

Literaturbasierte Untersuchung der Prozessmerkmale datengetriebener Prozesse im Anwendungsfeld der Produktion

Sean Paul Christiansen-Lenger^{1*}, Markus Rabe¹

¹Fachgebiet IT in Produktion und Logistik, Technische Universität Dortmund, Leonhard-Euler-Str. 5, 44227 Dortmund, Germany; *sean.christiansen@tu-dortmund.de

Abstract. Datengetriebene Prozesse sind heutzutage für viele Anwendungen im produktionslogistischen Bereich relevant. Durch die uneinheitliche Verwendung des Begriffs datengetrieben bzw. des englischen Begriffs *Data-driven* zur Prozessbezeichnung in der Literatur, ist keine eindeutige Klassifizierung für Prozesse als datengetrieben möglich. Um diesbezüglich eine Klassifikation zu ermöglichen, wurden aus Prozessbeschreibungen von datengetriebenen Prozessen aus der Fachliteratur Merkmale zur Klassifikation abgeleitet und als Checkliste dargestellt.

Einleitung

Um die Ansätze des Smart Manufacturing oder Digitaler Zwillinge zu realisieren, müssen große Datenmengen echtzeitnah verarbeitet werden. Datengetriebene Prozesse bilden die Grundlage für Smart Manufacturing [1; 2]. In der Fachliteratur werden im Bereich der Produktion unterschiedliche als datengetrieben klassifizierte Prozesse beschrieben, u. A. im Kontext der Produktionsplanung, der -überwachung und der -optimierung [1] sowie in produktionsnahen Bereichen wie der Simulation [3] und des Supply Chain Management [4; 5].

Ähnlich wie für den Begriff Big Data, für den sich auch bis in das Jahr 2022 noch keine einheitliche Definition durchgesetzt hat, gibt es auch für datengetriebene Prozesse keine allgemeingültige Definition. Synonym werden beispielsweise Begriffe wie *knowledge-based methods* [6] oder *big data driven* [4; 7] verwendet und es finden sich auch Bezüge zu Begriffen wie *twin driven* [8].

Da die in der Literatur uneinheitliche Verwendung der Prozessbezeichnung datengetrieben eine entsprechende Klassifizierung von Prozessen erschwert, werden im Folgenden die gemeinsamen Merkmale der datengetriebenen Prozesse in der Literatur hergeleitet. Diese Merkmale dienen als Grundlage für eine Klassifizierung

von Prozessen als datengetrieben. Um in der Praxis die Klassifizierung zu erleichtern, werden die Merkmale in eine Checkliste überführt, die eine Überprüfung eigener Prozesse bezüglich der Einordnung als datengetrieben ermöglicht. Zur besseren Lesbarkeit wird im Folgenden das deutsche Adjektiv *datengetrieben* für den englischen Begriff *Data-driven* verwendet. Für feststehende Fachbegriffe wird auf eine Übersetzung verzichtet.

1 Merkmale und Begriffsfindung

Das Verständnis für IT-Prozesse mit der Klassifikation datengetrieben hat sich im Laufe der Zeit gewandelt [9] und der Begriff datengetrieben wird beispielsweise auch in Fachdisziplinen des Journalismus [10] und der Linguistik [11] verwendet. Aus diesen Gründen werden zu der Ableitung einer Verständnisgrundlage für den produktionslogistischen Kontext ausschließlich aktuelle Veröffentlichungen aus diesem Fachbereich herangezogen.

Xu et al. beschreiben ein auf datengetriebene Prozesse ausgerichtetes Produktionssystem, an dem sich dieser wissenschaftliche Beitrag orientiert [12]. In dem von Xu et al. dargestellten Produktionssystem werden datengetriebene Prozesse direkt mit dem Fertigungsprozess verknüpft. Alle relevanten Prozessparameter werden beispielsweise durch Sensoren im Prozess oder Produktionssystem aufgenommen. Die aufgenommenen Messwerte werden in Echtzeit analysiert und interpretiert. Auf Basis dieser Interpretationen werden Entscheidungen getroffen und direkt in der realen Fertigung umgesetzt. Diese Form der Organisation eines Produktionssystems wird als datengetriebene Fertigung bezeichnet und kann durch die direkte Rückführung der Erkenntnisse des datengetriebenen Prozesses in den physikalischen Prozess

als Kreislauf dargestellt werden [12].

