

# 生産プロセスの強靱化を目指したプロセスダイナミクスと非線形性に対応できる異常検知手法の開発

名古屋大学大学院工学研究科物質プロセス工学専攻\*

藤原幸一

## 1. 研究の目的と背景

プロセス産業では、温度、圧力、流量などをリアルタイムで測定するためにハードウェアセンサーが広く使用されている。しかし、製品の品質情報や化学組成といった重要な変数は、通常オンライン測定が難しく、オフラインでの分析が必要となるため、リアルタイム制御が困難である。これに対処するため、プロセスデータに基づいて推定を行うソフトセンサ技術が発展してきた [1]。

ソフトセンサ設計では、部分最小二乗法 (partial least squares; PLS) などの回帰手法が用いられてきたが [2]、設備の老朽化やメンテナンスによるプロセス特性の変動により、推定精度が低下することが大きな問題となっている。この課題に対処するために、移動窓モデリング (moving window; MW) や Just-In-Time (Just-In-Time; JIT) モデリングが提案されている [3, 4]。特に局所重み付け PLS (locally-weighted PLS; LWPLS) は産業界でも一般的であるが [5]、LWPLS でも急激なプロセス変化へいつも対応できるとは限らない。

近年、転移学習 (TL) 手法を用いたソフトセンサの適応が試みられており [6]、中でも frustratingly easy domain adaptation (FEDA) は、特に製品グレード間の運転条件の転移において有効性が示されている [7]。しかし、従来の FEDA ではプロセス変化のタイミングを特定する必要があり、突発的な異常には対応が困難だった。

そこで本研究では、これらの課題を克服するため、JIT モデリングと TL を統合し、最新サンプル群に着目することで迅速かつ柔軟に適応可能な新たな手法である Latest Sample Targeting FEDA (LST-FEDA) を提案した [8]。さらに提案した LST-FEDA をシミュレーションデータと実プロセスデータに適用して、その有効性を検証した。

## 2. 提案手法 LST-FEDA

従来の FEDA は、にプロセス条件が変化する前後でソースドメイン (SD) とターゲットドメイン (TD) を定義し、特徴空間を拡張することによりドメイン適応を行う手法である [9]。図 1 では、ソースドメインの入力データ  $X_S$  とターゲットドメイン  $X_T$  の入力データをそれぞれ拡張し、共通の入力変数空間とドメイン固有の空間を形成する。具体的には、SD の拡張では  $X_S$  をそのまま保持しつつ、TD に対応する部分をゼロ行列でパディングし、TD の拡張では逆に SD に対応する部分をゼロ行列でパディングする。このよう

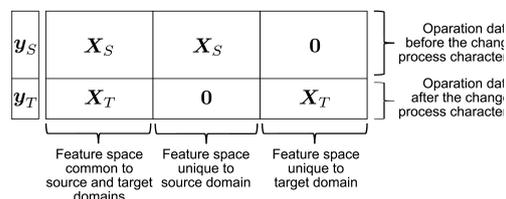


図 1: 従来の LEDA でのデータ拡張

\*2025.4 より北海道大学電子科学研究所に所属

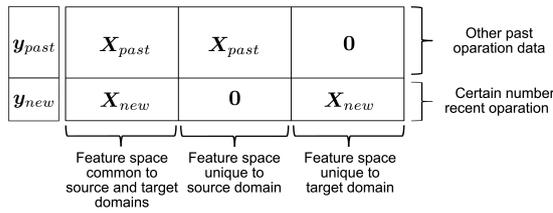


図 2: LST-LEDA でのデータ拡張

に両ドメインのデータを統合することで、モデルが両方のドメインに適応できるようになる。しかし、従来の FEDA は急激な変化においては変化時点を特定することが困難であり、適切なドメイン設定ができない問題があった。

