

製造工程に関する時系列データの分類及び 特徴把握のための機械学習手法の構築

	広島大学	*平田 智哉	HIRATA Tomoya
02502915	広島大学	林田 智弘	HAYASHIDA Tomohiro
01403974	広島大学	西崎 一郎	NISHIZAKI Ichiro
05000335	広島大学	関崎 真也	SEKIZAKI Shinya
1109150	太平洋セメント (株)	香月 毅	KATSUKI Takeshi
	太平洋セメント (株)	浅倉 綾太	ASAKURA Ryota
	太平洋セメント (株)	須藤 航太	SUDO Kouta

1. はじめに

ある製品の製造工程では、複数のオペレータがパラメータを適切に設定することで品質や生産量を制御している。全てのオペレータに共通する操作ルールは存在するが、状況に応じた細かい操作を行う場合、オペレータ個人の裁量や経験に依存することが多く、新人オペレータの教育を含めた長期的に安定した運用が困難であるという問題がある。本研究では、オペレータ操作の可視化や予測モデルの構築を目的とする。

先行研究では、時系列連続値環境に対応可能なクラシファイアシステムとして、NXCSM(Neural network eXtended Classifier System Merged) を用いたモデル [1] が提案されているが、精度の面で十分な結果とは言えない。本研究では、オペレータの操作の要・不要を判定するためのシステムを構築することで、製造工程における操作の必要な区間を高精度に抽出することを目的とする。

2. オペレータ操作モデルの構築

提案手法では、LSTM[2] を用いて無操作区間における状態の特徴量の時系列データの予測モデルを構築し、予測誤差に基づく時系列データの異常検知により、操作区間の抽出を行う。

2.1. LSTM による時系列予測にモデルに基づく操作モデル

n を状態の特徴量の次元数として、直前までの状態の特徴量に基づく LSTM からの出力値 $\hat{y}_i(t)$ と、実際の特徴量 $y_i(t)$ との誤差 $e_i(t) = |\hat{y}_i(t) - y_i(t)|, i = 1, 2, \dots, n$ の荷重誤差和を $E(t) = \sum_{i=1}^n w_i \cdot e_i(t)$ とする。また、幅を rng とした $e_i(t)$

の移動平均を $e_i^{rng}(t)$ として、 $rng = 60, 180$ との荷重和を $E_{MA}(t) = \sum_{i=1}^n (w_i \cdot e_i + w_i^{60} \cdot e_i^{60}(t) + w_i^{180} \cdot e_i^{180}(t))$ とする。

操作の有無の指標を $o(t)$ として、 $t = \tau$ に操作が発生する場合 $o(\tau) = 1$ とする。 $o(\tau - t_{pre}) = 0.03$ として、 $t = \tau - t_{pre}$ から $t = \tau$ まで $o(t)$ を時刻に対して直線的に増加させる。同様に、 $o(\tau + t_{for}) = 0.03$ として、 $t = \tau$ から $t = \tau + t_{for}$ まで $o(t)$ を直線的に減少させる。それ以外の時刻では、 $o(t) = 0.03$ とする。 $o(t)$ および $E(t), E_{MA}(t)$ が近くなるように、重み w_i, w_i^{60}, w_i^{180} を遺伝的アルゴリズムを用いて最適化する。

本研究では、指標 $ind(t)$ に基づいて操作の要・不要を判定するものとする。 $ind(1) = 0$ として、時刻 $t (\geq 2)$ において $E(t)$ あるいは $E_{MA}(t)$ の移動平均が増加した場合に $ind(t) = ind(t-1) + \alpha^+$ 、減少した場合 $ind(t) = ind(t-1) - \alpha^-$ として、 $ind(t) \geq \theta$ の場合に操作が必要、 $ind(t) < \theta$ の場合に不要と判定する。操作が必要と判定した時刻の割合 (要操作判定率) 及び、操作区間の正当率により提案手法の性能を評価する。ただし、操作区間正当率は操作発生時刻の 30 分前から操作発生時刻までの区間に対して操作が必要であると判定した割合とする。要操作判定率が小さく、操作区間正当率が大きければ良好な性能を持つと解釈される。

3. 数値実験

本研究では、ある連続する 3ヶ月 (期間 A とする) の操作者データを用いて数値実験を行う。同じ品種を連続して生産する期間をタームと呼び、タームごとに LSTM の学習を行う。ただし、本実験で




図 2: 11 タームにおける最良結果

は、この期間で生産される品種 a, b のうち品種 a を対象としており、期間 A は全 35 タームに分割される。実験の全体的な流れを図 1 に示す。




図 1: 実験の概要図

$ind(t)$ に関するパラメータの組み合わせを性能評価基準に基づいて探索的に最適化する。表 1 に各パラメータの探索範囲を示す。ただし、「移動平均幅」は $E(t)$, $E_{MA}(t)$ の移動平均幅を示す。

項目	範囲
移動平均幅 (分)	60, 120, 180, 240, 300, 360
閾値 θ	0.1, 0.2, ..., 0.9
$\alpha^+(\alpha^-)$	0.001, 0.002, ..., 0.029

11 タームは 3837 分間の区間であり、この検証において、 $E(t)$ の移動平均幅を 180 分、 $\alpha^+ = 0.012$, $\alpha^- = 0.024$, $\theta = 0.1$ としたとき、要操作判定率は 0.680、操作区間正答率は 1.000 という結果を得ることができた。ただし、長期的な時系列データを取り扱う LSTM の特性から、序盤のデータに対して適切な予測が難しいため、最初の 360

分間を要操作判定率および操作区間正答率の評価から除く。横軸を時刻 t 、縦軸を $E(t)$ および $E(t)$ の移動平均、 $ind(t)$ の値の推移としたグラフを図 2 に示す。閾値 θ は赤の点線で、操作発生時刻は太い黒い実線で示される。

図 2 から、 $ind(t)$ は操作発生時刻に近づくが増加し、操作発生後には急激に減少する傾向があることがわかる。

一方で、21 タームは 5760 分間の区間であり、この検証においては、 $E(t)$ の移動平均幅を 240 分、 $\alpha^+ = 0.015$, $\alpha^- = 0.013$, $\theta = 0.1$ としたとき、要操作判定率は 0.627、操作区間正答率は 0.880 という結果を得ることができた。

4. おわりに

本研究では、オペレータが操作を行う区間を不安定な状態であると解釈して安定的な状態を学習した時系列予測器を用いて、操作の要・不要を判定する手法を構築した。結果として、各タームにおいて高い操作区間正答率を得ることができた。

今後の課題として、移動平均幅、 θ 、 α^+ 、 α^- などのパラメータの最適化と、品種 b における提案手法の有効性の検証、従来手法との比較実験などが考えられる。

参考文献

- [1] 熊谷, 林田, 西崎, 関崎, 香月, 浅倉, 須藤, “製品製造工程におけるオペレータに対する予測モデルの開発”, 第 64 回システム制御情報学会研究発表講演会論文集, pp. 197–204, 2020.
- [2] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory”, *Neural Computation*, 9, pp. 1735–1780, 1997.