

一般発表 | Track 5: 高度なデータ利活用・ドメイン応用 (医療情報, 教育, 地理情報等)

2026年2月28日(土) 9:30 ~ 11:40 | 会場

[1K] モビリティ

座長: 山本 修平(筑波大学) コメントータ: 渡辺 陽介(名古屋大学)

9:30 ~ 9:55

[1K-01] EVライフログに基づくタイヤとバッテリーの温度特性を考慮した事前エネルギー消費量可視化システム

*藤田 歩夢¹、劉 屹¹、中島 誠敬¹、唐戸 涼太¹、金 翔琢¹、本多 理矩¹、富井 尚志¹ (1. 横浜国立大学)

9:55 ~ 10:20

[1K-02] グラフニューラルネットワークを用いた未観測地点の交通状況推定手法

*田中 悠¹、笠松 大佑¹ (1. 創価大学)

10:20 ~ 10:40

[1K-03] SUMOを用いたデマンド交通における配車アルゴリズムのシミュレーション評価

*楊 美琪¹、神山 剛¹ (1. 長崎大学)

10:40 ~ 11:00

[1K-04] ANCOVA型回帰によるガソリン価格反映特性の地域比較

*堀内 敬太¹、佐野 光希¹、山崎 綾一郎¹、山岸 祐己^{1,2,3}、祝田 実⁴、祝田 龍一⁴ (1. 静岡理工科大学、2. 浜松医科大学、3. 株式会社良品計画、4. 株式会社ジャストサービス・ネット)

11:00 ~ 11:25

[1K-05] [技術報告] モビリティデータ利活用の現状と展望—自動車業界における生成AI/AIエージェントの活用—

*笹井 健行¹ (1. トヨタ自動車株式会社)

EV ライフログに基づくタイヤとバッテリーの温度特性を考慮した 事前エネルギー消費量可視化システム

藤田 歩夢[†] 劉 屹[†] 中島 誠敬[†] 唐戸 涼太[†] 本多 理矩[†]
金 翔琢^{††} 富井 尚志^{†††}

[†] 横浜国立大学 大学院環境情報学府 情報環境専攻 〒240-8501 神奈川県横浜市保土ヶ谷区常盤台 79-7

^{††} 横浜国立大学 理工学部 数物・電子情報系学科 〒240-8501 神奈川県横浜市保土ヶ谷区常盤台 79-5

^{†††} 横浜国立大学 大学院環境情報研究院 〒240-8501 神奈川県横浜市保土ヶ谷区常盤台 79-7

E-mail: †{fujita-ayumu-td,liu-yi-tk,nakajima-masataka-fh,karato-ryouta-cz,honda-riku-bz}@ynu.jp,
††kimu-shoutaku-bz@ynu.jp, †††tommy@ynu.ac.jp

あらまし 電気自動車 (EV) の長距離走行では、適切な充電計画やルート選択を行うために、走行前にエネルギー消費量を正確に予測することが重要である。特に冬季は、気温低下によって転がり抵抗やバッテリー性能が影響を受けることが知られている。我々の先行研究では、気温の影響を考慮したエネルギー消費量予測モデルを提示した。しかし、先行研究ではタイヤの固有特性の考慮や、モデルの検証が不十分であった。そこで本研究では、ライフログとして蓄積された走行データを用い、気温を説明変数としたタイヤ転がり抵抗係数を求めた。さらに、求めた転がり抵抗係数が正しいことを立証した。この結果を用いて、本研究ではSOC (State of Charge) の推移を、バッテリーの温度特性を考慮して可視化する。走行実験によって、本研究で提案した手法の有効性を検証した。

キーワード 電気自動車, CAN データ, 地理データ, 気象データ, エネルギー消費予測

1 はじめに

近年、気候変動問題が世界的な課題となり、脱炭素化と省エネルギー化の重要性が高まっている。特に、世界全体の CO₂ 排出量において最終需要部門の約 25% を占める運輸部門 [1] に対する対策が急務となっている。その対策の一つとして、電気自動車 (Electric Vehicle: EV) が注目されている [2]。EV は走行時に CO₂ を排出しないだけでなく、ライフサイクル全体における CO₂ 排出量も、同クラスのガソリン車と比べて約 6 割にとどまるという特徴がある [3]。

一方、EV は航続距離の短さや充電時間の長さ、さらに充電施設の少なさなどの問題がある。特に冬季の場合は、気温の低下により EV 全体のエネルギー消費が増加し、実際の航続距離が減少する傾向が示されている [4]。その原因として、転がり抵抗や空気抵抗の増加、内部抵抗の増加によるバッテリー容量の減少 [5, 6] がエネルギー消費に大きな影響を与えることが挙げられる。したがって、冬季の長距離移動を想定した EV 利用においては、事前に EV の消費電力を予測し、航続距離を正確に把握したうえで適切な地点で充電できるよう走行計画を立てる必要がある。

EV の構造はシンプルであるため、物理方程式を用いてエネルギー消費を予測することができる [7]。EV のエネルギー消費は主に速度、道路の勾配、および加減速によって決定される。この特徴を利用して、我々の先行研究では EV のエネルギーベースラインマップ (Energy Baseline Map: EBM) を提案した [8]。EBM は仮想定速走行 (Virtual Constant Velocity

Running: VCVR) により生成したもので、定速走行が可能な理想的条件下で、速度帯と道路勾配に応じて必要となるエネルギー消費量を地図上に示したものである。さらに我々の先行研究では、エアコン消費量や転がり抵抗の温度補正を考慮した EBM も提案してきた [9]。一方で先行研究は、一部の車両特性を外部文献に基づいてモデル化しており、個別車両に対するモデル内訳の妥当性が不十分であった。そこで本研究では、エネルギー消費推定のための以下の車種固有パラメータを、EV ライフログに基づいてモデル構築することを目標とする。

- モータ・インバータ総合効率
- 転がり抵抗の温度補正
- 満充電時におけるエネルギー量

これにより、実走行データに基づいて EBM を再構築し、説明妥当性と実用性を両立したエネルギー消費推定の枠組みを提案する。また、提案手法の有効性を実証するため、冬季の北海道で長距離走行実験を実施し、先行研究と比較した精度検証を行う。最後に、提案する予測モデルを利用することで、各地点におけるエネルギー消費量およびバッテリー残量 (SOC: State Of Charge) 推移の可視化を提案する。

本研究の意義は、以下の 2 つである。

- (1) **EV ライフログの活用による車種固有パラメータの補正**
本研究では、EV ライフログに基づき、車種固有パラメータである転がり抵抗係数や満充電時におけるエネルギー量の補正モデルを構築する。従来のような専用設備を用いた実験を必要とせず、蓄積された日常的な走行ログを活用するだけで、個人に特化した消費エネルギー推定モデルを構

築できる点に意義がある。

(2) 冬季の長距離走行支援に向けたエネルギー消費予測

構築した補正モデルを用い、走行前に消費エネルギーを予測・可視化するシステムを提案する。これにより、EVにとって厳しい冬季においても、EVの実用的な運用が可能であることを示す。また、事前の充電計画を支援し、運転者に資する情報提供を行うことに意義がある。

