

Anwendung von Support Vector Regression zur vorausschauenden Identifikation von Störungswirkungen in der Produktionslogistik

Application of support vector regression for the predictive identification of disruptive effects in production logistics

*Nina Vojdani
Björn Erichsen*

*Lehrstuhl Produktionsorganisation und Logistik
Fakultät für Maschinenbau und Schiffstechnik
Universität Rostock*

Die Liefertermintreue ist eine der wichtigsten logistischen Kennzahlen. Diese hängt insbesondere bei produzierenden Unternehmen in hohem Maße von der Einhaltung geplanter Fertigstellungstermine ab. Unerwartet auftretende Störungen verursachen signifikante Abweichungen von geplanten Prozessabläufen und beeinträchtigen somit die Einhaltung der Fertigstellungstermine. Der Einsatz von Frühwarnsystemen im Rahmen von betrieblichen Störungsmanagement kann dazu beitragen, potentielle Störungswirkungen frühzeitig zu identifizieren, um somit den Handlungszeitraum für adäquate Reaktionen auf Störungen zu verlängern. In diesem Beitrag wird daher die Untersuchung der Support Vector Regression (SVR) bezüglich der Anwendbarkeit und Einsatzfähigkeit zur Identifikation von Störungswirkungen in der Produktionslogistik vorgestellt.

[Schlüsselwörter: Frühwarnung, Support Vector Regression, Störungswirkungen, Produktionslogistik]

On-time delivery performance is one of the most important logistic indicators. In particular, for producing companies the on-time delivery performance depends to a high degree on the fulfillment of planned completion dates. Unexpected disruptions cause significant deviations from planned processes and thus impair the compliance with the completion dates. The use of early warning systems in the context of operational disruption management can help to identify potential disruptive effects at an early stage in order to extend the action period for adequate reactions to disruptions. Therefore, in this paper the study of support vector re-

gression (SVR) with regard to applicability and operational capability for the identification of disruptive effects in production logistics is presented.

[Keywords: Predictive Monitoring, support vector regression, disruptive effects, production logistics]

1 EINLEITUNG

Entwicklungen der vergangenen Jahrzehnte haben dazu geführt, dass sich Störungen jeglicher Art in der heutigen Zeit deutlich stärker auf logistische und produktionsbezogene Prozesse auswirken. Ein wesentlicher Grund dafür ist der Abbau von Zeit-, Mengen- und Kapazitätspuffer zum Zwecke der Kostenreduktion und Steigerung der Effizienz. Vor allem bei der auftragsorientierten Produktion wirken sich unvorhergesehene Störungen unmittelbar auf den Fertigstellungstermin und somit auch auf die Liefertermintreue aus. Da die Einhaltung der zugesagten Liefertermine für produzierende Unternehmen eines der wichtigsten logistischen Ziele ist [ScS11], müssen potentielle Auswirkungen von unvorhergesehenen Störungen, die zu Verzögerungen bei der Auftragsabwicklung führen, rechtzeitig erkannt und antizipiert werden.

Diese Aufgabe ist dem Gebiet der Frühwarnung und dem betrieblichen Störungsmanagement zuzuordnen. Ausgangspunkt ist die prädiktive Identifikation von zukünftigen Entwicklungen, die potentielle Beeinträchtigungen für die Auftragsabwicklung bedeuten können. Damit verbunden sind die Generierung einer Frühwarnung und die Aktivierung des betrieblichen Störungsmanagements, um entsprechende Gegenmaßnahmen rechtzeitig einzuleiten.

Es existieren verschiedene Methoden und Verfahren, die zum Aufbau eines Frühwarnsystems genutzt werden können. Im Rahmen dieses Beitrags wird ein datengetriebenes System auf Basis von Support Vector Regression vorgestellt. Dieses System stellt eine Weiterentwicklung des am Lehrstuhl für Produktionsorganisation und Logistik (LPL) der Universität Rostock entwickelten Predictive-Monitoring-Systems (PMS) dar [VE18]. Im Gegensatz zu der bisherigen Verwendung von künstlichen neuronalen Netzen werden Support Vector Regressionen als Prognosefunktionen im Sinne der Frühwarnung eingesetzt, um den zukünftigen Zustand eines betrachteten Unternehmensbereiches bzw. Prozesses mittels ausgewählter Key Performance Indicators (KPIs) zu prognostizieren und somit kritische Entwicklungen und potentielle Störungswirkungen frühzeitig identifizieren zu können.

Die Motivation für die Anwendung von datengetriebenen Verfahren begründet sich darin, dass heutzutage bereits eine Vielzahl von Produktions- und Logistiksystemen verschiedene Daten generieren, die die einzelnen logistischen und produktionsbezogenen Prozessschritte abbilden [FKAL15]. Der Vorteil gegenüber modellgetriebenen Verfahren wie z.B. der ereignisdiskreten Simulation liegt darin, dass keine aufwendigen Modelle für spezifische Anwendungsfälle erstellt werden müssen. Daher bieten datengetriebene Verfahren auch ein hohes Maß an Adaptierbarkeit für verschiedene Anwendungsfälle. Bisher wurden datengetriebene Verfahren wie Support Vector Regression überwiegend in Bereichen wie der Naturwissenschaften und Medizin eingesetzt. Jedoch verfügen Produktion und Logistik über vielversprechende Anwendungspotenziale [FKAL15]. Um diese Potenziale zu erschließen, muss erforscht werden, welche datengetriebenen Verfahren für welche Anwendungsbereiche innerhalb der Produktion und Logistik nutzbringend eingesetzt werden können.

