

Entwurf eines Reifegradmodells zur Integration von Business Analytics im Bestandsmanagement

^aMatthias Brüggelolte, ^bMarkus Stute, ^{a,b}Christoph Besenfelder

^aLehrstuhl für Unternehmenslogistik, Fakultät Maschinenbau, TU Dortmund

^bFraunhofer-Institut für Materialfluss und Logistik, Dortmund

Die volatilen Geschäftsumgebungen von produzierenden Unternehmen stellen besondere Anforderungen an das Bestandsmanagement und verlangen fundierte und schnelle Entscheidungen der Unternehmen. Essentiell hierfür ist der Einsatz von Big Data und Business Analytics zu Analyse- und Prognosezwecken und zur Grundlage für letztlich autonome Entscheidungen. In dieser Arbeit wird ein Reifegradmodell entwickelt, das auf wichtigen technologischen, personellen und prozessualen Voraussetzungen für den Einsatz von Business Analytics basiert und produzierenden Unternehmen zur Bewertung und Weiterentwicklung ihres Bestandsmanagements dient.

The volatile business environments of manufacturing companies demand special requirements for the inventory management and require flexible and fast decisions of the companies. The application of Big Data and Business Analytics for analysis and forecasting purposes and to derive automated and ultimately autonomous decisions is essential for this task. This paper presents a maturity model based on important technological, personnel and process requirements for the application of Business Analytics and serves manufacturing companies to evaluate and improve their inventory management using Business Analytics.

[Schlüsselwörter: Bestandsmanagement, Big Data, Business Analytics, Reifegradmodell, Vorgehensmodell]

1 RELEVANZ VON BUSINESS ANALYTICS IM BESTANDSMANAGEMENT

Produzierende Unternehmen agieren heutzutage in einem globalen und dynamischen Geschäftsumfeld, das von stetigem Wandel und Unsicherheit hinsichtlich der Kundenbedürfnisse, einer verringerten Fertigungstiefe und weltweit konkurrierenden Zulieferernetzwerken geprägt ist. Die volatile Unternehmensumgebung stellt besondere Anforderungen an das Bestandsmanagement und verlangt fundierte und schnelle Entscheidungen der Unternehmen in diesem Bereich. Demzufolge nimmt die Relevanz des Bestandsmanagements als Querschnittsfunktion immer stärker zu.

Um richtige Entscheidungen hinsichtlich des Bestandsmanagements ableiten zu können, müssen hierfür be-

standsdeterminierende Daten beschafft, aufbereitet und genutzt werden. Aufgrund der angesprochenen Beschaffungs- und Nachfrageunsicherheiten, sind auf diesen Daten aufbauende, möglichst genaue Wiederbeschaffungszeit- und Nachfrageprognosen und Prognosemodelle für die Beschaffung von besonderer Bedeutung. Für ein effizientes Bestandsmanagement ist sowohl ein Kooperations- und Kollaborationsmanagement entlang der Supply Chain wie auch der vermehrte IT-Einsatz in Form von Big Data und Business Analytics notwendig.

Aufbauend auf den Einsatzmöglichkeiten von Business Analytics, insbesondere Predictive und Prescriptive Analytics, für das Bestandsmanagement in den drei Bereichen Beschaffung, Produktion und Nachfrageprognosen (Endkundennachfrage), wird nachfolgend ein Entwurf eines Reifegradmodells zur Integration von Business Analytics im Bestandsmanagement entwickelt. Das Reifegradmodell dient der Bewertung und Weiterentwicklung des Bestandsmanagements produzierender Unternehmen mithilfe des Einsatzes von Big Data und Business Analytics. Darüber hinaus wird ein Vorgehen zur Anwendung des Reifegradmodells im Unternehmen aufgezeigt.

2 KONZEPTIONELLE GRUNDLAGEN

2.1 BESTANDSMANAGEMENT

Das Bestandsmanagement dient als Querschnittsfunktion über alle Funktionsbereiche der Unternehmenslogistik. Diese Definition beschreibt das Bestandsmanagement aus unternehmensinterner Sicht. In der Praxis „bilden [...] mehrstufige logistische Systeme die Regel“ [Ij08]. Die Logistiknetze sind in der Regel unternehmensübergreifend, womit das Bestandsmanagement eine zentrale Aufgabe im Supply Chain Management ist.

Die Koordination der operativen Funktionen hinsichtlich des Bestandsmanagements entlang der gesamten Supply Chain führt zu besonderen Herausforderungen. Eine wesentliche Herausforderung sind die stochastischen Schwankungen der Liefer- bzw. Wiederbeschaffungszeiten, der externen Beschaffungsaufträge sowie die interne Durchlaufzeit der Produktionsaufträge, wodurch hohe Unsicherheiten in der Planung von Beständen resultieren. [Sch81; Sch07; Tem15]

Ausgangspunkt für das Bestandsmanagement sind Nachfrageprognosen, die als „Abschätzung des zukünftigen Bedarfs“ [Sch07] dienen und „für die Prognose der Nachfragemenge in der Wiederbeschaffungszeit eingesetzt“ [Tem15] werden. Da Prognosen „nahezu immer falsch“ [Bre10] sind, ergibt sich oftmals eine Fehleinschätzung bezüglich der realen Nachfrage. Diese Fehleinschätzung ist definiert durch den Vorhersage- bzw. Prognosefehler, der die Differenz zwischen der Nachfrage und der Vorhersage darstellt [Sch07]. Auf Basis der immer komplexer werdenden Unternehmens- und Supply Chain-Strukturen steigen gleichzeitig Intransparenz sowie die Anzahl der Einflussfaktoren auf das Bestandsmanagement [Bes+17]. Weiterhin fallen in diesem Kontext immer größere Datenmengen an [IDC14]. Um möglichst genaue Nachfrageprognosen zu erstellen und um richtige Entscheidungen hinsichtlich des Bestandsmanagements ableiten zu können, müssen in diesen großen Datenmengen die relevanten Daten erkannt, beschafft und analysiert werden [Iff+16]. Aufgrund der angesprochenen Beschaffungs- und Nachfrageunsicherheiten, sind auf diesen Daten aufbauende, möglichst genaue Nachfrageprognosen und Prognosemodelle für die Beschaffung von besonderer Bedeutung. Folglich ist sowohl ein Kooperations- und Kollaborationsmanagement entlang der Supply Chain als auch der vermehrte IT-Einsatz in Form von Big Data und Business Analytics notwendig. [IBM12; Nai15; Wan+16]

