

Schlussbericht

zu IGF-Vorhaben Nr. 18566 BR

Thema

Produktionslogistische Auftragsabwicklung mit Topologiebausteinen

Berichtszeitraum

01.01.2017 - 31.08.2019

Forschungsvereinigung

Bundesvereinigung Logistik (BVL) e. V.

Forschungseinrichtung(en)

TU Dresden - Professur für Technische Logistik (TL)

Dresden, 17.12.2019

Prof. Dr.-Ing. habil. Thorsten Schmidt

Ort, Datum

Name und Unterschrift aller Projektleiterinnen und Projektleiter der
Forschungseinrichtung(en)

Gefördert durch:



Bundesministerium
für Wirtschaft
und Energie

aufgrund eines Beschlusses
des Deutschen Bundestages

Hinweis: Bei der projektausführenden Stelle kam es zu Verzögerungen bei der Besetzung der zugehörigen Stelle. Die Bearbeitung des Forschungsprojektes begann deshalb erst am 01.09.2017.

1. Kurzfassung der Ergebnisse (Gegenüberstellung der durchgeführten Arbeiten und des Ergebnisses mit den Zielen.)

Im Rahmen des Projektvorhabens wurde eine Methode entwickelt, die für sehr variantenreich produzierende Unternehmen Lücken in der Plandatenbasis kompensiert und so eine robuste Planungsgrundlage generiert. Dies ermöglicht eine Produktionsplanung, die auf individuelle Kundenwünsche reagieren kann ohne den Steuerungsaufwand zu erhöhen und operativ in die Steuerung einzugreifen. Hierfür wurde ein Softwaretool entwickelt, das aus historischen Datensätzen, die aus gängigen ERP-Systemen zur Verfügung gestellt werden, Plandaten wie Produkt- und Prozessdaten mittels Machine Learning Algorithmen vorhersagt. Die Vorhersage wird durch eine Auftrittswahrscheinlichkeit und eine Abgleichwahrscheinlichkeit bewertet und kann so in die Planung eingebunden werden. Mit dem Wahrscheinlichkeitsabgleich wird ein kapazitiver Puffer aufgebaut um die Planung in ihrer Robustheit zu unterstützen. Die erzielten Ergebnisse sind also eine Ergänzung zu der in KMU üblichen Meistersteuerung. Es wird eine bessere Planbarkeit von Ressourcen und Materialien erreicht, was eine komplexe operative Steuerung verringert.

Die Anwendungsmöglichkeiten liegen insbesondere im produzierenden Gewerbe mit sehr variantenreichem Produktportfolio. Dabei zielt das entwickelte Tool auf die Vereinfachung der Planung und Steuerung neuartiger Produkte, indem Vorhersagen auf Grundlage von historischen Daten gemacht werden. Denkbar wäre diese Anwendung auch für eine längerfristige Planung in produzierenden Unternehmen. Somit könnten Anwendungen sowohl in der strategischen Planung, als auch in der Produktionsprogrammplanung gefunden werden. Ein entscheidender reglementierender Faktor hierbei ist jedoch die Datengrundlage, die speziell bei KMU sehr stark schwankt. Ohne ein gewisses Maß an Selbstdisziplin zum Sammeln von Produktionsdaten werden digitale Maßnahmen zur Produktionseffizienzsteigerung nicht optimal angewendet werden können.

2. Durchgeführte Arbeiten im Berichtszeitraum

- **(AP1) Analyse und Definition von Datengrundlage und Anforderungen**

AP1.1 Definition des Anforderungsprofils von KMU

Das Anforderungsprofil von KMU zu definieren ist die Grundlage zur Bearbeitung des Projektes. Deshalb wurde das Anforderungsprofil für sehr variantenreich produzierende Unternehmen zusammen mit dem PA erarbeitet. Hierzu wurde ein Workshop im Rahmen eines Kick-Off Meetings veranstaltet um die das Anforderungsprofil direkt mit dem Projektausschuss zu erarbeiten. Bei dem Gespräch und der anschließenden Diskussion sind folgende Anforderungen zusammengetragen worden:

- Kompensation von Datenlücken in Produktstruktur, Prozessketten und Einzelprozesszeiten durch Schätzungen anhand historischer Daten, wobei sich die Schätzmethode auf wenige, allgemein verfügbare Datenattribute beschränkt. Diese sind Produktmaße, Arbeitspläne und Prozesszeiten.
- Entwicklung einer vereinfachten MRPII-Planungsmethode, die unscharfe Daten verarbeiten kann.
- Entwicklung einer vereinfachten und robusten Steuerungsmethode, die unscharfe Daten einbinden kann. Hierbei wird die übliche Meistersteuerung nicht ersetzt, sondern sinnvoll ergänzt.
- Die Methoden müssen außerdem mit den KMU-typischen Abstufungen in der Datenqualität zurechtkommen.
- Die neu zu entwickelnden Methoden sollen ein hohes Maß an Automatisierung in die Planungs- und Steuerungsprozesse von KMU bringen.

AP1.2 Definition und Analyse der Datengrundlage

Mit Hilfe der in AP 1.1 erarbeiteten Anforderungen können die zu Grunde liegenden Daten für die Auftragsabwicklung analysiert werden und für das weitere Vorgehen verallgemeinert und in einer Definition beschrieben werden.

Wie schon in den Anforderungen beschrieben wurde, können in Auftragsystemen mit steigender Variantenanzahl zunehmend lückenhafte Plandaten vorgefunden werden. Ziele ist es diese Lücken in den Plandaten zu kompensieren, das heißt eine Vorhersage der Daten mit einer definierten statistischen Wahrscheinlichkeit zu erreichen. Die entwickelten Methoden hierzu müssen mit der in KMU typischen abgestuften Datenqualität und oft auch Quantität zurechtkommen. Wird eine geeignete Vorhersage erreicht, kann ein hohes Maß an Automatisierung im Planungs- und Steuerungsprozess erreicht werden.

Die Vorhersage der Plandaten bringt ein berechenbares Abweichungsrisiko mit sich, mit dem die eingesetzte MRPII-Planungsmethode zurechtkommen muss. Das heißt die Planungsmethode muss eine gewisse Robustheit besitzen um die generierten Daten verarbeiten zu können.

Als letzter Schritt wird das Abweichungsrisiko als Steuerungsparameter in eine robuste Steuerungsmethode integriert. Hierbei werden vorhandene Methoden adaptiert. Die übliche Meistersteuerung wird nicht ersetzt, diese soll sinnvoll ergänzt werden. Die aufgeführten Definitionen werden in Abbildung 1 zusammengefasst dargestellt.



Abbildung 1: Übersicht zum allgemeinen Vorgehen zur Erreichung der Projektziele

AP1.3 Analyse und Vergleich von Steuerungsparametern

Die Produktionssteuerung speziell in KMU obliegt dem jeweiligen unternehmerischen Zielsystem. Das heißt eine Vereinheitlichung von Steuerungsparametern und deren Steuerungsmethoden führt nur zu einer sehr groben Lösung und muss bei einem Transfer explizit angepasst werden. Aus diesem Grund werden Steuerungsparametrik und Steuerungsmodelle nur konzeptionell betrachtet.

Benötigte Steuerungsparameter in Abhängigkeit an die Zielgrößen:

- Durchlaufzeit
- Termintreue
- frühestmögliche Fertigung.

Hierbei ist auf die gegenseitige Abhängigkeit zu achten um die Zielkonsistenz sicherzustellen.

Dies wird durch folgende notwendige Parameter erreicht:

- Berücksichtigung Abweichungsrisiko im Rahmen der Planung
- Berücksichtigung Kapazitätsbeschränkung
- Maßnahmen zur Kapazitätsanpassung

- **(AP2) Entwicklung Planungssystematik für unscharfe Daten**

AP2.1 Entwicklung von Planungsmethoden bei unscharfen Daten

Besondere Anforderungen im Bereich der Planungsverfahren bestehen vor dem Hintergrund der Anwendung in KMU. So muss von einer Fertigungssteuerung ohne MES ausgegangen und damit der operativen Ebene eine gewisse Flexibilität in der Auftragsabfertigung gewährt werden. Gesucht wird demnach ein schlankes PPS, das eine robuste Grobplanung ermöglicht und die in KMU übliche Meistersteuerung unterstützt.