Dieser Ablauf mit Bezug auf ein umgebenes Framework wird in [12] detailliert beschrieben, ein weiteres Framework mit umfangreicherem Bezug zu dem Produktdaten-Lebenszyklus in [1]. In **Abbildung 1** wird in einer Weiterentwicklung einer Darstellung aus [12] der Ablauf eines datengetriebenen Prozesses sowie dessen Einbindung in der datengetriebenen Fertigung dargestellt.

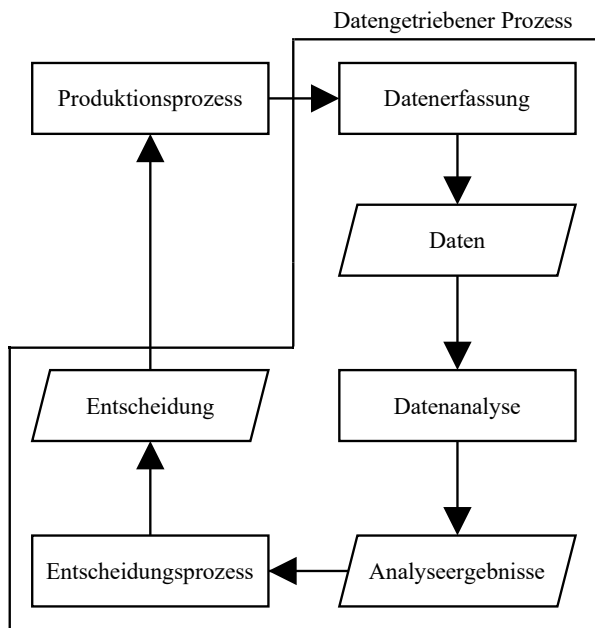


Abbildung 1: Ablauf datengetriebener Prozesse in der datengetriebenen Produktion

Basierend auf dem zuvor beschriebenen Ablauf werden im Folgenden die wichtigsten Merkmale diskutiert, die datengetriebenen Prozessen in der Literatur zugeordnet werden. Merkmale werden im Sinne der DIN 55350 verstanden, die ein Merkmal als „kennzeichnende Eigenschaft“ definiert, welche sowohl qualitativ als auch quantitativ sein kann [13].

Um mögliche Merkmale aktueller datengetriebener Prozesse darzulegen, wurden basierend auf der Anzahl der Zitationen und dem Journal Index Factor die relevantesten Veröffentlichungen mit Bezug auf Produktion und Logistik aus den Jahren 2015 bis 2021 analysiert und die gemeinsamen Merkmale als definierend eingestuft.

Datenzentrierte Prozessbetrachtung

Beispielsweise in [14] wird explizit darauf hingewiesen, dass es zur Gewinnmaximierung für moderne produzierende Unternehmen ein Schlüsselement ist, aus Daten Erkenntnisse zu gewinnen, um Entscheidungsprozesse

effektiv zu unterstützen [1; 2; 14]. In den aus dieser Notwendigkeit resultierenden datengetriebenen Prozessen [14] nehmen Daten in der Prozessbetrachtung eine zentrale Rolle ein, beispielsweise in [1; 6; 12; 14–16].

Datenerfassung

In der Mensch-Maschine-Material-Umgebung der Fertigung werden Daten aus Fertigungs- [1; 6; 14; 17] und Logistikprozessen [1; 6; 17; 18] durch Sensoren sowie Internet-der-Dinge-Technologien wie RFID, AutoID etc. [18–20] und von Werkern [1] direkt aufgenommen sowie indirekt aus Informationssystemen [1] oder aus historischen Daten [6; 14] übernommen. Historische Daten können dabei sowohl zum Training von Machine-Learning-Anwendungen [1; 6; 14] als auch zur teilweise automatischen Bewertung des Status oder zur Vorhersage zukünftiger Störungen in dem überwachten Prozess oder der Maschine genutzt werden [1]. Besondere Bedeutung wird in vielen Quellen auch der Echtzeitfähigkeit dieser Prozesse beigemessen, z. B. in [1; 16–18].

