

Projekt: CoE IoP

## Konzept für ein Entscheidungsunterstützungssystem im Störungsmanagement

### Nutzung von Process-Mining und Machine-Learning zur schnellen Reaktion auf Störungen in der Produktionssteuerung

Die sich ständig ändernden Kundenanforderungen sorgen für eine immer komplexere und dynamischer werdende Produktionsumgebung. In diesem Umfeld ist es die Aufgabe der Produktionssteuerung, die Erfüllung der Nachfrage des Kunden in der richtigen Qualität zum richtigen Zeitpunkt und mit möglichst geringen Kosten sicherzustellen. Abweichungen vom Soll-Zustand sollen dabei im Rahmen des Störungsmanagements möglichst früh erkannt und schnell durch die Wahl der richtigen Gegenmaßnahme beseitigt werden. In der Praxis stehen dem Entscheider dafür jedoch nur selten entsprechende Tools zur Verfügung, sodass Entscheidungen häufig auf Basis der Erfahrung der Mitarbeiter getroffen werden. Daher wird im Folgenden ein Referenzmodell für die Entwicklung eines Decision-Support-Systems, das eine schnelle Erkennung potenzieller Störungen und eine datenbasierte Entscheidung bezüglich einzuleitender Gegenmaßnahmen ermöglicht, vorgestellt. Das Projekt wird gefördert durch die *Deutsche Forschungsgemeinschaft (DFG)* im Rahmen der Exzellenzstrategie des Bundes und der Länder – EXC-2023 Internet of Production – 390621612.

Die Nutzung von Process-Mining- und Machine-Learning-Ansätzen im Störungsmanagement spricht die automatisierte Identifikation potenzieller Störungen und unterstützt somit die datenbasierte Entscheidungsfindung in der Produktionssteuerung. Im Rahmen des Exzellenzclusters „Internet of Production“ wird ein Decision-Support-System (DSS) entwickelt, das Störungen im Produktionsumfeld in Echtzeit erkennen soll und dem Entscheider mögliche Gegenmaßnahmen in der Benutzeroberfläche präsentiert. Die Produktionssteuerung muss im Rahmen des Störungsmanagements auf ungeplante und unvorhersehbare Abweichungen vom vorgegebenen Soll-Zustand entsprechend reagieren, um eine Verschlechterung der Performance des Produktionssystems zu verhindern<sup>1</sup>. Das Treffen der richtigen Entscheidung bzw. die Auswahl der richtigen Gegenmaßnahmen kurz nach Auftreten der Störung ist demnach von sehr großer Bedeutung<sup>2</sup>.

Im entwickelten DSS werden Störungen mittels Process-Mining erkannt und auf Basis von Machine-Learning klassifiziert. Schließlich lassen sich ebenfalls durch Machine-Learning geeignete Gegenmaßnahmen ableiten. Auf diese Weise kann die Zeitspanne zwischen Störungsidentifikation und Entscheidung deutlich verringert werden. Das DSS kann über das Nutzerfeedback kontinuierlich lernen, sodass es auf Änderungen im Produktionsumfeld entsprechend reagieren kann. Die Entscheidung über die durchzuführenden Gegenmaßnahmen liegt dabei weiterhin bei den Mitarbeitern.

Decision-Support-Systeme sind auf einer Informationstechnologie basierende Systeme zur Auswertung von Daten<sup>3</sup>. Ziel solcher Systeme ist es, die Entscheidungsqualität und die Reaktionsfähigkeit des Nutzers zu verbessern<sup>4</sup>. Ein DSS kann nach SAUTER<sup>5</sup> in drei Komponenten unterteilt werden: Daten, Modell und Benutzeroberfläche.

In der Datenkomponente werden die vorhandenen Daten gesammelt und strukturiert. Im Modell werden die Daten anhand verschiedener Szenarien analysiert und ausgewertet. Die Ergebnisse werden dem Nutzer dann auf der Benutzeroberfläche zugänglich gemacht. Auf diese Weise kann eine Validierung der Ergebnisse und ggfs. eine Anpassung des Modells erfolgen. Basierend auf dem Aufbau nach SAUTER wurde die in Bild 1 (S. 17) dargestellte Referenzarchitektur für ein DSS mit Process-Mining- und Machine-Learning-Komponenten entwickelt.

Das DSS erhält die Rückmeldedaten aus der Produktion von einem Enterprise-Resource-Planning-System (ERP) oder

<sup>1</sup> S. SCHWARTZ 2004, S. 11; S. MEISSNER 2017, S. 13

<sup>2</sup> S. LEITÃO 2011, S. 1275

<sup>3</sup> S. POWER 2008, S. 127

<sup>4</sup> S. WALTERSCHEID 1996, S. 22 f.

