Maschinelles Lernen für betriebliches Störungsmanagement in der Produktionslogistik

Björn Erichsen

Strukturierte Zusammenfassung

Trotz der aufwendigen Planung von Produktions- und Logistikabläufen und dem Bestreben potentielle Störungsquellen durch präventive Maßnahmen auszuschalten, gehören störungsbedingte Unterbrechungen und Verzögerungen zum Unternehmensalltag. Tritt eine unvorhergesehene Störung während der Produktionsausführung auf, bedarf es einer hohen Reaktionsfähigkeit und -qualität, um Maßnahmen zur Störungsbewältigung gezielt und frühzeitig einleiten zu können. Grundvoraussetzung für eine effiziente Störungsbewältigung ist die Verfügbarkeit von Informationen zur aufgetretenen Störung. Die wichtigsten Informationen sind hierbei der Störungsort, die Störungsursache und die Störungswirkung. Insbesondere bei der Generierung von aussagekräftigen Informationen zur Störungswirkung besteht die Problematik, dass das volle Ausmaß der Störungswirkung oftmals zum Zeitpunkt der Betrachtung noch gar nicht feststellbar ist. Erst im weiteren Verlauf der Produktionsausführung bzw. nach der Fertigstellung eines Produktionsauftrags wird die Störungswirkung vollständig sichtbar, z.B. in Form einer erhöhten Durchlaufzeit bzw. Verspätung eines Produktionsauftrags.

Die Anwendung von Verfahren des maschinellen Lernens stellt einen vielversprechenden Ansatz dar, um auf Basis von Betriebsdaten Störungsinformationen zu generieren. Dies kann dazu beitragen, die Reaktionsfähigkeit und -qualität beim Störungsmanagement zu erhöhen.

Daher wird in der vorliegenden Arbeit die Einsatzfähigkeit von maschinellen Lernverfahren untersucht. Es wird der Forschungsfrage nachgegangen, inwieweit diese Verfahren nutzbringend im Rahmen des reaktiven Störungsmanagements in der Produktionslogistik eingesetzt werden können, um potentielle Störungswirkungen frühzeitig zu prognostizieren und die Störungsorte und -ursachen zu identifizieren.

Damit die Einsatzfähigkeit von Verfahren des maschinellen Lernens untersucht werden kann, wird ein neuartiges Anwendungssystem zum Störungsmanagement entwickelt. Dafür werden im Rahmen der Konzeptentwicklung zunächst die Anforderungen an das System definiert sowie die Reihenfertigung und Werkstattfertigung als Anwendungsgebiete festgelegt. Daraufhin erfolgt die Entwicklung der Systemkomponente zur vorausschauenden Identifikation von Störungswirkungen, der Systemkomponente zur Identifikation von Störungsorten und -ursachen sowie des Monitoring-Dashboards.

Der Großteil der Entwicklungsarbeit bezieht sich auf die Systemkomponente zur vorausschauenden Identifikation von Störungswirkungen. Es wird angenommen, dass sich das systemdynamische Verhalten von Produktionen sowie den zugehörigen Logistikabläufen in den aufgenommenen Betriebsdaten widerspiegelt. Bei der Entwicklung eines Datenmodells stellen Betriebsdaten über abgeschlossene Produktionsaufträge die sogenannten Trainingsdaten dar. Die maschinellen Lernverfahren verwenden diese Trainingsdaten, um das systemdynamische Verhalten zu erlernen und für Prognosezwecke zu nutzen. Daraufhin ist es möglich, in regelmäßigen Abständen während der Produktionsausführung Prognosen über die voraussichtliche Auftragsdurchlaufzeit durchzuführen. Die prognostizierte Auftragsdurchlaufzeit wird mit der geplanten Soll-Durchlaufzeit verglichen. Die resultierende Differenz stellt die potentielle Störungswirkung dar.

Die Systemkomponente zur Identifikation von Störungsorten und -ursachen kommt zum Einsatz, nachdem eine voraussichtliche Störungswirkung in Form einer Verlängerung der Auftragsdurchlaufzeit prognostiziert wurde. Hierbei erfolgt der Identifikationsschritt mittels statistischer Analyse von Betriebsdaten. Das Monitoring-Dashboard dient als Schnittstelle zwischen dem Anwendungssystem und den Mitarbeitern, die für die Beobachtung und Bewältigung von Störungen zuständig sind und die generierten Störungsinformationen nutzen.

Basierend auf dem entwickelten Anwendungskonzept erfolgt die Entwicklung eines ausführbaren Systems. Als Anwendungsumgebung für das implementierte Störungsmanagementsystem dienen virtuelle Produktionen, die mittels Simulationssoftware erstellt werden. Es werden vier Simulationsmodelle erstellt, mit denen 13 unterschiedliche Simulationsexperimente durchgeführt werden. Die Experimente unterscheiden sich dahingehend, dass unterschiedliche Arten von Störungen mit unterschiedlicher Störungsdauer, Störungsort und -intensität auftreten.

Während eines Simulationslaufes werden Betriebsdaten aufgenommen, die den maschinellen Lernverfahren als Trainings- und Testdaten dienen. Als maschinelle Lernverfahren kommen künstliche neuronale Netze und Support Vector Regression zum Einsatz. Nach Abschluss der Trainingsphase stellen die trainierten künstlichen neuronalen Netze und Support Vector Regressionen ausführbare Prognosemodelle dar, die in der Lage sind, die voraussichtliche Auftragsdurchlaufzeit zu verschiedenen Zeitpunkten während einer Produktionsausführung zu prognostizieren. Je genauer der Prognosewert ist, desto aussagekräftiger ist auch der daraus abgeleitete Wert der voraussichtlichen Störungswirkung. Daher wird die Prognosefähigkeit der neuronalen und SVR-basierten Prognosemodelle umfangreich untersucht. Dafür wird ein Teil der aufgenommenen Betriebsdaten über abgeschlossene Produktionsaufträge als sogenannte Testdaten zurückgehalten. Mit den prognostizierten Werten und den tatsächlich eingetretenen Werten erfolgt die Ermittlung der Fehlermaße MAE (Mean Absolute Error), RMSE (Root Mean Squared Error) und MAPE (Mean Absolute Percentage Error), anhand derer die Prognosefähigkeit festgestellt wird.

Die Fehlermaßberechnungen zeigen, dass sowohl die SVR-basierten als auch die neuronalen Prognosemodelle bei 11 der 13 Simulationsexperimente über gute bis sehr gute Prognosefähigkeiten verfügen. Bei den anderen zwei Simulationsexperimenten steigen die Fehlermaße sowohl bei den SVR-basierten als auch den neuronalen Prognosemodellen an. Des Weiteren werden vermehrt Ausreißer bei den Prognosewerten beobachtet. Die Ergebnisse lassen sich damit begründen, dass mittels dieser beiden Simulationsexperimente die komplexesten Produktionsszenarien im Rahmen der vorliegenden Arbeit abgebildet werden. Je höher die vorliegende Komplexität ist, desto umfangreichere Daten werden für die Prognosedurchführung benötigt.

Insgesamt zeigen die Untersuchungen, dass sich künstliche neuronale Netze und Support Vector Regression in besonderem Maße für den Einsatz im reaktiven Störungsmanagement eignen, um aussagekräftige Informationen für die Störungsbewältigung zu generieren. Die wichtigsten Elemente dafür sind ein valides Datenmodell und ausreichende Trainingsdaten.