2 関連研究

近年、電気自動車 (EV) のエネルギー消費に関する研究が数多く報告されている。本章では、既存研究と比較することで、本研究の位置付けを示す。

Al-Wreikat ら [10] は、約 4 年間にわたって収集した 1,137 トリップ分の EV 実データを分析し、夏季に比べて冬季のエネルギー消費が最大 69.5%増加することを明らかにした。同様に、Yu ら [4] は EV の実データを用いて、高温条件下と低温条件下でエネルギー消費量がそれぞれ 19.82%と 67.3%増加し、さらに低温時にはバッテリー放電性能が大幅に低下することを示した。これらの研究では EV の実データを収集・分析しているが、気温の影響を考慮したエネルギー消費量の予測モデル構築までは至っていない。Song [11] は、外気温が 20°C から -7°C まで下がると、空気抵抗は約 10.1%増加し、転がり抵抗は約 54.8%増加することを示した。また、EV の実データから気温やタイヤ空気圧の影響を考慮した転がり抵抗係数のモデル構築を行ったが、実際の走行実験での検証までは行っていない。Ullah ら [12] は、EV の車両設計などの内部要因と、環境温度や勾配、運転スタイルなどの外部要因を統合的に考慮できる機械学習ベースのエネルギー推定モデルを提案したが、機械学習を用いているため、エネルギー消費要因の内訳がブラックボックスとなる欠点がある。Wang ら [13] は物理式を用いて道路情報、天候条件、運転行動を考慮した 2 種類の消費エネルギー推定モデル (オフライン/オンライン) を提案したが、これはトリップ単位のエネルギー消費を予測・評価する手法であり、距離ごとに消費エネルギーを可視化・推定する本研究とはアプローチが異なる。また、上記研究はいずれも EV のエネルギー推定モデルの精度評価に主眼を置いており、その結果を活用した実際の走行実験までは踏み込んでいない。

これらに対して本研究では、日常の走行で取得できるデータである EV ライフログを用いて、気温の影響を取り入れた EV のエネルギー消費予測モデルを構築する。また、走行の事前シミュレーションを実施することで、要因別消費エネルギーや SOC の推移を可視化する。これにより、ユーザはどの地点でどれだけのエネルギー消費が予測されるか、目的地到達の可能性や充電地点を走行前に把握できる。さらに、シミュレーションの結果を実際の冬季長距離走行実験と比較することで、本システムの有用性を検証する。

表 1: EV の駆動力に関わる変数

変数	単位	意味	データ取得方法
ρ	kg/m^3	空気密度	定数
μ	-	転がり抵抗係数	定数
g	m/s^2	重力加速度	定数
Cd	-	空気抵抗係数	カタログ値
A	m^2	車両前面投影面積	カタログ値
M	kg	車両重量	カタログ値
M_i	kg	慣性重量	車両総重量から換算
M_l	kg	積載重量	搭乗人数から換算
$v(t)$	m/s	車両速度	GPS 計測
θ	rad	道路勾配	地図
t	s	時刻	センサ計測時点

3 EV の消費エネルギー

3.1 物理式に基づく EV の駆動力による消費エネルギー

EV の駆動力 $F_{driving}$ [N] は、式 (1) のように 4 つの抵抗で表すことができる [7]。具体的には、加速抵抗 F_{acc} [N]、登坂抵抗 F_{slope} [N]、空気抵抗 F_{air} [N] および転がり抵抗 F_{roll} [N] である。

$$F_{driving}(t) = F_{acc}(t) + F_{slope}(t) + F_{air}(t) + F_{roll}(t) \quad (1)$$

また、4 つの抵抗はそれぞれ、式 (2)~(5) で表される。ただし、式中の変数は表 1 の通りである。

$$F_{acc}(t) = (M + M_i + M_l) \frac{dv(t)}{dt} \quad (2)$$

$$F_{slope}(t) = (M + M_l)g \sin \theta \quad (3)$$

$$F_{air}(t) = \frac{1}{2}\rho C_d A v(t)^2 \quad (4)$$

$$F_{roll}(t) = \mu(M + M_l)g \cos \theta \quad (5)$$

次に、駆動力 $F_{driving}$ [N] に対し、速度 $v(t)$ [m/s] をかけることで、車両が運動する際に必要なエネルギーの瞬時値 (仕事率 [W]) を算出できる。

$$P_{motor}^{physical}(t) = F_{driving}(t) \times v(t) \quad (6)$$

EV では電気エネルギーを駆動力に変換する過程でモータ・インバータ総合効率が生じる。この値は、モータの回転速度 $N(t)$ [rpm] とトルク $T(t)$ [Nm] によって決定される値であり、図 1 に示すグラフで説明されている。モータ・インバータ総合効率を用いて、力行時の EV の瞬時消費電力 $P_{battery}^{physical}(t)$ [W] を式 (7) で表すことができる。

$$P_{battery}^{physical}(t) = \frac{P_{motor}^{physical}(t)}{\eta(N(t), T(t))} \quad (7)$$

3.2 駆動力以外による消費エネルギー

自動車は駆動力以外に、エアコンや電装品によってもエネルギーを消費する。

自動車用空調システムは、車室内を快適に保つために、車室内外の環境条件に応じて動作が制御される [14]。そのため、EV のエアコン消費電力は外気温、湿度、日照条件などの気象要因に大きく影響を受ける。我々の先行研究では、ランダムフォ




図 1: モータ・インバータ総合効率 (文献 [7] より引用)

レストベースの EV のエアコン消費エネルギー推定モデルを構築した [15]. さらに, 5.2 節で説明する EBM-1 は, このモデルを用いて EV の走行時に生じるエアコンによる消費エネルギーを推定する.

電装品には, 常時使用される ECU (Electronic Control Unit, 電子制御装置) やカーナビと, 環境条件に応じて使用されるライトやワイパーがある. 消費電力は天気や時間帯で変動するが, 走行やエアコンに比べて絶対量は小さく, 同じトリップ内ではほぼ一定である. 以上より, 本研究では電装品の消費電力を一定 (250W) と仮定する¹.

3.3 EV ライフログ

本研究では, EV の日常的な走行中に取得できる GPS データと CAN² データを EV ライフログと定義する. 特に本研究では EV ライフログの中に含まれる ACC 機能を用いた定速走行データに注目する.

本研究では, 車種固有パラメータ推定のための学習データの作成や, EV 消費エネルギー推定モデルの評価を行うために CAN データを用いる. EV から取得した CAN データの内訳を表 2 に示す. ただし本研究では, モータトルクの値を式 (8) により補正して使用する [16].

$$T_{motor}^{measured} = 14.73 \times T_{motor}^{measured} - 1.29 \quad (8)$$

3.4 EV が気温の影響を受けるパラメータ

EV の消費エネルギーは, 走行条件や運転挙動だけでなく, 外気温の影響を受ける. 表 3 に, EV において気温の影響を受ける主なパラメータと, 気温低下時の変動傾向を整理する.

本研究では, これらの要因の中から特に転がり抵抗係数 μ と, 満充電時におけるエネルギー量 E_{full} [kWh] の 2 点に着目し, 温度補正モデルの構築を行う.

1: エネルギー消費量算出の際には [電装品の消費電力 (250W)] \times 時間の式を用いる. 時間はトリップ距離と定速走行速度から計算される. EBM は定速速度を前提とするため, 電装品による消費エネルギーはトリップ全域にわたって均等に現れる.

2: CAN は, 複数の ECU 間で通信を行う車載ネットワーク用に開発されたリアルタイム通信規格である.

