

時系列データと物理式の回帰による  
解釈可能な車両のエネルギー消費量推定手法A method for estimating vehicle energy that can be interpreted  
in terms of time series data and regression of physical equations森越 宥斗<sup>1)2)</sup> 西田 遼<sup>2)</sup> 大西 正輝<sup>2)</sup>  
Yuto Morikoshi Ryo Nishida Masaki Onishi

## 1 序論

電気自動車 (Electric Vehicle; EV) のエネルギー消費量を高精度かつ解釈可能な状態で推定する手法が求められている。自動車利用による CO<sub>2</sub> 排出量は、国内外ともに全体の約 16% を占めており、日本では自動車部門における CO<sub>2</sub> 排出量の約 40% がバスやトラック、タクシーなどの商用車に起因している。現在日本では、「2050 年カーボンニュートラル」の実現に向け、乗用車に加え商用車の電動化が推進されている [7]。商用車の EV 化が進むことで、電力需要の増加や充電タイミングの重複による電力システムの強化が必要となり、その結果として社会コストの増大が問題となる。また、運輸事業者は契約電力量の見直しや関連設備の導入・保守などのコストの増加が問題となる。これらの課題に対処するためには、電力需要を予測し、運行計画を最適化する必要がある。そのためには、EV のエネルギー消費量を正確に推定するモデルの開発が不可欠であり、推定精度とともに推定結果の正当性や計算方法の説明が求められる。

エネルギー消費量推定モデルは時空間的粒度に応じてマクロ、メソ、ミクロの 3 レベルに分類できる。1 回の移動における平均速度や、道路リンクごとの平均速度からエネルギー消費量を求める方法もあるが、本研究では 1 秒ごとの瞬間的なエネルギー消費量の推定方法を扱うミクロモデルに着目する。ミクロモデルは、瞬間的な速度や加速度、道路勾配などの走行情報を入力とするため、データ収集コストおよび計算コストは高いが、車両ごとの細かい挙動を考慮可能である [6]。そのため、ミクロモデルはより現実に近い推定が可能である。車両のミクロモデルは、物理式ベースのモデルとデータ駆動型のモデル、そしてこれらを組み合わせたハイブリッドモデルに分類できる。

物理式ベースのモデルは、動力学的特性から車両システムのエネルギー消費量を推定する。例えば、Fiori らは、車両の速度、加速度、道路勾配などの走行データから、物理式を用いて駆動力の計算を行い、さらにパワートレイン効率を考慮した上でエネルギー消費量を推定するモデルを提案している [3]。物理式ベースのモデルは、動力学的特性を考慮可能であり、広範な適用性を持つ。しかし、特定のシナリオやシステム条件に対する適応性が不足し、推定精度が低くなることがある。例えば、気温の変動によるバッテリーやエンジンの性能の変化や走行する道路の摩擦係数の違いなどが挙げられる。これらの要素はエネルギー消費量に影響を与える可能性があるが、物理式ベースのモデルではこれらの要素に適応することが困難である。

1) 金沢大学 Kanazawa University

2) 産業技術総合研究所 National Institute of Advanced Industrial Science and Technology (AIST)

データ駆動型のモデルは、大量の走行データをもとに、エネルギー消費量と入力変数の複雑な関係を捉えることが可能であり、推定精度を大幅に向上できる。Abdelaty らは、決定木モデルや勾配ブースティング木など複数の機械学習モデルを応用して、車両のエネルギー消費を高精度に推定する手法を提案した [1]。Chen らは、数秒前の車両の走行データを活用するために Long Short-Term Memory (LSTM) を用いた時系列処理を行い、高い精度で瞬間のエネルギー消費量を推定可能であることを示した [2]。データ駆動型のモデルは推定精度が高い一方で、モデルの解釈性は乏しく、物理式ベースのモデルと比較して、車両の動力学的特性が未活用であるという問題がある。

ハイブリッドモデルは、物理式ベースのモデルと機械学習を組み合わせたモデルである。物理式を活用しながら、機械学習により複雑なデータパターンをモデル化することができる。Xu らは、加速度の瞬時データを入力として、消費および回生状態の分類を機械学習により分類する手法を提案した。さらに、それぞれの状態で物理式ベースのモデルを用いてエネルギー消費量の推定を行うことで、エネルギー消費量の推定結果に解釈性を与えつつ、高精度に推定可能であることを示した [5]。

