

データの類似性を考慮した転移学習による予測モデルの性能向上 —燃料電池フォークリフト稼働データによる検証— Transfer Learning Utilizing Real Industrial Vehicle Date Based on Similar Usage Trends

松浦 慶伍
Keigo Matsuura

*1 ITデジタル推進部

要旨

予防保全に活用可能な高精度の予測モデル構築技術を確立したため紹介する。燃料電池フォークリフトの稼働データにはお客様ごとで使われ方が異なるという特徴があり、従来手法では予測モデルの精度向上に限界があった。そこで私たちは、使われ方が類似のデータをグルーピングし、同一グループ内で知識を共有させる転移学習の枠組みを提案することで、従来手法に比べて予測精度を16%向上させる効果を確認した。

キーワード: 転移学習、類似性

Abstract

We introduce a technology we have developed for building highly accurate prediction models applicable to preventive maintenance. Fuel cell forklift operation data varies in usage patterns depending on the customer, which has posed limitations in improving prediction accuracy using conventional methods. To address this, we proposed a transfer learning framework that groups data with similar usage patterns and enables knowledge sharing within each group. As a result, we confirmed a 16% improvement in prediction accuracy compared to conventional approaches.

Keywords: Transfer Learning, Similarity

1 はじめに

燃料電池(FC: Fuel Cell)フォークリフトのログデータをを用いて、予防保全(図1)に活用可能な高精度な予測モデルの構築技術を確立したため紹介する。

精度よく寿命予測ができることで寿命時期にあわせて、予め部品交換などの準備を行うことができるため停止期間の低減を期待できる。しかしながら、新たな動力源であるFCの劣化挙動は、お客様ごとに異なる使われ方の影響を受けて多様であり、高い精度での予測が難しいという課題があった^[1]。

上記の難しさを詳しく説明する。一般的にAIや機械学習を用いた予測モデルは、訓練データと同じ分布のデータを出力することを目指す。言い換えると、予測モデルの能力はおおよそ訓練データの平均程度の能力に収束する。より正確には、出力の決定方法に依存する。

例えば、10台の車両データを訓練データとした場合、内8台が標準的な使われ方、2台が特殊な使われ方をしていたとすると、後者の2台に対する予測精度は悪化する可能性がある。利用したFCフォークリフトの稼働データは、車両ごとに僅かに分布が異なっていた。そこで、私たちは出力の決定方法に転移学習という工夫を施すことで、高精度な予測を実現した。

本技術により、機械学習におけるベースラインなパラメータ同定手法であるRidge回帰と比較して、平均予測誤差を約16%削減することに成功した。

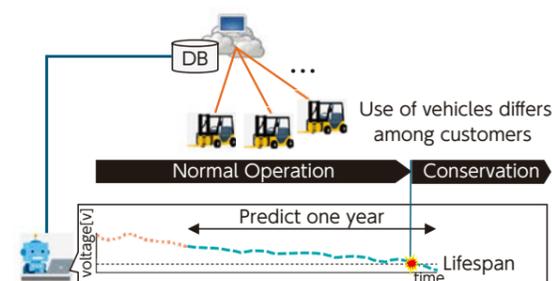


図1. 予防保全への予測モデルの活用: 寿命時期を1年前に予測することで最適な部品交換タイミングをお客様へ提供し、計画外な停止時間の軽減に貢献する
Fig.1 Preventive maintenance applying the ML technology

2 転移学習

本技術のコンセプトとなる転移学習について、まず一般的な定義を紹介した後に、本技術における独自の工夫点の概要を解説する。

神鳥^[2]らは、転移学習(Transfer Learning)という語は統一された形式的定義を与えることは難しいとしながらも、形式的でない定義としては、次のものが広く受け入れられるだろうと述べている。

「新規タスクの効果的な仮説を効率的に見つけ

出すために、1つ以上の別のタスクで学習された知識を得て、それを適用する問題」^[3]

今回においては、ある対象(ターゲット)の予測を行う際に、別の類似対象(ソース)から得られた知識を活用することで、予測精度を高める枠組みであると言える^[4-6]。

転移学習は、ターゲットとソースの間に大きな違いが存在する場合、かえって予測精度を悪化させる「負の転移」^[7]が生じることが、実用上の課題として知られている。この課題に対し、本研究では使用傾向が類似した車両同士の「グルーピング」を行い、グループ内限定の「転移学習」を実施することで負の転移を回避し、転移学習を実用可能な技術とした。詳細は3章で述べる。

