



Big Data Centrum

FALLBEISPIELE AUS DER PRAXIS



/ INHALT

Vorwort

- 2 Data Analytics – Einsatzgebiete und Werkzeuge

Nachfrageprognosen

- 6 Gäste- und Speiseprognose
in der Gemeinschaftsverpflegung
- 10 Datenbasierte Nachfrageprognose
im stationären Getränkehandel

Logistik / Supply Chain Management

- 13 Intralogistik in der verarbeitenden Industrie
- 16 Das ABC der Lageroptimierung
- 18 Auftragsdauer und Materiallager
eines metallverarbeitenden Unternehmens
- 20 Digitale Wertstromanalyse

Maschinendaten

- 23 Weniger Ausschuss durch optimierte
Maschineneinstellungen
- 26 Prozessanalysen in der elektronischen
Auftragsfertigung
- 28 Stromdatenanalyse und -monitoring als Einstieg
in die Prozessoptimierung

Big Data – und jetzt?

- 30 Auf dem Weg zur Data Driven Company

/ DATA ANALYTICS – WAS STECKT DAHINTER?

Unternehmen, die wissen, was der Kunde bestellen wird – noch bevor es der Kunde selbst weiß; Polizisten, die im Voraus berechnen können, wann und wo (mit hoher Wahrscheinlichkeit) ein Verbrechen geschehen wird; Systeme, die den bevorstehenden Ausfall einer Industriemaschine erkennen: was noch vor wenigen Jahren Gegenstand von Science Fiction-Erzählungen war, wird derzeit mit Hilfe von „Big Data“ Wirklichkeit. Grundlage von Big Data sind große Datenmengen und intelligente Data Analytics-Algorithmen. Große Datenmengen entstehen durch die zunehmende Digitalisierung, zum Beispiel beim privaten Surfen im Internet, im Unternehmen durch elektronische Datenverarbeitungssysteme oder in Industriemaschinen durch die Maschinensteuerung und Sensoren. Kernidee von Big Data ist es, diesen Datenstrom systematisch zu analysieren, um aus den verfügbaren Daten wertvolles Wissen zu erzeugen. Dass „Data Analytics“ funktioniert, führen Firmen wie Google und Amazon täglich aller Welt vor Augen.

Einsatzgebiete: Unbegrenzte Möglichkeiten?

Im Marketing setzen schon jetzt viele Unternehmen solche Techniken ein, tagtäglich kommt somit jeder von uns bereits mit den Ergebnissen von Data Analytics in Berührung, vielleicht ohne es zu merken. Speziell für Handelsunternehmen sind Absatzprognosen ein wichtiges Anwendungsgebiet. Wenn man schon im Vorhinein weiß, von was wieviel verkauft wird, dann kann nicht nur die Kundennachfrage besser bedient werden. Auch die Kosten lassen sich senken, weil die Lager nicht mehr mit Ladenhütern verstopft sind. Industrie 4.0 ist ein weiteres Zukunftsthema, bei dem Industrieunternehmen auf Data Analytics setzen. Ein Beispiel ist die vorausschauende Instandhaltung (Predictive Maintenance): Durch die kontinuierliche Auswertung der Betriebsdaten von Industriemaschinen sollen Wartungen maschinenindividuell genau dann durchgeführt werden, wenn sie notwendig sind – und nicht wenn es ein starrer Wartungsplan vorgibt, der nur auf einfachen Durchschnittswerten beruht. In der Finanzbranche (und in den Revisionsabteilungen von Unternehmen aller Branchen) ist hingegen Betrugserkennung das große Thema. Betrüger hinterlassen unweisentlich Spuren in den Daten, die sich durch intelligente Algorithmen aufdecken lassen.

Werkzeuge: Wie funktioniert Data Analytics?

Unternehmen, die konsequent Daten für ihren Erfolg nutzen wollen, müssen sich mit zwei Themenfeldern auseinandersetzen: Datenmanagement und Datenanalyse. Das Datenmanagement beinhaltet die systematische Speicherung von Daten in Datenbanksystemen oder auch einfach nur in Exceltabellen. Viele Unternehmen betreiben einen hohen Aufwand, um Daten zu speichern, zu verwalten und innerhalb des Unternehmens verfügbar zu machen. Damit allein ist jedoch noch kein Nutzen für das Unternehmen gewonnen. Im ersten Schritt bedeuten Daten also zunächst nur Kosten, erst durch den zweiten Schritt, die Datenanalyse, entsteht aus den Daten ein Mehrwert. Datenanalysen können dabei in unterschiedlichen Stufen mit steigender Komplexität durchgeführt werden:

— 1. Descriptive Analytics

Am Anfang einer Datenanalyse steht immer die deskriptive Analyse mit einfachen statistischen Verfahren. Hierbei werden statistische Kennzahlen (Mittelwerte, Häufigkeiten, Korrelationen) berechnet, Daten grafisch aufbereitet und einfache Zusammenhänge analysiert. Deskriptive Analysen schaffen Transparenz und allein damit lässt sich häufig schon ein enormer Mehrwert erzielen, wie einige der hier dargestellten Fallbeispiele eindrucksvoll zeigen. Am Beispiel der Kundennachfrage eines Händlers werden in diesem Schritt zum Beispiel Nachfrageunterschiede zwischen den Wochentagen oder zwischen verschiedenen Filialen festgestellt.

— 2. Diagnostic Analytics

Auffälligkeiten, die in den deskriptiven Analysen identifiziert wurden, werden im nächsten Schritt genauer untersucht. Durch statistische

Verfahren und Gespräche vor Ort werden die Gründe für Auffälligkeiten ermittelt. Für den Händler wird beispielsweise untersucht, warum sich ein Artikel in der einen Filiale besser und in der anderen schlechter verkauft, oder es werden die Ursachen großer Nachfrageschwankungen aufgedeckt.

— 3. Predictive Analytics

Ziel von Datenanalysen ist häufig die Erkennung von Zusammenhängen in historischen Daten, um anschließend Prognosen für die Zukunft berechnen zu können: Deuten die aktuell in der Maschine gemessenen Sensorwerte auf eine bevorstehende Maschinenstörung hin? Wie hoch wird in der nächsten Woche die Nachfrage für einen bestimmten Artikel in einer bestimmten Filiale sein? Diese Fragen lassen sich mit Regressions- und Klassifikationsverfahren beantworten. Dabei können sowohl klassische statistische Verfahren als auch maschinelle Lernalgorithmen aus dem Bereich der künstlichen Intelligenz eingesetzt werden.

— 4. Prescriptive Analytics

Wer die Zukunft aufgrund guter Prognosen kennt, kann sie auch gezielt beeinflussen. Die in historischen Daten identifizierten Muster werden im letzten Schritt verwendet, um möglichst optimale Entscheidungen zu treffen: Wie müssen die Parameter einer Maschine eingestellt werden, um eine bestmögliche Qualität zu erzeugen? Wie hoch soll der Lagerbestand eines Artikels sein, um die Nachfrage mit hoher Wahrscheinlichkeit bedienen zu können und den von der Geschäftsführung geforderten Servicelevel einhalten zu können? Hierbei sind neben maschinellen Lernverfahren auch Optimierungsalgorithmen von zentraler Bedeutung. Moderne Optimierungsalgorithmen basieren häufig auf Simulationen und nutzen beispielsweise die Vorteile der Schwarmintelligenz.

Praxisbeispiele

Im Folgenden ist eine Sammlung an konkreten Praxisbeispielen zusammengestellt, die am Technologie Campus Grafenau in Zusammenarbeit mit Unternehmen bearbeitet wurden. Als erstes werden zwei Beispiele für Nachfrageprognosen vorgestellt. Nachfrageprognosen spielen für viele Unternehmen eine wichtige Rolle, um die eigene Lagerhaltung zu optimieren und die Kundennachfrage möglichst immer bedienen zu können. Im ersten Beispiel geht es neben dem Ziel Kosten zu senken vor allem darum, die Verschwendung von Lebensmitteln zu reduzieren. Hierzu wurde ein Prognosesystem für Betriebskantinen

entwickelt. Im zweiten Fallbeispiel wurde ein Prognosesystem für den Getränke Einzelhandel entwickelt. Der nachfolgende Themenblock behandelt Fallbeispiele aus dem Bereich Logistik und Supply Chain Management: Themen sind hierbei die Optimierung des Einsatzes von Gabelstaplern in einem Produktionsbetrieb, die Lageroptimierung mit ABC-Analysen und die Optimierung von Durchlaufzeiten durch digitalisierte Wertstromanalysen. Der letzte Themenblock befasst sich mit der Auswertung von Maschinendaten: Ein wichtiges Thema ist hierbei die Reduzierung von Ausschuss durch optimierte Maschineneinstellungen (Predictive Quality); zwei weitere Fallbeispiele behandeln die Erfassung und Analyse von Maschinenstillstandszeiten zur Prozessoptimierung. /

A decorative dashed arc is positioned on the left side of the slide, spanning from the bottom towards the middle. It is composed of two segments: a green one on the left and a white one on the right.

NACHFRAGEPROGNOSEN

/ GÄSTE- UND SPEISEPROGNOSE IN DER GEMEINSCHAFTSVERPFLEGUNG

Freitag, 13:45 Uhr. Das Teammeeting hat wieder länger gedauert als gedacht und Sie haben einen riesigen Appetit. Da die Kantine in 15 Minuten schließt, sind Sie einer der letzten Gäste. Trotz der späten Zeit besteht noch die volle Auswahl an Tagesgerichten und auch das Salatbuffet ist noch prall gefüllt. —

So oder so ähnlich ist die Situation in vielen großen Betriebskantinen. Was für den Mitarbeiter einen großen Luxus darstellt, ist für den verantwortlichen Küchenleiter ein wahres Horrorszenario. Zum einen will er allen Mitarbeitern zu jeder Zeit eine volle Auswahl an Gerichten anbieten können, zum anderen können nicht verkaufte Gerichte oft nicht weiterverarbeitet und müssen deshalb entsorgt werden.

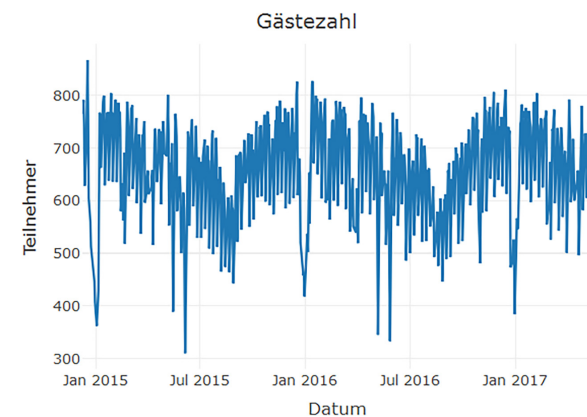
Wie kann Datenanalyse Küchenleiter bei dieser Thematik unterstützen? Dieselbe Herausforderung stellt sich nicht nur Betriebsgastronomien, sondern zeigt sich auch in weiteren Bereichen, wie z.B. dem Einzelhandel oder auch in der Beschaffung in Unternehmen, die die Nachfrage und den Bedarf ihrer Kunden abschätzen müssen.

Für den Küchenleiter stellen sich täglich drei ausschlaggebende Fragen:

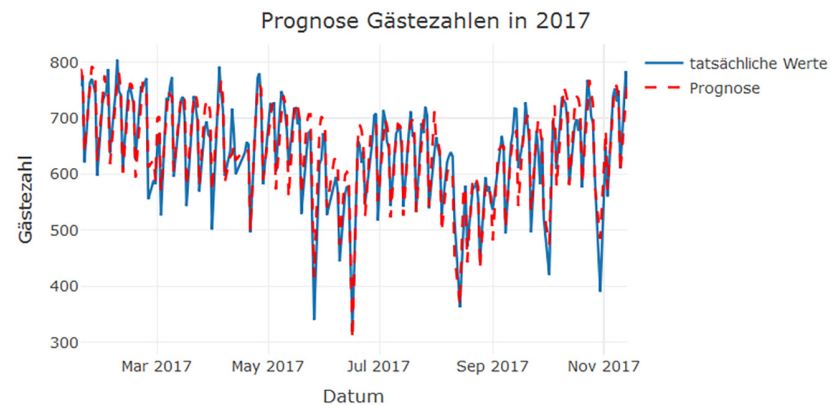
1. **Wie viele Gäste werden heute die Kantine aufsuchen?**
2. **Wie viele Speisen müssen insgesamt produziert werden?**
3. **Wie viele Portionen jeder Speise müssen zubereitet werden?**

Die wichtigste Informationsquelle, um diese Fragen datenanalytisch betrachten zu können, bietet das elektronische Kassensystem. Hier werden alle relevanten Informationen gespeichert und können ausgewertet werden.

