

Prophet による製造プロセスの多次元時系列分析:
プロセス因子相関の考慮による予測可能性向上法
Multifactorial Time Series Analysis for Industrial Process using Prophet:
Improving Predictability by Considering Process Factors

吹田 駿介[†] 山本 佑樹[†] 浅田 勝義[†] 山田 隆太[†] 森川 貴文[†]
Suita Shunsuke Yamamoto Yuki Asada Katsuyoshi Yamada Ryuta Morikawa Takafumi

1. はじめに

工業プロセスにおける各種性状管理に関する時系列は多変量因子が複雑に絡み合い予測困難なことが多い。アルミニウム加工に使用される潤滑油性状管理もその 1 つであり性状の確実な予測および管理の方法は確立されていない[1]。潤滑油性状は様々な計測値をもとに作業者の経験によって補給排油量を調整することで製造に適した状態を維持している。管理項目が膨大なものの性状管理法は暗黙知化されていることが多く、作業者の変更や作業者の習熟度の差異によってばらつきが生じる可能性がある。また、長年経験的に実施される管理作業は真に適切なものとは限らない。このような属人性を低減するためには性状変化の予測をもとに補給排油量が定量的に決定されることが望まれる。本研究では過去の補給排油実績と潤滑油の計測値を用いて関係因子を含めた性状の時系列予測を目的とし、多変量データである潤滑油性状に対して時系列モデリングを行い、その使用変数と予測可能性を調査する。

2. 予測モデル

時系列予測モデルには古典的な自己回帰モデルである AR モデルに始まり、ARIMA モデルや SARIMA モデルといった様々なモデルが存在する[2]。多次元時系列に対する予測では VAR モデルを使用した例[3]や自然言語の系列予測モデルである Transformer を利用した予測[4]が実験されている。

今回の潤滑油性状の時系列予測には Facebook (現 Meta) が開発した時系列モデリングライブラリ Prophet[5]を使用した。Prophet は一般的に単変量の時系列予測に用いられ、日付と予測対象の値が組になった時系列データを学習させることで予測モデルが構築可能である。Prophet のモデリング原理は複数の非線形関数を足し合わせる一般化加法モデル (Generalized Additive Model, GAM[6]) の 1 種であり、式(1)のように表される。式中の各項は次の通りである。 $g(t)$ は予測対象のトレンド成分であり長期から短期のトレンド成分、 $s(t)$ は季節成分であり周期性を持つ成分、 $h(t)$ は休日効果であり祝日などの突発的な影響を持つ成分を示す。Prophet には外部変数の追加が可能であり、予測対象の値の変動に関係する値を回帰式として予測式に組み込むことが可能である。外部変数を追加した場合の予測式は式(2)で表され、 i は使用する外部変数の数、 β_i は外部変数の回帰係数、 $X_i(t)$ は外部変数を示す。

$$y(t) = g(t) + s(t) + h(t) \quad (1)$$

$$y(t) = g(t) + s(t) + h(t) + \sum_{i=0}^n \beta_i X_i(t) \quad (2)$$

2.1 提案手法

1 つ目のモデルとして単純かつ一般的な Prophet の使用方法である単変量の時系列予測モデルを構築する (以降、外部変数不使用モデルと呼ぶ)。外部変数不使用モデルはモデル構築が単純な一方で、注目する因子とは異なる因子からの影響を考慮しない。2 つ目のモデルとして、外部変数を追加することで、追加された変数による影響を予測値に反映することが可能な多変量データを用いた時系列予測法を検討した (以降、外部変数使用モデルと呼ぶ)。適切な変数の追加を行うことで予測性能の向上が見込める一方で、モデルの表現力が高くなるため、学習データに Overfitting してしまう恐れもある。今回は潤滑油性状計測値、補給排油実績の全データを追加するモデルと、潤滑油管理者によって選択された項目のみを追加したモデルを構築し (図 1)、それぞれ外部変数不使用モデルの予測性能と比較を行う。なお、いずれのモデルにおいても Prophet のパラメータである changepoint_prior_scale、seasonality_prior_scale、seasonality_mode、changepoint_range、n_changepoint は optuna[7]によって決定した。

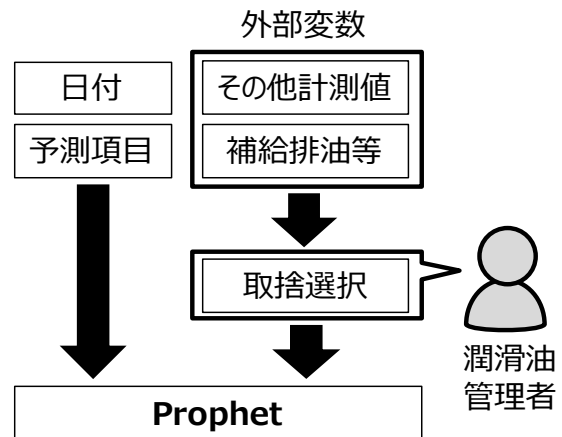


図 1 外部変数使用モデルの構築

3. 結果

潤滑油計測値 22 項目を予測対象として、各モデルでの予測を行う。225 日分の潤滑油計測値と補給排油等のデータを学習データ 180 日、テストデータを 45 日に分割し 3 つのモデルでのテストデータに対する予測性能を評価した。予測性能指標は平均二乗パーセント誤差 (RMSPE) とした。結果を表 1 に示す。

