

Nachfolgend finden Sie die Übersetzung ins Deutsche des frei verfügbaren Fachartikels:

Original:

„Toward Data-Driven and Multi-Scale Modeling for Material Flow Simulation: Characteristic Analysis of Modeling Methods“.

Nagahara, Satoshi Kaihara, Toshiya Fujii, Nobutada Kokuryo, Daisuke.

Verfügbar unter (Stand 23.6.2025):

<https://hdl.handle.net/20.500.14094/0100490281>

Dies ist eine nicht offizielle deutsche Übersetzung des Originals durch:

Markus Bans

ATS Prozessoptimierung Markus Bans

Web: <https://simio-simulation.de>

Lizenz:

Creative Commons Namensnennung 4.0 International (CC BY 4.0)

S. <https://creativecommons.org/licenses/by/4.0/deed.de>



Auf dem Weg zu datengetriebener und multiskaliger Modellierung für Materialflusssimulation: Charakteristisch Analyse von Modellierungsmethoden

Nagahara, Satoshi

Kaihara, Toshiya

Fujii, Nobutada

Kokuryo, Daisuke

(Zitat)

Angewandte Künstliche Intelligenz, 38(1):2367840

(Erscheinungs-
datum) 2024-
12-31

(Ressourcentyp
)

Zeitschriftenarti-
kel

(Ausführung)

Version des Datensatzes

(Rechte)



© 2024 Der/die Autor(en). Veröffentlicht mit Lizenz von Taylor & Francis Group, LLC.

Hierbei handelt es sich um einen Open-Access-Artikel, der unter den Bedingungen der Creative Commons Attribution License vertrieben wird, die die uneingeschränkte Nutzung, Verbreitung und Vervielfältigung in jedem Medium erlaubt, sofern das Originalwerk ordnungsgemäß zitiert wird.

(URL)

<https://hdl.handle.net/20.500.14094/0100490281>



Angewandte Künstliche Intelligenz

Eine internationale
Zeitschrift

ISSN: (Print) (Online) Homepage der Zeitschrift www.tandfonline.com/journals/uaai20

Auf dem Weg zu datengetriebener und mehrskaliger Modellierung für die Materialflusssimulation: Charakteristische Analyse von Modellierungsmethoden

Satoshi Nagahara, Toshiya Kaihara, Nobutada Fujii & Daisuke Kokuryo

Um diesen Artikel zu zitieren: Satoshi Nagahara, Toshiya Kaihara, Nobutada Fujii & Daisuke Kokuryo (2024) Towards Data-Driven and Multi-Scale Modelling for Material Flow Simulation: Charakteristische Analyse von Modellierungsmethoden, Angewandte Künstliche Intelligenz, 38:1, 2367840, DOI: [10.1080/08839514.2024.2367840](https://doi.org/10.1080/08839514.2024.2367840)

Um auf diesen Artikel zu verlinken:
<https://doi.org/10.1080/08839514.2024.2367840>



© 2024 Der/die Autor(en). Veröffentlicht mit
Lizenz von Taylor & Francis Group, LLC.



Online veröffentlicht: 17 Jun 2024.



Reichen Sie Ihren Artikel bei dieser
Zeitschrift ein



Artikelaufrufe: 72



Verwandte Artikel anzeigen



Zeigen Sie Crossmark
an

Die vollständigen Zugangs- und Nutzungsbedingungen finden Sie unter
<https://www.tandfonline.com/action/journalInformation?journalCode=uaai20>

Auf dem Weg zu datengetriebener und multiskaliger Modellierung für Material Strömungssimulation: Kennlinienanalyse der Modellierung Methodik

Satoshi Nagahara^{a,b}, Toshiya Kaihara^b, Nobutada Fujii^b und Daisuke Kokuryo^b

^aForschungsabteilung für Industrieautomatisierung, Hitachi, Ltd, Kanagawa, Japan; ^bGraduiertenschule für Systeminformatik, Universität Kobe, Hyogo, Japan

ABSTRAKT

Die Materialflusssimulation ist ein leistungsstarkes Werkzeug, um effiziente Abläufe in komplizierten Produktionssystemen wie der High-Mix- und Low-Volume-Produktion zu realisieren. Dennoch sind großer Aufwand und Fachwissen notwendig, um genaue Simulationsmodelle zu konstruieren. Wir haben einen halbautomatischen Modellierungsansatz vorgeschlagen, der als datengetriebene und mehrskalige Modellierung bezeichnet wird. Der Ansatz kombiniert verschiedene Modellierungsmethoden, um die Simulationsgenauigkeit zu maximieren. In diesem Artikel wird die vorgeschlagene Methode vorgestellt und die experimentell gewonnenen Ergebnisse für einfache Produktionssysteme vorgestellt, um die Eigenschaften von Modellierungsmethoden auf Basis von Warteschlangenmodellen oder maschinellen Lernmodellen zu untersuchen. Die Ergebnisse von Computereperimenten deuten darauf hin, dass die Überlegenheit und Unterlegenheit von Modellierungsmethoden von der Komplexität des Systems und dem Hintergrundwissen über die Aktivitätskonfiguration im System abhängt.

ARTIKEL-HISTORIE

Eingegangen am 4.
September 2023
Überarbeitet am 10.
Februar 2024
Angenommen 6.
Juni 2024

Einleitung

In jüngster Zeit sind Produktionssysteme wie High-Mix- und Low-Volume-Produktion aufgrund der Diversifizierung der Marktbedürfnisse komplizierter geworden. Um einen effizienten Betrieb in solchen Systemen zu erreichen, rücken cyber-physische Produktionssysteme (CPPS) und digitale Zwillinge in den Fokus (Monostori 2014). Für diese Konzepte ist die Stoffstromsimulation ein wichtiges Werkzeug, um die zukünftige Produktion vorherzusagen (Rosen et al. 2015). In der Praxis erfordert die Erstellung genauer Simulationsmodelle jedoch viel Aufwand und Fachwissen. Diese Schwierigkeit behindert die Realisierung des CPPS/Digital Twin-Konzepts in der Industrie, und es werden

automatische Modellierungsmethoden gefordert. In den letzten Jahren sind durch den Vormarsch von IoT-Geräten immer mehr Daten aus Produktionssystemen verfügbar. Darüber hinaus machen die Techniken des maschinellen Lernens (ML) bemerkenswerte Fortschritte. ML-Techniken ermöglichen es uns, das Systemverhalten aus den Daten zu identifizieren und Modelle mit unterschiedlichen Maßstäben zu erstellen, wie z. B. Produktionsprozesse und

KONTAKT Satoshi Nagahara  satoshi.nagahara.eb@hitachi.com  Industry Automation Research Dept, Hitachi Ltd. Kanagawa, Japan

© 2024 Der/die Autor(en). Veröffentlicht mit Lizenz von Taylor & Francis Group, LLC.

Hierbei handelt es sich um einen Open-Access-Artikel, der unter den Bedingungen der Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>) vertrieben wird, die die uneingeschränkte Nutzung, Verbreitung und Vervielfältigung in jedem Medium erlaubt, sofern das Originalwerk ordnungsgemäß zitiert wird. Die Bedingungen, unter denen dieser Artikel veröffentlicht wurde, erlauben die Veröffentlichung des akzeptierten Manuskripts in einem Repositorium durch den/die Autor(en) oder mit deren Zustimmung.

ganze Systeme. Es wird erwartet, dass diese Fähigkeit nützlich ist, da die vollständige Nachahmung eines tatsächlichen Systems oft schwierig ist und es erforderlich ist, das System entsprechend den verfügbaren Daten zu abstrahieren. Vor dem oben dargestellten Hintergrund schlagen wir einen datengetriebenen und multiskaligen Modellierungsansatz vor, der durch die Kombination verschiedener Modellierungsmethoden halbautomatisch genaue Simulationsmodelle konstruiert. In diesem Beitrag überprüfen wir die Überlegenheit und Unterlegenheit von Modellierungsmethoden durch computergestützte Experimente, um den Entwicklungsverlauf des vorgeschlagenen Ansatzes zu betrachten.

Herausforderungen bei der Modellierung von Materialflusssimulationen

Allgemeiner Modellierungsprozess für die Materialflusssimulation

Materialfluss ist die Bezeichnung für den Transport von Materialien. Die Materialflusssimulation ist eine weit verbreitete Technologie, die es uns ermöglicht, die Bewegung von Materialien in diskreten Systemen wie Produktions- und Logistiksystemen vorherzusagen. Die Materialflusssimulation wird hauptsächlich zur Unterstützung der menschlichen Entscheidungsfindung bei der Konstruktion von Produktionssystemen und der Produktionsplanung eingesetzt (Hoellthaler et al. 2019; Lechner et al. 2023).