Betrachten wir zunächst zum Beispiel die Gästezahlen einer Betriebskantine über einen Zeitraum von über 2 Jahren:



2 – Vergleich der Prognosewerte mit den tatsächlichen Gästezahlen im Zeitraum Januar 2017 bis November 2017



Die Gästezahlen in diesem Beispiel schwanken zwischen 300 und 800 Gästen am Tag. Durch verschiedene analytische Betrachtungen lassen sich aber viele Merkmale definieren, welche für diese Schwankungen verantwortlich sind. So hat der Wochentag zum Beispiel einen großen Einfluss auf die Gästezahlen. Freitags gehen in der Regel wesentlich weniger Gäste in die Kantine, da viele freitags kürzer arbeiten. Weitere eindeutige Merkmale sind z. B. die Schulferien und Brückentage.

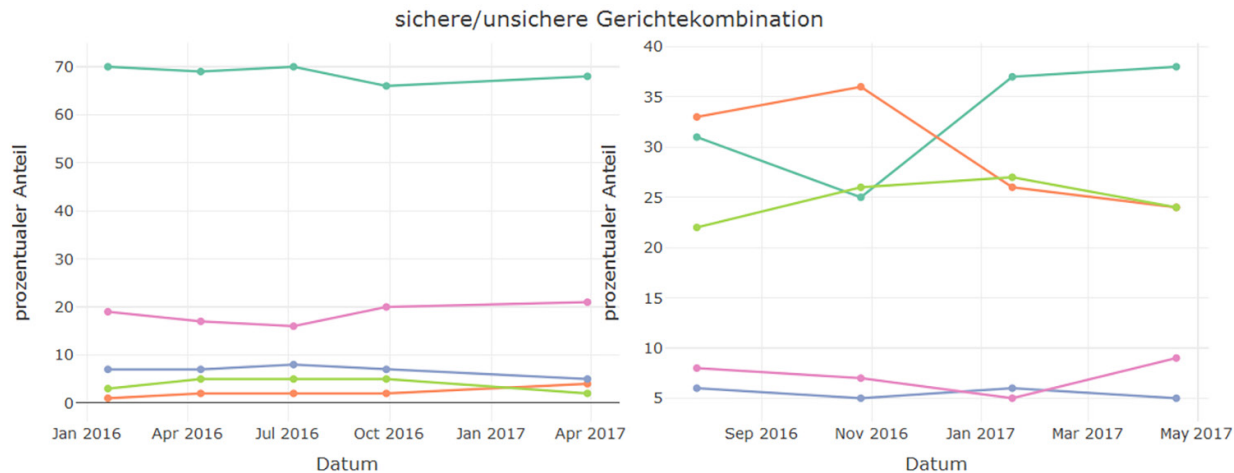
Mit Hilfe dieser Merkmale wurde nun ein statistisches Modell erstellt, welches zukünftige Essens-

teilnehmerzahlen vorhersagt. Abbildung 2 zeigt die Prognosen der beschriebenen Betriebskantine für das Jahr 2017 sowie die tatsächlichen Gästezahlen (Abb. 2).

Es ist zu erkennen, dass die Prognosen die tatsächlichen Werte sehr gut vorhersagen. Im durchgeführten Projekt wurde dieses Modell in drei verschiedenen Betriebsgastronomien angewandt. Die durchschnittlichen Abweichungen von den tatsächlichen Gästezahlen lagen dabei zwischen 4,0 % und 6,7%. Bei durchschnittlich 600 Gästen würde dies eine Abweichung zwischen 24 bis 42 Personen bedeuten.

Dasselbe gilt nun auch für die Prognose der benötigten Speisen. Hier spielen zusätzlich noch weitere Einflussfaktoren eine Rolle. Die Wahl der Speisen hängt zum Beispiel davon ab, welche Gerichte angeboten wurden und welche Alternativen (Salate, Desserts, ...) die Gäste wählen konnten. So liegt die durchschnittliche Abweichung bei der Prognose der Zahl verkaufter Hauptspeisen zwischen 5,4 % und 8,2 %, oder umgerechnet 32 bis 49 Portionen.

Eine Analyse der Verkaufszahlen der einzelnen Gerichte ergab, dass diese stark vom Speiseplan und daraus resultierend von ihren Konkurrenzprodukten



3 – Beispiel einer Gerichtekombination mit geringen Schwankungen (links) und hohen Schwankungen (rechts)

abhängen. Auffällig dabei ist, dass es bei den zusammengestellten Speisen sichere und unsichere Kombinationen gibt. Das bedeutet, dass gewisse Gerichtekombinationen immer ähnliche Verkaufsverhältnisse aufweisen, andere hingegen große Schwankungen. Verdeutlichen soll dies die Abbildung 3.

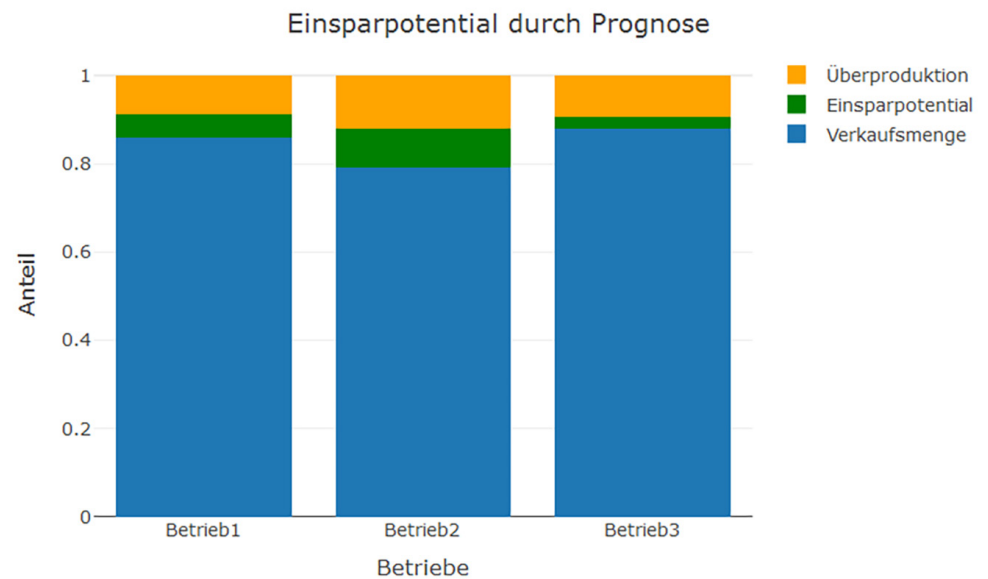
In der linken Grafik schwanken die prozentualen Verkaufsverhältnisse nur sehr gering. Lässt sich nun die Zahl der Gäste gut schätzen, können gute Rückschlüsse auf die benötigten Speisezahlen gezogen

werden. Anders verhält es sich in der Grafik rechts. Bei dieser Gerichtekombination liegen die Schwankungen bei bis zu 15 Prozentpunkten. Eine genaue Kalkulation der Portionsmengen ist trotz Kenntnis der Gästezahl schwierig und eine Abdeckung des Bedarfes jeder einzelnen Speise daher mit einer massiven Überproduktion verbunden.

Ein Vergleich der tatsächlichen Produktionsmengen der Betriebskantinen mit den prognostizierten Werten zeigt auf, dass ein hohes Einsparpoten-

tial vorhanden ist. Als Überproduktion wurde die Differenz zwischen der Kalkulation der Küchenleiter und der tatsächlich verkauften Mengen definiert. Die Überproduktion liegt in den drei analysierten Betriebskantinen zwischen 12 % und 24 %. Die Überproduktion des Prognosemodells schwankt in den drei Kantinen zwischen 10 % und 15 %. Dies würde eine Einsparung von 20 % bis 40 % bedeuten, oder anders ausgedrückt: Es müssten zwischen 2,5 % und 10 % weniger Speisen produziert werden. Abbildung 4 bildet diese Zahlen grafisch ab.

4 – Darstellung der Überproduktion und des Einsparpotentials in den drei Betriebsgastronomien

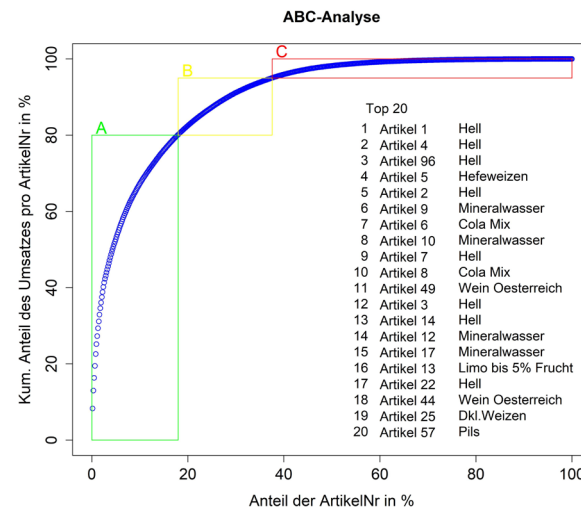


Als Unterstützung für die Betriebsleiter und Küchenchefs wurde am Technologie Campus Grafenau ein Tool entwickelt, mit welchem all die beschriebenen Analysen an eigenen Daten selbstständig durchgeführt werden können. Noch dazu dient es als Kontroll- und Monitoring-Tool. Dieses Tool ist frei zugänglich unter der Adresse:
tcg-shiny.th-deg.de/prognosys/

/ DATENBASIERTE NACHFRAGEPROGNOSE IM STATIONÄREN GETRÄNKEHANDEL

Damit Kunden in Lebensmittel- oder Getränkemarkten nicht vor leeren Regalen stehen, ist es für Händler existenziell, die Höhe der Kundennachfrage möglichst genau zu kennen. Wenn Produkte nicht verfügbar sind, besteht die Gefahr, dass die Kunden aufgrund der Vielzahl von Supermärkten und dem großen Angebot schnell zur Konkurrenz abwandern und ihre Einkäufe in anderen Geschäften tätigen. Beispielhaft für die Prognose der Kundennachfrage wird hier ein Pilotprojekt mit einem regionalen Getränkeshändler beschrieben. Ziel war die Unterstützung der Beschaffung und Personalplanung durch die Entwicklung einer Methodik zur automatisierten Nachfrageprognose.

Wenn Kunden im Einzelhandel einkaufen, werden meist die Daten des Einkaufs, also z. B. Artikel, Menge und Preis, im Kassensystem gespeichert. Diese Daten stehen in großer Menge zur Verfügung und können bei detaillierter Betrachtung dazu beitragen, die Kundenbedürfnisse besser zu verstehen und das

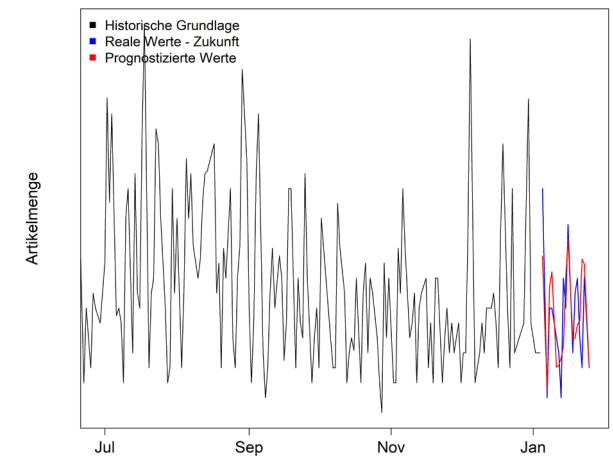


1 – ABC-Analyse für eine Filiale, 18 % der Artikel (A) erzeugen 80 % des Umsatzes, die nächsten 20 % der Artikel (B) erzeugen 15 % des Umsatzes, die weiteren 62 % der Artikel (C) erzeugen 5 % des Umsatzes.