しかし、既存のハイブリッドモデルは、瞬時の走行データのみを用いており、過去の車両状態を考慮できていない。過去数秒間の車両状態を考慮することで、運転の傾向や車両状態をより詳細に表現することができる。

そこで、本研究では既存のハイブリッドモデルを拡張し、過去の車両状態を考慮するアプローチを導入する。特に、EV にはエネルギー消費状態と回生状態が存在する。ここで、回生状態とは、EV が減速時に運動エネルギーを電気エネルギーに変換することで、駆動用のバッテリーに回収する状態のことを示す。回生の度合いを示す回生係数は複雑なプロセスによって決定され、この回生係数を過去数秒間の走行情報からなる時系列データから推定することで、エネルギー消費量をより正確に推定できると考えられる。本研究では、これらの知見を踏まえ、時系列データを活用したハイブリッドモデルの有効性を示す。実験では、EV の 1 秒ごとの走行データとエネルギー消費量を計測したオープンデータセットを用いて、従来のハイブリッドモデルと比較することにより、時系列データを入力することの有効性を検証する。

## 2 問題設定

本節では、問題定義を示す。表 1 に本論文で用いる記号の説明を示す。本研究では、時刻  $t$  における車両の走行データを表す  $v_t$ ,  $a_t$ ,  $\theta_t$ ,  $m$ ,  $T_t$  と時刻  $t$  から過去数秒分のデータである  $A_t$ ,  $V_t$  が与えられた場合に EV の瞬間エネルギー消費量  $E_t$  を高精度かつ解釈性高く推定する手法を明らかにする。

表 1 記号の説明

記号	説明
$E_t$	時刻 $t$ における車両のエネルギー消費量 (kWh)
$v_t$	時刻 $t$ における車両速度 (m/s)
$a_t$	時刻 $t$ における加速度 (m/s <sup>2</sup> )
$\theta_t$	時刻 $t$ における道路勾配 (rad)
$A_t$	過去の加速度データ, $A_t = \{a_t, a_{t-1}, a_{t-2}, \dots\}$
$V_t$	過去の速度データ, $V_t = \{v_t, v_{t-1}, v_{t-2}, \dots\}$
$m$	車両の重量 (kg)
$T_t$	時刻 $t$ における外気温 (°C)

### 3 提案モデル

本節では、まず提案モデルの概要を説明する。次に、使用した物理式とハイブリッドモデルを説明し、提案モデルについて明らかにする。

#### 3.1 モデルの概要

本研究では、XGBoost により車両状態を分類する機能を導入した Xu らのモデル [5] に着目した。図 1 に EV のエネルギー消費量を推定する提案モデルのアーキテクチャを示す。まず、EV のエネルギー消費量の状態について、消費状態と回生状態の 2 つに分類する。この分類は、EV の瞬時の走行データと過去の走行データを入力とした XGBoost により行う。状態の分類後、消費状態に対してはエネルギー消費に関する物理式を、回生状態に対しては回生エネルギーに関する物理式を用いることで、それぞれの状態におけるエネルギー消費量を推定する。さらに、過去のデータを含む走行データから回生係数を推定する。この係数は、加速度、速度、および外気温といったデータを用いて、重回帰モデルを組み合わせた手法により計算される。これにより、回生エネルギーをより正確に推定することが可能となる。

#### 3.2 物理式の説明

本研究で構築したハイブリッドモデルは、Fiori によって提案された物理式 (1) に基づいてエネルギー消費量を推定する [3]。式 (1) は車両が進行するための車輪に働く駆動力を表現した物理式である。

$$P_t^{\text{Wheels}} = \left( ma_t + mg \cdot \cos(\theta_t) \cdot \frac{C_r}{1000} (c_1 v_t + c_2) + \frac{1}{2} \rho_{\text{Air}} A_f C_D v^2(t) + mg \cdot \sin(\theta_t) \right) \cdot v_t \quad (1)$$