Produktionssysteme bestehen aus einer Reihe von Prozessen, in denen Materialien verarbeitet, montiert, gelagert usw. werden. Daher wird ein Materialflusssimulationsmodell im Allgemeinen durch eine Reihe von Warteschlangenmodellen beschrieben, die einen Produktionsprozess ausdrücken. Ein allgemeiner Modellierungsprozess sieht wie folgt aus. Zunächst werden die Parameter der Modellkonfiguration wie Umfang und

Granularität des Modells definiert, so dass der Zweck der Simulationsnutzung erreicht wird. Als nächstes werden die Daten vorbereitet, die zur Definition des Modells erforderlich sind. Warteschlangenmodelle bestehen aus verschiedenen Aktivitäten wie Disposition, Bearbeitung und Rüsten. **Tabelle 1** zeigt ein Beispiel für typische Aktivitäten, ihr Verhalten und die erforderlichen Informationen, um das Verhalten zu bestimmen. Es ist notwendig, verschiedene Daten zu sammeln und/oder zu erstellen, um die jeweiligen Verhaltensweisen im Zusammenhang mit diesen Aktivitäten zu definieren. Anschließend wird das Modell unter Verwendung der vorbereiteten Daten in einer Simulationssoftware implementiert. Schließlich wird das Modell validiert. Die Simulationsgenauigkeit wird durch den Vergleich der Simulationsergebnisse bewertet

Tabelle 1. Ein Beispiel für Aktivitäten in einem Warteschlangenmodell.

| Aktivität | Verhalten bei Aktivitäten | Erforderliche Informationen |
|--------------------------|--|--|
| Versendung | Wählen Sie Aufträge, die als nächstes verarbeitet werden sollen, aus Aufträgen in einer Warteschlange aus. | Regel für die Auftragsverteilung |
| Zuweisung von Ressourcen | Wählen Sie Ressourcen (z. B. Maschine, Arbeitskraft) aus, die für die nächsten Aufträge verwendet werden sollen. | Regel für die Ressourcenzuweisung |
| Einrichtung | Bestimmen Sie, ob Setupvorgänge erforderlich sind, basierend auf der Differenz des Produkttyps zwischen dem vorherigen Job und dem nachfolgenden Job, der von den Ressourcen verarbeitet wurde, und belegen Sie die Ressourcen dann bei Bedarf für einen vordefinierten Zeitraum von Setupvorgängen. | Auftretensbedingungen des Setup-Vorgangs und Rüstzeit für jede Bedingung |
| Zerspanung | Belegen Sie die Ressourcen für eine vordefinierte Zeit der Bearbeitungsvorgänge. | Bearbeitungszeit für jeden Produkttyp |
| Routing | Verschieben Sie Aufträge in die Warteschlange des nächsten Prozesses. | Prozessroute für jeden Produkttyp |

mit dem eigentlichen Produktionsprotokoll. Das Modell wird nach dem Trial-and-Error-Prinzip überprüft. Nicht nur das Aktivitätsverhalten, sondern auch die Modellkonfiguration wird manchmal überarbeitet, bis der erforderliche Genauigkeitsgrad erreicht ist. Der obige Modellierungsprozess besteht aus vielen manuellen Aufgaben. Darüber hinaus hängt es von den subjektiven Entscheidungen des Modellierers ab. Daher ist die Automatisierung des Modellierungsprozesses wichtig, um die Materialflusssimulation in großem Umfang nutzen zu können.

Verwandte Arbeiten und Herausforderungen

In Bezug auf die automatische Modellierung für die Materialflusssimulation nutzt die meiste bestehende Forschung Datenmodelle und Systemarchitekturen, um automatisch Simulationsprogramme aus Daten zu

generieren (Barlas und Heavey 2016). So schlugen Kirchhof et al. eine Methode vor, mit der Simulationsobjekte, die Produktionsprozesse repräsentieren, im Voraus definiert werden. Anschließend werden diese Objekte auf Basis von MES-Daten kombiniert (Kirchhof 2016). Steinbacher et al. stellten eine Ontologie zur Generierung von Materialflusssimulationsmodellen für Logistiksysteme zur Verfügung (Steinbacher et al. 2023). Darüber hinaus schlugen Henkenjohann et al. Standardmodule in der Produktion für die Materialflusssimulation vor, um die Modellimplementierung in die Simulationsumgebung zu vereinfachen (Henkenjohann et al. 2021). Diese Studien sind hilfreich, um den Aufwand für die Modellimplementierung zu reduzieren.

Einige Studien haben die Verbesserung der Simulationsgenauigkeit untersucht. So schlugen Karnok et al. beispielsweise eine Methode vor, die Prozessrouten und Betriebszeiten aus Produktionsprotokollen schätzt (Karnok und Monostori 2011). Popovics et al. schlugen eine Methode vor, um ein Antwortmodell eines Fördersystems aus SPS-Programmen zu konstruieren (Popovics und Monostori 2013). Nagahara et al. schlugen eine Methode vor, um Dispatching-Regeln mit Hilfe von ML-Techniken zu identifizieren (Nagahara, Sprock und Helu 2019). Sie schlugen auch eine Methode vor, die Parameter in einem Simulationsmodell kalibriert, um die Genauigkeit zu maximieren (Nagahara et al. 2020). May et al. nutzten Process-Mining-Techniken und Convolutional neural Networks, um Prozess-Routing und Ressourcenzuweisungsregeln aus Produktionsprotokolldaten zu identifizieren (May et al. 2024). Die oben genannten Methoden sind nützlich, um den Aufwand für die Datenaufbereitung zu reduzieren, um das Verhalten von Aktivitäten in Warteschlangenmodellen zu bestimmen. Darüber hinaus wurden ML-basierte Methoden vorgeschlagen, die die Input-Output-Beziehung des Systems direkt ausdrücken. Zum Beispiel schlugen Lingitz et al. eine Methode vor, die die Produktionsvorlaufzeit mit Hilfe von künstlichen neuronalen Netzen, Random Forest usw. vorhersagt (Lingitz et al. 2018). Da diese Methode keine Warteschlangenmodelle verwendet, können wir den Aufwand für die Definition der Aktivitätskonfiguration in Warteschlangenmodellen und die Aufbereitung von Daten für jede Aktivität reduzieren.

Wie oben erläutert, werden verschiedene Modellierungsmethoden vorgeschlagen, um das Verhalten eines Produktionssystems zu identifizieren. Welche Art von Modellierungsmethode für ein bestimmtes System geeignet ist, bleibt jedoch unklar. In der Praxis sind die Aktivitäten im realen Produktionssystem für jedes System unterschiedlich, und es ist oft schwierig und zeitaufwändig, alle Aktivitäten im System zu erfassen und in Simulationsmodellen zu beschreiben. Daher ist es wichtig, Modellierungsmethoden in Abhängigkeit von den Merkmalen und verfügbaren Informationen des Zielsystems zu verwenden. Darüber hinaus

sind in einem Produktionssystem mit mehreren Prozessen die Aktivitätskonfiguration und das Aktivitätsverhalten für jeden Prozess unterschiedlich. Daher kann die am besten geeignete Modellierungsmethode für jeden Prozess unterschiedlich sein, und es ist wichtig, mehrere Modellierungsmethoden zu verwenden, um ein genaues Modell des gesamten Systems zu erstellen. Unter dem oben genannten Gesichtspunkt haben wir in unserer früheren Studie einen datengetriebenen und mehrskaligen Modellierungsansatz vorgeschlagen, um die Konfiguration eines Simulationsmodells durch die Kombination verschiedener Modellierungsmethoden zu optimieren (Nagahara et al. 2022). In diesem Beitrag konzentrieren wir uns auf Produktionssysteme mit einem einzigen Prozess, der unterschiedliche Aktivitäten hat. Wir vergleichen die Vorhersagefähigkeit von Modellen, die mit verschiedenen Modellierungsmethoden erhalten wurden, um die Überlegenheit und Inferiorität der Modellierungsmethode als grundlegende Studie zu untersuchen, um die Nützlichkeit des vorgeschlagenen Ansatzes zu überprüfen.

Vorgeschlagene Methode

Klassifikation der Modellierungsmethoden

In diesem Kapitel wird der in unserer früheren Studie vorgeschlagene Modellierungsansatz kurz überprüft, um die in den folgenden Kapiteln vorgestellten Diskussionen zu ergänzen.

Tabelle 2 beschreibt die vorgeschlagene Klassifizierung der Modellierungsmethoden. Die Modellierungsmethoden werden unter zwei Gesichtspunkten klassifiziert: Modellskala wie die Aktivitäts-/Prozess-/Systemskala; und Modelltyp, z. B. ein weißes/schwarzes/grau Box-Modell. Hier gibt der Modellmaßstab den Umfang der Modelle an.

Modelle auf der Aktivitätsskala beziehen sich auf Modelle, die sich auf einzelne Aktivitäten konzentrieren, wie z. B.