Angebot daran auszurichten. Im vorliegenden Fall, sollten vorrangig die Kundenanzahl und die nachgefragten Mengen analysiert werden. Es standen die Daten der Verkäufe aus 19 Filialen und einem Erhebungszeitraum von gut zwei Jahren zur Verfügung. Zusätzlich wurden Daten über Marketingaktionen, Kalenderdaten (wie Feiertage und Ferien) und Wetterdaten verwendet, um deren Einflüsse auf den Verkauf zu berücksichtigen.

Das Produktsortiment des Getränkeshändlers umfasst über 2200 Artikel. Es ist jedoch sinnvoll die Analyse auf die wichtigsten Artikel zu beschränken, da die Mengen für sehr selten und gering verkaufte Artikel nur schlecht prognostiziert werden können und der Aufwand für eine gute Prognose einem geringen Nutzen für das Unternehmen gegenübersteht. In Abbildung 1 ist zu sehen, dass in einer Filiale 18 % der

2 — Die Darstellung zeigt die Prognose der Artikelmenge für ein Mineralwasser in einer Filiale. Die Prognosewerte werden für den berechneten Prognosezeitraum aufsummiert und in der Grafik auf Tagesbasis angezeigt.



Artikel für 80 % des Umsatzes verantwortlich sind. Gleiches trifft zu, wenn man das gesamte Unternehmen über alle Filialen betrachtet.

Für die Prognose der Kundenanzahl sowie der Artikelmen gen wurden vier verschieden komplexe Verfahren getestet und nach der Prognosegüte verglichen. Die einzelnen Artikel werden getrennt für jede Filiale vorhergesagt, da die Artikel in den einzelnen Filialen sehr unterschiedlich verkauft werden und die Vorhersage pro Filiale genauer ist. Für jede Kombination von Artikel und Filiale werden die Prognosemodelle separat berechnet und dadurch eine bessere Genauigkeit für jede Artikel-Filiale-Kombination erreicht. Die durchschnittliche absolute Abweichung der Prognose für die Artikelmen gen von den tatsächlichen Mengen liegt bei 13 %, allerdings wird nicht jeder Artikel gleich gut vorhergesagt. Die

Prognose der Artikelmenge wird auf Tagesbasis für standardmäßig 14 Tage berechnet, da dies in der Praxis ein adäquater Zeitraum zwischen Bestell- und Liefervorgang ist. Zu beachten ist hierbei auch die Tatsache, dass Wettervorhersagen mit steigendem Prognosehorizont immer ungenauer werden oder ab einem gewissen Zeitraum gar nicht vorhanden sind. Im gleichen Zuge wird die Prognose der Artikelmenge ungenauer. Deshalb ist es sinnvoll, den Prognosezeitraum nicht zu groß zu wählen.

In Abbildung 2 ist die Verlaufskurve der verkauften Artikelmenge eines Mineralwassers beispielhaft dargestellt. Die blaue und rote Kurve am rechten Rand der Grafik zeigt die realen und die prognostizierten Werte für einen Zeitraum von 14 Tagen.

Zur anschaulichen Darstellung wurde im Rahmen des Projektes ein Dashboard entwickelt, in dem Einstellungen wie Filiale, Artikel, Prognosemodell und Prognosezeitraum gewählt werden können. Bei der Menge an Filialen und Artikel erleichtert es, die Ergebnisse interaktiv nachzuvollziehen.

Die Ergebnisse können die Bestellprozesse, die Lagerbestandshaltung sowie die Personalplanung unterstützen. Deshalb sollen in der Weiterführung die entwickelten Algorithmen in das Kassensystem integriert werden. Des Weiteren können die Bestelllogiken, die Nachfrageprognose und die Lagerbestände zur Entwicklung eines Bestellvorschlagsystems zusammengefasst werden. /



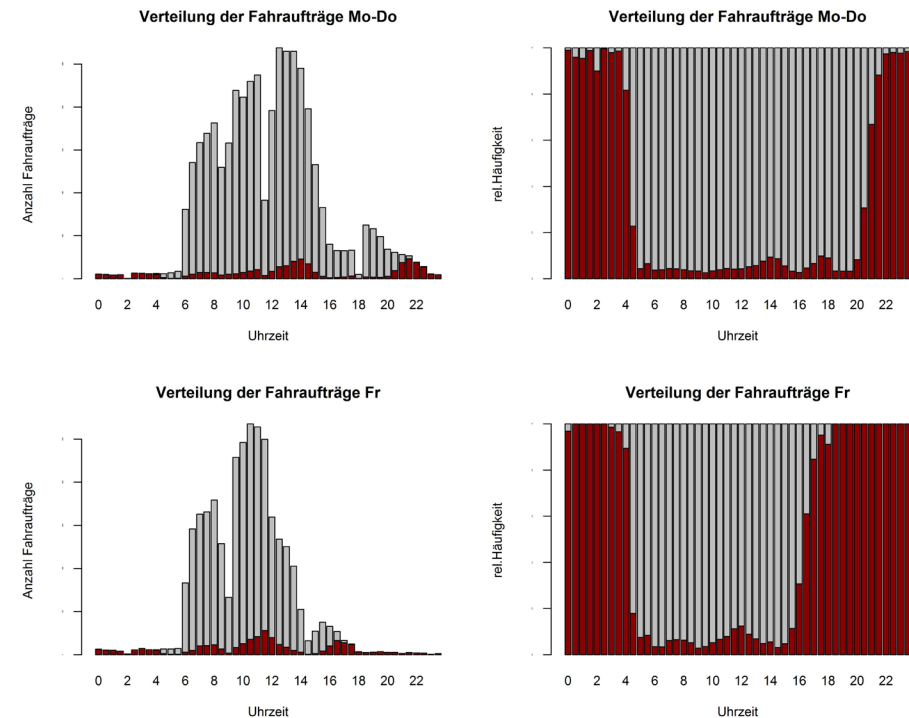
LOGISTIK / SUPPLY CHAIN MANAGEMENT

/ INTRALOGISTIK IN DER VERARBEITENDEN INDUSTRIE

In Betrieben der verarbeitenden Industrie ist die Intralogistik mittels Flurförderzeugen von großer Bedeutung, um möglichst reibungslose Abläufe in der Produktion zu gewährleisten. Der Transport durch Flurförderzeuge unterliegt häufig bestimmten Zielvorgaben, wie zum Beispiel der Einhaltung festgelegter Zeitfristen, innerhalb der ein Fahrauftrag abgearbeitet sein muss. Zur Überwachung und Optimierung der Leistungsfähigkeit des werksinternen Transportsystems kann die digitale Erfassung und Auswertung großer Datenmengen (Big Data) einen wichtigen Beitrag liefern. Nachfolgend werden die Ergebnisse einer Analyse der Materialbewegungen in einem mittelständischen Betrieb der fertigen Industrie vorgestellt.

Zunächst wurde quantitativ untersucht, wie sich das Transportvolumen zeitabhängig auf die einzelnen Strecken im Werk verteilt, d.h. wann wo wieviele

1 – Auftragsverteilung und Erfüllungsquote unterschieden nach Wochentagen

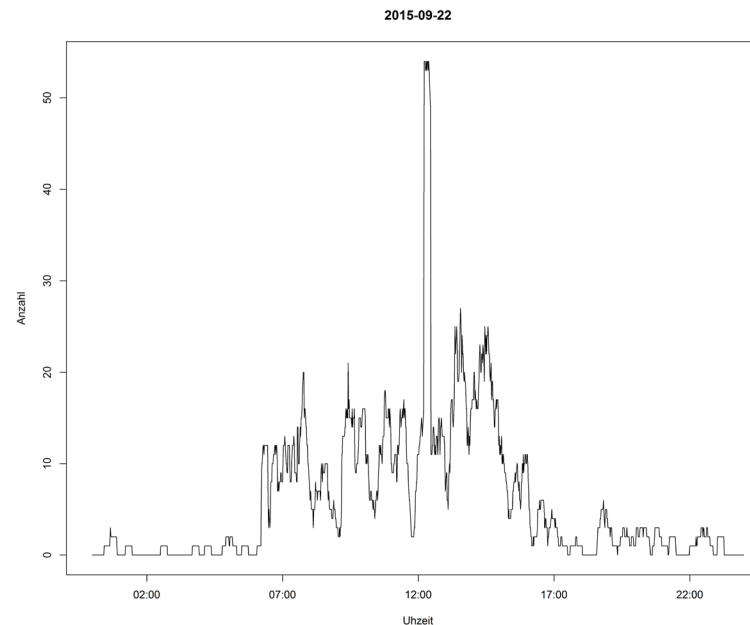


Aufträge transportiert wurden. So konnten die Hauptrouten sowie zeitliche und räumliche Spitzen ermittelt werden. Zusätzlich gibt es die Unternehmensvorgabe, dass ein Fahrauftrag innerhalb von zwei Stunden nach

Auftragserstellung abgeschlossen sein soll. Daher wurde parallel untersucht, wie sich die Erfüllungsquoten auf den einzelnen Strecken, sowie in Abhängigkeit von der Uhrzeit, unterscheiden (Abb. 1).

Montag bis Donnerstag wird in zeitlich identischen Schichten gearbeitet, daher sind diese vier Werk-tage in der Abbildung zusammengefasst. Freitags unterscheiden sich die Schichtarbeitszeiten zu den anderen Tagen. Eine Arbeitsschicht dauert kürzer und dadurch verschieben sich die Pausenzeiten. Ebenso gibt es freitags keine Nachtschicht, die Arbeitszeit endet um 18 Uhr. Daher ist eine geson-derte Betrachtung der Verteilung notwendig. Die beiden linken Grafiken (siehe Vorderseite: Seite 13) zeigen die absolute Verteilung der Aufträge. Es ist zu erkennen, dass um 6 Uhr Schichtbeginn ist, da hier die Auftragslage ansteigt. Gegen 9 Uhr vormittags und 12 Uhr mittags sinken die Auftragszahlen. Dies erklärt sich mit den Pausenzeiten im Betrieb. Montag bis Donnerstag erreicht die Auftragslage am frühen Nachmittag ihre Spitze, wohingegen freitags die Auftragslage ab 12 Uhr stark absinkt. Nach 18 Uhr sind freitags nahezu keine Aufträge mehr vorhanden, an den anderen Werktagen gibt es bis 23 Uhr immer wieder neue Fahraufträge. Der rot markierte Bereich in der Abbildung zeigt den Anteil an Fahr-ten, welcher nicht die Unternehmensvorgabe einer Erfüllung innerhalb von zwei Stunden nach Auftrags-

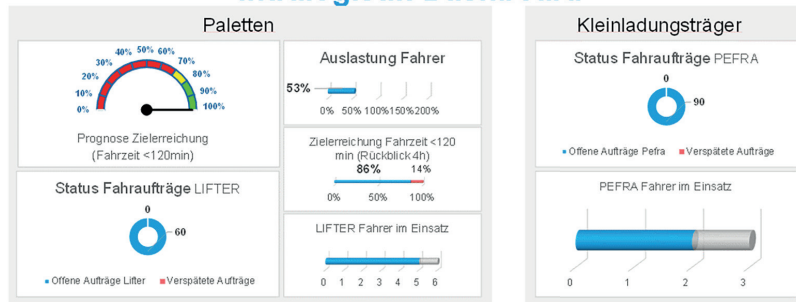
erstellung schafft. Um die Erfüllungsquoten über die Zeit miteinander vergleichen zu können, ist in den beiden rechten Grafiken (siehe Vorderseite: Seite 13) das relative Verhältnis zwischen den innerhalb der Unternehmensvorgaben abgearbeiteten Aufträgen und den nicht innerhalb von zwei Stunden erfüllten Aufträgen angegeben. Es ist deutlich zu sehen, dass vor 6 Uhr morgens und nach Schichtende des letzten Staplerfahrers keine Aufträge abgearbeitet werden können und daher der rote Balken dominiert. Die linken Abbildungen zeigen aber auch, dass in diesem Zeitraum so gut wie keine Aufträge anfallen. In den Regelarbeitszeiten ist die Erfüllungsquote durchgehend sehr hoch. Es fällt aber auf, dass zu den hoch-frequentierten Zeiten der Anteil nicht innerhalb des Zeitfensters erledigter Aufträge leicht zunimmt.