Für die Umsetzung des Planungssystems wurde die taktbasierte Fertigungssteuerung als passendes Konzept identifiziert, da es neben den allgemeinen Voraussetzungen zur Anwendung in KMU in besonderer Weise für die Verwendung von unscharfen Eingangsdaten geeignet ist: So sieht die taktbasierte Fertigungssteuerung explizit vor, dass kleinere Abweichungen auf operativer Ebene abgefangen werden, sodass eine Neugenerierung des Fertigungsprogramms durch die Absprache mit nachgelagerten Prozessen oftmals vermieden werden kann. Des Weiteren ergeben sich bei dem Verfahren implizite Pufferzeiten, da eine Übergabe zum nächsten Prozessschritt nur zum vollen Takt möglich ist. In Verbindung mit den unscharfen Eingangsdaten bzw. den entsprechenden Unsicherheitsparametern können diese Pufferzeiten aktiv genutzt werden, um Kapazitäten für mögliche Abweichungen vorzuhalten.

Für die Berücksichtigung unscharfer Primärdaten muss das Planungsverfahren zwingend über eine robuste Kapazitätsplanung verfügen. Klassische MRPII-Verfahren lösen dies in der Regel über nachgelagerten Prozesse, die die Ergebnisse der MRP-Kernalgorithmus überprüfen und korrigieren. JODLBAUER und REITNER (2012) hingegen konzipieren mit Material and Capacity Requirements Planning (MCRP) ein Verfahren, das eine Kapazitätsplanung innerhalb dieses Kernalgorithmus ermöglicht. Dadurch können unscharfe Daten mit ihren weitreichenden Einflüssen im Planungsprozess möglichst früh berücksichtigt werden. Das angewandte Verfahren zur Kapazitätsermittlung eignet sich zudem gut für die angestrebte taktbasierte Planungsmethodik. Abbildung 3 stellt die grundlegenden Planungsschritte des MCRP-Algorithmus dar.

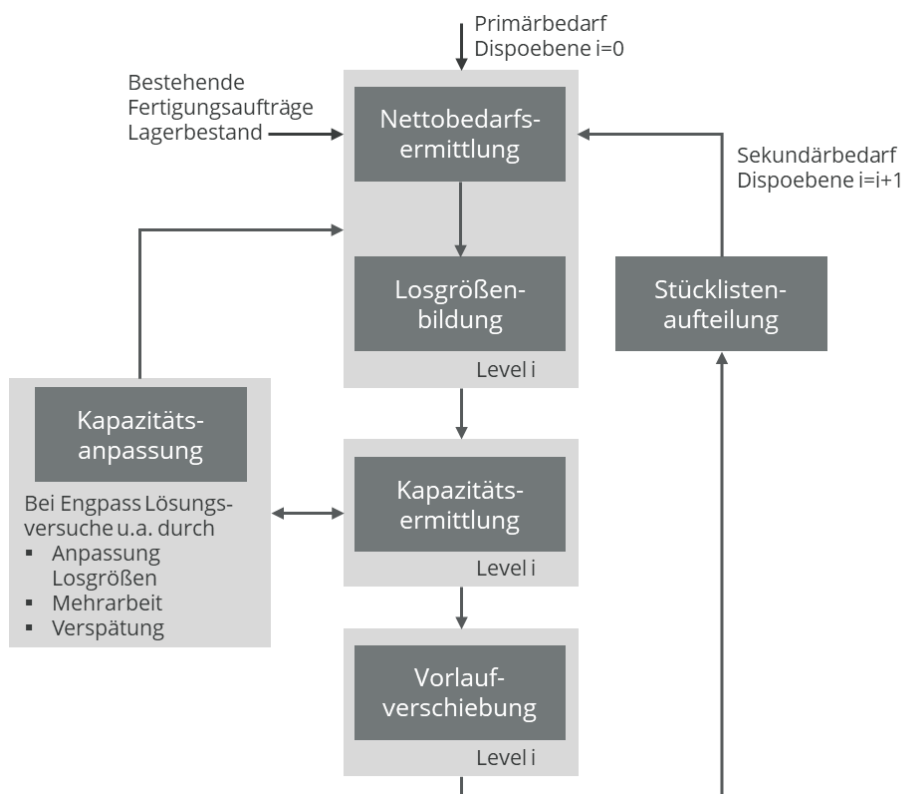


Abbildung 2: Darstellung des MCRP Algorithmus

Die wesentlichen Unterschiede zu einem klassischen MRP-Verfahren liegen hierbei im Schritt der Kapazitätsermittlung, dessen Ergebnisse direkt von der Vorlaufverschiebung genutzt werden können, sowie in der Kapazitätsanpassung, die sich drohender Engpässe annimmt. Für die Planung mit unscharfen Daten wurde das Verfahren im Bereich der Kapazitätsplanung erweitert,

sodass ein Abweichungsrisiko für einzelne Fertigungsaufträge festgestellt und als Parameter in die Steuerung eingebunden werden kann.

AP2.2 Entwicklung von Methoden zur Erzeugung der Primärdaten

Um eine robuste Planung zu Entwickeln bedarf es einer soliden Datengrundlage. Genau diese ist bei KMU nicht zwingend gegeben. So müssen Methoden gefunden werden die vorhandenen Daten sinnvoll zu bearbeiten, bzw. zu ergänzen. Im Betrachtungsrahmen sind zwei Arten von Datenlücken vorzufinden. Zum einen Datenlücken durch unzureichende Aufzeichnung von Produkt und Produktionsdaten und zum anderen Datenlücken die durch eine große Variation von Produkttypen auftreten. Diese Art von Daten soll kompensiert werden. Hierfür eignet sich das Machine Learning als Vorhersagemodell besonders gut. Aus historischen Daten wird künstlich neues Wissen generiert. Dabei verallgemeinern die Algorithmen nach einer Lernphase die Datengrundlage aufbauend auf einem statistischen Modell. So können dem trainierten System neue Daten zugeführt werden und dieses bewertet mit den erlernten Mustern und Gesetzmäßigkeiten.

Für die Entwicklung in diesem Projekt kommt das überwachte Lernen in Frage. Gegeben sind Datensätze von Paaren aus Ein- und Ausgabe. Aus diesen historischen Datenpaaren generiert der Algorithmus eine Funktion, die dem Eingabewert einen Ausgabewert zuordnet. Die verwendeten Algorithmen werden mit ihrer Trefferwahrscheinlichkeit bezüglich der Vorhersage bewertet. Ziel ist es die Trefferwahrscheinlichkeit so hoch wie möglich einzustellen. Das allgemeine Vorgehen sieht wie folgt aus;

- Datenimport
- Datenaufbereitung
- Auswahl des ML Algorithmus und dessen Training
- Modellauswertung

Am Anfang steht der Datenimport und die Begutachtung dieser. Zudem müssen die Attribute nach denen gelernt wird festgelegt werden. Dies variiert nach Ausrichtung der Firmen und dem angebotenen Produktspektrum. Eine automatisierte Erfassung der Daten muss im Einzelfall immer angepasst werden, da ERP System und allgemeine Erfassung von digitalen Daten variieren. Demnach ist eine Automatisierung bzw. verallgemeinerte Methodik hier schwer umsetzbar. Bezogen werden in jedem Fall die Stücklistendaten der Produktgruppen und die Arbeitspläne mit, wenn vorhanden, dazu gehörigen Prozesszeiten. Die Abbildung 3 verdeutlicht wie die Attribute mit den Produkten P_n vernetzt sind. Man kann sich das Ganze auch als Matrix vorstellen um Ein und Ausgabe nachzuvollziehen.

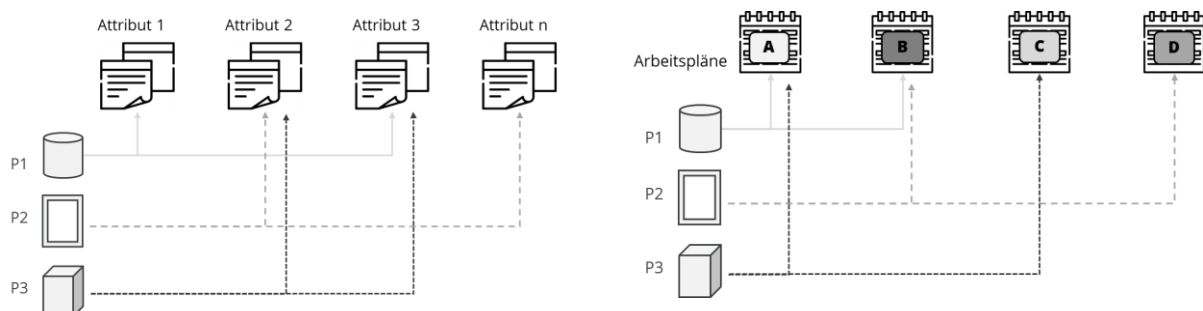


Abbildung 3: Zuordnung von Produkttypen und deren Attribute

Bei der Analyse der Datengrundlage wurden Attribute mit einfachen Kennzeichen für die Datenvorhersage ermittelt. Diese sind zum Beispiel, Werkstoff, Beschichtung, Maße und Masse. Zudem kommen Prozessfolgen und Prozesszeiten für eine Vorhersage in Frage. Üblicherweise können die Daten hierfür aus den benutzten ERP Systemen abgegriffen werden. Bearbeitungszeiten für Arbeitspläne liegen meist nicht digital vor. Diese Daten werden durch die zuständigen Meister verwaltet. Das Wissen wird hier durch Experten und deren Erfahrungswerten gespeist.