本研究で提案した LST-FEDA では、常に最新の一定数 ( $k$  個) のサンプルをターゲットドメインと定義し、それ以前のデータをソースドメインとすることで、サンプル更新に合わせて動的にドメインを再構成する。図 2 に LST-FEDA における入力特徴空間の拡張方法を示す。最新のサンプル群  $X_{new}$  を TD として設定し、それ以外の過去のサンプル  $X_{past}$  を SD とする。この拡張方法では、TD に属する最新サンプル  $X_{new}$  をそのまま保持し、SD に属する過去サンプル  $X_{past}$  をゼロ行列でパディングする。

このように特徴空間を拡張することにより、最新のプロセスデータを重視しながら、過去のデータも活用することで、プロセス特性の急激な変化や徐々に進行する変化に迅速かつ正確に適応することが可能となり、負の転移リスクも抑制できる、さらに提案した LST-FEDA は JIT モデリングとの親和性が高く、任意の JIT 手法と組み合わせ可能という特徴を有する。

### 3. 検証方法

#### 3.1 シミュレーションデータ(VAM プロセス)による検証

酢酸ビニルモノマー (VAM) プロセス (図 3 参照) を対象とし [10], プロセスシミュレータである Visual Modeler (オメガシミュレーション) を用いて 40 時間分のプロセスデータを取得した。運転開始 33 時間後に 7 種類の故障 MAL1 - MAL7 を発生させて、それぞれ故障の影響を受けた後でのソフトセンサの推定性能を評価した。ソフトセンサの推定目標は製品中 VAM 濃

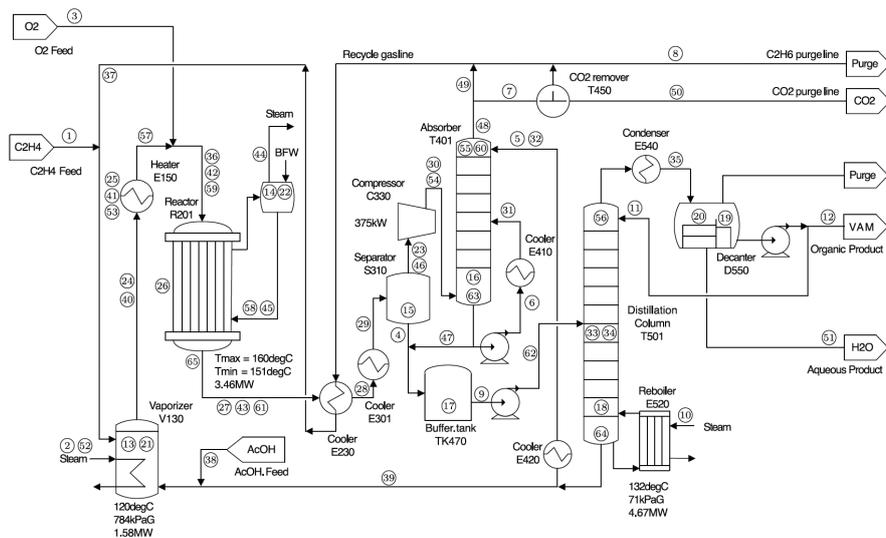


図 3: VAM プロセスの概要

度の 30 分間隔の測定値である。ソフトセンサの性能指標には相関係数 (R) と二乗平均平方根誤差 (RMSE) を用いた。

### 3.2 実プロセスデータ(FM プロセス)による検証

化学メーカーより提供されたフッ素系モノマープロセス (図 4) を対象として、提案法の性能を評価した。2020 年 7 月から 2023 年 6 月までの運転データを使用し、2-3 月は定期的なプロセスメンテナンスがある。このメンテナンスによるプロセス特性変動に対するソフトセンサの適応性能を検証した。推定目標は、ラボ分析に頼る製品純度の分析結果を推定することである。