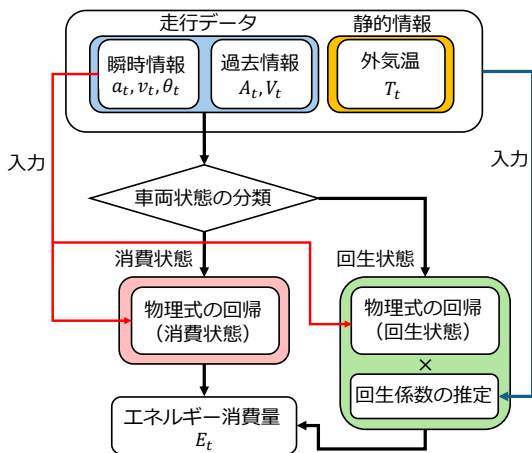


図 1 提案モデルのアーキテクチャ

ここで、 $P_t^{\text{Wheels}}$  は車両の駆動力 (kN)、 $g$  は重力加速度 (m/s<sup>2</sup>)、 $C_r$ 、 $c_1$ 、 $c_2$  は転がり抵抗係数、 $\rho_{\text{Air}}$  は空気密度 (kg/m<sup>3</sup>)、 $A_f$  は車両のフロント面積 (m<sup>2</sup>)、 $C_D$  は車両の空気抵抗係数である。

加速度  $a_t$  は、1 秒刻みで取得した車両速度を用いて式 (2) を用いて近似した値である。

$$a_t = v_t - v_{t-1} \quad (2)$$

車両のエネルギー消費量は  $P_t^{\text{Wheels}}$  に比例し、式 (3) として表現できる。ここでモーター効率、駆動系効率、およびその他のエネルギー損失を  $\eta$  とする。

$$E_t^{\text{con}} = \frac{1}{\eta} \cdot \frac{P_t^{\text{Wheels}}}{3600 \times 1000} \quad (3)$$

EV の消費エネルギーは式 (4) に示すように、速度、加速度、道路勾配の関数に変換することができる [5]。これは、転がり抵抗係数  $C_r$ 、 $c_1$ 、 $c_2$  や空気密度  $\rho_{\text{Air}}$ 、エネルギー損失  $\eta$  が定数であるという仮定に基づき、パラメータ  $\beta_0 \sim \beta_5$  と置くことによる。

$$E_t^{\text{con}} = \beta_0 + \beta_1 v_t \sin(\theta_t) + \beta_2 v_t \cos(\theta_t) + \beta_3 v^2(t) \cos(\theta_t) + \beta_4 v^3(t) + \beta_5 a_t v_t \quad (4)$$

EV のエネルギー消費量推定の際には、EV が減速時にエネルギー回生が発生することを考慮しなければならない。EV のエネルギー回生は式 (5) として表現できる。ここで  $k$  は回生係数であり、0 から 1 の値である。

$$E_t^{\text{reg}} = k \eta \cdot \frac{P_t^{\text{Wheels}}(t)}{3600 \times 1000} \quad (5)$$

EV の回生エネルギーは式 (4) と同様に速度、加速度、道路勾配の関数に単純化可能であるが、式 (6) に示すように回生係数を考慮する必要がある。

$$E_t^{\text{reg}}(t) = k(\beta_0 + \beta_1 v_t \sin(\theta_t) + \beta_2 v_t \cos(\theta_t) + \beta_3 v^2(t) \cos(\theta_t) + \beta_4 v^3(t) + \beta_5 a_t v_t) \quad (6)$$

式 (3) と式 (5) から、E 瞬時の消費エネルギーは式 (7) で表現できる。

$$E_t = \begin{cases} E_t^{\text{con}} \\ E_t^{\text{reg}} & \text{if } E_t^{\text{con}} < 0 \end{cases} \quad (7)$$

#### 3.3 ハイブリッドモデル

ハイブリッドモデルでは、まず消費と回生の 2 状態について機械学習を用いて分類を行う。次に、式 (7) を用いた物理式ベースのモデルにより、エネルギー消費量の推定を行う。

車両状態の分類を学習する際は、エネルギー消費量  $E^{\text{con}}$  が正である場合はラベル 0 (消費状態)、負である場合はラベル 1 (回生状態) を付与する。このラベルデータに対して、機械学習を用いて、速度と加速度、道路勾配の走行データを入力としたときにエネルギー消費量  $E^{\text{con}}$  が消費状態か回生状態かの分類を行う。