Tabelle 2. Klassifikation von Modellierungsmethoden.

| Modellierungsmethode | Modellmaßstab | Modelltyp | Definition |
|----------------------|---------------|---------------|--|
| Aktivität WBM | Aktivität | Weißer Kasten | Beschreiben Sie das Verhalten der Aktivität explizit und deduktiv auf Basis von Hintergrundwissen. |
| Aktivität BBM | | Blackbox | Erstellen Sie ein ML-Modell, das implizit die Eingabe-Ausgabe-Beziehung der Aktivität aus dem Aktivitätsprotokoll ausdrückt. |
| Prozess BBM | Prozess | Weißer Kasten | Erstellen Sie ein Warteschlangenmodell, in dem alle Aktivitäten durch die Aktivitäts- |

| | | | |
|-----------------|--------|---------------|---|
| | | | WBM ausgedrückt werden und die Verbindungen zwischen den Aktivitäten ebenfalls explizit beschrieben werden. |
| Prozess BBM | | Blackbox | Erstellen Sie ein ML-Modell, das die Prozessausgabe direkt aus der Eingabe vorhersagt. |
| GBM verarbeiten | | Grauer Kasten | Erstellen Sie ein Warteschlangenmodell, in dem die Summe/alle Aktivitäten durch die Aktivität BBM ausgedrückt werden und die Verbindungen zwischen den Aktivitäten explizit beschrieben werden. |
| System WBM | System | Weißer Kasten | Erstellen Sie ein Modell, in dem alle Prozesse durch Prozess-WBM ausgedrückt werden (wird in allgemeiner Simulationssoftware verwendet). |
| System BBM | | Blackbox | Erstellen Sie ein ML-Modell, das die Systemausgabe direkt aus der Eingabe vorhersagt. |
| System GBM-1 | | Grauer Kasten | Erstellen Sie ein Modell, in dem einige/alle Prozesse durch den Prozess GBM/BBM ausgedrückt werden. |
| Anlage GBM-2 | | | Erstellen Sie ein Modell, in dem jedes Subsystem, das aus einigen Prozessen besteht, im gesamten System durch das System BBM ausgedrückt wird. |

wie Disposition, Bearbeitung, etc. Modelle auf Prozessebene geben Modelle an, die sich auf einen Prozess konzentrieren, und Modelle auf Systemebene geben Modelle an, die sich auf ein System konzentrieren, das aus mehreren Prozessen besteht.

Als Aktivitätsskalenmodelle werden das Aktivitäts-White-Box-Modell (Aktivitäts-WBM) und das Aktivitäts-Black-Box-Modell (Aktivität BBM) definiert. Die Aktivität WBM ist ein Modell, in dem das Aktivitätsverhalten explizit und deduktiv definiert wird. Aktivität BBM ist ein ML-basiertes Modell, das die Input-Output-Beziehung der Aktivität induktiv ausdrückt. Als Prozessmaßstabsmodelle werden Prozess-WBM, Prozess-BBM und Prozess-Gray-Box-Modell (Prozess-GBM) definiert. Prozess-WBM ist ein Warteschlangenmodell, das aus Aktivitäts-WBMs besteht. Prozess-BBM ist ein ML-basiertes Modell, das die Input-Output-Beziehung des Prozesses induktiv ausdrückt. Prozess-GBM ist ein Queue-Modell, in dem einige oder alle Aktivitäten durch die Aktivität BBM ausgedrückt werden. Auf der Systemskala sind das System WBM, das System BBM, das System GBM-1 und das System GBM-2 definiert. System WBM besteht aus Prozess-WBMs. System BBM ist ein ML-Modell, das die Input-Output-Beziehung des Systems ausdrückt. Das System GBM-1 ist ein Modell, in dem einige oder alle Prozesse durch den Prozess GBM/BBM ausgedrückt werden. Das System GBM-2 ist ein Modell, bei dem jedes Subsystem im gesamten System durch das System BBM ausgedrückt wird.

Datengetriebene und multiskalige Modellierung

Basierend auf der obigen Klassifizierung wurde die in Abbildung 1 gezeigte datengetriebene und mehrskalige Simulationsmodellierung vorgeschlagen. Die vorgeschlagene Methode zielt darauf ab, durch die Kombination verschiedener Modellierungsmethoden ein genaues Simulationsmodell abzuleiten. Die Notationen von W/G/B in Abbildung 1 repräsentieren WBM/GBM/BBM auf einer beliebigen Skala (Aktivität/Prozess/System). Wie in den Modellen (a) gezeigt,

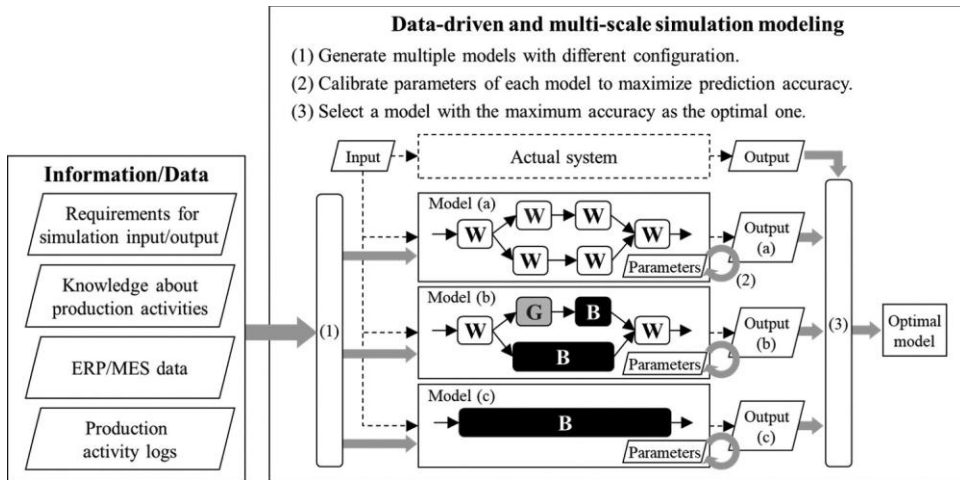


Abbildung 1. Schematische Darstellung des vorgeschlagenen Modellierungsansatzes. (b) und (c) In Abbildung 1 können verschiedene Modellkonfigurationen für ein bestimmtes System in Betracht gezogen werden. Die vorgeschlagene Methode generiert mehrere Modellkonfigurationen, indem sie die Prozesse und Aktivitäten integriert und aufteilt (Abbildung 1(1)). Anschließend werden die Parameter in jedem Modell entsprechend den Eingabe-/Ausgabeanforderungen für die Simulationsverwendung kalibriert, um Änderungen in der Ausgabe in Bezug auf Änderungen in der Eingabe genau vorherzusagen (Abbildung 1(2)). Schließlich wird das genaueste Modell ausgewählt (Abbildung 1(3)). Bei dieser Methode handelt es sich um eine datengetriebene Methode, die die optimale Modellkonfiguration auf der Grundlage der Simulationsgenauigkeit auswählt. Darüber hinaus handelt es sich bei dieser Methode um eine Multiskalen-Modellierungsmethode, die Modelle unterschiedlicher Skalen kombiniert.

Die Anforderungen an den Simulations-Input und -Output hängen vom Zweck des Simulationseinsatzes ab und es können verschiedene Zwecke des Simulationseinsatzes vermutet werden. Für die Antwort auf das Fälligkeitsdatum ist es beispielsweise wichtig, das Abschlussdatum und die Uhrzeit jedes Auftrags anhand des Ankunftsdatums und der Ankunftszeit jedes Auftrags als Simulationseingabe vorherzusagen. Auf der anderen Seite, wenn die Simulation für die Gestaltung eines Produktionssystems verwendet wird,

ist eine Simulation erforderlich, um den Durchsatz des Produktionssystems aus der Anzahl der Produktionsressourcen wie Maschinen vorherzusagen. Die Genauigkeit der Simulation sollte auf der Grundlage der obigen Perspektive bewertet werden. Mit anderen Worten, die Anforderung an Simulationsmodelle besteht darin, die Änderung der Ausgabe entsprechend der Änderung der Eingabe genau vorherzusagen. Bei der vorgeschlagenen Methode werden daher Simulationsmodelle so kalibriert, dass der Vorhersagefehler in der Ausgabe in [Abbildung 1\(2\)](#) minimiert wird.

Im Folgenden wird davon ausgegangen, dass die Eingabe und Ausgabe der Simulation das Ankunftsdatum-Uhrzeit bzw. das Abschlussdatum-Uhrzeit jedes Auftrags sind, um die Details des vorgeschlagenen Verfahrens konkret zu beschreiben. Für den Fall, dass wir das gesamte System in Subsysteme unterteilen und Subsystemmodelle konstruieren, wie in [Abbildung 1 gezeigt](#), werden Subsystemmodelle verbunden, indem wir das Datum und die Uhrzeit der Auftrags erledigung eines Subsystemmodells als Datum und Uhrzeit der Auftragsankunft anderer Subsystemmodelle verwenden. Daher ist es wichtig, Modelle in Betracht zu ziehen, die das Datum und die Uhrzeit des Auftragsabschlusses aus dem Datum und der Uhrzeit des Auftragseingangs vorhersagen. Da die Vorhersage von Datum und Uhrzeit der Auftrags erledigung ab dem Datum und der Uhrzeit des Auftragseintreffens gleichbedeutend mit der Vorhersage der Auftragsdurchlaufzeit ist, wird der Zweck der Simulation im Folgenden als Vorhersage der Auftragsdurchlaufzeit definiert.

