

Whitepaper

Daten, Analytics und Künstliche Intelligenz im Warehouse-Management

Inhalt

Daten und deren Bedeutung in WMS-Systemen	3
Zwei Arten der Datenerhebung in der Intralogistik	4
Generierung statischer Datensätze	5
Generierung von Live-Daten	6
Optimale Nutzung von Daten als zentrale Aufgabe	7
Data Analytics in der Intralogistik	8
Descriptive Analytics – die Aufbereitung von History-Daten	9
Best-Practice-Anwendung – Business-Intelligence mit PROLAG World	10
Predictive Analytics mit Live- und History-Daten im Ressourcenmanagement	11
Best-Practice-Anwendung: Prognosen in der Intralogistik mit PROLAG World	12
Prescriptive Analytics – Datennutzung in der Einlagerung	13
Best Practice Anwendung – Prescriptive Analytics bei der Einlagerung mit PROLAG World	14
Data Analytics mit Künstlicher Intelligenz – eine logische Entwicklung?	15
Herkömmliche Software und Maschinelles Lernen – was ist der Unterschied?	18
Best-Practice KI – Innovation bei CIM: Ortsvorschlag durch Künstliche Intelligenz	20
Künstliche Intelligenz im WMS – immer die beste Wahl?	20
Fazit – Data Analytics im Warehouse-Management	21

Daten und deren Bedeutung in WMS-Systemen

Wie in kaum einer anderen Branche sind Daten die Ursache dafür, weshalb Unternehmen sich früher oder später für eine Warehouse-Management-Software entscheiden. Listensteuerungen oder auch das im ERP-System integrierte WMS bieten ab einer gewissen Komplexität der Intralogistik gar kein oder nur noch ein begrenztes Optimierungspotential. In anderen Worten: Die eingetragenen Daten werden häufig nicht zur Verbesserung der Abläufe in der Intralogistik verwendet. Hersteller von WMS-Systemen werben deshalb mit dem hohen Optimierungspotential, das ihre Software bietet. Solche Potentiale finden sich beispielsweise in der Beschleunigung des Wareneingangs, der Routenfindung oder der Kommissionierreihenfolge. Herausfinden lassen sich diese Potentiale jedoch nur, indem man die Daten der jeweiligen Intralogistik korrekt nutzt.

Grundprämisse des softwaregesteuerten Warehouse-Managements ist folglich die Analyse, Strukturierung und Verwendung von Daten. Um die vorhandenen Daten bestmöglich zu nutzen, greifen Softwarehersteller daher auf Methoden des Data Minings, bzw. der Data Analytics zurück. Die Analyse großer Datenmengen wie beispielsweise Kundendaten oder Prozessdaten dient dazu, brauchbares Wissen zu extrahieren. Data Analytics greifen hierfür unter anderem auf statistische Methoden um Daten zu erkunden, zu visualisieren, zu entdecken und Muster und Trends in den Daten verständlich zu machen.¹ Ziel dabei ist es letztlich, einen Wettbewerbsvorteil für das jeweilige Unternehmen oder dessen Kunden zu generieren.²

¹ Sedkaoui, Soraya. Data Analytics and Big Data, John Wiley & Sons, Incorporated, 2018; S. 44.

² Cleve, Jürgen and Lämmel, Uwe. Data Mining, München: De Gruyter Oldenbourg, 2014; S. 2.

Zwei Arten der Datenerhebung in der Intralogistik

In der Praxis wird daher ein großer Aufwand betrieben, um möglichst exakte und viele Daten über die eigenen Artikel, die Lagerhilfsmittel, die Lagerarten und vieles mehr zu generieren. Dabei unterscheiden wir im Intralogistik-Bereich grob zwischen zwei Arten der Datenerhebung.





Generierung statischer Datensätze

Die erste Form sind statische Daten, die einen Intralogistik-Betrieb digital abbilden. Diese Digitalisierung der Intralogistik ist eine praktische Tätigkeit, die durch die Logistikfachkräfte in analogen Zeiten noch mit Stift und Zettelkasten durchgeführt wurde. Heutzutage nutzt man hierfür gewöhnlich einen Computer, Scanner und ein mobiles Datenerfassungsgerät (MDE), wodurch Artikel und Lagerhilfsmittel digital im WMS abgebildet werden können. Um die Datenqualität und den Workflow zu optimieren, gibt es Anbieter, die diesen Prozess mit eigens dafür ausgelegten Geräten wie Drohnen und Bilderkennungssystemen automatisieren. Die Gesamtheit der generierten Daten bildet schließlich die digitale Form der Intralogistik ab, mit der die Warehouse-Management-Software arbeitet.

Neben dem Lagerlayout und der Lagerphysik bilden den Großteil der Daten die sogenannten Artikel-Stammdaten, in denen unter anderem Informationen über die vorhandenen Lagerhilfsmittel und Artikel abgelegt sind. Dies kann beispielsweise die Beschaffenheit der eingelagerten Artikel betreffen, bestimmte Regeln zur Lagerung und zum Versand, Angaben zur Mindesthaltbarkeit und so weiter.

Grundsätzlich gilt: Je detaillierter die Stammdaten und je aktueller sie sind, desto höher die Datenqualität und desto besser kann die WMS ihr Optimierungspotential entfalten.


Generierung von Live-Daten

Der zweite Bereich der Datenerhebung sind die Live- und History-Daten (dt.: Vergangenheitsdaten), – also Daten, die im laufenden Betrieb der Intralogistik entstehen. Jede Bewegung im Lager wird vom WMS registriert, da die Steuerung dieser Bewegung über das System geht.

Platziert eine Logistikfachkraft beispielsweise einen Artikel im Regalfach, wird dies durch den Barcode-Scan der Software mitgeteilt. Diese und viele weitere Aktivitäten erzeugen Live-Daten aus dem Betrieb, die das System speichert. So zeichnet es auf, wieviel Zeit zur Kommissionierung benötigt wird, wie lange es dauert, bis das Regalfach erreicht wird oder welche Art von Artikel transportiert wird. Durch die Speicherung der Daten entstehen History-Daten mit deren Hilfe die Lagerbewegungen auch im Nachhinein sichtbar gemacht werden können.

WMS-Hersteller können sowohl die Live- als auch History-Daten nutzen, um die Intralogistik zu optimieren. Dies geschieht, indem Zusammenhänge, Cluster und dergleichen gezielt gesucht werden, um daraus Schlüsse zu ziehen und Entscheidungen zu treffen.

