

HUMANZENTRIERTE PRODUKTIONSPLANUNG MIT KI

Entwicklung eines Assistenzsystems

Lukas Vollenkemper
Marvin Mönikes
Florian Wortmann
Melanie Rudolph-Puls
Prof. Dr. Martin Kohlhase
Prof. Dr. Angelika Röchter
Prof. Dr. Christian Ewering

**WORKING
PAPER #5**



ÜBER DAS KOMPETENZZENTRUM ARBEITSWELT.PLUS

Wie wird Künstliche Intelligenz die Arbeitswelt verändern? Wie gelingt es, Veränderungen der Arbeitswelt gemeinsam zu gestalten? Und wie können Beschäftigte auf den Wandel eigentlich vorbereitet werden? Antworten auf diese Fragen liefern wir als Kompetenzzentrum Arbeitswelt.Plus.

Unserem gemeinsamen Leitmotiv **Mensch. Industrie. Morgen.** entsprechend entwickeln Hochschulen und Unternehmen aus OstWestfalenLippe im Kompetenzzentrum gemeinsam mit der IG Metall Ansätze für die Einführung von Künstlicher Intelligenz in der Arbeitswelt, beispielsweise im Hinblick auf die Arbeitsplatzgestaltung und die Qualifizierung von Mitarbeiter:innen.

ÜBER DIE WORKING-PAPER-REIHE

Damit die Ausprägung der künftigen Arbeitswelt nicht allein technologisch geprägt wird, braucht es eine **ganzheitliche Gestaltung**. Deshalb führt das Kompetenzzentrum Arbeitswelt.Plus Erkenntnisse der Arbeitsforschung im Kontext von KI-Anwendungen zusammen und entwickelt daraus passende Lösungen für mittelständische Unternehmen.

Mit dieser **Working-Paper-Reihe** geben wir Einblicke in die laufende Forschung der Wissenschaftler:innen des Kompetenzzentrums und möchten gleichzeitig einen Beitrag zur Diskussion rund um aktuelle Themen aus den Feldern Künstliche Intelligenz und Arbeitsforschung leisten.

ÜBER DIE AUTOR:INNEN



Lukas Vollenkemper

ist wissenschaftlicher Mitarbeiter an der Fachhochschule Bielefeld in der Arbeitsgruppe Cloud Based Automation. Er beschäftigt sich in seiner Forschung mit humanzentrierter Produktionsplanung und Ergonomiebewertung im industriellen Kontext.



Prof. Dr. Martin Kohlhase

ist Professor für Automatisierungs- und Regelungstechnik an der Fachhochschule Bielefeld. Als Mitbegründer des Center for applied Data Science erforscht er in der Arbeitsgruppe "Cloud Based Automation" Methoden des Machine Learning und der Data Science im anwendungsnahen Kontext.



Marvin Mönikes

ist Mitarbeiter bei der Bette GmbH & Co. KG. in Delbrück. Der Fokus seiner Tätigkeit liegt im Bereich der Arbeitsvorbereitung und EDV. Insbesondere das Optimieren der Prozesse von Produktionsplanung, -steuerung und -kontrolle ist eine seiner Kernaufgaben.



Prof. Dr. Angelika Röchter

ist Dekanin des Fachbereichs Betriebswirtschaft an der Fachhochschule der Wirtschaft. Sie beschäftigt sich in Forschung und Lehre mit arbeits- und organisationspsychologischen Fragestellungen sowie mit dem Thema Wissensmanagement.



Florian Wortmann

ist wissenschaftlicher Mitarbeiter an der Fachhochschule der Wirtschaft. Neben seiner Lehre betreut er Projekte zum Thema Wissensmanagement mit kleinen und mittelständischen Unternehmen



Prof. Dr. Christian Ewering

ist Dekan des Fachbereiches Informatik an der Fachhochschule der Wirtschaft. Schwerpunkte der Forschung und Lehre ist der Einsatz von Methoden des Operations Managements und Data Science in der betrieblichen Praxis.



Melanie Rudolph-Puls

ist wissenschaftliche Mitarbeiterin an der Fachhochschule der Wirtschaft Paderborn. Ihre Forschungsschwerpunkte umfassen Themen rund um die Mensch-Maschine-Interaktion hinsichtlich KI sowie das Wissensmanagement und die humanzentrierte Arbeitsplatzgestaltung.

ABSTRACT

Im Rahmen dieses Working Papers wird ein KI-gestütztes Assistenzsystem vorgestellt, welches dem Anwendungspartner Bette GmbH eine humanzentrierte Produktionsplanung ermöglicht. Dazu werden zunächst die Besonderheiten vorgestellt, welche die Produktionsplanung bei Bette herausfordernd machen. Dazu gehören insbesondere eine hohe Variantenvielfalt bei gleichzeitig hohen Qualitätsanforderungen. Außerdem führen stochastische Ereignisse wie Nacharbeit an einzelnen Produkten zu unerwarteten Mehraufwänden.

In einer ersten Befragung wurden Belastungsfaktoren und die Einstellung der Beschäftigten gegenüber KI und Digitalisierung abgefragt. Die Beschäftigten zeigten sich offen gegenüber neuen Technologien und gaben an, dass Staus und ungeplante Belastungsspitzen für sie ein Problem darstellen. In einer weiteren, täglichen, Befragung konnten die Ergebnisse weiter differenziert werden und so Ursachen für die Belastung und besonders belastete Arbeitsplätze identifiziert werden.

Aus den arbeitswissenschaftlichen Erkenntnissen werden Anforderungen an ein Assistenzsystem abgeleitet, welches die Planung verbessern soll, um die Beschäftigten zu entlasten. Anschließend wird ein KI-gestütztes Simulationsmodell als Lösungsansatz präsentiert. Das Modell kombiniert klassische Methoden aus der Automatentheorie und der ereignisdiskreten Simulation mit Machine-Learning-Algorithmen, um Steuerungslogiken und stochastische Ereignisse abzubilden.

