

Konzept und Erfahrungsbericht zur Nutzung Künstlicher Intelligenz im Fertigungsmanagement

Mauritz Mälzer*,
Marco Petersohn,
Jonas Arndt,
Lukas Zimmermann und
Steffen Ihlenfeldt

Fertigungsmanagementsysteme (MES) sind die zentrale Datendrehscheibe für Informationen aus der Fertigung. Daneben wird Künstliche Intelligenz (KI) in der Produktion zunehmend erfolgreich angewendet, vor allem durch die Entwicklungen der Industrie 4.0. Die Verbindung beider Felder wird in dieser Studie durch systematische Beschreibung möglicher Anwendungsfälle strukturiert und das Umfeld von MES-Anbietern im deutschsprachigen Raum evaluiert. Speziell für Prognoseaufgaben wird ein Umsetzungskonzept als praktikable Vereinfachung gängiger Vorgehensweisen zur Datenanalyse in Fertigungsbetrieben vorgestellt und anhand zweier pseudonymisierter Beispiele erläutert. Damit lassen sich Erkenntnisse aus dem Verbundprojekt PrognoseMES zu allgemeinen Handlungsempfehlungen abstrahieren und als potenziell richtungsweisende Weiterentwicklung von MES bündeln.

Einleitung

Unternehmen aus dem industriellen Umfeld stehen kontinuierlich im Wettbewerb mit anderen Marktteilnehmern. Aus wirtschaftlichen Gründen ist es daher unumgänglich, Optimierungspotenziale im Fertigungsmanagement konsequent zu erschließen [1, S. 200 ff]. Auch im Kontext Industrie 4.0 gewinnen Fertigungsmanagementsysteme oder Manufacturing Execution Systems (MES) bei

produzierenden Unternehmen stark an Bedeutung [2]. Fertigungsmanagementsysteme sichern die undurchsichtige Organisation von Fertigung und Produktion und sind für moderne Produktionsanlagen die zentrale Plattform für Daten und Informationen. Die Aufgaben im Fertigungsmanagement sind eng verknüpft mit dem Enterprise Resource Planning (ERP) und gelten als Ausgangspunkt für die Nutzung datenbezogener Optimierungspotenziale [3].

Im Bereich Datenanalyse im Produktionskontext ereignen sich viele neue Entwicklungen und Komplexitätssteigerungen, deren Handhabung zum eigenen Aufgabenfeld wird [4]. Insbesondere im Zusammenspiel von Daten und Prozessen fehlen den Unternehmen geeignete Werkzeuge und Methoden, um die Wirtschaftlichkeit und den Nutzen weitreichend zu validieren. Mit dem Projekt PrognoseMES soll der Status quo für den Bereich Künstlicher Intelligenz im MES so zusammengefasst werden, dass Betriebe die richtigen Schlüsse für ihre Datenstrategie ziehen können. Das Vorhaben beinhaltet

die Idee, an möglichst viele der gegebenen Datenschnittstellen anzuknüpfen und von der Aufzeichnung über die Analyse bis zur Auswertung geeignete Abläufe bereitzustellen. Im Kooperationsprojekt wurden Erfahrungen gesammelt, die nachfolgend durch eine Aufstellung von Anwendungsfällen und Handlungsempfehlungen verallgemeinert kommuniziert werden. Entstanden ist ein vorlagenbasierter Ansatz, der die Aufnahme zukünftiger Algorithmen und nutzerseitiger Eigenlösungen berücksichtigen kann.

Ziel dieser Studie

In dieser Studie wird eine Auswahl von KI-Anwendungsfeldern präsentiert, die verschiedene MES-Aufgaben, Unternehmensprozesse und Hierarchieebenen berücksichtigt. Bisher waren keine strukturierten Arbeiten zu Anwendungsfällen für KI im MES bekannt, auch wenn es eine Reihe von Studien zu ERP Software [5, 6, 7] und Produktionsmanagement [8] gibt. Das Thema Industrie 4.0 im MES wird breiter diskutiert, enthält KI jedoch

* Korrespondenzautor
Mauritz Mälzer, M. Sc.
Technische Universität Dresden
Institut für Mechatronischen Maschinenbau
Helmholtzstraße 7a, 01062 Dresden
Tel.: +49 (0) 351 463-36102
E-Mail: mauritz.maelzer@tu-dresden.de

Hinweis

Bei diesem Beitrag handelt es sich um einen von den Mitgliedern des ZWF-Advisory Board wissenschaftlich begutachteten Fachaufsatz (Peer-Review).

einem Lernverfahren zugeordnet werden können. Weiterhin sind sie sehr unternehmensindividuell und vergleichsweise umfangreich in der Umsetzung.