3 方法

本章では、本研究の技術内容について詳述する。章の構成として、まず使用データセットと時系列モデルの概要を説明し、その後、本提案手法の中核である「転移学習」と「グルーピング」、最後に全体の処理フローを示す。

原理的には、本提案手法は任意の多変量時系列データに適用可能であるが、現時点では本研究において使用したFCフォークリフトのデータセットに限定した評価に留まっており、汎用性については今後の検証が必要である。ただし、本手法で用いる温度や積載量といった変数は、他の電源装置にも共通して利用されている指標であることから、他の産業車両への適用可能性は高いと考えられる。

3.1 データセット

お客様の現場で稼働しているFCフォークリフトから取得されたデータを用いた。各車両における時系列データは、時刻を含む9種類のセンサ値から構成されており、1台あたりのサンプル数はおおよそ100点程度である。取得されたセンサ項目には、FC電圧(Voltage)、空気供給量(Airflow)、水素供給量(Hydrogen)、外気温(Temperature)、リフトの起動・停止回数(Lift start-and-stop)、積載量(Load amount)、出力切替回数(Power output change)、出力値(Power output value)が含まれる。

このうち、FC電圧・空気供給量・水素供給量の3項目(図2(a))は、車両の制御に関連する情報であ

り、空気や水素の供給を通じて化学反応を制御し、電圧を一定に保つ制御機構を反映している。一方、外気温、リフトの起動・停止回数、積載量、出力切替回数、出力値の5項目(図2(b))は、車両の使われ方に関連する情報であり、作業環境や運転パターン、負荷の程度などに関係している。

分析対象は、時刻を除いた8次元の多変量時系列データであり、これをもとに予測モデルの構築と評価を行った。

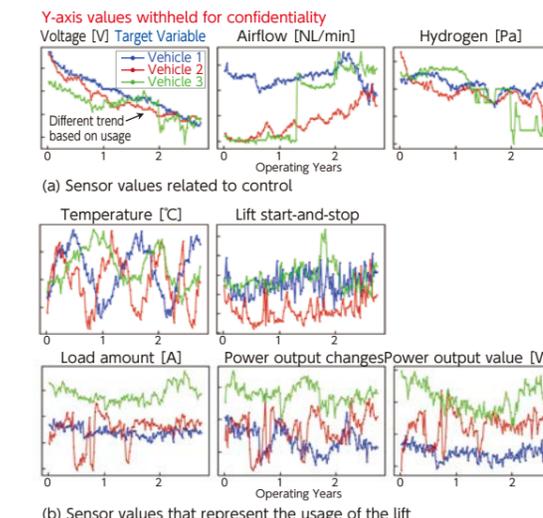


図2. 時系列データの外観: (a) 制御に関する3項目 (b) 使われ方に関する5項目。3台の車両の比較でも、使われ方によってデータ傾向が異なることがわかる
Fig.2 Time series plots of features

3.2 時系列モデル

モデルを選定するためにデータを分析して特徴を確認した。ここでは、時系列モデルの性能に与える影響が大きいとされる多重共線性と定常性の有無の確認結果に絞って紹介する。

センサはすべてFCシステム周辺に設置されており、多重共線性が懸念されたが8変数間の相互相関は弱く、モデルへの悪影響は低いと想定された。また、制御の影響や装置の劣化はあるものの、対象変数には定常性が見られた。

これらのデータ特徴を考慮して本研究ではベクトル自己回帰モデル(VARX: vector Autoregression model with exogenous)を採用した。

VARXモデルは、複数の相互依存する内生変数(endogenous variables)を、それらの過去の値と外部から与えられる外生変数(exogenous variables)の系列と関連付ける自己回帰方程式モデルの1つである。モデル構造は以下のように定

式化され、

$$\hat{y}_{i,t} = \sum_{j=1}^3 W_{1,ij} y_{j,t-1} + \sum_{k=1}^5 W_{2,ik} x_{k,t} + W_{3,i} \quad (1)$$

ここで、 $\hat{y}_{i,t}$ は時刻tにおける予測値であり、データセットの第2列～第4列に対応する。3つの連立方程式を解くことで、第2列の変数(すなわちFC電圧)を用いてFC電池の寿命予測を行う。

t-1における1はラグ数を示し、1つ前の時点までの情報を用いることを意味する。jは内生変数の数であり、これは第2～4列に該当する3つの変数である。kは外生変数の数であり、第5～9列に該当する5つの変数である。