Während andere Branchen also erst damit begonnen haben, Daten durch Werbetracker, Kundenbefragungen und dergleichen zu generieren, liegen in den Logistikbetrieben mit professioneller Lagerverwaltung riesige Datenmengen vor. Wie und ob sie genutzt werden, hängt stark von den verwendeten Warehouse-Management-Systemen ab. Die meisten Hersteller von WMS-Systemen verwenden viel Zeit darauf, Logiken zu implementieren, die diese Daten vollumfänglicher und besser nutzen.





Optimale Nutzung von Daten als zentrale Aufgabe

Die Datenanalyse darf somit als eine der zentralen Tätigkeiten der Intralogistik-Software-Hersteller bezeichnet werden. Dieser Umstand wird häufig vergessen, wenn man sich die Herausforderungen ansieht, mit denen viele WMS-Hersteller bei der Implementierung ihrer Systeme konfrontiert sind.

Im Vordergrund stehen meist die Prozesse der jeweiligen Anwender, die in die Software integriert werden müssen oder die an die Software angepasst werden müssen. Auch die Arbeit mit dem System ist ein sehr prägender Faktor, wenn es um die Praxis geht. Die Schnittstelle zwischen Mensch und Software – die Benutzeroberfläche – erfordert oftmals intensive Schulungsmaßnahmen, besonders, wenn das User Interface nicht intuitiv gestaltet ist.

Auch die Digitalisierung und die Übertragung der Lagerdaten ist ein wichtiger Prozess, der im Vordergrund steht und vor Ort aktiv passiert. Dass die dabei gewonnenen Daten das „Gold der Intralogistik“ sind, gerät verständlicherweise auf Anwenderseite gerne aus dem Blick.

Es benötigt ein hohes Maß an Expertise, das Potential der Daten zu erkennen und es ist Aufgabe der WMS-Hersteller, dies zu leisten und in der Software umzusetzen. Im Idealfall bekommen die Anwender dies gar nicht mit.

Data Analytics in der Intralogistik

Das Ziel eines WMS-Systems ist auf Anwenderseite somit eine optimale und flüssig laufende Intralogistik zu erreichen – auf Entwicklerseite bedeutet dies jedoch, möglichst viele Daten zu generieren und vorhandene Daten effektiv zu nutzen.

Schlagworte wie Data Mining, Big Data, Data Science und Data Analytics dominieren zwar nicht das Marketing-Jargon in der Branche, aber sie beschreiben dennoch einen wesentlichen Tätigkeitsbereich. Spricht man von Data Analytics, meint man den Prozess mithilfe von computergestützten Methoden in bestimmter Weise relevante und einflussreiche Muster in Datensätzen sichtbar zu machen und für einen bestimmten Zweck zu verwenden.

Im Folgenden werfen wir einen Blick auf drei Arten der Datennutzung, die in der Intralogistik gängig sind. Dabei handelt es sich um Descriptive, Predictive und Prescriptive Analytics, die anhand von Best-Practice Beispielen erläutert werden.

Zudem gilt es einen Blick auf die verwendeten statistischen Methoden zu werfen und die Frage, was das Ganze eigentlich mit Künstlicher Intelligenz zu tun hat.

Descriptive Analytics – die Aufbereitung von History-Daten

Optimierungsmöglichkeiten in der Intralogistik müssen häufig erst sichtbar gemacht werden, bevor sie umgesetzt werden. Aus diesem Grund greift man auf sogenannte Business-Intelligence-Tools zurück, die dabei unterstützen. Business-Intelligence-Tools helfen bei der Entscheidungsfindung – weshalb sie von Beratungsunternehmen teuer verkauft werden.

Professionelle WMS-Anbieter dagegen haben sie in ihre Software integriert und grafisch so aufbereitet, dass sie im Lager- und Produktionsalltag tatsächlich zu Rate gezogen werden können. Grundlage für die Analysen und Zusammenfassungen solcher Tools sind die in der Intralogistik vorhandenen Daten. Ganz zentral dabei sind die bereits erwähnten History-Daten.³ Diese werden verwendet, um die Systemnutzung zu verbessern oder betriebswirtschaftliche Entscheidungen zu treffen.

Ganz konkret könnten beispielsweise in einer Intralogistik die Leistungskennzahlen der Materialflussdaten in einem Lager analysiert werden – also Durchlaufzeiten, Bestandsveränderungen oder Pickzeiten. Ein Business-Intelligence-Tool greift auf diese gesammelten Daten zu, analysiert sie, stellt sie gegebenenfalls grafisch dar und macht so auf Schwachstellen oder Optimierungspotentiale im Lager aufmerksam.

Diese Form der Datenanalyse nennt sich Descriptive oder Diagnostic Analytics. Sie nutzt Vergangenheitsdaten, um Diagnosen zu stellen und Zustände zu beschreiben. Wichtig dabei ist zu beachten, dass die Diagnose meist nicht vom Tool selbst gestellt wird, sondern von Menschen getroffen wird. Descriptive Analytics helfen dabei, Kennzahlen auf einen Blick zu erfassen und erleichtern so die Entscheidungsfindung.⁴

³ Vgl. Abbot, Dean: Applied Predictive Analytics: Principles and Techniques for the Professional Data Analyst (Wiley, 2014). S. 3. [Predictive Analytics]