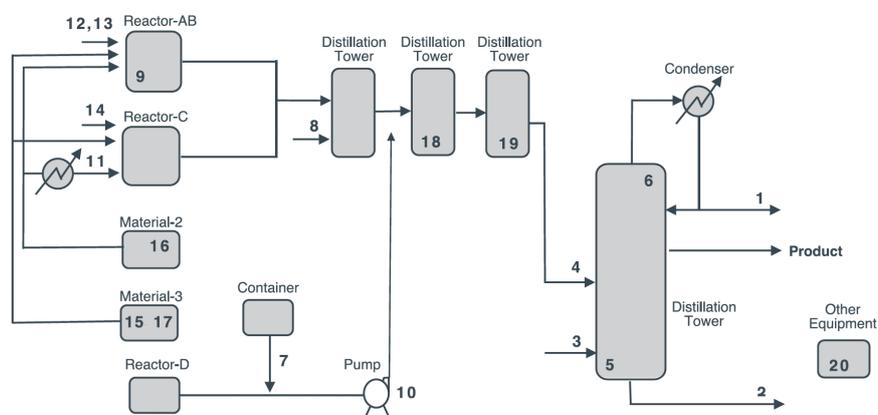


図 4: FM プロセスの概要

## 4. 実験結果

### 4.1 VAM プロセスにおける評価

図 5 に MAL1 におけるソフトセンサによる推定結果を示す。従来の LWPLS (Model 1) および LWPLS+FEDA (Model 2) に対し、提案手法 LST-FEDA (Model 3) は故障発生直後から推定精度の回復が早く、長期的にも安定して推定可能であった。提案した LST-FEDA は、MAL1-MAL7 のすべてにおいて、故障後の 240-600 分間の推定精度で最も高い R および最小の RMSE を達成した。

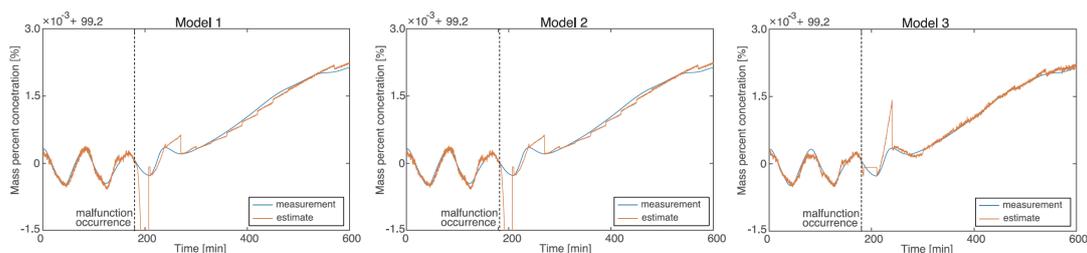


図 5 : VAM プロセスの故障 MAL1 における推定結果

## 4.2 FM プロセスにおける評価

図 6 に FM プロセスにおけるソフトセンサによる製品純度の推定結果を示す。図中央の水色の帯が定期メンテナンス期間である。メンテナンスによる大幅なプロセス変動にもかかわらず、LST-FEDA (Model 3) は推定精度を維持できた。表 3 に示すとおり、プロセスメンテナンス前後期間を通じて、他手法より高い R および低い RMSE を達成していることを確認した。具体的には、R では約 6%、RMSE では約 13%の性能改善を認めた。

このことより、提案する LST-FEDA の有効性が確認できたといえる。

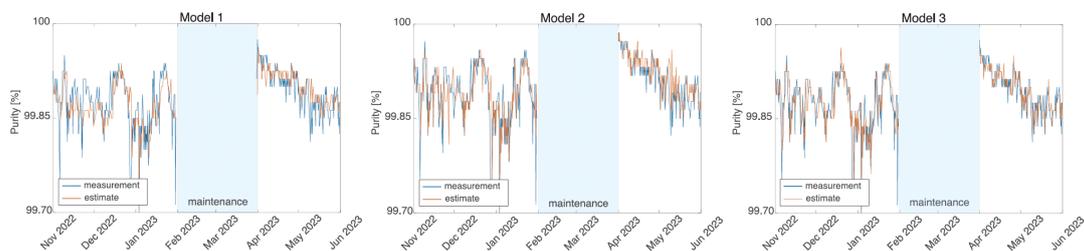


図 6 : FM プロセスの推定結果

## 5. 成果の考察

本研究にて提案した LST-FEDA は、最新サンプルに焦点を当てることで、ソフトセンサのプロセス変動への即時適応を可能とし、さらに過去サンプルの活用によって推定性能の向上も確認できた。これにより、LST-FEDA は突発的故障のみならず計画的メンテナンスといったさまざまな種類のプロセス特性の変化にも柔軟に対応できるといえる。