Zielgerichtete Wissensgenerierung

Die zentrale Aufgabe von datengetriebenen Prozessen ist, Wissen aus Daten zu generieren [1; 4; 6; 12; 14; 15; 21]. Wissensentdeckung kann in zwei Arten eingeteilt werden. Sie kann deskriptiv sein, also der Zusammenfassung oder dem ungerichteten Entdecken von Wissen dienen oder prädiktiv sein, um zielgerichtet Wissen zu entdecken, um im Idealfall direkt Strategien zu entwickeln, die als Entscheidungsgrundlagen dienen können [14].

Anders als bei Knowledge-Discovery-Prozessen ist bei vielen datengetriebenen Prozessen das Ziel, eine vor Anwendung des Prozesses definierte Art von Wissen zu extrahieren, die das Lösen einer vorher definierten Aufgabe ermöglichen soll [1; 6; 12; 15; 16]. Datengetriebene Prozesse lassen sich demnach als hypothesengetrieben bezeichnen und können rein deskriptiv oder rein prädiktiv sowie eine Kombination aus beidem sein.

Checkliste

Die abgeleiteten Prozessmerkmale werden in **Tabelle 1** zusammengefasst. Diese ist in Form einer Checkliste gehalten, die eine Einordnung von Prozessen als datengetrieben ermöglichen soll. Dafür muss der Prozess jedes der drei Kriterien erfüllen. Für das Kriterium 2 müssen dafür beide Unterkriterien erfüllt sein, für das Kriterium 3 genügt die Erfüllung eines Unterkriteriums. Zur Erfüllung eines Unterkriteriums reicht jeweils aus, wenn eine der

beschriebenen Merkmalsausprägungen erfüllt wird.

Tabelle 1: Checkliste zur Einordnung von IT-Prozessen als datengetrieben

Kriterium	Quellen
1. Prozessbetrachtung	
• Fokussierung auf Daten zur Entscheidungsunterstützung	[1; 6; 12; 14–16]
2. Wissensgenerierung	
• Hypothesengetrieben	[1; 4; 6; 12; 14; 15; 21]
• Form der Wissensextraktion	
○ Deskriptiv	[1; 4; 6; 12; 14; 15; 21]
○ Prädiktiv	[1; 4; 6; 12; 14; 15; 21]
○ Mischform deskriptiv-prädiktiv	[1; 4; 6; 12; 14; 15; 18; 21]
3. Datenerfassung	
• Direkte Datenerfassung	[1; 6; 14; 16; 17]
• Indirekte Datenerfassung	
○ Erfassung von korrelierten Daten	[12]
○ Übernahme aus IT-Systemen, z. B.	
▪ Prozessdaten	[1]
▪ Historische Daten	[1; 6; 14; 16–18]

2 Datengetriebene Prozesse im Kontext der Simulation

Durch die angestrebte Anwendung im Digitalen Schatten [17] und Digitalen Zwilling [18; 22] werden datengetriebene Prozesse auch für die Simulation immer relevanter. In der Vergangenheit konnten Daten in Produktionssystemen kaum in Echtzeit gesammelt oder verarbeitet werden [3]. Deshalb wurden historische Daten oder Expertenwissen zur Erstellung von Modellen verwendet [3; 12; 23]. Diese Modelle kommen überwiegend zur Entscheidungsunterstützung im langfristigen Planungshorizont

zum Einsatz [3; 23]. Dahingegen werden Simulationsmodelle in digitalen Zwillingen, die reale Systeme simulieren, mit Echtzeitdaten synchronisiert und können somit auch im operativen Geschäft Grundlagen für Entscheidungen bilden [3].