Es wird zudem ein Workflow zur humanzentrierten Produktionsplanung vorgestellt. Dieser erweitert die klassische Arbeitsvorbereitung durch einen Feedback-Loop, welcher mithilfe des Simulationsmodells Belastungsfaktoren für die Beschäftigten direkt an den Planenden zurückgibt, sodass die Belastungen schon in der Planung verhindert werden können. Ziel ist es, eine gleichmäßige Auslastung der Arbeitsplätze untereinander und im Zeitverlauf zu gewährleisten. Das Assistenzsystem ist zum gegenwärtigen Projektstand in der Lage Belastungen (Anzahl Arbeitsgänge) für einzelne Arbeitsplätze für die nächsten fünf Stunden zuverlässig vorherzusagen. Dies bezieht insbesondere auch stochastisch auftretende Ereignisse wie Nacharbeiten mit ein, welche bisher zu ungeplanter Mehrarbeit an einzelnen Arbeitsplätzen geführt haben. Mithilfe dieser Information sollen in Zukunft gezielte Änderungen am Produktionsplan durchgeführt werden, die Belastungen verhindern. Der Erfolg des Assistenzsystems soll in einer weiteren Befragung am Ende des Projektes evaluiert werden.

1 Einleitung

Das Projekt ImpliKIt ist ein Leuchtturmprojekt des regionalen Kompetenzzentrums Arbeitswelt.Plus im Raum Ostwestfalen-Lippe (OWL). Im Rahmen des Konsortiums sollen Arbeitsforschung und Informatik, basierend auf Methoden der „Künstlichen Intelligenz“ (KI), humanzentrierte Lösungen entwickeln, die dem Mittelstand in OWL den Zugang zu KI-Methoden erleichtern. Das Leuchtturmprojekt ImpiKIt wird in Kooperation mit Bette, einem mittständischen produzierenden Unternehmen mit hoch automatisierter Fertigung, durchgeführt.

Bette ist seit 1952 Spezialist für Badelemente aus glasiertem Titan-Stahl. Das Sortiment umfasst Badewannen, Duschflächen, Duschwannen, Waschtische und passende Installationssysteme. Die Bette-Fertigung verbindet Hightech-Produktion mit Manufakturarbeit, wo sie dem Kundennutzen dient. Mehr als die Hälfte der Produkte werden heute auf Kundenwunsch individualisiert. Aufgrund der hohen Variantenvielfalt können über 35 Mio. unterschiedliche Produkte produziert werden. Die Produktion ist darauf ausgerichtet, Stückzahl 1 in einem sehr hohen Automatisierungsgrad zu fertigen. Die Produkte durchlaufen dabei, mittels einer rechnergesteuerten Förderanlage, die Produktionsschritte in individueller Reihenfolge und belegen Maschinen und Arbeitsplätze unterschiedlich lang. Nacharbeitsgänge und Ausschuss sind weitere Faktoren, die die Produktion beeinflussen. Diese Komplexität macht es, mit konventionellen Methoden der Arbeitsvorbereitung, unmöglich, alle Arbeitsplätze gleichmäßig auszulasten. Es kommt zu Staus an einzelnen Maschinen und / oder Arbeitsplätzen und so zu Belastungsspitzen, in denen die Beschäftigten stark gefordert sind.

Ziel des Leuchtturmprojekts ist es, mit Hilfe künstlicher Intelligenz die Belastung von Beschäftigten sowie die Auslastung von Arbeitsplätzen und Maschinen bis zu 5 Stunden im Voraus zu ermitteln. Dafür stellt Bette langfristig und umfassend Betriebsdaten zu jedem Produkt bereit. Neben der individuellen Seriennummer hält Bette bspw. Arbeitsvorräte, Maschinendaten und Maschinenparameter fest. Das Prognosemodell wird auf historischen Daten aus der Produktion trainiert und verifiziert. In Echtzeit erhobene Daten ermöglichen später im betrieblichen Alltag eine sichere Prognose.

Die Ergebnisse der Simulation fließen in die Arbeitsvorbereitung ein und unterstützen bei der Erstellung von Arbeitsplänen. Basierend auf den ermittelten Auslastungsprognosen können beispielsweise gezielt Produkte mit unkritischen Arbeitsschritten zur Nivellierung der Arbeitsplatzauslastung eingeplant werden. Die Wahrscheinlichkeit, dass es zu Belastungsspitzen für die Mitarbeiter*innen oder zu Materialstaus an Maschinen oder Arbeitsplätzen kommt, wird deutlich reduziert. Durch die entwickelte Lösung treten somit Belastungsspitzen für Beschäftigte nur noch selten auf.

2 Arbeitswissenschaftliche Erhebung der Arbeitsbelastung

2.1 Erste Mitarbeiterbefragung

Zu Beginn des Projekts wurde eine quantitative Befragung der Beschäftigten in der Produktion durchgeführt, um eine Einschätzung der aktuellen Belastungssituation in der Produktion des Praxispartners zu erhalten. Sie bezog sich insbesondere auf die Erfassung der Arbeitssituation bei hohen Produktaufkommen (Staus) und die damit verbundene Wahrnehmung von körperlichen und psychischen Anforderungen und Belastungen der Beschäftigten. Ergänzend wurden Daten zur Einschätzung des (sozialen) Arbeitsumfelds sowie zur Arbeitszufriedenheit erhoben. Auch die grundlegende Einstellung gegenüber neuen Technologien und KI wurde basierend auf einer Selbst- und Fremdeinschätzung erfragt.

