzern über Onlineshops. Angeboten werden 1,8 Millionen Artikel und 3.600 Marken.


Wie bei anderen E-Commerce-Unternehmen auch, verursachen Rücksendungen von Waren hohe Kosten, bei Otto jährlich mehrere Millionen Euro. Eine Analyse der verfügbaren Daten ergab, dass Kunden, die ihre bestellte Ware innerhalb von zwei Tagen erhalten, im Schnitt weniger zurücksenden. Zudem bevorzugen Kunden es, ihre Bestellung in einer Lieferung zu erhalten und nicht verteilt über mehrere Sendungen.

Da Otto Artikel anderer Hersteller verkauft und einen großen Teil davon nicht auf Lager hat, ergab sich eine verzwickte Lage: Entweder wartet man, bis alle Artikel einer Bestellung eingetroffen sind, um sie dann in einer Lieferung zu versenden, was zumeist länger als zwei Tage dauert. Oder man versendet sofort nach Wareneingang, was dann zu mehreren Lieferungen führt.

Otto setzte einen Deep-Learning-Algorithmus ein, der ursprünglich aus der Teilchenphysik stammt. Die KI analysierte rund drei Milliarden Datensätze und 200 Variablen, darunter erfolgte Transaktionen, Suchanfragen auf der Otto Website und Wettervorhersagen, um daraus eine Vorhersage über die Käufe der nächsten Woche abzuleiten.


Das KI-System erwies sich dabei als ausgesprochen erfolgreich. Es sagt mit einer Genauigkeit von 90 Prozent vorher, was innerhalb der nächsten 30 Tage verkauft werden wird. Deshalb kann Otto jetzt monatlich rund 200.000 Artikel im Voraus ordern und bei Bestellung schneller in einer einzigen Sendung verschicken. Das Ergebnis: Seit Einführung des KI-Systems ist die Anzahl der Retouren pro Jahr um über zwei Millionen Artikel gesunken. Durch weniger Pakete wird zudem die Umweltbelastung deutlich reduziert.

Einen anderen Ansatz verfolgt Zalando. Um die Retouren zu senken, experimentiert man dort mit dem Thema Größen, denn die falsche Größe eines Produkts ist für 30 bis 40 Prozent der Retouren verantwortlich, wie man herausgefunden hat. Ziel ist es, diese Zahl zu reduzieren. Dafür setzt Zalando auf Machine Learning. Gestartet wurde mit Schuhen. Eine Anzahl Frauen und Männer probiert Schuhe in ihrer Größe an und meldet, ob sie passen oder nicht. Diese Daten wertet die KI aus und versucht, daraus ein Muster abzuleiten. Bestellt ein Kunde in Zukunft einen Schuh und nimmt üblicherweise immer Größe 39, soll das System ihm sagen können, dass für diese spezielle Marke vielleicht die Größe 40 besser ist. ■



3.3.2 ZALANDO: EIN PERSÖNLICHER SHOP FÜR JEDEN KUNDEN

Zalando ist als Schuh- und Modehändler gestartet, versteht sich aber inzwischen als Technologiekonzern, der Dienstleister für die gesamte Modebranche sein möchte. Deshalb beschäftigt der Konzern inzwischen mehrere tausend Programmierer. Laut einem Bericht des Handelsblatts soll innerhalb der nächsten anderthalb Jahre ein zweistelliger Millionenbetrag in intelligente Algorithmen, die über bestehende Recommender-Ansätze hinausgehen, fließen, die individuelle Onlineshops für jeden Kunden erstellen und eine optimierte, reduzierte Auswahl aus den 300.000 Artikeln bieten, die Zalando jede Saison in den Markt bringt. ■



3.3.3 KÜNSTLICHE INTELLIGENZ IN DER LUFT

Ein häufiges Ärgernis in großen Lagern sind Zähl- und Erfassungsfehler bei der Inventur der gelagerten Güter. Allein in den USA verursacht das jährlich einen finanziellen Schaden im Milliarden-Dollar-Bereich. Künstliche Intelligenz kann auch zur Lösung dieses Problems einen Beitrag leisten.