2 STAND DER FORSCHUNG

In diesem Abschnitt werden bisherige Arbeiten aus dem Bereich der Frühwarnung und des Störungsmanagements für logistische und produktionsbezogene Anwendungsfälle aufgezeigt. Da die Kernfunktion des in diesem Beitrag vorgestellten Frühwarnsystems die Prognose der voraussichtlichen Durchlaufzeiten von eingelasteten Produktionsaufträgen ist, wird auch auf verschiedene Forschungsarbeiten eingegangen, die sich mit Prognose von Durchlaufzeiten beschäftigen.

Hotz [Hot07] beschäftigt sich mit simulationsbasierten Frühwarnsystemen zur Unterstützung der operativen Produktionsteuerung und -planung in der Automobilindustrie. Die Frühwarnsysteme werden in der operativen Anwendung mit dem gegenwärtigen Systemzustand des realen Systems initialisiert und sind somit in der Lage zukünftige Systemzustände zu prognostizieren. Durch die

Vorhersage von Ereignissen, Zuständen oder Entwicklungen können frühzeitig geeignete Gegenmaßnahmen eingeleitet werden.

Czaja [Cza09] entwickelt ein indikatorbasiertes Frühwarnsystem für das Qualitätsmanagement in der Automobilindustrie. Auf der Grundlage einer umfangreichen Untersuchung in der deutschen Automobilindustrie identifiziert Czaja verschiedene Frühwarnindikatoren. Aus diesen werden Informationen abgeleitet, um kritische Entwicklungen zu identifizieren und frühzeitig Entstörungsmaßnahmen einleiten zu können.

Genç [Gen15] stellt die Entwicklung eines Frühwarnsystems für ein adaptives Störungsmanagement vor. Das Anwendungsziel ist die Absicherung von Produktionsabläufen bei serienproduzierenden Unternehmen in komplexen Lieferketten. Die Grundlage des Frühwarnsystems bildet der Einsatz der RFID-Technologie zur echtzeitnahen und ereignisbasierten Informationsgewinnung und -bereitstellung. Regelbasierte Verfahren nutzen die bereitgestellten Informationen zur Identifikation von kritischen Ereignissen, die auf den Frühwarnkategorien Produkt, Prozess und Lieferant basieren.

Alenezi et al. [AMT07] adressieren das Problem der Lieferterminbestimmung bei einer kundenauftragsorientierten Produktion. Dafür wird ein System entwickelt, welches mittels Support Vector Regression die voraussichtliche Durchlaufzeit eines eingegangenen Kundenauftrags prognostiziert. Auf dieser Basis wird dann ein Liefertermin festgelegt. Alenezi et al. testen verschiedene Kernels und Verlustfunktionen der Support Vector Regression anhand von drei unterschiedlichen Produktionsszenarien. Diese Arbeit setzt den Fokus auf die Bestimmung von Lieferterminen. Eine prozessbegleitende Prognose der Auftragsdurchlaufzeiten insbesondere unter dem Einfluss von Störungen wird nicht durchgeführt.

Lingitz et al. [LGAGPM18] stellen den Einsatz von verschiedenen Verfahren des maschinellen Lernens in der Halbleiterfertigung zur Prognose von Auftragsdurchlaufzeiten vor. Dabei finden keine prozessbegleitende Prognose sowie keine explizite Störungsbetrachtung statt.

Pfeiffer et al. [PGKM16] präsentieren eine Methode zur Bestimmung von Auftragsdurchlaufzeiten, die auf der Kombination von Simulation und statistischem Lernen basiert. Dabei werden die ereignisdiskrete Simulation sowie Lineare Regressionsmodelle und Entscheidungsbäume eingesetzt. Dieser Ansatz ist für die prozessbegleitende Prognose ausgelegt und zielt darauf ab, Störungen rechtzeitig zu erkennen.

Vojdani et al. [VEL17] stellen ein agentenbasiertes Assistenzsystem für die Feinplanung und Lieferterminbestimmung vor. Der Fokus liegt in der Anwendung bei auftragsorientierten Einzel- und Variantenfertigungen. Dabei

erfolgt die Lieferterminbestimmung unter Berücksichtigung der aktuellen Produktionssituation.

Die bisherigen Recherchen ergaben, dass sich keine der Forschungsarbeiten mit Frühwarnsystemen und betrieblichen Störungsmanagement unter Anwendung der Support Vector Regression im Bereich der Produktionslogistik beschäftigen.