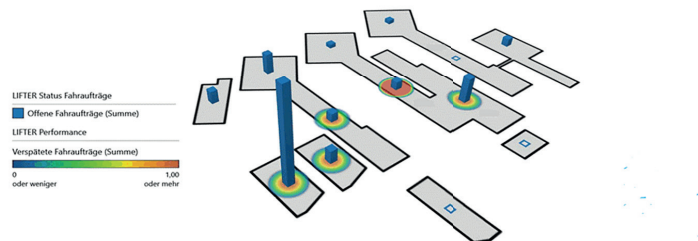
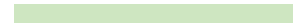
2 — Tagesspezifische Auftragsverteilung am 22.09.2015

Ein Ziel des Unternehmens ist es, die Erfüllungsquote möglichst hoch zu halten. Daher ist es sinnvoll, alle nicht innerhalb des vorgegebenen Zeitraums geschafften Aufträge näher zu untersuchen, um Auffälligkeiten oder Gründe dafür herauszufinden. Eine genauere Betrachtung eben dieser Aufträge zeigte auf, dass vermeidbare Faktoren eine Rolle spielen. Einer dieser Faktoren war das Ansammeln von Fahraufträgen durch einzelne Mitarbeiter. Es wurden teilweise Aufträge nicht sofort nach ihrer Erstellung in das System eingelesen, sondern Mitarbeiter haben diese gesammelt und anschließend zeitgleich ins System eingespielt. Für die Flurfahrer wird es daher fast unmöglich alle Aufträge innerhalb der Zielzeit abzuarbeiten. Abbildung 2 verdeutlicht diese Problematik.

Intralogistik-Dashboard



3 – Dashboard mit Live-Kennzahlen



Um ca. 12 Uhr mittags wurden an diesem Tag 50 Aufträge gleichzeitig ins System eingespeist. Wären diese Aufträge nacheinander eingelesen worden, würden keine solchen Auftragsspitzen entstehen und die Erfüllungsquote würde leichter erreicht werden.

Neben den statischen Analysen der IST-Zustände war es im Projekt auch von Interesse, ein dynamisches System zu entwickeln, welches ein ständiges Monitoring der Prozesse ermöglicht. Durch Zeitstempel für jeden einzelnen Auftrag war es möglich eine Fahrzeitmatrix und dadurch die mittlere reale

Fahrdauer für jede einzelne Strecke zu ermitteln. Basierend auf den Ergebnissen konnte anschließend ein Kennzahlensystem aufgebaut werden, welches die Effizienz und Auslastung im Fahrbetrieb wiedergibt. Über ein Dashboard können diese Kennzahlen in Echtzeit dargestellt werden. Abbildung 3 zeigt das entwickelte Dashboard.

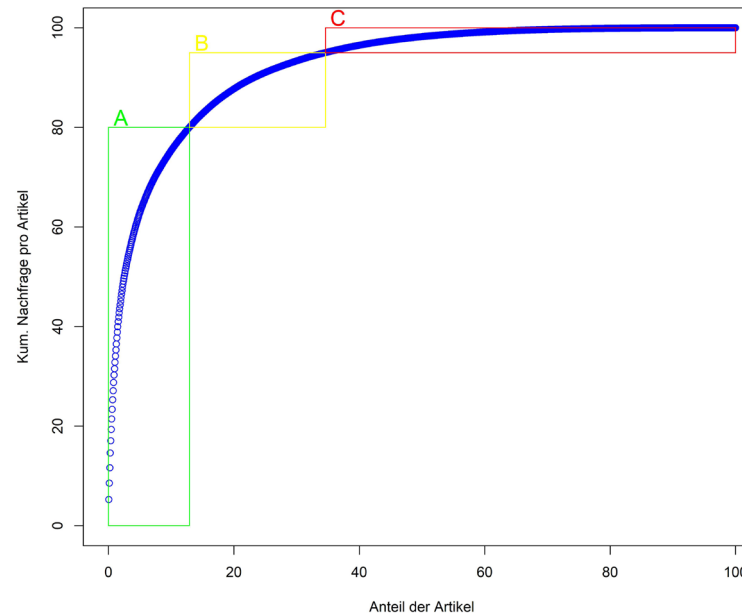
Das Dashboard gibt alle Kennzahlen In-Time an. Es ist zu sehen, wie viele Fahrer momentan im Einsatz sind, wie viele Fahraufträge offen sind, wie die aktuelle Erfüllungsquote aussieht und wie groß die momentane Auslastung ist. Zusätzlich wird angegeben wo momentane Auftragshotspots sind. Das

Unternehmen hat diesen Monitor im Einsatz und kann nun innerhalb von kürzester Zeit reagieren, falls die Erfüllungsquote absinkt oder auch zu viele Fahrer im Einsatz sind.

Die Staplerfahrer können selbst wählen, in welcher Reihenfolge sie die Aufträge abarbeiten. Durch die Bestimmung der Fahrzeitmatrix für jede Strecke ist es möglich, Simulationsanalysen durchzuführen, welche testen, wie sich verschiedene Regeln für die Reihenfolge der abzuarbeitenden Fahraufträge auf die Auslastung im Betrieb auswirken. Dazu wurde ein regelbasierter Algorithmus entwickelt und in einer Simulationsstudie getestet. Mit Hilfe der entwickelten Kennzahlen konnte ein Vergleich mit dem momentanen Ist-Zustand gezogen werden. Die Ergebnisse dieser Simulation wurden in einem Demonstrationslabor am Technologie Campus Graftenau veranschaulicht. /

/ DAS ABC DER LAGEROPTIMIERUNG

Lageroptimierung spielt in fast allen Industriebereichen eine große Rolle. Dabei gibt es bei der Lagerhaltung meist zwei Hauptprobleme. Das erste besteht darin, dass Artikel oft ohne System eingelagert werden. Dadurch entsteht ein zu hoher Transportaufwand bei der Abholung der Artikel. Das zweite Hauptproblem ist, dass keine systematische Methodik verwendet wird, um den optimalen Lagerbestand für jedes Produkt zu bestimmen. In vielen Unternehmen wird eine ganze LKW-Ladung eines Artikels bestellt und bis zu einem bestimmten Bestand verbraucht, bevor wieder nachbestellt wird. Infolge dessen wird zu viel Ware im Lager aufbewahrt, was die Lagerkosten erhöht. Bei unsystematischer Lagerhaltung steigt auch die Abholzeit des Artikels in der Intralogistik. Beide Problemstellungen können durch Daten- und Materialflussanalysen behandelt werden.

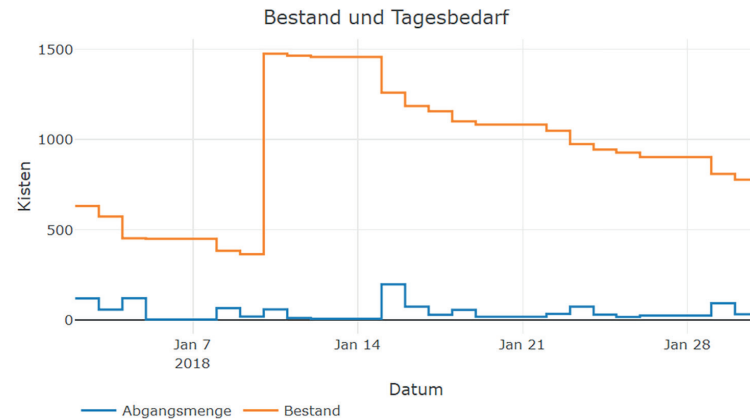
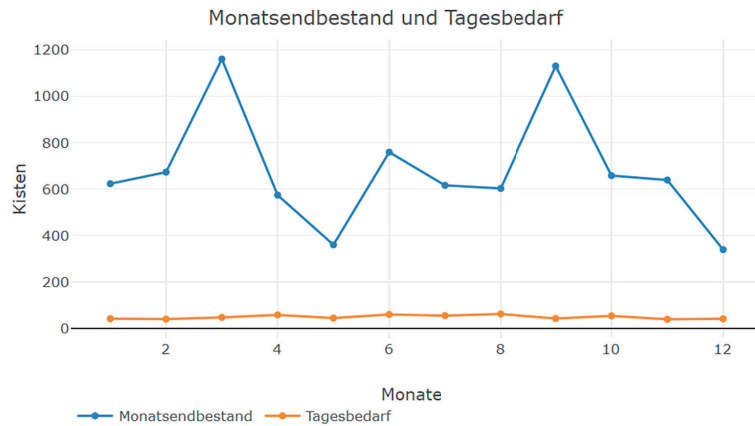


1 – ABC-Analyse

Auf Basis der Absatzdaten für das Jahr 2018 wurde eine ABC/XYZ-Analyse bei einem Getränkehersteller durchgeführt. Die Daten enthalten die Lagerbewegungen aller Artikel für das ganze Jahr. Die Artikel mit der höchsten Nachfrage werden als A-Artikel klassifiziert. B-Artikel zeichnen sich durch eine moderate Nachfrage aus. Die Artikel mit der geringsten Nachfrage sind C-Artikel. Branchenunabhängig erzeugen üblicherweise ca. 15% der Artikel (A-Artikel) fast 80% des Umsatzes, wobei knapp 65% der Artikel lediglich zu 5% des Umsatzes beitragen. Aus diesem Grund ist es ratsam mit den Artikelgruppen

unterschiedlich zu verfahren. Im Lager empfiehlt es sich z.B. die häufig benötigten A-Artikel in dem am schnellsten zugänglichen Bereich einzulagern. Abbildung 1 zeigt die für das Unternehmen durchgeführte ABC-Analyse, welche einer klassischen Verteilung entspricht.

Darauf aufbauend werden beim XYZ-Verfahren die Artikel aufgrund ihrer Umsatzregelmäßigkeiten, also ihren Absatzschwankungen, in drei verschiedene Klassen eingeteilt. X-Artikel haben einen konstanten Verbrauch und die Mengenschwankungen sind



2 – Bestand und Bedarf eines ausgewählten Artikels

eher gering. Daher lassen sich diese Artikel meist gut prognostizieren. Y-Artikel weisen stärkere Schwankungen im Verbrauch auf. Bei Z-Artikeln spricht man von völlig unregelmäßigem oder sporadischem Verbrauch.

Die Kombination aus ABC-Analyse und XYZ-Analyse liefert sehr nützliche Aussagen:

AX: Wichtiger Artikel und gut prognostizierbar.

CX: Absatzschwacher Artikel, aber gut prognostizierbar.

AZ: Wichtiger Artikel, jedoch schwer kalkulierbar.

CZ: Absatzschwacher Artikel mit sehr unregelmäßigem oder sporadischem Bedarf.

Ein weiterer Teil der Analysen ist die Bestimmung der optimalen Reichweite für jeden Artikel. Die Reichweite sagt aus, wie viele Tage der Bestand eines Artikels ausreicht, um die Verbrauchernachfrage zu befriedigen. Zunächst muss für jeden Artikel

der Tagesbedarf bekannt sein. Der optimale Lagerbestand ergibt sich durch die Multiplikation dieses Bedarfes mit einem bestimmten Faktor, der je nach Einordnung aus der ABC/XYZ-Analyse unterschiedlich sein kann. Auf diese Weise werden die Lagerbestände unter Kontrolle gehalten. In vielen Branchen ist der Tagesbedarf im Sommer jedoch höher als im Winter. Also wird ein Korrekturfaktor verwendet. Dieser Korrekturfaktor ergibt sich aus den verfügbaren Daten. Für eine Prognose in die Zukunft werden sowohl ein saisonaler als auch ein monatlicher Korrekturfaktor berücksichtigt.