また、LST-FEDA は計算負荷が小さいため、リアルタイム適用が可能であり、実プロセスへの展開が現実的である点も大きな利点である。

## 6. 結論と今後の展望

本研究では、プロセス特性の急激および緩慢な変化に対応可能なソフトセンサ更新手法 LST-FEDA を提案し、シミュレーションおよび実プロセスデータを用いた検証によりその有効性を実証した。本成果はすでに学術論文として公表している [8]。

今後は、他の JIT モデリング手法との組み合わせ検討、およびターゲットサンプル数  $k$  の自動最適化アルゴリズム開発に取り組む予定である。これと平行して、実プロセスへの実装、実用化を目指し、本邦の製造業における生産効率の一層の向上に貢献したい。

### まとめ

- プロセス特性が急激に変化する場合でも、迅速に変化に適応して安定した推定性能を実現できるソフトセンサを開発するために、新たな転移学習である LST-FEDA を提案した。

- LST-FEDA と JIT モデリングを組み合わせたソフトセンサは、シミュレーションデータのみならず、実プロセスにおいても高い有効性を確認した。
- LST-FEDA は、将来、本邦のプロセス産業における生産性向上に大きく貢献する可能性がある。

#### 謝辞

本研究は公益財団法人天野工業技術研究所の支援を受けて実施された。ここに記して感謝の意を表す。

#### 参考文献

1. M. Kano, K. Fujiwara, Virtual sensing technology in process industries: trends and challenges revealed by recent industrial applications, *J. Chem. Eng. Jpn.* 46(1) (2013) 1–17.
2. S. Wold, M. Sjöström, L. Eriksson, PLS-regression: a basic tool of chemometrics, *Chemometr. Intell. Lab. Syst.* 58 (2) (2001) 109–130.
3. J. Liu, D.-S. Chen, J.-F. Shen, Development of self-validating soft sensors using fast moving window partial least squares, *Ind. Eng. Chem. Res.* 49 (22) (2010)11530–11546.
4. K. Fujiwara, M. Kano, S. Hasebe, A. Takinami, Soft-sensor development using correlation-based just-in-time modeling, *AIChE J.* 55 (7) (2009) 1754–1765.
5. S. Kim, R. Okajima, M. Kano, S. Hasebe, Development of soft-sensor using locally weighted PLS with adaptive similarity measure, *Chemometr. Intell. Lab. Syst.* 124 (2013) 43–49.
6. S.J. Pan, Q. Yang, A survey on transfer learning, *IEEE Trans. Knowl. Data Eng.*22 (10) (2010) 1345–1359.
7. N. Yamada, H. Kaneko, Adaptive soft sensor based on transfer learning and ensemble learning for multiple process states, *Anal. Sci. Adv.* 3 (5–6) (2022)205–21.
8. K. Katayama, K. Yamamoto, K. Fujiwara: Adaptive Soft-sensor Update by Latest Sample Targeting Frustratingly Easy Domain Adaptation, *Chemometr. Intell. Lab. Syst.*, (2024) 105246.
9. H.D. III, Frustratingly easy domain adaptation, 2009, CoRRabs/0907.1815.arXiv:0907.1815.
10. Y. Machida, S. Ootakara, H. Seki, Y. Hashimoto, M. Kano, Y. Miyake, N. Anzai, M. Sawai, T. Katsuno, T. Omata, Vinyl acetate monomer (VAM) plant model: Anew benchmark problem for control and operation study, *IFAC-PapersOnLine*49 (7) (2016) 533–538.
- 11.