3 FRÜHWARNSYSTEM ZUR IDENTIFIKATION VON STÖRUNGSWIRKUNGEN

3.1 GRUNDIDEE

In Abbildung 1 ist das grundlegende Vorgehen zur Identifikation von Störungswirkungen dargestellt. Es wird der Bearbeitungszeitraum für einen spezifischen Produktionsauftrag gezeigt. Nach Einlastung des Auftrags in die Produktion werden entlang des Produktionsverlaufs zu bestimmten Zeitpunkten (Checkpoints) die aktuellen Betriebsdaten des Produktionssystems zu relevanten Kennzahlen verdichtet.

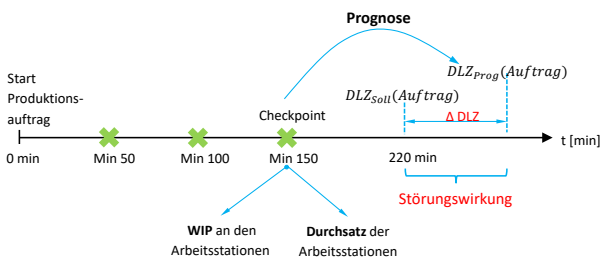


Abbildung 1. Grundlegendes Konzept zur Prognose von Störungswirkungen (in Anlehnung an [VE18])

Diese spiegeln den aktuellen Zustand des Systems, in dem der betrachtete Auftrag bearbeitet wird, wider und werden als Input für die Prognose verwendet. Das Prognoseverfahren ist in der Lage auf Basis des aktuellen Systemzustands die voraussichtliche Durchlaufzeit des gesamten betrachteten

Produktionsauftrags vorauszusagen. Es wird bei der Prognose davon ausgegangen, dass ab dem Prognosezeitpunkt der weitere Produktionsverlauf ohne Störungen im System verläuft. Das bedeutet die prognostizierte Durchlaufzeit ist nur solange gültig, bis erneut eine Störung auftritt. Diese Störung wird dann bei der Prognoserechnung an dem Checkpoint, der unmittelbar nach dieser Störung liegt, berücksichtigt. Mit der erneuten Prognoserechnung wird ein neuer Wert für die voraussichtliche Durchlaufzeit ermittelt. Anzumerken ist, dass die Prognosen zu Zeitpunkten innerhalb der Auftragsausführung durchgeführt werden, die vorher bei den Trainingsdaten über abgeschlossene Produktionsaufträge des gleichen Typs definiert worden sind.

Die prognostizierte Durchlaufzeit des betrachteten Auftrags wird mit der geplanten Soll-Durchlaufzeit abgeglichen.

$$\Delta DLZ = DLZ_{prog} - DLZ_{soll}$$

Das ΔDLZ drückt eine potentielle Störungswirkung aus, welche sich unter den gegebenen Umständen voraussichtlich entfalten wird. Da sich eine ungeplante Verlängerung der geplanten Durchlaufzeit unmittelbar auf die Einhaltung eines zugesagten Liefertermins auswirkt, sollten frühzeitig Gegenmaßnahmen eingeleitet werden, um der prognostizierten Störungswirkung entgegenzuwirken. [VE18]

3.2 SYSTEMARCHITEKTUR

In diesem Abschnitt wird die Systemarchitektur des Frühwarnsystems vorgestellt, siehe Abbildung 2. Die Support Vector Regressionen, welche als Prognosefunktionen fungieren, sind der zentrale Bestandteil des Frühwarnsystems. Der Prognoseprozess besteht aus zwei grundlegenden Schritten.

Im ersten Schritt müssen zunächst sogenannte Trainingsdaten erzeugt werden. Diese Trainingsdaten sind aufbereitete, strukturierte Prozessdaten von bereits abgeschlossenen Produktionsaufträgen.

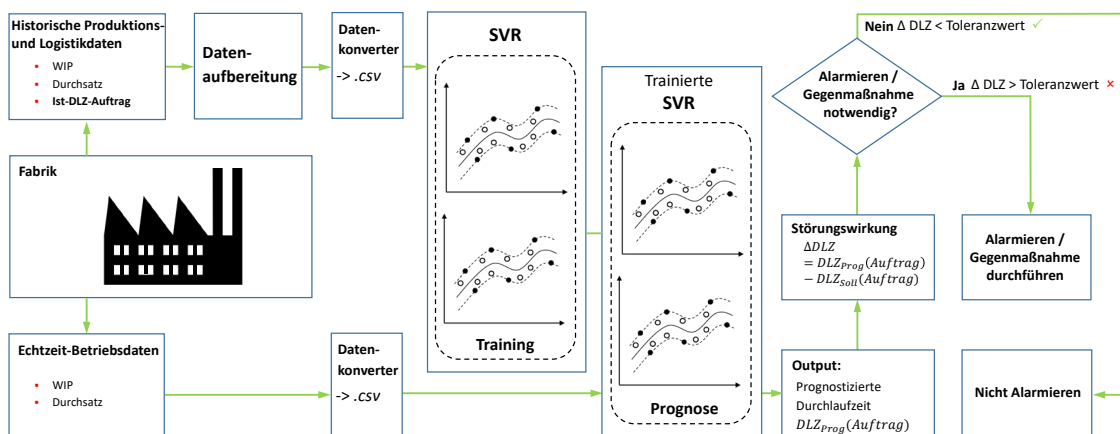


Abbildung 2. Systemarchitektur des SVR-basierten Frühwarnsystems (in Anlehnung an [VE18])

Diese Prozessdaten werden zu relevanten Leistungskennzahlen aggregiert und den Support Vector Regressionen als Input bereitgestellt. Diese können trainiert werden und erlernen dadurch das systemdynamische Verhalten der zugrundeliegenden Produktionslogistik.