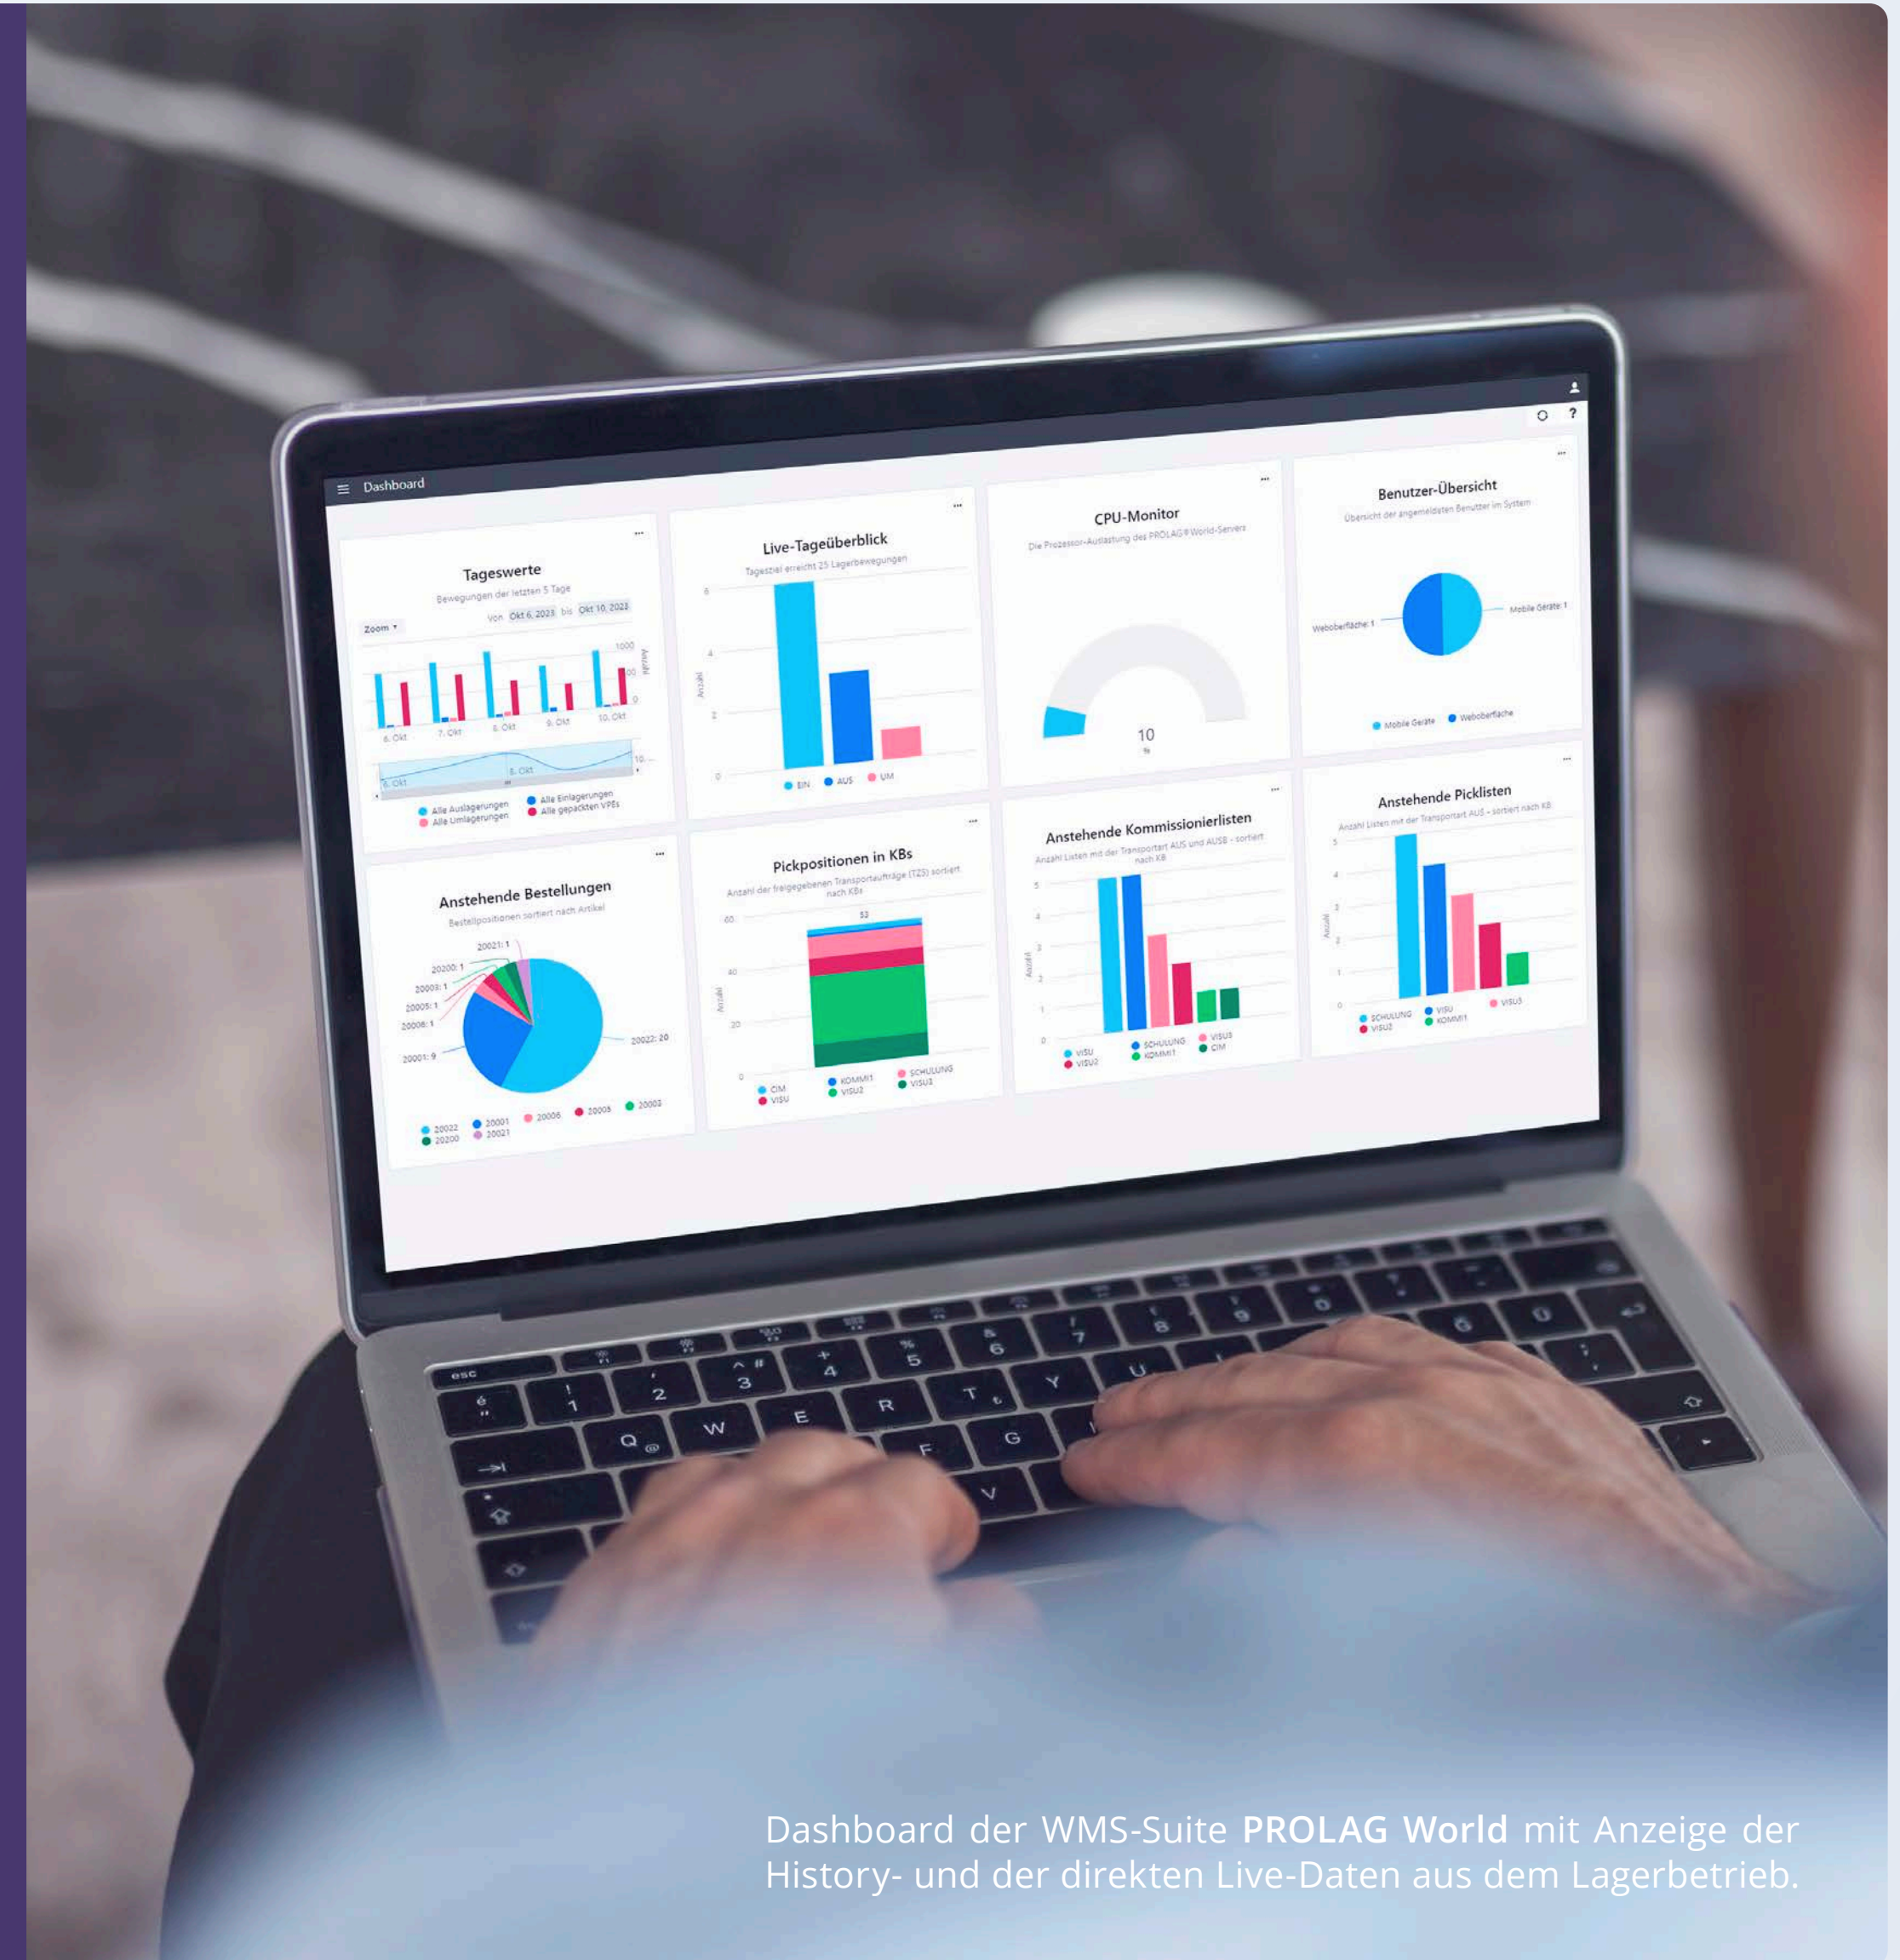
⁴ Möller, Frederik; Hompel, Michael ten (Hg.) e.a.: Bedeutung von Daten im Zeitalter der Digitalisierung (Whitepaper). In: Future Challenges in Logistics and Supply Management, Schriftenreihe des Fraunhofer IML