Prognoseaufgaben stellen das zweite Feld dar; sie sind in jeder MES-Aufgabe zu finden. Im Vergleich zu Planungsanwendungen erstrecken sich Prognoseaufgaben auf einen beschränkteren Datenraum und sind am Markt präsenter (vgl. Kapitel „KI bei MES-Anbietern“). Die Herangehensweise für beispielsweise die Vorhersage von Personalverfügbarkeit [19] oder Key Performance Indikatoren (KPI) sowie deren Äquivalenten auf niedrigerem Hierarchielevel (z. B. Maschinenauslastung und -ausbeute [20]) lässt sich vereinheitlichen (vgl. Kapitel „Projekt PrognoseMES und Beispiele“). Grund dafür ist, dass Prognoseaufgaben oft als Probleme formuliert werden können, für deren Lösung überwachte Lernverfahren anwendbar sind. Die Überführung der Herangehensweise in einen vorlagenbasierten Ablauf ist daher möglich. Besondere Verbreitung findet bereits die Zustandsüberwachung mit den Teilbereichen vorausschauende Wartung (Predictive Maintenance) [21, 22] und Qualitätsvorhersage (Predictive Quality) [23, 24]. Ein isolierter Anwendungsfall ist die Auswahl von Stichproben für die Qualitätsanalyse. Sofern eine vollständige Kontrolle nicht stattfinden kann, lässt sich die verfügbare Kapazität zur Überprüfung möglichst repräsentativer bzw. aussagekräftiger Stichproben einsetzen [25].

Das dritte Feld, die Anomalieerkennung, bezieht sich auf Anwendungsfälle, die vorwiegend im Überwachungskontext auftreten [26, S. 18]. Überwachung ist erforderlich in den Bereichen Energiemanagement [27], Fehlerlokalisierung [28], Plausibilitätsprüfung [29], Lieferantenqualität [30] oder Prüfmittelabweichung.

Zuletzt verbleibt der Anwendungsbereich der Assoziierung mit zwei Fällen: die Ermittlung von prozessübergreifenden Indikatoren für bestimmtes Prozessverhalten [31] sowie die Zusammenstellung von Informationen [32].

■ KI bei MES-Anbietern

Der Einzug der KI-Themen in die Leistungsportfolios der MES-Anbieter ist bisher auf wenige praxistaugliche An-

wendungsfälle beschränkt. Um einen Eindruck der Verbreitung von KI im Angebot der Anbieter zu bekommen, wurde die Webpräsenz einer Auswahl von MES-Anbietern im deutschsprachigen Raum ausgewertet. Als Grundlage wurde der Marktpiegel des MES D.A.CH. Verbandes 2019/2020 [33] herangezogen. Demnach sind 183 Unternehmen bekannt, welche MES-Produkte im deutschsprachigen Raum entwickeln oder vertreiben. Davon wurden alle Unternehmen zur Analyse ausgewählt, die mehr als 1000 Beschäftigte oder mindestens 5000 Installationen oder mehr als 10.000 Maschinenkopplungen aufweisen können. Die Webrecherche ergab, dass sich 37 (42 %) der 88 betrachteten Unternehmen direkt auf das Thema KI und angrenzende MES-Anwendungsszenarien beziehen. Innerhalb der KI-Erwähnungen kommt „Predictive Maintenance“ in 51 Prozent der Fälle vor, „Predictive Analytics“ in 14 Prozent und „Predictive Quality“ in 11 Prozent, allerdings gab es dabei Überschneidungen. Konkrete Fallbeispiele bzw. die Nennung von Algorithmen, Herangehensweisen oder Werkzeugen waren in den Webpräsenzen nicht zu finden (Stand November 2021).