2.2 BIG DATA UND BIG DATA ANALYTICS

Der Begriff Big Data bezeichnet große Datenmengen, deren Erfassung, Speicherung und Analyse die konventionelle Hard- und Softwareumgebungen übersteigen [Man+11; Mer11; San14]. Die Definitionen von Big Data fokussieren die drei zentralen Charakteristiken, die aufgrund ihrer Anfangsbuchstaben auch als die 3 V's bezeichnet werden: *Volume*, *Velocity* und *Variety* [Lan01].

Die erste Eigenschaft *Volume* betrifft die großen Datenmengen. Diese können durch die Möglichkeit und Notwendigkeit der Unternehmen begründet werden, kontinuierlich immer mehr relevante Daten außerhalb der konventionellen Datenquellen aufzunehmen, zu speichern und daraus neue Analysemöglichkeiten zu generieren [KD15].

Die zweite Charakteristik *Velocity* bezieht sich auf die Geschwindigkeit der Daten. Aus den Entwicklungen im Rahmen von Big Data resultieren Datenmengen, die sich immer schneller verändern [Fin14]. Dadurch entsteht die Notwendigkeit Methoden zu entwickeln, die mit extrem skalierbaren Geschwindigkeiten sehr volatile Datenmengen verarbeiten können [Kri13].

Die dritte Eigenschaft *Variety* bezeichnet die Vielfalt der Daten. Diese bezieht sich auf die unterschiedlichen Werttypen (numerisch, kategorisch) und die Datenformate

(z.B. Audio, Video) [KD15]. Hierbei werden auch strukturierte und unstrukturierte (z.B. Multimedia-Daten wie Text, Grafik oder Audio) Daten abgegrenzt [FM16; Fin14].

Um eine optimale Nutzung aller relevanten Daten zu gewährleisten und somit die Potenziale von Big Data ausnutzen zu können, müssen Unternehmen zunehmend Informationen aus mehreren Datenquellen integrieren [Man+11; MMT15]. Eine schnelle Verfügbarkeit dieser Daten ist hierfür besonders wichtig [MMT15].

Die Datenqualität ist eine weitere Schlüsselkomponente beim Einsatz von Big Data, da sie einen wichtigen Einfluss auf die Qualität der Bestandsentscheidungen hat [MMT15; Mor15]. Um uneinheitliche Datenquellen zusammenzubringen und die Datenqualität sicherzustellen, setzen Unternehmen Techniken zur Datenintegration, -aufbereitung und -transformation ein und sammeln die aufbereiteten Daten anschließend in einer unternehmensweiten physischen Datenbank (Data Warehouse) [GP17; KD15; LB11]. Der Prozess des Data Warehousing ist ein Treiber von Data Mining und ein Schlüssel für den erfolgreichen Einsatz von Advanced bzw. Big Data Analytics in Organisationen [Bos09; LB11].

Data Mining

Data Mining bezeichnet die Analyse von großen und komplexen Datenmengen [Fin14]. Der Fokus von Data Mining liegt auf der automatischen Entdeckung von Wirkzusammenhängen, Mustern, Strukturen und Trends, um aufschlussreiche und aussagekräftige Ergebnisse zu generieren [Bos09; KD15; LL15; Man+11]. Die angewendeten computergestützten Methoden kommen aus den Bereichen der Statistik, des maschinellen Lernens und der künstlichen Intelligenz [KD15]. Die gängigsten Bereiche des Data Mining sind die folgenden [KD15; LL15]:

- Association: Entdeckung von Regeln für die Beziehungen zwischen zwei oder mehreren Attributen
- Classification: Vorhersage, ob ein Datenpunkt zu einer vordefinierten Klasse gehört
- Clustering: Identifikation von Clustern auf Basis von Eigenschaften der Daten
- Prediction: Vorhersage eines numerischen Wertes für eine Zielvariable auf Basis von numerischen oder kategorischen Prädiktorvariablen

Im Zusammenhang mit Analysen von Big Data wird häufig auch von Advanced oder Big Data Analytics gesprochen [LB11; San14]. Diese können als Kombination von traditioneller Analytik und Data Mining Techniken zur Analyse von großen Datenmengen definiert werden [Kri13].

Business Intelligence & Business Analytics

Business Intelligence steht für „das Integrieren von Strategien, Prozessen und Applikationen, um aus [...] Daten [...] Wissen über Potenziale und Perspektiven des Unternehmens zu erzeugen“ [GP17]. Ziel dieses Wissens ist es, bessere unternehmerische Entscheidungen zu treffen und somit die Leistung eines Unternehmens zu verbessern [Bos09; Gro15].

Der Begriff Business Analytics beschreibt Techniken zur Sammlung, Aufbereitung und Interpretation von Daten, um aussagekräftige Informationen aus diesen abzuleiten [Dek16]. Business Analytics umfasst Business Intelligence sowie Advanced bzw. Big Data Analytics [Shm+18].

Die Business Analytics Techniken können in die drei Entwicklungsstufen Descriptive, Predictive und Prescriptive Analytics unterteilt werden [Dek16; Sou14]. Zusätzlich hierzu ist die Entwicklungsstufe der Diagnostic Analytics in der Literatur zu finden [Lan12]. Mit fortschreitender Entwicklungsstufe der Business Analytics steigt die Schwierigkeit des Einsatzes, aber auch der Wert, den die Ergebnisse liefern [Lan12].