Insgesamt konnten 35 Fragebögen ausgewertet werden, was einer Teilnahmequote von 50% entspricht. Im Durchschnitt waren die Befragten seit mehr als 10 Jahren im Unternehmen, wobei 40% der Befragten mehr als 20 Jahre im Unternehmen beschäftigt waren. Das Durchschnittsalter lag zwischen 40 und 49 Jahren. Bei der Untersuchung hat sich herausgestellt, dass insgesamt eine erhöhte Belastung wahrgenommen wurde, was sich sowohl in Form körperlicher Erschöpfung als auch in einem erhöhten Stresslevel äußerte. Die (körperliche) Belastung wurde durchschnittlich mit 6,0 (Skala 1-10) bewertet. 52% der Befragten wählten eine 7 oder höheren Wert. Das Stresslevel unterlag einer durchschnittlichen Bewertung von 6,9 (Skala 1-10). Auch hier gaben 57% der Mitarbeiter eine 7 oder einen höheren Wert an. Ein Faktor, der zu einem erhöhten Stressniveau führte, ist zumindest zweitweise bestehender, starker Zeitdruck. 60% der Befragten gaben an, oft oder immer unter hohem Zeitdruck zu arbeiten.

Das Stauaufkommen spielte eine erhebliche Rolle in Bezug auf die Belastungssituation in der Produktion. 66% der Befragten gaben an, mindestens täglich einen Stau wahrzunehmen. 20% nahmen Staus sogar mehrmals täglich wahr.

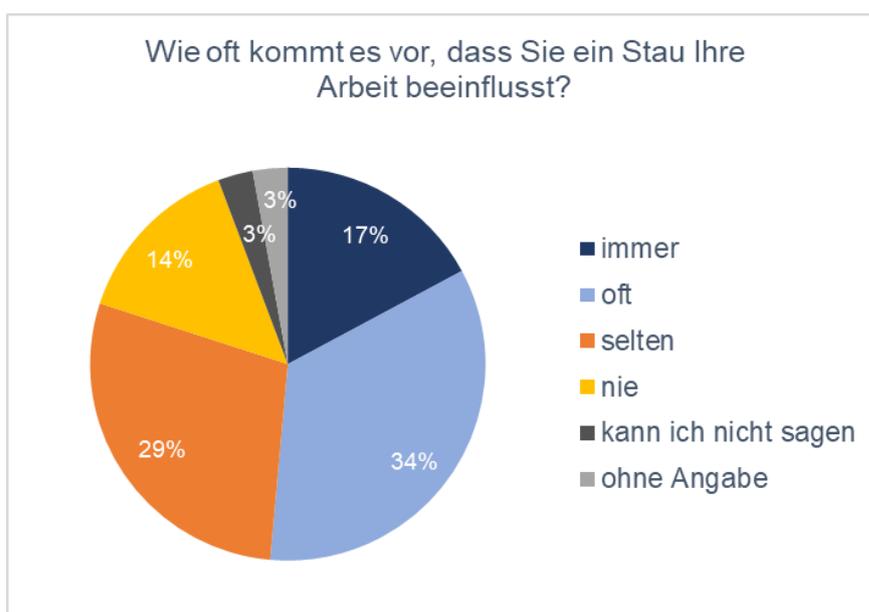


Abbildung 1: Verteilung der Stauwahrnehmung

Nach Aussage von 51% der Mitarbeitenden beeinflussten Staus die Arbeit “oft” oder “immer”. Ein Drittel der Teilnehmenden gab an, dass diese Beeinflussung “sehr stark” oder “stark” sei. Als wahrgenommene Ursachen für die Staus wurden von den Mitarbeiter*innen u.a. eine nicht ausbalancierte Planung sowie technische Probleme genannt.

Die Einstellung der Belegschaft gegenüber neuen Technologien wurde von den Befragten grundsätzlich als positiv eingeschätzt. Ihre eigene Einstellung gegenüber neuen Technologien bewertete die Hälfte der Mitarbeiter*innen als aufgeschlossen (Selbsteinschätzung), die Einstellung der Belegschaft als neutral (Fremdeinschätzung). Bezogen auf die Einstellung gegenüber dem Einsatz von KI fiel die Bewertung insgesamt neutral aus. 30% der Mitarbeiter*innen bezeichneten sich selbst als aufgeschlossen gegenüber dem Einsatz von KI.

2.2 Kurzbefragung

Um die (staubedingte) Belastungssituation im Werk über die Zeit hinweg an verschiedenen Arbeitsplätzen differenzierter zu erfassen, wurde im Zeitraum vom 27.09.2021 bis zum 15.10.2021 täglich eine Kurzbefragung über die an einzelnen Arbeitsplätzen installierten Terminals durchgeführt. Diese Befragung beinhaltete sowohl Fragen, die sich auf die direkte Wahrnehmung der Belastungssituation (Anstrengung, Stress) beziehen, als auch Fragen, die indirekt über die individuelle Einschätzung des Arbeitsvolumens die Beanspruchung der Mitarbeiter widerspiegeln sollten (z.B. Bewertung der Taktzeit). Die Kurzbefragung wurde an 29 Stationen der Produktion und an insgesamt 15 Tagen durchgeführt. Hierzu wurden am Schichtende per Zufallsprinzip 3 Fragen aus einem Fragenpool von insgesamt 17 Fragen beantwortet. Insgesamt wurden 2058 Antworten ausgewertet. Zusätzlich wurde ein Knopf zur Staumeldung an jeder Station installiert, wodurch in diesem Zeitraum 86 Staumeldungen verzeichnet werden konnten.