Projekt PrognoseMES und Beispiele

Das Projekt PrognoseMES ist ein FuE-Verbundprojekt zwischen der ccc software gmbh und der TU Dresden, gefördert durch den Europäischen Fonds für Regionale Entwicklung (EFRE) und durch Steuermittel auf Grundlage des von den Abgeordneten des Sächsischen Landtags beschlossenen Haushaltes. Die Zusammenarbeit erstreckt sich über einen Zeitraum von zwei Jahren und hat die Produkt- bzw. Portfolioerweiterung des Unternehmenspartners zum Ziel. Zwei Teilbereiche stehen dabei im Fokus: die Einbindung maschineller Lernalgorithmen in die Analysefunktionen des MES sowie die ergänzende Anknüpfung branchenübergreifender Industrienachrichten zur erweiterten Berücksichtigung in Vorhersagen. Im Laufe der Bearbeitung wurde festgestellt, dass die Entwicklung eines eigenständigen Software-Add-ons für diese Zwecke nicht geeignet ist, dafür aber ein vorlagenbasiertes Vorgehensmodell, das vorwiegend für die Anwendungsfälle

aus dem Bereich „Prognose“ nutzbar ist. Im Rahmen des Projektes wurde ein dreistufiger Modulablaufplan konzipiert, um zielgerichtet Anwendungsfälle mit hohem Nutzwert zu validieren und um kritische Entwicklungsstadien in Datenanalyseverfahren für Entscheidungsprozesse zu identifizieren.

Durch Anlehnung an die Vorgehensweise der „Data Mining Methodology for Engineering Applications (DMME)“ [34] liegt ein weit verbreiteter Modellansatz zugrunde, um datengetriebene Optimierungsansätze umzusetzen. Ausgangsbedingung für den Einstieg ist ein aufbereiteter Datenkontext und eine ausformulierte Fragestellung (Durchlaufen des DMME-Vorgehensmodells bis einschließlich „Technical Realization“). Erfahrungsgemäß ist der Einstieg in die Analyse grundsätzlich unternehmensspezifisch. Die Vereinfachung auf drei Stufen ohne vielschichtige Schleifen hat sich in der Praxis als am besten kommunizierbar erwiesen, bietet schnell sichtbare Ergebnisse und enthält frühzeitige Abbruchkriterien zur Beibehaltung der Kosten-Nutzen-Ziele. Hierin begründet sich ein klarer Mehrwert für Unternehmen, die KI als Werkzeug zur Prozessverbesserung in Erwägung ziehen. Bevor der Inhalt der Stufen erläutert wird, ist die Ausgangssituation zu klären. Der hier vorgestellte Ansatz lässt sich in jedem produzierenden Unternehmen anwenden, unabhängig davon ob ein MES genutzt wird oder nicht. Das Vorhandensein eines MES erleichtert die Datenbeschaffung, vordergründig sind aber drei Punkte relevant: Erstens muss Unternehmens- und Prozesswissen vorhanden sein, um ein Ziel wirtschaftlich zu begründen und technisch zu präzisieren (Beispiel: „Ausbeute von 90 auf 93 Prozent an Montagestraße XY erhöhen, aktuell 50.000 € Nacharbeitskosten p.a.“). Zweitens muss das Ziel als Fragestellung mit Hypothesen formuliert werden (Beispiel: „Kann das Montageergebnis bereits vor Durchlaufen der Endkontrolle vorhergesagt werden? Angenommen wird, dass die Probleme lieferantenbedingt sind und auch auf die Montagekraft zurückgeführt werden können.“). Drittens muss der Zugang zu den relevanten Daten ermöglicht werden können. Sind die Punkte erfüllt, kann das in Bild 2 dargestellte Vorgehen angestoßen werden.




Bild 2. Dreistufiger Ablaufplan

In einer explorativen Datenanalyse (EDA) wird ein Verständnis für die Daten aufgebaut und das Erfolgspotenzial der Fragestellung eingeschätzt. Dafür erfolgt zunächst die Beschreibung des Datenraumes, erst unter Zuhilfenahme lediglich verlustfreier Datentransformation, nachfolgend auch unter Anwendung von verlustbehafteten/informationsverdichtenden Algorithmen. Statistische Beschreibungen sowie Korrelations- und Regressionsanalysen lassen sich in Berichtform aufarbeiten. Anhand dieses Berichtes werden die Erkenntnisse mit den Fragestellern diskutiert und die Fortführungsmöglichkeiten evaluiert. Besteht Aussicht auf weitere Erkenntnisse, schließt sich eine Modellbildungsphase an. Darin wird der Vorverarbeitungsstand aus der explorativen Datenanalyse ausgebaut und Modelle erzeugt. Eine händische Modellauswahl inkl. Hyperparameteroptimierung kann für besondere Erklärbarkeitsanforderungen oder Performance-Steigerungen gerechtfertigt werden, ist jedoch im ersten Anlauf weniger wirksam als automatisierte Werkzeuge. Durch Auswahl geeigneter Evaluationsmetriken lässt sich das Zielmodell vor den Anforderungen der Fragestellung bewerten. Liegt ein positives Ergebnis vor, erfolgt die Inbetriebnahme