[†] 株式会社 UACJ UACJ Corporation

表 1 モデルの予測性能

項目	RMSPE (%)		
	外部変数使用 モデル	外部変数使用 モデル (全項目使用)	外部変数使用 モデル (項目選択)
1	4.24	5.25	5.05
2	47.71	94.19	79.34
3	15.33	22.69	17.01
4	10.60	20.11	11.38
5	26.23	35.28	26.77
6	54.54	42.02	41.69
7	19.40	33.44	35.02
8	2.48	1.33	1.36
9	7.06	10.82	8.81
10	3.62	7.16	6.08
11	2.90	6.68	3.28
12	9.30	18.19	10.43
13	8.19	17.06	9.63
14	40.66	26.33	17.13
15	2.82	2.17	1.69
16	21.25	36.39	34.10
17	5.22	7.31	5.03
18	21.05	19.36	10.36
19	91.81	136.37	79.54
20	28.89	35.65	31.07
21	50.90	53.37	46.03
22	136.73	100.12	94.17

4. 考察

予測対象時系列の 22 項目中、13 項目では外部変数不使用モデルの性能が最も高かったことから、これら項目では対象項目自体の過去の時系列成分が予測に強く関係しており共変数の影響が小さいと解釈できる。一方、外部変数使用モデルのうち、潤滑油管理者（ドメイン知識）によって外部変数を選択設定したモデルでは 8 項目の予測において最も性能が高かった。代表例として外部変数の追加によって性能が向上した項目（表 1 における項目 18）に対する外部変数不使用モデルと外部変数使用モデルの予測値・実測値のグラフを図 2、図 3 にそれぞれ示す。図中の右側 20% における赤線がテストデータに対する予測値、青線が実測値である。外部変数不使用モデルでは学習データの上昇傾向に沿って予測が行われているが、外部変数使用モデルでは外部変数によって短期間での変動（上昇/下降）が予測されていることがわかる。これは検討する系において如何に共変数の影響が大きいかを示唆するものである。

5. おわりに

潤滑油性状に対する時系列予測を Prophet によって実施した。今回の使用データに対する予測では、外部変数不使用モデル、または潤滑油管理者が外部変数を設定した外部変数使用モデルの予測性能が高く、計測されている全項目を外部変数に使用したモデルの予測性能は低い傾向が見られた。このことから、潤滑油性状の予測モデルでは予測対象項目に作用する因子を外部変数に設定することが可能で

項目18に対する予測




図 2 外部変数不使用モデルによる項目 18 の予測

項目18に対する予測




図 3 外部変数使用モデルによる項目 18 の予測

あれば予測性能向上が見込め、そうでない場合は対象項目の時系列データのみから単変数予測する事が望ましいことが判明した。また、今回のモデルでは予測対象以外の因子の時系列性（時間的因果関係）を予測に組み込んでいないため、予測性能向上のためには Prophet 以外のモデルによる多変数予測も検討する必要があると考えられる。

参考文献

- [1] 吹田 駿介, 坂下 修梧, 山田 隆太, 山本 佑樹, 浅田 勝義, “機械学習を応用したクーラント性状管理法の検討”, 日本トライボロジー学会トライボロジー会議予稿集, A26 (2021).
- [2] 島田 直希, “時系列解析 自己回帰型モデル・状態空間モデル・異常検知 Advanced Python 1”, 共立出版, 2021
- [3] 水野 太介, 森山 健, 山先 純也, 長谷 智紘, 湯山 藍美, 前田 俊二, 高橋 雅也, 田中 和英, 星平 祐吾, “多変数時系列データへのベクトル自己回帰モデルの適用に関する考察”, 精密工学会春季大会 学術講演会講演論文集, 2016
- [4] 本田 良司, 小笠原 範光, 小玉 亮, “Transformer による時系列予測”, 人工知能学会全国大会論文集, 2020
- [5] Facebook, “Prophet | Forecasting at scale.”, <https://facebook.github.io/prophet/>
- [6] Trevor Hastie, Robert Tibshirani, “Generalized Additive Models”, Statistical Science 1 (3), 1986
- [7] Takuya Akiba, Shotaro Sano, Toshihiko Yanase, Takeru Ohta, Masanori Koyama, “Optuna: A Next-generation Hyperparameter Optimization Framework”, arXiv:1907.10902, 2019