Die gesammelten Daten müssen zunächst für die Algorithmen lesbar gemacht werden. Dies bedeutet eine Überprüfung der Schreibweisen, Punctuation, Dubletten und Fehlstellen sowie das Beheben dieser Abweichungen. Zudem werden die Daten binarisiert und skaliert wieder abgespeichert. Die Arbeitspläne werden, sofern sie digital erfasst werden, in Prozess- und in einer weiteren Skalierung in Sequenzbibliotheken zerlegt und abgespeichert. Dies ist wichtig um im weiteren Ablauf hierauf zurück greifen zu können. Die hieraus entstehenden Bibliotheken bilden die Trainingsdaten der ML Algorithmen. Schematisch ist dieser Vorgang in Abbildung 4 dargestellt. Die Trainingsdaten bilden sich dann letztendlich aus sogenannten Samples und Labels. Die Trainingsdaten werden nun von den ML-Algorithmen aufgegriffen um ihr Zielfunktion zu lernen.

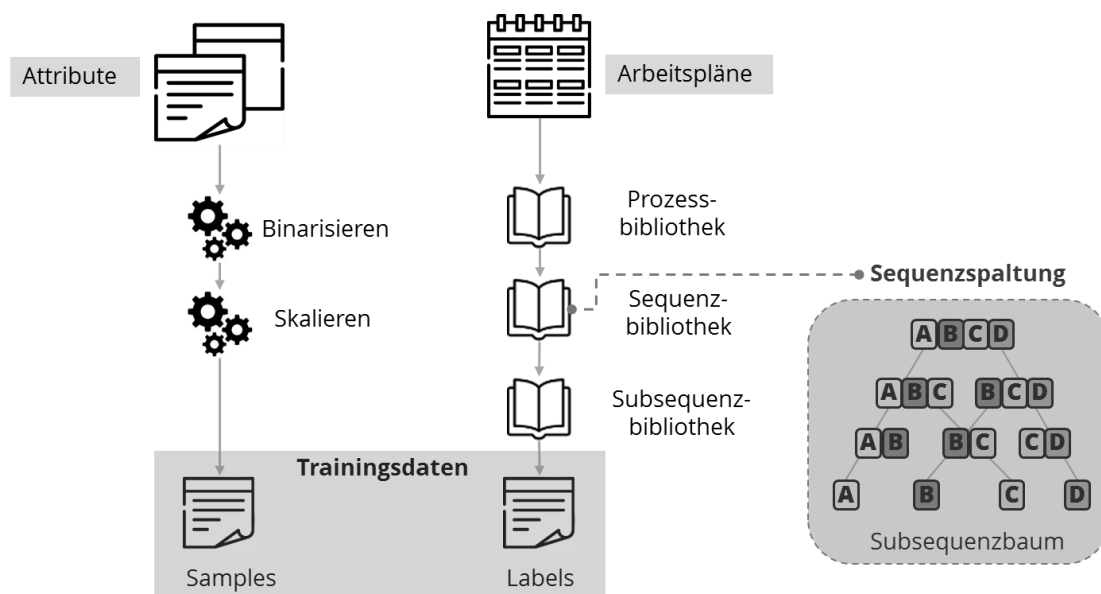


Abbildung 4: Datenvorbereitung und anlegen von Bibliotheken

Der Vorgang der Datenaufbereitung wird in Abbildung 4 dargestellt. Im linken Strang wird der Verlauf der Stücklisten mit seinen Attributen gezeigt und im rechten Strang der Verlauf der Arbeitsplandaten. ML kann in diverse algorithmische Ansätze unterteilt werden. Während es beim nicht überwachten Lernen um die Entwicklung eines statistischen Modells aus einer gegebenen Menge an Eingangsdaten geht, wird beim überwachten Lernen aus Ein- und Ausgangsdaten eine Funktion konstruiert. In der Anwendung dieses Projektes werden überwachte Lernmethoden verfolgt.

Die verwendeten Algorithmen sollen aus den Datenbanken eine mathematische Funktion

$$f: X \rightarrow Y$$

entwickeln, bzw. lernen. Die Herausforderung hierbei liegt in den Mengen X und Y und in der Art der vorhandenen Daten. In der Mathematik ist das Element X genau einem Element Y zugeordnet, bei den vorliegenden Datenbanken jedoch finden sich oft Messfehler, Fehlstellen und andere statistische Effekte. Dies hat zur Folge, dass für den Wert X mehrere Aussagen bezüglich Y getroffen werden können. Diese Widersprüche müssen durch die Algorithmen so korrigiert werden, dass möglichst viele Einträge durch die Funktion abgebildet werden können. (Frochte, 2019)

Mit dem überwachten Lernen gehen hauptsächlich Klassifizierungsalgorithmen überein. Der Algorithmus hat also genügend Ein- und Ausgabewerte mit eindeutiger Zuordnung, man spricht hier von Markierung oder Labeling. Bei der Klassifikation wird die gelernte Funktion Feature genannt. Das Klassifizierungsproblem wird beschrieben mit X als Raum der Featurevektoren und C eine Menge von Klassen. Gelernt wird also hier eine Funktion c. Die fehlerfreie Klassifizierung wäre demnach

$$c: X \rightarrow C .$$

Wie oben schon beschreiben ist in der Regel durch die unvollständig vorliegenden Datenbanken nur eine Menge von Beispielen bekannt.

$$D = \{(x_1, c(x_1)), (x_2, c(x_2)), \dots (x_n, c(x_n))\} \subseteq X \cdot C$$

Die Konstruktion von c ist daher die Lösung des Klassifizierungsproblems. Die genutzten Merkmale in diesem Forschungsvorhaben sind Halbzeug, Substrat und Maße, die gesuchte Zielmengen sind die Prozesse.

Fehlende Basisdaten können also durch ML Algorithmen kompensiert werden. Die Vorhersage dieser Daten ist aber mit einer Trefferwahrscheinlichkeit versehen, die über einen sogenannten Score bewertet wird (Frochte, 2019). Für die weitere Planung der Produktion wird ein Ähnlichkeitskoeffizient entwickelt, der in die Planungsstrategie aufgenommen wird. In der Literatur finden sich einige Ansätze die diese Ähnlichkeitsstrategien nutzen um neue Arbeitsabläufe in das vorhandene Produktionsspektrum einzuordnen.

Auf Grund der lückenhaften Datengrundlage diverser KMU wird eine Kombination verschiedener ML Algorithmen angewandt. So werden instanzbasierte und modellbasierte Algorithmen kombiniert. Instanzbasierte Algorithmen lernen auswendig und verallgemeinern mit Hilfe eines Ähnlichkeitsmaßes. Modellbasierte Algorithmen erzeugen ein Modell aus einem Beispieldatensatz und nutzen dieses für Vorhersagen. Aufgrund der beschränkten Datenqualität werden dabei einfache Modelle (*Nächste-Nachbarn-Klassifikation*, *lineare Regression*) eingesetzt. Die im Rahmen der Datenlückenkompensation zu erwartenden Schätzfehler werden in der nachfolgenden PPS berücksichtigt. Das entwickelte Verfahren wird aus zwei Datenquellen gespeist. Zum einen werden Datensets aus Stücklisten verwendet und zum anderen Arbeitspläne mit den zugehörigen Sequenzen und Prozesszeiten verglichen. Es wird eine Kompensation der Produktstrukturlücken durch Zuordnung ähnlicher Stücklistenelemente aus dem vorhandenen Produktprogramm vorgenommen. Für die Bewertung der Produktstrukturschätzung kommen verschiedene Indikatoren zur Anwendung. Diese sind der *Precision-Recall* (PR) und der F1-Score. Auf der anderen Seite wird die Kompensation der Prozesskettenlücken durch Zuordnung ähnlicher Prozessketten aus dem vorhandenen Produktprogramm verwendet. Die notwendige Ähnlichkeitsbewertung der Prozessketten erfolgt durch Sequenzanalyse. Dabei findet eine Kombination aus den Methoden „Paarweises Sequencealignment“ und „Abgleich von

Subsequenzbäumen“ Anwendung. Beide Methoden wurden bereits im Rahmen anderer Projekte eingesetzt (u. a. zur Identifikation von Standardisierungspotenzial, Typenvertreterbildung). Nachgelagert wird ein geeigneter Indikator zur Bewertung der MLA aus den beiden Datenquellen nebst Kompensation gesucht. In unserem Beispiel werden Produktdaten, Substrat, Fertigteil und Halbzeug sowie die Gesamtdaten genutzt. Für die Prozessdaten werden Ressource und Prozesszeitquantil verwendet. Zudem wird ein Apriori – Algorithmus appliziert um Zusammenhänge zwischen den Produktdaten und Prozessdaten aufzudecken.

