

Ein Ansatz für ein Predictive-Monitoring-System zur Identifikation von Störungswirkungen in der Produktionslogistik mittels künstlichen neuronalen Netzen

An approach for a predictive monitoring system for the identification of disruptive effects in production logistics using artificial neural networks

Nina Vojdani
Björn Erichsen

Lehrstuhl Produktionsorganisation und Logistik
Fakultät für Maschinenbau und Schiffstechnik
Universität Rostock

Unerwartet auftretende logistische und produktionsbezogene Störungen gehören zum betrieblichen Alltag von Unternehmen und wirken sich negativ auf deren Prozess der Leistungserstellung aus. Die prädiktive Identifikation von potentiellen Störungen kann in Form einer Frühwarnung dazu beitragen den Handlungszeitraum für Gegenmaßnahmen zu verlängern, um somit der eigentlichen Störungswirkung rechtzeitig entgegenzuwirken. Im Zeitalter zunehmend umfangreicheren Datenmengen über betriebliche Abläufe sowie Informationsbereitstellung in Echtzeit erscheint der Einsatz prädiktiver Methoden besonders vielversprechend. Im Rahmen dieses Beitrags wird ein Ansatz für ein Predictive-Monitoring-System (PMS) zur Identifikation von Störungswirkungen in der Produktionslogistik vorgestellt. Die Kernfunktion des Systems basiert auf künstlichen neuronalen Netzen.

[Schlüsselwörter: Predictive Monitoring, künstliche Neuronale Netze, Störungswirkungen, Produktionslogistik]

Unexpectedly occurring logistical and production-related disruptions are part of the day-to-day operations of companies and have a negative impact on their process of service provision. The predictive identification of potential disturbances in the form of an early warning can help to extend the action period for countermeasures so as to counteract the actual disruptive effect in good time. In the age of increasingly large amounts of data about operational processes as well as providing information in real time, the use of predictive methods seems particularly promising. This article presents an approach to a predictive monitoring system (PMS) for identifying disruptive effects in production logistics. The core function of the system is based on artificial neural networks.

[Keywords: Predictive Monitoring, artificial neural networks, disruptive effects, production logistics]

1 EINLEITUNG

Die logistischen und produktionsbezogenen Störungen sind sowohl auf interne als auch auf externe Unsicherheiten zurückzuführen. Interne Unsicherheiten bei einem typischen Produktionssystem können z.B. der außerplanmäßige Ausfall von Produktionsmaschinen oder fehlerhafte Bauteile sein. Externe Unsicherheiten entlang einer Wertschöpfungskette umfassen z.B. mengenmäßige, quantitative und qualitative Abweichungen der Rohmaterialien und Einzelteile, Schwankungen der Kundennachfrage sowie unzuverlässige Kapazitäten von Zulieferunternehmen. Diese Unsicherheiten können sich negativ auf die Produktionsergebnisse bzw. -leistung auswirken und zu einer Erhöhung der Komplexität der Produktionsplanung und -terminierung sowie der gesamten Wertschöpfungskette führen.

Die hohe Störanfälligkeit der betrieblichen Prozesse und gleichzeitige Abnahme der verfügbaren Reaktionszeit für Gegenmaßnahmen (siehe Abbildung 1) erfordern den Einsatz von neuen Methoden und Werkzeugen, um diesen Herausforderungen begegnen zu können.

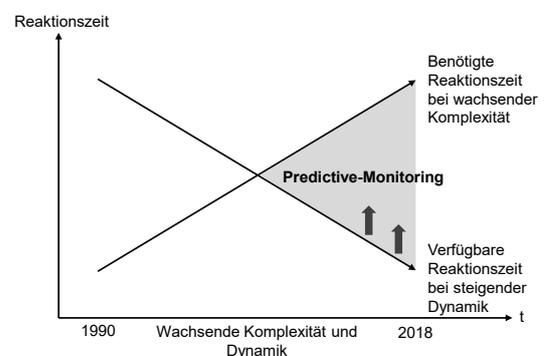


Abbildung 1. Zeitschere nach Bleicher (i.A. an[Ble11])

Zu diesem Zweck wurde am Lehrstuhl für Produktionsorganisation und Logistik (LPL) der Universität Rostock ein Ansatz für ein Predictive-Monitoring-System (PMS) mit dem Ziel der frühzeitigen Identifikation von Störungswirkungen mittels künstlichen neuronalen Netzen entwickelt. Der Kern des Systems ist eine Prognosefunktion, womit der zukünftige Zustand des betrachteten Unternehmensbereichs bzw. Prozesses anhand ausgewählter Key Performance Indicators (KPIs) prognostiziert wird. Kritische Entwicklungen im Prozess lassen sich frühzeitig erkennen, wodurch eine Erhöhung der verfügbaren Reaktionszeit erzielt wird. Der gewonnene Zeitvorteil kann genutzt werden, um gezielt Gegenmaßnahmen einzuleiten und potenziellen Störungswirkungen entgegen zu wirken bzw. abzumildern.

Im Rahmen dieses Beitrags wird der Einsatz von künstlichen Neuronalen Netzen zur Identifikation von Störungswirkungen in produktionslogistischen Prozessen vorgestellt. Zunächst werden verschiedene in der Literatur diskutierte Methoden des Predictive-Monitoring sowie Beispiele für die Anwendung von künstlichen Neuronalen Netzen in verschiedenen Bereichen der Produktion und Logistik vorgestellt.

