



生産システムシミュレーションにおけるデータ駆動型マルチスケールモデリング手法に関する研究（フローショップ生産システムを対象としたモデル構造整理とモデル同定）

永原, 聡士
貝原, 俊也
藤井, 信忠
國領, 大介

(Citation)

日本機械学会論文集, 91(941):24-00107

(Issue Date)

2025

(Resource Type)

journal article

(Version)

Version of Record

(Rights)

© 2025 一般社団法人日本機械学会

© 2025 The Japan Society of Mechanical Engineers

この記事はクリエイティブ・コモンズ [表示 - 非営利 - 改変禁止 4.0 国際]ライセンスの下に提供されています。

(URL)

<https://hdl.handle.net/20.500.14094/0100497763>



生産システムシミュレーションにおける データ駆動型マルチスケールモデリング手法に関する研究 (フローショップ生産システムを対象としたモデル構造整理とモデル同定)

永原 聡士^{*1,*2}, 貝原 俊也^{*3}, 藤井 信忠^{*2,*4}, 國領 大介^{*2}

A study on data-driven and multi-scale modeling method for production system simulation “Model configuration and identification for flow shop production systems”

Satoshi NAGAHARA^{*1,*2}, Toshiya KAIHARA^{*3}, Nobutada FUJII^{*2,*4} and Daisuke KOKURYO^{*2}

^{*1} Industry Automation Research Department., Research and Development Group, Hitachi, Ltd.

292 Yoshida-cho, Totsuka-ku, Yokohama-shi, Kanagawa 244-0817, Japan

^{*2,*3} Graduate School of System Informatics, Kobe University

1-1 Rokkodai-cho, Nada-ku, Kobe-shi, Hyogo 657-8501, Japan

^{*4} Information Science and Technology Center, Information Infrastructure and Digital Transformation Initiatives Headquarters, Kobe University

1-1 Rokkodai-cho, Nada-ku, Kobe-shi, Hyogo 657-8501, Japan

Received: 22 April 2024; Revised: 6 October 2024; Accepted: 2 December 2024

Abstract

To efficiently operate complicated production systems such as mixed-flow production, production system simulation is a promising tool. However, constructing accurate simulation models requires significant effort. In this study, we proposed a data-driven and multi-scale modeling approach that optimizes model configuration by combining multiple modeling methods. In order to verify the usefulness of the proposed approach, we organized the possible model configurations from the perspective of available data from target system and conducted computational experiments for flow shop production systems to compare various model configurations. The experimental results show that the optimal model configuration strongly depends on the complexity of target system and models to be identified, and it is important to divide the model so as to reduce the complexity.

Keywords : Production system simulation, Production system, System identification, Machine learning

1. 緒 言

近年、多品種少量化など複雑な生産システムを効率的に運用するための仕掛けとして、Cyber-Physical Production System (以下、CPPS) や Digital Twin が注目されている (Monostori, 2014). これらの仕組みにおいては、サイバー空間におけるフィジカル空間の精緻なモデリングが重要となる. 特に Digital Twin においては、実生産システムの将来の挙動を予測するための生産システムシミュレーション (Production System Simulation, 以下 PSS) が重要とされている (Rosen et al., 2014). また、PSS は Reconfigurable Manufacturing System などの新たなコンセプトの生産システムを実現する上でも有用である (Gola et al., 2021). これらの仕組みにおいては、PSS には実システムの挙動を正確に予測することが求められるが、高精度なシミュレーションモデルの構築には多大な労力を要しているのが実態であり、これが産業界でのシミュレーション活用の障壁の一つになっている. 一方近年、生産現場から収集されるデータは粒度・精度ともに向上しており、機械学習技術も様々な分野で発展を遂げている. 上記を背景に、筆者らは、加工組立系の生産システムを対象に、データや機械学習技術を活用して

No.24-00107 [DOI:10.1299/transjsme.24-00107], J-STAGE Advance Publication date : 11 December, 2024

^{*1} 正員, (株) 日立製作所 研究開発グループ 産業オートメーション研究部 (〒244-0817 神奈川県横浜市戸塚区吉田町 292)

^{*2} 正員, 神戸大学 大学院システム情報学研究科 (〒657-8501 兵庫県神戸市灘区六甲台町 1-1)

^{*3} フェロー, 神戸大学 大学院システム情報学研究科

^{*4} 正員, 神戸大学 DX・情報統括本部 情報基盤センター

E-mail of corresponding author: satoshi.nagahara.cb@hitachi.com

PSS のモデルを半自動的に構築するデータ駆動型マルチスケールモデリングを提案している (永原ら, 2023). 本報では, データ駆動型マルチスケールモデリングのコンセプトについて概説した上で, 仮想的なフローショップ生産システムを対象としたモデリング手法の比較実験について報告する.

本論文は本章を含めて 5 章で構成される. 第 2 章では, PSS の一般的なモデルとモデリングプロセス, 関連研究, 自動モデリングの課題と本研究の位置づけを述べる. 第 3 章では, 既報で述べたデータ駆動型マルチスケールモデリングの全体像と単工程システムを対象とした提案方式の実現方法について概説した後, 本方法を複数工程システムに拡張する方法を提案する. そして, 第 4 章では, 仮想的なフローショップシステムを対象とした実験結果を述べ, 提案手法の有用性に関する考察を述べる. 最後に, 第 5 章において, 総括と今後の課題を述べる.

2. 生産システムシミュレーションの自動モデリングにおける課題と本研究の位置付け

2・1 一般的な生産システムシミュレーションモデルとモデリングプロセス

PSS は, コンピュータ上に構築した生産システムモデルにおいて, モノが所定の処理時間を経て設備を渡り歩いていく様を表現することでシステムの挙動を予測するものである (日比野, 2013). PSS は主にライン設計, 納期回答, 生産計画などに活用される. 本研究で対象とする加工組立系のシステムにおいては, 生産システム内の各工程を, その工程での処理を待っているジョブ群の Queue を有したモデル (以下, Queue モデル) で表現することが多い. Queue モデル内では, 表 1 に示すようなアクティビティを定義する. また, PSS の一般的なモデリングプロセスは, (1)モデル構造定義, (2)データ準備, (3)モデル実装, (4)モデル検証からなる. 表 1 のアクティビティやモデリングプロセスの詳細は既報を参照されたい (永原ら, 2023). 現状のモデリングプロセスでは, 特にモデル構造の定義やモデル検証 (精度評価とモデルの見直し) に属人的な判断や多大な工数を要しており, モデル構造の最適化も含めたモデリングプロセスの自動化・高精度化が課題である.