Wie bereits erwähnt, gibt es in Produktionssystemen verschiedene Tätigkeiten wie Disposition, Rüsten und Bearbeiten. Wenn die Aktivitätskonfiguration des Zielsystems und das Verhalten aller Aktivitäten bekannt sind, kann die System-WBM auf der Grundlage der oben genannten Informationen erstellt werden. Auf der anderen Seite, wenn das Verhalten einiger Aktivitäten unbekannt ist und die tatsächlichen Protokolldaten bezüglich der Ein- und Ausgabe des Aktivitätsverhaltens (im Folgenden nennen wir diese Daten als Aktivitätsprotokolldaten), können Aktivitäts-BBMs dieser Aktivitäten unabhängig voneinander unter Verwendung der Aktivitätsprotokolldaten und ML-Techniken erstellt werden. Wenn die Daten des Aktivitätsprotokolls jedoch nicht verfügbar sind, ist es notwendig, ein Modell aus anderen Daten zu erstellen. Für den Fall, dass z.B. die Daten bezüglich des Beginns und der Fertigstellungszeit der Rüstaktivität für jeden Job nicht verfügbar sind und die Daten bezüglich des Ankunfts- und Fertigstellungsdatums jedes Prozesses verfügbar sind, ist es notwendig, Modelle mit den letztgenannten Daten zu kalibrieren. Für solche Fälle haben wir zwei Modellierungsmethoden vorgeschlagen; (1) Die eine besteht darin, ein GBM zu erstellen, indem die Parameter kalibriert werden, die das Verhalten von Aktivitäten in Warteschlangenmodellen definieren, und (2) die andere besteht darin, ein BBM zu erstellen, das das Datum und die Uhrzeit des

Auftragsabschlusses direkt aus dem Datum und der Uhrzeit der Auftragsankunft durch ML-Techniken vorhersagt.

Als Methode für (1) schlagen wir eine Methode vor, die die Parameter in GBMs mit Hilfe der Partikelschwarmoptimierung (PSO) kalibriert, bei der es sich um eine kontinuierliche Optimierungstechnik handelt. Für den Fall, dass beispielsweise ein Warteschlangenmodell mit einer Bearbeitungsaktivität als Prozess-GBM bestimmt wird, muss die Bearbeitungszeit für den Produkttyp als Parameter, die das Verhalten der Bearbeitungsaktivität definieren, entsprechend kalibriert werden, um eine genaue Vorhersage der Auftragsdurchlaufzeit zu gewährleisten. Die Parameter, die kalibriert werden müssen, hängen von der Aktivitätskonfiguration des Modells ab. Bei dieser Methode wird der Parametervektor \mathbf{X} , der das Verhalten jeder Aktivität in GBMs definiert, von PSO durchsucht, um den Fehler bei der Auftragsvorlaufzeit zu minimieren. Die Zielfunktion J_{GBM} wird durch Gleichung (1) dargestellt.

$$J_{GBM} = \|\mathbf{It}^{ref} - \mathbf{It}^{GBM}\| \quad (1)$$

Dabei sind \mathbf{It}^{ref} und \mathbf{It}^{GBM} jeweils Vektoren der Vorlaufzeit im Zielsystem und GBM. \mathbf{It}^{GBM} entspricht der vorhergesagten Vorlaufzeit im GBM, wenn die Werte des Parametervektors \mathbf{X} angewendet **werden**. Als Methode für die Aktualisierung von \mathbf{X} wird das von Choi et al. vorgeschlagene R-Best-Modell verwendet (Choi, Ohmori und Yoshimoto 2011). \mathbf{X} wird durch die folgenden Gleichungen aktualisiert:

$$\mathbf{X}_i^{k+1} = \mathbf{X}_i^k + \mathbf{V}_i^{k+1} \quad (2)$$

$$\begin{aligned} \mathbf{V}_i^{k+1} = w \times \mathbf{V}_i^k + c_1 * rand() * (\mathbf{gbest} - \mathbf{X}_i^k) \\ + c_2 * rand() * (\mathbf{pbest}_i - \mathbf{X}_i^k) \end{aligned} \quad (3)$$

Hier wird \mathbf{V} als Geschwindigkeitsvektor bezeichnet. \mathbf{X}_{ki} und \mathbf{V}_{ki} sind jeweils der Parametervektor und der Geschwindigkeitsvektor des Teilchens i in der Generation k . \mathbf{gbest} ist der Parametervektor der besten Lösung im Suchprozess, und \mathbf{pbest}_i ist der Parametervektor der besten Lösung von Teilchen i im Suchprozess. W , $C1$ und $C2$ sind Gewichtungsfaktoren.

Als Methode für (2) schlagen wir eine Methode vor, die ein BBM unter Verwendung von ANN (künstliches neuronales Netz) mit N Eingängen und 1 Ausgabe konstruiert. Die Eingabe von KNN ist ein Merkmalsvektor für einen beliebigen Auftrag, und die Ausgabe ist die vorhergesagte Vorlaufzeit dieses Auftrags. Die Verlustfunktion J_{BBM} wird durch Gleichung (4) dargestellt.

$$J_{BBM} = \|\mathbf{It}^{ref} - \mathbf{It}^{BBM}\| \quad (4)$$

Hier ist \mathbf{It}^{BBM} ein Vektor der von BBM **vorhergesagten** Vorlaufzeit. Da die Vorlaufzeit von Auftrag i nicht nur vom Ankunftsdatum und der Ankunftszeit von Auftrag i **abhängt**, sondern auch vom Produkttyp und den Aufträgen, die vor und nach Auftrag i eintreffen, sollten die Eingaben von KNN solche

Informationen enthalten. Daher definieren wir die Merkmale von Job i als Gleichungen (5), (6) und (7).

i

$$x_m^i = \begin{cases} 1 & \text{if } pt_i = m \\ 0 & \text{otherwise} \end{cases} \quad (m = 1, \dots, M) \quad (5)$$

$$y_{d,m}^i = \sum_j \delta_{j,d,m}^i \quad (j = 1, \dots, N; d = -D, \dots, D-1; m = 1, \dots, M) \quad (6)$$

$$\text{where } \delta_{j,d,m}^i = \begin{cases} 1 & \text{if } j \neq i \text{ and } pt_j = m \text{ and} \\ & d \cdot \Delta D \leq t_j^{in} - t_i^{in} < (d+1) \cdot \Delta D \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

Here, x_m^i and $y_{d,m}^i$ are the features of job i . pt_i is the index of product type of job i .

, also $x^i = [x_1^i; x_2^i; \dots; x_M^i]^T$ ist ein One-Hot-Vektor, der den Produkttyp des Auftrags i darstellt. $y_d; m$ bezeichnet die Anzahl der eingehenden Aufträge der Produktart m in einem bestimmten Zeitraum, die durch t_i^{in} und die Parameter D und ΔD bestimmt wird. D steht für die Anzahl der Aufträge, die vor und nach dem Auftrag i eintreffen. ΔD ist die Längeneinheit der obigen Periode. Also, $y_d; m$ ist eine Variable, die die Merkmale des Arbeitsankunftsplans ausdrückt.

Die oben beschriebenen Methoden sind nicht nur auf einen einzelnen Prozess, sondern auch auf mehrere Prozesse anwendbar. Wenn die Produktionsprotokolldaten für jeden Prozess das Datum und die Uhrzeit der Auftragsankunft/-fertigstellung enthalten, kann das System GBM durch die Kombination von Prozess-GBM oder BBM jedes Prozesses erstellt werden. Auch wenn nur das Datum und die Uhrzeit des Auftragseingangs im ersten Prozess und das Datum und die Uhrzeit der Auftrags erledigung im letzten Prozess in den Daten des Produktionsprotokolls verfügbar sind, ist es möglich, ein System GBM oder ein System BBM mit den oben genannten Methoden zu erstellen.

Computergestützte Experimente

Zweck der Experimente

Das vorgeschlagene Verfahren kombiniert WBM/BBM/GBM, um eine hohe Genauigkeit zu erreichen. Mit anderen Worten, die vorgeschlagene Methode geht davon aus, dass die Überlegenheit jeder Modellierungsmethode von den Eigenschaften des Zielsystems abhängt. Die Überlegenheit der Modellierungsmethode hängt eng mit den verfügbaren Daten und dem Hintergrundwissen zusammen. Wenn wir zum Beispiel alle Aktivitäten im Zielsystem und deren Verhalten kennen, erreichen System WBM eine hohe

Genauigkeit. Wenn die Aktivitäten und/oder ihr Verhalten teilweise unbekannt sind, wäre die System-WBM ungenau. Wenn jedoch das Aktivitätsprotokoll einiger Aktivitäten verfügbar ist, ist es möglich, von ihnen eine Aktivität BBM zu erstellen. Das Verständnis der Überlegenheit und Unterlegenheit von Modellierungsmethoden ist wichtig, um Methoden zur Optimierung der Modellkonfiguration in Betracht zu ziehen.