me – andernfalls ein Abbruch, ggf. mit Rückkehr zur EDA. Die Inbetriebnahme bedeutet meist die Überführung in ein Dashboard-ähnliches Interface. Modell-Updates und tiefere Integration in das Fertigungsmanagement müssen unternehmensindividuell konzipiert werden. Schließlich folgt die Rückkehr in die Geschäftsroutine, beispielsweise den Plan-Do-Check-Act (PDCA)-Zyklus. Eine weitere Detaillierung soll explizit vom ausführenden Datenanalyseteam vorgeschlagen werden. Der dreistufige Modulablaufplan hilft Entscheidungsteams im Unternehmen beim Setzen von Meilensteinen. Unterschätzt wird erfahrungsgemäß der Aufwand für die im vorigen Absatz beschriebene Vorbereitung, die nur schwer an Dienstleistungsunternehmen o.Ä. abgegeben werden kann.

Beispiel Montageprozess

Zur Verdeutlichung soll im Folgenden die Vorgehensweise anhand zweier Anwendungsbeispiele erläutert werden. Im ersten Beispiel wurde in der Forschungszusammenarbeit der Montageprozess eines Elektromotors auf Basis des o.g. Modulablaufes untersucht und durch den KI-Einsatz optimiert. Zielstellung war die Vorhersage der Produktgüte (IO oder NIO). Vermutet wurden Montagefehler als Folge bestimmter Komponentenpaarungen. Durch Wechsel der Lieferanten sollte sich die Nacharbeit reduzieren, vornehmlich durch Einsparung von Maschinenstunden. Der Anwendungsfall ist der „Predictive Quality“ bzw. der Lieferantenbewertung zuzuordnen und als Teil der Prozessüberwachung ein Beispiel aus der Prognose. Der betrachtete Datenauszug enthielt ca. 15.000 Teilaufträge, die binnen zehn Fertigungstagen montiert wurden. Etwa 2,1 Prozent der Aufträge erforderten Nacharbeit bzw. lösten kurzzeitige Stillstände aus. Die Anzahl der Teilekombinationen erlaubt über 2.000 Produktvariationen, gefertigt in zwei Linien je zehn Speicherprogrammierbarer Steuerungen (SPS). Zu den Aufträgen wurden in Summe ca. 13 Mio. Datenpunkte aufgezeichnet mit je 24 Parametern. Die explorative Datenanalyse bestätigte die Vermutung statistisch, in der Phase der Modellbildung konnten zusätzliche Einflüsse der Montagekraft festgestellt werden. Durch

Fallbeispiel Montageprozess

Daten:

- 10 Produktionstage á 1500 Montageaufträge in zwei Linien
- 15000 Teilaufträge, davon 2,1% Nacharbeit
- 13 Mio Datenpunkte mit je 24 Parametern
- 2,4GB Datenvolumen

Zielstellung:

- Vorhersage der Produktgüte für frühzeitiges Ausschleusen der Bauteile

Hypothese:

- Lieferantenspezifische Schwankungen verursachen Nacharbeit

Lösungsweg:

- AutoML
- XGBoost
- Shapley-Werte

Ergebnis:

- 80% der Fehlmontagen frühzeitig erkannt
- Einsparung von 29h Maschinenstunden pro Woche
- Reduktion Nacharbeit & Stillstände

Bild 3. Eckdaten zum Anwendungsfall „Montageprozess“

Einsatz von AutoML war es im Ergebnis möglich, 80 Prozent der Fehlmontagen frühzeitig zu erkennen, woraus sich eine Zeitersparnis von mehr als 42 Maschinenstunden wöchentlich in der Fertigung ergaben, da das Ausschleusen von NIO-Produkten durch die Qualitätssicherung sowie das Herunterfahren von Produktionsmaschinen bei Störungen unterbunden werden konnte. Die Integration der Modelle in das Fertigungsmanagementsystem steht zum jetzigen Zeitpunkt noch aus (Bild 3).