表 2: EV から取得した CAN データの内容

変数	単位	意味
$V(t)$	V	バッテリー端の電圧
$I(t)$	A	バッテリー端の電流
$P_{aux}(t)$	W	電装品出力
$P_{ac}(t)$	W	エアコン出力
SOH	%	バッテリー劣化状態
SOC	%	バッテリー充電状態
T_{motor}	Nm	モータのトルク
GIDS	-	総電力量に相当する値
T_{amb}	°C	気温
$T_{battery}$	°C	バッテリー温度

表 3: EV が気温の影響を受ける主なパラメータ

変数	意味	気温低下時	主な理由
μ	転がり抵抗係数	増加	タイヤ硬化による損失増大
E_{full}	満充電時エネルギー量	減少	反応速度低下や内部抵抗増加
P_{ac}	エアコン消費電力	増加	暖房負荷の増大
R_{in}	バッテリー内部抵抗	増加	電解液粘性の増大
ρ	空気密度	増加	空気の収縮

まず, 転がり抵抗係数 μ については, 先行研究において温度補正を考慮した消費エネルギー推定を行った [9]. しかし, 従来のモデルでは特定のデータセットに対してオーバーフィットが生じていた点や, 検証が不十分であったという課題が残されている. そこで本研究では, EV ライフログを活用することで, 実走行環境における転がり抵抗の温度補正モデルを改めて構築する.

次に, 満充電時におけるエネルギー量 E_{full} についても補正を行う. リチウムイオンバッテリーは低気温環境下で取り出し可能なエネルギー量が減少する. これは, 単位時間あたりの消費電力の変動とは別に, 正確な航続距離推定において無視できない要因である. さらに, 実車のバッテリーは劣化による容量低下が生じる. これらの影響をモデルに組み込む.

以上の背景から, 本論文では EV ライフログを用いてこれら 2 つの変動要因を気温の関数として定式化し, エネルギー推定モデルへと組み込む手法を提案する. 空気密度やバッテリー内部抵抗の気温による影響の補正については, 今後の課題とする.

3.5 転がり抵抗の温度補正モデル

転がり抵抗は, タイヤの種類や摩耗, 路面舗装状態, 天候による路面状況の変動だけでなく, 気温の影響も受ける. ISO28580 規格 [17] によれば, 転がり抵抗と気温の関係は以下の式 (9) で示すことができる. 式 (9) は, 気温が T_{amb} [°C] における転がり抵抗 F_r [N]³ と, 基準となる 25°C における転がり抵抗 F_{r25} [N] との関係を示す. したがって, 式 (9) に基づき, 式 (5) の転がり抵抗係数 μ の温度補正を行うことができる (式 (10)). 式 (10) において μ_{25} は基準となる 25°C における転がり抵抗係数を表す.

$$F_{r25} = F_r [1 + K_t (T_{amb} - 25)] \quad (9)$$

$$\mu(T_{amb}) = \frac{\mu_{25}}{[1 + K_t (T_{amb} - 25)]} \quad (10)$$

3: 式 (9) の F_r は, 式 (5) における F_{roll} に相当する.

μ_{25} はタイヤと路面の組み合わせで決まる値である。また、温度補正係数 K_t は気温がタイヤに与える影響の度合いを表す値である。4.2節では、これら2つの値をEVライフログから同定する手法について述べる。

3.6 EVの内部データに基づく消費エネルギーと満充電時におけるエネルギー量

EVの走行によるバッテリー端出力 $P_{battery}^{measured}(t)[W]$ およびモータ端出力 $P_{motor}^{measured}(t)[W]$ は、表2の値を使用して式(11)、(12)のような計算により取得できる。

$$P_{battery}^{measured}(t) = I(t) \times V(t) - (P_{ac}(t) + P_{aux}(t)) \quad (11)$$

$$P_{motor}^{measured}(t) = \frac{2\pi T_{motor}(t) N_{motor}(t)}{60} \quad (12)$$

モータはタイヤと減速機を通じてつながっているため、モータの回転速度 $N_{motor}(t)$ は減速比 u を用いて式(13)で表される。

$$N_{motor}(t) = u N_{tire}(t) \quad (13)$$

また、タイヤの回転速度 $N_{tire}^{measured}(t)[rpm]$ はタイヤ周 $L[m]$ と車速 $v(t)_{measured}[m/s]$ を用いて式(14)で表される。

$$N_{tire}(t) = \frac{60v(t)}{L} \quad (14)$$

走行開始から t 秒経過した時点での消費エネルギー量 $E_{cumulated}(t)[kWh]$ は、式(15)で求められる。

$$E_{cumulated}(t) = \int_0^t P_{battery}(\tau) d\tau \quad (15)$$

ここで、EVの満充電時におけるエネルギー量を $E_{full}[kWh]$ 、走行途中で充電をした場合の充電量を $E_{charge}[kWh]$ とおくと、エネルギー残量 $E_{remaining}(t)[kWh]$ は式(16)で表される。

$$E_{remaining} = E_{full} - E_{cumulated} + E_{charge} \quad (16)$$

実際の多くのEVでは、バッテリー残量を直感的に把握するために、SOC[%]という指標が用いられる。SOCはバッテリー残量をパーセンテージで示したものであり、ユーザはこの指標を見てバッテリー残量を判断する。そこで、本研究では式(17)を用いてバッテリー残量 $E_{remaining}$ からSOCを変換する。

$$SOC = \frac{E_{remaining}}{E_{full}} \times 100 \quad (17)$$

ここで、満充電時におけるエネルギー量 E_{full} は、バッテリー温度とバッテリー劣化の影響を受ける。本研究で扱う満充電時エネルギー量には3種類の指標が存在する。それぞれの意味や関係を以下に整理する。

- E_{rated} : 定格満充電時エネルギー量
新車かつ常温状態における満充電容量
- $E_{full}(t, T_{battery})$: 実満充電時エネルギー量
経過時間 t によるバッテリー劣化と、バッテリー温度 $T_{battery}$ による影響を受けて変動する実際の満充電容量。
- $\tilde{E}_{full}(T_{battery})$: 劣化補正済み満充電時エネルギー量
バッテリー劣化の影響を取り除き、バッテリー温度 $T_{battery}$ のみによる変動を評価するための指標。




図2: 予備実験の結果

表4: 路面Aにおける予備実験の結果

使用タイヤ	μ_{25}	K_t	R^2
夏タイヤ	0.011	0.018	0.97
スタッドレスタイヤ	0.011	0.012	0.94

EVライフログとして、 E_{full} とバッテリー劣化の指標であるSOHを、さまざまな温度条件および劣化状態で取得することができる。これらの値を用いることで、劣化の影響を補正した \tilde{E}_{full} を求めることが可能である(式(18))。

$$\tilde{E}_{full}(T_{battery}) = \frac{E_{full}(t, T_{battery})}{SOH(t)} \times 100 \quad (18)$$

4.3節では、実際のEVライフログを用いて \tilde{E}_{full} とバッテリー温度 $T_{battery}$ の関係を分析し、温度補正モデルの構築を行う。

4 外気温を用いた車種固有パラメータの補正

本章ではEVライフログを用いて、転がり抵抗係数 μ および満充電時におけるエネルギー量 E_{full} の温度補正モデルの構築を行う。

4.1 転がり抵抗係数測定予備実験

4.2節では、EVライフログを用いて転がり抵抗係数 μ を推定する。その推定精度を検証するためには、基準となる μ が必要となる。そこで本研究では、低速走行による惰行走行実験を実施し、実験的に μ を算出した。

本実験は、舗装状態の異なる2種類の路面(路面A, 路面B)上で実施した。路面Aは粗い舗装, 路面Bは良好な舗装状態である。実験には表6に示すタイヤを使用し、変速機をニュートラルに設定した低速惰行走行を複数回行った。惰行中の車速変化から減速度を算出し、空気抵抗および勾配の影響が小さい条件下では転がり抵抗が支配的であると仮定して、転がり抵抗係数 μ を求めた。本実験を複数の外気温条件で実施し、各条件における μ を算出した。