Aus den oben dargestellten Perspektiven haben wir in einer früheren Studie Computereperimente durchgeführt, um Prozess-GBM und Prozess-BBM für Produktionssysteme mit einem einzelnen Prozess und einer einzigen Maschine zu vergleichen (Nagahara et al. 2022). Aus dieser Studie haben wir festgestellt, dass der Prozess GBM dem Prozess BBM tendenziell überlegen ist, wenn die Aktivitätskonfiguration im tatsächlichen Prozess bekannt ist.

Für diese Forschung führen wir zusätzliche Experimente durch, um die obige Analyse zu ergänzen. Konkret untersuchen wir, wie sich die Komplexität des Systems auf die Vorhersagefähigkeit des Prozesses GBM und des Prozesses BBM auswirkt, und zwar durch die Experimente für ein Produktionssystem mit einem einzigen Prozess und mehreren Maschinen. Darüber hinaus untersuchen wir die Generalisierbarkeit von Modellierungsmethoden im Vergleich zur Veränderung der Arbeitsanfallshäufigkeit.

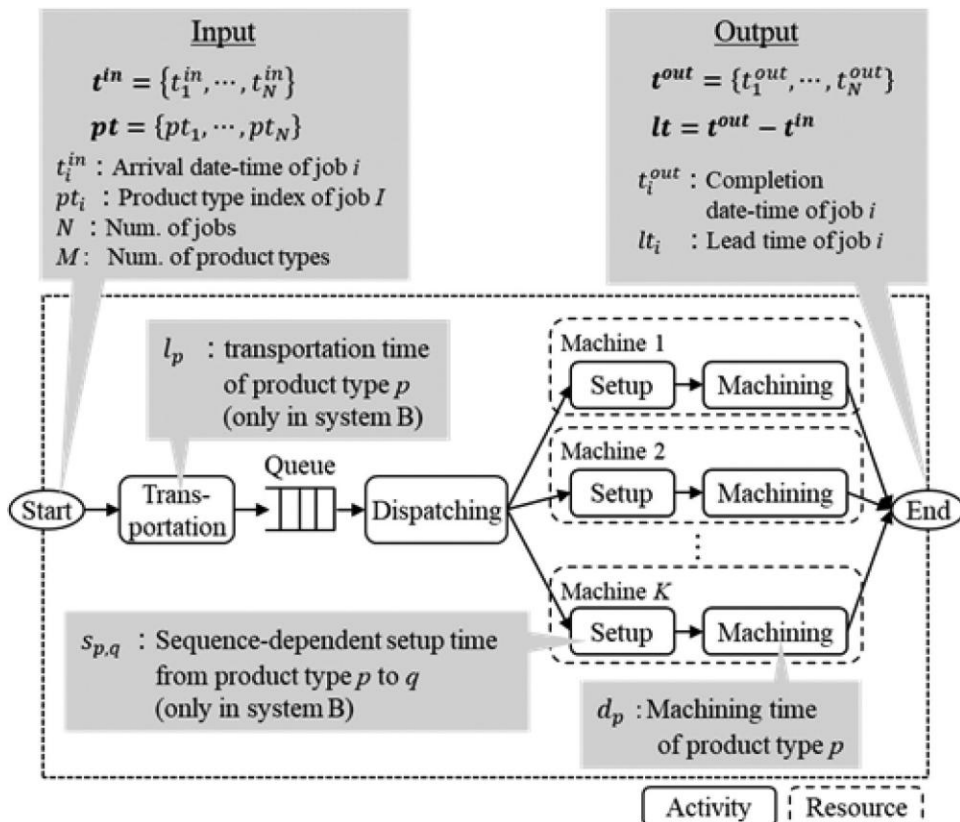


Abbildung 2. Versuchsbedingungen: Zielproduktionssystem.

Experimentelle Bedingungen

In diesem Experiment werden zwei virtuelle Produktionssysteme als Zielproduktionssysteme angenommen: System A und System B in [Abbildung 2](#). Sowohl System A als auch System B sind Mixed-Flow-Produktionssysteme mit einem einzigen Prozess. System A besteht aus Dispositions- und Bearbeitungstätigkeiten. System B verfügt außerdem über transport- und reihenfolgeabhängige Rüstaktivitäten. Die Transportzeit lp und die Bearbeitungszeit dp unterscheiden sich je nach Produkttyp p . Einrichtungszeit sp ; Q unterscheidet sich für die Kombination des bisherigen Produkttyps P und des aufeinanderfolgenden Produkttyps Q . Die Einplanungsregel ist First-In-First-Out (FIFO).

Für dieses Experiment werden Prozess-WBMs von System A und B als tatsächliches Produktionssystem betrachtet. Konkret haben wir 1.000 Szenarien erstellt, in denen das Ankunftsdatum-Uhrzeit-Element und der Produkttypindex pti von Job i nach dem Zufallsprinzip für die Modellierung bzw. Validierung festgelegt werden. Anschließend werden für jedes Szenario aus den *Simulationsergebnissen der Prozess-WBMs der Fertigstellungsdatum-Zeit-TiM* und die Durchlaufzeit lti des Auftrags i berechnet. Dabei werden bei WBMs die Werte von lp , dp und sp ; q werden zufällig gesetzt. In jedem Szenario beträgt die Anzahl der Produkttypen M 5 und die Anzahl der Einzelvorgänge N 50. Die Anzahl der Maschinen wird variiert, um die Auswirkungen der Systemkomplexität zu untersuchen.

Darüber hinaus wenden wir verschiedene Bedingungen der Jobankunftshäufigkeit für die Modellierung und Validierung von Datensätzen an, um die Generalisierbarkeit zu bewerten. Wir führen einen Parameter α ein und setzen t_i^{in} in jedem Szenario durch die Gleichungen (8) und (9) ein.

$$t_i^{in} = t_i^{initial} + \alpha * T * r_i (i = 1, \dots, N) \quad (8)$$

$$where r_i \leftarrow U[0, 1], T = \sum_{j=1}^N \left(d_{pt_j} + \sum_{q=1}^M s_{pt_j,q} / M \right) \quad (9)$$

In diesen Gleichungen stellt $t_i^{initial}$ das anfängliche Datum-Uhrzeit-Verhältnis der Simulation dar. Der kleinere Wert von α gibt die höhere Häufigkeit des Auftragseingangs an. Der Wert von α wird nach dem Zufallsprinzip von $U(1/2\alpha_{min}, \alpha_{Maximum})$ für jedes Szenario festgelegt. Außerdem werden α_{min} und α_{max} für jedes Dataset festgelegt. Im Folgenden werden α_{min} und α_{max} als Parameter für die Ankunftshäufigkeit bezeichnet; außerdem werden $\delta\alpha_{min}$; α_{max^p} für den Modellierungsdatensatz bzw. den Validierungsdatensatz als α^{mmin} , α^{mmax} und α^{vmin} , α^{vmax} beschrieben.

Da es sich bei den Systemen A und B um deterministische Systeme handelt, ist es leicht ersichtlich, dass genaue Prozess-WBMs konstruiert werden können, wenn die Aktivitätskonfiguration und ihr Verhalten bekannt sind.

Daher betrachten wir für dieses Experiment den Fall, in dem das Verhalten einiger Aktivitäten unbekannt ist und kein Aktivitätsprotokoll von ihnen verfügbar ist. Konkret sind die Zeitinformatoren lp , dp , sp ; q sind unbekannt. Nur die Informationen, die in den Teilen "Input" und "Output" in [Abbildung 2 beschrieben](#) sind, sind aus dem Produktionsprotokoll verfügbar.

In der obigen Problemeinstellung werden der Prozess GBM und der Prozess BBM verglichen. Prozess-GBM ist ein Warteschlangenmodell mit einer vordefinierten Aktivitätskonfiguration.

Die unbekannt Parameter im Modell wie lp , dp , sp ; q sind kalibriert, um den Vorhersagefehler durch PSO zu minimieren. Als Prozess-GBM betrachten wir zwei Modelle: GBM-A und GBM-B, die jeweils aus den gleichen Aktivitäten mit System A und System B bestehen. Als Prozess BBM wird ein KNN verwendet, das die Durchlaufzeit jedes Auftrags aus dem Produkttyp und dem Ankunftsdatum und der Ankunftszeit jedes Auftrags vorhersagt.