Anschließend erfolgt in Kapitel 3 der Entwurf einer Systemarchitektur für ein Predictive-Monitoring-System und in Kapitel 4 die prototypische Anwendung an einem ausgewählten Use-Case.

2 IN DER LITERATUR DISKUTIERT ANSÄTZE

Genç [Gen15] entwickelt ein ereignisbasiertes Frühwarnsystem, welches Grundlage für ein adaptives Störungsmanagement im Rahmen der Wertschöpfung in Lieferketten ist. Die zentrale Komponente des Frühwarnsystems sind regelbasierte Verfahren zur Identifikation von kritischen Ereignissen, welche auf den Frühwarnkategorien Produkt, Prozess und Lieferant basieren und eine gezielte Bewertung der Kritikalität ermöglichen. Die Datengrundlage für das System bildet der standardisierte Einsatz der RFID-Technologie. Dadurch wird eine echtzeitnahe und überbetriebliche Informationsgewinnung und -bereitstellung realisiert.

Fernández et al. [FSC10] stellen einen Webservice vor, der die Überwachungs- und Benachrichtigungsfunktionen eines Supply-Chain-Event-Management-Systems ausführt. Der Webservice basiert auf einem Referenzmodell, das eine tiefere Analyse des Auftretens und der Kausalität von Events in Supply Chains und damit das Antizipieren von Störungsevents mittels Bayes-Netzen ermöglicht. Ein Bayes-Netz mit Entscheidungsknoten stellt dabei die Ursache-Wirkungsbeziehungen in einem Supply Prozess dar und wird zur Vorhersage von relevanten Systemzuständen während eines Supply Prozesses eingesetzt.

Czaja [Cza09] entwickelt ein auf Frühindikatoren basierendes Frühwarnsystem für das Qualitätsmanagement in der Automobilindustrie. Dafür werden zunächst relevante Beobachtungsbereiche systematisch bestimmt. Anschließend werden in den einzelnen Bereichen Indikatoren identifiziert, aus denen Informationen frühzeitig abgeleitet werden können, um kritische Entwicklungen zu identifizieren.

Metzger et al. [MFE12] untersuchen die Einsatzpotentiale von Predictive Monitoring in der Transport- und Logistikbranche. Relevante Probleme in diesen Bereichen sind z.B. kurzfristige Stornierungen von Transportbuchungen sowie Verspätungen bei Lieferaufträgen. Dabei stellen Metzger et al. den Entwurf einer cloud- und serviceorientierten Kollaborations- und Integrationsplattform vor. Die Vorhersagefähigkeiten von kritischen Entwicklungen in Transportprozessen basieren auf den Zugang zu einer Vielzahl unterschiedlicher Datenquellen und beziehen sich dabei auf einen kurzfristigen Zeithorizont. Als Beispiel werden Vorhersagen von Wetterdaten genannt, die als Input-Daten für die Plattform dienen sollen. Verläuft eine Wetterfront über eine der beobachteten Transportrouten, wird der Warenempfänger über ein erhöhtes Risiko für die Verspätung der avisierten Transporte informiert.

Rogge-Solti et al. [RW15] präsentieren einen Ansatz für die Vorhersage der verbleibenden Restdurchführungszeit von Produktions- und Dienstleistungsprozessen und die Einschätzung über das Risiko einer Terminüberschreitung. Basierend auf diesen Informationen können beispielsweise zusätzliche Ressourcen eingesetzt und die Prozessausführungen beschleunigt werden, um eine Terminüberschreitung zu verhindern. Grundlage der Vorhersagen sind spezielle stochastische Petri-Netze.

Markwardt [Mar04] entwickelt ein hybrides Modell zur Modellierung von Materialflusssystemen. Dieses ermöglicht die Prognose des Bedarfs an Stauplätzen und der Auslastung von Ressourcen. Das Modell bildet Transportsysteme ab, die aus mehreren ähnlichen Elementen modular aufgebaut sind. Mit einem numerischen Modell können die Abgangsströme und weitere relevante Kenngrößen eines Transportsystemelementes durch zugrundeliegende technische Parameter und die logistische Belastung approximiert werden. Durch die Vernetzung der einzelnen Modelle der Transportsystemelemente zu einem übergeordneten Modell können Warteschlangenlängen und Auslastungen ermittelt werden. Die numerische Modellierung wird dabei mit künstlichen neuronalen Netzen realisiert.

Yang [Yan10] entwickelt mit künstlichen neuronalen Netzen eine Metamodellierungsmethode zur Erstellung von Durchlaufzeit-Durchsatz-Profilen für Fertigungssysteme. Diese Profile sollen die Wirkungsbeziehungen der beiden kritischen Leistungskenngrößen darstellen, eine umfassende Leistungsbewertung von Fertigungssystemen

ermöglichen und somit zur Unterstützung bei langfristigen Entscheidungen, wie Kapazitätserweiterungen, beitragen.