Die tägliche Kurzbefragung bestätigte grundsätzlich die Kernergebnisse der vorangegangenen quantitativen Befragung. Die Anstrengung des Arbeitstages wurde insgesamt auf mittlerem Niveau mit einer Tendenz zu „eher anstrengend“ angegeben. Außerdem führen die Staus auch in dieser Einschätzung häufig zu einer zusätzlichen Belastung der Produktionsmitarbeiter. Besonders an Arbeitsplatz 7 und 8, in denen die beschichteten Produkte gebrannt werden, wurden viele Staumeldungen (Meldungen per Knopfdruck) verzeichnet:

Eine Korrelationsanalyse bestätigt zuvor dargestellte Zusammenhänge. Die am Arbeitsplatz empfundene Anstrengung korreliert deutlich mit dem empfundenen Stauaufkommen, sowie mit der gesamten Anzahl der bearbeiteten Produkte und dem Nacharbeitsaufkommen. Das Stressempfinden steigt mit Anzahl der bearbeiteten Produkte und der Anstrengung.

Um die Auswirkung durch die KI auf die Arbeitssituation und speziell die Wahrnehmung von körperlichen und physischen Belastungen der Mitarbeiter ermitteln zu können, ist eine vergleichende Befragung nach Einführung der KI geplant und erforderlich.

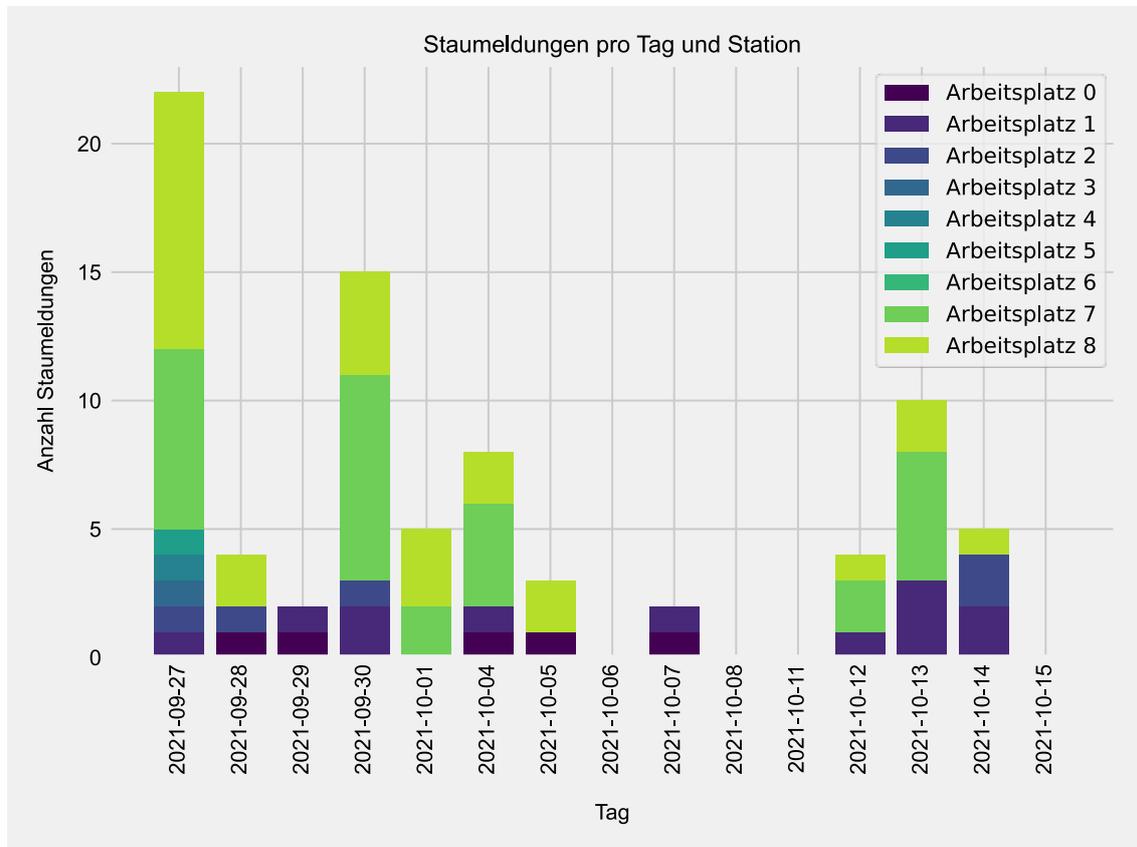


Abbildung 2: Staumeldungen an den verschiedenen Arbeitsstationen

3 Ableitung von Anforderungen an ein KI-Assistenzsystem

Aus der beschriebenen Ausgangssituation beim Praxispartner sowie der arbeitswissenschaftlichen Betrachtung ergeben sich Anforderungen an die technische Lösung.

Humanzentriert: Die entwickelte KI-Lösung muss die Belastung der Beschäftigten berücksichtigen und abbilden. Dafür müssen die in Kapitel 2 ermittelten Belastungssituationen von der KI prognostiziert und einem Nutzer verständlich zur Verfügung gestellt werden. Im Fall von Bette muss die Anzahl an Produkten, die in einem gewählten Zeitintervall bearbeitet werden sollen, zuverlässig pro Arbeitsplatz vorhergesagt werden.

Dynamische Anpassung: Bei einer variantenreichen Fertigung werden schnell neue Arbeitsschritte und Optionen hinzukommen. Auch ändern sich durch die stetige Verbesserung des Produktionsprozesses die Belastungssituationen und -verteilungen. Die Lösung muss sich somit in regelmäßigen Abständen aktualisieren, ohne dass große (programmtechnische) Eingriffe durch den Menschen notwendig sind. Die KI-Lösung muss durch weiteres Training seine Parameter an einen neuen Datensatz anpassen, solange dieser in seiner Form mit dem heutigen identisch ist.