Experimentelle Ergebnisse: Der Einfluss der Systemkomplexität auf die Vorhersagegenauigkeit

Die experimentellen Ergebnisse zur Untersuchung des Einflusses der Systemkomplexität auf die Vorhersagegenauigkeit sind in [Tabelle 3 dargestellt](#). Als Genauigkeitsindex wird der Bestimmungskoeffizient (R^2) der Auftragsdurchlaufzeit verwendet. [Tabelle 3](#) zeigt den R^2 -Wert von Modellen für System A und System B. Das genaueste Modell für jedes System ist fett dargestellt. In diesem Experiment werden α^{min} , α^{max} und α^{vmin} , α_{mvax} auf 0:8 festgelegt. 1:0P.

Für System A ist GBM-A das genaueste Modell. Da GBM-A die gleiche Aktivitätskonfiguration wie System A hat und nur die Bearbeitungsaktivität hat, zeigt GBM-A auch bei zunehmender Anzahl der Maschinen fast vollständig imitiertes System A an. Dieses Ergebnis deutet darauf hin, dass die Parameterkalibrierung von PSO die global optimale Lösung erreicht hat. Auf der anderen Seite zeigt GBM-B eine hohe Genauigkeit für den Fall einer einzelnen Maschine, aber die Genauigkeit nimmt mit der Zunahme der Maschinen ab. Obwohl es eine Lösung gibt, die eine hohe Genauigkeit erreicht, da GBM-B über genügend Ausdruckskraft verfügt, um System A zu imitieren, fiel PSO in eine lokal optimale Lösung. Bei mehreren Maschinen führten die Fehler in Parametern wie der Bearbeitungszeit zu Fehlern im Timing, wann jede Maschine in den Leerlauf versetzt wurde. Dann führen die Fehler zu einem Unterschied in der Verarbeitungsreihenfolge von Jobs und dem Unterschied im Auftreten und der erforderlichen Zeit der Setup-Aktivität. Diese Komplexität von GBM-B erschwert die Parameterkalibrierung. [Tabelle 4](#) zeigt den R^2 -Wert, wenn die Bearbeitungszeit einen Fehler von 20 % aufweist. Wie in [Tabelle 4 gezeigt](#), nimmt die Genauigkeit von GBM-B aufgrund der Zunahme der Maschinen im Vergleich zu GBM-A ab. Dies hatte zur Folge, dass

GBM-B bei mehreren Maschinen, wie in Tabelle 3 dargestellt, BBM unterlegen war. Dieses Ergebnis deutet darauf hin, dass BBM möglicherweise besser ist, wenn die Aktivitätskonfiguration teilweise unbekannt ist.

Tabelle 3. Genauigkeit jedes Modells für System A und System B.

| Zielsystem | Ein. von Maschinen | R2 der Vorlaufzeit des Auftrags [-] | | |
|------------|-----------------------|--|-------|------|
| | | GBM-A | GBM-B | BBM |
| System A | 1 | 1.00 | 1.00 | 0.97 |
| | 3 | 1.00 | 0.62 | 0.97 |
| | 5 | 1.00 | 0.52 | 0.97 |
| System B | 1 | 0.79 | 1.00 | 0.73 |
| | 3 | 0.79 | 0.77 | 0.75 |
| | 5 | 0.66 | 0.69 | 0.71 |

Tabelle 4. Genauigkeit, wenn die Parameter der Bearbeitungszeit einen Fehler von 20 % aufweisen.

| Zielsystem | Anzahl von Maschinen | R2 der Vorlaufzeit des Auftrags [-] | |
|------------|-------------------------|-------------------------------------|-------|
| | | GBM-A | GBM-B |
| System A | 1 | 0.94 | N/A |
| | 3 | 0.92 | N/A |
| | 5 | 0.89 | N/A |
| System B | 1 | N/A | 0.99 |
| | 3 | N/A | 0.72 |
| | 5 | N/A | 0.53 |

Für System B weist GBM-A im Vergleich zu System A eine geringere Genauigkeit auf, da GBM-A nicht über genügend Aktivitäten verfügt, um System B auszudrücken. Auf der anderen Seite zeigt GBM-B eine hohe Genauigkeit in 1 Maschinengehäuse. Die Genauigkeit nimmt jedoch bei mehreren Maschinengehäusen ab, und GBM-B ist anderen Modellen wie GBM-A und BBM unterlegen. Dieses Ergebnis deutet darauf hin, dass GBM nicht immer das beste ist, auch wenn die Aktivitätskonfiguration des Zielsystems vollständig bekannt ist.

Aus den obigen Ergebnissen wird festgestellt, dass GBM tendenziell besser ist, wenn die Aktivitätskonfiguration des Zielsystems bekannt ist und die Komplexität von System und Modell relativ gering ist, da BBM sonst GBM übertreffen kann. Wie in Abschnitt 2.2 erwähnt, ist es in der Praxis oft schwierig und zeitaufwändig, alle Vorgänge im System zu verstehen. In solchen

Fällen ist es notwendig, dass die in GBM definierten Aktivitäten die Aktivitäten im System abdecken, um zu gewährleisten, dass GBM das Zielsystem nachahmen kann. Die Zunahme der Aktivitäten erschwert jedoch die Parameterkalibrierung. Da es eine Kompromissbeziehung zwischen der Ausdruckskraft des Modells und der Anpassungsfähigkeit der Parameterkalibrierung gibt, ist es wichtig, notwendige und ausreichende Aktivitäten in GBM einzuführen. Die experimentellen Ergebnisse deuten darauf hin, dass BBM im Vorteil ist, wenn GBM aufgrund der hohen Komplexität der Zielsysteme und/oder des Mangels an Hintergrundwissen über die Aktivitätskonfiguration von Zielsystemen mit hoher Komplexität eingesetzt werden muss.

Die Verallgemeinerungsfähigkeit von Modellierungsmethoden

Das Ergebnis von Experimenten zur Untersuchung der Generalisierungsfähigkeit von Modellierungsmethoden ist in den [Abbildungen 3 und 4](#) dargestellt. Die [Abbildungen 3 und 4](#) sind die Ergebnisse für System A bzw. B. In den Experimenten wurden α^{mmin} ; α^{mmax} und α^{vmin} ; α^{vmax} variiert, um zu analysieren, wie sich der Unterschied in den Bedingungen für die Arbeitsankunft in Modellierungs- und Validierungsdatensätzen auf die Genauigkeit auswirkt. Jedes Diagramm in den [Abbildungen 3 und 4](#) ist das Ergebnis bei einem bestimmten Wert von α^{vmin} ; α^{vmax} , und die horizontale Achse beträgt α^{mmin} ; α^{mmax} .

[Abbildung 3a](#) zeigt das Ergebnis für System A mit einer einzelnen Maschine.

GBM-A und

GBM-B zeigt eine stabil hohe Genauigkeit, unabhängig vom Wert von α^{mmin} ; α^{mmax} und α^{vmin} ; α^{vmax} . Das liegt daran, dass die Parameterkalibrierung von GBM-A und GBM-B scheiterte, um die global optimale Lösung in einem einzigen Maschinenfall zu finden. Auf der anderen Seite nimmt die Genauigkeit von BBM ab, wenn α^{mmin} ; α^{mmax} und