Durch die Verbindung eines Modells mit dem entsprechenden physikalischen Prozess durch einen datengetriebenen Prozess sollen sogenannte datengetriebene Modelle im dynamischen Fertigungsumfeld Entscheidungen treffen [21] oder den Entscheidungsträgern Alternativen empfehlen können. Modelle sind dadurch nicht länger statisch, sondern werden durch Echtzeitdaten aktualisiert und teilweise angepasst [3].

Um die Einsatzmöglichkeiten der Checkliste zur Einordnung von Prozessen als datengetrieben anhand der jeweiligen Prozessbeschreibung zu demonstrieren, wird diese in einem Use Case angewandt. Als Use Case wurde die von Qiao et al. [24] beschriebene Anwendung eines datengetriebenen Prozesses mit einem numerischen Modell zur Vorhersage von Werkzeugverschleiß ausgewählt, da diese Veröffentlichung die aktuell relevante Verknüpfung von datengetriebenen Prozessen mit der Simulation und dem Digitalen Zwilling beschreibt.

In diesem Use Case werden in einem Fräsprozess die Prozesskräfte, Vibrationen und Lautstärkeemissionen mit Sensoren in Echtzeit gemessen. Diese Daten werden in einem Modell zur Vorhersage von Werkzeugverschleiß analysiert. Das Modell berechnet durch die Verwendung eines Rekurrenten Neuronalen Netzes (RNN) den Verschleiß des Werkzeugs basierend auf den oben genannten Prozessdaten. Das RNN wurde mit gespeicherten Prozessdaten und korrespondierenden Verschleißdaten der Freiflächen des Fräskopfs trainiert [24].

Basierend auf der Prozessbeschreibung von Qiao et al. wurde die in der vorliegenden Veröffentlichung erstellte Checkliste bezüglich der Klassifizierung des Prozesses aus [24] wie in **Tabelle 2** dargestellt ausgefüllt. Die Prozessbetrachtung ist durch das Training des RNN durch Prozessdaten und die Verwendung von Echtzeitprozessdaten zur Vorhersage von Verschleiß primär auf Daten ausgerichtet (Kriterium 1). Die Wissensgenerierung ist hypothesengetrieben, da davon ausgegangen wird, dass der Verschleiß durch die aufgenommenen Prozessdaten vorhersagbar ist und stellt eine Mischung aus deskriptiver und prädiktiver Wissensgenerierung dar (Kriterium 2). Die Datenerfassung findet überwiegend direkt im Prozess durch Sensoren statt. Da die Verschleißanalyse des Werkzeugs, die getrennt vom Prozess und der direkten Datenaufnahme stattfindet, lediglich

zum Training des RNN verwendet wird, wird auch Kriterium 3 als erfüllt angesehen.

Tabelle 2: Basierend auf der Prozessbeschreibung aus [24] ausgefüllte Checkliste zur Einordnung von IT-Prozessen als datengetrieben

Kriterium	Erfüllung?
	✓/x
1. Prozessbetrachtung	
• Fokussierung auf Daten zur Entscheidungsunterstützung	✓
2. Wissensgenerierung	
• Hypothesengetrieben	✓
• Form der Wissensextraktion	
○ Deskriptiv	
○ Prädiktiv	
○ Mischform deskriptiv-prädiktiv	✓
3. Datenerfassung	
• Direkte Datenerfassung	✓
• Indirekte Datenerfassung	
○ Erfassung von korrelierten Daten	
○ Übernahme aus IT-Systemen, z. B.	
▪ Prozessdaten	
▪ Historische Daten	✓

3 Diskussion und Ausblick

Um Smart Manufacturing zu realisieren, reicht das Internet der Dinge nicht aus, da dieses lediglich Transparenz der verfügbaren Informationen bietet [25]. Dadurch werden datengetriebene Prozesse relevant, da diese basierend auf Wissensgenerierung aus den immer größer werdenden Datenmengen Entscheidungsgrundlagen bilden können oder Entscheidungen autonom treffen können. Da der Begriff datengetriebener Prozess in der Literatur uneinheitlich verwendet wird, wurden zur Bildung einer Klassifikationsgrundlage die relevantesten Veröffentlichungen aus dem produktionslogistischen Kontext von 2015 bis 2021 herangezogen und gemeinsame Merkmale der dargestellten Prozesse abgeleitet. Diese Merkmale wurden zur Klassifikation von Prozessen in Form einer Checkliste dargestellt. Die Anwendung dieser Checkliste wurde im weiteren Verlauf gezeigt.