Wie im oberen Abschnitt beschreiben, werden zunächst recht einfache Klassifizierungsalgorithmen trainiert. Diese Algorithmen sind; Nearest Neighbors, Linear SVM, RBF SVM, Gaussian Process, Decision Tree, Random Forest, Neural Net, AdaBoost, Naive Bayes, QDA. Für diese Algorithmen werden etwa 70% der Daten für das Training verwendet und als trainierte Sequenzen abgespeichert. Die restlichen 30% der Daten werden für die Testphase vorgehalten. Hier wird überprüft wie gut die Algorithmen arbeiten und wie gut die Vorhersage ist.

Da die Algorithmen wie eine Art Black Box funktionieren und eher schwer verständlich für Anwender sind, wird die Überprüfung mittels Lernkurven vorgenommen. Hierbei kommen (Receiver Operating Characteristics) ROC Kurven und Bias und Varianz Raten zum Einsatz. Bei dem Vergleich der benutzten Klassifizierer haben drei besonders gute Ergebnisse erzielt. Hierzu gehören die Nearest Neighbors, Decision Tree und Naive Bayes.

Nächste Nachbarn: In der Mustererkennung ist der k-nearest neighbors Algorithmus (k-NN) eine nichtparametrische Methode zur Klassifizierung und Regression. In beiden Fällen besteht die Eingabe aus den k engsten Trainingsbeispielen im Featurebereich. In der k-NN-Klassifizierung ist die Ausgabe eine Klassenzugehörigkeit. Ein Objekt wird durch eine Vielzahl von Stimmen seiner Nachbarn klassifiziert, wobei das Objekt der Klasse zugeordnet wird, die unter seinen k nächsten Nachbarn am häufigsten ist (k ist eine positive ganze Zahl, typischerweise klein). Wenn $k = 1$ ist, dann wird das Objekt einfach der Klasse dieses einzelnen nächstgelegenen Nachbarn zugeordnet. k-NN ist eine Art instanzbasiertes Lernen, bei dem die Funktion nur lokal angenähert wird und alle Berechnungen bis zur Klassifizierung verschoben werden. Sowohl für die Klassifizierung als auch für die Regression kann eine nützliche Technik darin bestehen, den Beiträgen der Nachbarn Gewichte zuzuweisen, so dass die näheren Nachbarn mehr zum Durchschnitt beitragen als die entfernteren. Ein gemeinsames Gewichtungsschema besteht beispielsweise darin, jedem Nachbarn eine Gewichtung von $1/d$ zu geben, wobei d der Abstand zum Nachbarn ist. Die Nachbarn werden aus einer Menge von Objekten entnommen, für die die Klasse (bei k-NN-Klassifikation) oder der Wert der Objekteigenschaft (bei k-NN-Regression) bekannt ist. Dies kann als der Trainingssatz für den Algorithmus betrachtet werden, obwohl kein expliziter Trainingsschritt erforderlich ist. Eine Besonderheit des k-NN-Algorithmus besteht darin, dass er empfindlich auf die lokale Struktur der Daten reagiert.

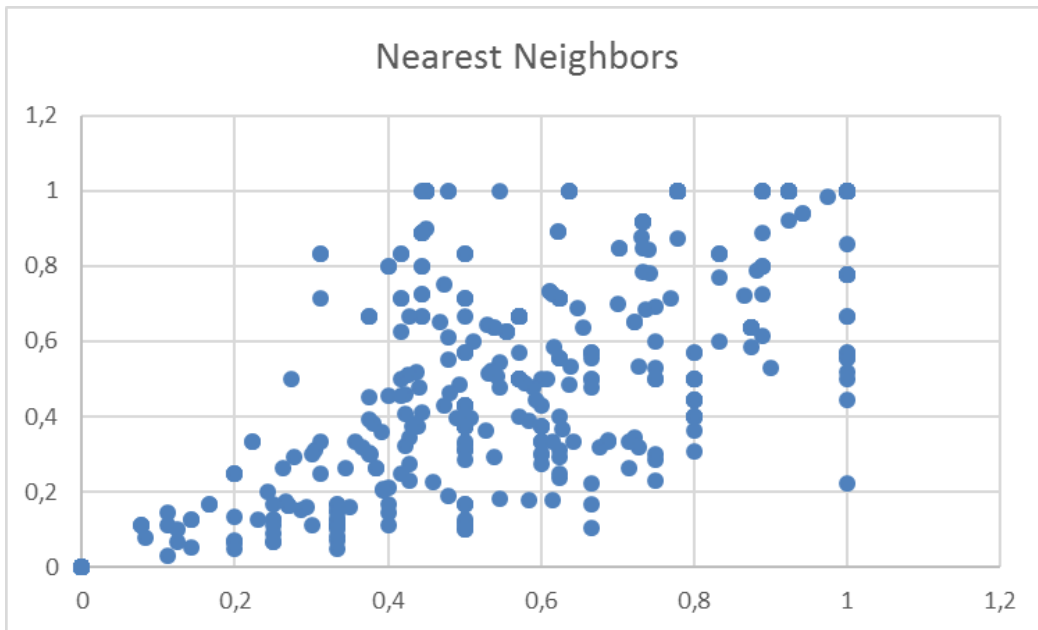


Abbildung 5: ROC Kurve für den Nearest Neighbors Klassifizierer

Abbildung 5 zeigt die Treffer in Abhängigkeit zum Testdurchlauf an. Es wird eine sehr starke Streuung abgebildet, was für die weitere Verwendung in der Planung ungünstig erscheint.

Decision tree: Entscheidungsbäume sind geordnete, gerichtete Bäume, die der Darstellung von Entscheidungsregeln dienen. Die grafische Darstellung als Baumdiagramm veranschaulicht hierarchisch aufeinanderfolgende Entscheidungen. Sie haben eine Bedeutung in zahlreichen Bereichen, in denen automatisch klassifiziert wird oder aus Erfahrungswissen formale Regeln hergeleitet oder dargestellt werden. Die Streubreite der Treffer ist bei dem Decision Tree wesentlich geringer. Die Angleichung der Punkte zur Trefferwahrscheinlichkeit 1 ist aber auch hier eher gering.