得られた結果を図2に示す。また、得られた μ に対して式(10)におけるパラメータ μ_{25} および K_t を同定した結果を4に示す。

図2における路面Aについて2つのタイヤの傾向を見ると、どちらも気温の影響を受けていることが確認された。一方で表4を見ると、気温の影響の受けやすさを表す K_t はタイヤごとに異なることが確認された。

次に図2における夏タイヤについて2つの道路の傾向を見ると、同一の外気温条件においても μ に差が生じていることが確認された。この差は、主として路面舗装状態の違いによるものと考えられる。次節ではEVライフログから μ を推定するが、その際に得られる μ が路面Aおよび路面Bにおいて測定された範囲内に収まっていれば、推定結果として妥当であると判断する。なお、両道路においては同一温度条件下でも μ に最大で約0.003程度の差が生じており、本研究における μ の推定には、この誤差を含むことは避けられない。路面舗装状態が μ に及ぼす影響については、今後の課題とする。

4.2 転がり抵抗係数の温度補正モデルの構築


本節では、EVライフログのうち定速走行区間に着目し、式(10)における μ_{25} および K_t を同定するための方法について述べる。

EVライフログ内で i 回目に記録された定速走行区間において、一定速度 v_c [m/s] の状態で n 点の走行データが得られたとする。このとき、各時刻 t_j における転がり抵抗係数 $\mu(t_j)$ は、モータ端出力から、物理式によって計算される空気抵抗と登坂抵抗を差し引いた値を基に、式(19)のように推定できる。


$$\mu_i(t_j) = \frac{P_{\text{motor},i}^{\text{measured}}(t_j) - P_{\text{air},i}(t_j) - P_{\text{slope},i}(t_j)}{(M + M_t)g \cos \theta_i(t_j) v_c} \quad (19)$$

ここで、1回の定速走行区間内では路面状態が大きく変化しないと仮定する。このとき、同一走行 i において各時刻 t_j で算出された $\mu_i(t_j)$ は、本来ほぼ一定値をとると考えられる。しかし、実際にはセンサ誤差や瞬間的な外乱の影響によりばらつきが生じる。そこで、本研究では走行 i に対する代表値となる転がり抵抗係数 μ_i を、各時刻 t_j で求めた $\mu_i(t_j)$ の中央値として定義した。中央値を用いることで、外れ値の影響を抑え、定速走行区間における代表的な転がり抵抗係数を推定することができる。これらの推定された μ を用いて式(10)におけるパラメータ μ_{25} および K_t を最小二乗法により同定する。

図3(a)に、夏タイヤにおける推定 μ と、同定した温度補正モデルの結果を示す。同様に、図3(b)には、スタッドレスタイヤ走行時の推定 μ および補正モデルを示す。また、各タイヤに対して同定された μ_{25} および K_t の値を表5にまとめる。表4と表5を比較すると、EVライフログから推定した μ は、実験により得られた値とおおむね一致していることが分かる。さらに、図3(a)に示すように、舗装状態の異なる2種類の実験道路で得られた μ の範囲内に、EVライフログによる推定値が概ね収まっていることが確認できる。以上の結果から、本手法による転がり抵抗係数 μ の推定の妥当性が示された。これにより、実走行データに基づいた μ の温度補正モデルの構築が可能となった。得られたパラメータは、5章における長距離走行データを用いた消費エネルギー予測および精度評価において使用する。



(a) 夏タイヤ



(b) スタッドレスタイヤ

図3: EVライフログより推定した μ の分布と温度補正モデル

表5: 同定された温度補正モデルのパラメータ

使用タイヤ	データ件数	μ_{25}	K_t	R^2
夏タイヤ	205	0.010	0.016	0.63
スタッドレスタイヤ	91	0.010	0.011	0.63

4.3 満充電時におけるエネルギー量の温度補正モデルの構築

本節では、 \tilde{E}_{full} のバッテリー温度による影響をモデル化する。本実験車両には、Leaf Spy Pro の仕様書⁴において、EVバッテリーの残量とされる GIDS という指標がある。GIDS とはクーロンカウンティング法で計測された値とされ、日産 LEAF ではこの項目の値を利用して SOC や走行可能距離を計算しているとされる。GIDS を用いると、バッテリー残量 $E_{remaining}$ [kWh] は式(20)により求められる。

$$E_{remaining} = \text{GIDS} \times 0.0775 \quad (20)$$

ここで、満充電時 (SOC = 100%) に着目すると、 $E_{remaining}$ は E_{full} を表す。式(18)を用いて求めた \tilde{E}_{full} とバッテリー温度 $T_{battery}$ の関係および回帰直線を図4に示す。図より、 \tilde{E}_{full} がバッテリー温度 $T_{battery}$ の影響を受けていることが確認された。

本解析で用いたデータは、前日の充電終了から十分な時間が経過し、バッテリー温度 $T_{battery}$ と気温がほぼ一致している時

4: "LeafSpy Pro Help Version 1.3.10 (iOS)", Turbo3, <https://leafspy.com/wp-content/uploads/2024/04/LeafSpy-Help-1.3.10-iOS.pdf>, 参照 2026/03/17.


図 4: \tilde{E}_{full} とバッテリー温度の関係

表 6: タイヤの使用期間

使用タイヤ	製品名称 (型番)	使用期間
夏タイヤ	BRIDGESTONE REGNO GR-XIII	2025 年 2~12 月
スタッドレスタイヤ	BRIDGESTONE BLIZZAK VRX3	2023~2025 年の冬季

点のものである。そのため、バッテリー温度 $T_{battery}$ は外気温 T_{amb} と等しいとみなし、以降の補正モデルでは入力として気温を用いる。

なお、リチウムイオンバッテリーの温度特性は本来非線形であり、内部抵抗や電極反応の温度依存性により複雑な挙動を示す。しかし、本研究で得られた温度範囲に限定すると、 \tilde{E}_{full} は温度に対して概ね線形に増加する傾向を示した。そこで、本研究ではこの観測範囲において一次関数による近似を採用し、温度補正モデルを式 (21) のように構築する。

$$\tilde{E}_{full} = 0.079 \times T_{amb} + 59.21 \quad (21)$$

5 実走行データを用いた精度検証

5.1 使用車両

本研究では、日産 LEAF ZAA-ZE1 型 (グレード: e+ AUTECH) を用いて EV の実走行に基づく CAN データを取得した。ただし、使用期間中にタイヤを交換している。各期間におけるタイヤの種類を表 6 に示す。また、諸元表より、本車両における $E_{rated} = 62 \text{ kWh}$ である。

5.2 EBM

我々の先行研究では、EV のエネルギーベースラインマップ (EBM) を提案した [8]。これはある道路の走行で必ず必要となる最低限のエネルギーを地図上に可視化したものであり、定速走行時のエネルギー消費に基づく。定速走行は、加減速による余計なエネルギー消費を発生させないため、EV にとって理想的な走行の一つといえる。先行研究では、一定速度と道路勾配のみを考慮した EBM に対して、拡張した以下のモデルを提案してきた [9]。

- (1) EBM-1: エアコン消費量を考慮した EBM
- (2) EBM-2: 転がり抵抗の温度補正を行った EBM
- (3) EBM-3: (1) と (2) の両方を考慮した EBM




図 5: EV ライフログに基づくモータ・インバータ総合効率 (先行研究 [16])

表 7: EBM-3 作成条件

道路名称	日付	始点	終点	距離 [km]	想定速度 [km/h]	気温 [°C]
Road1	2025/12/20	札幌	北見	307	60~80	3~7
Road2	2025/12/21	北見	稚内	376	60~80	-1.5~1.5
Road3	2025/12/22	稚内	札幌	329	60~80	-5~-1