Im zweiten Schritt, welcher die Einsatzphase darstellt, werden die im operativen Betrieb erfassten Maschinen- und Betriebsdaten von Produktions- und Logistikabläufen den trainierten Support Vector Regressionen in Echtzeit bereitgestellt. Dafür müssen die entsprechenden Systeme der betrachteten Produktion und Logistik mit performanten Informations- und Kommunikationstechnologien ausgestattet sein. Der Ausgabewert einer Support Vector Regression ist die prognostizierte Durchlaufzeit eines beobachteten Produktionsauftrags, welche unter den zum Prognosezeitpunkt herrschenden Bedingungen in der ausführenden Produktion und Logistik voraussichtlich erreicht wird. Die prognostizierte Durchlaufzeit wird mit der geplanten Soll-Durchlaufzeit des beobachteten Produktionsauftrags verglichen. Überschreitet die Differenz (ΔDLZ) einen definierten Toleranzwert, wird eine Frühwarnung herausgegeben und die Einleitung von Gegenmaßnahmen empfohlen.

3.3 DATENMODELL UND DATENAUFBEREITUNG

Das Datenmodell gilt sowohl für die Erhebung von Trainingsdaten als auch für die Erfassung von Echtzeitdaten im operativen Einsatz des Frühwarnsystems. Dabei werden die Messungen der Logistik- und Produktionsdaten zur Erhebung der Leistungskennzahlen ereignisdiskret durchgeführt. Im Folgenden wird auf die im Rahmen dieses Beitrags verwendeten Kennzahlen eingegangen.

Durchsatzleistung der Arbeitsstation i (D_T^i [stk/h]):

- i Index der Arbeitsstation
- j Index der auf Arbeitsstation i bearbeiteten Teile
- m Anzahl Arbeitsstationen
- n Anzahl der auf Arbeitsstation i bearbeiteten Teile
- T Zeitwert am Checkpoint

$$D_T^i = \frac{j}{T} \text{ mit } i = 1, \dots, m \text{ und } j = 1, \dots, n$$

Work in Progress bei Arbeitsstation i (WIP^i [stk]):

- WIP^i Work in Progress bei Arbeitsstation i inklusive vorgelagertem Puffer

- WIP_T^i Work in Progress am Checkpoint
- i Index der Arbeitsstation
- m Anzahl Arbeitsstationen
- t Zeitwert

$$WIP_{t+1}^i = \begin{cases} WIP_t^i + 1, & \text{wenn Zugang} \\ WIP_t^i - 1, & \text{wenn Abgang} \end{cases}$$

mit $i = 1, \dots, m$

Während des operativen Einsatzes werden an den festgelegten Checkpoints die aktuellen Logistik- und Produktionsdaten der jeweiligen Support Vector Regression zur Prognosedurchführung bereitgestellt, siehe Abbildung 3.

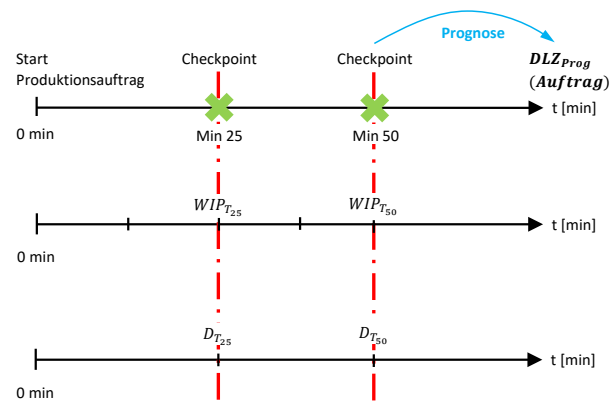


Abbildung 3. Datenmodell (in Anlehnung an [VE18])

Wie in Abschnitt 3.1 beschrieben, wird bei der Prognose davon ausgegangen, dass ab dem Prognosezeitpunkt der weitere Produktionsverlauf ohne Störungen im System verläuft. Daher gehört zu den historischen Daten eines abgeschlossenen Produktionsauftrags auch die genaue Dokumentation der aufgetretenen Störungen. Für die Aufbereitung der Trainingsdaten ist zu beachten, dass die Checkpoints frühestens nach Beendigung der letzten aufgetretenen Störung gesetzt werden dürfen, siehe Abbildung 4. Daher ist es sinnvoll die Trainingsdatenreihen entsprechend des zeitlichen Auftretens von Störungen zu klassifizieren und danach sinnvolle Zeitpunkte für das Setzen der Checkpoints abzuleiten.