Die XYZ-Analyse kann bei der Bestimmung des optimalen Lagerbestandes hilfreich sein. Je höher die Gewissheit über die prognostizierte Nachfrage, desto geringer der benötigte Lagerbestand bei verlässlicher Versorgung durch die Lieferanten. Das bedeutet, dass für AX-Artikel die niedrigsten Lagerbestände hinsichtlich der täglichen Nachfrage

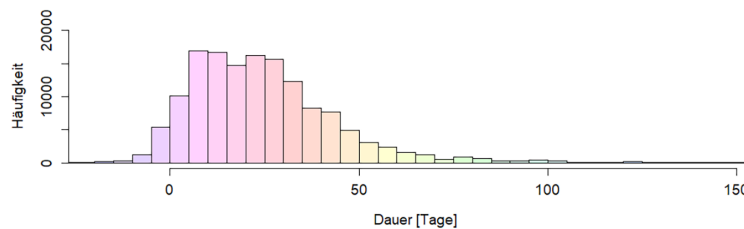
(Reichweite) bestehen sollten, da diese gut prognostizierbar sind und das gebundene Kapital reduziert werden kann.

Neben der Prognose für zukünftige Bedarfe ist auch ein historisches und aktuelles Monitoring der Daten von Vorteil. Es können dadurch überflüssige Bestände aufgedeckt oder auch schleichende Veränderungen in den Absatzmengen bemerkt werden. Abbildung 2 zeigt die Größe des Lagerbestands und den täglichen Bedarf über ein Jahr sowie über die Tage des Monats Januar 2018 für einen ausgewählten Artikel.

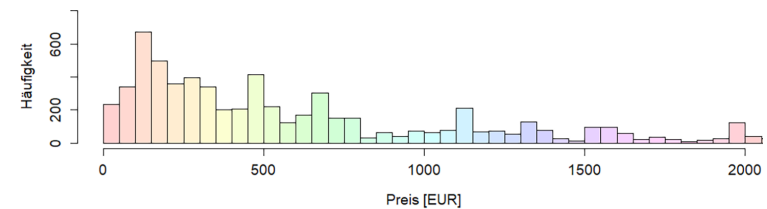
Stehen Informationen über das Werkslayout zur Verfügung, so können Simulationen aufzeigen, welche Fahrstrecke in der Intralogistik bei der aktuellen Lagerhaltung aufgewendet wird und wie sich diese durch eine optimierte Lagerhaltung verbessern lässt. /

/ AUFTRAGSDAUER UND MATERIALLAGER EINES METALLVERARBEITENDEN UNTERNEHMENS

1 – Verteilung der Auftragsdauer



2 – Verteilung der Auftragspreise



In der verarbeitenden Industrie ist die Optimierung von Produktionsprozessen und Lagerhaltung ein wichtiger Stellhebel, um Effizienzsteigerungen im Unternehmen zu erreichen. Als Beispiel wird ein Pilotprojekt mit einem metallverarbeitenden Unternehmen vorgestellt. Nach einer Unternehmensbegehung wurden die Auftragsdauern, Auftragspreise und der Bedarf von Komponenten und Rohmaterialien analysiert, um erste Optimierungspotentiale sichtbar zu machen.

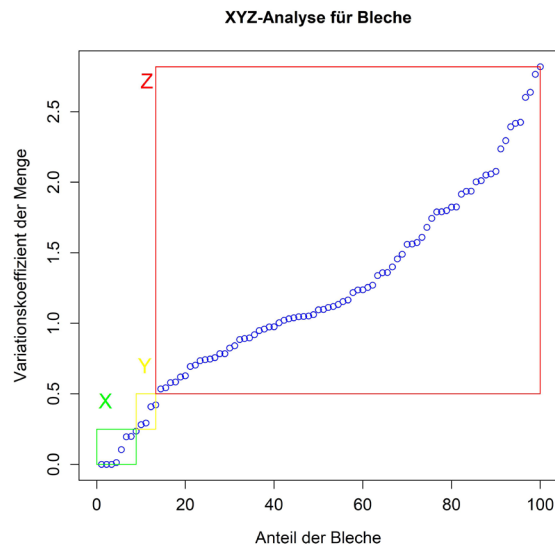
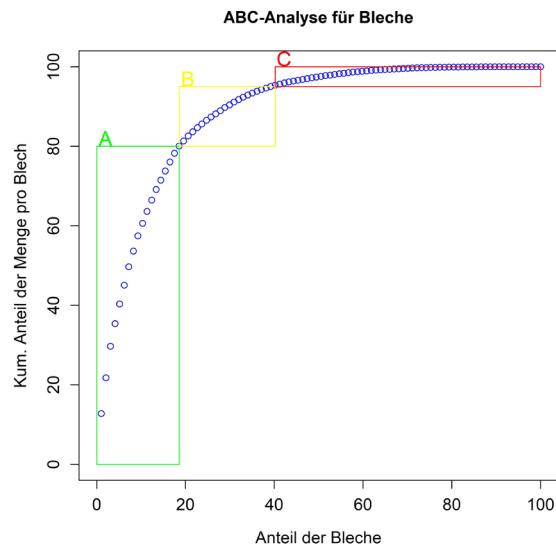
Die Auftragsdauer hängt neben den Bearbeitungsvorgängen selbst vor allem von den intralogistischen Prozessen in der Produktion, z. B. dem Transport der Rohmaterialien, ab. Die durchschnittliche

Auftragsdauer lag im vorliegenden Fall bei 26 Tagen (Median bei 22 Tagen), auffällig lang andauernde Aufträge wurden genauer untersucht. Mögliche Gründe für Verzögerungen sind beispielsweise Versorgungsengpässe oder administrative Arbeitsschritte. Die Wichtigkeit von Produktionsaufträgen hängt insbesondere von den Auftragspreisen ab. Deshalb lag der Fokus der Analysen auf den Aufträgen, mit dem größten Volumen, und den dafür benötigten Komponenten.

Ebenso wichtig war es für das betreffende Unternehmen, den Verbrauch von Komponenten und Rohmaterialien zu erfassen und daraus Ansatzpunkte zur Optimierung der Lagergestaltung zu erhalten. Die

am häufigsten verwendeten Materialien sollten an schnell zugänglichen Lagerpositionen vorgehalten werden und wenig verwendete Materialien in anderen Bereichen des Lagers. Die Bleche als Rohmaterial sind in dem Unternehmen die Hauptkomponente und es existiert eine dynamische Lagerhaltung. Man ging zunächst der Frage nach, welche Bleche am häufigsten für die Produktion benötigt werden. Etwa 19 % der Bleche decken 80 % des Blechbedarfs in der Produktion ab, wie in Abbildung 3 zu sehen ist. Allerdings werden diese Bleche teils unregelmäßig und in sehr unterschiedlichen Mengen benötigt. In Abwägung mit der Abrufbarkeit von Lieferanten und deren Lieferzeiten ist die Justierung des Sicherheitsbestands im Lager und die Lagerpositionierung

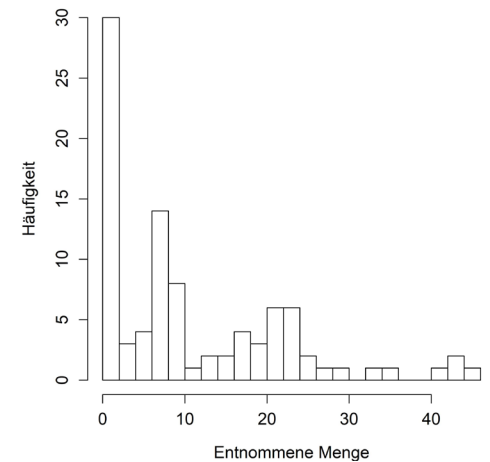
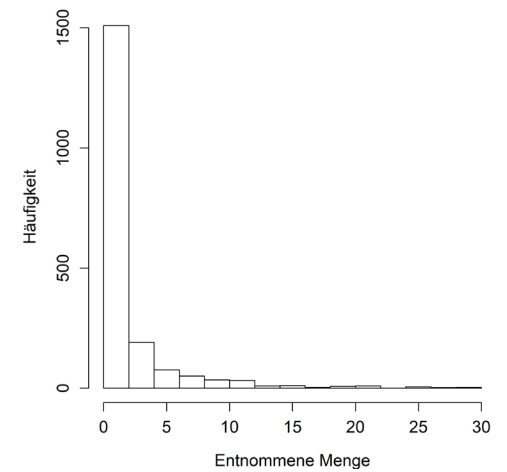
3 – ABC-Analyse und XYZ-Analyse für Bleche



äußerst wichtig. Nur acht der am wenigsten benötigten Bleche weisen einen niedrigen aber relativ regelmäßigen Verbrauch auf, der dann auch gut planbar ist. Da die Verbrauchsschwankungen bei den am meisten verbrauchten Blechen sehr stark sind, ist eine datenbasierte Bedarfsprognose nur mit hohem Risiko einsetzbar. Ein optimales Sicherheitsniveau

kann dagegen sehr wohl mit statistischen Methoden auf Basis der vorliegenden Daten berechnet werden. Mit derart berechneten optimalen Sicherheitsniveaus kann die Einhaltung eines vorgegebenen Servicelevels garantiert werden und gleichzeitig können die Bestände auf ein Mindestmaß reduziert werden. /

4 – Entnommene Mengen zweier Bleche



/ DIGITALE WERTSTROMANALYSE

Der Wertstrom beschreibt den Weg, den ein Produkt während des Entstehungsprozesses durchläuft. Schritt für Schritt wird durch jeden ausgeübten Prozessschritt direkt der Wert des Produktes gesteigert. Der Theorie nach lässt sich somit der Produktpreis eins zu eins auf die Arbeitsschritte umlegen. Es wird nur das getan, wofür der Kunde letztendlich auch bereit ist zu zahlen.

Realität oder Wunschvorstellung?

Werden entlang der Produktionskette wirklich nur Tätigkeiten ausgeübt, welche den Wert des Produktes steigern? Oder entsteht in mancher Hinsicht Verschwendung, z. B. durch aufgeblasene Prozesse, hohe Lagerbestände oder ein nicht optimales Produktionslayout?

Viele Unternehmen, gerade kleine und mittlere, können diese Fragen oft nicht beantworten, jedoch

steigt zunehmend das Bewusstsein für die Aussagekraft dieser Antworten. Die Methode der Wertstromanalyse bietet seit Jahrzehnten die Möglichkeit, eine erste grundlegende Transparenz entlang der Wertschöpfungskette zu schaffen und somit Aussagen zu den genannten Fragen zu treffen.

Als Ergebnis liefert die Wertstromanalyse ein Schaubild des betrachteten Prozesses mit all seinen wertschöpfenden, nicht-wertschöpfenden aber notwendigen, verschwenderischen Tätigkeiten, sowie den Material- und Informationsflüssen. Angereichert wird der Wertstrom mit aussagekräftigen Kennzahlen wie z.B. Prozess-, Liege- und Rüstzeiten, Beständen und Ressourcenbedarfen.

Bei der Durchführung der Methodik werden die vier charakteristischen Phasen Produktfamilienbildung, Kundenbedarfsanalyse, Wertstromaufnahme und Wertstromanalyse durchschritten.

Zu Beginn wird das zu betrachtende Produkt bzw. die Produktfamilie definiert, zu welchem im Anschluss der Kundenbedarf analysiert wird. Zur Aufnahme eines Wertstroms dienen definierte Prozessdaten und Informationen, die durch Befragung der Mitarbeiter, Messen von Zeiten oder Zählen von Beständen erhoben werden. Die relevanten Daten und Informationen werden abschließend in eine Visualisierung des Wertstromes überführt, welche durch einheitliche Wertstromsymbole erfolgt. Auf Basis der Prozessdaten lassen sich zudem definierte Kennzahlen ermitteln. Digital abgebildet werden kann mit derzeit bestehenden Softwarelösungen lediglich die Visualisierung des Endergebnisses.