一方で、先行研究 [9] における EBM では、モータ・インバータ総合効率として文献 [7] に基づく効率マップを用い、その前提のもとで転がり抵抗の温度補正モデルを構築していた。これに対し本研究では、先行研究 [16] で提案された EV ライフログに基づくモータ・インバータ総合効率マップ (図 5) を用いるとともに、本研究でモデル化した転がり抵抗の温度補正を用いた EBM を提案する。また本章では、先行研究と本研究のモデルの精度検証を行い、比較する。

5.3 実験道路

本研究で提案する EBM-2 の精度検証を行うため、2025 年 12 月 20 日から 22 日に北海道において 3 回の長距離走行実験を実施した。EBM-2 を作成したルートを図 6 に示す。また、具体的な EBM-2 作成条件を表 7 に示す。



5.4 検証結果

先行研究 [9] および本研究の EBM-2 に基づく予測と、実際に走行を行った結果を図 7 に示す。また、数値での詳細を表 8 にまとめる。本研究では、EBM-2 に基づく推定消費エネルギーと実測消費エネルギーの差を評価するために、相対誤差 ε_r [%] を式 (22) で定義する。

$$\varepsilon_r = \frac{E_{EBM} - E_{CAN}}{E_{CAN}} \times 100 \quad (22)$$

ここで、 E_{EBM} は EBM-2 に基づく推定消費エネルギー量、 E_{CAN} は実測消費エネルギー量を表す。

結果より、Road1 は先行研究の方が精度が高いものの、Road1 と Road3 は本研究の予測と実測値がおおむね一致していることが確認された。先行研究ではモータ・インバータ総合効率に文献値を用いていたのに対し、本研究では効率マップと転がり抵抗の温度補正モデルの双方を、同一車両の EV ライフログの

(a) EBM による累計消費エネルギー量 $E_{cumulated}$ の推移の様子

(b) EBM による SOC 推移の様子

図 8: EBM の例

8(b)において、横軸には主な充電スポットの位置を示しており、想定される充電量および充電後の走行可能距離も併せて可視化している。これにより、どの地点でどの程度充電を行えば目的地まで到達可能かを、走行前の段階で把握することができる。

7 まとめと今後の課題

本研究では、日常走行により取得可能な EV ライフログを用いて、タイヤの転がり抵抗係数 μ および EV バッテリーの満充電時におけるエネルギー量 E_{full} の温度補正モデルを構築した。さらに、これらの補正モデルをもとに、北海道における冬季長距離走行を対象として出発前の消費エネルギーを予測し、実走行結果との比較検証を行った。

その結果、提案手法は先行研究と同等の予測精度を維持しつつ、EV ライフログに基づいて車両固有の特性を同定するモデル構築の枠組みを実現できた。すなわち、外部文献値に依存することなく、実走行データからモデルを再構築した上で実用的な精度を確保できた点に、本研究の意義がある。

一方で、冬季条件下では降雪や圧雪等による路面状態の変化により転がり抵抗が大きく変動する可能性があることが示唆された。本研究では気温を主要な説明変数として補正を行ったが、路面状態や降雪量、風況などの外的要因を考慮することで、さらなる精度向上が期待される。これらを統合した拡張モデルの構築を今後の課題とする。

謝 辞

本研究の一部は横浜国立大学人工知能研究拠点学長裁量経費の支援による。道路勾配データ作成の一部については、株式会社ゼンリンデータコムの「いつも Navi API」から取得した道路標高データを用いた。

文 献

- [1] International Energy Agency. Analysis - Transport, 2022. Last accessed: 12 December 2023.
- [2] 経済産業省資源エネルギー庁. 令和 2 年度エネルギーに関する年次報告 (エネルギー白書 2022), Last accessed: 22 July 2022.
- [3] 黒川文子. EV へのシフトと CO₂ 排出量に関する考察. 環境共生研究, No. 11, pp. 25–36, 2018.
- [4] Hanzhengnan Yu, Yu Liu, Jingyuan Li, and Tieqiang Fu. Investigation of energy consumption characteristics of electric passenger car under high and low temperature conditions. *2020 5th ACPEE*, pp. 742–746, 2020.
- [5] Jerzy Ejsmont, Stanislaw Taryma, Grzegorz Ronowski, and Beata Swieczko-Zurek. Influence of temperature on the tyre rolling resistance. *International Journal of Automotive Technology*, Vol. 19, pp. 45–54, 2018.
- [6] Jerzy Ejsmont, Grzegorz Ronowski, Wojciech Owczarzak, and Slawomir Sommer. Temperature influence on tire rolling resistance measurements quality. *International Journal of Automotive Technology*, Vol. 23, pp. 109–123, 2022.
- [7] 廣田幸嗣, 小笠原悟司. 電気自動車工学. 森北出版, ISBN9784627743120, 2017.
- [8] Yi Liu, Sayoko Soga, Xin He, Yuto Tanaka, and Takashi Tomii. Design of an electric vehicles' energy baseline map and application for energy consumption analysis. *DASFAA 2024*, pp. 139–154, July 2024.
- [9] 何新, 劉屹, 田中悠斗, 中島誠敬, 唐戸涼太, 藤田歩夢, 富井尚志. EV の冬季長距離運転支援のための事前エネルギー消費量可視化システム. 情報処理学会論文誌データベース (TOD), Vol. 18, No. 4, 2025.
- [10] Yazan Al-Wreikat, Clara Serrano, and José Ricardo Sodr . Effects of ambient temperature and trip characteristics on the energy consumption of an electric vehicle. *Energy*, Vol. 238, Part C, p. 122028, 2022.
- [11] Jingeun Song. Evaluation of driving resistance and energy consumption in electric vehicles under various ambient and tire temperatures using real-world driving data. *eTransportation*, Vol. 25, p. 100454, 2025.
- [12] Irfan Ullah, Kai Liu, Toshiyuki Yamamoto, Rabia Emhamed Al Mamlouk, and Arshad Jamal. A comparative performance of machine learning algorithm to predict electric vehicles energy consumption: A path towards sustainability. *Energy Environment*, Vol. 33(8), pp. 1583–1612, 2022.
- [13] Jiquan Wang, Igo Besselink, and Henk Nijmeijer. Battery electric vehicle energy consumption prediction for a trip based on route information. *Proc IMechE Part D: J Automobile Engineering*, Vol. 232(11), pp. 1528–1542, 2017.
- [14] カーエアコン研究会, 藤原健一. カーエアコン: 熱マネジメント・エコ技術. 東京電機大学出版局, ISBN9784501418403, 2009.
- [15] 何新, 劉屹, 曾我紗代子, 田中悠斗, 富井尚志. エアコン消費エネルギーを考慮した EV のエネルギー消費マップの作成と評価. WebDB 夏のワークショップ 2023, No. 2023-DBS-177(18), pp. 1–6, 9 2023.
- [16] 曾我紗代子, 劉屹, 田中悠斗, 何新, 富井尚志. EV ライフログを用いた EV のエネルギー消費推定モデルの提案と評価. 情報処理学会論文誌データベース (TOD), Vol. 17, No. 4, pp. 1–17, 10 2024.
- [17] International Organization for Standardization (ISO). Passenger car, truck and bus tyre rolling resistance measurement method — single point test and correlation of measurement results. Technical Report ISO 28580, 2018.
- [18] 七里祐輔, 劉屹, 曾我紗代子, 田中悠斗, 何新, 富井尚志. 空間サンプリングされた道路データのスキーマによる EV エネルギーライフログの有効活用. 第 15 回データ工学と情報マネジメントに関するフォーラム (DEIM2023), 5C-9-2, pp. 1–10, 3 2023.