3 EINSATZ VON KÜNSTLICHEN NEURONALEN NETZEN ZUR STÖRUNGSIDENTIFIKATION

Zunächst wird das grundlegende Vorgehen zur Identifikation von Störungswirkungen vorgestellt. Abbildung 2 zeigt den Betrachtungszeitraum für einen spezifischen Produktionsauftrag. Nach Beginn werden entlang des Produktionsverlaufs in bestimmten Zeitabständen Betriebsdaten gesammelt und zu relevanten Kennzahlen verdichtet, welche als Input für die Prognose dienen. Diese Kennzahlen spiegeln das Systemverhalten der Produktion unter der Systemlast, also einem bestimmten Auftrag, wider. Bei den erhobenen Kennzahlen handelt es sich um Durchschnittswerte sowie kumulierte Werte, welche bei jedem neuen Prognosezeitpunkt, unter Berücksichtigung der vergangenen Messungen, aktualisiert werden. Das Prognoseverfahren ist in der Lage, das Systemverhalten vorauszusagen, wobei die Systemlast ein Auftrag ist, dessen spezifische Merkmale grundsätzlich vorher bekannt sind.

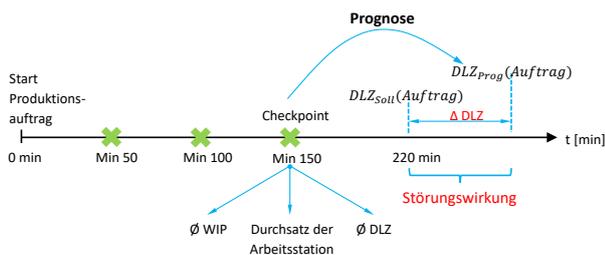


Abbildung 2. Grundlegendes Konzept zur Prognose von Störungswirkungen (Betrachtungszeitraum)

Als Output generiert das PMS die prognostizierte Durchlaufzeit des betrachteten Auftrags, basierend auf allen bis dato verfügbaren Daten über den Auftrag und den beteiligten Ressourcen.

Diese prognostizierte Durchlaufzeit wird mit der geplanten Soll-DLZ des Auftrags abgeglichen.

$$\Delta DLZ = DLZ_{Prog} - DLZ_{Soll}$$

Das ΔDLZ drückt eine potentielle Störungswirkung aus, die sich unter den Umständen, welche zum Zeitpunkt der Prognose herrschen, voraussichtlich entfalten wird, falls keine Gegenmaßnahmen eingeleitet werden.

3.1 ENTWURF DES PMS ZUR IDENTIFIKATION VON STÖRUNGSWIRKUNGEN

In diesem Abschnitt wird auf die verschiedenen Komponenten eingegangen, welche notwendig sind, um die Identifikation von Störungswirkungen durchzuführen. Abbildung 3 zeigt die Systemarchitektur des Predictive-Monitoring-Systems. Die Prognosefunktion zur Ermittlung des zukünftigen Verhaltens von Produktions- und Logistikabläufen ist der zentrale Bestandteil des Systems und besteht aus mehreren künstlichen neuronalen. Die Prognose findet in zwei Schritten statt.

Im ersten Schritt werden die sogenannten Trainingsdaten erzeugt, welche zur numerischen Modellierung benötigt werden. Diese Trainingsdaten setzen sich aus strukturierten, historischen Daten über abgeschlossene Produktions- und Logistikprozesse bezüglich spezifischer Aufträge zusammen, welche zu Leistungskennzahlen aggregiert werden. Die neuronalen Netze werden mit diesen

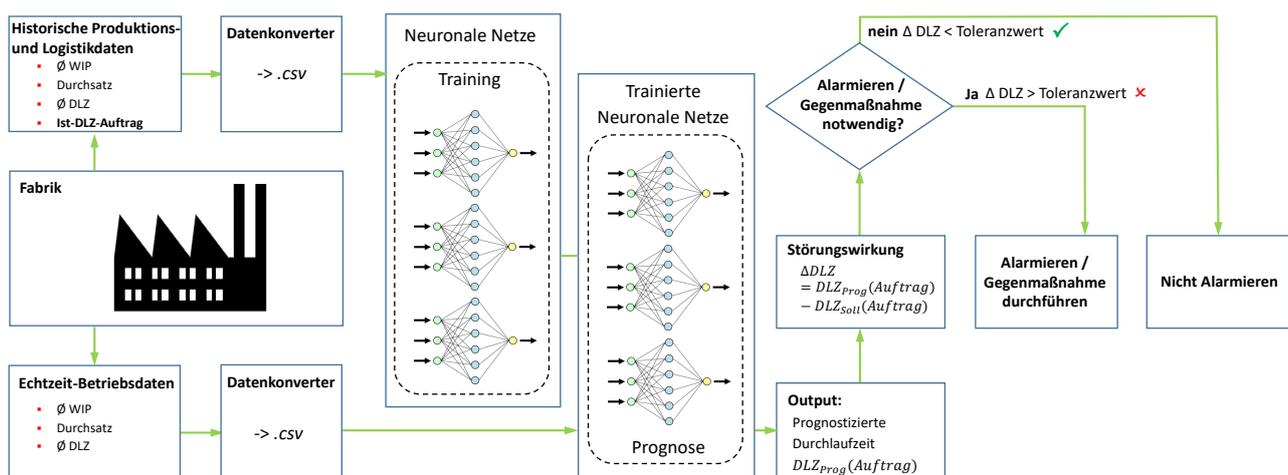


Abbildung 3. Systemarchitektur des Predictive-Monitoring-Systems

Daten trainiert und erlernen dadurch das systemdynamische Verhalten der zugrundeliegenden Produktionslogistik.