Stochastisch: Viele Einflussfaktoren für Belastung sind im betrachteten Produktionsumfeld stochastischer Natur. Ausfälle von Maschinen oder Qualitätsmängel, die eine Nacharbeit erfordern, treten zufällig auf und beeinflussen die Situation der Beschäftigten am Arbeitsplatz. Die Lösung muss Verzögerungen und Nacharbeiten korrekt abbilden. Für die wesentlichen Produktspezifikationen muss eine Wahrscheinlichkeit für Nacharbeit an der jeweiligen Arbeits- bzw. Prüfstation ermittelt werden.

Zeithorizont: Ein Eingreifen in den Produktionsprozess ist durch den hohen Automatisierungsgrad sehr aufwändig. Belastungssituationen sollten deshalb schon bei der Produktionsplanung berücksichtigt werden. Bis die neuen Produkte die letzten Stationen in der Fertigungskette erreicht haben, vergehen etwa fünf Stunden. Deshalb muss die KI-Lösung einen Zeithorizont von fünf Stunden im Voraus prognostizieren können.

Die hier dargestellten Anforderungen bilden die Grundlage für das später entwickelte Assistenzsystem.

4 Technische Umsetzung eines KI-Assistenzsystems für die humanzentrierte Produktionsplanung

Um die oben genannten Anforderungen zu erfüllen, wird eine Lösung entwickelt, die dynamisch aus Daten ein Simulationsmodell für die Fertigung des Praxispartners erstellt. Dieses Simulationsmodell wird anschließend in den Workflow der Produktionsplaner integriert. Dieser Ziel-Workflow ist in Abbildung 4 dargestellt. Der bisherige Workflow entspricht einer klassischen Produktionsplanung. Die Arbeitsvorbereitung erstellen einen Produktionsplan (Reihenfolgeplan) aus den Kundenaufträgen, der anschließend in der Fertigung ausgeführt wird. Dieses Vorgehen soll durch ein KI-gestütztes Simulationsmodell, das auf Basis von historischen Daten trainiert wird, ergänzt werden. Das Simulationstool wird von den Planern genutzt, um die von ihnen erstellten Produktionsreihenfolge zu simulieren und zu verifizieren. Das Simulationstool informiert die Planer über mögliche Engpässe oder Überlastungen der Beschäftigten, die innerhalb der nächsten fünf Stunden auftreten können. Die Planer nehmen anschließend die notwendigen Änderungen vor, um den betreffenden Arbeitsplatz bzw. die Beschäftigten zu entlasten.

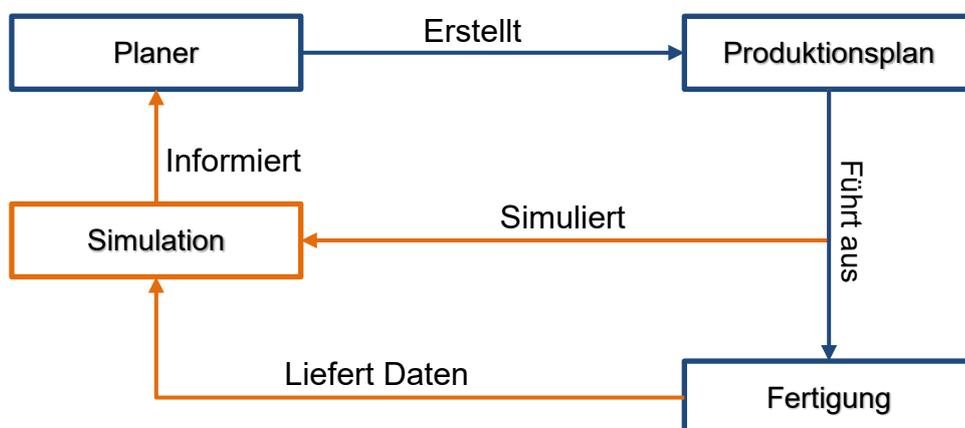


Abbildung 3: Workflow der Produktionsplaner mit dem Simulationstool. In blau der bestehende Workflow und in orange der neue Feedback-Loop, der in ImpliKIt umgesetzt wird.

Die Fertigung liefert sowohl Live-Daten als auch historische Daten an das Simulationsmodell. Letztere werden verwendet, um das Simulationsmodell in einem Trainingslauf zu initialisieren und die wichtigen Parameter zu adaptieren. Das Modell nutzt Live-Daten aus der Produktion, um zum Simulationsstart die aktuelle Belegung der Arbeitsplätze und des Transportsystems auszulesen. Im Trainingslauf müssen zunächst alle wichtigen Arbeitsplätze und das Transportsystem abgebildet werden. Datengrundlage für das Simulationsmodell bilden die Positionsdaten und die Produktdaten. Jede Meldung von Positionsdaten enthält eine eindeutige Produktkennung, einen Zeitstempel, eine Position und eine Tätigkeit, die am Produkt durchgeführt wird (oder durchgeführt werden soll). Das Verhalten eines einzelnen Produktes kann als stochastischer zeitbewerteter Automat $N_t = (\mathcal{Z}, \mathcal{V}, \mathcal{W}, L, \tau, \mathcal{Z}_0)$ mit Ein- und Ausgängen beschrieben werden (Lunze, 2013). Dabei bezeichnet

\mathcal{Z} Menge von Zuständen,

\mathcal{V} Menge von möglichen Eingaben,

\mathcal{W} Menge von möglichen Ausgaben (Ausgabealphabet),

L Verhaltensrelation $L : \mathcal{Z} \times \mathcal{Z} \times \mathcal{V} \rightarrow [0, 1]$,

τ Relation von Verweilzeiten $\tau : \mathcal{Z} \times \mathcal{Z} \rightarrow \mathbb{R}$,

\mathcal{Z}_0 Menge der möglichen Anfangszustände.