グラフニューラルネットワークを用いた未観測地点の交通状況推定手法

田中 悠[†] 笠松 大佑[†]

[†] 創価大学大学院理工学研究科 〒192-8577 東京都八王子市丹木町 1-236

E-mail: [†]e25d5302@soka-u.jp, ^{††}dxk@ieee.org

あらまし 交通状況データの計測は地点が限られており、全ての地点で交通状況を把握することは難しい。既存の交通状況予測は完全教師あり学習が主流であり、未計測地点の混在を想定していない。本研究では未計測地点と計測地点が混在する場合に着目し、計測地点の交通状況から計測地点と未計測地点の交通状況を予測するモデルの構築に取り組む。学習手順に半教師あり回帰型を採用し、モデルに Graph Convolutional Network(GCN) に代表される構造的バイアスの獲得に特化した機構を組み込んだモデルを用いる。新宿駅周辺を対象に実験を行った結果、半教師あり回帰によって、過去数週間分の計測地点の交通状況から将来の未計測地点の交通量状況をベースラインより高い精度で予測することを確認した。

キーワード スマートシティ, 地理データ, 都市データ, グラフニューラルネットワーク, 交通

1 はじめに

交通分野における施策と交通状況調査の関係は強く、ビッグデータやディープラーニングを代表とする高度なデータ指向技術が発展する前の時代から、道路行政や交通計画の土台として利用されてきた [15], [16]。特に近年ではデータ指向技術の発展に伴い、都市部で観測されるあらゆる方面のデータを相互に利用することで各分野の機能を高度化する取り組みとして、アーバンコンピューティングの研究が進められている [13], [14]。交通分野においても、従来から利用されてきた都市間交通需要のような定常的でマクロな単位から見る交通状況だけでなく、交差点、車線合流部などの細かな地点ごとに、信号機の 1 サイクル時間の程の短さの、ミクロな単位で計測された交通状況データを活用していく事例が増えており [4], [8], [10]、応用の幅の広さから交通状況データはアーバンコンピューティングにおいて重要度を増している。

一方でミクロな交通状況をリアルタイムで計測し続けることは難しい。データを集める手段には、計測機器で構築された交通流計測システムにを用いて計測を行う方法と、個人の移動履歴から交通量を推定的に算出する HaaS (Human as a Sensor) の 2 つが存在するが [15]、いずれの手法にも網羅性の観点から制限がある。第一に交通流計測システムは設置と運用に要するコストの高さから広域を網羅的に観測することが難しい。日本で実運用されている警視庁の交通流計測システムにおいても、観測地点は都市部の一部のエリアや国道をはじめとする主要地点に限られている。また HaaS はモビリティ端末や交通車両に取り付けられた GPS(Global Positioning System) で計測した移動履歴を必要とするため、取得可能な団体は通信基盤を提供する事業者や、経路案内サービスを提供するサービスプロバイダなど一部の民間企業に限られる。

計測システムのハイコスト化問題はアーバンコンピューティングの文脈においても指摘されており [13]、対応策として完全




図 1 未計測地点を含む道路ネットワークにおける交通状況予測。

教師あり学習による補間手法 [7] が提案されている。しかしながら、完全教師あり学習による手法は既存のセンサーネットワークから不要な機器を減らすことによるコスト削減を目的としており、予測対象地点の計測データが存在することを前提とする。そのため既存システムの拡大には貢献しない。

そこで本研究では、計測地点と未計測地点が混在するネットワーク上において、グラフ構造を取り込む機構を持たせたディープラーニングモデルに半教師あり学習を適用し、回帰的に既存の計測データから過去データの存在しない未計測地点の交通量を推定する手法を設計することを目的とする (図 1)。

2 関連研究

GNN (グラフニューラルネットワーク). GNN (Graph Neural Network) はグラフ理論で発展したスペクトラル解析を応用したスペクトラル (Spectral GNN) 系、ノード間の結合に基づいて処理するスペーシャル (Spatial GNN) 系、注意機構を導入したアテンション (GAT: Graph Attention) 系の 3 つの系統を持つ。Spectral GNN はグラフ構造を行列として表現した隣接行列から算出されるグラフラプラシアン の性質を利用したモデルで、代表的なモデルにグラフ畳み込みニューラルネットワーク (GCN: Graph Convolutional Network) がある [6]。対して Spatial GNN はメッセージパッシングを基本とした方式であり、各ノードを隣接するノードの特徴量を用いて更新する。GAT は GCN の処理機構に注意機構を導入した処

理体系で、近接するノードや対象ノードの特徴量の値から動的に強く評価したいノードを選択し、対象ノードの値を更新する ([9], [3]).

ST-GCN(Spatio-Temporal Graph Convolutional Network) [12]. 時系列処理に特化したモジュールと GNN ブロックを組み合わせたモデルとして、ST-GCN(Spatio-Temporal Graph Convolutional Network) がある. ST-GCN では GNN ブロックとして採用された GCN と、時間系列ブロックとして 1 次元 CNN(Convolutional Neural Network) をベースにゲート機構を追加したゲート付き畳み込み層の 2 つが組み合わされて考案された、ST(Spatio-Temporal) ブロックが用いられており、モデル全体は ST ブロック 2 層と出力層で構成された. 過去の交通量データから未来の交通量データを予測する完全教師ありの課題において、予測精度の改善に成功している [12].

2.1 半教師あり学習

半教師あり学習は教師データが限られている状況で、モデルの最適化を行う際に適用される学習アルゴリズムである [11]. 教師あり学習と異なり、入力と出力の組に偏りなどがあり、一部の出力について正解データを用意できない場合に適用される. GNN はノードとノードの関係性から特徴量を更新するラベルプロパゲーション機構を持つことから、データの欠損を前提とした半教師あり学習による予測と高い親和性を持つことが指摘されている. 実際に GCN を用いて実施された半教師あり学習によるラベル予測において、その効果が確認された [6].

3 研究課題

複数のセンサーで構築された交通流量計測システムのオープンデータを用いて、計測地点と未計測地点の混在する道路ネットワークを想定し、それらの地点の未来の交通量を予測することを課題とする. 学習手順として半教師あり回帰の手順を採用し、モデルに道路ネットワークがもつ構造的な特性を取り込む機構と、計測地点と未計測地点でパラメータを共有する層を導入することで、教師データのない地点における交通状況予測の実現を試みる.

警察庁が運営する交通流量計測システムのオープンデータを利用して特性の異なるモデルを半教師あり回帰の手順で学習し、短期予測と長期予測の 2 つの検証シナリオで精度比較を通して、モデルの構造と学習手順が予測精度に与える影響を検証する.

4 提案手法

単位時間ごとに推移する交通状況特徴量 f_t について、事前に特徴量 f_t を取得できる計測地点 $v \in V_{source}$ と、取得できない未計測地点 $v \in V_{target}$ で構成される頂点集合 $V = V_{source} \cup V_{target}$ が道路ネットワーク構造に基づいて設定された接続関係 E によってグラフ $G = \{V, E\}$ を形成したとする. 入力単位時間ステップ数 t_{in} 個の計測地点の連続する特徴量 $f_{v \in V_{source}, t-t_{in}:t}$ から、続く目的単位時間ステップ数 t_{out} 個の全ての頂点の特徴量 $f_{v \in V, t+1:t+t_{out}}$ を予測するモデルを構築する.