Im zweiten Schritt werden die im operativen Betrieb zu erfassenden Maschinen- und Betriebsdaten über Produktions- und Logistikafläufe dem trainierten KNN in Echtzeit bereitgestellt. Es wird davon ausgegangen, dass die entsprechenden Systeme der Produktion und Logistik mit intelligenter Sensorik ausgestattet sind und im Sinne von cyberphysischen Systemen dem PMS Daten zur Verfügung stellen können.

Die darauffolgende Netzantwort (Output) ist eine prognostizierte Durchlaufzeit des betrachteten Produktionsauftrags, welche unter den zum Zeitpunkt der Prognose herrschenden Bedingungen in der ausführenden Produktion und Logistik voraussichtlich erreicht wird.

In der anschließenden Komponente wird die Soll-Durchlaufzeit des Produktionsauftrags mit der prognostizierten Durchlaufzeit verglichen. Bei einer Abweichung wird eine Störungswirkung identifiziert, welche ausgehend vom Zeitpunkt der Prognose voraussichtlich eintreten wird. Überschreitet die Abweichung einen festgelegten Toleranzbereich, werden Gegenmaßnahmen eingeleitet.

3.2 DATENMODELL FÜR INNERBETRIEBLICHE PRODUKTIONS- UND LOGISTIKABLÄUFE

Das Datenmodell gilt sowohl für die Erhebung von Trainingsdaten als auch für die Erfassung von Echtzeitdaten im operativen Einsatz des PMS. Die Messungen für die Daten zur Erhebung der Leistungskennzahlen werden ereignisdiskret durchgeführt. Bei jeder Zustandsänderung im Produktionsprozess, die Einfluss auf die relevanten Kennzahlen hat, werden diese aktualisiert.

Dabei handelt es sich um eine Auswahl grundlegender produktionslogistischer Kennzahlen zur Beschreibung des Produktionsprozesses. Diese Auswahl kann um weitere Kennzahlen erweitert werden, um erweiterte Prognosen durchzuführen. Im Folgenden wird auf die grundlegenden Kennzahlen eingegangen.

Durchschnittlicher Work in Progress bei Arbeitsstation i (\emptyset WIP_j^i [stk]):

WIP_j^i ... Work in Progress bei Arbeitsstation i inklusive vorgelagertem Puffer

t_j Verweildauer von WIP_j^i im System bis zur nächsten Zustandsänderung

i Index der Arbeitsstation

j Index der Zustandsänderung des Work in Progress

m Anzahl Arbeitsstationen

n Anzahl Zustandsänderungen des Work in Progress

$$\emptyset WIP_j^i = \frac{\sum_{j=1}^n WIP_j^i * t_j}{\sum_{j=1}^n t_j}$$

$$\emptyset WIP_j^i = \frac{WIP_1^i * t_1 + WIP_2^i * t_2 + \dots + WIP_n^i * t_n}{t_1 + t_2 + \dots + t_n}$$

mit $i = 1, \dots, m$ und $j = 1, \dots, n$

Durchsatzleistung der Arbeitsstation i (D_k^i [stk/min]):

i Index der Arbeitsstation

k Index der auf Arbeitsstation i bearbeiteten Teile

m Anzahl Arbeitsstationen

l Anzahl der auf Arbeitsstation i bearbeiteten Teile

t_k Zeit seit Produktionsstart

$$D_k^i = \frac{k}{t_k} \text{ mit } i = 1, \dots, m \text{ und } k = 1, \dots, l$$

Durchschnittliche Durchlaufzeit der bearbeiteten Teile bei Arbeitsstation i (\emptyset DLZ_k^i [min]):

i Index der Arbeitsstation

k Index der auf Arbeitsstation i bearbeiteten Teile

m Anzahl Arbeitsstationen

l Anzahl der auf Arbeitsstation i bearbeiteten Teile

$t_k^{Start(i)}$ Zeitpunkt des Eintreffens des Teils k beim Puffer vor Arbeitsstation i

$t_k^{Ende(i)}$ Zeitpunkt des Bearbeitungsende des Teils k bei Arbeitsstation i

DLZ_k^i Durchlaufzeit eines Teils k bezogen auf Arbeitsstation i

$$DLZ_k^i = t_k^{Ende(i)} - t_k^{Start(i)}$$

$$\emptyset DLZ_k^i = \frac{DLZ_1^i + DLZ_2^i + \dots + DLZ_l^i}{l}$$

$$\emptyset DLZ_k^i = \frac{\sum_{k=1}^l DLZ_k^i}{l}$$

mit $i = 1, \dots, m$ und $k = 1, \dots, l$

Für die Erhebung von Trainingsdaten werden Checkpoints festgelegt, an denen die bis dato aktuellsten Werte der Leistungskennzahlen im zeitlichen Verlauf des Auftrags festgehalten und anschließend dem KNN des jeweiligen Checkpoints für die Trainingsphase bereitgestellt werden.