Table 1 An example of activities in queue models of production system simulation.

Activity	Behavior	Required information
Dispatching	Select jobs to be processed next from jobs in a queue.	Dispatching rule
Resource assignment	Select resources (e.g., machine, worker) to be used for the next jobs.	Assignment rule
Setup	Occupy the resources for the setup time determined based on the information about jobs (e.g., product type) and the resources.	Setup occurrence condition, setup time
Machining	Occupy the resources for the machining time determined based on the information about the jobs (e.g., product type) and the resources.	Machining time
Routing	Move jobs to the queue of next processes.	Process routing rule

2・2 既存研究と本研究の位置づけ

PSS の自動モデリングに関する既存研究には, データモデルやシステムアーキテクチャの事前定義により, モデル実装を自動化するものが多い (Balras, et al., 2016). 例えば, Kirchhof らは, 生産プロセスを表すオブジェクトを事前に定義し, オブジェクトを選択・結合することでモデル実装する方法を提案している (Kirchhof et al., 2016). シミュレーション精度向上に関しては, 生産実績データから工程経路や作業時間を推定する方法や, PLC (Programmable Logic Controller) プログラムからコンベアシステムの応答モデルを同定する方法などが提案されている (Karnok, et al., 2011, Popovics, et al., 2013). また, 生産実績データからディスパッチングルールを同定する方法や, Queue モデル内のパラメータを同定する手法も提案されている (永原, 2021, Nagahara, et al., 2020). 一方で, Queue モデルを前提とするのではなく, プロセスやシステムの入出力関係を直接同定する機械学習ベースの手法も提案されている. 例えば Lingitz らは, ANN (Artificial Neural Network) 等を用いて生産リードタイムを予測する手法を提案している (Lingitz, et al., 2018). また, PSS ではなく Discrete Event Simulation や Agent-based Simulation の分野ではデータ同化技術を応用した研究も報告されている (Xie et al., 2016, Hu et al., 2019). 上記の研究は, (2)データ準備や(4)モデル検証の労力低減に貢献するものである.

上述のように, PSS やその周辺のシミュレーションにおいては, 既存研究で様々なモデリング手法が提案されている. これらのモデリング手法により, 各工程やシステム全体といった様々なスケールのモデルを構築するこ

とができる。一方、特定のシステムを対象とする際には、どのようなモデル構造が適しているかは明らかではなく、モデル構造の最適化には依然として課題がある。これに対し筆者らは、高精度なモデル構造を自動導出するデータ駆動型マルチスケールモデリングを提案している（永原ら, 2023）。提案方式は、Activity, Process, Systemといった複数のスケールにおいて、演繹的な手法や機械学習などの帰納的な手法で構築した複数のモデルを組み合わせることで様々なモデル構造を自動生成し、最も精度の高いモデル構造を導出する。既報では、仮想的な単工程システムを対象に、Queue モデルベースと ANN ベースのモデルの比較を行い、モデル構造・モデリング手法の優劣が、実システムやモデルの複雑さに依存することを示した（永原ら, 2023）。本報では、これを複数工程システムに拡張する方法を提案するとともに、複数工程システムにおけるモデル構造・モデリング手法の比較実験結果を示す。なお、本報では、既報と同様に、納期回答等のユースケースを前提として、各ジョブの投入日時から生産完了日時を予測することをシミュレーションの目的とする。そのため、以降、各ジョブの投入から生産完了までの生産リードタイムをシミュレーションの予測指標とする。

3. データ駆動型マルチスケールモデリングの複数工程システムへの拡張

本章では、既報で提案した、モデリング手法の分類、データ駆動型マルチスケールモデリング、単工程システムに対するモデリング方法について本報の説明に必要な情報に限定して述べた上で、複数工程システムに対するモデリング方法を提案する。

3・1 モデリング手法の分類

提案方式であるデータ駆動型マルチスケールモデリングは、複数のモデリング手法を組合せる方法である。そのため本研究では、Activity/Process/System からなるモデルのスケールと、White/Black/Gray からなるモデルのタイプでモデリング手法を分類する。詳細は既報を参照されたい（永原ら, 2023）。Activity は生産工程における処理時間やディスパッチングルールなど、モデル構造を検討する際の最小単位要素を表すスケールである。また、System は生産システム全体を表すスケールである。上記に対して、Process は1つの工程を表すスケールである。一般的なシミュレーションモデルは、複数のアクティビティで1つの工程を表現し、複数の工程を繋ぎ合わせてシステム全体を表現することが多く、また、生産システムの実績データも工程単位で取得されていることが多い。本研究では上記の点を踏まえて、Activity/Process/System のスケールでモデリング手法を分類する。また、前章で述べたように、モデリング手法に関する既存研究においては、旧来的な Queue モデルを用いた演繹的な方法に加え、実績データと機械学習を用いた Black-box モデリング手法や、演繹的な方法で構築したモデルのパラメータをデータから同定する手法（データ同化など）が登場しており、本研究ではこれらを踏まえて、White/Black/Gray のタイプでモデリング手法を分類する。

アクティビティスケールのモデルは、ディスパッチングルールなどのアクティビティの振る舞いを表現したモデルであり、アクティビティ White Box Model (WBM) とアクティビティ BBM (BBM) の2種類に分類する。プロセススケールのモデルは、単工程を対象としたモデルであり、プロセス WBM/BBM/GBM (Gray Box Model) の3種類に分類する。プロセス BBM は、プロセスの入出力関係を実績データから帰納的に同定した機械学習ベースのモデルである。プロセス GBM は、一部または全てのアクティビティをアクティビティ BBM によって表現した Queue モデルである。システムスケールのモデルは複数工程システムを対象としたモデルであり、システム WBM/BBM/GBM として分類している。また、システム GBM として、システム GBM-1/GBM-2 の2種類のモデルを定義する。システム GBM-1 は、一部または全ての工程がプロセス GBM またはプロセス BBM によって表現されたモデルである。システム GBM-2 は、システム内の複数工程を含むサブシステムを、システム BBM によって表現したモデルである。

なお、既報では、単工程システムを対象に、プロセス BBM とプロセス GBM の比較を示した。本報では、複数工程システムを対象に、システム BBM とシステム GBM を比較する。

Table 2 Classification of modeling methods.