$W_{1,ij}$ は内生変数に対する標準化偏回帰係数、 $W_{2,ik}$ は外生変数に対する標準化偏回帰係数、 $W_{3,i}$ はトレンド項に対する標準化偏回帰係数であり、以後、これらを総称してモデルパラメータと呼ぶ。データセットは標準化済みのため切片項は存在しない。

3.3 提案手法

(1) コンセプト

本研究のアプローチは、他車両の知識(本手法では、モデルパラメータ)を自車両へ転移することで予測精度を向上させるものである。しかし、既に2章で述べたように、類似性を考慮せずに転移すると「負の転移」が発生するため、他車両との共通点を取り込みつつ、自車両固有の特徴は維持させる必要がある。

この2つをバランスさせるため、使用傾向が類似した車両同士の「グルーピング」を行い、グループ内限定の「転移学習」を実施することを提案した。イメージを図3で解説する。図3は、各点が1台の車両を表し、車両の特徴空間上の分布を模擬している(機械学習に明るい方には、モデルパラメータを2次元空間へ射影した図だと置き換えていただきたい)。当初、全車両は図3(a)のように1つの領域に密集していると仮定していたが、データ分析した結果、図3(b)のように複数のクラスタに分かれて分布していることが明らかになった。これは、お客様ごとに異なる使われ方をしていることが原因と推測される。

この結果を踏まえ、本研究では各車両の固有性を保ちながら知識の転移を行うために、車両が集中するクラスタ領域ごとにグルーピングを行い、同一グループ内でのみ転移を行う方向性を採用し

た。

転移の方法としては、各車両のモデルパラメータが属するグループ内では、共通部分空間を共有するという仮定を置き、グループ内の車両のモデルパラメータをその平均値へと近づけるような正則化項の拡張を新たに提案した。

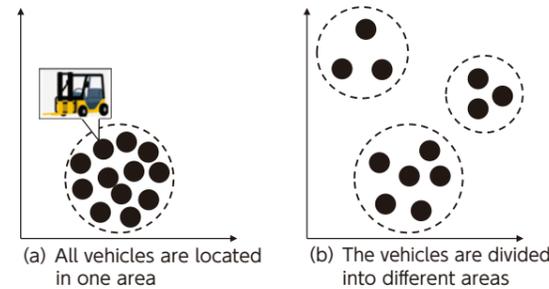


図3. 車両の特徴空間。1点が車両1台を表す:
(a) すべての車両は1つの領域に密集
(b) 車両ごとに複数の領域に分かれる
Fig.3 Space of usage characteristics

(2) 私たちの転移学習

本研究における知識とは、モデルパラメータである。車両ごとのモデルパラメータは、事前に推定済みであるという前提のもと、同一グループに属する他車両のモデルパラメータの平均的な値へ、自車両のモデルパラメータを近づける操作を転移学習と呼ぶ。これらの数学的な表記は機械学習におけるベースラインな正則化手法の1つであるRidge回帰を拡張し、第3項を追加することで実現した。具体的な正則化の式は以下となる。

$$W_{fix}^T = \arg \min \left\{ \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \lambda_2 \|W^T\|^2 + \lambda_3 \sum_{k=1}^N \rho(T, S_k) \|W^T - W^{S_k}\|^2 \right\} \quad (2)$$

ここで、上付きの Tは「ターゲット車両(自車両)」を、 S_k は「ソース車両(類似使用傾向を持つ他車両)」を示す。 W_{fix}^T は転移後に得られる自車両の最適化済みモデルパラメータ、 W^T は自車両の初期モデルパラメータ、 W^{S_k} は他車両(ソース)のモデルパラメータ、nは自車両のデータポイント数、Nは全車両数、 y_i は実測値、 \hat{y}_i は予測値をそれぞれ示す。 λ_2 と λ_3 はハイパーパラメータであり、 $\rho(T, S_k)$ は以下のように定義される関数である。

$$\rho(T, S_k) = \begin{cases} 1 & T \text{ and } S_k \text{ are same group} \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