In der Merkmalsableitung wird besonders die Abgrenzung zu Big Data Analytics deutlich. Während im Kontext von Big Data große vorhandene Datenmengen mit dem Ziel einer deskriptiven Wissensentdeckung analysiert werden, wird bei der Auslegung von datengetriebenen Prozessen bereits ein konkretes Ziel verfolgt. Zur Lösung einer oder mehrerer klar definierter Aufgaben werden die zu analysierenden Daten gezielt ausgewählt oder, wie in [12] ausführlich dargestellt, direkt oder indirekt aufgenommen. Dabei bedienen sich datengetriebene Prozesse unter anderem Anwendungen aus dem Big-Data-Kontext, wie z. B. Data Analytics [4] oder Data Mining [21]. Der Unterschied zwischen den Begriffen zeigt sich auch bei der Datenaufnahme und der Bedeutung einzelner Messdaten, welchen im Kontext von Big Data wesentlich weniger Bedeutung beigemessen wird, da diese, im Gegensatz zu der Verwendung in datengetriebenen Prozessen, einzeln trivial und ungenau sind [12].

Weiterer Forschungsbedarf bezüglich eines einheitlichen Definitionsvorschlags für datengetriebene Prozesse wird dadurch bedingt, dass sich das Begriffsverständnis weiter im Wandel befindet. Ein Beispiel dafür liegt im Bereich der Datenerfassung (Kriterium 2 der Checkliste). Da im Kontext datengetriebener Prozesse häufiger die Datenaufnahme und -verarbeitung in Echtzeit beschrieben wird, muss das Kriterium „Datenerfassung“ der Checkliste in Zukunft gegebenenfalls um Echtzeitfähigkeit erweitert werden.

Wie auch im Anwendungsbeispiel der Checkliste gezeigt, werden datengetriebene Prozesse im Bereich der Simulation immer relevanter. Bei diesen datengetriebenen Modellen ist weitere Forschung in Bezug auf Verifikation und Validierung (V&V) notwendig. In allen gängigen Vorgehensmodellen kommt V&V eine wichtige Rolle zu, sodass ohne begleitende V&V ein Modell nicht als glaubwürdig gelten kann. Dies stellt in Bezug auf datengetriebene Modelle eine Herausforderung dar, da V&V-Techniken überwiegend von Experten durchgeführt werden, auch wenn bei einzelnen Tests und Techniken durchaus Automatisierungspotential besteht [26]. Besonders ist zu diskutieren, welche V&V-Techniken bei Modellen, die beispielsweise durch Machine Learning entstanden sind, sinnvoll anwendbar sind. Auch ist die Frage zu klären, ob die stichprobenartige V&V eines Modells ausreichend ist, oder ob eine durchgängige V&V auch bei kleineren Veränderungen im System weiterhin notwendig ist.

Wie bei der V&V ist es auch in weiteren Bereichen von datengetriebenen Prozessen noch nicht möglich,

komplett auf Expertenwissen zu verzichten. Da datengetriebene Prozesse hypothesengetrieben sind, müssen die auszuwertenden Daten oder Datenquellen zunächst basierend auf einem vermuteten Zusammenhang ausgewählt werden. Dies wird im Anwendungsbeispiel in Abschnitt 2 durch die Auswahl der zu messenden Prozessparameter deutlich.

Auch die Datenanalyse in datengetriebenen Prozessen kann nicht vollständig automatisiert werden. Beispielsweise ist bei Prozessen zur Fehlererkennung Expertenwissen beim Training von Neuronalen Netzen weiter essentiell, da ohne Training der Neuronalen Netzen neu auftretende Fehlertypen fälschlicherweise bereits bekannten Fehlertypen zugeordnet werden können [6].

Vorarbeiten zu diesem Paper basieren auf der Forschungsarbeit [27].