Die Zustände stellen alle Situationen dar, in denen sich ein Produkt in der Fertigung befinden kann. Bei Bette können an vielen Positionen verschiedene Tätigkeiten durchgeführt werden, sodass ein Zustand als Kombination von Position und Tätigkeit definiert wird. Dazu werden in den Daten (Positionsmeldungen) alle Kombinationen von Tätigkeit und Position gesucht, die dann die Menge \mathcal{Z} bilden.

Eingaben des Automaten sind Produkteigenschaften, die als Vektor codiert werden und Informationen über den Sollweg des Produkts durch die Produktion enthalten. Der Sollweg bezeichnet eine Untermenge von \mathcal{Z} und repräsentiert den Weg, den ein Produkt im Idealfall durch die Produktion bis zur Fertigstellung nehmen wird. Er wird One-Hot-Codiert und ebenfalls als Vektor dargestellt. Durch die Verknüpfung mit den Produkteigenschaften ergibt sich der Eingabevektor $v \in \mathcal{V}$, der somit das jeweilige Produkt und den entsprechenden Sollweg beschreibt.

Das Ausgabealphabet des Automaten besteht in diesem Fall aus der Menge der Zustände \mathcal{Z} und Zeitstempeln t . Der Automat beschreibt welche Zustände zu welchem Zeitpunkt erreicht werden.

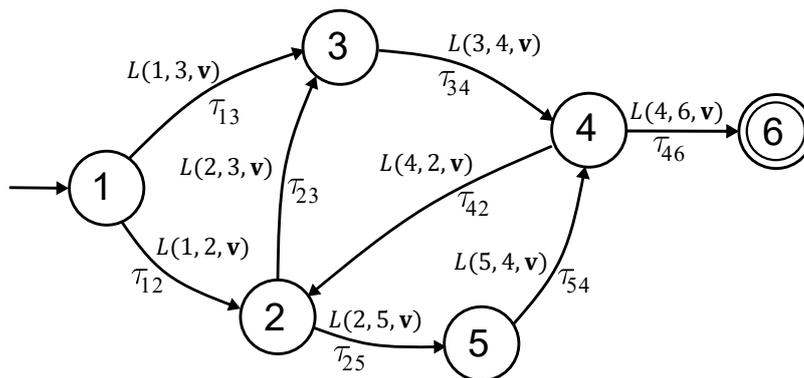


Abbildung 4: Darstellung des zeitbewerteten E/A-Automaten, der ein einzelnes Produkt beschreibt. In diesem Beispiel gibt es 6 Zustände. Der eingehende Pfeil links zeigt auf den Anfangszustand, der doppelte Kreis um Zustand 6 zeigt an, dass es sich um einen Endzustand handelt.

Die Verhaltensrelation L ist in diesem Fall eine Funktion, die in Abhängigkeit von der Eingabe Zuständen Wahrscheinlichkeiten zuordnet, mit der das Produkt von z nach z' (Nachfolgezustand) wechselt. Um dieses Verhalten zu erlernen, wird in den Produktionsdaten nach Produkten gesucht, die sich in einem Zustand z befunden haben. Anschließend kann anhand der Daten ermittelt werden in welchen Folgezustand z' das Produkt gewechselt ist. So kann für alle Kombinationen z, z' gezählt werden wie häufig Produkte von z nach z' gewechselt werden. Daraus ergibt sich eine Übergangsmatrix G die als gerichteter Graph visualisiert werden kann. Dieser Graph stellt ein einfaches Modell der Produktion dar. Alle erreichbaren Positionen sowie die Transportwege können abgebildet werden. Die zugehörige Verhaltensrelation $L(z, z')$ kann im einfachsten Fall die relative Häufigkeit aus der Matrix G zurückgeben. In vielen Fällen wird die Entscheidung, wo ein Produkt bearbeitet wird, oder die Wahrscheinlichkeit, mit der es in Nacharbeit kommt, durch die Produkteigenschaften bestimmt. Um solche komplexeren Zusammenhänge abbilden zu können werden ML-Modelle eingesetzt, die den Zuständen zugeordnet und im Folgenden näher beschrieben werden.

Für jeden Zustand, der mehr als eine ausgehende Kante aufweist, wird ein lokales stochastisches Modell erstellt. Aufgrund der großen Anzahl an lokalen Modellen, müssen diese in kurzer Zeit trainierbar sein. Aus diesem Grund wurde eine logistische Regression als Modell gewählt. Eingangsgrößen für jedes lokale Modell sind die Produkteigenschaften (Eingabe \vec{v}). Die Ausgangsgrößen sind Wahrscheinlichkeiten für jede ausgehende Kante des betrachteten Zustands. Um die Modelle zu trainieren, wird für jedes Modell eine eigene Datenbasis gebildet. Für alle Produkte, die im Training durch den jeweils betrachteten Zustand gelaufen sind, werden die Eigenschaften (im Anwendungsfall Form, Farbe, Sollweg...) und der Nachfolgezustand (Folgeknoten) festgehalten. Produkteigenschaften sind dabei die Spezifikation von Form, Farbe und Sonderkonfigurationen, welche als Vektor aus binären Variablen kodiert werden können. Es ist davon auszugehen, dass an einer bestimmten Stelle in der Produktion nur ein kleiner Teil der Eingangsgrößen einen Einfluss hat. Deshalb werden die logistischen Regressionsmodelle mithilfe einer Lasso Regularisierung trainiert (Hastie, Tibshirani, & Friedman,

2009). Das Training findet dabei nach dem One-Vs-Rest Schema statt, sodass für jede Kante im Graphen ein eigenes (lokales) Regressionsmodell trainiert wird (Chmielnicki & Stapor, 2016). An einem Entscheidungsknoten (Zustand) werden für n mögliche Ausgänge n Modelle trainiert, welche eine Wahrscheinlichkeit ermitteln, ob ein Produkt diese Kante passiert oder nicht (binär). Ein Problem, das bei dieser Strategie bekanntermaßen auftritt, ist eine Ungleichverteilung der Klassen. Für viele Ausgänge n , gibt es mehr Produkte, die nicht n gewählt haben als solche, die n gewählt haben. Dieses Problem kann umgangen werden, indem die Stichprobe durch Resampling zugunsten der unterrepräsentierten Klasse verändert wird (He & Garcia, 2009). Die Wahrscheinlichkeiten der einzelnen (lokalen) Modelle müssen zusammengefasst werden, sodass sie in Summe eins ergeben. Die finale Wahrscheinlichkeit für jede Kante wird deshalb mit der Summe der Wahrscheinlichkeiten normiert. Der Workflow zur Erstellung der Verhaltensrelationen ist in Abbildung 6 dargestellt.