Modeling method	Model scale	Model type	Definition
Activity WBM	Activity	White-Box	Describe the behavior of activity explicitly and deductively based on background knowledge.
Activity BBM		Black-Box	Build a ML model that inductively express the input-output relationship of the activity from activity log.
Process WBM	Process	White-Box	Build a Queue model in which all activities are expressed by Activity WBM and the connections between activities is also explicitly and deductively described.
Process BBM		Black-Box	Build a ML model that directly predict the process output from input.
Process GBM		Gray-Box	Build a Queue model in which some/all activities are expressed by Activity BBM and the connections between activities is also explicitly and deductively described.
System WBM	System	White-Box	Build a model in which all processes are expressed by Process WBM.
System BBM		Black-Box	Build a ML model that directly predict the system output from input.
System GBM-1		Gray-Box	Build a model in which some/all processes are expressed by Process GBM/BBM.
System GBM-2			Build a model that any sub-system, which is composed with some processes, is expressed by System BBM.

3・2 データ駆動型マルチスケールモデリング

図1にデータ駆動型マルチスケールモデリングの概略図を示す。ここで、マルチスケールとは Activity, Process, System といった異なるスケールのモデルを組合せることをさしている。図1の W/G/B は WBM, GBM, BBM を表す。図1のモデル(a), (b), (c)に示すように、提案方式では、複数のモデル構造を、対象システム内のプロセスやアクティビティを統合・分割することで生成する(図1(1))。モデル(a), (b), (c)は、それぞれシステム WBM, システム GBM, システム BBM の一例である。モデル(a)においては、各アクティビティや各工程の結合関係は、MES 等のデータやモデリング担当者の背景知識に基づき定義される。一方、モデル(b)や(c)は GBM/BBM を含んでおり、これらのモデルは生産実績データに基づき同定される。具体的には、シミュレーションの入出力要件に基づき、入力変化に対する出力変化の予測精度を最大にするように各モデルのパラメータを同定する(図1(2))。そして、生成されたモデル群の中から最も精度の高いモデルを選択する(図1(3))。




Fig. 1 Schematic view of the proposed modeling approach.

3・3 単工程システムに対するモデリング方法

本節では、既報で提案した、単工程システムを対象としたプロセス GBM とプロセス BBM の構築方法の概要を述べる。既報では、プロセス GBM の構築方法として、連続最適化手法である Particle Swarm Optimization (PSO) を用いる方法を提案した。本方法では、プロセス GBM 内の各アクティビティの振る舞いを定義するパラメータベクトル $\mathbf{X}$ を、リードタイム予測誤差が最小となるように PSO により探索する。PSO における目的関数 J^{GBM} を以下に示す。

$$J^{GBM} = \|\mathbf{lt}^{ref} - \mathbf{lt}^{GBM}\| \quad (1)$$

ここで、 lt^{ref} と lt^{GBM} はそれぞれ、実績およびプロセス GBM における各ジョブのリードタイムのベクトルである。つまり lt^{GBM} は、パラメータベクトル X を反映したプロセス GBM における予測リードタイムに相当する。本研究では、PSO における探索効率向上を狙った手法である R-best モデルを用いる (Choi et al., 2011)。

プロセス BBM に対しては、 N 入力 1 出力の ANN を用いる。ANN の入力はあるジョブに関する特徴量ベクトルであり、出力は当該ジョブのリードタイムの予測値である。ANN における損失関数 J^{BBM} を以下に示す。

$$J^{BBM} = \|lt^{ref} - lt^{BBM}\| \quad (2)$$

ここで lt^{BBM} は、プロセス BBM による予測リードタイムのベクトルである。多品種少量生産のような生産システムにおいては、あるジョブのリードタイムは、そのジョブの品種や投入日時だけでなく、そのジョブの前後に投入されるジョブ群の影響も受けるため、ANN の入力ベクトルにはこれらの情報を含むように設計することが重要である。そこで本研究では、ジョブ i の特徴量として式(3), (4), (5)で定義される x, y を用いる。

$$x_i = \begin{cases} 1 & \text{if } pt_i = p \\ 0 & \text{otherwise} \end{cases} \quad (p = 1, \dots, M) \quad (3)$$

$$y_{d,p} = \sum_{j=1}^N \delta_{j,d,p} \quad (d = -D, \dots, D-1, \quad p = 1, \dots, M) \quad (4)$$

$$\text{where } \delta_{j,d,p} = \begin{cases} 1 & \text{if } j \neq i \text{ and } t_j^{in} + d \cdot \Delta D \leq t_i^{in} < t_j^{in} + (d+1) \cdot \Delta D \text{ and } pt_j = p \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

ここで、 M および N はそれぞれ、品種数とジョブ数を表す。 pt_i はジョブ i の品種番号である。つまり x は、ジョブ i の品種の one-hot ベクトル表現である。また、 t_i^{in} はジョブ i の投入日時であり、 ΔD は時間を表す定数である。 $y_{d,p}$ はジョブ i の到着日時と、定数 D および ΔD によって決定される期間における品種 p の投入ジョブ数である。つまり y は、ジョブ i の前後期間における投入計画の特徴量を表現したベクトルである。

3・4 複数工程システムに対するモデリング方法

本節では、前節で述べた方法を複数工程システムに拡張する方法について述べる。複数工程システムを対象とする場合、取り得るモデリング手法は、対象システムから取得可能な実績データに依存する。ここで、工程 1, 工程 2, 工程 3 からなるフローショップ型のシステムを考える。この場合、シミュレーションの予測指標は、各ジョブにおける工程 1 投入から工程 3 処理完了までのリードタイムである。

ここで、仮に本システムにおいて、各ジョブの工程 1 への投入日時と各工程の処理完了日時が既知（生産実績データとして取得可能）である場合を、図 2(a)に示す。この場合は、ある工程の処理完了日時を後工程の投入日時とみなすことで、図 2(a)に示す様に、各工程に対して前節のプロセス GBM/BBM 構築方法を適用することが可能である。図 2(a)は、工程 1 と工程 2 に対してプロセス GBM を、工程 3 に対してプロセス BBM を適用した場合のモデル構造である。このように各工程のモデルを構築した後、それらのモデルを結合することで、複数工程システム全体のモデルを得ることができる。この様に、各工程のモデルを個別に構築してから結合する方法を、以降では方法①と呼ぶ。本方法で得られたモデルは 3-1 節で述べたシステム GBM-1 に相当する。