第3項は、同一グループ内にある他車両のパラメータとの差異を抑制することで、パラメータの共通性を高めている。この項の効果を図4で幾何

学的に説明する。図4(a)の各点はRidge回帰によって車両ごとに推定されたモデルパラメータの初期値である。図4(b)では、これらをソースに式(2)を用いて転移を行った結果、モデルパラメータが更新され3台の車両の平均値に近づいている様子が示されている。本提案手法により、グループ内での知識共有を通じて、モデルパラメータが効果的に平均値へと収束し、精度向上が実現できることが確認された。

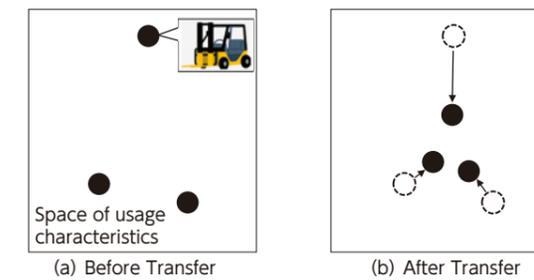


図4. 車両の特徴空間:
(a) 転移学習前のモデルパラメータの配置
(b) 転移学習後のモデルパラメータの配置(式(2)を使用)
Fig.4 Space of usage characteristics

(3) グルーピング

グルーピングの目的は、ターゲット車両(自車両)の固有性と、ソース車両(他車両)との共通性とのバランスを取ることにある。グルーピング手法は、各変数間の類似度を算出するための手法として Dynamic Time Warping (DTW)^[8]を用い、クラスタリング技術と組み合わせて実装されている。

本手法は、大きく3つの処理から構成されている(図5)。まず(I)DTWを用いて類似度行列を作成し、次に(II)その類似度行列に対して階層的クラスタリングを行い、最後に(III)クラスタリング結果を突き合わせてグループを定義する。

(I)では、特定の変数に対してN×Nの類似度行列を作成する。ここでNは対象となる車両台数であり、各要素は車両間で該当変数の学習期間を比較することで計算されたDTW類似度を表す。比較対象とする変数には、リフト操作に関連する5つの変数を使用している。

(II)では、それぞれの類似度行列に対して階層的クラスタリングを行い、2つのクラスタに分割している。クラスタ数を2としたのは、環境条件を大きく2種類に分類し、明確に異なる使用環境を分離するためである

(III)では、すべての変数で同一のクラスタ配置となった車両同士を同一グループと見なし

る。これは、5つの変数がそれぞれ車両の使用環境を表しているという仮定に基づく。言い換えれば、これらの変数がすべて同一パターンで一致する場合、それらの車両は同様の外部環境下で使用されていると判断される。

この手法には1つの制約がある。クラスタ数を変数ごとに2つと固定しているため、定義可能なグループ数は最大で32(2⁵:2はクラスタ数、5は変数の数)に限られる点である。スケーラビリティ(拡張性)に弱さがある点は課題である。

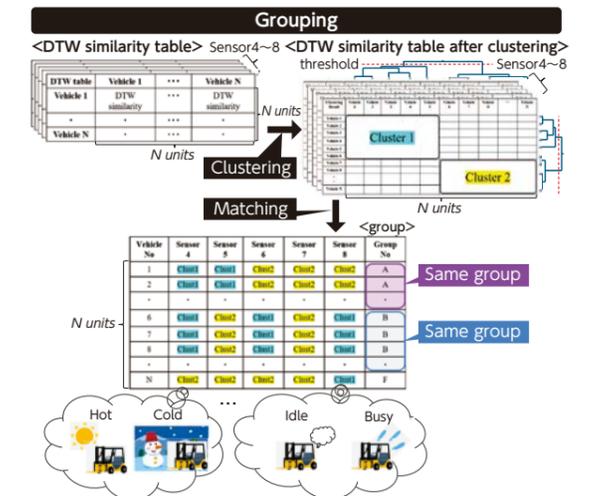


図5. 負の転移を軽減するためのグルーピング手法:
・リフト操作に関連する5つの変数ごとに車両間の類似度行列を作成
・類似度行列ごとに階層クラスタリングを行い2つのクラスタを形成
・5つの変数のクラスタが完全一致する場合を同じグループと定義
Fig.5 Grouping method to reduce negative transitions

(4) 処理フロー

処理全体の流れを図6に示す。はじめに、N台分のデータセットに対して、前述の手法に基づいてグルーピング処理を実施する。これと同時に、各車両に対してRidge回帰を用いて初期のモデルパラメータを推定する。