Best-Practice-Anwendung: Business-Intelligence mit PROLAG World

Die WMS-Suite PROLAG World nutzt nicht nur History-Daten für sein integriertes Business-Intelligence-Tool, sondern im Dashboard können auch die sogenannten Live-Daten direkt aus dem Lagerbetrieb aufbereitet angezeigt werden.

Als besonders wertvoll im Praxisbetrieb hat sich die Personalisierung des Dashboards für jede*n einzelne*n Mitarbeiter*in herausgestellt. Somit können die jeweils tatsächlich relevanten Leistungskennzahlen, Qualitätskennzahlen und Strukturdaten auf einen Blick angezeigt werden und zur Trendanalyse genutzt werden.

Moderne Lagerverwaltungssysteme sind so aufgebaut, dass sie auftragsunabhängige und skalierbare Prozesse im Lager ermöglichen. Das bedeutet, dass sie zumindest über standardisierte Schnittstellen verfügen, um Drittsysteme, wie z. B. einen untergeordneten Materialflussrechner, flexibel anbinden zu können. Noch größere Vorteile für den User bringen Add-ons wie ein integrierter Materialflussrechner. Die IT-Landschaft wird so homogener, Schnittstellen werden vermieden und Fehlerquellen damit eliminiert.



Dashboard der WMS-Suite PROLAG World mit Anzeige der History- und der direkten Live-Daten aus dem Lagerbetrieb.

Predictive Analytics mit Live- und History-Daten im Ressourcenmanagement

In den Predictive Analytics geht es nicht mehr nur darum, vorhandene Daten zu sammeln und aufzubereiten. Ziel ist es hier, eine möglichst akkurate Vorhersage über die mittelbare und unmittelbare Zukunft zu treffen. Eine Anwendung, die auf Predictive Analytics basiert, kumuliert die Häufigkeiten bestimmter in Betracht gezogener Datenpunkte und leitet daraus automatisiert eine Wahrscheinlichkeitsanalyse für die Zukunft ab.⁵

Skaliert auf die Menge an Daten, die im Live-Betrieb einer Intralogistik permanent generiert werden und die vorhanden sind, kann dies nicht mehr einfach durch Menschen gemacht werden. Mittels Predictive Analytics in der Intralogistik können damit beispielsweise die Wahrscheinlichkeiten für hohe Auslastungen an bestimmten Tagen errechnet werden. Grundlage hierfür sind einerseits die bereits erwähnten Vergangenheitsdaten, jedoch können hier auch Live-Daten bereits eine Rolle spielen.

Je nach WMS-Hersteller und Software-Architektur werden unterschiedliche Methoden der Predictive-Analytics eingesetzt. Grundlage ist gewöhnlich ein Algorithmus, der auf Basis bisheriger Daten in der Lage ist, eine Vorhersage über die unmittelbare Zukunft zu treffen. Derartige Logiken sind in fortgeschrittenen WMS-Systemen schon lange zu finden. So wird dies bereits aktiv im Ressourcenmanagement eingesetzt, wo mit Wahrscheinlichkeiten gearbeitet wird.