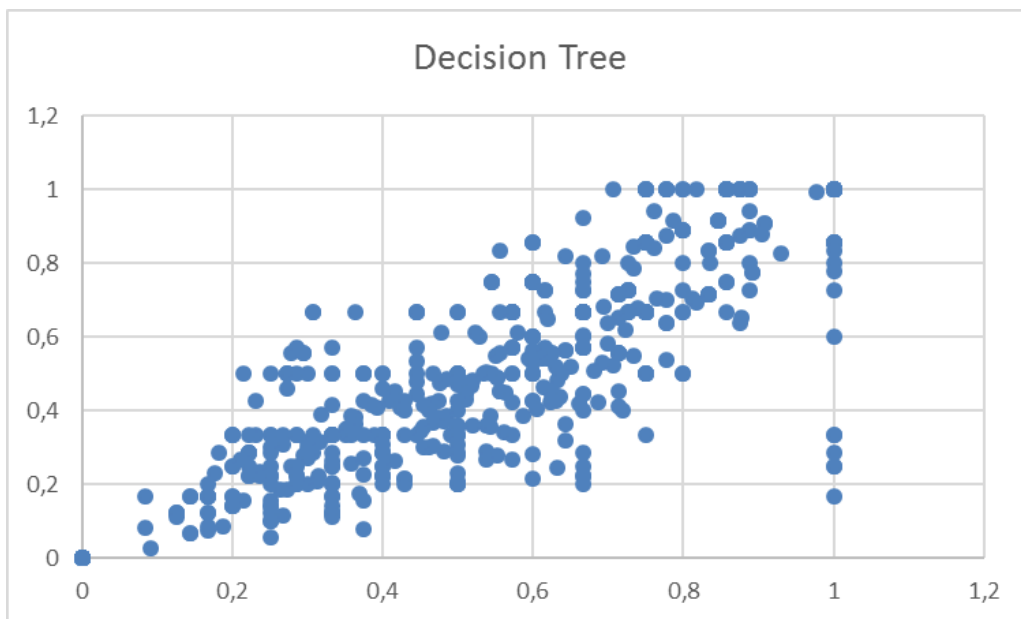


Abbildung 6: ROC Kurve für den Decision Tree Klassifizierer

Naive Bayes: Im maschinellen Lernen sind naive Bayes-Klassifikatoren eine Familie von einfachen "probabilistischen Klassifikatoren", die auf der Anwendung des Bayes-Theorems mit starken (naiven) Unabhängigkeitsannahmen zwischen den Merkmalen basieren. Das Bayes-Theorem ist eine beliebte (Baseline)-Methode für die Kategorisierung von Texten, das Problem, Dokumente als zu der einen oder anderen Kategorie gehörend (wie Spam oder legitim, Sport oder Politik, etc.) mit Wortfrequenzen als Merkmale zu beurteilen. Mit entsprechender Vorverarbeitung ist es in diesem Bereich konkurrenzfähig mit fortschrittlicheren Methoden einschließlich unterstützender Vektorgeräte. Es findet auch Anwendung in der automatischen medizinischen Diagnose. Naive Bayes Klassifikatoren sind hoch skalierbar, die eine Reihe von Parametern erfordern, die linear in der Anzahl der Variablen (Merkmale / Prädiktoren) in einem Lernproblem liegen. Das Maximum-Likelihood-Training kann durch die Auswertung eines geschlossenen Ausdrucks, durchgeführt werden, der lineare Zeit in Anspruch nimmt, anstatt durch teure iterative Approximation, wie sie für viele andere Arten von Klassifikatoren verwendet wird. In der Statistik und der Informatikliteratur sind naive Bayes-Modelle unter einer Vielzahl von Namen bekannt, darunter einfache Bayes und Unabhängigkeit Bayes. Alle diese Namen verweisen auf die Verwendung des Bayes-Satzes in der Entscheidungsregel des Klassifikators, aber Naive Bayes ist keine (notwendigerweise) Bayes'sche Methode.




Abbildung 7: ROC Kurve für den Naive Bayes Klassifizierer

Abbildung 7 zeigt die Trefferwahrscheinlichkeiten des Naive Bayes. Hier ist deutlich der kurze aber steile Anstieg der Trefferwahrscheinlichkeiten zur 1 hin zu erkennen. Die Streuung variiert allerdings noch sehr und muss mit Mitteln der Datenbereinigung behoben werden.

Mit diesen drei ML Algorithmen wird im weiteren Verlauf gearbeitet. Mit der Verknüpfung der Produkttypen sind Attribute und gelabelte Sequenzdaten eindeutig zuzuordnen. Das Ergebnis der Trainingsphase ist eine Bibliothek mit vorhergesagten Subsequenzdaten, im weiteren Verlauf als Protosequenz bezeichnet. In Abbildung 9 werden die Protosequenzen schematisch als Buchstaben dargestellt, in einer Art Sequenzbaum. Attribute und Arbeitsplandaten werden eindeutig miteinander verknüpft um die spätere Vorhersage zuordnen zu können. Kommen nicht zugeordnete Daten hinzu, müssen diese erst gelabelt werden um die Verbindung der Datensets zu gewähren. Die Vorhersagedaten werden, wie in der Abbildung dargestellt in einer

Protosequenzbibliothek abgelegt. Hier wird anschließend geprüft welche Trefferwahrscheinlichkeit die Sequenzen haben und mittels Ähnlichkeitsabgleich wird ein Arbeitsplan erstellt.

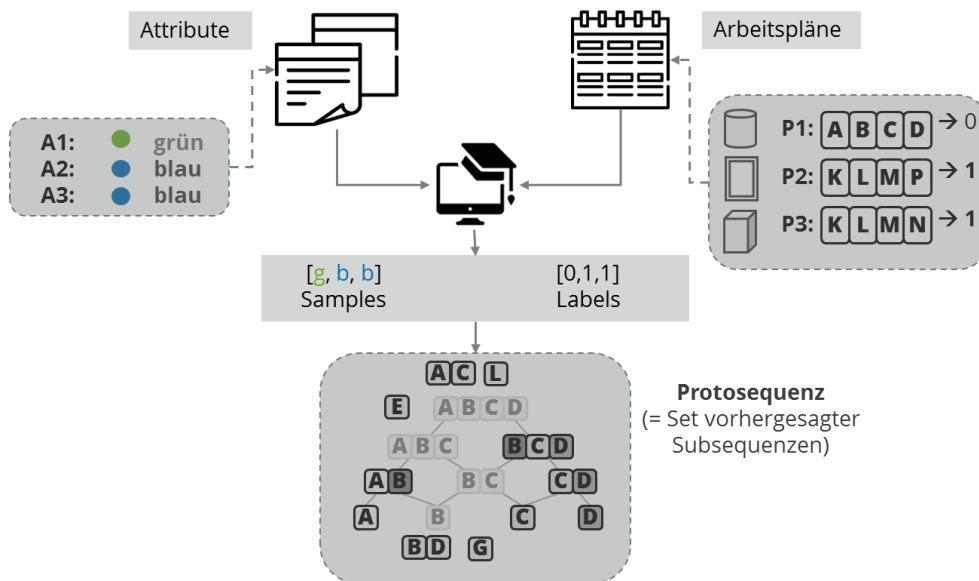


Abbildung 9: Trainieren der Datensets und ablegen als Protosequenz

Um die Genauigkeit der abgelegten Protosequenzen bewerten zu können werden verschiedene Punktbewertungen angewendet und auf ihre Eignung überprüft. Die Bewertungen sind True positive rate =Recall, F1 score, Precision Rate wight, Inherited score. Die Bewertungen können mittels der Konfusionsmatrix erläutert werden, siehe Abbildung 8.

		ML Vorhersage	
		falsch	wahr
Tatsächliche Aussage	falsch	Richtig negativ	Falsch positiv
	wahr	Falsch negativ	Richtig positiv

Abbildung 8: Confusionmatrix

Die Confusion Matrix bildet die realen wahren Aussagen und die realen falschen Aussagen ab, hier tatsächliche Aussage. In Kombination mit der Vorhersage und deren wahre und falsche Treffer ergeben sich also richtig negativer Treffer und richtig positive Treffer, hier grün unterlegt. Diese beiden Trefferraten geben die Vorhersagegüte der ML-Algorithmen wieder. Die beiden weiß unterlegten Felder in der Matrix geben die Fehlertypen wieder. Hierbei wird zwischen I.- falsch positiv und II.- falsch negativ Fehler unterschieden. Wobei der Fehler II. Ordnung eine größere Gewichtung hat. Die Berechnungsmethoden der einzelnen Scores wird im Folgenden erläutert.:

FGA $\frac{TP+TN}{TP+FP+TN+FN}$

Recall TPS $\frac{\sum TP}{\sum TP+\sum FN}$

$$F1 \text{ Score} \quad 2PPV * \frac{TPR}{PPV} + TPR$$

$$\text{Precision PRW} \quad \frac{TP}{TP+FP}$$

Inherited score IR

Folgende Scores werden für die Bewertung der Plandatenvorhersage herangezogen. Um die Aussagegewichtung der Scores vergleichen zu können, wird hier eine kurze Einführung aufgezeigt.

TPS:

Der *True Positive* Score bezieht ausschließlich positive Treffer in die Bewertungsbilanzierung ein. Somit wird nur ein Bruchteil der möglichen Vorhersageleistung in die Bewertung einbezogen. Potenziale in der möglichen Vorhersagewahrscheinlichkeit werden nicht vollständig ausgeschöpft.

F1:

Der sogenannte *F1 Score* ist eine Kombination aus *True Positive* und *True Negative*. Die Gesamtheit der Treffer wird damit dargestellt und ist damit sehr gut für die Vorhersagebewertung geeignet.

PRW:

Die Gewichtung des *Precision und Recall* bewertet lediglich die als korrekt positiv vorhergesagten Vorhersagen und bewertet damit nicht das gesamte Vorhersagepotenzial aus.