その後、式(2)に基づき、各グループ単位でモデルパラメータを更新する処理を行う。これら一連のプロセスを通じて、最終的な予測モデルのパラメータが推定される。

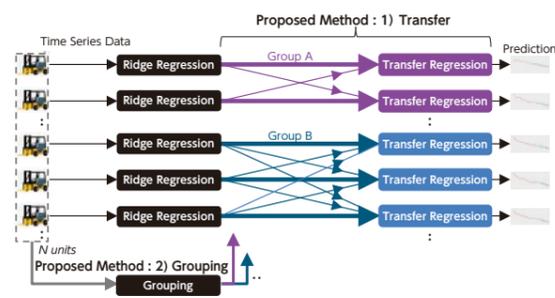


図6. 処理フロー: ソースモデルパラメータ W^{S_k} をRidge回帰によって推定する。同時に、 $\rho(T, S_k)$ の値を特定するために、N台の車両データから類似度行列を計算する。最後に、得られた $\rho(T, S_k)$ と W^{S_k} を入力として、(2)を用いてモデルパラメータを再度推定する
Fig.6 Process flow

4 実験設定

本章では、パラメータ推定方法、モデル評価の手法、および実験ケースについて説明する。

(1) パラメータ推定方法

まず、学習と評価のデータ分割について述べる。全期間のうち、各車両の最後の50点を評価データとして用い、それ以前のデータを学習データとして使用した。データセットに含まれる車両数は25台である。各車両における学習データの時系列長は、最少で48点、最多で171点、平均で93点であった。

ハイパーパラメータ λ_2 と λ_3 については、交差検証を用いて決定した。具体的には、学習データを10分割し、10通りの評価パターンを作成したうえで、 λ_2 と λ_3 のそれぞれに対して100通りの値を設定し、合計で1万通りのグリッドを生成した。各グリッド点に対して、10通りの評価パターンでモデルを評価し、平均二乗誤差(MSE)を計算した。その結果、1万通りの組み合わせのなかから、最も平均MSEが小さくなる λ_2 と λ_3 の組み合わせを選択した。

(2) 評価方法

モデルの入力データ数は1点、出力データ数は50点と設定した。おおよその目安として、1つのデータ点は約1週間分の情報に相当し、50点で約1年分の情報を表す。

モデル性能の評価には、評価データ50点を用いた二乗平均平方根誤差(RMSE: Root Mean Squared Error)を指標として用いた。年単位での劣化傾向を捉えることを目的としており、RMSEはこの目的において信頼性の高い評価指標である。

RMSEの値が大きいくほど予測性能が低く、小さいほど性能が高いことを意味する。

(3) 実験ケース

本研究では、以下の3つのケースを比較対象として設定した。

1つ目は転移を行わないケースであり、ベースライン手法としてRidge回帰を用いた。2つ目はグルーピングを行わずに全車両から転移を行うケースである。3つ目は使用傾向に基づいてグルーピングを行い、グループ内でのみ転移を行うケースである。

5 結果

表1に、実験で比較した3つのケースの結果をまとめる。表中には、転移なし(Ridge回帰)、グルーピングなしでの転移、グルーピングありでの転移という3つのケースについて、それぞれ25台の車両におけるRMSEの平均値と標準偏差を示している。

予測精度(RMSEの平均値)が最も高かったのはグルーピングありの転移学習(0.17)であり、最も低かったのはグルーピングなしの転移(0.24)であった。これは、グルーピングなしでの転移学習が実用的ではないことを示唆している。

また、RMSEの標準偏差についても、グルーピングありのケースが最も小さく(0.09)、予測性能のばらつきが抑えられていることが確認できた。これにより、本研究で提案した手法が複数の車両に対しても安定して効果を発揮することが示された。

表1. 車両25台のRMSEの結果一覧
Table1 SUMMARY OF RMSE FOR 25 UNITS

Method	Average	Standard Deviation
No Transfer (Ridge)	0.20	0.13
Transfer without Grouping	0.24 (+21%)	0.16 (+23%)
Transfer with Grouping	0.17 (-16%)	0.09 (-31%)

5.1 グルーピングの効果

図7(a)には、3つの実験ケースにおける各車両のRMSE値を一覧で示している。図7(b)の右側の列には、グルーピングあり・なしでの転移学習の差分を示しており、グルーピングが効果的であった車両には青でハイライトが施されている。