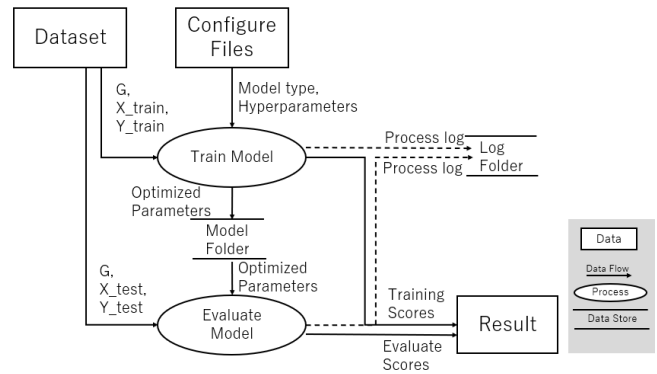


図 2 システム構成図.

4.1 システム構成と学習手順

グラフ G , 学習用の特徴量データ X_{train} と対応する正解データ Y_{train} , 検証用の特徴量データ X_{test} と対応する正解データ Y_{test} が存在するとき、モデル M を訓練し、精度を検証するシステムの全体像を図 2 に示す. 学習フェーズでは X_{train}, Y_{train}, G を用いて、予測モデルの半教師あり回帰学習を行う. このとき X_{train} のうち V_{target} に属する頂点に関する特徴量 $X_{train, target}$ の値はダミー値で代替する. また勾配計算に用いる損失関数 $\mathcal{L}(y, \bar{y})$ に渡す値は、 V_{source} に属する頂点に関する特徴量 $y_{source}, \bar{y}_{source}$ に限定する (式 1).

$$\text{TrainingLoss} = \mathcal{L}(y_{source}, \bar{y}_{source}). \quad (1)$$

検証フェーズでは X_{train}, Y_{train}, G を X_{test}, Y_{test}, G に置き換えて、頂点を限定せずに損失を算出する.

4.2 埋め込み層 (Embedding Layer)

未計測地点におけるパラメータ更新を促すため、入力層として未計測地点と計測地点でパラメータを共有する埋め込み層の導入を考案した. 埋め込み層の機構には 1 次元 CNN を採用する. 画像処理で用いられる 2 次元 CNN の場合、チャンネル方向の長さが C_{in} , 縦方向の長さが W , 横方向の長さが H である画像を処理するために、縦方向の長さが k_H , 横方向の長さが k_W , チャンネル方向の長さが C_{in} のカーネルを出力チャンネル数 C_{out} の数だけ持つ. このとき、入力チャンネルを交通状況特徴量 f , 縦方向を頂点 V , 横方向を時間 $t-t_{in}:t$ とみなし、カーネルサイズを頂点方向は 1, 時間方向は k_t , 出力チャンネル数は埋め込み後特徴量長に設定することで、共有カーネルを用いた埋め込みを実行することが可能となる. 特にストライド長とカーネルサイズ k_w を同じ大きさにすることで、時間方向の系列長を W/k_w に縮めることが可能である. 埋め込み層はカーネルサイズが異なる 2 層の 1 次元 CNN で構成する.

4.3 近傍平均モデル, GCN モデル, ST-GCN モデル

計測地点の特徴量データから計測地点, 未計測地点の特徴量を予測する予測モデルとして近傍平均モデル, GCN モデル, ST-GCN モデルを使用する. モデルアーキテクチャを図 3 に示す.

近傍平均モデル. グラフ構造を考慮した未計測地点の交通状況予測のベースラインとして近傍平均モデルを定義する. 入力

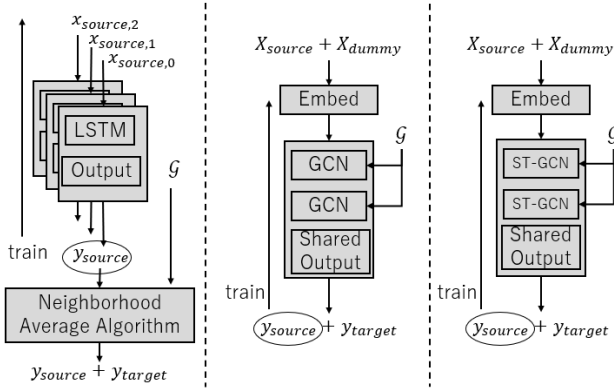


図3 モデルアーキテクチャ。(左) 近傍平均モデル, (中央)GCN モデル, (右)ST-GCN モデル.

特徴量を時系列データとみなし, 計測地点ごとに異なる予測モデルを対応させ, 過去の交通状況から出力単位時間ステップ数 t_{out} 先までの該当地点の特徴量を予測するモデルを構築する. 計測地点ごとの予測モデルは, 時系列データ処理に特化したモデルとして評価のある LSTM(Long Short Term Memory) [5] を採用する. なお出力層は全結合層とする. 未計測地点の予測値には, 隣接する計測地点の予測値の平均値を採用する.

$$y_{source,i} = \text{Output}_i(\text{LSTM}_i(x_{source,i})) \quad (2)$$

$$y_{target,j} = \text{Average}(y_{i \in \text{Neighbor}(j) \cap V_{source}}). \quad (3)$$

GCN モデル. グラフ構造を考慮する学習可能ブロックとして, 中間層に 2 層の Graph Convolutional Network(GCN) [6] を採用した Sequence to Sequence 型の予測モデルを設計した. 一度の推論で計測地点と未計測地点を含む全ての地点について出力単位時間ステップ数 t_{out} 先までの該当地点の特徴量を出力する. 入力層には埋め込み層, 出力層には各頂点でパラメータを共有する全結合層を配置した.

ST-GCN モデル. グラフ構造に加えて時間方向の特性を考慮するブロックとして, 中間層に 2 層の Spatio-Temporal Graph Convolutional Network [12] を採用した予測モデルを設計した. 入力層, 出力層には GCN モデルと同様に埋め込み層とパラメータを共有する全結合層を配置した.

5 実験

5.1 システム要件

実験システムとして, nvidia 製の汎用 GPU (RTX A5000) を搭載する ubuntu22.04 をインストールしたマシンに仮想空間を作成し, 仮想空間に Python, PyTorch, PyTorch Geometric を中心としたライブラリを導入した. 搭載した GPU の RAM サイズは 24GB, CPU は 24 コア 100MHz, メインメモリのサイズは 32GB である.

5.2 実験条件

警察庁の交通流量計測システムのセンサーのうち新宿駅周辺の 85 地点を対象に, ランダムに抽出した 17 地点を未計測地点として実験を行う. 交通状況特徴量は日本道路交通情報センターが公開する断面交通量を使用し [2], 接続関係は日本交通管



図4 新宿駅周辺の断面交通量観測地点.

理技術協会 [1] から取得した座標情報から手で設定する. 対象エリアを図 4 に示す. 断面交通量は 5 分ごとに計測される. 2023 年 8 月から 2024 年 5 月までを学習データ, 2024 年 6 月から 7 月までを検証データとする. 入力単位ステップ数は 14 日分に当たる $14 \times 24 \times 12$ とし, 出力単位ステップは 1 とする. 断面交通量に含まれていた欠損値は, 1 時間を基準に欠損期間が短い場合は時間方向で線型補間を行い, 欠損期間が長い場合には同一時刻の平均値で補間した.

学習時, 検証時に用いる損失関数 \mathcal{L} は平均二乗誤差 (MSE:Mean Squared Error) とする.