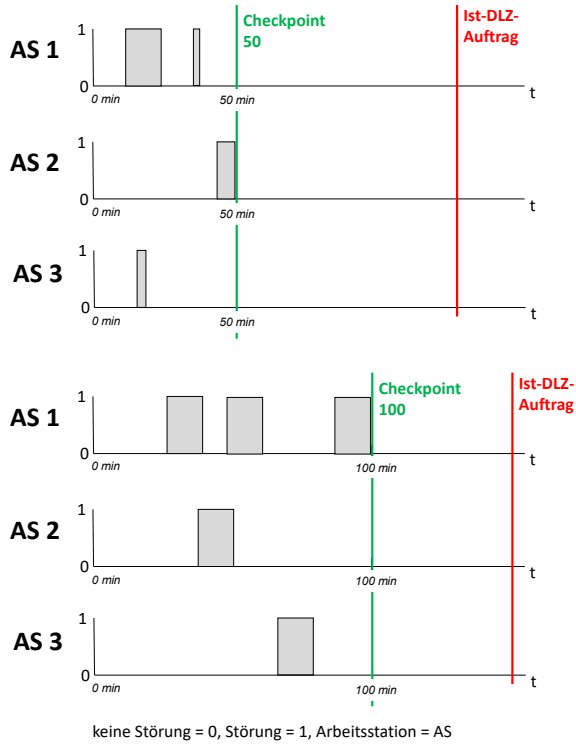


Abbildung 4. Dokumentation von Störereignissen

3.4 SUPPORT VECTOR REGRESSION

Die Support Vector Regression ist ein datengetriebenes Verfahren des maschinellen Lernens und kann in eine lineare und nicht lineare Verfahrensweise unterteilt werden. Im Folgenden wird die grundlegende Funktionalität der Support Vector Regression anhand des linearen Falls aufgezeigt. Die Trainingsdaten setzen sich aus Eingangswerten x_i ($i = 1, 2 \dots$) und Zielwerten y_i ($i = 1, 2 \dots$) zusammen. Bei der ϵ -Support Vector Regression ist eine „Tube“ (Röhre) um die Regressionsgerade definiert, siehe Abbildung 5. Das Ziel ist, eine Funktion $f(x)$ zu ermitteln, die maximal mit dem Wert ϵ von den Zielwerten y_i aller Trainingsdaten abweicht und dabei so flach wie möglich ist. Bei einer Funktion, die dieses Ziel erfüllt, liegen demnach alle Trainingsdatenpunkte innerhalb der „Tube“, wobei diese maximal Breit ist (siehe „Margin“ in Abbildung 5). Das bedeutet, die Vektoren am Rand der „Tube“, die sogenannten Support-Vectors, haben den maximalen Abstand zueinander.

Die lineare Funktion hat die Form [SmS04]:

$$f(x) = \langle w, x \rangle + b, \quad w, x \in \mathbb{R}^d, \quad b \in \mathbb{R}$$

Dabei sind w und b Parameter der Regressionsgerade, die es zu ermitteln gilt. Es wird eine möglichst flache Funktion erreicht, wenn w minimiert wird. Dieses Problem kann als konvexes Optimierungsproblem beschrieben werden [SmS04]:

$$\begin{aligned} &\text{minimiere} && \frac{1}{2} \|w\|^2 \\ &\text{unter der} && y_i - \langle w, x_i \rangle - b \leq \epsilon \\ &\text{Bedingung} && \langle w, x_i \rangle + b - y_i \leq \epsilon \end{aligned}$$

Da es zu Fällen kommen kann, in denen das beschriebene Optimierungsproblem nicht lösbar ist, werden Schlupfvariablen ξ, ξ^* eingeführt, siehe Abbildung 5. Die Schlupfvariablen nehmen allerdings erst einen Wert größer als Null an, wenn der Abstand von y_i zur Regressionsgeraden größer als ϵ ist, siehe Abbildung 6. Dadurch ergibt sich die folgende Problemformulierung [SmS04]:

$$\begin{aligned} &\text{minimiere} && \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ &\text{unter der} && y_i - \langle w, x_i \rangle - b \leq \epsilon + \xi_i \\ &\text{Bedingung} && \langle w, x_i \rangle + b - y_i \leq \epsilon + \xi_i^* \\ &&& \xi_i, \xi_i^* \geq 0 \end{aligned}$$




Abbildung 5. SVR - Linearer Fall (in Anlehnung an [SmS04])




Abbildung 6. ϵ -insensitive Verlustfunktion (in Anlehnung an [SmS04])

Damit die Support Vector Regression auch für nichtlineare Fälle angewendet werden kann, wie es für die Funktionalität des Frühwarnsystems notwendig ist, ist eine Erweiterung mit Lagrange-Multiplikatoren und

Kernelfunktionen durchzuführen. Siehe dazu [SmS04] und [Vap98]