Ein^{vmin} ; Ein^{vmax} sind unterschiedlich. Dies ist ein allgemeiner

Trend in der ML-Branche und es wird angenommen, dass

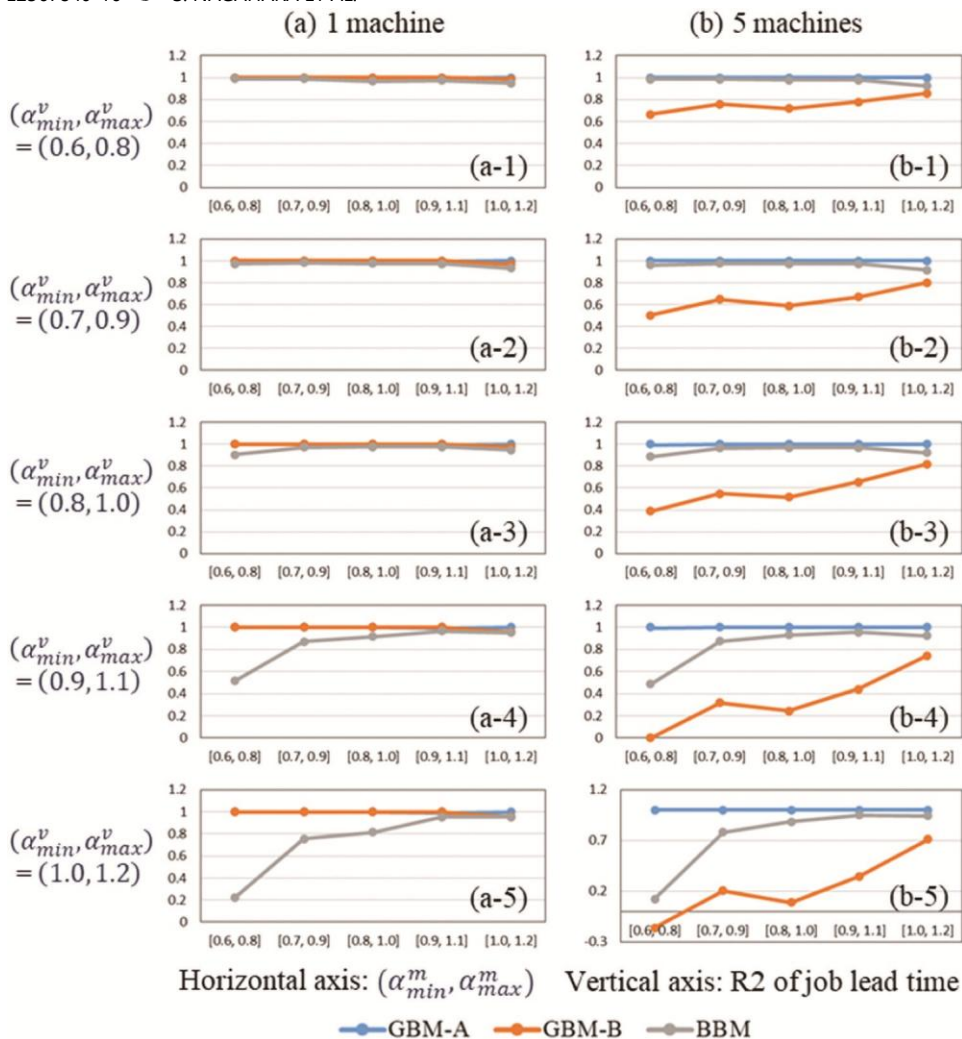


Abbildung 3. Analyse der Generalisierungsfähigkeit jedes Modells für System A.

Verursacht durch Überanpassung an das Modellierungsdataset. In den Fällen, in denen $\alpha^{vmin}; \alpha^{vmax}$ niedrig ist, ändert sich die Genauigkeitsänderung um die Differenz von $\alpha^{mmin}; \alpha^{mmax}$

klein ist, wie in den **Abbildungen 3** (a-1) und (a-2) zu sehen ist. Dieses Ergebnis deutet darauf hin, dass BBM, das mit den Daten mit spärlichen Auftragsankünften trainiert wurde, d. h. $\alpha^{mmin}; \alpha^{mmax}$ hoch ist, eine hohe Genauigkeit unter dichten Ankunftsbedingungen erreicht, d. h. $\alpha^{mmin}; \alpha^{mmax}$ niedrig ist. Auf der anderen Seite zeigt BBM, das mit den Daten mit dichten Ankunftsbedingungen trainiert wurde, eine geringe Genauigkeit unter spärlichen Ankunftsbedingungen, wie in **Abbildung 3** (a-5) gezeigt. Dieses Ergebnis deutet darauf hin, dass BBM, das mit Daten mit geringer Auslastung des Auftragseingangs trainiert wurde, eine hohe Generalisierungsfähigkeit

aufweist, aber die Aufklärung der Ursache dieses Ergebnisses ist ein zukünftiges Problem.

Abbildung 3b zeigt das Ergebnis für System A mit fünf Maschinen. In diesem Fall nimmt die Genauigkeit von GBM-B ab, da die Parameterkalibrierung durch PSO in die

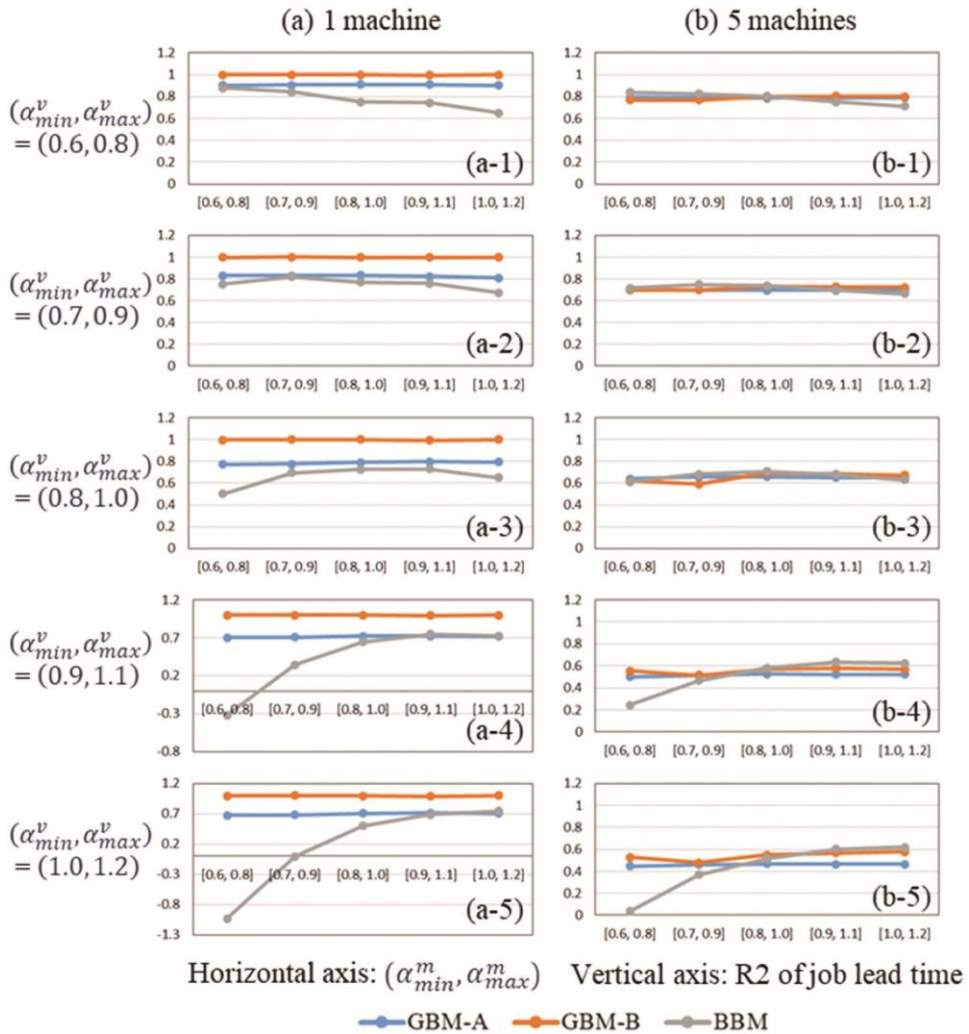


Abbildung 4. Generalisierungsfähigkeitsanalyse jedes Modells für System B.

eine optimale Lösung vor Ort. Da es sich bei PSO um eine heuristische Optimierungsmethode handelt, ist es schwierig, aus diesen Ergebnissen solide Trends zu erkennen, aber die Genauigkeit nimmt tendenziell zu, wenn ein Datensatz mit wenigen Auftragseingängen modelliert wird. Es wird vermutet, dass die Schwierigkeit bei der Parameterkalibrierung aufgrund der Modellkomplexität relativ gering wird, da die Job-Queue in GBM unter spärlichen Ankunftsbedingungen manchmal leer sein kann.

Als Nächstes zeigt **Abbildung 4a** das Ergebnis für System B mit einem Computer. GBM-B und BBM zeigen einen ähnlichen Trend im Vergleich zum

Fall von System A. Die Genauigkeit von GBM-A ist relativ gering, aber die Genauigkeit nimmt nicht ab, auch wenn α^{mmin} ; α^{mmax} von α^{vmin} ; α^{vmax} abweichen. Dieses Ergebnis deutet darauf hin, dass GBM-A aufgrund der geringen Ausdruckskraft von GBM-A nicht an die Modellierungsdatensätze angepasst ist.

Abbildung 4b zeigt das Ergebnis für System B mit fünf Maschinen an. In diesem Fall nimmt die Genauigkeit aller Modelle aufgrund der Komplexität des Zielsystems ab. BBM

übertrifft GBMs, wenn α^{mmin} ; α^{mmax} gleich und/oder geschlossen zu α^{vmin} ist, α^{vmax} , andernfalls wird die Überlegenheit/Unterlegenheit umgekehrt.

In diesem Experiment wird die Verallgemeinerungsfähigkeit von Modellierungsmethoden für die Veränderungen der Arbeitsantrittshäufigkeit untersucht. Auf der anderen Seite gibt es weitere mögliche Veränderungen in Produktionssystemen, wie z.B. Maschinenausfälle in der Praxis. Für den Fall eines Maschinenausfalls hat GBM den Vorteil, dass die Anzahl der Maschinen im Modell explizit geändert werden kann, aber die in diesem Dokument verwendete BBM ist nicht in der Lage, die Informationen über den Maschinenausfall in das Modell zu übertragen. Die Evaluierung und Verbesserung der Generalisierungsfähigkeit für solche Veränderungen sind Zukunftsthemen.