Auf Basis der Vergangenheitsdaten können die erforderlichen Kapazitäten im Wareneingang für die kommenden Tage und Wochen entsprechend eingeplant werden. Engpässe können dadurch verhindert werden. Auch Saisondaten, die Aufschluss über ein erhöhtes Aufkommen bestimmter Artikel geben, können mittels Predictive Analytics zur Vorhersage verwendet werden.

⁵ Vgl. Predictive Analytics, S. 3ff.

Best-Practice-Anwendung: Prognosen in der Intralogistik mit PROLAG World

Das Lagerverwaltungssystem PROLAG World trackt permanent die Pick- und Kommissionierzeiten, die die Mitarbeiter*innen im Arbeitsalltag benötigen. Die Software nutzt die dadurch generierten Daten, um mithilfe einer hinterlegten Logik unterschiedliche Prognosen zu treffen. So können Vorhersagen über die Kommissionierdauer bestimmter Artikelgruppen schon im Auftragseingang getätigt werden.

Für die Personalplanung und auch für Business-Intelligence-Entscheidungen sind diese Daten von hohem Wert. Insbesondere die Feierabendprognose, die aus diesen Daten errechnet wird, hat für die Schichtplanung im Lager eine hohe praktische Relevanz.

Das permanente Pick- und Kommissionierzeiten-Tracking in PROLAG World trifft unterschiedliche relevante und im Lagerbetrieb äußerst nützliche Prognosen.



Prescriptive Analytics – Datennutzung in der Einlagerung

Eine weitere Form der Verwendung von Daten sind die sogenannten Prescriptive Analytics, also die vorschreibende Analyse. Wie der Name schon suggeriert, soll bei dieser Art der Datennutzung nicht mehr nur ein Zustand beschrieben werden (Descriptive Analytics) oder Vorhergesehen werden (Predictive Analytics), sondern sie soll einen konkreten Handlungsvorschlag ergeben.⁶

Schon diese Zielvorgabe erfordert eine komplexe Logik, die in der Lage ist, mindestens zwei mögliche Entscheidungswege auf Basis eines Dateninputs zu unterscheiden. Die Komplexität des zugrundeliegenden Algorithmus hängt dabei stark vom erforderlichen Leistungsumfang ab. Die verschiedenen Definitionen von Prescriptive Analytics sprechen einerseits von Modellen, die selbst eine Vorhersage treffen und auf dieser Basis eine Entscheidung empfehlen oder sogar selbst durchführen. Diese Modelle erfordern häufig Deep Learning Methoden auf Grundlage von künstlichen neuronalen Netzen, auf die wir später noch eingehen.

Weniger komplexe, aber dennoch anspruchsvolle Lösungen sind beispielsweise sogenannte ABC-Modelle. Diese können von sich aus gewöhnlich keine Vorhersage über die Zukunft treffen. Aber aufgrund definierter Datenpunkte können diese eine erwünschte Entscheidung treffen und deren Ausführung anweisen. Dies ist also im engeren Sinne keine künstliche Intelligenz, sondern die logische Beschreibung zuvor festgelegter Parameter mit Echtzeitdaten.

Es ist wichtig, sich an dieser Stelle den Unterschied in der Methode vor Augen zu führen: Prescriptive Analytics müssen nicht zwangsläufig auf künstliche neuronale Netze zurückgreifen. Häufig sind es menschliche Datenanalysten, die die Parameter für einen Algorithmus definieren, sodass die Logik im Grunde nur das tut, was zuvor bereits festgelegt wurde. Dies ist sowohl mit maschinellen Lernverfahren (das sogenannte Supervised Learning – dt.: überwachtes Lernen) als auch ohne maschinelles Lernverfahren möglich. In beiden Fällen nutzt man die Analyse von Datensätzen für die Entscheidungsfindung.

⁶ Vgl. Cote, Catherine: What is Prescriptive Analytics? 6 Examples.
In: Harvard Business School online. <https://online.hbs.edu/blog/post/prescriptive-analytics>
(Zuletzt aufgerufen am: 11.4.2023).

Best-Practice-Anwendung: Prescriptive Analytics bei der Einlagerung mit PROLAG World

PROLAG World, die Intralogistik-Suite von CIM, verfügt über das Modul der sogenannten ABC-Analyse, die die Einlagerung effizienter gestaltet.

Die ABC-Analyse generiert mithilfe vordefinierter Parameter im Artikelstamm den bestmöglichen Lagerplatz. Vereinfacht erklärt werden Artikel je nach Umschlagfrequenz – ob Langsam- oder Schnelldreher – weiter hinten im Lager an sogenannten C Plätzen oder näher am Kommissionierplatz, den sogenannten A-Plätzen positioniert.

Durch die optimierte Platzierung von Artikeln im Lager, können beispielsweise Wegzeiten erheblich eingespart werden. Durch Datenanalyse lässt sich die ABC-Analyse stets optimieren, indem mithilfe statistischer Methoden die Umschlagzeiten der Artikel regelmäßig automatisch übertragen werden.

Das Modul der sogenannten ABC-Analyse in PROLAG World gestaltet jeden Einlagerungsprozess wesentlich effizienter.

The screenshot displays the 'Artikelstamm' (Article Master) interface in PROLAG World. A table lists various articles with columns for 'Artikelnummer', 'Artikelbeschreibung', 'Artikelgruppe', 'Länge', 'Breite', 'Höhe', 'Zulagern erlaubt', 'Stückvolumen', 'Stückgewicht', and 'Standardmenge'. A modal dialog box titled 'ABC-Analyse ausführen' is open, allowing users to set a 'Beginn' (start date) to 11.12.2017 and an 'Ende' (end date) to 11.10.2023. There is a checkbox for 'Artikel ohne Bestand berücksichtigen' which is checked. The dialog also includes 'Abbrechen' and 'OK' buttons.