Beispiel Beschichtungsprozess

Das zweite Anwendungsbeispiel wurde in Zusammenarbeit mit einem Folienbeschichtungsunternehmen durchgeführt. Zielstellung war die algorithmengestützte Auswahl von Auftragskomponenten, die bis zu diesem Zeitpunkt empirisch getätigt wurde. Der Vermutung nach sind die Auftragskomponenten je nach Alter bzw. Verschleißgrad für andere Beschichtungsprozesse geeignet und damit die Ausbeute von der Auswahl abhängig. Der Anwendungsfall vereint die Bereiche Prozessüberwachung und Auftragsplanung. Zunächst liegt eine Prognoseaufgabe vor, die später in die Planung einbezogen werden kann. Für die explorative Datenanalyse wurden

Fallbeispiel Beschichtungsprozess

Daten:

- 1 Kalenderjahr
- 11000 Teilaufträge, davon 5% Ausschuss
- 11000 Datenpunkte mit je 56 Parametern
- 2,5MB Datenvolumen

Zielstellung:

- Algorithmengestützte Auswahl der Auftragskomponenten

Hypothese:

- Alter und Verschleißgrad der Auftragskomponente unterschiedliche geeignet für unterschiedliche Produkte

Lösungsweg:

- Statistische Beschreibung
- Varianzanalyse
- multiple Regression

Ergebnis:

- Es gibt keine Hinweise für den Einfluss der betrachteten Komponenten auf die Ausbeute
- Einfluss stattdessen für Umgebungsparameter gefunden
- Falsch vermuteter Zusammenhang frühzeitig erkannt

Bild 4. Eckdaten zum Anwendungsfall „Beschichtungsprozess“

Schichtzusammensetzungen, Rüstzeiten, Material und Lieferanten sowie Fehler-typen und Stillstände untersucht. Fünf verschiedene Ansatzpunkte für vertiefende Betrachtungen haben sich ergeben, darunter Einflussanalysen zu Prozessparametern, Fertigungshistorie und Verschleiß. Die Vertiefungsmöglichkeit mit größtmöglichem Optimierungspotenzial war im betrachteten Fall die Untersuchung geometrischer Veränderungen an den Beschichtungskomponenten. Dennoch hat die nähere Betrachtung ergeben, dass Varianzinflationsfaktoren und Regressionskoeffizienten ein hohes Maß an Multikollinearität in den Daten bezeugen. Wiederholbare bzw. haltbare Prognosen konnten mit Regressionsanalysen und Entscheidungsbäumen nicht erzielt werden, weshalb die Fortsetzung des Vorhabens ausgesetzt wurde. Es konnte somit in einem frühen Stadium erkannt werden, dass an dieser Stelle der Einsatz von aufwendigen Berechnungsmodellen wirtschaftlich nicht zu rechtfertigen ist. Die dreistufige Strukturierung zeigt hierin eine Stärke: Einerseits wurden Anwendungsszenarien aufgedeckt, andererseits fallspezifisch als vorläufig nicht weiter verfolgenswert erkannt (Bild 4).

Zusammenfassung und Empfehlungen für Unternehmen

Grundsätzlich besteht ein hohes Nutzenpotenzial von KI im MES-Umfeld für Unternehmen. Nach unserer Erfahrung fällt es kleinen und mittelständischen Unternehmen (KMU) schwer die Vorgehensreihenfolge für Datenanalysevorhaben zu fassen. In diesem Beitrag wurde eine greifbare Übersicht über mögliche Handlungsfelder und deren Reifegrad bei MES-Anbietern gegeben. Ferner wurde ein einfacher, dreistufiger Ansatz formuliert, der den Einstieg in den Analyseprozess verständlich macht und klare Anforderungen an die Problemaufbereitung von Unternehmen stellt. Ist der Wertschöpfungsprozess des Unternehmens sowie der zu untersuchende technologische Prozess dokumentiert bzw. in Absprachen gut kommunizierbar, kann das Datenanalyseproblem mit vorlagenbasierten Arbeitsschritten bearbeitet werden. Die Vereinfachung auf die drei Schritte EDA, Modellierung und Deployment eignet sich gut für die transparente Vereinbarung von Dienstleistungen in der Datenanalyse. Dabei kann ohne Einschränkungen Wert auf Wiederverwertbarkeit der Algorithmen und Werkzeuge sowie auf eine systemoffene Übergabe der Datenverarbeitungskette und Modelle gelegt werden. Die Berücksichtigung von Ausstiegsszenarien wird im Falle unzureichender Aussagekraft der Daten als fester Bestandteil eingeplant. Der dreistufige Ablaufplan verspricht einen Mehrwert durch die Benennung der kritischen Punkte im Datenanalysevorhaben, er ermöglicht die Unterstützung bei der zielgerichteten Fokussierung und Bewertung geeigneter Nutzenaspekte im MES-Umfeld. Damit steht die Wirtschaftlichkeit KI-orientierter Vorhaben in Unternehmen klar im Vordergrund.