An den festgelegten Checkpoints werden während des operativen Einsatzes die aktuellen Daten aus der Produktion dem jeweiligen KNN für die Prognose bereitgestellt. (siehe Abbildung 4)

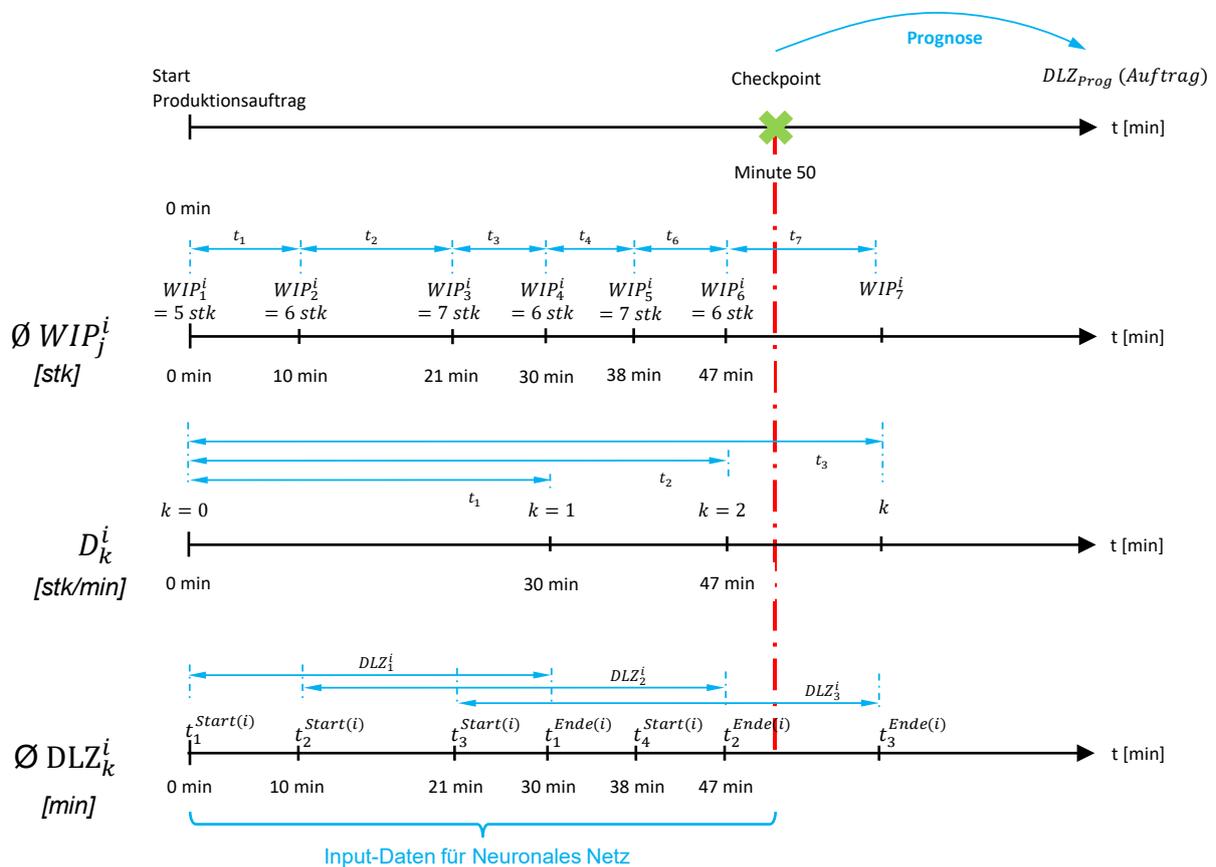


Abbildung 4. Datenmodell

3.3 KÜNSTLICHE NEURONALE NETZE ZUR PROGNOSE DES SYSTEMVERHALTENS - KONZEPTIONELLES MODELL

Ein künstliches neuronales Netz (KNN) besteht im Wesentlichen aus Knoten, sogenannten Neuronen, welche über gewichtete Kanten miteinander verbunden sind. Die Anordnung der Neuronen erfolgt in drei verschiedenen Arten von Schichten: Eingabe-, Ausgabe- und versteckte Schicht. Jedes Neuron besitzt eine Aktivierungsfunktion ψ . In diesem Beitrag wird dafür die Sigmoid-Funktion angewendet:

$$\psi = f(x) = \frac{1}{1 + e^{-x}}$$

Dieser werden mehrere Eingangswerte x_i ($i = 1, 2 \dots$) übergeben, welche vorher mit w_i ($i = 1, 2 \dots$) gewichtet werden. Der resultierende Ausgabewert y ergibt sich aus

$y = \psi(\sum_i w_i * x_i)$. Durch die Verknüpfung der Neuronen zu einem Netz ist der Ausgabewert y eines Neurons zugleich Eingangswert für weitere Neuronen innerhalb der versteckten Schicht. In der Eingabeschicht gelangen die Eingabewerte von außen in das Netz. Die Ausgabeneuronen (Output-Layer) liefern die Netzantwort in Form eines Ausgabevektors. [Mar04]

Der Lernvorgang eines neuronalen Netzes basiert auf den Gewichten w_i ($i = 1, 2 \dots$) der Verbindungen zwischen den einzelnen Neuronen. Dieser erfolgt mittels Trainingsdaten, einer Menge von Eingangsvektoren x_t und den bekannten Zielvektoren d_t . Das Netzwerktraining hat zum Ziel die Gewichte der Neuronenverbindungen so lange zu verändern, bis sich die Ausgabevektoren $y_t = net(x_t)$ den vorher bekannten Zielvektoren möglichst nahe annähern. Das eingesetzte überwachte Lernverfahren Backpropagation sorgt dafür, dass die Gewichte der Neuronenverbindungen sukzessiv verändert werden. [Mar04]