一方、仮に工程 1 と工程 2 の処理完了日時が未知な場合は、方法①のように各工程のモデルを個別に同定することはできず、工程 1 への投入日時から工程 3 の処理完了日時を直接予測するモデルが必要になる。この場合は、図 2(b-1)に示す様に、3 つの工程を 1 つの BBM で表現する方法が考えられる。この BBM は、プロセス BBM と同様の方法で構築可能である。つまり、工程 1 への投入日時から式(3), (4), (5)により特徴量 x, y を計算し、これらを入力として、工程 1 投入から工程 3 処理完了までのリードタイム lt^{BBM} を出力とする ANN モデルを構築することで、3 工程を纏めた BBM を得ることができる。これは、3-1 節で述べたシステム BBM に相当し、この様に、3 工程を纏めて 1 つの BBM を構築する方法を、以降では方法②と呼ぶ。また、同条件における別の方法として、図 2(b-2)に示す様に、3 工程全てをプロセス GBM で表現した上で、3 工程に含まれるパラメータを同時に同定する方法も考えられる。具体的には、PSO のパラメータベクトル X に 3 工程のパラメータ全てを含めた上で、工程 1 投入から工程 3 処理完了までの実績リードタイム lt^{ref} と予測リードタイムを lt^{GBM} の誤差を最初とするパラメータを PSO により探索することで、システム GBM-1 に相当するモデルを得ることができ

る。この様に、各工程をプロセス GBM で表現した上で、全工程のパラメータを同時に同定する方法を、以降では方法③と呼ぶ。

また、仮に工程 1 の処理完了日時は既知であり、工程 2 の処理完了日時は未知である場合は、図 2(c-1)(c-2)に示す方法が考えられる。図 2(c-1)には、工程 1 をプロセス GBM/BBM としてモデル化し、工程 2 と 3 からなるサブシステムを 1 つの BBM として表現することで、システム GBM-2 に相当するモデルを得る方法を示している。この様に、工程 2 と 3 を纏めて 1 つの BBM で表現する方法を、以降では方法④と呼ぶ。一方、図 2(c-2)に示す方法は、方法③と同様に、工程 2 と 3 をプロセス GBM で表現した上で、2 工程に含まれるパラメータを PSO で同時に同定することで、システム GBM-1 に相当するモデルを得る方法である。この様に、工程 2 と 3 をそれぞれプロセス GBM で表現した上で、両工程のパラメータを同時に同定する方法を、以降では方法⑤と呼ぶ。

このように、対象システムが複数工程になった場合においても、単工程システムに対するモデリング方法を拡張して適用することが可能である。なお、図 2(a)のケースにおいては、各工程をプロセス GBM/BBM で表現して個別に同定する方法(方法①)に限らず、一部の工程群を纏めて BBM で表現する方法や複数工程のパラメータを同時に同定する方法(方法②③④⑤)も適用可能である。このように、あるシステムを対象としたときに取り得るモデル構造やモデルの同定方法は、対象システムから得られる情報に依存する。提案方式では、これらを考慮して複数のモデル構造を生成し、各モデル構造においてモデル内のパラメータを同定した上で、精度が最も高いモデル構造を採用するものである。ここで、モデリングにおける前提条件は、対象システムの工程の構成や、対象システムに対する背景知識の有無などがあるが、どのような条件においてどのようなモデル構造・モデル同定方法が優位であるか(精度が高くなるか)は定かでない。そのようなモデリング方法の優劣や特性を知るとは、特に複雑・大規模なシステムを対象とする際に、高精度が期待できるモデル構造を生成するために有用と考えられる。既報では単一工程を対象にモデリング方法の優劣比較を示したが、複数工程では、どのような実績データが取得可能かという点も優劣に影響すると考えられる。上記を踏まえ、本報では次章より、複数工程を対象としたモデリング方法の比較を示す。




Fig. 2 Examples of model configuration and calibration methods for different conditions of available information.

4. 計算機実験と考察

4・1 実験条件

本章では、仮想的な生産システムを対象として、前章で述べた方法によって構築したモデルの比較結果を示す。本実験では、対象システムを構成する工程として、図3に示す2種類の工程タイプA, Bを想定する。




Fig. 3 Experimental conditions: Process type A and B.

工程タイプA, Bはともに複数並列設備を有する工程であるが、工程タイプAはディスパッチ・加工のアクティビティを、工程タイプBは加えて搬送・段取替えのアクティビティを有する。各ジョブは段取替え・加工している間、設備を占有する。本工程は機械加工工程を想定したものであり、搬送時間 l_p と加工時間 d_p は品種 p ごとに異なるものとする。また、段取替えは設備における治具交換を想定し、段取替え時間 $s_{p,q}$ は、設備で処理する前品種 p と後品種 q の組合せごとに異なるものとする。これらの時間は乱数により与える。また、ディスパッチングルールは先入先出(FIFO)とし、設備割当ルールは、空き設備が1つの場合はその設備に割り当て、空き設備が複数ある場合は段取替え時間が最小となる設備を選択して割り当ててものとする。

本実験では、各工程が工程タイプA, Bのいずれかである様な、フローショップ型の3工程からなる多工程システムを対象とする。工程間では1ジョブずつ搬送されるものとする。また、一般に機械加工のフローショップシステムでは工程間の負荷をバランスさせるように工程設計や設備数が与えられることを踏まえ、各工程における負荷が凡そ同程度になるように、加工時間と段取替え時間を設定する。本実験では、3つの工程それぞれが工程タイプA, Bのいずれかである8パターンのシステムを対象とする。以降、例えば工程1, 2, 3の工程タイプがそれぞれA, B, AのシステムをSys-ABAと表記する。つまり本実験では、Sys-AAA, Sys-AAB, Sys-ABA, Sys-ABB, Sys-BAA, Sys-BAB, Sys-BBA, Sys-BBBの8パターンのシステムを対象とする。なお、異なるシステム間においても、工程番号と工程タイプが同じであれば各工程の時間情報($l_p, s_{p,q}, d_p$)は、同じ値としている。つまり、予め定義した工程1-A, 工程1-B, 工程2-A, 工程2-B, 工程3-A, 工程3-Bの6種類の工程を組合せることでフローショップシステムを構成する。本実験では、これら8パターンのシステムをWBMで表現したシミュレーションモデルを実システムと仮定し、本WBMによるシミュレーション結果を実システムの生産実績と仮定する。また、品種数を5, 投入ジョブ数を50, 各工程の設備数を3とし、各ジョブの投入日時や品目を乱数で与えた投入シナリオを、モデル構築用・精度評価用にそれぞれ1,000シナリオ生成して用いる。また、シミュレーション開始時点において、初期仕掛として各工程にそれぞれ3つのジョブが存在するものとする。