Artikelnummer	Artikelbeschreibung	Artikelgruppe	Länge	Breite	Höhe	Zulagern erlaubt	Stückvolumen	Stückgewicht	Standardmenge
10001	Honig im runden Glas	CIM-promotional-item	50,0	45,0	50,0	—	0,1125	105,0	
10002	CIM Imagebroschüre	CIM-promotional-item	300,0	215,0	5,0	—	0,3225	50,0	
10003	CIM-Flyer	CIM-promotional-item	210,0	100,0	1,0	—	0,021	9,0	
10004	CIM-USB Stick 4GB	CIM-promotional-item	56,0	15,0	10,0	—	0,0084	15,0	
10005	Kugelschreiber CIM GmbH...	CIM-promotional-item	140,0	15,0	10,0	—	0,021	12,0	
10006	Block kariert, CIM GmbH, ...	CIM-promotional-item	297,0	210,0	3,0	—	0,1871	140,0	
10007	Tasse groß mit CIM-Logo	CIM-promotional-item				—	1,17	331,0	
10008	Untertasse groß	CIM-promotional-item				—	0,4594	295,0	
10009	Honig im runden Glas	CIM-promotional-item				—	0,1125	105,0	
10010	Spezialanfertigung	CIM-promotional-item				—	0,1125	105,0	
10011	Artikel für Produktion	CIM-promotional-item				—	0,1125	105,0	
10012	Honig im runden Glas - S...	CIM-promotional-item				—	0,1575	145,0	
10013	Honig im runden Glas - S...	CIM-promotional-item				—	0,11	95,0	
10014	Honig im runden Glas - kl...	CIM-promotional-item				—	0,05	45,0	
10021	Notzblock, mit CIM-Logo	CIM-promotional-item				—	0,1125	105,0	
10022	Turnbeutel grau, mit CIM-...	CIM-promotional-item				—	0,3225	50,0	
10023	CIM-Flyer	CIM-promotional-item	210,0	100,0	1,0	—	0,021	9,0	
10024	Ansteck-Button CIM-Logo	CIM-promotional-item	40,0	40,0	5,0	—	0,008	15,0	
10025	Kugelschreiber, mit CIM-L...	CIM-promotional-item	140,0	15,0	10,0	—	0,021	12,0	
10026	Flowerballs	CIM-promotional-item	40,0	22,0	60,0	—	52,8	45,0	
20001	Cornflakes	Lebensmittel	24,1	16,1	8,2	✓	3,1817	0,75	
20002	Cornflakes - NBV	Lebensmittel	24,1	16,1	8,2	✓	3,1817	0,75	
20003	Honig - MHD	Lebensmittel	50,0	45,0	50,0	✓	3,1817	0,75	
20004	Cornflakes - mit Prüfvorsc...	Lebensmittel	24,1	16,1	8,2	✓	3,1817	0,75	
20005	Tasse groß - Chargenartikel		130,0	100,0	90,0	—	1,17	331,0	
20006	Waschmaschine - Serienn...	Elektro	60,5	60,4	95,8	—	350,0724	14,3	
20007	MP3-Player - Seriennum...	Elektro	10,1	8,1	2,1	—	2,2956	1,2	

Data Analytics mit Künstlicher Intelligenz – eine logische Entwicklung?

Spricht man von Data Mining oder Data Analytics ist heutzutage häufig die Nutzung künstlicher Intelligenz impliziert.⁷ Dies hat maßgeblich damit zu tun, dass Methoden maschinellen Lernens bei hohen Datenmengen (Big Data) und klar definierten Parametern in den Data Analytics bekanntermaßen vielversprechende Ergebnisse erzeugen können.

Mit dem Launch großer Sprachmodelle (LLM) durch amerikanische IT-Konzerne, hat sich in der medialen Berichterstattung zudem der Eindruck verfestigt, dass Künstliche Intelligenz jetzt für den Einsatz in allen Bereichen bereit ist. Denn unabhängig von der Anwendung, hat Künstliche Intelligenz grundsätzlich immer den gleichen

Ausgangspunkt: Sie dient einzig dem Zweck, unüberschaubar große Datenmengen selbstständig zu analysieren, Schlüsse daraus zu ziehen, Vorhersagen zu machen und Entscheidungen zu treffen.

Kurz: Sie macht all das, was bereits im vorigen Teil des vorliegenden Whitepapers angesprochen wurde und nach wie vor häufig durch sogenannte Data Analysten umgesetzt wird.

Im Intralogistik-Bereich wird nun oftmals die Erwartung geäußert, dass eine KI die Daten aus der Intralogistik schneller durchforstet und dabei mehr und unwahrscheinlichere Zusammenhänge findet, als dies ein Mensch tun würde.⁸