Abbildung 5 zeigt den konzeptionellen Aufbau der neuronalen Netze. Die Eingabeneuronen erhalten Werte der Kennzahlen \emptyset WIP, Durchsatz, \emptyset DLZ. Ein Ausgabeneuron gibt die Netzantwort als DLZ des betrachteten Auftrags. Dieser Wert wird mit der Ist-DLZ des abgeschlossenen Auftrags verglichen und der daraus resultierende Fehler mittels Backpropagation-Verfahren zur Einstellung der Neuronengewichte verwendet. Die Trainingsdaten sind in der Regel Prozessdaten von bereits abgeschlossener Produktionsaufträgen. In diesem Beitrag wurden sie durch ereignisdiskrete Simulation generiert.

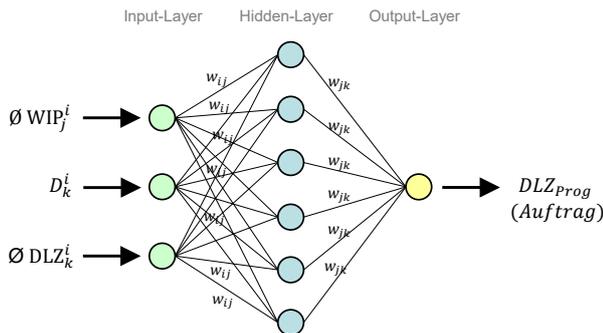


Abbildung 5. Künstliches neuronales Netz

4 PROTOTYPISCHE ANWENDUNG

4.1 BESCHREIBUNG DES SZENARIOS

Anhand eines beispielhaften Produktionsszenarios wird die Anwendung des Predictive-Monitoring-Systems vorgestellt. Für die prototypische Anwendung wird ein Einprodukt-Fall betrachtet. Es wird angenommen, dass es sich hinsichtlich Menge und Produkt um einen regelmäßig wiederkehrenden Produktionsauftrag handelt. Das Szenario

ist in einem ereignisdiskreten Simulationsmodell abgebildet. Dabei handelt es sich um eine einfache Reihenfertigung eines Produktes, welches drei Arbeitsstationen durchlaufen muss (siehe Abbildung 6). Die Durchführungszeiten an den einzelnen Stationen sind exponentialverteilt.

Des Weiteren werden verschiedene Störungen, die sich hinsichtlich Ort, Zeitpunkt und Intensität unterscheiden, während der Simulationsläufe induziert. Das Predictive-Monitoring-System generiert erst dann sinnvolle Prognosen über potentielle Störungswirkungen, wenn die verfügbaren Trainingsdaten viele unterschiedliche Störungsszenarien beinhalten.

4.2 GENERIERUNG VON TRAININGS- UND TESTDATEN

Die Trainingsdaten bestehen aus operativen Prozessdaten von bereits abgeschlossener Produktionsaufträgen, die mittels Simulation generiert werden. Bekannt sind somit vor allem die Ist-Durchlaufzeit sowie weitere relevante Kennzahlen. Während der Auftragsausführung wurden dabei produktionslogistische Messwerte erhoben und für die Eingabe in einen Input-Layer eines neuronalen Netzes an ausgewählten Zeitpunkten (Checkpoints) im Produktionsverlauf zu relevanten Kennzahlen verdichtet. Als Zielvektor \mathbf{d}_t wird die Ist-Durchlaufzeit des betrachteten Produktionsauftrags verwendet. In Abhängigkeit der stochastischen Einflüsse, die in der Produktion und innerbetrieblichen Logistik herrschen, nehmen die Kennzahlen, welche an einem ausgewählten Zeitpunkt berechnet werden, unterschiedliche Werte für einen Produktionsauftrag an. Jede Datenreihe stellt somit einen beobachteten Auftrag dar.