Descriptive Analytics dienen als kompakte, vergangenheitsbezogene Zusammenfassung oder Darstellung der Datenstruktur [Gro15; Shm10]. Die Diagnostic Analytics suchen auf Basis historischer Daten nach Erklärungen für die Unternehmensabläufe und bieten somit einen tieferen Einblick in die Daten [Lan12].

Predictive Analytics stellen vorausschauende Analysen dar [Sou14]. Die zentrale Aufgabe besteht darin, Zusammenhänge zwischen erklärenden Variablen und den vorherzusagenden Variablen aus vergangenen Ereignissen zu erfassen und diese zur Vorhersage von unbekanntem, zukünftigen Ergebnissen zu nutzen [Ber17]. Demnach ist Predictive Analytics ein Begriff zur Beschreibung der Anwendung von Data Mining auf vorausschauende Problemstellungen [Fin14].

Prescriptive Analytics bilden die letzte Phase des entwickelten Reifegradmodells dar und leiten „Entscheidungsoptionen [ab], um zukünftige Vorteile zu nutzen oder um Risiken zu minimieren“ [Gro15]. Prescriptive Analytics umfassen vor allem Optimierungs- und Simulationsmodelle [Wan+16].

Business Analytics sind ein unverzichtbares Werkzeug für Supply Chain Entscheidungen in volatilen Umgebungen [Bla+15]. Dies ist vor allem durch die folgenden drei Faktoren zu begründen [Bla+15; Cla16]:

1. Verfügbarkeit von Daten in der wachsenden Big Data Umgebung (Datenflut)
2. Einbezug von sowohl endogenen Daten als auch einer Vielzahl exogener Daten und die Nutzung

dieser durch eine fundierte Mustererkennung für Analyse- und Prognosezwecke

3. Fortschritte in der IT-Technologie

Im Rahmen des Bestandsmanagements kann Business Analytics produzierende Unternehmen unterstützen, die richtige Balance zwischen den für das Bestandsmanagement relevanten Kostenarten (Bestell-, Lagerhaltungs- und Fehlmengenkosten) zu finden [IBM12].

Aufgrund von möglichen Liefer- und Nachfrageunsicherheiten sind insbesondere Predictive Analytics ein wichtiges Tool, um die Transparenz und Flexibilität der Supply Chain zu verbessern [Wan+16] und demzufolge kurzfristig fundierte Entscheidungen im Bestandsmanagement zu treffen. Prescriptive Analytics sind darüber hinaus in der Lage, Vorschläge für Entscheidungsoptionen (Bestandsoptimierung, Disposition, Scheduling, Lieferantenauswahl) abzuleiten [Çel15; RPG09; Tal+13].

Die Einführung und Verbesserung von Business Analytics in Zusammenhang mit Big Data stellt eine große Herausforderung dar [Kri13; Sat12]. Die Anwendung von Reifegradmodellen ist daher sinnvoll, um ein besseres Verständnis für den Zielzustand der Unternehmensprozesse und -organisation zu entwickeln und diesen in Teilschritte zu unterteilen [Mor15; Sat12]. Da Business Analytics eine zentrale Möglichkeit zur Verbesserung des Bestandsmanagements bieten, wird nachfolgend ein Reifegradmodell entwickelt, das zur Integration von Business Analytics im Bestandsmanagement eingesetzt werden kann.

3 REIFEGRADMODELL ZUR INTEGRATION VON BUSINESS ANALYTICS IM BESTANDSMANAGEMENT

Ziel des entwickelten Reifegradmodells ist, dass produzierende Unternehmen die IST-Situation ihres Bestandsmanagements bewerten (IST-Reifegradbewertung) und darauf aufbauend ihr Bestandsmanagement durch die Integration und die Weiterentwicklung von Business Analytics verbessern können (Reifegradsteigerung).

Dimensionen des Reifegradmodells

Das Reifegradmodell besteht aus den drei aufeinander aufbauenden Dimensionen *Daten*, *Analytics* und *Organisation*. Diese stellen die zentralen Säulen für die Integration von Business Analytics im Bestandsmanagement dar. Die drei Dimensionen dürfen nicht isoliert voneinander betrachtet werden, sondern sind von wichtigen Abhängigkeiten geprägt.

Die Gesamtreifegradbewertung ist in der Abbildung 1 entsprechend der drei Dimensionen dargestellt. Jede Dimension besteht aus mindestens einem Kriterium, das jeweils auf einer Punkteskala von 0 bis 10 Punkten bewertet wird. Die Gesamtbewertung der jeweiligen Dimension

ergibt sich aus dem Durchschnitt der Bewertungen der einzelnen Kriterien. Nachdem der IST-Reifegrad des Unternehmens festgestellt wurde, kann ein SOLL-Reifegrad bestimmt werden (siehe Vorgehen zum Reifegradmodell).

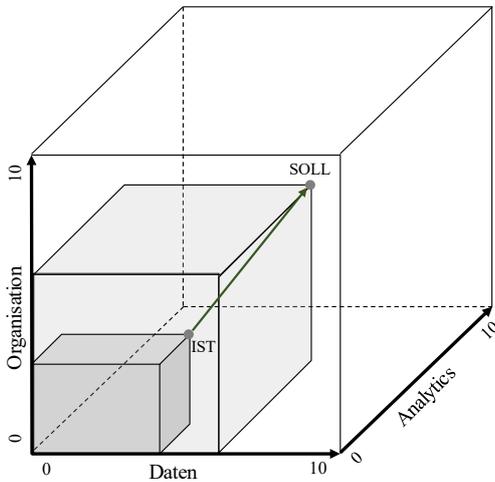


Abbildung 1: Dimensionen des Reifegradmodells

Nachfolgend werden die drei Dimensionen und ihre Kriterien näher erläutert.