⁷ Vgl. Whitepaper Daten, S. 14

⁸ Vgl. Whitepaper IML KI in der Logistik

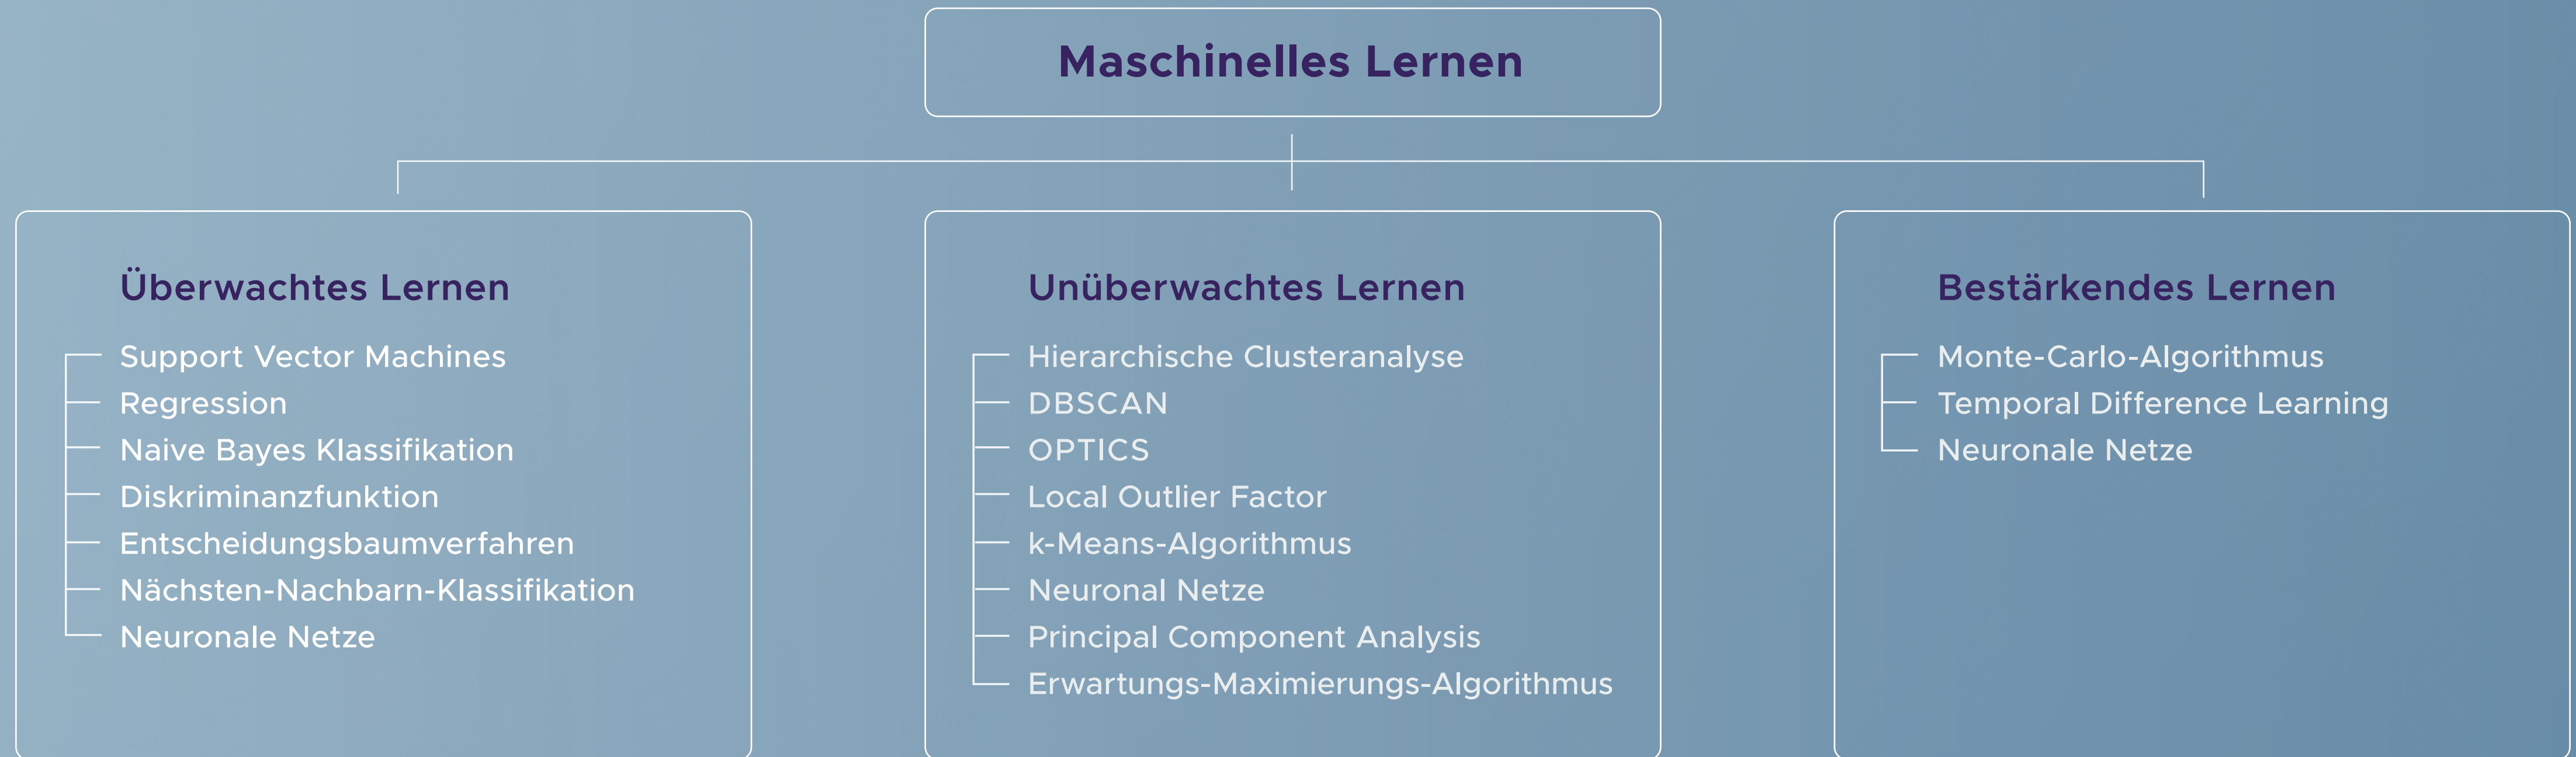



Abbildung 1: Eine Übersicht über die Methoden maschinellen Lernens.
Quelle: KI in der Logistik, Fraunhofer IML; S. 8.

[Erläuterung Schaubild: Die Methoden maschinellen Lernens werden häufig auf künstliche neuronale Netze reduziert, beschränken sich jedoch nicht darauf. Algorithmen, die beispielsweise auf linearer Regression basieren, werden ebenfalls auch zum Maschinellen Lernen gerechnet. Anders als Neuronale Netze werden sie jedoch nur für ein Verfahren des Maschinellen Lernens verwendet, dem sogenannten Überwachten Lernen. Neuronale Netze dagegen verwendet man zusätzlich noch für sogenanntes Unüberwachtes Lernen und Bestärkendes Lernen (Reinforcement Learning), weshalb sie die wohl bekannteste Form maschinellen Lernens sind.^{9]}


⁹ Vgl. Whitepaper KI – Künstliche Intelligenz in der Logistik S. 5–8; siehe auch u.a.: IWML Report 06.2023: Daten. Das Gold des 21. Jahrhunderts; Seite 23. [Whitepaper KI]



Im Intralogistik-Bereich sind die Methoden Künstlicher Intelligenz, wie beispielsweise Deep Learning mithilfe Künstlicher Neuronaler Netze, nach wie vor kaum in Verwendung.¹⁰ Dies hat mutmaßlich nicht nur mit der technologischen Hürde und dem Know How zu tun, das bei der Entwicklung von Neuronalen Netzen und ähnlichen Methoden nötig ist. Eine weitere Hürde könnte sein, dass die zum Training benötigten Lagerdaten nicht milliardenfach im Internet vorhanden sind. Dennoch gelten Deep-Learning und Maschinelles Lernen als wichtigster Entwicklungsschwerpunkt für die kommenden Jahre.¹¹

¹⁰ Vgl. Fraunhofer-Institut für Materialfluss und Logistik IML: WMS Marktreport Kompakt 2022. Trends und Entwicklungen auf dem Markt für Warehouse-Management-Systeme, S. 22, 33. [WMS Marktreport] 06.2023: Daten. Das Gold des 21. Jahrhunderts; Seite 23. [Whitepaper KI]

¹¹ WMS-Marktreport, S. 33.



Herkömmliche Software und Maschinelles Lernen – was ist der Unterschied?


Unabhängig davon welches Ziel mit dem Maschinellen Lernverfahren verbunden ist und mit welcher Methode es erreicht wird, ist ein zentrales Unterscheidungsmerkmal zwischen herkömmlichen Algorithmen und Methoden Künstlicher Intelligenz festzuhalten.