Literaturverzeichnis

- [1] Tao, F.; Qi, Q.; Liu, A.; Kusiak, A. Data-driven smart manufacturing. *Journal of Manufacturing Systems*. 2018; 48: S. 157–169. doi: 10.1016/j.jmsy.2018.01.006.
- [2] Shao, G.; Jain, S.; Shin, S. Data analytics using simulation for smart manufacturing. In: Tolk, A.; Diallo, S.Y.; Ryzhov, I.O.; Buckley, S.J.; Miller, J.A.; Yilmaz, L. (Hrsg.): *Proceedings of the 2014 Winter Simulation Conference*, 07.12.2014–10.12.2014, Savannah, GA. Piscataway, NJ: IEEE Press: S. 2192–2203. doi: 10.1109/WSC.2014.7020063.
- [3] Jeong, Y.; Singh, A.; Zafarzadeh, M.; Wiktorsson, M.; Baalsrud Hauge, J. Data-driven manufacturing simulation: towards a CPS-based approach. In: Säfsten, K.; Elgh, F. (Hrsg.): *SPS2020: Proceedings of the Swedish Production Symposium*, 07.10.2020–8.10.2020, Jönköping, Sweden. Amsterdam: IOS Press Incorporated: S. 587–596. doi: 10.3233/ATDE200197.
- [4] Kamble, S.S.; Gunasekaran, A. Big data-driven supply chain performance measurement system: a review and framework for implementation. *International Journal of Production Research*. 2020; 58(1): S. 65–86. doi: 10.1080/00207543.2019.1630770.
- [5] Nguyen, D.T.; Adulyasak, Y.; Cordeau, J.-F.; Ponce, S.I. Data-driven operations and supply chain management: established research clusters from 2000 to early 2020. *International Journal of Production Research*. 2021; 60(59): S. 1–25. doi: 10.1080/00207543.2021.1956695.
- [6] Wen, L.; Li, X.; Gao, L.; Zhang, Y. A new convolutional neural network-based data-driven fault diagnosis method. *IEEE Transactions on Industrial Electronics*. 2018; 65(7): S. 5990–5998. doi: 10.1109/TIE.2017.2774777.
- [7] Qiao, F.; Liu, J.; Ma, Y. Industrial big-data-driven and CPS-based adaptive production scheduling for smart manufacturing. *International Journal of Production Research*. 2021; 59(23): S. 7139–7159. doi: 10.1080/00207543.2020.1836417.
- [8] Tao, F.; Cheng, J.; Qi, Q.; Zhang, M.; Zhang, H.; Sui, F. Digital twin-driven product design, manufacturing and service with big data. *The International Journal of Advanced Manufacturing Technology*. 2018; 94(9-12): S. 3563–3576. doi: 10.1007/s00170-017-0233-1.
- [9] Na, Y.; Peng, S. A data-driven approach for identification and detection of intermittent faults. In: Liu, M.; Nogueiras Melendez, A.A.; Zhang, B.; Liu, X. (Hrsg.): *2021 4th IEEE International Conference on Industrial Cyber-Physical Systems (ICPS)*, 10.05.2021 - 12.05.2021, Victoria, BC, Canada. Piscataway, NJ: IEEE Press: S. 455–460. doi: 10.1109/ICPS49255.2021.9468167.
- [10] Hammond, P. From computer-assisted to data-driven: Journalism and Big Data. *Journalism*. 2017; 18(4): S. 408–424. doi: 10.1177/1464884915620205.
- [11] Men, H. Data-driven learning in enhancing learners' language idiomaticity. *International Journal of Emerging Technologies in Learning (iJET)*. 2020; 15(23): S. 27. doi: 10.3991/ijet.v15i23.19023.
- [12] Xu, K.; Li, Y.; Liu, C.; Liu, X.; Hao, X.; Gao, J.; Maropoulos, P.G. Advanced data collection and analysis in data-driven manufacturing process. *Chinese Journal of Mechanical Engineering*. 2020; 33(1): S. 1–21. doi: 10.1186/s10033-020-00459-x.
- [13] Deutsche Industrie Norm DIN 55350:2021-10, Begriffe zum Qualitätsmanagement. Berlin: Beuth.
- [14] Cerquitelli, T.; Pagliari, D.J.; Calimera, A.; Bottaccioli, L.; Patti, E.; Acquaviva, A.; Poncino, M. Manufacturing as a data-driven practice: methodologies, technologies, and tools. *Proceedings of the IEEE*. 2021; 109(4): S. 399–422. doi: 10.1109/JPROC.2021.3056006.
- [15] Subramanian, M.; Skoogh, A.; Salomonsson, H.; Bangalore, P.; Bokrantz, J. A data-driven algorithm to predict throughput bottlenecks in a production system based on active periods of the machines. *Computers & Industrial Engineering*. 2018; 125: S. 533–544. doi: 10.1016/j.cie.2018.04.024.
- [16] Zhang, Y.; Cheng, Y.; Wang, X.V.; Zhong, R.Y.; Zhang, Y.; Tao, F. Data-driven smart production line and its common factors. *The International Journal of Advanced Manufacturing Technology*. 2019; 103(1-4): S. 1211–1223. doi: 10.1007/s00170-019-03469-9.
- [17] Roh, P.; Kunz, A.; Netland, T. Data-driven detection of moving bottlenecks in multi-variant production lines. *IFAC-PapersOnLine*. 2018; 51(11): S. 158–163. doi: 10.1016/j.ifacol.2018.08.251.
- [18] Ivanov, D.; Dolgui, A. A digital supply chain twin for managing the disruption risks and resilience in the era of Industry 4.0. *Production Planning & Control*. 2021; 32(9): S. 775–788. doi: 10.1080/09537287.2020.1768450.