3.1 DIMENSION: DATEN

Daten sind für das Bestandsmanagement und den Einsatz von Business Analytics von zentraler Bedeutung und stellen daher die erste Dimension des Reifegradmodells dar. Die Reifegradbewertung hinsichtlich der Dimension Daten basiert auf den drei Kriterien *3V's*, *Datenqualität* und *Datenmanagement*. Aufgrund der Wichtigkeit für die Ergebnisse der folgenden Datenanalysen stellt die Datenqualität ein eigenständiges Kriterium dar. Das Kriterium Datenmanagement beschreibt die Integration von Big Data (*3V's*) aus unterschiedlichen Quellen, die Vereinheitlichung der Daten sowie die Qualität der Daten gegebenenfalls zu steigern.

3 V's

Das Kriterium *3V's* bewertet die für das Bestandsmanagement genutzte Datenmenge (Volume), die Geschwindigkeit (Velocity) und Vielfalt bzw. Struktur (Variety) der Daten. Ein effizientes Bestandsmanagement setzt grundsätzlich die Integration und Verfügbarkeit zahlreicher Daten aus unternehmensinternen und -externen Quellen voraus. Für eine hohe Prognosegenauigkeit der Kundennachfrage sind neben dem aktuellen Kundenkaufverhalten interne Variablen (z.B. Nachfragemengen für ähnliche Produkte, Preisgestaltung), externe Wirtschaftsindikatoren (Markt- und Wettbewerbsinformationen), Wetterdaten oder Informationen aus Social Media in die Prognosemodelle miteinzubeziehen [Bla+15; Cha16; IBM12; Leh16; MMT15].

Für eine bessere Vorhersage und eine Reduzierung von Wiederbeschaffungszeiten sind auf Beschaffungsseite neben Daten zur Lieferantenperformance exogene Unsicherheiten (diskrete Ereignisse und kontinuierliche Beschaffungsrisiken) für das Bestandsmanagement von Relevanz [San14; Sou14; TM09]. Vernetzte Sensoren und maschinengenerierte Daten schaffen zusätzlich ein besseres Verständnis für die unternehmensinternen Durchlaufzeiten, was sich sowohl auf die Produktions- als auch auf die Lagerbestände positiv auswirkt [Luo+17; SR17; Wan+16].

Für eine hohe Reifegradstufe des Kriteriums *3V's* werden somit echtzeitnahe Informationen zum Kundenkaufverhalten, Produktionsdaten und relevante externe Daten entlang der Supply Chain benötigt. Die Abbildung 2 stellt die Referenztable für das Kriterium *3V's* der Dimension Daten dar.

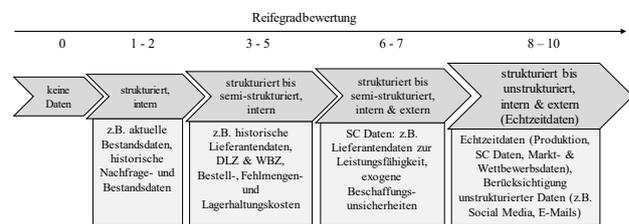


Abbildung 2: Referenztable Daten *3V's*

Datenqualität

Durch das Kriterium *Datenqualität* wird die Qualität der für das Bestandsmanagement genutzten Daten bewertet. Eine gute Datenqualität wird erreicht, wenn die folgenden Subkriterien optimal erfüllt sind: Aktualität, Konsistenz, Korrektheit, Verfügbarkeit, Zugänglichkeit und Vollständigkeit [Gro15; OÖ16]. Unvollständige, nicht eindeutige, veraltete oder nicht zugängliche Daten sorgen somit beispielsweise für eine Abstufung hinsichtlich der Punkteskala für dieses Kriterium.

Datenmanagement

Das Kriterium *Datenmanagement* bewertet die Integration von Daten aus verschiedenen Quellen und Systemen, notwendige Datenaufbereitungen und mögliche Datentransformationen. Zur Integration von Daten aus verschiedenen Quellen und IT-Systemen ist ein Data Warehouse sinnvoll [KD15; LB11]. Der Schritt der Datenaufbereitung und -transformation ist häufig notwendig, da die verfügbaren Daten oft in unterschiedlichen Formaten auftreten, Daten inkorrekt sind oder Werte fehlen [KD15]. Ein gutes Datenmanagement hat somit einen direkten, positiven Einfluss auf die Datenqualität und ist für die Ergebnisse der darauf aufbauenden Analytics von zentraler Bedeutung. Die Reifegradbewertung für das Kriterium Datenmanagement basiert auf der Automatisierungsstufe

(manuell, teil-automatisiert, automatisiert und selbstlernend, autonom) und der entsprechenden Leistungsfähigkeit der Datenaufbereitung, -integration und -transformation.

3.2 DIMENSION: ANALYTICS

Die Dimension Analytics teilt sich in die drei Kriterien Business Analytics, IT-Infrastruktur und Organisation Analytics auf. Somit ermöglicht sie im Rahmen des Reifegradmodells eine Bewertung der angewandten Business Analytics Techniken und der dafür notwendigen Voraussetzungen zur erfolgreichen Anwendung dieser.

Business Analytics

Die eingesetzten Business Analytics stellen Techniken und Modelle aus den drei bzw. vier Business Analytics Phasen Descriptive, (Diagnostic), Predictive und Prescriptive Analytics dar. Die Reifegradstufe steigt dabei grundsätzlich mit fortschreitender Analytics Phase. Abbildung 3 stellt die Reifegradstufen hinsichtlich des Einsatzes von Business Analytics im Bestandsmanagement dar. Die Punkteskala basiert auf der Automatisierungsstufe der angewandten Business Analytics (manuell bis autonom). Die Anwendungsmöglichkeiten von Business Analytics, insbesondere von Predictive und Prescriptive Analytics, für das Bestandsmanagement sind in der Referenztabelle hinsichtlich ihrer Automatisierungsstufen und ihres Nutzens in die Punkteskala von 0 bis 10 eingeteilt. Die individuell einzusetzenden Techniken auf SKU-Ebene sind dabei jedoch abhängig vom Nachfrageverlauf und der finanziellen Bedeutung des Artikels. Auf Basis einer Artikelsegmentierung können geeignete Prognosemethoden für die jeweiligen Artikelgruppen gefunden werden. Die automatisierten, selbstlernenden und die autonomen Modelle sind dementsprechend insbesondere für Produkte mit niedriger Prognostizierbarkeit und hohem finanziellem Wert von großer Bedeutung [Cha16].