物理式ベースのモデルでは、学習の際にエネルギー消費量の正負でデータセットを分割し、それぞれの状態で推定を行う。具体的には、消費状態 (ラベル 0) と回生状態 (ラベル 1) のデータセットを個別に用い、それぞれのデータセットに対して学習を行う。

### 3.4 提案モデル

本研究では、入力データを時系列データに拡張することで、過去の走行データを考慮可能にし、車両の状態を正確に分類できるようにした。

また、エネルギー消費量の推定の際に、回生係数を時系列データから特定することで、より詳細に回生プロセスを表現できるように拡張を行った。図 2 に、回生係数を推定する方法を示す。まず速度と加速度の時系列データ  $A_t$ ,  $V_t$  からそれぞれ重回帰モデルにより 1 つの値を抽出する。さらに、抽出された速度と加速度のデータ、そして外気温  $T_t$  をそれぞれ重回帰モデルにより重み付けすることにより回生係数を推定する。また、Fiori らの研究によれば、回生係数は指数関数的に変化することが示されている [3]。したがって、回帰モデルの出力を指数関数に入力し、0 から 1 の値にスケールする。

## 4 実験

本節では、既存のハイブリッドモデルに対して、時系列データを入力可能にするものの有効性を検証する。以下、使用するデータセット、比較モデル、評価方法、結果について述べる。

### 4.1 データセット

オープンデータセットである Vehicle Energy Dataset (VED) [4] を用いて、実験を行う。VED に含まれるデータはアメリカのミシガン州で 2017 年 11 月から 2018 年 11 月までの約一年間、383 台の車両をモニターすることで収集されたものである。データは、1 秒間隔で取得された GPS の位置情報、燃料消費量や電力消費量、速度で構成される。ガソリン車、ハイブリッド車、プラグインハイブリッド車、EV の 4 種類のエネルギータイプの車両が含まれており、本研究ではそのうち EV のデータのみを抽出して使用する。ここで、VED に含まれる EV 車両は 2013 年製の日産リーフ 3 台である。データの前処理では、まずマップマッチングを行い、異常な位置情報、電流と電圧の欠落など、無効なデータを削除した。さらに Google Maps API により高度情報を取得し、得られた高度情報から勾配を計算した。前処理後の合計 665 トリップ、99923 秒分のデータを 3:1:1 の割合で訓練用データ、検証用データ、テスト用データに分割した。この際、トリップごとにまとめて分割を行った。

### 4.2 モデルの設定

提案モデルの学習方法の設定を述べる。訓練用データと検証用データを用いて、モデルの学習とハイパラメータのチューニングを行い、テストデータを用いて最

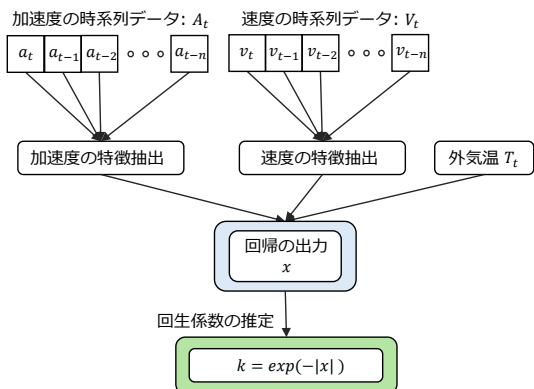


図 2 回生係数の推定方法

終的なモデル評価を実施した。

消費または回生状態の分類に用いる XGBoost の学習では、目的関数を binary logistic, 評価指標を error 率とした。また、決定木の数や学習率、正則化項などのハイパラメータを最適化した。物理式ベースのモデルの学習には、最適化手法として確率的勾配降下法を、損失関数として平均二乗誤差を使用した。さらに、学習率のスケジューリングを行いながら学習率の最適化を行い、過学習を防ぐために Early stopping を適用した。また、回生状態では、回生係数の推定結果と物理式ベースのモデルの出力の積をとることで同時に学習を行った。提案モデルのハイパラメータは、Optuna を使用して最適化した。

また、実験を通じて、XGBoost モデルの入力には、過去 8 秒分の走行データ、回生係数の推定においては、過去 6 秒分の走行データを使用することで最も高い精度が達成された。したがって、モデルの入力設定をこの条件に従って行った。