Literatur

1. Kletti, J.; Deisenroth, R.: Lehrbuch für digitales Fertigungsmanagement. Springer-Verlag, Berlin, Heidelberg 2021
DOI: 10.1007/978-3-662-63202-4
2. Mantravadi, S.; Möller, C.: An Overview of Next-generation Manufacturing Execution Systems: How Important is MES for Industry 4.0? *Procedia Manufacturing* 30 (2019), S. 588–595
DOI: 10.1016/j.promfg.2019.02.083

3. Liang, C.; Li, Q.: Enterprise Information System Project Selection with Regard to BOCR. *International Journal of Project Management* 26 (2008) 8, S. 810–820
DOI: 10.1016/j.ijproman.2007.11.001
4. Panetto, H.; Iung, B.; Ivanov, D.; Weichhart, G.; Wang, X.: Challenges for the Cyber-physical Manufacturing Enterprises of the Future. *Annual Reviews in Control* 47 (2019), S. 200–213
5. Abich, V.: Künstliche Intelligenz im ERP-Umfeld. In: Aichele, C.; Herrmann, J. (Hrsg.): *Betriebswirtschaftliche KI-Anwendungen*. Springer Fachmedien Wiesbaden, Wiesbaden 2021, S. 195–223
DOI: 10.1007/978-3-658-33532-8_7
6. Shojaeinasab, A.; Charter, T.; Jalayer, M.; Khadivi, M.; Ogunfowora, O.; Raiyani, N.; Yaghoubi, M.; Najjaran, H.: *Intelligent Manufacturing Execution Systems: A Systematic Review*. *Journal of Manufacturing Systems* 62 (2022), S. 503–522
DOI: 10.1016/j.jmsy.2022.01.004
7. Dogan, A.; Birant, D.: *Machine Learning and Data Mining in Manufacturing*. *Expert Systems with Applications* 166 (2021) 2, S. 114060
DOI: 10.1016/j.eswa.2020.114060
8. Burggräf, P.; Wagner, J.; Koke, B.: *Artificial Intelligence in Production Management: A Review of the Current State of Affairs and Research Trends in Academia*. In: 2018 International Conference on Information Management and Processing (ICIMP). IEEE, 2018, S. 82–88
9. Arica, E.; Powell, D.: Status and Future of Manufacturing Execution Systems. In: 2017 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM). IEEE, 2017, S. 2000–2004
DOI: 10.1109/IEEM.2017.8290242
10. VDI-Gesellschaft Produkt- und Prozessgestaltung (Hrsg.): *VDI 5600: Fertigungsmanagementsysteme (Manufacturing Execution Systems – MES)*. Beuth Verlag, Berlin 2016
11. ISO (Hrsg.): *IEC 62264–1:2013 Enterprise-control System Integration – Part 1: Models and Terminology*. ISO, Geneva, Switzerland 2013
12. VDE (Hrsg.): *IEC 61512–1:1997 Batch Control – Part 1: Models and Terminology*. VDE Verlag, Berlin 1997
13. Hanke, M.; Rexroth, B.: *The Reference Architectural Model Industrie 4.0 (rami 4.0)*. *ZVEI 2* (2015) 2, S. 4–9
14. Toader, F. A.: *Production Scheduling in Flexible Manufacturing Systems: A State of the Art Survey*. *Journal of Electrical Engineering, Electronics, Control and Computer Science* 3 (2017) 1, S. 1–6
15. Zhang, C.; Song, W.; Cao, Z.; Zhang, J.; Tan, P. S.; Chi, X.: *Learning to Dispatch for Job Shop Scheduling via Deep Reinforcement Learning*. *Advances in Neural Information Processing Systems* 33 (2020), S. 1621–1632