4 ANWENDUNGSSZENARIO

Anhand eines beispielhaften Produktionsszenarios wird die Anwendung des Frühwarnsystems vorgestellt. Der prototypischen Anwendung ist ein Mehrproduktfall zugrunde gelegt. Das Szenario ist in einem ereignisdiskreten Simulationsmodell abgebildet. Dabei handelt es sich um zwei parallel angeordnete Reihenfertigungen, die über ein gemeinsames Transportsystem mit Rohteilen versorgt werden. Des Weiteren werden auch die Fertigteile über ein gemeinsames Transportsystem zum Fertigwarenlager transportiert, siehe Abbildung 7. Die Durchführungszeiten an den einzelnen Arbeitsstationen sind exponentialverteilt. Bei dem exemplarischen Auftragsstyp für welchen das Frühwarnsystem trainiert wird, handelt es sich um 20 Teile von Produkt A und 20 Teile von Produkt B.

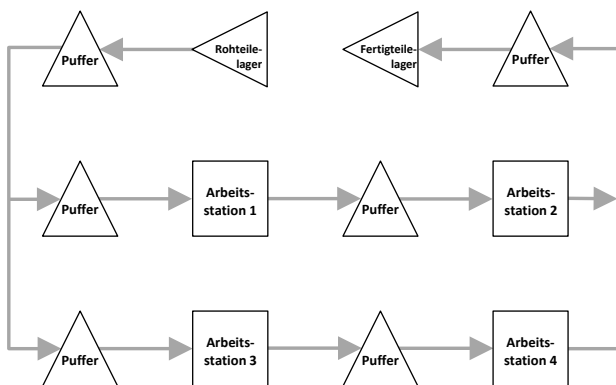


Abbildung 7. Beispielhaftes Produktionsszenario

4.1 GENERIERUNG VON TRAININGS- UND TESTDATEN

Damit das Frühwarnsystem während des operativen Betriebs sinnvolle Prognosen erstellen kann, müssen die verwendeten Trainingsdaten eine Vielzahl unterschiedlicher Produktionsverläufe bezüglich des betrachteten Auftragsstyps beinhalten. Zu diesem Zwecke werden verschiedene Störungen, die sich hinsichtlich Ort, Zeitpunkt und Dauer unterscheiden, während der Simulationsläufe induziert. Jeder Simulationslauf generiert eine Trainingsdatenreihe, die einen beobachteten Auftrag darstellt. Durch die stochastischen Einflüsse nehmen die Kennzahlen an den Checkpoints unterschiedliche Werte bei Ausführung des jeweiligen Produktionsauftrags an. Demensprechend variiert auch die entsprechende Ist-Durchlaufzeit des jeweiligen Produktionsauftrags.

Durch das Auftreten von Störungen werden die Verfügbarkeiten der Arbeitsstationen und Transportsysteme reduziert. Den Arbeitsstationen und Transportsystemen werden dabei für jeden Simulationslauf unterschiedliche Einsatz-

verfügbarkeiten zugeteilt. Da jeder Arbeitsstation und jedem Transportsystem drei unterschiedliche Einsatzverfügbarkeiten zugeteilt werden, ergeben sich $(3 \text{ hoch } 6) = 729$ unterschiedliche Szenarien. Zum Zwecke der Zufallszahlenverwendung bezüglich der exponentialverteilten Bearbeitungszeiten, wird jedes Experiment zwei Mal ausgeführt. Dadurch ergeben sich 1458 Datenreihen für jeden ausgewählten Checkpoint. Da ein Produktionsauftrag im vorliegenden Szenario bei störungsfreier Auftragsabwicklung ca. 200 min benötigt, wurden die Checkpoints Min 40, Min 80, Min 120 und Min 160 gesetzt, an denen Trainingsdaten gesammelt werden. Jeder Checkpoint verfügt über eine eigene Support Vector Regression.

Für die Bestimmung der Prognosegenauigkeit der trainierten Support Vector Regressionen werden weitere Prozessdaten generiert und als Testdaten verwendet. Die ungesenen Testdaten werden als Eingabewerte in die trainierten Support Vector Regressionen eingelesen. Der generierte Ausgabewert wird mit dem tatsächlichen Wert, in diesem Fall der Ist-Durchlaufzeit des Auftrags, verglichen. Liegt die Abweichung des Ausgabewerts von dem tatsächlichen Wert innerhalb eines Toleranzbereichs, ist die trainierte Support Vector Regression in der Lage ein „Muster“ in den Eingabewerten zu erkennen.

4.2 AUSWERTUNG DER TESTLÄUFE

In Abbildung 8 ist ein Vergleich von den tatsächlichen Ist-Durchlaufzeiten der Aufträge und den zugehörigen prognostizierten Durchlaufzeiten abgebildet. Dabei liegen die meisten Punkte nahe der Ideallinie.

Zur Bestimmung der Prognosegüte des vorgestellten Frühwarnsystems werden der Root Mean Square Error (RMSE) und der Mean Absolute Percentage Error (MAPE) herangezogen.