<sup>5</sup> S. Sauter 2010, S.14 f.

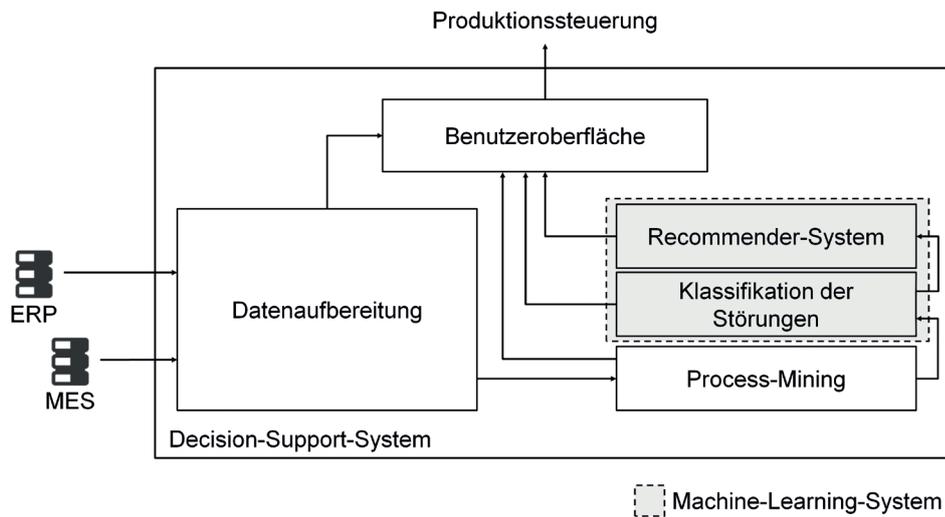


Bild 1: Referenzarchitektur für ein Decision-Support-System zur Erkennung von Störungen und Ableitung von Gegenmaßnahmen anhand von Process-Mining und Machine-Learning (eigene Darstellung)

einem Manufacturing-Execution-System (MES). Die Daten beinhalten im Wesentlichen die Start- und Endzeitpunkte der Tätigkeiten sowie die verwendeten Ressourcen in einem für das Process-Mining verständlichen Format. Nach der Strukturierung der Daten erfolgt die Weitergabe an das Process-Mining-Subsystem. Dort werden die Prozessdaten in Echtzeit analysiert und die Prozesse auf Konformität mit den vorgegebenen Soll-Prozessen geprüft.<sup>6</sup> Weichen die Prozesse von den Soll-Prozessen ab, meldet das System eine Störung. Im Falle einer Störung werden die betroffenen Daten an das Machine-Learning-System weitergegeben.

Das Machine-Learning-System besteht aus dem sogenannten Recommender-System und einem Element zur Klassifizierung der Störungen. Die grundsätzliche Idee des Machine-Learning-Ansatzes basiert auf dem künstlichen Generieren von Wissen durch Erfahrung. Ein Modell wird anhand von Beispieldaten trainiert und soll selbständig bestimmte Muster in den Datensätzen erkennen. Ein erfolgreich trainiertes Modell ist dann in der Lage, das vorher erlangte Wissen auf

einen neuen, unbekanntem Datensatz zu transferieren und dort ähnliche Muster zu erkennen. Zur Klassifizierung der Störungen im Anwendungsfall wird das Machine-Learning-System (ML-System) demgemäß zunächst anhand vorhandener Störungsklassifikationen in der Literatur trainiert, bevor es auf die Rückmeldedaten angewendet werden kann. Der Nutzer kann dabei zudem in den Lernprozess des Systems eingreifen, indem er eine Rückmeldung an das System hinsichtlich der Korrektheit der Klassifizierung gibt. Je nach Klassifizierung entscheidet das ML-System dann, ob es sich bei der Störung nur um eine einfache Abweichung innerhalb vorgegebener Toleranzen handelt oder um eine Störung, die eine Reaktion nach sich zieht. Diese Information wird dann an das sogenannte Recommender-System weitergegeben. Aufgabe des Recommender-Systems ist es, dem Nutzer basierend auf der Störung bis zu drei mögliche Gegenmaßnahmen vorzuschlagen. Dabei sind folgende Machine-Learning-Algorithmen denkbar: Collaborative-Filtering und Reinforcement-Learning. Beim Collaborative-Filtering werden Daten basierend auf Gemeinsamkeiten gefiltert. Das Collaborative-Filtering ist vor allem für seine Anwendung im E-Commerce bekannt. Dabei wird angenommen, dass Konsumenten mit gleichen Vorlieben für ein Produkt auch ähnliche Vorlieben für ein