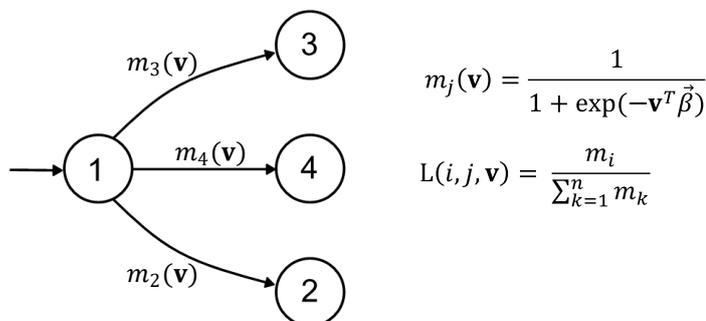


Abbildung 5: Logistische Regressionsmodelle als Abbildung der Steuerungslogik. Vom Zustand 1 können drei Folgezustände angenommen werden. Es werden drei Logistische Regressionsmodelle ($m_j(\mathbf{v})$). Jedes gibt die Wahrscheinlichkeit an der jeweiligen Kante j zu folgen. Damit die Wahrscheinlichkeiten in Summe 1 ergeben müssen die Einzelwahrscheinlichkeiten normiert werden.

Das dargestellte Klassifikationsschema kann auf alle binären Klassifikationsmodelle mit probabilistischer Ausgabe übertragen werden. Die ML-Modelle erzeugen die benötigten Wahrscheinlichkeiten $L(z, z', \mathbf{v})$.

Die Verweilzeiten in jedem Zustand werden durch die Funktion $\tau(z, z')$ beschrieben. Ähnlich wie für die Verhaltensrelationen werden auch hier zunächst die historischen Daten analysiert. Für alle Kanten im Graphen (Abbildung 5) können die Ankunftszeiten der Produkte an Ursprungs- und Zielknoten verglichen werden. Die durchschnittliche Zeitspanne zwischen allen Zustandspaaren z, z' wird gespeichert und als Verweilzeit $\tau(z, z')$ verwendet.

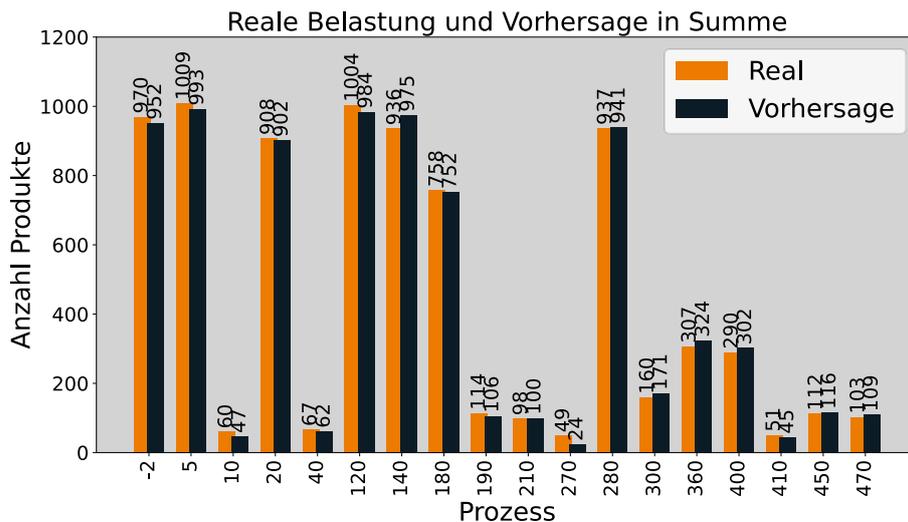


Abbildung 6: Vorhersage der Wege von 1000 Produkten durch den Produktionsprozess. Hier können auch stochastisch auftretende Arbeitsgänge (300, 360, 400) präzise vorhergesagt werden.

Damit das Simulationstool getestet und bewertet werden kann, wurden 1000 Produkte und deren Wege in der Fertigung simuliert. Abbildung 7 zeigt, wie oft dabei einzelne Punkte im Produktionssystem angefahren wurden. Verglichen wird dies mit den realen Pfaden der Produkte. Die Vorhersage der Belastung ist in Summe dabei präzise genug, um Belastungsspitzen vom normalen Betrieb zu unterscheiden, die Abweichung liegt in fast allen Punkten unter 10%.

5 Fazit und Ausblick

Aus arbeitswissenschaftlicher Sicht ist festzuhalten, dass hier gezeigt werden konnte, dass eine nicht ausbalancierte Produktion und damit einhergehende Staus eine Belastung für die Beschäftigten darstellen. Sowohl in der quantitativen Befragung zu Beginn des Projekts als auch in der Kurzbefragung konnten Zusammenhänge zwischen Stau-Aufkommen und körperlicher Belastung gezeigt werden. Auffällig ist jedoch, dass nicht alle Stationen der Produktion gleichermaßen durch Staus betroffen sind. Die angewandte Methodik der Kurzbefragung am Arbeitsplatz zeigt hier besondere Vorteile. So ist es möglich, Arbeitsplätze zu identifizieren, die von den untersuchten Belastungssituationen stärker betroffen sind als andere.