Herkömmliche Software erzeugt seine Ausgabe durch eine im Algorithmus hinterlegte Logik, die auf Basis der eingegebenen Daten eine Entscheidung trifft. Je nach verwendetem Algorithmus können auch statistische Methoden und Häufigkeiten die Berechnungsgrundlage sein.

Tatsache aber ist, dass ein Algorithmus zuvor von einem Menschen entwickelt wird. Wie schon oben beschrieben, ist hierfür eine Datenanalyse notwendig, auf deren Basis ein Analyst beispielsweise Schlussfolgerungen für Lagerstrategien oder Wegeoptimierungen zieht. Aus den gewonnenen Erkenntnissen über die Datenlage wird dann der Algorithmus formuliert, der die beobachteten Patterns nutzt und das gewünschte Ziel umsetzt.¹² >

¹² Vgl. Whitepaper KI, S. 4ff.

Herkömmliche Software



> Methoden Künstlicher Intelligenz, insbesondere Künstliche Neuronale Netze, sind in der Lage, diesen Prozess selbst zu übernehmen. Die Vorgehensweise ist hier dementsprechend umgekehrt: Datenanalysten übergeben dem Neuronalen Netz oder einer anderen Methode Maschinellen Lernens aufbereitete Daten, die die KI analysiert und mit denen sie eine Ausgabe, einen „Output“, erzeugt.

Durch sogenannte Belohnungskonzepte mit einer zugrunde liegenden Kostenfunktion lernt die KI, ob der Output ein wünschenswertes oder weniger wünschenswertes Ergebnis erzeugt hat. Entsprechend passt sie die Grundlage der Entscheidung an – also die dahinter liegende Logik. Folglich ist der Algorithmus das Ergebnis dieses Lernprozesses.

Durch die riesige Menge an Daten, die eine KI zum Training verwendet, findet sie möglicherweise andere Zusammenhänge zwischen den einzelnen Daten, mit denen sie bessere Ergebnisse erreicht. Entsprechend wenig vorhersehbar ist die Logik, auf deren Basis die KI ihren Algorithmus entwickelt.

Maschinelles Lernen




Abbildung 2: Unterschied zwischen herkömmlicher Software und Maschinellem Lernen.
Quelle: KI in der Logistik, Fraunhofer IML, S. 5

Best-Practice KI:

Intelligente Einlagerungsstrategien durch Künstliche Intelligenz

Als Ergebnis einer zweijährigen Forschungs Kooperation führt CIM als Marktneuheit das Modul „Ortsvorschlag durch KI“ in seiner Software PROLAG World ein. Das Feature bietet komplexen Intralogistik-Betrieben einen hohen Optimierungsfaktor, da es automatisiert einem Artikel den idealen Standort zuweist. Ein Eingriff in die Stammdaten ist hierfür nicht nötig. Durch das Training mit den Live- und History-Daten des jeweiligen Lagers ist das KI-Modul in der Lage, selbst einen Standort je nach Umschlagshäufigkeit ideal zu positionieren, sodass im Warenausgang die Wege messbar reduziert werden. Logistikbetriebe erreichen so Bestzeiten bei der Auslagerung. Diese Optimierung beschleunigt den Warenausgang, reduziert Wegzeiten, spart Energie und kann durch die bessere Auslastung Personalkosten reduzieren.

Tipps für KI in der Intralogistik:

- Die Wirtschaftlichkeit des Trainings für das KI-Modul steigt mit der Leistungsfähigkeit der Intralogistik.
- Komplexe Artikelstrukturen versprechen ein besseres Ergebnis bei der Wahl der Einlagerungsstrategie durch KI. Das KI-Modul entdeckt durch das Training Zusammenhänge, die menschlichen Data Analysts entgehen.
- Je mehr Daten, desto besser die KI: Große Intralogistikbetriebe können leichter bessere Ergebnisse mit einem KI-Modul erreichen.
- Ist Künstliche Intelligenz immer die beste Wahl? Nehmen Sie Kontakt zu den Experten von CIM auf. Sie stehen Ihnen mit Rat und Tat zur Seite und helfen dabei, Ihre Fragen zu beantworten.

Fazit

Es geht nicht ohne Daten – das ist die zentrale Erkenntnis, die die Betrachtungen über die Data Analytics in der Intralogistik gebracht hat. Während Daten in anderen Bereichen als „Gold“ bezeichnet werden, sind sie schlicht der Daseinsgrund für WMS-Systeme.

Dabei zeichnet sich die Güte des WMS-Systems durch die Qualität der Datennutzung aus. Denn je besser die vorhandenen Daten über die Intralogistik genutzt werden, desto größer sind die Optimierungspotentiale. Optimierte Wege, durchdachte Einlagerungsstrategien und ein verbesserter Warenausgang lassen sich mithilfe der drei großen Analytics-Methoden realisieren. Descriptive, Predictive und Prescriptive Data Analytics sind die drei Teilbereiche der Datenanalyse, die sich in der Intralogistik wiederfinden. Diese sind zentrale Methoden für Business-Intelligence-Tools, Entscheidungshilfen und gewisse Automaten, die das WMS selbstständig durchführen kann.

Die Best-Practice-Anwendungen, die das WMS **PROLAG World** zeigt, machen deutlich, wie vielfältig Data Analytics in der Intralogistik zum Wirken kommen. Zugleich lernen wir, dass eine professionelle Datenanalyse zahlreiche Potentiale freilegen kann, die die Intralogistik optimieren.

Mithilfe des KI-Moduls in **PROLAG World**, das selbstständig eine intelligente Einlagerungsstrategie entwickelt, können insbesondere Betriebe mit einer komplexen Artikelstrukturen das Optimierungspotential ihrer Intralogistik auf ein neues Level bringen. Die Betrachtungen in diesem Whitepaper haben auch aufgezeigt, dass Künstliche Intelligenz in der Intralogistik-Steuerung keinen disruptiven, also zerstörerischen Charakter hat. Ihr Einsatz ist vielmehr das Ergebnis eines schon seit Jahren andauernden technologischen Trends, der durch die Nutzung von KI weiter verstärkt wird: Die Datenanalyse zur Optimierung von Intralogistik-Prozessen auf höchstem Niveau.

CIM GmbH
Livry-Gargan-Straße 10
82256 Fürstenfeldbruck

☎ +49 8141 5102-0
@ info@cim.de

CIM GmbH
Niederlassung Münster
Wolbecker Windmühle 67
48167 Münster

☎ +49 2506 30615-0
@ info@cim.de

CIM GmbH
Niederlassung Niederlande
Prinses Margrietplantsoen 33
2595 AM Den Haag

☎ +31 (0) 70 450 002-0
@ info@cim-logistics.nl

FOLLOW US