次に、比較対象のモデルについて説明する。本実験では、各工程を表現するプロセスGBMとして、GBM-A, GBM-Bの2種類のモデルを用いる。GBM-Aは、工程タイプAと同じアクティビティ構成を持つQueueモデルであり、モデル内の未知パラメータ(PSOで同定すべきパラメータ)は加工時間 d_p である。GBM-Bは、工程タイプBと同じアクティビティ構成を持つQueueモデルであり、未知パラメータは搬送時間 l_p , 加工時間 d_p , 段取替え時間 $s_{p,q}$ である。上記2種類のGBMとANNベースのBBMを用いて、方法①～⑤により構築したシステムGBM/BBMを比較対象のモデルとする。なお、PSOにおける粒子数は未知パラメータ数の10倍とし、探索の終了条件は、300世代連続で暫定解が更新されないこととする。

最後に、モデルのリードタイム予測精度の評価指標について説明する。本実験では決定係数 R^2 を精度評価指標とする。具体的には、実システムと仮定した WBM におけるシナリオ s のジョブ i のリードタイムを $lt_{s,i}^{System}$ 、システム GBM/BBM におけるシナリオ s のジョブ i のリードタイムを $lt_{s,i}^{Model}$ とし、以下の式(6)(7)により決定係数 R^2 を算出する。

$$R^2 = 1 - \frac{\sum_{s \in S} \sum_{i \in N_s} (lt_{n,i}^{System} - lt_{n,i}^{Model})^2}{\sum_{s \in S} \sum_{i \in N_s} (lt_{n,i}^{System} - \bar{lt}^{System})^2} \quad (6)$$

$$\text{where } \bar{lt}^{System} = \frac{\sum_{s \in S} \sum_{i \in N_s} lt_{n,i}^{System}}{\sum_{s \in S} |N_s|} \quad (7)$$

ここで、 S は評価用シナリオの集合、 N_s はシナリオ s におけるジョブの集合である。本実験では、上記の R^2 により、ジョブの投入日時や品種の異なるシナリオ群全体に対する精度を評価する。

4・2 実験結果と考察

複数工程システムの実験結果を述べる前に、工程毎に構築したプロセス GBM 及びプロセス BBM の予測精度について示す。結果を表 3 に示す。表中の各行に、あるシステムのある工程に対する GBM-A、GBM-B、BBM の R^2 値を示している。当該工程に対して最も高い精度を得たモデルの R^2 値を赤字で示しており、当該工程が工程タイプ A の場合を青色セル、工程タイプ B の場合を橙色セルで示している。表 3 より、GBM-A は、工程タイプ A（青色）に対しては常に高い精度を示しているが、工程タイプ B（橙色）に対しては精度が低い。これは GBM-A は、工程タイプ A とはアクティビティ構成が一致している一方で、工程タイプ B に対しては一部のアクティビティ（搬送・段取替えアクティビティ）が不足していることが原因と考えられる。一方、GBM-B は、工程タイプ A を表現するに足るアクティビティを有しているにもかかわらず、Sys-AAA と Sys-AAB の工程 2 を除き精度が低くなっている。また GBM-B は、同じアクティビティ構成を有する工程タイプ B に対しても多くのケースで BBM に劣っている。これは、段取替え等を含む GBM-B の複雑性と未知パラメータの多さにより、PSO による探索が局所解に陥ったことが原因と考えられる。3 つのモデルの優劣関係は、対象システムの各種条件によっても変化することが想定されるが、今回の条件においては、工程タイプ A に対しては GBM-A、工程タイプ B に対しては BBM が相対的に優位である。

Table 3 Experimental result: R^2 value of process scale models.

System	Process No.	Process type	Process model		
			GBM-A	GBM-B	BBM
Sys-AAA	1	A	1.00	0.82	0.94
	2	A	1.00	1.00	0.96
	3	A	1.00	0.69	0.94
Sys-AAB	1	A	1.00	0.82	0.94
	2	A	1.00	1.00	0.96
	3	B	0.48	0.65	0.76
Sys-ABA	1	A	1.00	0.82	0.94
	2	B	0.28	0.48	0.68
	3	A	1.00	0.73	0.95
Sys-ABB	1	A	1.00	0.82	0.94
	2	B	0.28	0.48	0.68
	3	B	0.28	0.70	0.72

System	Process No.	Process type	Process model		
			GBM-A	GBM-B	BBM
Sys-BAA	1	B	0.56	0.61	0.77
	2	A	1.00	0.86	0.95
	3	A	1.00	0.80	0.95
Sys-BAB	1	B	0.56	0.61	0.77
	2	A	1.00	0.86	0.95
	3	B	0.37	0.67	0.76
Sys-BBA	1	B	0.56	0.61	0.77
	2	B	0.11	0.61	0.67
	3	A	1.00	0.59	0.96
Sys-BBB	1	B	0.56	0.61	0.77
	2	B	0.11	0.61	0.67
	3	B	0.34	0.79	0.76

次に、複数工程システムに対する精度評価結果について述べる。ここでは、3.4 節で述べたように、取り得るモデル構造やモデル同定方法が対象システムから取得可能な情報によって異なることを踏まえ、以下に示す 3 つのケースについてそれぞれ結果を示す。

Case 1 : 全ての工程の処理完了日時が取得可能な場合

Case 2 : 工程 3 の処理完了日時のみが取得可能な場合

Case 3 : 工程 1 と工程 3 の処理完了日時が取得可能な場合

Case 1 : 全ての工程の処理完了日時が取得可能な場合

Case 1 の結果を表 4 に示す。表中の 1 行が 1 つのモデル構造に該当し、表中の右方向に、各システムに対する当該モデルの R^2 値を示している。全ての工程の処理完了日時が既知である Case 1 においては、図 2 に示した全てのモデル構造を取り得るため、No. 1~31 の 32 種類のモデル構造に対する結果を示している。No. 1~27 は、方法①により各工程のプロセス GBM/BBM を結合した際の結果である。表中の赤字は、あるシステムに対して、最も高い精度を得たモデルを示している。また、青色セルは、全ての工程において、実システムとモデルでアクティビティ構成が一致している場合を示している。また、橙色セルは、実システムにおけるタイプ A の工程には GBM-A、タイプ B の工程には BBM を用いた場合を示している。まず、全ての工程がタイプ A である Sys-AAA に対しては、全ての工程を GBM-A としたモデル (No. 1) が最も精度が高い。また、タイプ B の工程が含まれている Sys-AAA 以外のシステムにおいては、橙色セルで示したモデルが高い精度を示している。これらの結果から、各工程に対して高精度なプロセスモデルを繋ぎ合わせることで、高精度なシステムモデルを得られる傾向にあることがわかる。一方で、Sys-ABA, Sys-BAA, Sys-BAB, Sys-BBA においては、僅かな差ながら、橙色セル以外のモデル (タイプ A の工程にも BBM を用いたモデル) が最も精度が高い。これは、表 3 に示す様に、BBM は、GBM-A には劣るもののタイプ A の工程に対して高精度であることに起因していると考えられる。また、3.3 節で述べた方法②④により、全て若しくは一部の工程群を 1 つのサブシステムとして BBM で表現した場合の結果を No. 28~31 に示す。No. 28~30 が工程 2 と工程 3 を 1 つの BBM で表現した場合、No. 31 が全工程を 1 つの BBM で表現した場合である。No. 28~31 のモデルの精度は、いずれのシステムにおいても、No. 1~27 の中の最良モデルに劣る結果となっている。本結果より、各工程の処理完了日時が取得可能なシステムにおいては、複数工程を纏めて 1 つの BBM で表現するのではなく、各工程のモデルを個別に同定して結合する方が良い傾向にあることがわかる。