In Zeiten der Digitalisierung stehen die benötigten Daten und Informationen mehr und mehr in den Systemen zur Verfügung. Weshalb in einem Projekt am Technologie Campus Grafenau der Prototyp einer digitalen Wertstromanalyse entwickelt wird, um



somit die Teile der Wertstromanalyse an geeigneten Stellen zu automatisieren. Sowohl Anwender als auch Prozessbeteiligte können dadurch unterstützt und entlastet, sowie die Aufbereitung der Analyseergebnisse beschleunigt werden. Anspruch an das Tool ist ein möglichst einfacher und intuitiver Ansatz.

Die digitale Umsetzung der vier Phasen wurde mit Fokus auf einfache Anwendungsfälle in einen ersten Prototyp überführt. Hier besteht bereits die Möglichkeit, die Bildung der Produktfamilien und den zugehörigen Kundenbedarf automatisiert aus geeigneten

Rohdaten aufzubereiten. Für die dritte Phase – der Aufnahme des Wertstroms – welche klassischerweise direkt vor Ort und analog erfolgt, beinhaltet das Tool einen Leitfaden aus definierten Leitfragen und zu erhebenden Prozessdaten. Alle erhobenen Daten und Informationen werden zentral gesammelt. Die abschließende Visualisierung des Wertstroms sowie die Darstellung relevanter Kennzahlen, erfolgt automatisiert auf Basis der in den vorhergehenden Phasen Schritt für Schritt durch den Nutzer aufbereiteten Eingaben.

Die weitere Zielsetzung des Projektes umfasst die Entwicklung einer Anwendung mit browserbasierter Benutzeroberfläche. Diese soll auch komplexe Wertströme abbilden. Parallel dienen klassische Wertstromanalysen bei Pilotprojektpartnern dazu, vielfältige Erfahrungen und tiefgehendes Praxiswissen über komplexe Wertströme in die Entwicklung einfließen zu lassen. /

MASCHINENDATEN



/ WENIGER AUSSCHUSS DURCH OPTIMIERTE MASCHINENEINSTELLUNGEN

Wie müssen Maschinen eingestellt werden?

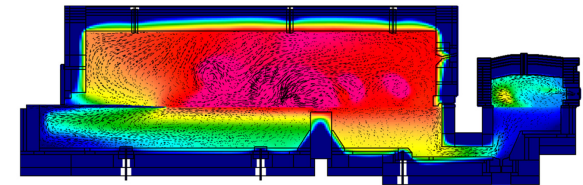
Ausschuss bedeutet Verschwendung. Ein wichtiger Einflussfaktor, um dies in der Produktion zu minimieren, ist die optimale Einstellung von Maschinen. Häufig ist das aber gar nicht so einfach, vor allem dann, wenn es viele Einstellmöglichkeiten und häufigere Wechsel in den Materialien und Produkten gibt. Aufgrund der großen Anzahl an möglichen Konstellationen ist es dann auch für erfahrene Mitarbeiter kaum mehr möglich, die Maschinenparameter optimal einzustellen, um bestmögliche Qualität zu produzieren. Hilfestellung können dann entscheidungsunterstützende KI-Systeme geben. Diese Systeme basieren auf selbstlernenden Algorithmen, die auch in komplexen Situationen versteckte Muster in den Maschinendaten erkennen können. Die künstliche Intelligenz (KI) berechnet situationsabhängig Vorschläge für eine optimale Maschineneinstellung. Neben Produktionsunternehmen interessieren sich auch zunehmend die

Maschinenhersteller selbst für solche Systeme, die sie – als Service für ihre Kunden – direkt in die Maschinen integrieren können.

Glas – ein besonders anspruchsvolles Produkt

Glasproduzenten können ein Lied davon singen, wie schwer es sein kann, Maschinen- und Anlagenparameter richtig einzustellen. Dies liegt vor allem an der Vielzahl von möglichen Einflussfaktoren auf die Qualität der Glasprodukte, wie zum Beispiel die Rohstoffzusammensetzung sowie verschiedene Temperaturen und Drucke während des Produktionsprozesses. Zwischen all diesen Faktoren gibt es komplexe und häufig unerwartete Wechselwirkungen. Fällt zum Beispiel eine Produktionslinie aus, so kann das auch Auswirkungen auf die benachbarte, eigentlich unabhängige Produktionslinie haben –

1 – Schematischer Querschnitt einer Schmelzwanne: In der Schmelzwanne werden die Ausgangsmaterialien wie Quarzsand und Pottasche unter hohen Temperaturen zu flüssiger Glasschmelze aufgeschlossen



bereits allein aufgrund der Änderung der Umgebungstemperatur. Nicht alle Faktoren können direkt beeinflusst werden und das System ist relativ träge. Da sich das Material längere Zeit in der Glasschmelze (Abbildung 1) befindet, wirken sich Änderungen erst mit einem längeren Zeitverzug auf die Qualität des Produkts aus. Dieser Zeitverzug unterliegt außerdem unbekannten Schwankungen, da sich das Material unterschiedlich lang in der Schmelzwanne befinden kann. Generell sind Messungen der Produktionsbe-

2 — Glaswolle wie sie zum Beispiel als Dämmstoff in der Baubranche verwendet wird.



dingungen aufgrund der hohen Temperaturen in der Schmelzwanne eine eigene Herausforderung. Aus diesen Gründen gibt es in der Glasindustrie ein besonderes Interesse an entscheidungsunterstützten Systemen, zumal die Glasindustrie im Vergleich zu anderen Branchen unter überdurchschnittlich hohen Ausschussquoten leidet.

Die Produktion einer perfekten Glaswolle

Im vorliegenden Fall war es das Ziel, in einem Pilotprojekt erste Wechselwirkungen zwischen den verschiedenen Produktionsparametern und der Qualität bei der Produktion von Glaswolle (Abbildung 2) zu untersuchen. Hierzu wurden die historischen Daten zu Produktionsparametern mit Qualitätsdaten verknüpft und anschließend einem maschinellen Lernverfahren übergeben.

Die Qualität der produzierten Glaswollefasern wird auf einer Skala von 1 bis 10 bewertet. Um das

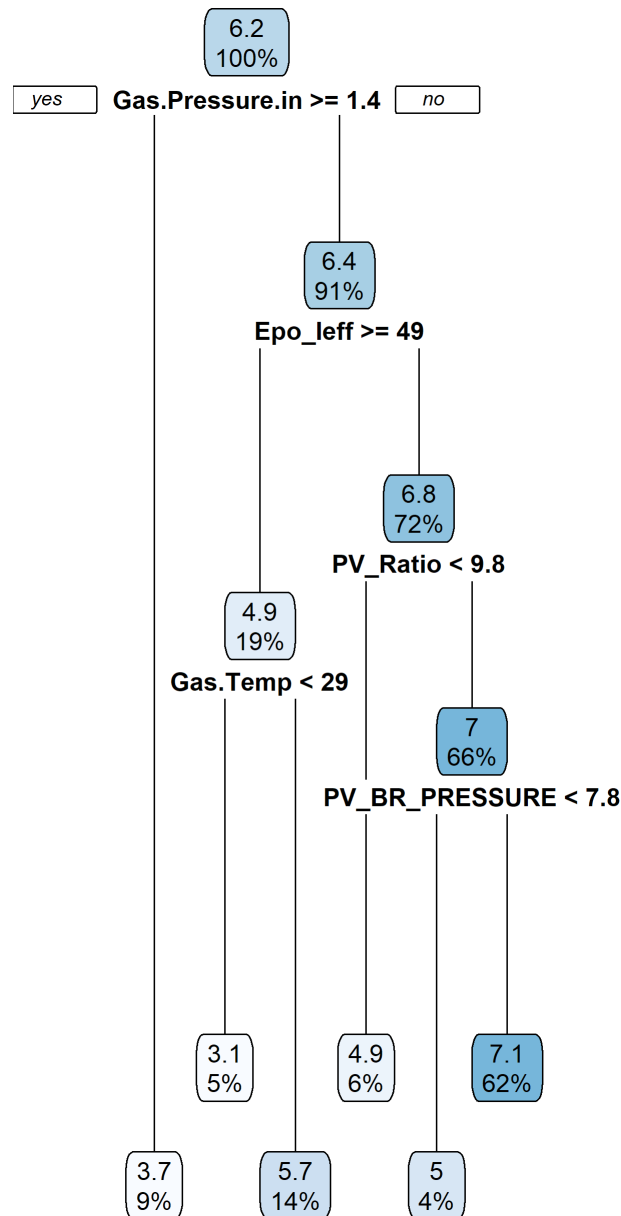
Problem aber nicht komplizierter zu machen als nötig, wurde in der Datenanalyse nicht versucht die genaue Qualität zu prognostizieren. Stattdessen wurde lediglich nach Ausschuss oder nicht Ausschuss unterschieden. Datenanalytisch handelt es sich daher um ein Klassifikationsproblem, wofür in dem Pilotprojekt beispielhaft zwei verschiedene maschinelle Lernverfahren verwendet wurden: Support Vector Machines und Entscheidungsbäume. Support Vector Machines sind ein sehr mächtiges und vielfältig einsetzbares maschinelles Lernver-

fahren. Allerdings besitzt es den Nachteil, dass das System wie eine Black-Box agiert, so dass die von der KI vorgeschlagenen Entscheidungen vom Maschineneinsteller nicht nachvollzogen werden können. Eine hohe Transparenz ist ein großer Vorteil von Entscheidungsbäumen. Abbildung 3 zeigt einen Entscheidungsbaum. Anhand dieses Entscheidungsbaums kann der Maschineneinsteller grafisch nachvollziehen, welcher Wert welchen Parameters zu welcher Entscheidung beiträgt. Dies erhöht das Vertrauen in das System und fördert so dessen Akzeptanz in der Produktion.

Mit den getesteten Verfahren konnte in ersten Berechnungen bereits eine Prognosegenauigkeit von durchschnittlich über 80% erreicht werden. Dies zeigt, dass schon mit einer relativ geringen Datenbasis und einem überschaubaren Aufwand selbst in einem komplexen Umfeld wie der Glasproduktion erste Erkenntnisse und Verbesserungen erzielt werden können. Dabei ist die Verfügbarkeit von Daten

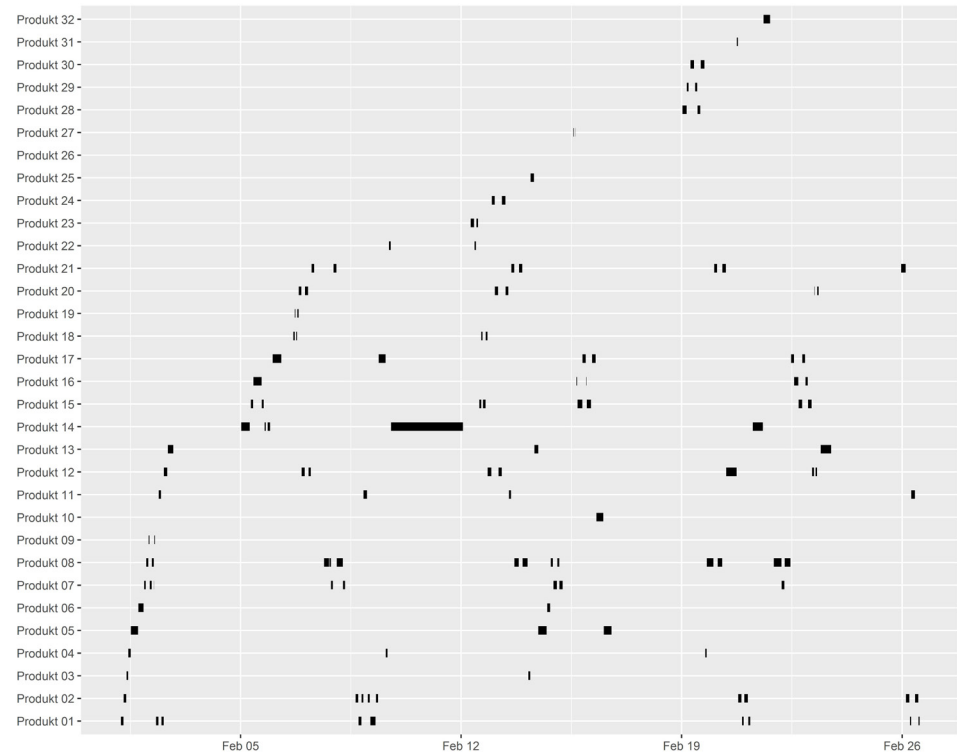
3 – Der aus den Daten errechnete Entscheidungsbaum visualisiert, welche Parametereinstellung zu welcher Qualität führt.

von entscheidender Bedeutung. Die Entwicklung eines zuverlässigen entscheidungsunterstützenden KI-Systems kann allerdings erst in einem anschließenden umfangreicheren Entwicklungsprojekt erfolgen. Gerade bei der Untersuchung von Zusammenhängen zwischen Maschinenparametern und der produzierten Qualität ist die Verknüpfung der verschiedenen Datenquellen oftmals eine besondere Herausforderung. Während die Maschinendaten meist in hoher zeitlicher Auflösung vollständig in Echtzeit vorliegen, werden Qualitätsdaten möglicherweise nur stichprobenartig und mit deutlichem Zeitverzug erhoben. Dadurch kann es schwierig sein, bei einem Ausschussprodukt nachträglich festzustellen unter exakt welchen Bedingungen es produziert wurde. /



/ PROZESSANALYSEN IN DER ELEKTRONISCHEN AUFTRAGSFERTIGUNG

1 — Produktionszeiten der verschiedenen Produkte im Zeitraum vom 01.02. bis 26.02.