Das US-Unternehmen Intelligent Flying Machines (IFM) hat eine Flugdrohne entwickelt, die für die räumliche Orientierung kein GPS benötigt, sondern sich mit Hilfe von KI-Algorithmen in geschlossenen Räumen zielsicher bewegen kann. Die Kamera erfasst die Artikel und ihre Position; anschließend werden die Daten mit dem Warehouse Management System (WMS) abgeglichen. Die Grundlage dafür sind intelligente Algorithmen. ■

3.4 VON PREDICTIVE MAINTENANCE ZU PRESCRIPTIVE MAINTENANCE

Um sich dem Bedarf nach einer (fast) absolut zuverlässigen Hardware für einen hochperformanten Lagerbetrieb zu nähern und Produktionsausfälle zu verhindern, kommen KI-Technologien auch für die Lebens(rest)dauervorhersage von Maschinen und Anlagen zum Einsatz. **Predictive Maintenance (vorbeugende Instandhaltung) dient dem Erkennen des bevorstehenden Ausfalls eines Betriebsmittels und der Einleitung vorbeugender Maßnahmen, um das zu verhindern.** Dazu zählen vier Säulen:


- **Datenerfassung**
- **Datentransfer**
- **Datenauswertung**
- **funktionserhaltende Maßnahmen**

Die Datenerfassung erfolgt aus Kostengründen bei den meisten Industrieanlagen noch über Prüfungen und Wartungen. Durch die sinkenden Kosten von Sensoren und Datentransfereinrichtungen wird sich die digitale Überwachung in Echtzeit aber durchsetzen. Die erfassten Daten werden zentral gesammelt und können unter verschiedenen Gesichtspunkten ausgewertet werden. Bei drohenden Problemen können dann rechtzeitig die erforderlichen Maßnahmen eingeleitet werden, um einen Ausfall oder längeren Stillstand der Anlage zu verhindern.

Bereits dabei können entsprechend trainierte KI-Systeme assistieren, vor allem bei der Analyse der Datenflut. Damit vorbeugende Wartung funktioniert, müssen sämtliche relevanten Bewegungen der betrachteten Komponenten erfasst und gespeichert werden, inklusive der dazugehörigen Parameter. Je nach betrachtetem Gerät sind es andere Faktoren, welche einen Einfluss auf die Betriebszuverlässigkeit haben. Bei einem Tor sind das zum Beispiel jedes Öffnen und Schließen, zusammen mit den Aktionen aller dabei involvierten Komponenten, von der Steuerung bis zum Druckzylinder und dem Rollenabrieb.

Der nächste darauf aufbauende Schritt ist dann Prescriptive Maintenance. Aufbauend auf einer Prognose des nächsten Ausfalles werden der Wartungszeitpunkt, das entsprechende Personal und idealerweise auch schon die Ersatzteilerbereitstellung vorausschauend und in einer Schwachlastzeit geplant. Eventuell geht diese Planung so weit, die Parameter des betreffenden Equipments dahingehend zu beeinflussen, dass schadensrelevante Bewegungen nicht mehr mit voller Leistung, sondern möglichst schonend unter optimaler Nutzung der Infrastruktur ausgeführt werden, um nicht vor dem geplanten Wartungstermin einen Ausfall zu provozieren.

Es wäre zudem falsch anzunehmen, dass auf die Sensoren immer Verlass sein muss. Moderne Sensorik und die Verknüpfung der Sensoren lässt fehlerhafte Sensorwerte erkennen und diese durch die KI in Kombination mit anderen Messwerten entsprechend interpolieren. Es muss nicht immer die Maschine sein, es kann auch der Sensor selbst einen Defekt aufweisen, welcher nicht notwendigerweise zu einem geplanten Stillstand führen muss. ■



FAZIT: WIE KÜNSTLICHE INTELLIGENZ DIE WERTSCHÖPFUNGSKETTE VERÄNDERT

Der Einsatz von KI, das lässt sich jetzt schon mit Gewissheit sagen, wird die logistischen Prozesse auf allen Stufen in den kommenden Jahren massiv beeinflussen. Die angeführten Beispiele demonstrieren, in welchem Umfang KI heute bereits in der Logistik eingesetzt wird.

Nach Ansicht vieler Experten werden KI-Technologien vor allem auf die folgenden Bereiche Auswirkungen haben:

- **Produktivität:** KI steigert die Produktivität im Lager deutlich, vor allem bei Online-Retailern durch automatisches Errechnen besserer Lösungen.
- **Kommunikation:** Lagermitarbeiter und Supervisoren müssen zeitnah miteinander kommunizieren, um auf Veränderungen oder Störungen zu reagieren. Vernetzte KI-gesteuerte Roboter gewährleisten eine nahezu zeitgleiche und fehlerfreie Kommunikation und tragen damit zur Produktivitätssteigerung bei.
- **Lagerverwaltung:** Schon in wenigen Jahren werden große Bereiche im Lager komplett automatisiert arbeiten. KI-Technologien werden dabei mehr und mehr zu integralen Bestandteilen, vor allem auch bei kurz- und mittelfristigen Prognosen.
- **Personalkosten:** Effektiverer Einsatz von Personal durch KI-gesteuerte Einsatzplanung führt zu geringeren Personalkosten oder höherer Sicherheit durch Reservenbildungen, beispielsweise für Krankheitsfälle.
- **Robotik:** KI-gesteuerte Roboter verkürzen die Kommissionierzeiten deutlich.
- **Lagerbestand:** KI-Technologien führen zur Reduktion von Lagerbeständen und schnelleren Durchlaufzeiten.