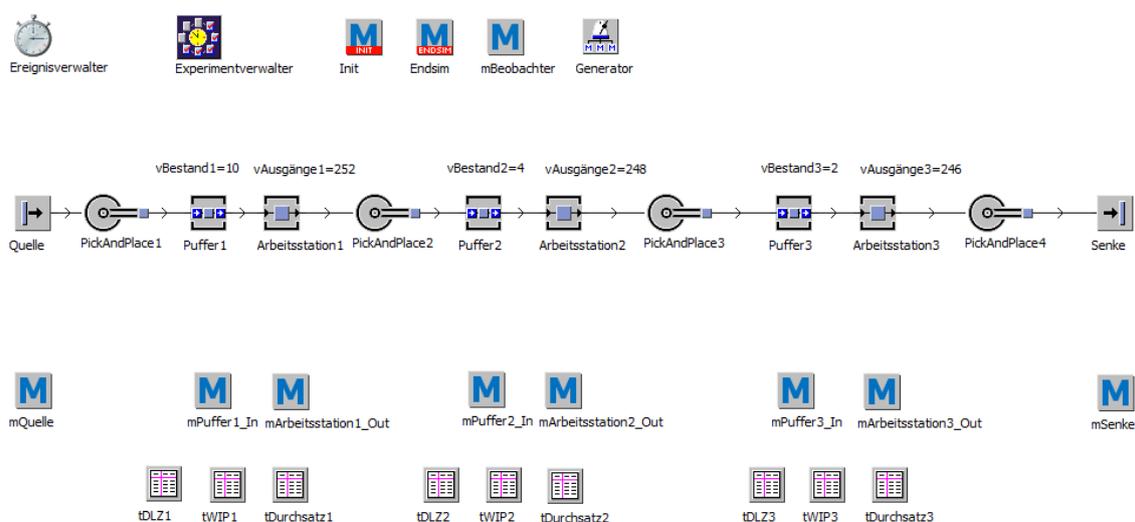


Abbildung 6. Einfache Reihenfertigung

Abbildung 7 zeigt einen Auszug von Prozessdaten, welche als Trainingsdaten verwendet werden. An einem ausgewählten Zeitpunkt im Produktionsverlauf, z.B. Minute 100 nach Produktionsbeginn, wurden relevante Kennzahlen eines Auftrags berechnet. Es werden verschiedene Datenreihen unter Einfluss von Störungen generiert, um dem neuronalen Netz Daten über möglichst viele unterschiedliche Verläufe eines bestimmten Auftrags bereitstellen zu können. Nur dadurch kann das systemdynamische Verhalten eines Auftrags umfassend erlernt und durch anschließende Verhaltensprognosen im operativen Betrieb frühzeitige Identifikationen von Störungswirkungen ermöglicht werden.

Abbildung 8 zeigt den zugehörigen Experimenteplan bezüglich der induzierten Störungen während der Simulationsläufe des vorgestellten Produktionsszenarios. Durch das Auftreten von Störungen werden die Verfügbarkeiten der Arbeitsstationen reduziert. Den Arbeitsstationen werden dabei für jeden Simulationslauf unterschiedliche Einsatzverfügbarkeiten zugeteilt. Da jeder Arbeitsstation fünf unterschiedliche Einsatzverfügbarkeiten zugeteilt werden, ergeben sich $(5 \text{ hoch } 3) = 125$ unterschiedliche Szenarien.

Für die Validierung (Bestimmung der Prognosegenauigkeit) eines trainierten neuronalen Netzes werden weitere Prozessdaten als Testdaten generiert. Die Testdaten werden ebenso als Eingabevektoren x in das trainierte neuronale Netz eingelesen. Mit einem Abfragealgorithmus wird ein Ausgabewert generiert und dieser mit dem tatsächlichen Wert, in diesem Fall der Ist-Durchlaufzeit des Auftrags, verglichen. Entspricht der Ausgabewert mit minimaler Abweichung dem tatsächlichen Wert, ist das trainierte neuronale Netz in der Lage ein „Muster“ in den Eingabewerten zu erkennen und einen passenden Ausgabewert zu berechnen.

4.3 TESTLÄUFE UND AUSWERTUNG

Für den operativen Einsatz werden acht Checkpoints im Produktionsverlauf festgelegt, an denen das Predictive-Monitoring-System eingesetzt werden soll. Dafür werden für jeden Prognosezeitpunkt mittels Simulation 125 Datenreihen generiert.

Zielvektor d_t	Daten für Eingabevektor x (Kennzahlenwerte 100 min nach Produktionsbeginn)								
Ist-DLZ-gesamt [min]	Ø-DLZ-AS1 [min]	Ø-WIP-AS1 [Stk]	Durchsatz-AS1 [Stk/min]	Ø-DLZ-AS2 [min]	Ø-WIP-AS2 [Stk]	Durchsatz-AS2 [Stk/min]	Ø-DLZ-AS3 [min]	Ø-WIP-AS3 [Stk]	Durchsatz-AS3 [Stk/min]
948.72	34.26	6.60	0.11	10.89	1.06	0.09	8.68	0.75	0.08
998.26	31.61	6.85	0.09	10.52	0.89	0.09	8.65	0.68	0.08
1044.35	42.87	7.97	0.08	9.99	0.73	0.07	8.11	0.49	0.06
1135.41	47.21	8.27	0.08	9.84	0.73	0.07	8.27	0.52	0.06
1199.52	49.14	8.40	0.08	10.03	0.72	0.07	8.58	0.52	0.06
977.73	34.42	6.62	0.11	10.56	1.03	0.10	8.56	0.75	0.09
999.09	32.05	6.89	0.09	10.37	0.86	0.09	8.56	0.69	0.09
1042.47	40.09	7.77	0.08	9.69	0.73	0.07	8.51	0.53	0.06
1136.37	47.21	8.27	0.08	9.83	0.73	0.07	8.27	0.53	0.06
1200.42	48.64	8.36	0.08	10.03	0.73	0.07	8.58	0.53	0.06
1020.32	32.53	6.66	0.11	15.39	1.54	0.08	8.58	0.60	0.07
...

Abbildung 7. Auszug Prozessdaten – Kennzahlenwerte an einem ausgewählten Zeitpunkt (100 min nach Produktionsbeginn)

Szenario	Verfügbarkeit		
	Arbeitsstation 1 [%]	Arbeitsstation 2 [%]	Arbeitsstation 3 [%]
1	100	100	100
2	95	100	100
3	90	100	100
4	85	100	100
5	80	100	100
6	100	95	100
...
122	95	80	80
123	90	80	80
124	85	80	80
125	80	80	80

Abbildung 8. Experimenteplan für Simulationsläufe

Weitere 26 Datenreihen werden jeweils generiert, um die Prognosegenauigkeit der trainierten neuronalen Netze zu

überprüfen. Abbildung 9 zeigt zusammengefasst die Ergebnisse der untersuchten Prognosegenauigkeit. Die Werte zeigen die durchschnittliche Abweichung der prognostizierten DLZ von der Ist-Durchlaufzeit der Aufträge.