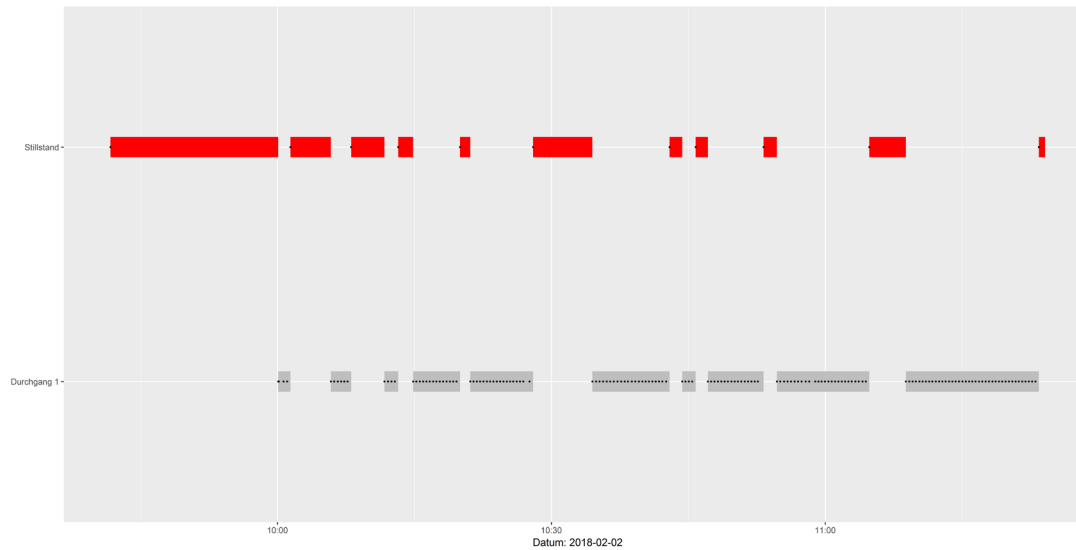


Die elektronische Auftragsfertigung zeichnet sich dadurch aus, dass Produkte meist in großer Zahl produziert werden. Die Herstellung der Produkte geschieht dabei meist in mehreren Prozessschritten, welche nacheinander vollautomatisch in einer Produktionsstraße durchlaufen werden. Dies hat den Vorteil, dass bei fehlerfreiem Betriebsablauf die Fertigungszeit optimiert werden kann. Gibt es jedoch an einer Maschine ein Problem, führt dies schon wenig später zu einem Stillstand aller Produktionsmaschinen der Fertigungslinie.

Da bei Produktwechseln alle Maschinen einer Fertigungslinie aufwendig umgerüstet werden müssen und auch immer erst eine Testreihe durchgeführt werden muss, sind Unternehmen bestrebt, ein Produkt immer möglichst lange zu produzieren, um unnötige Stillstandzeiten durch Umrüstungen und Tests zu vermeiden.

Nachfolgend werden die Ergebnisse der Prozessanalyse einer solchen Fertigungslinie in der elektronischen Auftragsfertigung von Platinen dargestellt. Zunächst wurden die Produktionszeiten einzelner Produkte untersucht. Abbildung 1 zeigt diese für eine einzelne Maschine der Fertigungslinie und für einen Zeitraum von 4 Wochen.

Es ist zu erkennen, dass Produkte nur in sehr kurzen Zeiträumen produziert werden. Oftmals gibt es Produktwechsel zu neuen Produkten und nach kurzer Zeit wird wieder das ursprüngliche Produkt produziert. An den Wochenenden wird im betreffenden Unternehmen nicht produziert. Die lange Produktionszeit bei Produkt 13 folgt daher, dass nach dem



2 — Darstellung der Taktzeiten eines Fertigungsauftrages in einer Maschine der Fertigungslinie.

Wochenende dasselbe Produkt weiter produziert wurde. Da im Unternehmen ein 3-Schichtbetrieb herrscht wird von Montag bis Freitag 24 Stunden am Tag produziert. Im betrachteten Datenzeitraum wäre eine maximale Produktionszeit von 401 Stunden pro Maschine möglich. Bei der in Abbildung 1 dargestellten Maschine wurde allein für Umrüstungen eine Zeit von 88 Stunden aufgebracht. 49 Stunden wurden dafür verwendet, die ersten Werkstücke nach einem Produktionswechsel zu testen. Von den verbleibenden 263 Stunden möglicher Produktionszeit wurde jedoch nur 149 Stunden störungsfrei produziert. Die restlichen 114 Stunden stand die Maschine durch Produktionsstau in Folge einer Störung in der Fertigungslinie.

Abbildung 2 zeigt den Verlauf eines Fertigungsauftrages in einer Maschine. Jeder schwarze Punkt in der Grafik stellt dabei den Ankunftszeitpunkt einer Platine in der Maschine dar. Wie bereits beschrieben, wird die erste Platine eines neuen Fertigungsauftrages besonders begutachtet, bevor die getaktete Fertigung beginnen kann. Daher gibt es nach Ankunft der ersten Platine einen längeren Stillstand der Maschine. Beginnt nun die geregelte Fertigung, sollten die Platinen in kurzen Zeitintervallen nacheinander in der Maschine eintreffen. Die Grafik zeigt, dass es immer wieder Unterbrechungen gibt und längere Zeit keine neuen Platinen in der Maschine ankommen. Im dargestellten Fall (Abbildung 2) wurden beispielsweise innerhalb einer Produktionszeit von 102 Minuten insgesamt 165 Platinen verarbeitet. Wären keine Bandstillstände während der Produktionszeit aufgetreten, hätte dieselbe Menge an

Platinen in 60 Minuten produziert werden können. Die Effizienz der Maschine beträgt bei diesem Fertigungsprozess daher nur 59%.

Abschließend wurde noch die Fehlerhäufigkeit beim Fertigungsprozess untersucht. Von über 13.700 untersuchten Platinen wurde bei fast 11.000 Platinen mindestens ein Fehler auf der Platine angezeigt. Dies entspricht gut 80% aller Platinen. In mehr als 98% der Fälle handelt es sich dabei um Pseudofehler, welche keine Relevanz für die Produktqualität haben. Jedoch müssen alle angezeigten Fehler von einem Mitarbeiter kurz betrachtet werden. Die Analyse der Produktionsdaten zeigt daher ein enormes Potential für Optimierungen im Produktionsablauf auf. In der Folge wird im Unternehmen nun ein automatisiertes Monitoring von weiteren Maschinen und Fertigungslinien aufgebaut. /

/ STROMDATENANALYSE UND -MONITORING ALS EINSTIEG IN DIE PROZESSOPTIMIERUNG

Der Stromverbrauch spielt in nahezu allen Unternehmen und in jeder Branche eine wichtige Rolle. Viele Unternehmen bezahlen für ihren Stromverbrauch einen festen Tarif. Wird eine festgelegte Spitzenlast überschritten, müssen sie einen Spitzenstromzuschlag bezahlen. Dieser wird jedoch nicht nur für die Zeit der Überschreitung dieses Schwellenwertes, sondern gleich für einen längeren Zeitraum fällig. Daher ist es wünschenswert, dass diese Spitzenstromlast nicht überschritten wird.

Durch eine Analyse des Stromverbrauches der Produktionsmaschinen im Unternehmen lässt sich feststellen, wie hoch der Stromverbrauch der Maschinen je nach Tätigkeit ist. Neben der Kalkulation der Kosten können so auch Prozesse in der Hinsicht optimiert werden, dass möglichst alle Maschinen ausgelastet sind, der Spitzenstromverbrauch jedoch

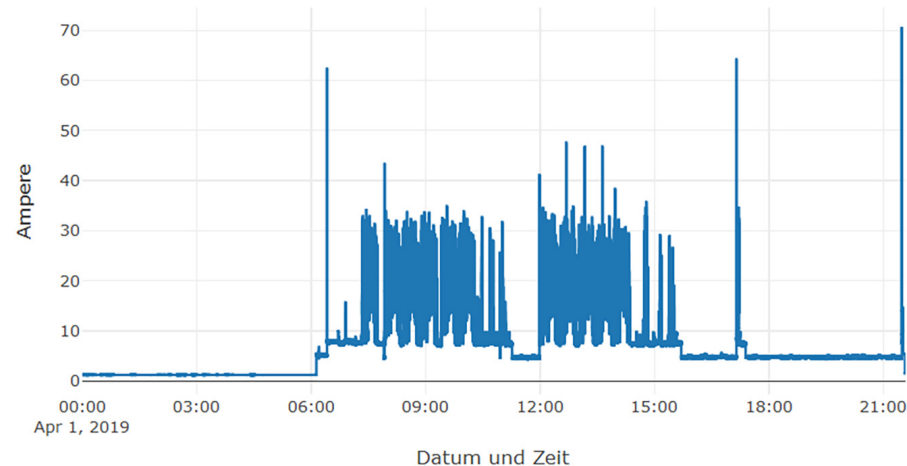
einen gewissen Schwellenwert nicht übersteigt. So könnten Fertigungsprozesse zukünftig auch verbrauchsoptimiert geplant werden.

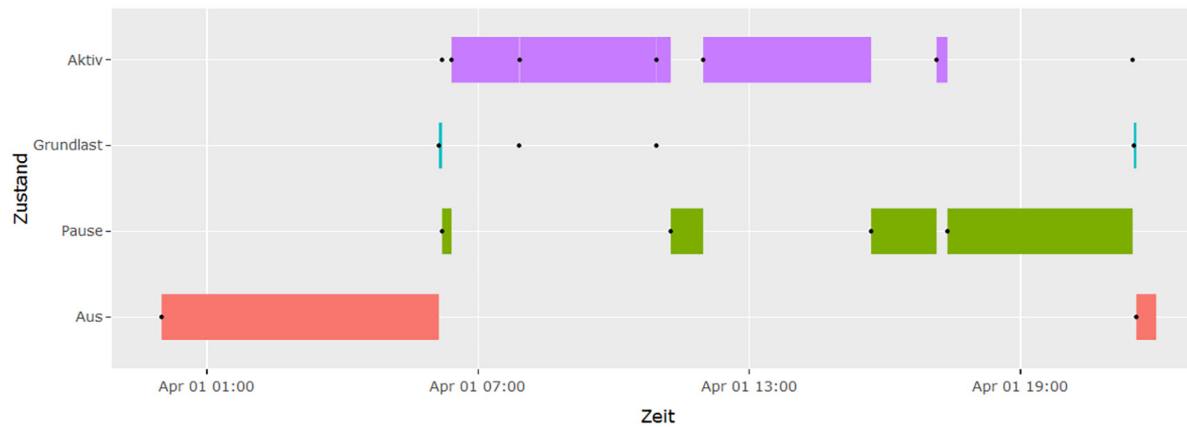
Nachfolgend werden die ersten Schritte und Ergebnisse einer solchen Stromdatenanalyse geschildert und Möglichkeiten der Erweiterung dieser Analysen für eine Prozessoptimierung vorgestellt. Für die durchgeführten Analysen wurde an fünf verschie-

denen Maschinen je ein Strommessgerät angeschlossen, welche sekundlich den Stromverbrauch abfragen und in eine Datenbank einspeisen. Ein typischer Tagesverlauf einer dieser Maschinen findet sich in Abbildung 1.