Schlussfolgerung

Wir haben einen neuartigen Modellierungsansatz für die Materialflusssimulation vorgeschlagen, der als datengetriebene und mehrskalige Simulationsmodellierung bezeichnet wird und darauf abzielt, die Modellkonfiguration in Bezug auf die Simulationsgenauigkeit durch die Kombination verschiedener Modellierungsmethoden zu optimieren. Für diese Studie haben wir rechnerische Experimente für ein virtuelles Produktionssystem mit einem einzigen Prozess durchgeführt, um die Eigenschaften von Modellierungsmethoden zu untersuchen. Dabei haben wir folgende Erkenntnisse gewonnen: (1) Wenn die Aktivitätskonfiguration des Zielsystems teilweise unbekannt ist und/oder die Komplexität des Systems hoch ist, kann BBM GBM übertreffen. (2) Im Vergleich zu GBM reagiert BBM empfindlicher auf den Unterschied zwischen Modellierungs- und Validierungsdatensatz, insbesondere wenn es auf spärliche Bedingungen bei der Ankunft von Aufträgen angewendet wird. (3) BBM, die unter spärlichen Bedingungen bei der Arbeitsankunft trainiert werden, zeigen tendenziell eine bessere Genauigkeit und Generalisierbarkeit. Die Überlegenheit und Unterlegenheit von Modellierungsmethoden hängt von der Komplexität sowohl der Systeme als auch der Modelle, dem Hintergrundwissen über das System und den möglichen Veränderungen im System ab. Diese Ergebnisse deuten darauf hin, dass der vorgeschlagene Modellierungsansatz, der

verschiedene Modellierungsmethoden kombiniert, nützlich ist, um genaue Simulationsmodelle zu erhalten, da die Eigenschaften der Systeme und das Hintergrundwissen in praktischen Fällen unterschiedlich sind.

Als zukünftige Arbeit beabsichtigen die Autoren, die Ursachen von (2) zu untersuchen. Darüber hinaus werden Experimente für kompliziertere Systeme wie mehrere Prozesse durchgeführt, um Methoden zu entwickeln, die Modellkonfigurationen optimieren, um das vorgeschlagene Konzept zu realisieren.

Offenlegungserklärung

Der/die Autor(en) hat keinen potenziellen Interessenkonflikt gemeldet.

Erklärung zur Datenverfügbarkeit

Die Daten, die die Ergebnisse dieser Studie stützen, sind auf Anfrage vom korrespondierenden Autor, S. N., erhältlich.

Referenzen

- Barlas, P. und C. Heavey. 2016. Automatisierung von Eingabedaten zur diskreten Ereignissimulation für die Fertigung: Ein Überblick. *Internationale Zeitschrift für Modellierung, Simulation und wissenschaftliches Rechnen* 7 (1):1630001. doi:[10.1142/S1793962316300016](https://doi.org/10.1142/S1793962316300016) .
- Choi, H., S. Ohmori und K. Yoshimoto. 2011. Verbesserung der Partikelschwarmoptimierung: Vorschlag eines R-Best-Modells und einer Parameteranpassung unter Berücksichtigung der Suchphase und des Suchzustands. 21. Internationale Konferenz für Produktionsforschung, Stuttgart, Deutschland, 2079–83.
- Henkenjohann, M., R. Joppen, D. Köchling, S. Enzberg, A. Kuhn und R. Dumitrescu. 2021. Identifikation und Spezifikation von Standardmodulen in der Produktion für eine Materialflusssimulation. *Procedia CIRP* 99:21–26. doi:[10.1016/j.procir.2021.03.004](https://doi.org/10.1016/j.procir.2021.03.004) .
- Hoellthaler, G., M. Schreiber, K. Vernickel, J. Isa, J. Fischer, N. Weinert, R. Rosen und S. Braunreuther. 2019. Rekonfiguration von Produktionsanlagen durch Optimierung und Materialflusssimulation. *Procedia CIRP* 81:133–38. doi:[10.1016/j.procir.2019.03.024](https://doi.org/10.1016/j.procir.2019.03.024) .
- Karnok, D. und L. Monostori. 2011. Ermittlung von Arbeitsplänen und Prozesszeitinformationen aus Ereignisprotokollen. *IFAC Proceedings Bände* 44 (1):14055–60. doi:[10.3182/20110828-6-IT-1002.01448](https://doi.org/10.3182/20110828-6-IT-1002.01448) .
- Kirchhof, P. 2016. Generieren Sie automatisch Flow-Shop-Simulationsmodelle aus SAP-Daten. Tagungsband der Wintersimulationskonferenz 2016, Arlington, Virginia, USA, 3588–89.
- Lechner, M., P. Mothwurf, L. Nohe und R. Daub. 2023. Die Stoffflusssimulation in der Herstellung von Lithium-Ionen-Batteriezellen als Planungsinstrument zur Kosten- und Energieoptimierung. 5. Konferenz über Produktionssysteme und Logistik, Stellenbosch, Südafrika, 212–21.
- Lingitz, L., V. Gallina, F. Ansari, D. Gyulai, A. Pfeiffer, W. Sihn und L. Monostori. 2018. Vorhersage der Vorlaufzeit mit Algorithmen des maschinellen Lernens: Eine Fallstudie eines Halbleiterherstellers. *Procedia CIRP* 72:1051–56. doi:[10.1016/j.procir.2018.03.148](https://doi.org/10.1016/j.procir.2018.03.148) .
- May, M. C., C. Nestroy, L. Overbeck und G. Lanza. 2024. Framework zur automatisierten Modellgenerierung für Materialflusssimulationen von Produktionssystemen. *Internationale*

- Monostori, L. 2014. Cyber-physische Produktionssysteme: Wurzeln, Erwartungen und Herausforderungen in Forschung und Entwicklung. *Procedia CIRP* 17:9–13. doi:[10.1016/j.procir.2014.03.115](https://doi.org/10.1016/j.procir.2014.03.115) .
- Nagahara, S., T. Kaihara, N. Fujii und D. Kokuryo. 2022. Ein Vorschlag für einen datengetriebenen und mehrskaligen Modellierungsansatz für die Materialflusssimulation. IFIP WG 5.7 Internationale Konferenz APMS 2022, Gyeongju, Korea, 297–215.
- Nagahara, S., S. Serita, Y. Shiho, S. Zheng, H. Wang, T. Chida und C. Gupta. 2020. Auf dem Weg zu einer datengetriebenen Modellierung der Materialflusssimulation: Automatische Parameterkalibrierung mehrerer Agenten aus spärlichen Produktionsprotokollen. 16. Internationale IEEE-Konferenz für Automatisierungswissenschaft und -technik, 1096–101.
- Nagahara, S., T. A. Sprock und M. M. Helu. 2019. Auf dem Weg zu einer datengetriebenen Modellierung von Produktionssimulationen: Identifizierung von Dispositionsregeln durch Techniken des maschinellen Lernens. *Procedia CIRP* 81:222–27. doi:[10.1016/j.procir.2019.03.039](https://doi.org/10.1016/j.procir.2019.03.039) .
- Popovics, G. und L. Monostori. 2013. Die Generierung von ISA-Standard Simulationsmodellen wird durch Daten unterstützt, die in Low-Level-Controllern gespeichert sind. *Procedia CIRP* 12:432–37. doi:[10.1016/j.procir.2013.09.074](https://doi.org/10.1016/j.procir.2013.09.074) .
- Rosen, R., G. Wichert, G. Lo und K. D. Bettenhausen. 2015. Über die Bedeutung von Autonomie und digitalen Zwillingen für die Zukunft der Fertigung. *IFAC-Papersonline* 48 (3):567–72. doi:[10.1016/j.ifacol.2015.06.141](https://doi.org/10.1016/j.ifacol.2015.06.141) .
- Steinbacher, L. M., T. Düe, M. Veigt und M. Freitag. 2023. Automatische Modellgenerierung für Materialflusssimulationen der Fremdlogistik. *Zeitschrift für intelligente Fertigung*. doi:[10.1007/s10845-023-02257-3](https://doi.org/10.1007/s10845-023-02257-3).

Dies war eine Übersetzung ins Deutsche des frei verfügbaren Fachartikels:

Original:

„Toward Data-Driven and Multi-Scale Modeling for Material Flow Simulation: Characteristic Analysis of Modeling Methods“.

Nagahara, Satoshi Kaihara, Toshiya Fujii, Nobutada Kokuryo, Daisuke.

Verfügbar unter (Stand 23.6.2025):

<https://hdl.handle.net/20.500.14094/0100490281>

Dies ist eine nicht offizielle deutsche Übersetzung des Originals durch:

Markus Bans
ATS Prozessoptimierung Markus Bans
Web: <https://simio-simulation.de>

Lizenz:

Creative Commons Namensnennung 4.0 International (CC BY 4.0)

S. <https://creativecommons.org/licenses/by/4.0/deed.de>