図8では、9次元のモデルパラメータ空間を主成

分分析(PCA: principal component analysis)により2次元空間へ射影した結果を示している。図中の三角形は転移を行わないRidge回帰によるパラメータを示しており、これらは複数の領域に分布している。これは3.3(1)で述べたように、グルーピングの根拠となるものである。図7(b)の右側の列の結果からも、グルーピングの有効性が確認された。

車両ごとにグルーピングの効果を検討すると、とくにグループBとCに属する車両群において精度の向上が顕著であり、グループ内のすべての車両で改善が見られた。

改善が見られた要因として、図8に示す通り、グループBとCの車両は転移を行わない状態でも互いに近い位置に分布していたことが挙げられる。これは、それらの車両におけるモデルパラメータの構成比率が類似しており、多くの部分空間を共有していることを意味している。そのため、モデルパラメータの構成をグループ内で整合させることで、予測モデルの汎化性能が向上したと考えられる。

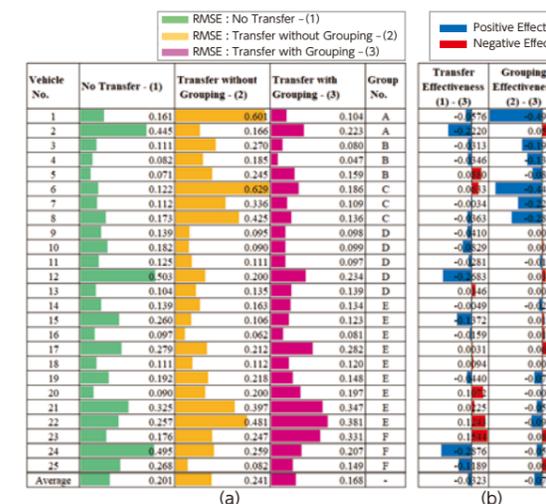


図7. RMSEの一覧と分析結果:
(a) 転移なし、グルーピングなし転移、グルーピングあり転移
(b) 転移学習の有効性、グルーピングの有効性転移学習により、予測精度の悪い3台のRMSE値が大幅に減少した。グルーピングすることで精度の悪化が緩和され、とくにグループBとCの精度が向上した
Fig.7 List and analysis of RMSE

5.2 転移学習の効果

図7(b)の左側の列には、転移なし(Ridge回帰)とグルーピングありの転移学習とのRMSEの差分が示されており、転移が有効であった車両は青でハイライトされている。

各車両に対する転移の効果を見ると、とくに車両No.2(RMSE: 0.45 → 0.22)、車両No.12

(0.50 → 0.23)、および車両No.24(0.50 → 0.21)で大幅な精度向上が確認された。これらのうち2台の結果は図9に示しており、転移を行わなかった場合には、将来1年のトレンド傾向の予測を外す傾向が見られたが、提案手法を適用することで改善された。残る1台も同様である。

以上の結果から、本手法は使われ方の変化などにもとれないトレンド傾向を外す場合に対し、とくに高い効果を示す可能性が示唆された。

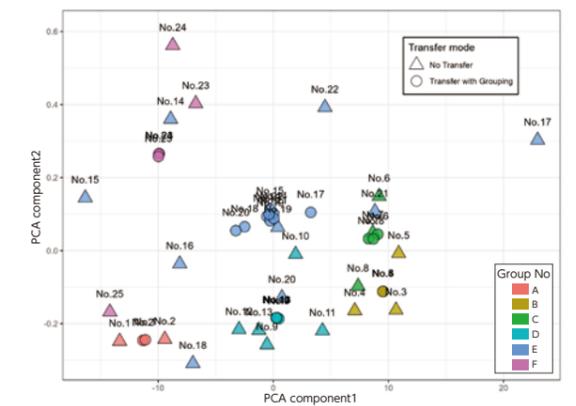


図8. PCAを用いて9次元のモデルパラメータを2次元に射影した図: 色はグループを表し、△は転移なし、○はグルーピングあり転移を示す
Fig.8 Visualization of the nine model parameters in a two-dimensional space using PCA

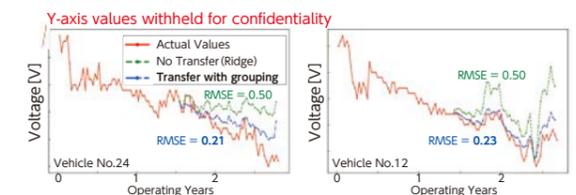


図9. 予測精度が最も向上した車両No.24とNo.12の観測値と予測値の時系列プロット: 年単位のトレンド傾向の予測を外していたケースにおいて、予測精度が大きく改善された
Fig.9 Time series plot of observed and predicted values for vehicle 24 and 12, which showed the greatest improvement in prediction accuracy. The trend improved.