なお、動的に回生係数を推定する効果を検証するために、提案モデルにおいて回生係数が一定であるパターンについても推定精度の評価を行う。

### 4.3 比較手法

本節では、比較として既存の物理式を用いたモデルとデータ駆動型のモデルである LSTM について説明する。

- Power-based model**: Fiori が提案した駆動力の物理式を項ごとに分解し、速度、加速度、道路の勾配に単純化した式 (4) を用いて、係数  $\beta$  を特定することでエネルギー消費量を推定するモデル。
- State-classification + Power-based model [Xu<sup>+</sup>, 2023][5]**: Power-based model と XGBoost を用いた車両状態を分類機能を組み合わせたモデル。消費と回生の 2 状態について異なる Power-based モデルを学習することによって、エネルギー消費量を推定する。
- LSTM**: 2 つの LSTM 層と 2 つの全結合層の合計 4 層で構成したデータ駆動型のモデル。実験の結果最も精度がよくなった 8 秒分の走行データと外気温を入力に用いた。

### 4.4 評価方法

本研究では、評価指標として Root Mean Square Error (RMSE), Mean Absolute Error (MAE),  $R^2$  を用いる。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N (E_t - \hat{E}_t)^2} \quad (8)$$

$$\text{MAE} = \frac{1}{N} \sum_{t=1}^N |E_t - \hat{E}_t| \quad (9)$$

$$R^2 = 1 - \frac{\sum_{t=1}^N (E_t - \hat{E}_t)^2}{\sum_{t=1}^N (E_t - \bar{E}_t)^2} \quad (10)$$

ここで、 $\hat{E}_t$  は、それぞれエネルギー消費量の予測値である。また、 $N$  はデータの総数、 $\bar{E}_t$  は実際のエネルギー消費量の平均値を表す。

表 2 既存モデルとの精度比較

Model	RMSE	MAE	R <sup>2</sup>
Power-based	0.001663	0.001099	0.6917
[Xu <sup>+</sup> , 2023]	0.001647	0.001053	0.6976
<b>Proposed</b>	<b>0.001570</b>	<b>0.001002</b>	<b>0.7253</b>
w/o regeneration factor	0.001597	0.001020	0.7157
LSTM	0.001345	0.000830	0.7984

#### 4.5 結果

表 2 に各モデルでの推定精度を示す。表 2 から、提案モデルは物理式を活用した既存のモデルと比較して、すべての指標において優れた結果となった。このことから、既存のハイブリッドモデルについて、時系列データを考慮することで推定精度の向上ができると示された。

また、提案モデルと回生係数を動的に変更しないモデルとの比較により、走行状況で回生係数を動的に変化させることで推定精度が向上することが明らかとなった。

一方で、提案モデルは、データ駆動型の LSTM モデルと比較して推定精度が劣ることが確認された。ただし、LSTM のような高精度を示すデータ駆動型モデルは、その内部構造が複雑であるため、入力した特徴量の関係性や推定への寄与度を明確に示すことが難しい。このため、推定精度と解釈性はトレードオフの関係にある。提案モデルは、その出力が明確な数式として表現できるため、予測結果の解釈が容易である。表 3 に提案モデルの学習によって 2 つの車両状態 で得られたフィッティング結果を示す。表 3 に示すように、加速度、速度、道路勾配といった入力データがどのようにエネルギー消費量に影響を与えるかが数式によって示されるため、予測結果の背後にあるメカニズムを理解しやすい。

本研究で明らかとなったモデルの課題点として、車両の状態分類において、回生状態の分類の精度が低くなっていることが挙げられる。図 3 に示した車両の状態分類結果の混同行列から、回生状態における分類精度は、約 64% となっていることがわかる。この精度は、消費状態における分類精度の約 96% と比較して、非常に低くなっている。このことから、回生状態における分類精度を向上することで、エネルギー消費量の推定精度が大きく向上すると予測される。そのため、データの预处理や追加の特徴量を検討し、改善する必要があると考えられる。

#### 5 結論

本研究では、EV のエネルギー消費量推定において、既存のハイブリッドモデルに時系列データを考慮できるように拡張を行い、モデルの解釈性を保持したまま、時系列データが推定精度の向上に有効であることを検証した。その結果、既存のハイブリッドモデルについて時系列データを考慮できるようにすることで推定精度が向上