Table 4 Experimental result: R^2 value of system scale models (Case 1).

Model No.	Model configuration			Target system							
	Process 1	Process 2	Process 3	Sys-AAA	Sys-AAB	Sys-ABA	Sys-ABB	Sys-BAA	Sys-BAB	Sys-BBA	Sys-BBB
1	GBM-A	GBM-A	GBM-A	1.00	0.89	0.81	0.63	0.73	0.61	0.60	0.41
2			GBM-B	0.92	0.92	0.81	0.77	0.71	0.66	0.62	0.54
3			BBM	0.98	0.95	0.83	0.79	0.74	0.68	0.62	0.58
4		GBM-B	GBM-A	1.00	0.89	0.87	0.78	0.71	0.59	0.71	0.60
5			GBM-B	0.92	0.93	0.83	0.81	0.69	0.63	0.69	0.65
6			BBM	0.98	0.95	0.88	0.84	0.71	0.64	0.72	0.68
7		BBM	GBM-A	0.97	0.87	0.91	0.81	0.74	0.62	0.74	0.65
8			GBM-B	0.90	0.89	0.87	0.85	0.72	0.67	0.72	0.69
9			BBM	0.96	0.93	0.92	0.88	0.75	0.69	0.75	0.71
10	GBM-B	GBM-A	GBM-A	0.85	0.80	0.81	0.66	0.74	0.65	0.63	0.48
11			GBM-B	0.78	0.78	0.78	0.75	0.71	0.68	0.64	0.59
12			BBM	0.85	0.82	0.82	0.77	0.75	0.70	0.66	0.62
13		GBM-B	GBM-A	0.85	0.80	0.80	0.73	0.71	0.63	0.71	0.62
14			GBM-B	0.78	0.78	0.75	0.71	0.68	0.65	0.66	0.66
15			BBM	0.85	0.82	0.80	0.75	0.71	0.67	0.72	0.67
16		BBM	GBM-A	0.86	0.81	0.84	0.77	0.75	0.67	0.75	0.67
17			GBM-B	0.79	0.79	0.78	0.75	0.72	0.69	0.69	0.69
18			BBM	0.86	0.83	0.84	0.80	0.76	0.71	0.75	0.71
19	BBM	GBM-A	GBM-A	0.92	0.83	0.80	0.61	0.82	0.72	0.71	0.55
20			GBM-B	0.86	0.84	0.80	0.75	0.79	0.77	0.71	0.67
21			BBM	0.92	0.88	0.82	0.77	0.82	0.78	0.72	0.69
22		GBM-B	GBM-A	0.92	0.83	0.84	0.74	0.79	0.69	0.79	0.70
23			GBM-B	0.86	0.84	0.81	0.77	0.76	0.74	0.74	0.74
24			BBM	0.92	0.88	0.85	0.79	0.75	0.75	0.80	0.76
25		BBM	GBM-A	0.92	0.83	0.88	0.78	0.83	0.72	0.82	0.73
26			GBM-B	0.87	0.83	0.83	0.81	0.80	0.76	0.77	0.77
27			BBM	0.92	0.88	0.89	0.84	0.83	0.79	0.82	0.79
28	GBM-A	BBM		0.95	0.90	0.91	0.86	0.75	0.69	0.74	0.70
29	GBM-B			0.84	0.80	0.83	0.77	0.75	0.71	0.75	0.71
30	BBM			0.84	0.80	0.83	0.76	0.76	0.73	0.76	0.72
31	BBM			0.89	0.84	0.86	0.81	0.81	0.75	0.80	0.73

Case 2 : 工程 3 の処理完了日時のみが取得可能な場合

Case 2 における結果を表 5 に示す。表 5 には、Case 2 において取り得る 9 つのモデル構造 (No. 1~9) の結果を示している。ただし、No. 1~8 においては、全工程の GBM 内のパラメータを同時に同定する方法 (方法③) を用いている点に注意されたい。表 5 より、多くのシステムにおいて、No. 9 が最も高い精度を示している。本

結果は、No. 1～8 においては、全工程の GBM 内のパラメータを同時に同定するため、PSO における解空間が大きくなり探索が難化することで精度が低下したためと考えられる。本結果から、仮に対象システムの各工程のアクティビティ構成が既知であっても、必ずしも GBM が良いわけではなく、GBM のパラメータ同定が困難なケースでは複数工程を纏めて BBM で表現した方が良いことを示している。

Table 5 Experimental result: R^2 value of system scale models (Case 2).

ModelNo.	Model configuration			Target system							
	Process 1	Process 2	Process 3	Sys-AAA	Sys-AAB	Sys-ABA	Sys-ABB	Sys-BAA	Sys-BAB	Sys-BBA	Sys-BBB
1	GBM-A	GBM-A	GBM-A	0.87	0.89	0.82	0.73	0.72	0.61	0.63	0.55
2			GBM-B	0.61	0.68	0.80	0.42	0.46	0.27	0.43	0.33
3		GBM-B	GBM-A	0.65	0.54	0.62	0.43	0.57	0.41	0.41	0.34
4			GBM-B	0.68	0.68	0.69	0.68	0.59	0.59	0.67	0.55
5	GBM-B	GBM-A	GBM-A	0.69	0.66	0.74	0.69	0.64	0.46	0.63	0.63
6			GBM-B	0.64	0.67	0.73	0.63	0.65	0.63	0.64	0.66
7		GBM-B	GBM-A	0.67	0.66	0.62	0.67	0.63	0.65	0.72	0.62
8			GBM-B	0.62	0.60	0.65	0.63	0.58	0.62	0.73	0.67
9	BBM			0.89	0.84	0.86	0.81	0.81	0.75	0.80	0.73