anderes Produkt haben. Auf diese Weise kann vom Verhalten eines Konsumenten auf das eines anderen mit ähnlichen Vorlieben geschlossen werden. Im Falle der Produktionssteuerung können dem Nutzer basierend auf der Störung geeignete Gegenmaßnahmen vorgeschlagen werden. So könnte beispielsweise durch das Process-Mining eine Abweichung identifiziert werden, welche in der ersten Stufe des Machine-Learning-Systems als Maschinenausfall induzierte Störung klassifiziert wird. Das Recommender-System würde nun bei Anwendung des Collaborative-Filtering-Algorithmus auf Basis der Klassifikation und der betroffenen Maschine drei Gegenmaßnahmen vorschlagen, welche bei einer ähnlichen Situation angewandt wurden. Mögliche Vorschläge wären: Verschiebung auf eine Alternativmaschine, warten, bis die Maschine instandgesetzt wurde oder Fremdvergabe.

Beim Reinforcement-Learning wird das Problem als Markovsches Entscheidungsproblem modelliert, bestehend aus Zuständen, Handlungen, einer Übergangs- und einer Belohnungsfunktion<sup>7</sup>. Zustände sind Abbildungen des Systems zu einem bestimmten Zeitpunkt. Handlungen beeinflussen den Zustand des Systems. Die Übergangsfunktion beschreibt, wie sich der Zustand des Systems durch eine Handlung

<sup>6</sup> S. GARCIA ET AL. 2019, S. 260

<sup>7</sup> S. VAN OTTERLO U. WIERING 2012, S. 3

## Production Control Cockpit

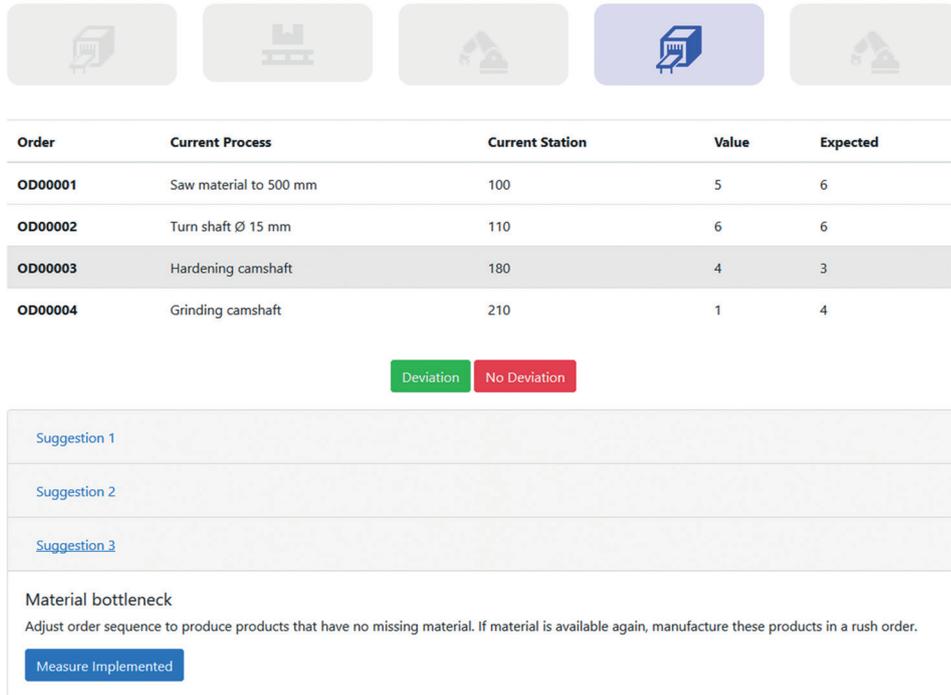


Bild 2: Benutzeroberfläche des Decision-Support-Systems (eigene Darstellung)

ändert. Anhand der Belohnungsfunktion wird die Güte der Handlung bewertet. Das System wird dann darauf trainiert, immer die Handlung mit der größten Belohnung zu wählen. Im gegebenen Anwendungsfall können die Störungen als Zustände und die Gegenmaßnahmen als Handlungen gesehen werden. Das Recommender-System empfiehlt die drei Gegenmaßnahmen mit dem höchsten Belohnungswert. Bezogen auf das oben aufgeführte Beispiel würde in diesem Fall jede mögliche Gegenmaßnahme durch das System simuliert und anhand der Belohnungsfunktion bewertet werden. Jene könnte sich beispielsweise an der verursachten Verzögerung und an der Anzahl verspäteter Aufträge orientieren.

Die Informationen werden dann an die Benutzeroberfläche weitergegeben und entsprechend visualisiert (siehe Bild 2).