6 まとめ

本研究では、燃料電池フォークリフトの稼働データに対して、使われ方の類似性を考慮した転移学習の枠組みを提案し、予測モデルの性能向上を実現した。従来手法では、車両ごとの使用傾向の違いにより予測精度にばらつきが生じ、特定の車両では年単位のトレンド傾向を外すケースも見られた。これに対し、本手法では使用傾向に基づくグルーピングを行い、グループ内でのみ知識を共有することで、「負の転移」を回避しつつ精度向上を図った。

提案手法は、従来手法であるRidge回帰と比較して、予測誤差の平均を16%、標準偏差を31%削減する効果を示した。とくに、年単位のトレンド予測を外していたケースでは、誤差を最大58%削減するなど、顕著な改善が確認された。

本技術は、使われ方が多様な産業車両の現場において、予測精度の向上を通じて予防保全の実現を支援する有効な手法であると考えられる。今後は、より長期間のデータや異なる製品ラインナップへの適用を視野に入れ、本手法の頑健性と汎用性の検証を進めていく予定である。

謝辞

本研究の指導を頂いた産業技術総合研究所の赤穂氏、本村氏、佐々木氏、有益な議論を頂いたALラボの皆様、ならびに本研究を進める機会を頂いたトヨタL&Fカンパニー H2プロジェクト、先行開発部、ITデジタル推進部含む社内のすべての皆様へこの場を借りて感謝の意を表します。

参考文献

- [1] W. He, T. Liu, W. Ming, Z. Li, J. Du, X. Li, X. Guo, and P. Sun, "Progress in prediction of remaining useful life of hydrogen fuel cells based on deep learning," *Renew. Sustain. Energy Rev.*, vol. 192, pp. 114193, March 2024.
- [2] [神島 10] 神島敏弘: 転移学習, 人工知能学会誌 Vol.25, No. 4, pp. 572-580 (2010)
- [3] NIPS 2005 Workshop - Inductive Transfer: 10 Years Later, <http://iitrl.acadiau.ca/itws05/> (2005)
- [4] S. J. Pan and Q. Yang, "A survey on transfer learning," *IEEE Trans. Knowl. Data Eng.*, vol. 22, pp. 1345-1359, October 2010.
- [5] F. Zhuang, Z. Qi, K. Duan, D. Xi, Y. Zhu, H. Zhu, H. Xiong, and Q. He, "A comprehensive survey on transfer learning," in *Proceedings of the IEEE*, vol. 109, no. 1, pp. 43-76, January 2021.
- [6] K. Weiss, T. M. Khoshgoftaar, and D. Wang, "A survey of transfer learning," *J. Big Data*, vol. 3, 9, May 2016.
- [7] M. Rosenstein, Z. Marx, L. P. Kaelbling, and T. G. Dietterich, "To transfer or not to transfer," in *Neural Information Processing Systems*, 2005.
- [8] T. Giorgino, "Computing and visualizing dynamic time warping alignments in R: The dtw package," *J. Stat. Softw.*, vol. 31, pp. 1-24, August 2009

著者紹介



松浦 慶伍

開発の経緯と開発者の思い

当社のCSR重要課題の1つである「新たな価値の創出」に貢献すべく、本技術の開発に取り組みました。他車両の知識を活用するという「転移学習」のコンセプトは、当社産総研アドバンスト・ロジスティクス連携ラボに出向していた際、同研究所の赤穂 昭太郎氏からご教示いただいたものです。

転移学習は機械学習分野では一定の成熟を見せている技術ですが、自分と他者の共通性の混合度合いをバランスさせるため、類似度を定義することが課題でした。当初、何をもち「類似」とするのか見当もつかず、約30台の多変量データをさまざまな視点で眺める日々が続き、結果的に、波形を見るだけで車両の名前を当てられるようになったことは良い思い出です。

独自性と共通性をバランスさせる話は各所で見受けられますが、1つの視点だけで最適解が見える場合は少なく、多様な視点を持つことで徐々にその輪郭が見えてくる場合が多いと感じています。この教訓を活かしつつ、今後は研究開発分野に留まらず、ITを通じた組織全体の価値最大化に向けて貢献したいと考えています。