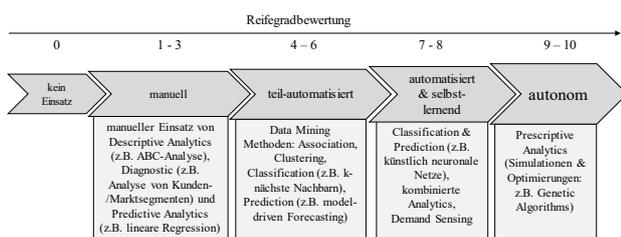


Abbildung 3: Referenztabelle Business Analytics

IT-Infrastruktur

Eine entsprechende IT-Infrastruktur ist Voraussetzung für den Einsatz von Business Analytics Techniken der jeweiligen Reifegradstufe. Neben dem benötigten Speicherplatz für die großen Datenmengen und der Rechenleistung für die Ausführung der Analytics ist, die eingesetzte Software, ein zentraler Aspekt im Bereich der IT-Infrastruktur [Man+11; San14; Wan+16]. Um mögliche Bedarfe für Upgrades oder Innovationen feststellen zu können, ist eine

kontinuierliche Überprüfung der IT-Infrastruktur notwendig [Man+11; Wan+16]. Die Reifegradbewertung des Kriteriums IT-Infrastruktur ist abhängig von der Unternehmensgröße und dem damit verbundenen Datenvolumen.

Organisation Analytics

Das dritte Kriterium bewertet die Organisation der Analytics im Unternehmen. Die Organisation des ganzheitlichen Bestandsmanagements wird mit der Dimension Organisation betrachtet, das Kriterium Organisation Analytics bezieht sich somit lediglich auf die Organisation der relevanten unternehmensinternen IT-Anwendungen. Entscheidend für eine hohe Reifegradstufe in diesem Bereich ist einerseits die Zentralisierung der Analytics, die den Zugang für alle Unternehmensbereiche ermöglicht und somit Analytics für alle Mitarbeiter des Unternehmens zugänglich macht [San14]. Andererseits sind die Fähigkeiten und das Know-how der Mitarbeiter (insbesondere Management und Data Scientists bzw. Analysts) in Bezug auf den Umgang mit Business Analytics entscheidend für dieses Kriterium [LL15; San14; SS15].

3.3 DIMENSION: ORGANISATION

Die Organisation des Bestandsmanagements im Unternehmen selbst und die Gestaltung der Kollaboration entlang der Supply Chain bildet die dritte Dimension des Reifegradmodells zur Integration von Business Analytics im Bestandsmanagement. Diese Dimension ist verantwortlich für die relevanten Prozesse und deren Abstimmung im Unternehmen (unternehmensinterne Organisation) und die Organisation des Austausches von wichtigen Informationen entlang der Supply Chain (unternehmensübergreifende Organisation) und bewertet somit den Stellenwert des Bestandsmanagements innerhalb des Unternehmens und der Supply Chain.

Abbildung 4 stellt die Referenztabelle (Reifegradstufen 0, 5 und 10) für die Dimension Organisation dar. Der Fokus liegt in den unteren Reifegradstufen zunächst auf der unternehmensinternen Koordination der bestandsrelevanten Funktionen und Prozesse, in den höheren Reifegradstufen finden schließlich auch zunehmend unternehmensübergreifende Kooperationen und Kollaborationen statt.

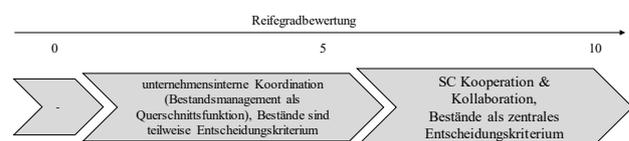


Abbildung 4: Referenztabelle Business Analytics

4 VORGEHENSMODELL ZUR ANWENDUNG DES REIFEGRADMODELLS

Das nachfolgend beschriebene Vorgehensmodell unterstützt produzierende Unternehmen bei der IST-Reifegradbewertung und der Reifegradsteigerung in Bezug auf die Integration von Business Analytics im Bestandsmanagement. Der angestrebte Zielzustand (Ziel-Reifegradstufe) des produzierenden Unternehmens ist grundsätzlich abhängig von individuellen Gegebenheiten, der Unternehmens- und Supply Chain Strategie [Sch+17].

Abbildung 5 stellt das Vorgehensmodell des Reifegradmodells mitsamt dem Vorgehen für die Dimensionen Daten und Analytics (CRISP-DM) dar.