Case 3 : 工程 1 と工程 3 の処理完了日時が取得可能な場合

Case 3 における結果を表 6 に示す。表 6 には、Case 3 において取り得る 16 のモデル構造 (No. 1～16) の結果を示している。ただし、No. 1～12 においては、工程 2 と工程 3 の GBM 内のパラメータを同時に同定する方法 (方法⑤) を用いている点に注意されたい。まず、Sys-AAA に対しては No. 1、Sys-BAA に対して No. 9 が最良となっている。これは、工程 2 と工程 3 のモデルが、ともに未知パラメータの少ない GBM-A であり、かつ、対象システムの工程とアクティビティ構成が一致しているため、PSO によるパラメータ同定が最適解に到達しやすい条件であることが理由と考えられる。また、Sys-AAB、Sys-ABA、Sys-ABB に対しては No. 13 が最良となっている。これは、工程 2 若しくは工程 3 がタイプ B になることで、PSO によるパラメータ同定が難化し、工程 2 と工程 3 を一つの BBM で表現した方が良い結果を得たものと考えられる。本結果は、Case 2 で得られた結果と同様の傾向を示している。一方で、Sys-BAB、Sys-BBA、Sys-BBB に対しては No. 16 が最良となっている。タイプ B の工程に対しては BBM が優位であることと、Case 1 で述べた考察を踏まえると、これらの 3 システムに対しては、工程 1 と工程 2 & 3 をそれぞれ BBM で表現して結合した No. 15 が最良になることが想定されるが、本結果はその想定に反するものである。加えて、Sys-BAA に対しても、No. 16 は No. 15 より精度が高い。本結果は、たとえ途中工程の処理完了日時が取得可能なシステムであっても、全工程を一つの BBM で表現した方が良いことを示しており、取得可能なデータに基づいてモデルを分割・結合することが、必ずしも最良ではないことを意味している。

Table 6 Experimental result: R^2 value of system scale models (Case 3).

ModelNo.	Model configuration			Target system							
	Process 1	Process 2	Process 3	Sys-AAA	Sys-AAB	Sys-ABA	Sys-ABB	Sys-BAA	Sys-BAB	Sys-BBA	Sys-BBB
1	GBM-A	GBM-A	GBM-A	1.00	0.90	0.85	0.70	0.73	0.62	0.65	0.54
2			GBM-B	0.79	0.75	0.78	0.69	0.65	0.57	0.68	0.51
3		GBM-B	GBM-A	0.76	0.81	0.81	0.67	0.66	0.55	0.66	0.56
4			GBM-B	0.70	0.76	0.81	0.80	0.64	0.59	0.68	0.64
5	GBM-B	GBM-A	GBM-A	0.85	0.80	0.82	0.69	0.74	0.65	0.70	0.59
6			GBM-B	0.71	0.70	0.76	0.66	0.67	0.60	0.70	0.54
7		GBM-B	GBM-A	0.65	0.72	0.76	0.63	0.62	0.54	0.69	0.58
8			GBM-B	0.58	0.62	0.73	0.72	0.61	0.61	0.66	0.63
9	BBM	GBM-A	GBM-A	0.92	0.84	0.82	0.68	0.82	0.73	0.75	0.64
10			GBM-B	0.75	0.73	0.77	0.63	0.72	0.68	0.75	0.59
11		GBM-B	GBM-A	0.74	0.76	0.78	0.62	0.68	0.62	0.75	0.66
12			GBM-B	0.67	0.72	0.79	0.76	0.68	0.69	0.74	0.72
13	GBM-A	BBM		0.95	0.90	0.91	0.86	0.75	0.69	0.74	0.70
14	GBM-B			0.84	0.80	0.83	0.77	0.75	0.71	0.75	0.71
15	BBM			0.84	0.80	0.83	0.76	0.76	0.73	0.76	0.72
16	BBM			0.89	0.84	0.86	0.81	0.81	0.75	0.80	0.73

最後に、Case 1, 2, 3 の結果を踏まえた考察を述べる。3.4 節で述べたように、全工程の処理完了日時が取得可能な場合は、方法①～⑤の全てのモデル構造・モデル同定方法をとることができる。つまり、Case 1 においては Case 2, 3 で示したモデルも構築可能である。しかし、Case 2, 3 で示したモデルは、いずれも Case 1 における最良モデルに劣っていることから、基本的には、対象システムを工程別に分割した上で、各工程のプロセスモデルを個別に同定して結合する方法が良い傾向にあることがわかる。一方で、一部の工程の処理完了日時が取得不可の場合には、複数工程からなるサブシステムを同定する必要がある。この際、サブシステム内の各工程をプロセス GBM で表現したモデル構造では、サブシステムに含まれる工程が増えるほど未知パラメータ数が増加しパラメータ同定が難化する。その結果、仮に実システムと同じアクティビティ構成を持つモデルであっても、サブシステムを 1 つの BBM で表現したモデル構造に劣る場合がある。これは、対象システムから取得可能なデータの粒度によって最適なモデル構造が変わることを示している。また、Case 3 では全工程を 1 つに纏めたシステム BBM が最良となる結果が得られた。これらの結果は、対象システムから得られるデータに基づき、取り得るモデル構造を様々生成して同定・評価・採用する提案方式の有用性を示している。

5. 結 言

本研究では、生産システムシミュレーションの高精度・モデリング自動化を目的として、データ駆動型マルチスケールモデリング方式を開発している。本方式では、Activity, Process, System のモデルスケールと White, Black, Gray のモデルタイプの観点で分類した複数のモデリング手法を組み合わせることで、モデル構造を最適化する。本報では、既報で報告した単工程システムに対するモデリング手法を複数工程システムに拡張する方法を示すとともに、仮想的なフローショップシステムを対象としたモデル構造・同定方法の比較実験を通して、提案方式の必要性・有用性を示した。今後の課題としては、ジョブショップシステムなどのより複雑なシステムや、現実のシステムを対象とした検討が挙げられる。また、加工時間のばらつきなどの不確実性を有するシステムに対する評価やモデル同定方法の改良も課題である。