Im Logistics Trend Radar von DHL werden darüber hinaus zwei übergreifende Trends ausgemacht, die durch den Einsatz von KI erst ermöglicht werden:

- **Antizipatorische Logistik:** Die Prognose von Nachfrageentwicklungen hat Auswirkungen auf die gesamte Supply Chain, vom Hersteller, der seine Produktion hochfahren kann, über die Transportunternehmen, die eine entsprechende Anzahl Fahrzeuge bereitstellen können, bis hin zum Handel, der im Vorfeld entsprechende Bestände ordern und lagern und seine Personalplanung darauf einstellen kann. Antizipatorische Logistik ermöglicht zudem das frühzeitige Erkennen von Risiken in der Supply Chain, vom drohenden Ausfall eines Fahrzeugs oder einer Maschine bis hin zu saisonalen Erkrankungswellen mit Auswirkungen auf das Personal.
- **Selbstlernende Systeme:** Machine Learning findet Anwendung beim Lesen handschriftlicher Dokumente (z. B. Brief- oder Paketbeschriftungen) sowie beim Erkennen wiederkehrender Ereignisse im Lager oder bei der Kommissionierung, die dann in bestimmte Kommissionierregeln umgesetzt werden können. Auch die rechtzeitige automatische Nachbestellung von Artikeln in passenden Stückzahlen lässt sich durch selbstlernende Algorithmen optimieren.



Häufig handelt es sich dabei allerdings noch um Insellösungen, die zudem einen hohen Aufwand an Rechenleistung sowie an Programmierung erfordern. Das verlangt große Investitionen in Personal und Technik. Gerade für mittelgroße Unternehmen wird sich der Aufbau einer eigenen KI-Abteilung deshalb nicht rechnen. Allerdings gibt es erfahrene externe Dienstleister, die entsprechende Leistungen erbringen können.

Dabei sollte man nie aus den Augen verlieren, dass in einer integrierten Supply Chain das Lagersystem in der Lage sein muss, auf die Ausgaben der KI zu reagieren, denn sonst erhält man wieder nur eine Stand-alone-Lösung. **Eine schrittweise Integration von KI-Technologien in ein umfassendes und skalierbares Logistiksoftwaresystem scheint daher momentan die beste Strategie zu sein.** So werden Disruptionen weitgehend vermieden und eine stufenweise Erweiterung des Systems um zusätzliche Elemente ist möglich.

Auf diese Weise wird gewährleistet, dass die Kontrolle über das System nicht verloren geht. Und es sollte immer Fallback-Strategien für unvorhersehbare Veränderungen geben. Nur so lässt sich die permanente Funktionsfähigkeit eines Lagers garantieren. ■



WAMAS® Lighthouse von SSI Schäfer ist eine zentrale Informationsplattform, welche die gesamte Supply Chain analysiert und visualisiert. Über verschiedene Dashboards lassen sich nicht nur aktuelle Leistungsdaten der logistischen Anlagen und Prozesse jederzeit abrufen, sondern auch auf Basis von integrierten KI-Algorithmen Szenarios entwerfen und durchspielen.




DER ANSATZ VON SSI SCHÄFER

Insbesondere für die Lagertechnik braucht es eine ganzheitliche Herangehensweise. Obwohl Entwicklungen wie Industrie 4.0 die dezentrale Steuerung als grundlegenden Ansatz haben, müssen sich auch dezentral gesteuerte, also lokale maschinen- oder anlagenbezogene Optimierungsverfahren ins Orchester des ganzheitlichen Ablaufes einordnen und harmonisch aufeinander abstimmen.