Aufbauend auf einem Startworkshop, in dem wichtige Ziele definiert werden, und einer Analyse des IST-Prozesses werden Potentiale definiert und der IST-Reifegrad mithilfe der Referenztabellen bestimmt. Auf Basis des gewünschten SOLL-Reifegrads werden Projektvorschläge mit entsprechenden Umsetzungsmaßnahmen definiert, die wiederum eine Auswirkung auf die ursprüngliche Strategie haben. [JS16]

Die Projektvorschläge umfassen insbesondere die technologischen Aspekte im Bereich der Dimensionen Daten und Analytics. Um neue Datenquellen und Business Analytics Methoden einzuführen, muss ein Data Mining Prozess (CRISP-DM) durchlaufen werden. Hierfür sind die definierte Strategie und die erarbeiteten Umsetzungsmaßnahmen eine wichtige Basis (Business Understanding). Insbesondere die neu zugewonnenen Datenquellen werden schließlich analysiert und die Datenqualität verifiziert (Data Understanding), um mögliche Datenaufbereitungsmaßnahmen definieren zu können (Data Preparation). Mithilfe der aufbereiteten Daten kann je nach Reifegradstufe das bereits vorhandene Business Analytics Modell weiterentwickelt werden oder ein neues Modell eingeführt werden (Modeling). Um die Erreichung der erarbeiteten Projektziele zu überprüfen, wird das gebildete Modell schließlich bewertet (Evaluation). Basierend auf dieser Bewertung wird über das weitere Vorgehen entschieden (Deployment) und das Modell kann im Idealfall zur Serienreife gebracht werden. [Cha+00]

Die Bewertung des Modells und die Entscheidung, ob das Modell implementiert wird, bestimmt darüber, in wie weit der gewünschte SOLL-Reifegrad erreicht werden kann. Somit entsteht ein erneuter Einfluss auf die Unternehmens- und Supply Chain Strategie und auf die folgenden Verbesserungsmaßnahmen. Das Vorgehensmodell stellt daher ein aufeinander abgestimmtes kontinuierliches Programm dar. Der gewünschte SOLL-Reifegrad ist so zu definieren, dass er nicht zu große oder nur schwer realisierbare Sprünge bezüglich der Ausrichtung des Bestandsmanagements und der Analytics verlangt.

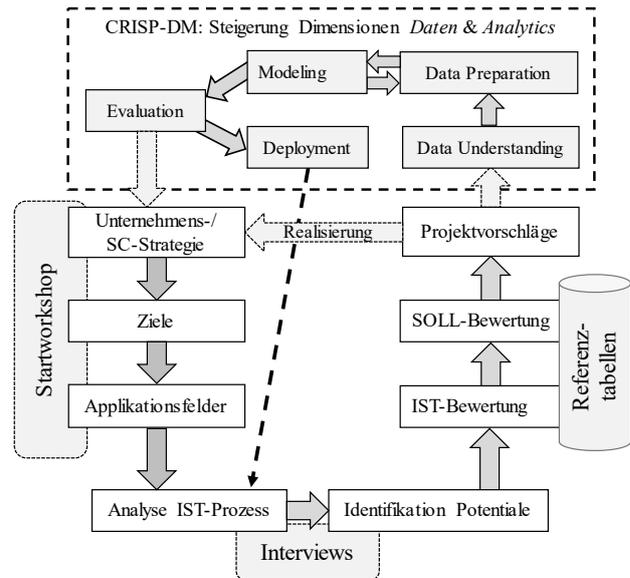


Abbildung 5: Vorgehensmodell zur Anwendung des Reifegradmodells i.A.a. [Cha+00; JS16]

5 ZUSAMMENFASSUNG UND AUSBLICK

In Zusammenhang mit der Verfügbarkeit von großen Datenmengen (Big Data), Entwicklung neuer Datenanalysemethoden und den Fortschritten in der IT-Technologie erweisen sich Business Analytics als wichtiges Tool für das Supply Chain Management und das Bestandsmanagement [Bla+15].

Das entwickelte Reifegradmodell zur Integration von Business Analytics im Bestandsmanagement umfasst die technologischen, prozessualen und personellen Voraussetzungen, die für die Einführung und Weiterentwicklung von Business Analytics und ein davon abhängiges erfolgreiches Bestandsmanagement notwendig sind. Das Reifegradmodell ermöglicht mithilfe der definierten Dimensionen und der tiefergehenden Kriterien eine umfassende Bewertung des Bestandsmanagements in Hinblick auf die Integration von Business Analytics und kann als Grundlage für eine Weiterentwicklung in diesem Bereich dienen. Dabei ist die Vergleichbarkeit zu anderen produzierenden Unternehmen durch Referenztabellen gegeben.

Unternehmen mit der höchsten Reifegradstufe erreichen schließlich den Status einer agilen, transformativen und optimierten Organisation im Bestandsmanagement [Sat12]. Durch die zahlreichen endogenen und exogenen Echtzeitdaten und den Einsatz von Prescriptive Analytics mit maximaler Supply Chain Kooperation und Kollaboration wird letztlich ein autonomes Bestandsmanagement ermöglicht. Hierzu ist jedoch gerade im Bereich der Prescriptive Analytics eine Weiterentwicklung der Techniken und Methoden notwendig, um diese anwendungsbezogener und praxisnäher zu gestalten.

Die Blockchain Technologie und weitere Entwicklungen im Rahmen von Big Data werden in Zukunft für einen weiteren Anstieg verfügbarer Daten und Informationen (Volume) sorgen. Insbesondere die Blockchain wird in Zukunft einen wesentlichen Beitrag zur Transparenz und Datenqualität leisten. unstrukturierte Daten und Echtzeitdaten werden weiter an Bedeutung gewinnen. In markt- bzw. kundenorientierten Supply Chains wird die Nachfrage und ihre Prognose in Zukunft eine noch zentralere Rolle einnehmen. Diese Entwicklungen werden dazu führen, dass Analytics und Algorithmen auf der Basis von Industrie-Benchmarking von Echtzeit-Lernsystemen für das zukünftige Bestandsmanagement der Unternehmen benötigt werden [CC13].

Diese Arbeit wurde vom "Leistungszentrum für Logistik und IT" des Ministeriums für Innovation, Wissenschaft und Forschung des Landes Nordrhein-Westfalen unterstützt.