IS:

Der *Inherited Score* wurde speziell für die Subsequenzbewertung gewählt. Dabei bewertet er Subsequenzen mit der Länge > 1 indem er die einzelnen Sequenzen mit dem (ggfs. abgeschwächten) PRW-Scores weitergibt.

Für die schnelle Darstellung und Bewertung der Scores wurde eine Art Heatmap gewählt. So konnten alle Attribute in Abhängigkeit mit den Prozessen abgebildet werden. Zusätzlich wurde noch der Support von 1% und 5% angegeben. In der Heatmap zeichnen sich zwei Bereiche ab, die in der Datenaufbereitung differenziert verarbeitet und deklariert wurden. Die Prozessdefinitionen wurden zum einen in mittels Prozesszeitquantil und zum anderen mittels Ressourcen zugeordnet. Die Prozessdefinition mit Ressourcenzuordnung liefert bessere Score Ergebnisse, als die Zuordnung über die Prozesszeitquantile. Der Grund hierfür kann sein, dass für ein und das selbe Quantil mehrere Ergebnisse korrekt sind. So werden die Wahrscheinlichkeiten für eine korrekte Vorhersage herabgesetzt. Die Ressourcenzuordnung ist demnach geeigneter für die Prozessdefinition.

Produktset	Prozess- definition	Support	TPS		F1W		PRW		IS	
			FGA	Mittl. Ähnl.	FGA	Mittl. Ähnl.	FGA	Mittl. Ähnl.	FGA	Mittl. Ähnl.
S	PZ-Q	0,01	0,06	0,54	0,12	0,66	0,12	0,65	0,12	0,69
S	PZ-Q	0,05	0,04	0,43	0,09	0,67	0,09	0,66	0,08	0,68
H	PZ-Q	0,01	0,17	0,55	0,21	0,61	0,21	0,60	0,21	0,63
H	PZ-Q	0,05	0,13	0,46	0,17	0,57	0,17	0,57	0,15	0,58
Gesamt	PZ-Q	0,01	0,17	0,62	0,17	0,58	0,18	0,59	0,09	0,40
Gesamt	PZ-Q	0,05	0,05	0,35	0,12	0,56	0,12	0,57	0,11	0,57
F	PZ-Q	0,01	0,21	0,52	0,29	0,65	0,28	0,64	0,31	0,69
F	PZ-Q	0,05	0,06	0,38	0,19	0,65	0,20	0,64	0,21	0,65
S	Res	0,01	0,13	0,75	0,25	0,79	0,24	0,79	0,20	0,76
S	Res	0,05	0,08	0,68	0,18	0,77	0,18	0,78	0,14	0,72
H	Res	0,01	0,25	0,64	0,29	0,70	0,30	0,70	0,27	0,70
H	Res	0,05	0,19	0,55	0,23	0,67	0,24	0,67	0,22	0,66
Gesamt	Res	0,05	0,17	0,67	0,18	0,67	0,18	0,67	0,11	0,54
F	Res	0,05	0,31	0,68	0,34	0,74	0,35	0,74	0,33	0,73
F	Res	0,01	0,33	0,68	0,35	0,73	0,35	0,73	0,33	0,73

Abbildung 9: Ergebnisse des Vergleiches der angewendeten Scores

Eine weitere Möglichkeit die Subsequenzen zu bewerten wurde mittels einer Methode aus der Bioinformatik untersucht. Bei der Sequenzanalyse werden Sequenzstränge der DNA miteinander verglichen. Hintergrund ist die Zuordnung der Sequenzstränge zu Funktionalitätsbeziehungen. Die Funktionalitätsbeziehungen in diesem Projekt sind die Verknüpfungen von Produkttyp zu den Prozessdefinitionen.

Die Sequenzen werden an Hand einer Matrix analysiert. Dabei werden ähnliche Sequenzen übereinandergeschrieben. Lücken oder Sequenzreste werden mit Platzhaltern versehen. Sehr lange Sequenzen werden üblicherweise mittels moderner Rechentechnik analysiert. Hierfür wird dynamisch programmiert um in der gesamten Sequenz nach ähnlichen Abschnitten zu suchen. Dies wird lokale Methode bezeichnet.

In diesem Projekt wurde der Gotoh Algorithmus eingesetzt. Dieser Algorithmus sucht in lange Sequenzen nach ähnlichen Teilbereichen. Die Abhängigkeiten von Produkten und Prozessen können so sehr gut ermittelt werden. Eine Mehrdeutigkeit durch verwendete Prozesszeitquantile wie bei den Scores wird hier auch beobachtet. Allerdings kann hier durch geschickte Variation der betrachteten Sequenzlänge und Platzieren von Platzhaltern die Auswirkung auf ein Minimum reduziert werden. Abbildung 10 zeigt ein Berechnungsbeispiel in dem eine vorhergesagte Sequenz und historische Sequenz verglichen werden. Eine Protosequenz wird vorhergesagt, linke Seite des Bildes. Diese wird mit den historischen Datengrundlagen verglichen, woraus sich die entsprechenden Ähnlichkeiten als Punktwertung ergeben.

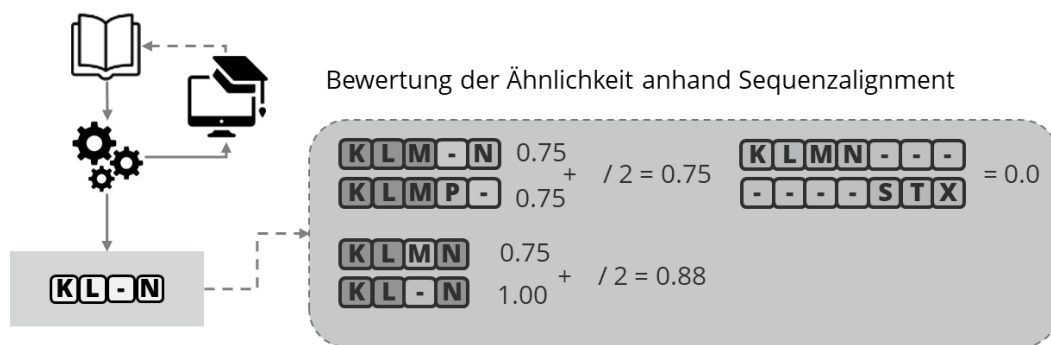


Abbildung 10: Bewertung der Protosequenz bzgl. deren Ähnlichkeit zu historischen Daten

Zusammenfassend besteht die Entwicklung aus zwei Teilbereichen. Der erste Bereich kombiniert ML Algorithmen um aus Produktstammdaten und Arbeitsplänen Vorhersagen für unscharfe Plandaten zu generieren. Der zweite Bereich vergleicht diese Vorhersagen mit historischen Daten und bildet Ähnlichkeiten aus. So können für neue Produktgruppen Arbeitspläne vorhergesagt werden.

- **(AP3) Entwicklung Steuerungsparametrik und Steuerungsmodelle**

Aus den Gesprächen mit dem PA und den Anforderungen aus der Industrie wurde definiert, dass eine Substitution zur vorhandenen üblichen Meistersteuerung nicht zielführend ist und in vielen Fällen auch nicht möglich. Dies liegt zum einen an den unterschiedlichen Zielausrichtungen der Unternehmen und zum anderen an der steigenden Variation der Produkte. So wurde entschieden die vorhandene Meistersteuerung mit sinnvollen Modulen zu ergänzen. So werden dem Meister Arbeitsplandaten generiert und zur Verfügung gestellt. Gerade bei neuen Produkten ist die zur Verfügung Stellung von Plandaten eine Ergänzung und Arbeitserleichterung.