- y Istwert der Testdatenreihe
- \bar{y} Prognostizierter Wert der Testdatenreihe
- N Anzahl der Testdatenreihen

$$RMSE = \sqrt{\frac{\sum(y-\bar{y})^2}{N-1}}$$

$$MAPE = \frac{1}{N} \sum \frac{|y-\bar{y}|}{y} * 100\%$$

Die Prognosegüte ist davon abhängig, wie gut die Support Vector Regressionen mit den bereitgestellten Daten trainiert wurden. Durch die Hinzunahme weiterer produktionslogistischer KPIs als Input-Daten kann die Prognosegüte gegebenenfalls positiv beeinflusst werden.

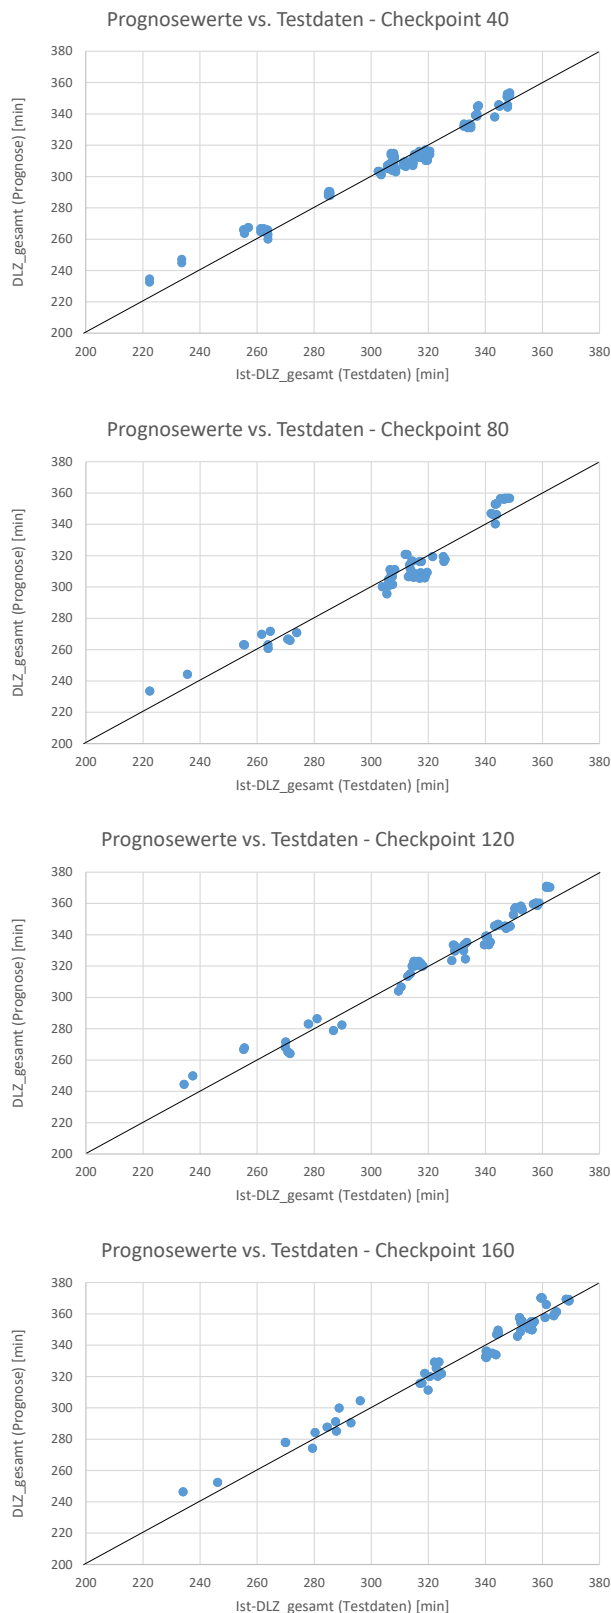


Abbildung 8. Abweichung Prognosewert und Ist-DLZ (Testdaten)

Abbildung 9 zeigt zusammengefasst die Ergebnisse für die Testdaten bezüglich der Prognosefehler der Support Vector Regressionen an den jeweiligen Checkpoints.

Checkpoint [min]	RMSE [min]	MAPE [%]
40	5,03	1,38%
80	7,22	2,05%
120	5,60	1,49%
160	5,90	1,50%

Abbildung 9. Prognosefehler

Die relativ geringen Prognosefehler bei allen Checkpoints sprechen für eine hohe Prognosegüte des Frühwarnsystems. Das bestätigt, dass das vorgestellte Frühwarnsystem ausreichend trainiert ist und es zu keinem Under- oder Overfitting der Trainingsdaten gekommen ist.

5 PREDICTIVE-MONITORING-DASHBOARD

Abbildung 10 zeigt die exemplarische Darstellung von Frühwarninformationen im Rahmen eines Dashboards. Anhand des Vergleichs der Soll-Durchlaufzeit und der Prog.-Durchlaufzeit wird die Abweichung bzw. die Störungswirkung berechnet und ein Zustandsstatus abgeleitet. Falls erforderlich wird eine entsprechende Frühwarnung generiert.