Wie geht dies aber, wenn Komponenten oder Teilsysteme von unterschiedlichen Herstellern oder Lieferanten oder Partnern kommen? Welche Restriktionen ergeben sich automatisch, wenn speziell bei Verfahren, die auf Supervised oder Reinforced Learning basieren, das notwendige Feedback wegen Schnittstellen- oder Funktionalitätenproblemen nicht gegeben werden kann? Und nicht zuletzt: Wie effizient kann KI eingesetzt werden, wenn die jeweiligen Ansätze der einzelnen Hersteller/Lieferanten nicht hinreichend bekannt sind, um aufeinander abgestimmt zu werden?

SSI Schäfer offeriert als einziger Intralogistikanbieter die Möglichkeit der horizontalen und vertikalen Integrierbarkeit aller Komponenten und Systemteile als Grundlage für die Umsetzung neuer Technologien: ►



*WMS (Warenmanagement-System), MFR (Materialflussrechner), SPS (speicherprogrammierbare Steuerung)

Diese integrierte Welt aus Hardwarekomponenten und entsprechenden Softwaretools ist eine Grundvoraussetzung, um nicht nur einzelne Maschinen im Warenfluss voneinander lernen zu lassen, sondern auch gleichzeitig durch das Feedback der darüberliegenden Systeme den gemeinsamen Gesamterfolg der intelligenten (lokalen) Steuerungen bewerten zu können.

Damit eröffnet sich auch die Möglichkeit, diese Technologieerweiterung zum gezielten Positionieren der jeweiligen Algorithmen und Ansätze zu nutzen. Die Devise „so viel lokal wie möglich – so wenig zentral wie nötig – alles OHNE Qualitäts- und Performanceverlust“ ist dabei Leitlinie, um entsprechende Forecasting-, Prediction-, Decision- und weitere Entscheidungs(unterstützungs)tools gezielt dort zu positionieren, wo sie am meisten Sinn machen und den größten Nutzen bringen.

Dieser ganzheitliche Ansatz birgt zudem einen Vorteil für den Fall, dass eine KI mit einer gänzlich neuen Situation konfrontiert ist, die sie bis dato noch nie gelernt hatte. Dann kann auf bestehende klassische, validierte und etablierte Strategien aus der WAMAS® Welt für die Entscheidungsfindung zurückgegriffen werden.

Am Ende entscheidet aber trotz aller Technologie der Nutzen für den Kunden im Zuge eines optimalen, flexibleren und dynamischeren Lagerbetriebs über den Erfolg. ■

Impressum

Whitepaper

Künstliche Intelligenz in der Logistik

Herausgeber

SSI SCHÄFER IT Solutions GmbH
Friesachstraße 15
8114 Friesach
Tel. +43 3127 2000
friesach@ssi-schaefer.com

Verantwortlich für den Inhalt

SSI SCHÄFER IT Solutions GmbH
Jacqueline Fauland

Alle Rechte vorbehalten.

Nachdruck nur mit ausdrücklicher

Genehmigung des Herausgebers.

Für Druckfehler keine Haftung.

Quellen

Björn Böttcher, Daniel Klemm, Dr. Carlo Velten, Machine Learning im Unternehmenseinsatz - Ergebnisse einer empirischen Studie in Kooperation mit The unbelievable Machine Company (*um) und Hewlett Packard Enterprise, Crisp Research, Januar 2017 (<https://www.crisp-research.com/neue-studie-machine-learning-im-unternehmenseinsatz-kunstliche-intelligenz-als-grundlage-digitaler-transaktionsprozesse/>) | R. Buchmann, E. Issing, S. Hochrein & M. Bleifuß. The Internet of Things (IoT) within the Intra-logistics Industry, Whitepaper, SSI SCHÄFER 2016 | Ian Goodfellow, Yoshua Bengio, Aaron Courville, Deep Learning, MIT Press, 2016 | McKinsey Global Institute, The age of analytics - Competing in a data-driven world, 2016 (<https://www.mckinsey.com/business-functions/mckinsey-analytics/our-insights/the-age-of-analytics-competing-in-a-data-driven-world>) | Michael Oettinger. Data Science: Eine praxisorientierte Einführung im Umfeld von Machine Learning, künstlicher Intelligenz und Big Data (German Edition), tredition, Kindle-Version. | Calvin Seward, Optimizing Warehouse Operations with Machine Learning on GPUs, 2016 (<https://devblogs.nvidia.com/optimizing-warehouse-operations-machine-learning-gpus/>)
Bildnachweise: S. 3: ©shutterstock, jocic, ©shutterstock, Zerbor | S. 4: ©shutterstock, Tatiana Shepeleva | S. 5: ©shutterstock, Zapp2Photo | S. 15: ©iStock, Chesky_W | S. 16: ©shutterstock, MicroOne