6 LITERATUR

- [Ber17] Berea, Anamaria: 2017. Predictive Analytics. In *Encyclopedia of Big Data* (170-1), S. 1–5. Cham (Schweiz): Springer International Publishing.
- [Bes+17] Besenfelder, Christoph; Brüggelolte, Matthias; Austerjost, Maximilian; Kämmerling, Nicolas; Pötting, Moritz; Schwede, Christian; Schellert, Maximilian: 2017. Paradigmenwechsel der Planung und Steuerung von Wertschöpfungsnetzen. Unter Mitarbeit von Michael ten Hompel, Michael Henke und Uwe Clausen.
- [Bla+15] Blackburn, Robert; Lurz, Kristina; Priebe, Benjamin; Göb, Rainer; Darkow, Inga-Lena: 2015. A predictive analytics approach for demand forecasting in the process industry. *International Transactions in Operational Research* 22(3): 407–428.
- [Bos09] Bose, Ranjit: 2009. Advanced analytics: Opportunities and challenges. *Industrial Management & Data Systems* 109(2): 155–172.
- [Bre10] Bretzke, Wolf-Rüdiger: 2010. *Logistische Netzwerke*. 2. Aufl. Berlin, Heidelberg: Springer-Verlag.
- [CC13] Cecere, Lora M.; Chase, Charles W.: 2013. *Bricks matter: The role of supply chains in building market-driven differentiation*. Hoboken, NJ: John Wiley & Sons, Inc. (Wiley & SAS business series).
- [Çel15] Çelebi, Dilay: 2015. Inventory control in a centralized distribution network using genetic algorithms: A case study. *Computers & Industrial Engineering* 87: 532–539.
- [Cha+00] Chapman, Pete; Clinton, Julian; Kerber, Randy; Khabaza, Thomas; Reinartz, Thomas; Shearer, Colin; Wirth, Rüdiger: 2000. *CRISP-DM 1.0: Step-by-step data mining guide*. Hg. v. SPSS.
- [Cha16] Chase, Charles W.: 2016. *Next generation demand management: People, process, analytics, and technology*. Hoboken, NJ: John Wiley & Sons Inc. (Wiley & SAS business series).

- [Cla16] Clasen, Mareike: 2016. Vom Ur-knall zur Prognose: Über den Einsatz innovativer Methoden aus der Spitzenforschung für Forecasting, automatische Disposition und Werbemittelsteuerung. In *Controlling im Handel: 177–192*. Wiesbaden: Springer Fachmedien Wiesbaden.
- [Dek16] Deka, Ganesh C.: 2016. Big Data Predictive and Prescriptive Analytics. In *Big data: 30–55*. Hershey: IGI Global.
- [FM16] Fasel, Daniel; Meier, Andreas: 2016. Was versteht man unter Big Data und NoSQL? In *Big Data: 3–16*. Wiesbaden: Springer Fachmedien Wiesbaden.
- [Fin14] Finlay, Steven: 2014. Predictive analytics, data mining and big data: Myths, misconceptions and methods. Basingstoke, New York: Palgrave Macmillan.
- [Gro15] Gronwald, Klaus-Dieter: 2015. Integrierte Business-Informationssysteme: ERP, SCM, CRM, BI, Big Data Analytics – Prozesssimulation, Rollenspiel, Serious Gaming. Berlin, Heidelberg: Springer Berlin Heidelberg.
- [GP17] Groß, Christoph; Pfennig, Roland: 2017. Professionelle Softwareauswahl und -einführung in der Logistik: Leitfaden von der Prozessanalyse bis zur Einsatzoptimierung. Wiesbaden: Springer Fachmedien Wiesbaden.
- [IBM12] IBM Corporation: 2012. Predictive inventory management: Keeping your supply chain in balance. New York: IBM.
- [IDC14] IDC: 2014. The Digital Universe of Opportunities: Rich Data & the Increasing Value of the Internet of Things.
- [Iff+16] Iffert, Lars; Bange, Carsten; Mack, Melanie; Vitsenko, Jevgeni: 2016. *Advanced & Predictive Analytics: Schlüssel zur Wettbewerbsfähigkeit*.
- [IJ08] Inderfurth, Karl; Jensen, Thomas: 2008. Lagerbestandsmanagement. In *Handbuch Logistik: 153–166*. Berlin, Heidelberg: Springer Berlin Heidelberg.
- [JS16] Jodlbauer, Herbert; Schagerl, Michael: 2016. Reifegradmodell Industrie 4.0: Ein Vorgehensmodell zur Identifikation von Industrie 4.0 Potentialen. In *Informatik 2016: 1473–1487*. Bonn: Gesellschaft für Informatik (GI-Edition Lecture Notes in Informatics Proceedings).
- [KD15] Kotu, Vijay; Deshpande, Bala: 2015. *Predictive analytics and data mining: Concepts and practice with RapidMiner*. Waltham, MA: Morgan Kaufmann.
- [Kri13] Krishnan, Krish: 2013. *Data warehousing in the age of big data*. Burlington: Elsevier Science (The Morgan Kaufmann Series on Business Intelligence).
- [Lan01] Laney, Doug: 2001. *3D Data Management: Controlling Data Volume, Velocity, and Variety*. Hg. v. META Group Inc.
- [Lan12] Laney, Doug: 2012. *Information Economics, Big Data and the Art of the Possible with Analytics*. Gartner, 2012.
- [LL15] Larose, Daniel T.; Larose, Chantal D.: 2015. *Data Mining and Predictive Analytics*. 2. Aufl. Chichester: Wiley-Blackwell (Wiley series on methods and applications in data mining).
- [Leh16] Lehmacher, Wolfgang: 2016. *Globale Supply Chain: Technischer Fortschritt, Transformation und Circular Economy*. 1. Aufl. 2016. Wiesbaden: Springer Gabler.
- [LB11] Linoff, Gordon S.; Berry, Michael J. A.: 2011. *Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management*. 3rd ed. Indianapolis: Wiley Pub. Inc.
- [Luo+17] Luokkanen-Rabetino, Karita; Rajala, Arto; Sillanpää, Ilkka; Shahzad, Khuram: 2017. Supply Chain Intelligence. In *Real-time Strategy and Business Intelligence: 193–223*. Cham (Schweiz): Springer International Publishing.
- [Man+11] Manyika, James; Chui, Michael; Brown, Brad; Bughin, Jacques; Dobbs, Richard; Roxburgh, Charles; Byers, Angela H.: 2011. *Big data: The next frontier for innovation, competition, and productivity*. Hg. v. McKinsey Global Institute. McKinsey Global Institute.
- [MMT15] Mehanna, Walid; Müller, Florian; Tunco, Can: 2015. *Predictive Forecasting und die Digitalisierung der Unter-*