Die prognostizierten Werte für die gesamte Durchlaufzeit der beobachteten Aufträge im vorliegenden Szenario weisen im Durchschnitt eine geringe Abweichung von der Ist-Durchlaufzeit auf. Somit sind die neuronalen Netze an jedem Checkpoint in der Lage ein „Muster“ in den vorliegenden Prozessdaten zu erkennen und daraus auf die voraussichtliche Durchlaufzeit des gesamten betrachteten Auftrags zu schließen.

Da während der Ausführung eines Produktionsauftrags jederzeit verschiedene Arten von Störungen auftreten können [VE16] und die bis dato prognostizierten Durchlaufzeit damit obsolet ist, ist es notwendig, regelmäßig

neue Prognosen zu erstellen, um eine valide Aussage über eine voraussichtliche Abweichung von der geplanten Durchlaufzeit zu erhalten.

Checkpoint [min]	mittlere Abweichung der Prognose [%]
100	1.92%
200	1.86%
300	2.19%
400	3.14%
500	2.01%
600	2.12%
700	1.86%
800	1.37%

Abbildung 9. Prognosegenauigkeit des Predictive-Monitoring-Systems

5 ZUSAMMENFASSUNG UND AUSBLICK

In diesem Beitrag wurde die prototypische Entwicklung eines Predictive-Monitoring-Systems (PMS) zur Prognose von Störungswirkungen in der Produktionslogistik vorgestellt. Der Kern des Systems basiert auf künstlichen neuronalen Netzen, die zur numerischen Modellierung ausgewählter Kenngrößen von produktionslogistischen Prozessen verwendet werden. Die erstellten Modelle bzw. Netze sind in der Lage aus historischen Daten das systemdynamische Verhalten von Produktions- und Logistikabläufen zu erlernen und während des operativen Einsatzes aus aktuellen Prozessdaten prognostizierte Werte für ausgewählte Kenngrößen zu ermitteln.

Der entwickelte Prototyp wurde anhand eines ereignisdiskreten Simulationsmodells getestet. Mit dem dort implementierten produktionslogistischen Szenario wurden Prozessdaten generiert und für Trainingszwecke der KNN eingesetzt. Weitere generierte Prozessdaten dienen der Evaluation des Prototyps.

In einem nächsten Schritt werden die Einsatzmöglichkeiten für weitere produktionslogistische Szenarien untersucht.

LITERATUR

- [Ble11] Bleicher, K. (2011) *Das Konzept integriertes Management; Visionen-Missionen-Programme*. Campus-Verlag
- [Cza09] Czaja, L. (2009) *Qualitätsfrühwarnsysteme für die Automobilindustrie*. Dissertation Universität Erlangen-Nürnberg, Wiesbaden: Gabler
- [Gen15] Genc, E. (2015) *Frühwarnsystem für ein adaptives Störungsmanagement*. München: Herbert Utz Verlag

- [FSC10] Fernández, E., Salomone, E., Chiotti, O. (2010) *Compound Web Service for Supply Processes Monitoring to Anticipate Disruptive Event*. In: W. Cellary and E. Estevez (Eds.): *Software Services for e-World*. I3E 2010. IFIP Advances in Information and Communication Technology, vol 341, pp. 51-60, Berlin: Springer
- [Mar04] Markwardt, U. (2004) *Modellierung modularer Materialfluss-Systeme mit Hilfe von künstlichen neuronalen Netzen*. Dissertation TU Dresden
- [MFE12] Metzger, A., Franklin, R., Engel, Y. (2012) *Predictive Monitoring of Heterogeneous Service-Oriented Business Networks: The Transport and Logistics Case*. 2012 Annual SRII Global Conference (SRII), San Jose, CA, pp. 313-322.
- [MRR17] Márquez-Chamorro, A., Resinas, M., and Ruiz-Cortés, A. (2017) *Predictive monitoring of business processes: a survey*. In: *IEEE Transactions on Services Computing*
- [RW15] Rogge-Solti, A., Weske, M. (2015) *Prediction of business process durations using non-Markovian stochastic Petri nets*. *Information Systems*, 54. Jg., S. 1-14.
- [VE16] Vojdani, N., Erichsen, B. (2016) *Untersuchung der Auswirkungen von Störungen auf produktionslogistische Prozesse mittels Simulation*. *Logistics Journal: Proceedings*
- [Yan10] Yang, F. (2010) *Neural network meta-modeling for cycle time-throughput profiles in manufacturing*. *European Journal of Operational Research* 205.1, pp. 172-185.

Prof. Dr.-Ing. Nina Vojdani ist Lehrstuhlinhaberin des Lehrstuhls für Produktionsorganisation und Logistik an der Universität Rostock.

Björn Erichsen, M.Sc. ist wissenschaftlicher Mitarbeiter am Lehrstuhl für Produktionsorganisation und Logistik an der Universität 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