16. Mohan, J.; Lanka, K.; Rao, A. N.: A Review of Dynamic Job Shop Scheduling Techniques. *Procedia Manufacturing* 30 (2019), S. 34–39
DOI: 10.1016/j.promfg.2019.02.006
17. Boute, R. N.; Gijbrenchts, J.; Jaarsveld, W.; Vanvuchelen, N.: Deep Reinforcement Learning for Inventory Control: A Roadmap. *European Journal of Operational Research* 298 (2021) 2, S. 401–412
DOI: 10.1016/j.ejor.2021.07.016
18. Homayouni, S. M.; Fontes, D. B.: Production and Transport Scheduling in Flexible Job Shop Manufacturing Systems. *Journal of Global Optimization* 79 (2021) 2, S. 463–502
19. Skelton, A. R.; Nattress, D.; Dwyer, R. J.: Predicting Manufacturing Employee Turnover Intentions. *Journal of Economics, Finance and Administrative Science* 25 (2019) 49, S. 101–117
DOI: 10.1108/JEFAS-07-2018-0069
20. Tongsuksai, S.; Mathrani, S.: „Integrating Cloud ERP Systems with New Technologies Based on Industry 4.0: A Systematic Literature Review. In: 2020 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE). IEEE, 2020, S. 1–6
DOI: 10.1109/CSDE50874.2020.9411570
21. Carvalho, T. P.; Soares, F. A.; Vita, R. et al.: A Systematic Literature Review of Machine Learning Methods Applied to Predictive Maintenance. *Computers & Industrial Engineering* 137 (2019), S. 106024
DOI: 10.1016/j.cie.2019.106024
22. Zonta, T.; Costa, C. A.; et al.: Predictive Maintenance in the Industry 4.0: A Systematic Literature Review. *Computers & Industrial Engineering* 150 (2020), S. 106889
23. Schmitt, J.; Böning, J.; Borggräfe, T.; Beitinger, G.; Deuse, J.: Predictive Model-based Quality Inspection Using Machine Learning and Edge Cloud Computing. *Advanced Engineering Informatics* 45 (2020), S. 101101
DOI: 10.1016/j.aei.2020.101101
24. Gittler, T.; Relea, E.; Corti, D. et al.: Towards Predictive Quality Management in Assembly Systems with Low Quality Low Quantity Data – A Methodological Approach. *Procedia CIRP* 79 (2019), S. 125–130
DOI: 10.1016/j.procir.2019.02.026
25. Lee, J. H.: Artificial Intelligence-based Sampling Planning System for Dynamic Manufacturing Process. *Expert Systems with Applications* 22 (2002) 2, S. 117–133
DOI: 10.1016/S0957-4174(01)00049-5
26. Chalapathy, R.; Chawla, S.: Deep Learning for Anomaly Detection: A Survey. *arXiv preprint arXiv:1901.03407*. 2019
DOI: 10.1145/3394486.3406704
27. Walther, J.; Weigold, M.: A Systematic Review on Predicting and Forecasting the Electrical Energy Consumption in the Manufacturing Industry. *Energies* 14 (2021) 4, S. 968
DOI: 10.3390/en14040968
28. Lu, W.; Li, Y.; Cheng, Y.; Meng, D.; Liang, B.; Zhou, P.: Early Fault Detection Approach with Deep Architectures. *IEEE Transactions on Instrumentation and Measurement* 67 (2018) 7, S. 1679–1689
DOI: 10.1109/TIM.2018.2800978
29. Jadli, A.; Hain, M.: Automatic Document Classification Using Deep Feature Selection and Knowledge Transfer. In: 2020 1st International Conference on Innovative Research in Applied Science, Engineering and Technology, IRASET 2020. Institute of Electrical and Electronics Engineers Inc., 2020
DOI: 10.1109/IRASET48871.2020.9092256
30. Cavalcante, I. M.; Frazzon, E. M.; Forcelini, F. A.; Ivanov, D.: A Supervised Machine Learning Approach to Data-driven Simulation of Resilient Supplier Selection in Digital Manufacturing. *International Journal of Information Management* 49 (2019), S. 86–97
DOI: 10.1016/j.ijinfomgt.2019.03.004
31. Susto, G. A.; Schirru, A.; Pampuri, S.; McLoone, S.; Beghi, A.: Machine Learning for Predictive Maintenance: A Multiple Classifier Approach. *IEEE Transactions on Industrial Informatics* 11 (2014) 3, S. 812–820
DOI: 10.1109/TII.2014.2349359
32. Khromov, S.; Kulagin, M.; Sidorenko, V.: Machine Learning Application for Support for Automated Control Systems Users. *Journal of Physics: Conference Series* 1680 (2020) 012019
33. MES D.A.CH / HIR.GmbH (Hrsg.): Checkliste: MES D.A.CH Marktspiegel 2019/2020. CheckVision GmbH, Wiesbaden 2019
34. Huber, S.; Wiemer, H.; Schneider, D.; Ihlenfeldt, S.: DMME: Data Mining Methodology for Engineering Applications. *Procedia CIRP* 79 (2019), S. 403–408
DOI: 10.1016/j.procir.2019.02.106