- nehmenssteuerung. *IM+io - Fachzeitschrift für Innovation, Organisation und Management* (4): 28–32.
- [Mer11] Merv, Adrian: 2011. It's going mainstream, and it's your next opportunity. *Teradata Magazine Online* (1).
- [Mor15] Morabito, Vincenzo: 2015. *Big Data and Analytics: Strategic and Organizational Impacts*. Cham (Schweiz): Springer International Publishing.
- [Nai15] Nair, Prashant R.: 2015. Tackling Supply Chain Management through Business Analytics: Opportunities and Challenges. In *Emerging ICT for bridging the future*: 569–576. Cham (Schweiz): Springer.
- [OÖ16] Otto, Boris; Österle, Hubert: 2016. *Corporate Data Quality: Voraussetzung erfolgreicher Geschäftsmodelle*. Berlin: Springer Gabler.
- [RPG09] Radhakrishnan, P.; Prasad, V. M.; Gopalan, M. R.: 2009. Optimizing Inventory Using Genetic Algorithm for Efficient Supply Chain Management. *Journal of Computer Science* 5(3): 233–241.
- [San14] Sanders, Nada R.: 2014. *Big data driven supply chain management: A framework for implementing analytics and turning information into intelligence*. Upper Saddle River, NJ: Pearson Education.
- [Sat12] Sathi, Arvind: 2012. *Big Data Analytics: Disruptive technologies for changing the game*. Chicago: MC Press.
- [Sch81] Schneeweiß, Christoph: 1981. *Modellierung industrieller Lagerhaltungssysteme: Einführung und Fallstudien*. Berlin: Springer.
- [SS15] Schoenherr, Tobias; Speier-Pero, Cheri: 2015. Data Science, Predictive Analytics, and Big Data in Supply Chain Management: Current State and Future Potential. *Journal of Business Logistics* 36(1): 120–132.
- [Sch07] Schönsleben, Paul: 2007. *Integrales Logistikmanagement: Operations und Supply Chain Management in umfassenden Wertschöpfungsnetzwerken*. 5., bearbeitete und erweiterte Auflage. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg.
- [Sch+17] Schuh, Günther; Anderl, Reiner; Gausemeier, Jürgen et al.: 2017. *Industrie 4.0 Maturity Index: Die digitale Transformation von Unternehmen gestalten*. München: Herbert Utz Verlag (acatech STUDIE).
- [SR17] Serrato, Marco; Ramirez, Jorge: 2017. The Strategic Business Value of Big Data. In *Big Data Management*: 47–70. Cham (Schweiz): Springer International Publishing.
- [Shm10] Shmueli, Galit: 2010. To Explain or to Predict?. *Statist. Sci.* 25(3): 289–310.
- [Shm+18] Shmueli, Galit; Bruce, Peter C.; Yahav, Inbal et al.: 2018. *Data mining for business analytics: Concepts, techniques, and applications* in R. Hoboken, NJ: Wiley.
- [Sou14] Souza, Gilvan C.: 2014. Supply chain analytics. *Business Horizons* 57(5): 595–605.
- [Tal+13] Taleizadeh, Ata A.; Niaki, Seyed T. A.; Aryanezhad, Mir-Bahador; Shafii, Nima: 2013. A hybrid method of fuzzy simulation and genetic algorithm to optimize constrained inventory control systems with stochastic replenishments and fuzzy demand. *Information Sciences* 220: 425–441.
- [Tem15] Tempelmeier, Horst: 2015. *Bestandsmanagement in Supply Chains*. 5., erweiterte und verbesserte Auflage. Norderstedt: BoD - Books on Demand.
- [TM09] Trkman, Peter; McCormack, Kevin: 2009. Supply chain risk in turbulent environments—A conceptual model for managing supply chain network risk. *International Journal of Production Economics* 119(2): 247–258.
- [Wan+16] Wang, Gang; Gunasekaran, Angappa; Ngai, Eric W.T.; Papadopoulos, Thanos: 2016. Big data analytics in logistics and supply chain management: Certain investigations for research and applications. *International Journal of Production Economics* 176: 98–110.

Autoren Informationen:

Matthias Brüggelolte, M. Sc. ist wissenschaftlicher Mitarbeiter am Lehrstuhl für Unternehmenslogistik. Er studierte Wirtschaftsingenieurwesen an der Technischen Universität Dortmund mit den Schwerpunkten Produktion und Logistik. Matthias Brüggelolte arbeitet im Leistungszentrum für Logistik und IT.

Markus Stute, M. Sc. ist wissenschaftlicher Mitarbeiter am Fraunhofer-Institut für Materialfluss und Logistik in der Abteilung Supply Chain Development & Strategy. Er studierte Wirtschaftsingenieurwesen an der Technischen Universität Dortmund mit den Schwerpunkten Produktion und Logistik.

Christoph Besenfelder, Dipl.-Logist. ist Forschungskordinator am Lehrstuhl für Unternehmenslogistik der Technischen Universität Dortmund und am Fraunhofer-Institut für Materialfluss und Logistik in Dortmund. Er studierte Logistik an der Technischen Universität Dortmund und ist Fraunhofer-Forschungsmanager, European Industrial Engineer und EOQ-Quality Manager. Seine Forschungsschwerpunkte sind Unternehmenslogistik und das Management der Industrie 4.0.