

並列機械スケジューリングの最適化のための 機械学習を用いた作業時間推定

山城広周[†] 野中尋史[†]

[†]長岡技術科学大学

1 はじめに

製造業の現場において、数理最適化手法の適用が従来から行われてきた。その中でも生産スケジューリング問題は重要な問題の一つであり、盛んに研究が行われている。

Liら [1] の研究では、混合整数線形計画モデルを用いて金属 3D プリントとして知られているアディティブマニュファクチャリング (AM) 機械のスケジューリング手法を提案した。彼らの研究では、著者らが作成したデータセットを用いて評価を行っている。他にも、すでに作業時間が定義されたデータセットを用いている研究が多数存在する。しかし、実際の工場では作業時間が既知であるとは限らない。

この問題は、2つの方法で解決することができる。1つ目は、既知の処理時間を用いるのではなく、一様分布や正規分布などの単純な確率分布から処理時間をサンプリングする方法 [2][3] である。2つ目は、機械学習に基づいた予測方法である。

本研究では、機械学習モデルを用いて工程情報から作業時間を予測することを検討する。具体的には、製品の材料や製造数などの値を入力、作業時間を目的変数とする回帰モデルを構築する。機械学習モデルは実際の工場の様々な推定問題で利用されており [4][5]、本研究の作業時間推定にも有益であることが考えられる。

2 手法

提案システムでは、作業時間が未知な場合が多い現実の工場に適用可能な汎用性が利点である。本研究では初めに、機械学習に必要なデータを、作業現場から計測し、工程情報を入力として機械学習モデルを用い

て作業時間を推定する。最後に、推定した作業時間を用いてスケジューリングを行う。

2.1 機械学習

本研究では、LightGBM、ガウス過程、リッジ回帰、ニューラルネットワークの4つの機械学習モデルを用いて作業時間を推定した。また、スケジューリングを行う際に利用する推定作業時間は、もっとも MAPE 値の低いものを用いた。

2.2 機械スケジューリング

本研究で用いる工場データは、全てのジョブがすべての機械で処理でき、作業時間が機械に依存しない工程であるため、同一並列機械スケジューリング問題として取り扱う。また、評価の簡単化のために、目的関数が総作業時間(メイクスパン)の最小化である機械スケジューリング問題である作業機械の作業時間が同一な並列機械スケジューリング問題を解く。

最適化に用いる変数と、式の定義を記す。 J は最適化に用いるジョブを表し、 n 個存在するため、添え字 $j, j = 1, 2, \dots, n$ を用いて J_j と表記する。 M は最適化に用いる機械数を表し、 m 個存在し、添え字 $i, i = 1, 2, \dots, m$ を用いて M_i と表記する。 p_{ij} は機械 i におけるジョブ j の作業時間を表す。

$$\min \sum_{i=1}^m \sum_{j=1}^n p_{ij} x_{ij} \quad (1)$$

$$\text{s.t.} \quad \sum_{i=1}^m x_{ij} = 1 \quad \forall j = 1, 2, \dots, n \quad (2)$$

$$x_{ij} \in \{0, 1\} \quad \forall i = 1, 2, \dots, m \quad \forall j = 1, 2, \dots, n \quad (3)$$

式 1 は全ての作業が完了する時間を表し、式 2 は任意のジョブに関して、一つの機械のみに割り当てることを表す。

Combination of Machine Learning and Scheduling: Estimation of Processing Time Using Machine Learning and Real Factory Data for Optimization of Parallel Machine Scheduling Problem

Hirochika Yamashiro[†], and Hirofumi Nonaka[†]

[†]Nagaoka University of Technology

1603-1, Kamitomioka, Nagaoka, Niigata, 940-2188 Japan

s173358@stn.nagaokaut.ac.jp

3 実験

本研究では、提案手法を評価するため、研究協力企業より提供された製造サンプルごとにまとめられた作業時間が既知である工程情報を使用する。工程情報は、2018年7月から一年分のデータである。データの前処理を行い、項目数が10個、データ数は22537件となった。データ項目の要素数を表1にまとめる。これらの項目を入力として、作業時間を予測する機械学習モデルを構築し、推定した作業時間を用いて並列機械スケジューリング問題を解く。機械学習モデルの評価指標は平均絶対誤差率 (MAPE) を用いた。

表 1: 項目ごとの要素数

項目	変数の種類	カテゴリ数
Number of processes	自然数	-
Machine code	カテゴリ	18
Work completion flag	カテゴリ	2
Quality level	カテゴリ	5
Material A	カテゴリ	184
Parameter A	カテゴリ	63
Parameter B	カテゴリ	101
Parameter C	カテゴリ	21
Parameter D	カテゴリ	2
Parameter E	カテゴリ	38
Actual processing time	自然数	-

最適化の手順は、10日分の工程情報を抽出し、1日ごとのジョブ数と機械数、推定した作業時間を用いて最適化を行う。最適スケジュールの評価方法は、1日ごとのメイクスパンの短縮率を算出し、その平均値を用いる。

4 結果と考察

各機械学習モデルの平均の MAPE 値を表2に示す。平均の MAPE 値を比較すると、LightGBM の MAPE 値が最も低かった。機械学習モデルの平均の MAPE 値は、LightGBM が最良であったため、LightGBM の予測作業時間を、並列機械スケジューリングの最適化に用いた。最適スケジュールの makespan の平均短縮率は、29.5%であった。

本研究では、実データの作業時間の分布と、作業時間の平均と分散から作成した正規分布を用いて Kolmogorov-Smirnov(KS) 検定を行った。KS 検定の結果、 p 値が0となり帰無仮説が棄却された。これにより、本研究で用いたデータは正規分布に従わないため、実際

表 2: MAPE value for each model

Models	MAPE
LightGBM	22.5
Ridge Regression	22.6
Gaussian Process	22.9
Neural Network	43.8

の工場のデータが正規分布に従わないことが示された。正規分布に従わない理由として、同一の製品であったとしても、作業者などの違いによって作業時間に偏りが出るためである。

実験の結果から、機械学習の推定値を用いてスケジューリングをすることで現状のスケジュールよりも makespan を約 30%短縮することができた。その理由として、現状のスケジュールでは特定の機械に処理が集中しており、スケジューリング最適化によってその処理が他の機械に割り振られたためだと考えられる。

5 終わりに

本研究では、実際の工場データにおいて、作業時間が複雑な分布に従う場合の作業時間の推定と、機械スケジューリングを行うためのシステムを提案した。今後の予定として、作業時間のバラツキを考慮した確率的なスケジューリングを検討する。

参考文献

- [1] Li, Q., Kucukkoc, I., & Zhang, D. Z. (2017). Production planning in additive manufacturing and 3D printing. *Computers & Operations Research*, 83, 157-172.
- [2] Lin, S. W., & Ying, K. C. (2017). Uniform parallel-machine scheduling for minimizing total resource consumption with a bounded makespan. *IEEE Access*, 5, 15791-15799.
- [3] Shen, J., & Zhu, Y. (2019). A parallel-machine scheduling problem with periodic maintenance under uncertainty. *Journal of Ambient Intelligence and Humanized Computing*, 10(8), 3171-3179.
- [4] Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. D. P., Basto, J. P., & Alcalá, S. G. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024.
- [5] Kang, Z., Catal, C., & Tekinerdogan, B. (2020). Machine learning applications in production lines: A systematic literature review. *Computers & Industrial Engineering*, 149, 106773.