Die Autoren dieses Beitrags

Mauritz Mälzer, M.Sc., geb. 1994, studierte Maschinenbau an der RWTH Aachen. Seit 2020 ist er Wissenschaftlicher Mitarbeiter in der Arbeitsgruppe Maschinendatenverwertung des Instituts für Werkzeugmaschinenentwicklung und adaptive Steuerungen der TU Dresden.
Marco Petersohn, M.A., geb. 1988, studierte General Management an der HTWK Leipzig. Seit 2016 ist er als Mitarbeiter in der Geschäfts- und Produktentwicklung bei der ccc software gmbh tätig.

Jonas Arndt, Fachinformatiker, geb. 1994. arbeitet seit 2020 als Softwareentwickler bei der ccc software gmbh.

Lukas Zimmermann, B.Sc., geb. 1998, studiert Informatik an der TU Dresden.

Prof. Dr.-Ing Steffen Ihlenfeldt, geb. 1971, leitet das Institut für Werkzeugmaschinenentwicklung und adaptive Steuerungen der TU Dresden sowie das Fraunhofer Institut für Werkzeugmaschinen und Umformtechnik (IWU) in Chemnitz.

Abstract

Concept and Experience Report on the Use of Artificial Intelligence in Manufacturing Management. Manufacturing Execution Systems (MES) are the central data hub for information from manufacturing. In addition, artificial intelligence (AI) is increasingly being successfully applied in production, especially through the developments of Industry 4.0. The combination of both fields is structured in this study by systematically describing possible use cases and evaluating the environment of MES providers in German-speaking countries. Specifically for forecasting tasks, an implementation concept is presented as a practicable simplification of common procedures for data analysis in manufacturing companies and explained using two pseudonymized examples. In this way, findings from the joint project PrognoseMES are abstracted into general recommendations for action and bundled as a step towards the further development of MES.

Förderhinweis

Die hier vorgestellten Arbeiten wurden im Rahmen des FuE-Verbundprojekts „PrognoseMES“ 100390519 gefördert. Die Finanzierung erfolgt durch den Europäischen Fonds für Regionale Entwicklung (EFRE) und durch Steuermittel auf Grundlage des von den Abgeordneten des Sächsischen Landtags beschlossenen Haushaltes.

Schlüsselwörter

Künstliche Intelligenz, Maschinelles Lernen, Fertigungsmanagement, Manufacturing Execution System, Industrie 4.0, Anwendungsfälle, Gebrauchstaugliche Künstliche Intelligenz

Keywords

Artificial Intelligence, Machine Learning, Production Management, Manufacturing Execution System, Industry 4.0, Use Cases, Usable Artificial Intelligence

Bibliography

DOI 10.1515/zwf-2022-1060

ZWF 117 (2022) 5; page 332–337

© 2022 Walter de Gruyter GmbH,

Berlin/Boston, Germany

ISSN 0947-0085 · e-ISSN 2511-0896



Europa fördert Sachsen.
EFRE
Europäischer Fonds für
regionale Entwicklung



Diese Maßnahme wird mitfinanziert durch Steuermittel auf Grundlage des von den Abgeordneten des Sächsischen Landtags beschlossenen Haushaltes.