Produktion		Lager	
Auftrag 4711		Auftrag 4712	
Soll-Durchlaufzeit:	200 min	Soll-Durchlaufzeit:	200 min
Prog.-Durchlaufzeit:	240 min	Prog.-Durchlaufzeit:	205 min
Abweichung:	+40 min	Abweichung:	+5 min
Zeitpunkt:	112 min	Zeitpunkt:	85 min
Status:	●	Status:	●
Frühwarnung:	Alarm	Frühwarnung:	kein Alarm

Abbildung 10. Predictive-Monitoring-Dashboard

6 ZUSAMMENFASSUNG UND AUSBLICK

In diesem Beitrag wurde die Anwendung von Support Vector Regression zur Identifikation von Störungswirkungen in der Produktionslogistik vorgestellt. Die Prognosefunktionen des entwickelten Frühwarnsystems sind in der Lage aus historischen Daten von abgeschlossenen Produktionsaufträgen das systemdynamische Verhalten von Produktions- und Logistikabläufen zu erlernen. Während des operativen Einsatzes können aus aktuellen Prozessdaten eines laufenden Auftrags Werte für ausgewählte Kenngrößen prognostiziert werden. Im vorgestellten Fall wird die voraussichtliche Durchlaufzeit eines Produktionsauftrags

prognostiziert und mit der geplanten Soll-Durchlaufzeit verglichen. Eine Abweichung von der Soll-Durchlaufzeit drückt eine potentielle Störungswirkung aus, die sich voraussichtlich entfaltet, falls keine Gegenmaßnahmen eingeleitet werden.

Das entwickelte Prognosesystem wurde anhand eines ereignisdiskreten Simulationsmodells getestet und eine hohe Prognosegüte nachgewiesen. In einem nächsten Schritt wird die Anwendung für weitere produktionslogistische Szenarien untersucht und ein direkter Vergleich mit anderen Methoden des maschinellen Lernens, z.B. künstlichen neuronalen Netzen, vorgenommen.

LITERATUR

- [AMT07] Alenezi, A., Moses, S. A., Trafalis, T. B. (2007) *Real-time prediction of order flowtimes using support vector regression*. *Computers & Operations Research*, 35(11), 3489-3503
- [Cza09] Czaja, L. (2009) *Qualitätsfrühwarnsysteme für die Automobilindustrie*. Dissertation Universität Erlangen-Nürnberg, Wiesbaden: Gabler
- [FKAL15] Freitag, M., Kück, M., Ait Alla, A., Lütjen, M. (2015). *Potenziale von Data Science in Produktion und Logistik*
- [Gen15] Genc, E. (2015) *Frühwarnsystem für ein adaptives Störungsmanagement*. München: Herbert Utz Verlag
- [Hot07] Hotz, I. (2007) *Simulationsbasierte Frühwarnsysteme zur Unterstützung der operativen Produktionssteuerung undplanung in der Automobilindustrie*
- [LGAGPM18] Lingitz, L., Gallina, V., Ansari, F., Gyulai, D., Pfeiffer, A., Monostori, L. (2018) *Lead time prediction using machine learning algorithms: A case study by a semiconductor manufacturer*. *PROCEDIA CIRP*, 72, 1051-1056
- [PGKM16] Pfeiffer, A., Gyulai, D., Kádár, B., Monostori, L. (2016) *Manufacturing lead time estimation with the combination of simulation and statistical learning methods*. *Procedia CIRP*, 41, 75-80
- [SmS04] Smola, A. J., Schölkopf, B. (2004) *A tutorial on support vector regression*. *Statistics and computing*, 14(3), 199-222
- [ScS11] Schuh, G.; Stich, V. (2011) *Produktion am Standort Deutschland.Aachen*. Druckservice Zillekens 2011, S. 16–17
- [Vap98] Vapnik, V. (1998) *Statistical learning theory*. New York: Wiley
- [VEL17] Vojdani, N., Erichsen, B., Lück, T. (2017) *Nutzung von Produktionsechtzeitdaten –Eine agentenbasierte Feinplanung mittels Simulation*. *Logistics Journal: Proceedings 2017*
- [VE18] Vojdani, N., Erichsen, B. (2018) *Ein Ansatz für ein Predictive-Monitoring-System zur Identifikation von Störungswirkungen in der Produktionslogistik mittels künstlichen neuronalen Netzen*. *Logistics Journal: Proceedings 2018*

Prof. Dr.-Ing. Nina Vojdani, Head of the Chair of Production Organisation and Logistics, University of Rostock.

Björn Erichsen, M.Sc., Research assistant at the Chair of Production Organisation and Logistics, University of Rostock.

Adresse: Lehrstuhl Produktionsorganisation und Logistik, Universität Rostock, Richard-Wagner-Str. 31, 18119 Rostock, Deutschland, Tel: +49 381 498-9250, Fax: +49 381 498-9252, E-Mail: lp1@uni-rostock.de