文献

- Barlas, P. and Heavey C., Automation of input data to discrete event simulation for manufacturing: A review, *International Journal of Modeling. Simulation and Scientific Computing*, Vol. 7 (2016), No.1630001.
- Choi, H., Ohmori, S. and Yoshimoto, K., Improvement of particle swarm optimization: Proposal of R-best model and parameter adjustment with consideration to searching phase and state. 21st International Conference on Production Research (2011), pp. 2079-2083.
- Gola, A., Pastuszak, Z., Relich, M., Sobaszek, L. and Szwark, E., Scalability analysis of selected structures of a reconfigurable manufacturing system taking into account a reduction in machine tools reliability. *Eksplotacja i Niezawodność – Maintenance and Reliability*, Vol. 23, Issue 2 (2021), pp.242-252.
- 日比野浩典, 生産システムのシミュレーション技術の最新動向, 計測と制御, 第 52 巻, 第 1 号 (2013), pp. 29-34.
- Hu, X. and Wu, P., A data assimilation framework for discrete event simulations. *ACM Transactions on Modeling and Computer Simulation*, Vol. 29, No. 3 (2019), Article 17.
- Karnok, D. and Monostori, L., Determination of routings and process time information from event logs. Preprints of the 18th IFAC World Congress (2011), pp.14055-14060.
- Kirchhof, P., Automatically generation flow shop simulation models from SAP data. *Proceedings of the 2016 Winter Simulation Conference* (2016), pp.3588-3589.
- Lingitz, L., Gallina, V., Ansari, F., Gyulai, D., Pfeiffer A., Sihn, W. and Monostori, L., Lead time prediction using machine learning algorithms: A case study by a semiconductor manufacturer. *Procedia CIRP* 72 (2018), pp.1051-1056.
- Monostori, L., Cyber-physical production systems: Roots, expectations and R&D challenges, *Procedia CIRP*, Vol.17 (2014), pp.9-13.
- 永原聡士, 機械学習を用いた生産現場における着工順序ルールのモデリング, 日本機械学会論文集, Vol. 87, No. 897 (2021), pp. 1-11.
- 永原聡士, 貝原俊也, 藤井信忠, 國領大介, 生産システムシミュレーションにおけるデータ駆動型マルチスケールモデリングアプローチの提案 (単工程システムを対象としたモデル同定に関する基礎検討), 日本機械学会

論文集, Vol. 89, No.928 (2023), pp. 1-12.

- Nagahara, S., Serita, S., Shiho, Y., Zheng, S., Wang, H., Chida, T. and Gupta, C., Toward data-driven modeling of material flow simulation: automatic parameter calibration of multiple agents from sparse production log. 16th IEEE International Conference on Automation Science and Engineering (2020), pp.1096-1101.
- Popovics, G. and Monostori, L., ISA standard simulation model generation supported by data stored in low level controllers. *Procedia CIRP* 12 (2013), pp.432-437.
- Rosen, R., Wichert, G., Lo, G. and Betternhausen, K. D., About the importance of autonomy and digital twins for the future of manufacturing, *IFAC-PapersOnLine*, Vol.48, No.3 (2015), pp.567-572.
- Xie, X., Verbraeck, A. and Gu, F., Data assimilation in discrete event simulations - A rollback based sequential monte carlo approach, 2016 Symposium on Theory of Modeling and Simulation (2016), DOI: 10.23919/TMS.2016.7918817.

References

- Barlas, P. and Heavey C., Automation of input data to discrete event simulation for manufacturing: A review, *International Journal of Modeling. Simulation and Scientific Computing*, Vol. 7 (2016), No.1630001.
- Choi, H., Ohmori, S. and Yoshimoto, K., Improvement of particle swarm optimization: Proposal of R-best model and parameter adjustment with consideration to searching phase and state. 21st International Conference on Production Research (2011), pp. 2079-2083.
- Gola, A., Pastuszak, Z., Relich, M., Sobaszek, L. and Szwark, E., Scalability analysis of selected structures of a reconfigurable manufacturing system taking into account a reduction in machine tools reliability. *Eksplotacja i Niezawodność – Maintenance and Reliability*, Vol. 23, Issue 2 (2021), pp.242-252.
- Hibino, H., State-of-the-art of Simulation in Manufacturing System. *Journal of the Society of Instrument and Control Engineers*, Vol. 52, No. 1 (2013), pp. 29-34.
- Hu, X. and Wu, P., A data assimilation framework for discrete event simulations. *ACM Transactions on Modeling and Computer Simulation*, Vol. 29, No. 3 (2019), Article 17.
- Karnok, D. and Monostori, L., Determination of routings and process time information from event logs. Preprints of the 18th IFAC World Congress (2011), pp.14055-14060.
- Kirchhof, P., Automatically generation flow shop simulation models from SAP data. *Proceedings of the 2016 Winter Simulation Conference* (2016), pp.3588-3589.
- Lingitz, L., Gallina, V., Ansari, F., Gyulai, D., Pfeiffer A., Sihn, W. and Monostori, L., Lead time prediction using machine learning algorithms: A case study by a semiconductor manufacturer. *Procedia CIRP* 72 (2018), pp.1051-1056.
- Monostori, L., Cyber-physical production systems: Roots, expectations and R&D challenges, *Procedia CIRP*, Vol.17 (2014), pp.9-13.
- Nagahara, S., Modeling of job sequencing rule on shop-floor by machine learning techniques. *Transactions of the Japan Society of Mechanical Engineers (in Japanese)*, Vol. 87, No.897 (2021), pp.1-11.
- Nagahara, S., Kaihara, T., Fujii, N., Kokuryo, D., Data-driven and multi-scale modeling approach for production system simulation (Fundamental study on model identification for single process systems). *Transactions of the Japan Society of Mechanical Engineers (in Japanese)*, Vol. 89, No. 928 (2023), pp.1-12.
- Nagahara, S., Serita, S., Shiho, Y., Zheng, S., Wang, H., Chida, T. and Gupta, C., Toward data-driven modeling of material flow simulation: automatic parameter calibration of multiple agents from sparse production log. 16th IEEE International Conference on Automation Science and Engineering (2020), pp.1096-1101.
- Popovics, G. and Monostori, L., ISA standard simulation model generation supported by data stored in low level controllers. *Procedia CIRP* 12 (2013), pp.432-437.
- Rosen, R., Wichert, G., Lo, G. and Betternhausen, K. D., About the importance of autonomy and digital twins for the future of manufacturing, *IFAC-PapersOnLine*, Vol.48, No.3 (2015), pp.567-572.
- Xie, X., Verbraeck, A. and Gu, F., Data assimilation in discrete event simulations - A rollback based sequential monte carlo approach, 2016 Symposium on Theory of Modeling and Simulation (2016), DOI: 10.23919/TMS.2016.7918817.