表 3 消費状態と回生状態における係数

Coefficient	Depleting	Regeneration
$\beta_0$ (intercept)	$2.64 \times 10^{-4}$	$9.05 \times 10^{-4}$
$\beta_1 (v_t \sin(\theta_t))$	$2.51 \times 10^{-4}$	$2.34 \times 10^{-4}$
$\beta_2 (v_t \cos(\theta_t))$	$3.27 \times 10^{-4}$	$-2.16 \times 10^{-4}$
$\beta_3 (v_t^2 \cos(\theta_t))$	$-1.80 \times 10^{-5}$	$7.37 \times 10^{-7}$
$\beta_4 (v_t^3)$	$4.04 \times 10^{-7}$	$6.03 \times 10^{-9}$
$\beta_5 (a_t v_t)$	$2.78 \times 10^{-4}$	$2.62 \times 10^{-4}$
R <sup>2</sup>	0.7302	0.6187

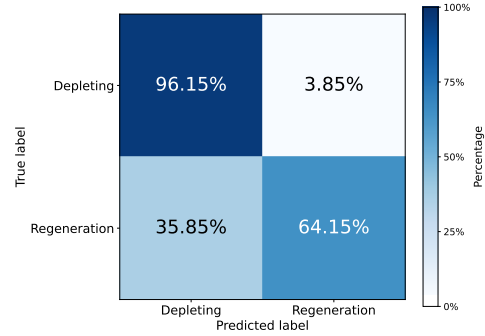


図 3 XGBoost による車両状態分類の混同行列

した。したがって、ハイブリッドモデルについても、正確なエネルギー消費量の推定には瞬時のデータだけでなく過去の走行情報が有効であることが明らかになった。

ただし、状況によっては、より高い精度が必要とされる場合があり、その場合には複雑なモデルが求められることもある。そのような場合には、適切な解釈手法やモデルの説明可能性を向上させるための研究が必要である。今後は、複雑なモデルの解釈性を高める手法の開発や、説明可能な AI の研究を進めることが重要であると考えられる。また、データ駆動型のモデルについて、モデルの解釈性を高めるために、物理法則にしたがった推定を行う Physics-informed-Model の開発をすることで、高い精度かつ物理法則に従っていることから、事業者が信頼できる推定結果を提案できると期待される。

#### 謝辞

この成果の一部は、国立研究開発法人新エネルギー・産業技術総合開発機構 (NEDO) の助成事業 (JPNP21028) の結果得られたものです。

#### 参考文献

- [1] Hatem Abdelaty, Abdullah Al-Obaidi, Moataz Mohamed, and Hany E.Z. Farag. Machine learning prediction models for battery-electric bus energy consumption in transit. *Transportation Research Part D: Transport and Environment*, 96:102868, 2021.
- [2] Yuche Chen, Yunteng Zhang, and Ruixiao Sun. Data-driven estimation of energy consumption for electric bus under real-world driving conditions. *Transportation Research Part D: Transport and Environment*, 98:102969, 2021.
- [3] Chiara Fiori, Kyoungso Ahn, and Hesham A. Rakha. Power-based electric vehicle energy consumption model: Model development and validation. *Applied Energy*, 168:257–268, 2016.
- [4] Geunseob Oh, David J. Leblanc, and Huei Peng. Vehicle energy dataset (ved), a large-scale dataset for vehicle energy consumption research. *IEEE Transactions on Intelligent Transportation Systems*, 23(4):3302–3312, 2022.
- [5] Hao Xu, Ran Tu, Tiezhu Li, and Haibo Chen. Interpretable bus energy consumption model with minimal input variables considering powertrain types. *Transportation Research Part D: Transport and Environment*, 119:103742, 2023.
- [6] Rui Zhang and Enjian Yao. Electric vehicles' energy consumption estimation with real driving condition data. *Transportation Research Part D: Transport and Environment*, 41:177–187, 2015.
- [7] 片野 博明 and 増井 利彦. 東京都の業務部門における 2030 年までの温室効果ガス排出量半減の達成シナリオの分析. *環境科学会誌*, 36(3):94–108, 2023.