Dargestellt werden demnach alle Prozesse, bei denen eine Störung auftritt, sowie die Abweichung vom Soll-Zustand. Zu jeder Störung werden dem Nutzer bis zu drei Gegenmaßnahmen vorgeschlagen. Die Entscheidung darüber, welche

Gegenmaßnahme umgesetzt wird, liegt beim Nutzer. Im Nachgang kann der Nutzer die Effektivität der Maßnahme zurückmelden, sodass das System anhand dieser Daten fortlaufend trainiert werden kann. Weiterhin können dem System neue Gegenmaßnahmen zugespielt werden, sodass auf diese Weise eine kontinuierliche Anpassung an das dynamische Umfeld der Produktionssteuerung möglich ist. Die Benutzeroberfläche ist als Web-Applikation entwickelt, um eine mobile Anwendung zu gewährleisten. So kann der Nutzer unabhängig von seinem Standort auf die Daten zugreifen und im Falle einer Störung entsprechend eingreifen.

### Literatur

ALPAYDIN, E.: *Introduction to Machine Learning. Selected Papers of Lionel W. McKenzie. 2. Auflage.* MIT Press, Cumberland [u. a.] 2016.

GARCIA, C. D. S; MEINCHEIM, A; FARIA JUNIOR, E. R; DALLAGASSA, M. R; SATO, D. M. V; CARVALHO, D. R; SANTOS, E. A. P; SCALABRIN, E. E.: *Process mining techniques and applications – A systematic mapping study.* In: *Expert Systems with Applications* 133(2019), S. 260 – 295.

LEITÃO, P.: *A holonic disturbance management architecture for flexible manufacturing systems.* In: *International Journal of Production Research* 49(2011)5, S. 1269 – 1284.

MEISSNER, J. P.: *Adaptives Abweichungs-management in der Fertigungssteuerung bei Kleinserien, 1. Auflage.* Schriftenreihe Rationalisierung; Bd. 153. Hrsg.: G. Schuh. *Apprimu, Aachen 2017.* – Zugl.: Aachen, Techn. Hochsch., Diss., 2017.

NING, X; DESROSIERS, C; KARYPIS, G.: *A Comprehensive Survey of Neighborhood-Based Recommendation Methods.* In: *Recommender Systems Handbook.* Hrsg.: F. Ricci; L. Rokach; B. Shapira. Springer, Boston (MA) 2015, S. 37 – 76.

OTTERLO, M. VAN; WIERING, M.: *Reinforcement Learning and Markov Decision Processes.* In: *Reinforcement Learning. Adaptation, Learning, and Optimization.* Hrsg.: M. Wiering; M. van Otterlo. Springer, Berlin [u. a.] 2012, S. 3 – 42.

POWER, D. J.: *DECISION SUPPORT SYSTEMS: A Historical Overview.* In: *Handbook on Decision Support Systems;* Bd. 1: *Basic Themes.* Hrsg.: F. Burstein; C. W. Holsapple. Springer, Berlin [u. a.] 2008, S. 121 – 140.

REITMAIER, T.: Aktives Lernen für Klassifikationsprobleme unter der Nutzung von Strukturinformationen. *Intelligent Embedded Systems*; Bd. 5. Kassel University Press, Kassel 2015. – Zugl.: Kassel, Univ., Diss. 2015.

SAUTER, V. L.: *Decision Support Systems for Business Intelligence*. 2. Auflage. Wiley, New York [u. a.] 2010.

SCHWARTZ, F.: *Störungsmanagement in Produktionssystemen*. Shaker, Aachen 2004. – Zugl.: Hamburg, Univ., Diss., 2004.

VAN OTTERLO, M; WIERING, M.: *Reinforcement Learning and Markov Decision Processes*. In: *Reinforcement Learning. Adaptation, Learning, and Optimization*. Hrsg.:

M. Wiering; M. van Otterlo. Springer, Berlin [u. a.] 2012, S. 3 – 42.

WALTERSCHEID, H.: *Effektivität computergestützter Management-Entscheidungsprozesse*. Deutscher Universitätsverlag 1996. – Zugl.: Konstanz, Univ., Diss., 1995.

---

#### Ansprechpartner:



Markus Fischer, M.Sc.  
FIR e. V. an der RWTH Aachen  
Wissenschaftlicher Mitarbeiter  
Bereich Produktionsmanagement  
Tel.: +49 241 47705-419  
E-Mail: [Markus.Fischer@fir.rwth-aachen.de](mailto:Markus.Fischer@fir.rwth-aachen.de)

**Projekttitel:** CoE IoP – Cluster of Excellence Internet of Production

**Forschungs-/Projektträger:** Deutsche Forschungsgemeinschaft

**Förderkennzeichen:** 390621612

**Projektpartner:** Cybernetics Lab, Lehrstuhl für Process and Data Science

**Internet:** [iop.rwth-aachen.de](http://iop.rwth-aachen.de)