Als Lösung für die Beanspruchung im Tagesgeschäft konnte bereits in der quantitativen Befragung der Wunsch der Beschäftigten nach einer ausbalancierteren Planung, sowie die Vermeidung technischer Störungen identifiziert werden. Die Befragungen bekräftigen damit den Bedarf für ein KI-gesteuertes Assistenzsystem, das die Produktionsplaner unterstützt, einen ausgewogenen Produktionsprozess zu gewährleisten. Um die Effektivität des der KI-Lösung zu evaluieren, ist nach Einführung des Simulationstools eine weitere quantitative Befragung geplant.

Das KI-Assistenzsystem wurde in Zusammenarbeit und für Bette entwickelt. Produkte können unterschiedliche Arbeitsschritte und Wege verfolgen und Schleifen in der Fertigung durchlaufen. Eine Übertragung des Modells auf andere Produktionssysteme, die eine ähnliche Fertigung besitzen, ist möglich. Es können mithilfe des Systems Produktionen modelliert werden, welche einzelne, identifizierbare Produkte durch ein festes Wegenetz transportieren. Dabei können Steuerungsentscheidungen im Produktionsprozess, sowie Nacharbeiten stochastischer Natur durch KI-Modelle abgebildet werden. Ein wichtiger Faktor für das Training der Modelle sind die vorliegenden Produktions- und Planungsdaten. Die Verfolgung der Produkte in den Daten im Verlauf der Fertigung muss nahezu lückenlos sein. Historische Daten verbessern die Modellgüte. Für eine Übertragung auf andere Produktionsprozesse muss geprüft werden, ob eine hinreichende Datengrundlage vorliegt oder aufgebaut werden kann.

Die entwickelte Lösung ist ein Assistenzsystem. Es ist nicht dazu gedacht, den menschlichen Entscheidungsvorgang zu ersetzen. Vielmehr liefert das System notwendige Informationen für bessere Entscheidungen und entlastet damit sowohl die Beschäftigten in der Produktion als auch die Planenden in der Arbeitsvorbereitung. Durch die Kooperation steigt das Vertrauen in die Lösung und kritische Fehler sowohl auf menschlicher wie auf technischer Seite können vermieden werden. Dies soll langfristig das Vertrauen und die Technologieakzeptanz erhöhen. Der Beitrag zeigt außerdem, wie klassische Methoden, wie die Simulation, von ML-Methoden profitieren und so ihr volles Potential auch in kleinen und mittelständischen Unternehmen entfalten können. Das Projekt leistet auf diese Weise sowohl einen Beitrag zur technischen Entwicklung moderner IT-Lösungen als auch zur betrieblichen Gesundheit der Beschäftigten sowie der Technologieakzeptanz im Unternehmen.

6 Literaturverzeichnis

- Chmielnicki, W., & Stapor, K. (2016). Using the one-versus-rest strategy with samples blancing to improve pairwise coupling classification. *International Journal of Applied Mathematics and Computer Science*, 191–201.
- Hastie, T., Tibshirani, R., & Friedman, J. H. (2009). *The Elements of Statistical Learning. Data Mining, Inference and Prediction*. New York: Springer.
- He, H., & Garcia, E. A. (2009). Learning from Imbalanced Data. *IEEE Transactions on Knowledge and Data Engineering*, 1263–1284.
- Lunze, J. (2013). *Ereignisdiskrete Systeme*. Oldenbourg Wissenschaftsverlag.

IMPRESSUM

Verantwortlich für den Inhalt

Lukas Vollenkemper, Fachhochschule Bielefeld
Marvin Mönikes, Bette GmbH & Co. KG
Florian Wortmann, Fachhochschule der Wirtschaft
Melanie Rudolph-Puls, Fachhochschule der Wirtschaft
Prof. Dr. Martin Kohlhase, Fachhochschule Bielefeld
Prof. Dr. Angelika Röchter, Fachhochschule der Wirtschaft
Prof. Dr. Christian Ewering, Fachhochschule der Wirtschaft

Fotos/Abbildungen

Titel: Bette GmbH & Co. KG
S. 2: Fachhochschule Bielefeld, Fachhochschule der Wirtschaft, Bette GmbH & Co. KG
S. 6, 8, 9, 11, 12, 13: Fachhochschule Bielefeld

Gestaltung & Redation

Salome Leßmann
it's OWL Clustermanagement GmbH

Empfohlene Zitierweise

Vollenkemper, L.; Mönikes, M.; Wortmann, F.; Rudolph-Puls, M.; Kohlhase, M.; Röchter, A.; Ewering, C. (2023): Humanzentrierte Produktionsplanung mit KI - Entwicklung eines Assistentensystems. Working-Paper-Reihe des Kompetenzzentrums Arbeitswelt.Plus, Paderborn, Nr. 5, <https://doi.org/10.55594/UXIT4205>

Erscheinung

03/2023



Möchten Sie mehr über die Forschungsarbeit im Kompetenzzentrum Arbeitswelt.Plus erfahren? Auf unserer Website finden Sie detaillierte Informationen zu allen Forschungsschwerpunkten.

Kompetenzzentrum Arbeitswelt.Plus

c/o it's OWL Clustermanagement GmbH

Zukunftsmeile 2

33012 Paderborn

www.arbeitswelt.plus



GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung

Dieses Forschungs- und Entwicklungsprojekt wird durch das Bundesministerium für Bildung und Forschung (BMBF) im Programm „Zukunft der Wertschöpfung – Forschung zu Produktion, Dienstleistung und Arbeit“ gefördert und vom Projektträger Karlsruhe (PTKA) betreut. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei der Autorin / beim Autor.