In der Abbildung lässt sich erkennen, dass die Maschine um kurz nach 06:00 Uhr morgens eingeschaltet wird. Ebenso ist erkennbar, wann sie sich

1 — Stromverbrauch einer Stanz- und Lasermaschine an einem Tag





1 — Aktivitätsdiagramm einer Stanz- und Lasermaschine an einem Tag

im Ruhezustand, Abkantvorgang oder Laservorgang (höhere Ausschläge) befindet. Es kann daher ebenfalls analysiert werden, wie viel Anteil welcher Vorgang im Tagesverlauf hat. Darstellen lässt sich dies z.B. über ein Zustandsdiagramm wie in Abbildung 2.

An diesem Tag war die Maschine 30 % des Tages ausgeschaltet. Ebenfalls 30 % der Zeit war der Verbrauch der Maschine nur auf einem niedrigen Niveau: da sie entweder eingeschaltet war, aber nicht benutzt wurde (z. B. Pausen), oder da die Maschine während der Arbeit immer wieder kurze Phasen nur die Grundlast benötigte (z. B. in der Zeit des Blechdrehens beim Stanzvorgang).

Neben diesen Betrachtungen kann neben der Stromstärke auch die Scheinleistung der Maschinen

berechnet werden und man erhält einen stetigen Überblick über die verursachten Stromkosten jeder Maschine. Die Verbräuche der Maschinen können über die Zeitstempel aufsummiert werden. Sind alle Maschinen an je einem Stromzähler angeschlossen kann der Gesamtstromverbrauch und die Stromlast zu jedem Zeitpunkt ermittelt werden.

Werden noch dazu die Zeiten hinterlegt, wann welche Produkte auf einer Maschine produziert wurden, kann man Stromverbrauchsmuster für jeden Prozess hinterlegen. So wird es möglich auch prädiktive Analysen durchzuführen. Es können Abschätzungen über zukünftige Stromkosten getroffen werden. Eine optimierte Produktionsplanung zur Vermeidung von Stromspitzen ist bereits im Vorhinein möglich. Sind Schwankungen in den Strompreisen bekannt, ist

eine Berücksichtigung dieser insofern möglich, dass stromintensive Prozesse zu den Zeiten durchgeführt werden, zu denen die Preise niedrig sind.

Ein weiterer Ansatzpunkt für die Nutzung der Stromdaten ist die vorrauschauende Maschinenwartung. Sind Stromverbrauchsmuster für alle Prozesse hinterlegt, können zukünftige Abweichungen von diesen Mustern erkannt werden. Diese lassen einen Hinweis auf den Verschleiß der Maschinen zu. Damit entsteht die Möglichkeit einer frühzeitigen Kontrolle, ob eine Wartung der Maschine notwendig ist. /

/ AUF DEM WEG ZUR DATA DRIVEN COMPANY

Unzählige Praxisbeispiele zeigen mittlerweile, dass Unternehmen enorm davon profitieren können, wenn sie Daten systematisch analysieren und nutzen. Allerdings zeigt sich in der Praxis auch immer wieder, dass Unternehmen mit Datenanalyse-Projekten scheitern und sich der erwartete Nutzen nicht einstellt. Grund dafür sind eine Reihe von Fehlern, die Unternehmen häufig bei der Durchführung von ersten Datenanalyse-Projekten begehen. Das kann fatale Folgen haben. Zum einen bedeutet ein gescheitertes Projekt zunächst eine Verschwendung von Ressourcen. Weit schlimmer aber ist die Konsequenz für das weitere unternehmerische Handeln. Scheitert das erste große Data Analytics Projekt, dann ist das Thema innerhalb des Unternehmens für die nächste Zeit „verbrannt“ und es werden keine weiteren Projekte mehr gestartet. Der Weg zur Data Driven Company ist erst einmal verbaut, das Unternehmen fällt in diesem Bereich hinter die Konkurrenz zurück. Um dies zu verhindern, gehen wir etwas genauer auf die häufigsten Fehler ein und wie diese vermieden werden können.

Auswege aus den häufigsten Fehlern bei Data Analytics Projekten

Fehler Nr. 1:

— Zu viel Gewicht auf das Sammeln von Daten

Zweifellos gibt es keine Datenanalyse ohne Daten. Viele Unternehmen tätigen daher zunächst große Investitionen in das Sammeln von Daten und verschieben die Datenanalysen auf später, wenn Daten in großem Stil gesammelt, in einer Datenbank gespeichert und systematisiert wurden. Hierbei entstehen aber zunächst ausschließlich Kosten, denn ein Mehrwert wird erst durch die Nutzung der Daten erzeugt. Die Gefahr liegt darin, dass die „Vorarbeiten“ kein Ende nehmen und mit den Analysen erst zu spät (oder gar nicht) begonnen wird. Oftmals stellt sich auch erst bei den Analysen heraus, welche Daten gebraucht werden. Wenn diese erforderlichen Daten nicht erhoben wurden, muss mit dem Datensammeln erst wieder neu begonnen werden. Daher ist es besser schon frühzeitig mit ersten Analysen auf den bereits vorhandenen Daten zu beginnen. Dann zeigen sich schnell erste Erfolge und es ist frühzeitig klar, welche Daten tatsächlich erfasst und gespeichert werden müssen.

Fehler Nr. 2:**— Zu wenig Ressourcen für die Datenanalyse**

Datenanalyse kostet Ressourcen und viele Unternehmen investieren zu wenig in die Datenanalyse. Dies ist umso bemerkenswerter, da die Erhebung, Speicherung und Verwaltung der Daten sehr hohe Kosten verursacht, aber der Mehrwert erst durch gute Analysen entsteht. Kosten sollten daher eher beim Datensammeln eingespart werden und nicht beim Nutzen der Daten. Denn wenn die Daten nicht mit dem erforderlichen Aufwand und der erforderlichen Qualität analysiert und genutzt werden, dann war die Erhebung, Speicherung und Verwaltung der Daten schließlich vergeblich. Für eine gute Analyse müssen ausreichend zeitliche Ressourcen und finanzielle Mittel bereitgestellt werden. Weil der Mehrwert der teuer erkauften Datenbestände allein durch die Analyse entsteht, sollte diese zur Chefsache werden und gehört nicht in die Verantwortung eines Praktikanten.

Fehler Nr. 3:**— Zu geringe Fokussierung auf konkrete Use Cases**

In vielen Fällen werden Data Analytics Projekte gestartet, in denen lediglich der zu untersuchende Datenbestand definiert wird. Der Arbeitsauftrag an den Datenanalysten lautet dann, in diesem Datenbestand nach „interessanten Erkenntnissen“ zu suchen. Ohne ein konkretes Ziel oder einem klar definierten Use Case, entsteht in solch

allgemeinen Analysen erfahrungsgemäß aber kaum ein Mehrwert. Meist findet der Datenanalyst in den Daten dann nur ohnehin bekannte Muster wieder. Am Beginn der Analysen sollte daher nicht vordergründig die Auswahl des Datensatzes stehen, sondern in erster Linie die konkrete Fragestellung, die durch Datenanalysen beantwortet werden soll.

Fehler Nr. 4:**— Zu frühe Festlegung auf spezielle Methoden wie Neuronale Netze**

Data Analytics wird in Publikationen und auf Veranstaltungen von starken Trendthemen wie Deep Learning oder Neuronale Netze dominiert. Oftmals erfolgt daher bei Data Analytics Projekten bereits zu Beginn eine Vorfestlegung auf spezielle, besonders angesagte Methoden. Dies geschieht nicht aus inhaltlich wohlüberlegten Gründen, sondern lediglich aufgrund der besonderen medialen Präsenz dieser Methoden. Neuronale Netze sind nur eines von vielen möglichen alternativen Verfahren aus dem Bereich des maschinellen Lernens – und maschinelle Lernalgorithmen sind nur eine relativ kleine Gruppe unter vielen anderen möglichen Datenanalyseverfahren. Dabei sind maschinelle Lernalgorithmen bei Weitem nicht immer die beste Wahl für die Lösung eines Datenanalyseproblems. Sich von vornherein auf Deep Learning oder Neuronale Netze festzulegen, ist deshalb auch in etwa so, als würde sich der Arzt schon vor der Untersuchung des Patienten auf eine bestimmte Therapie festlegen.

Fehler Nr. 5:**– Zu wenig Datenanalyse-Kompetenz**

Die Vorfestlegung auf eine bestimmte, medial besonders präsen- te Datenanalysemethode (Fehler Nr. 4) erfolgt häufig aufgrund mangelnder eigener Datenanalyse-Kompetenz. Erst durch die Analyse entsteht aus den Daten ein Mehrwert und diese Analyse benötigt entsprechend Zeit, Personal, Wissen und Fachkompetenz. Wenn dies im Unternehmen nicht vorliegt, muss es aufgebaut oder als Dienstleistung einge- kauft werden. Stets sollte dabei beachtet werden, dass es besser ist keine Datenanalyse durchzuführen als eine qualitativ schlechte Daten- analyse. Denn fehlerhafte Ergebnisse können in die falsche Richtung weisen mit möglicherweise fatalen Folgen und Fehlentscheidungen.

Fehler Nr. 6:**– Zu große Anfangsprojekte**

Entsprechend der herausragenden Bedeutung von Big Data ist die Versuchung groß, gleich mit einem breit angelegten Großprojekt zu starten. Ein solches Vorgehen ist aber riskant, da sich häufig erst im

Verlauf der Analysen zeigt, ob die Daten wirklich den erwarteten Mehrwert besitzen, der sich für den Unternehmenserfolg nutzen lässt. Es ist daher besser zunächst mit mehreren Kleinprojekten zu starten und dann die erfolgreichsten Ansätze weiter zu verfolgen.

Fehler Nr. 7:**– Zu hohe Erwartungen**

Durch die starke mediale Präsenz werden oftmals unrealistisch hohe Erwartungen geschürt. Wie in vielen erfolgreichen Praxisbeispielen gezeigt wurde, kann Data Analytics richtig angewendet und mit ent- sprechenden gezielten Investitionen einen bedeutenden Nutzen für den Unternehmenserfolg liefern. Aber ebenso haben viele Praxisbei- spiele gezeigt, dass Data Analytics kein Allheilmittel ist und manchmal die Daten eben auch keinen wirklich nutzbaren Mehrwert enthalten. /

Herausgeber

THD – Technische Hochschule Deggendorf
Technologie Campus Grafenau
Forschungsteam „Business Data Analytics & Optimization“
Hauptstraße 3
94481 Grafenau

Ansprechpartnerin:
Magdalena Gruber
Tel: +49 (0)8552/ 97 56 20-64
E-Mail: info.data-analytics@th-deg.de
www.th-deg.de/de/tc-grafenau

Juni 2019



Big Data Centrum

Das Projekt „Big Data Zentrum Ostbayern-Südböhmen“ wird gefördert durch:



Europäische Union
Europäischer Fonds für
regionale Entwicklung



Ziel ETZ
Freistaat Bayern –
Tschechische Republik
2014 – 2020 (INTERREG V)