- [19] Zhang, Y.; Zhang, G.; Wang, J.; Sun, S.; Si, S.; Yang, T. Real-time information capturing and integration framework of the internet of manufacturing things. *International Journal of Computer Integrated Manufacturing*. 2015; 28(8): S. 811–822. doi: 10.1080/0951192X.2014.900874.
- [20] Tao, F.; Cheng, J.; Qi, Q. IIHub: an industrial internet-of-things hub toward smart manufacturing based on cyber-physical system. *IEEE Transactions on Industrial Informatics*. 2018; 14(5): S. 2271–2280. doi: 10.1109/TII.2017.2759178.
- [21] Kuo, Y.-H.; Kusiak, A. From data to big data in production research: the past and future trends. *International Journal of Production Research*. 2019; 57(15-16): S. 4828–4853. doi: 10.1080/00207543.2018.1443230.
- [22] Zhang, C.; Zhou, G.; He, J.; Li, Z.; Cheng, W. A data- and knowledge-driven framework for digital twin manufacturing cell. *Procedia CIRP*. 2019; 83: S. 345–350. doi: 10.1016/j.procir.2019.04.084.
- [23] Gutenschwager, K.; Rabe, M.; Spieckermann, S.; Wenzel, S. *Simulation in Produktion und Logistik*. Berlin, Heidelberg: Springer. 2017.
- [24] Qiao, Q.; Wang, J.; Ye, L.; Gao, R.X. Digital twin for machining tool condition prediction. *CIRP Procedia*. 2019; 81: S. 1388–1393. doi: 10.1016/j.procir.2019.04.049.
- [25] Bi, Z.; Da Xu, L.; Wang, C. Internet of things for enterprise systems of modern manufacturing. *IEEE Transactions on Industrial Informatics*. 2014; 10(2): S. 1537–1546. doi: 10.1109/TII.2014.2300338.
- [26] Rabe, M.; Wenzel, S.; Spieckermann, S. *Verifikation und Validierung für die Simulation in Produktion und Logistik*. Berlin, Heidelberg: Springer. 2008.
- [27] Heimeshoff, L. *Data Driven - Untersuchung datengetriebener Prozesse im Umfeld von Produktion und Logistik* [Bachelorarbeit]. [Fakultät Maschinenbau]. Technische Universität Dortmund, 2021.