AP3.1 Untersuchung von Steuerungsmethode-Parameter-Paarung

Die Meister benötigen für die Steuerung in der Produktion Angaben für Material, Ressourcen, Prozesszeiten und entsprechende Puffer um operative Steuerungen vorzunehmen. Diese müssen so abgestimmt sein, dass ein erneutes Eingreifen in Konfliktsituationen unnötig wird. Entsprechende Puffer sind bereits in der Planungsebene zu generieren. Aus dem MCRP Algorithmus heraus werden diese Puffer noch vor Auftragsfreigabe erstellt. Die Plandatenkompensation bei variantenreichen Produktionen liefert die benötigten Planungsgrundlagen. Nach der Berechnung werden die Parameterdaten und der Produktionsplan an den Meister gegeben und von ihm auf die jeweiligen Ressourcen aufgeteilt. Eine schematische Darstellung dieser Methodik wird in Abbildung 11 gezeigt. Das erste Element am Kopf der Darstellung verdeutlicht die Auftragsfreigabe mit den zugehörigen Arbeitsplandaten. Diese Daten werden auf die jeweiligen Meister und ihre Zuständigkeiten verteilt. Die Meister steuern die in ihren Zuständigkeiten liegenden Produktionen mit den zu bereit gestellten Material, Ressourcen und Prozesszeiten. Eine erneute Anpassung dieser Daten ist nicht zweckmäßig, da es zu erhöhtem Aufwand kommen würde, mit Anpassungen in der gesamten Produktion. Aus diesem Grund sei hier noch einmal das große Potenzial der Plandatenkompensation mittels ML erwähnt. Dieser Planungsschritt erstellt notwendige Daten aus einer historischen Datenmenge und nimmt eine Abschätzung vor, ähnlich wie es ein Experte mit seinem Erfahrungswissen machen würde. Der entscheidende Vorteil der ML Methode ist das kalkulierbare Risiko der Abweichung.

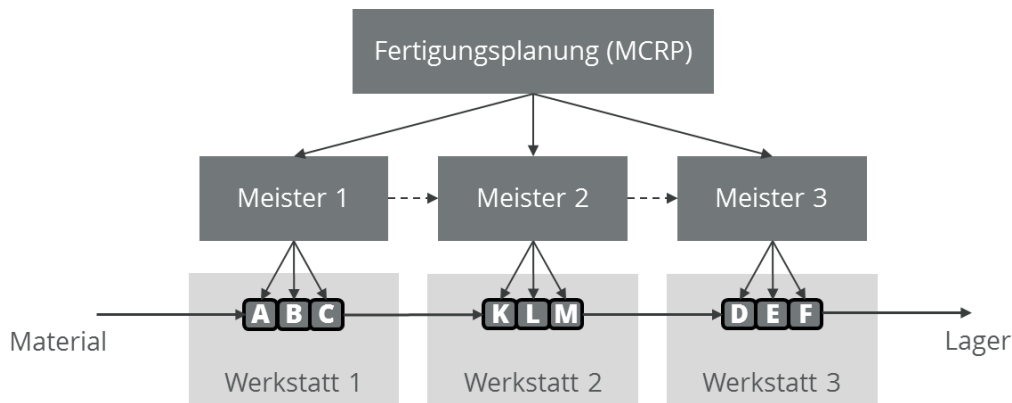


Abbildung 11: Modell zur Modulbereitstellung an die Meister.

AP3.2 Entwicklung von Berechnungsmethoden für

Steuerungsparameter

Die dem Meister bereitgestellten Parameter zur Steuerung der Fertigung werden bereits in der Planungsebene noch vor der Auftragsfreigabe berechnet. So werden erhöhte Steuerungsaufwände vermieden. Meister sollen nur in Ausnahmefällen eingreifen, etwa bei Ressourcenausfällen oder Qualitätsproblemen. Parameter wie:

- Materialkapazitäten
- Liefertermine
- Prozesszeiten

Werden im MCRP berechnet und den ausführenden Experten zur Verfügung gestellt.

AP3.3 Parameter und Aktualisierung der Steuerungsinformationen

Eine Aktualisierung der Steuerungsinformation ist nach der Auftragsfreigabe nicht erwünscht, da hier massiv in den Steuerungsablauf eingegriffen werden muss und so der Aufwand erhöht wird. So wird bereits in der Planungsebene, vor Auftragsfreigabe Materialkapazitäten, Liefertermine und Prozesse optimiert.

• (AP4) Entwicklung Demonstrator

Zur Kompensation von Plandaten wurde im Sinne eines Demonstrators ein Programm konstruiert, das die Vorhersagen auf Grund von Machine Learning Algorithmen und historischen Datensätzen vornimmt. Die grundlegenden Algorithmen sind übertragbar. Im einzelnen Fall müssen allerdings Anpassungen bezüglich Datenintegration und Datenbereinigung vorgenommen werden. Der Demonstrator ist also Anpassungsfähig zu halten um einen Transfer zu gewährleisten. Der Demonstrator liegt als Quellcode in der Programmiersprache Python vor. Bei Bedarf kann eine Benutzeroberfläche hinzugefügt werden, die auf Grund der Anpassungsfähigkeit zunächst weggelassen worden ist. Der Demonstrator übernimmt das Training der ML-Algorithmen mit historischen Daten und stellt die Vorhergesagten Daten wieder der Planungsebene wieder zur Verfügung. Desweiteren macht er Vorhersagen mit neu hinzugegebenen Daten und bewertet diese auf ihre statistische Wahrscheinlichkeit hin. Die Übergabe der Wahrscheinlichkeitsaussage zu den Attributen wird von einem zweiten Demonstrator verarbeitet. Hier handelt es sich um den erweiterten Planungsalgorithmus MCRP. Dieser wurde in der Programmiersprache JAVA implementiert um eine Schnittstelle zu den bestehenden ERP-Systemen zu gewährleisten. Der MCRP Algorithmus verarbeitet die

Parameter aus den Vorhersagen und ermittelt einen Puffer um die Planung so robust wie möglich zu machen.

• **(AP5) Auswertung und Evaluation**

In diesem Projekt wurde ein Ansatz zur Automatisierten Wissensgenerierung für die kalkulierbare Unschärfe von Plandaten in der Planung- und Steuerung von Produktionen mit sehr hoher Variation entwickelt. Voraussetzung ist, dass Plandaten gesammelt und gespeichert werden. Nur dann können Vorteile daraus gezogen werden. Somit war eine notwendige Aufgabe dieses Projektes Kompensationsalgorithmen für Datenlücken zu entwickeln. Die Neuentwicklung ist eine automatisierte Kompensation von Datenlücken, wobei nicht von einer universell anwendbaren Methode gesprochen werden kann. Auf Grund der sehr schwankenden Ausgangslage der Datenbasis muss der Prototyp mehr oder weniger stark angepasst werden. Die Kombination und Anwendung von mehreren Methoden, ML für die Attributvorhersage und Sequenzanalyse für die Prozesszeitvorhersage, verdeutlicht die Komplexität dieses Moduls. Angewendet auf historische Daten beschränkt die Entwicklung nicht nur auf Plandatenvorhersagen. Eine differenzierte Einsatzweise ist durchaus denkbar in Bereichen wie Produkttypenvorhersage, Produktionsplanung und unter Einbezug von Marktinformationen auch Umsatzplanung. Somit könnten Module für die Langfristige, mittelfristige und kurzfristige Planung zum Einsatz kommen.

Der Einsatz von Methoden der KI bzw. des ML in produzierenden Unternehmen können generell zu wirtschaftlichen Vorteilen verhelfen, sofern das Potenzial von Plan- und Auftragsdaten erkannt wurde. Aus diesen Daten kann Wissen generiert werden, welches sonst nur von Experten mit langjähriger Erfahrung stammen kann. Nutzen aus diesem Wissen kann zum Beispiel in

- der Zustandsüberwachung,
- dem Qualitätsmanagement,
- dem Energie-Management,
- der Bedarfs Vorausschau und
- der Konsumfreude der Kunden

angewandt werden. Desweiteren können bei hochwertigen Datenbeständen Produktions- und Geschäftsprozesse automatisiert werden (Elliot, 2018). Es lassen sich also Mehrwerte in Bereich von Produktion, Management und Planung generieren. Somit sind entscheidende Faktoren wie, verkürzte Rüstzeiten, verlässliche Produktionsplanung und „Null“-Fehler Fertigung realisierbar (Röhrig, 2019).

3. Verwendung der Zuwendung

TL:

- Im Berichtszeitraum wurden zur Durchführung der Arbeiten 24 Monate wissenschaftlich-technisches Personal (Einzelansatz A.1 des Finanzierungsplans) eingesetzt.
- Es wurden zwei Studentische Hilfskräfte in die Bearbeitung mit einbezogen und jeweils zwei Abschlussarbeiten sowie Seminararbeiten verfasst.

- Für Geräte (Einzelansatz B des Finanzierungsplans) und Leistungen Dritter (Einzelansatz C des Finanzierungsplans) wurden keine Ausgaben geplant und keine durchgeführt.

4. Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die durchgeführten Arbeiten leisten einen angemessenen Beitrag zum Forschungsvorhaben der Entwicklung einer robusten produktionslogistischen Auftragsabwicklung mit Topologiebausteinen. Dabei konnte die Komplexität der durchgeführten Arbeiten mit Hilfe von mehreren Studien- und Abschlussarbeiten auf ein höheres Niveau gebracht und im Bereich der Datenlückenkompensation sogar noch übertroffen werden. Die durchgeführten Arbeiten waren in Inhalt und Umfang ein notwendiger Teilschritt zur Erreichung des geplanten Forschungsziels. Eine besondere Gewichtung wurde in die Datenlückenkompensation gelegt, da ein Misserfolg in diesem Bereich die Gefährdung der Zielstellung mit sich gebracht hätte. Die Ergebnisse des Projektes entsprechen den Erwartungen des Arbeitsablaufs. Zum Erreichen der Zielstellung wurden Mitarbeiter laut Plan beschäftigt.

5. Darstellung des wissenschaftlich-technischen und wirtschaftlichen Nutzens der erzielten Ergebnisse insbesondere für KMU sowie ihres innovativen Beitrags und ihrer industriellen Anwendungsmöglichkeiten

Im Rahmen dieses Projektes wurde eine Methode entwickelt, die für sehr variantenreich produzierende Unternehmen Lücken in der Plandatenbasis kompensiert und so eine robuste Planungsgrundlage generiert. Dies ermöglicht bei diesen Unternehmen eine Planungseffizienz, die auf individuelle Kundenwünsche reagieren kann ohne den Steuerungsaufwand zu erhöhen und operativ in die Steuerung einzugreifen. Hierfür wurde ein Softwaretool entwickelt, das aus historischen Datensätzen, die aus gängigen ERP-Systemen zur Verfügung gestellt werden, Plandaten wie Produkt- und Prozessdaten mittels Machine Learning Algorithmen vorhersagt. Die Vorhersage wird durch eine Auftrittswahrscheinlichkeit und eine Abgleichwahrscheinlichkeit bewertet und kann so in die Planung eingebunden werden. Mit der Wahrscheinlichkeitsaussage wird ein kapazitiver Puffer aufgebaut um die Planung in ihrer Robustheit zu unterstützen. Die erzielten Ergebnisse sind also eine Ergänzung zu der in KMU üblichen Meistersteuerung. Es wird eine bessere Planbarkeit von Ressourcen und Materialien erreicht, was eine komplexe operative Steuerung verringert.

KMU sind mit dem Einsatz dieses Tools in der Lage auf Produktschwankungen schneller reagieren zu können und mit einer robusteren Planung Liefertermine, Kapazitäten und Ressourcen besser vorherzusagen, bzw. auszulasten.

Als besondere Innovation ist hervorzuheben, dass gezielt auf eher schlechte Datengrundlage in KMU eingegangen wurde und durch geschickte Kombination mit verschiedenen MLA und Sequenzvergleichsalgorithmen eine gute Datenlückenkompensation erreicht wurde. Diese Kompensationsmethodik kann auch als eigenständige Entwicklung in anderen

Wirtschaftszweigen neben dem Maschinenbau und der Informationstechnologie Anwendung finden.

Die Anwendungsmöglichkeiten liegen insbesondere im produzierenden Gewerbe mit sehr variantenreichem Produktportfolio. Dabei zielt das entwickelte Tool auf die Vereinfachung der Planung und Steuerung neuartiger Produkte, indem Vorhersagen auf Grundlage von historischen Daten gemacht werden. Denkbar wäre diese Anwendung auch für eine längerfristige Planung in produzierenden Unternehmen. Somit könnten Anwendungen sowohl in der strategischen Planung, als auch in der Produktionsprogrammplanung gefunden werden. Ein entscheidender reglementierender Faktor hierbei ist jedoch die Datengrundlage, die speziell bei KMU sehr stark schwankt. Ohne ein gewisses Maß an Selbstdisziplin zum Sammeln von Produktionsdaten werden digitale Maßnahmen zur Produktionseffizienzsteigerung nicht optimal angewendet werden können.

6. Plan zum Ergebnistransfer in die Wirtschaft

Folgende Transfermaßnahmen wurden im Berichtszeitraum durchgeführt:

Während der gesamten Projektlaufzeit wurde der intensive Kontakt mit Partnern des Projektbegleitenden Ausschusses gepflegt und weitergeführt. Dabei wurde neben der Datenbereitstellung für die Validierung der Entwicklung auch immer wieder die Diskussion gesucht um auf Vorstellungen und Bedürfnisse aus der Wirtschaft eingehen zu können. Besonders enger Kontakt wurde zu Firma Layertec GmbH und Waco GmbH gehalten. Hier kann sich zukünftig eine weitere Forschungszusammenarbeit entwickeln.

Weitere Transfers direkt in Partnerunternehmen wurde mittels einer Diplomarbeit zum Thema Erweiterung eines MCRP-Algorithmus um Kostenbewertung erreicht. Hierbei wurde ein Algorithmus zur Robusten Planung von Material und Kapazitäten in die Programmiersprache JAVA implementiert, erweitert und zusammen mit der Firma Alltrotec GmbH verifiziert. Hieraus ergab sich eine weitere Zusammenarbeit zur Entwicklung eines schlanken und robusten Planungstools.

Folgende Maßnahmen werden nach dem Berichtszeitraum durchgeführt:

Eine weitere Zusammenarbeit zum Transfer der in diesem Projekt erzielten Ergebnisse ist mit der Firma Layertec GmbH zustande gekommen. Dieses Unternehmen sieht großes Potenzial in der Applizierung von Vorhersagemethoden mittels historischer Daten zur Unterstützung der Planungs- und Steuerungsmethodik, sowie der Arbeitsplanvorhersage. Hier werden weitere Arbeiten aufgenommen um die vorhandenen Ergebnisse anzupassen und für den Einsatz im Unternehmen vorzubereiten. Eine Kooperation mit der Firma Alltrotec GmbH kann zu einer Produktentwicklung führen, die in der hauseigenen Plattform für Modulkomponenten angeboten wird. Hierfür sind noch Anpassungen zur Systemintegration und den entsprechenden Zielvorgaben zu unternehmen.

Die Firma Lenze GmbH ist ebenfalls an dem Prognosetool zur Datenlückenkompensation interessiert. Eine Zusammenarbeit zum Wissenstransfer wird angestrebt.

Zur Übersicht sind im Plan für den Ergebnistransfer in die Wirtschaft die bereits begonnenen bzw. durchgeführten Maßnahmen grau markiert:

Maßnahme	Ziel	Ort / Rahmen	Datum / Zeitraum
Projektbegleitender Ausschuss (PA)	Fortlaufende Diskussion mit Vertretern des PA	Regelmäßige Treffen zum Projektstand	Gesamte Laufzeit
Ansprache weiterer interessierter Unternehmen	Gewinnung zur Mitarbeit im PA, Problemsensibilisierung	z. B. Messen, Tagungen	Gesamte Laufzeit
Diskussion	Problemsensibilisierung, Wissenstransfer	Dresden / Forum Technische Logistik und Arbeitssysteme	2018
Internetpräsenz	Wissenstransfer		2018
Diplomarbeit / Vortrag	Wissenstransfer	Ergebnisvorstellung mit Vertretern des PA	2018
Forschungsseminararbeit / Vortrag	Wissenstransfer	Ergebnisvorstellung mit Vertretern des PA	2018
Vortrag / Präsentation	Wissenstransfer	Controllerforum Dresden	2018
Abschlussbericht	Wissenstransfer		2019
Diskussion	Wissenstransfer, Verifikation & Validierung	Unternehmen des PA	2019
Vortrag / Präsentation	Wissenstransfer	Fachtagung Technische Logistik	2020

Quellen

Elliot, T. (2018). Machine Learning: 3 konkrete Anwendungen. Retrieved July 16, 2019, from https://www.produktion.de/digital_supply_chain/machine-learning-3-konkrete-anwendungen-119.html

Frochte, J. (2019). Maschinelles Lernen – Überblick und Abgrenzung. In *Maschinelles Lernen* (pp. 13–31). München: Carl Hanser Verlag GmbH & Co. KG. <https://doi.org/10.3139/9783446459977.002>

Goyal, Jain, & Jain. (2012). Operation sequence based similarity coefficient for RMS. *Annals of DAAAM for 2012 & Proceedings of the 23rd International DAAAM Symposium*, 23(1), 281–284.

Müller, J., Wenzel, A., & Lasch, R. (2016). Identifying Complexity-Inducing Variety: Adapting ClustalW for Semiconductor Industry (pp. 159–171). Springer, Cham. https://doi.org/10.1007/978-3-319-20863-3_12