検証はモデルが 1 回の推論出力するステップ数までの値を用いて評価する短期予測シナリオ評価と, 出力値を再帰的に入力し, 1 日程度先まで予測させて得た値を用いる長期予測シナリオ評価の 2 パターンで行う. 評価スコアとして全体誤差 AllAreaLoss, 計測地点誤差 SourceLoss, 未計測地点誤差 TargetLoss の 3 つを算出する. 評価誤差を以下に示す. 式中の \parallel はテンソルの結合を意味する.

$$\text{AllAreaLoss} = \mathcal{L}(\bar{y}_{source} \parallel \bar{y}_{target}, y) \quad (4)$$

$$\text{SourceLoss} = \mathcal{L}(\bar{y}_{source}, y_{source}) \quad (5)$$

$$\text{TargetLoss} = \mathcal{L}(\bar{y}_{target}, y_{target}). \quad (6)$$

長期予測シナリオ評価では, 2024 年 6 月 1 日から 14 日までを第一の入力とし, 予測値のうち 1 ステップ分を前の入力の最後に追加して予測を再度実行する, という工程を繰り返すことで 1 日程度先までの予測値を出力する. 予測長は 1 日分 (288) と数余剰ステップ 18 時間分 (216) で計 504 ステップとする.

使用するモデルは近傍平均モデル, GCN モデル, ST-GCN モデルの 3 種とする. 学習率, エポック数, バッチサイズは 0.001, 5, 300 を基本とし, 近傍平均モデルのみ学習率を 0.005, エポック数を 15 に設定した.

また剪定実験として, 入力層を単純な全結合層に置き換えた GCN - Emb モデルを用意し, 埋め込み層によるパラメータ共有の効果を検証した.

5.3 実験結果

短期予測シナリオ, 長期予測シナリオにおけるモデルごとの

表 1 シナリオごとの各モデルの予測誤差 (MSE).

短期予測シナリオ	全体	計測地点	未計測地点
Neighbor Avg	280.912	197.835	613.220
GCN	550.269	443.778	976.233
ST-GCN	714.575	369.076	2096.573
GCN - Emb	525.277	448.783	831.254
長期予測シナリオ	全体	計測地点	未計測地点
Neighbor Avg	626.691	557.901	901.852
GCN	629.499	635.645	604.912
ST-GCN	602.733	304.451	1795.864
GCN - Emb	823.966	902.351	510.424




図 5 未計測地点 827 (宮下) における長期予測の結果.




図 6 計測地点 2259 (大久保二) における長期予測の結果.

予測精度を表 1 に示す. 評価指標は左から順に, 評価指標は全体誤差 AllAreaLoss, 計測地点誤差 SourceLoss, 未計測地点誤差 TargetLoss を指す.

5.4 短期予測シナリオにおける評価

評価指標を比較した結果, 全体, 計測地点, 未計測地点のすべての場合において近傍平均モデルの予測誤差が小さいという結果となった. 特に計測地点における精度が高く, 短期予測において過去データと正解値は強い結びつきを持つことが確認された. 一方で GCN モデルは, 予測誤差は近傍平均モデルよりも大きかったものの, 計測地点に対する未計測地点の精度比が 2.13 倍で, 精度比が 3 倍以上あった近傍平均モデルと比べて小さく, 計測地点と未計測地点での精度差が小さいことから, ノード間でのプロパゲーション機構が有意に働いたことを示す結果となった.

ST-GCN モデルは未計測地点における予測誤差が 2096 と最も大きく, 精度比は 5 倍あることから, 未計測地点における予測には向かない結果となった.




図 7 未計測地点における正解値と予測値の相関の強さ.

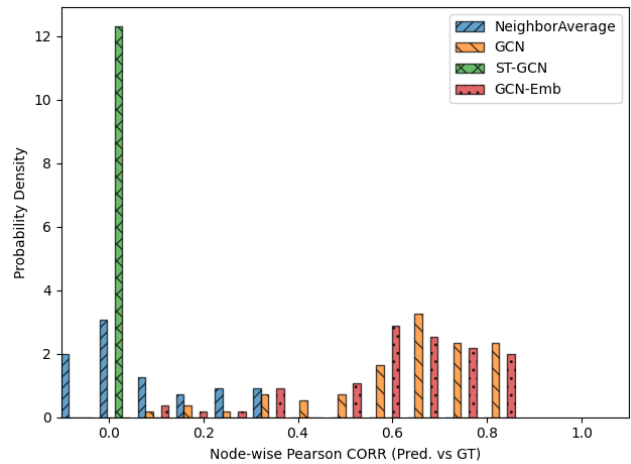


図 8 計測地点における正解値と予測値の相関の強さ.

5.5 長期予測シナリオにおける評価

再帰的な推論による長期間の予測を行った例として, 未計測地点 (宮下) と計測地点 (大久保二) における予測値の折れ線グラフを図 5, 6 に示す.

プロットの結果, GCN モデルのみ未計測地点と計測地点において長期間波形を再現することに成功した. 近傍平均モデルと ST-GCN モデルは 1 から 2 ステップ先までは予測可能であるものの, 以降は出力値が横ばいとなっており, 予測退化の発生を示す結果となった.

そこで予測退化の発生傾向を確認するため, 各モデルの出力と正解値との相関係数を算出した. 未計測地点, 計測地点においてモデルごとに各ノードの相関係数をヒストグラムとしてまとめた結果を図 7, 8 に示す. その結果, 近傍平均モデルと ST-GCN モデルにおいて相関係数が小さい傾向にあることが発覚した. 特に計測地点における相関係数の分布が低い値に寄っていることから, 未計測地点が持つノイズや半教師あり学習による影響ではなく, 採用したモデルの特性として予測退化が発生しやすい状態にあったと考えられる.

近傍平均モデルにおいて予測が退化した原因は, ベースとする LSTM が, 再帰的な予測を想定していないモデルであった可能性があげられる. 入力値のうち実測値の値が占める割合が

減ることで、入力ベクトル内に予測誤差を持つ値の割合が増加し、ベクトル内の値の分布が未知となった結果、モデルが安定解として定数を出力するようになったと考えられる。

また ST-GCN モデルにおいても同様に予測が退化したことから、ベースとする ST-GCN の時系列方向に対する分布の獲得度が高く、予測誤差による入力ベクトルの分布ずれに対応できなかつたと考えられる。

対して GCN モデルは、時系列予測特性を獲得する機能が構造的に弱いことが、結果として予測退化への耐性を持つこととなった。このことから、再帰推論によって長期予測を行う場合、時間方向での入力分布への依存度を小さくし、予測誤差による分布のずれに対応できるモデルを構築する必要がある。

5.6 剪定実験: 埋め込み層の評価

入力層として採用した埋め込み層を評価するため、GCN モデルと GCN-Emb モデルについて短期予測シナリオ・長期予測短期予測シナリオにおける予測誤差、長期予測のプロット、正解値と予測値の相関係数の強さの比較を行う。

短期予測シナリオにおける予測誤差を比較したところ、計測地点での精度が改善する一方で、未計測地点では予測精度が悪化することが確認された。未計測地点での予測精度は 140 ポイント近く悪化しており、計測地点での改善値と比べて大きいことから導入効果が小さく見える結果となった。一方で長期予測シナリオでは、未計測地点での精度悪化は 100 ポイント前後に収まっているにも関わらず、計測地点での精度改善は 200 ポイントを超えており、総じて計測地点での精度改善効果が高いといえる結果となった。

長期予測のプロットから、GCN モデルの予測値は GCN-Emb モデルの予測値と比較して小さくなる傾向があった。正解値に対して GCN モデルの値が高い値を予測している場合でも、GCN モデルが低い値を予測している場合でも、GCN-Emb モデルの予測値は GCN モデルの予測値よりも低い位置にあることから、埋め込み層の導入した結果、予測値が小さくなる方向にバイアスがかかるようになった可能性がある。

相関係数の分布からは大きな差分は読み取れず、予測退化の発生しやすさと埋め込み層の関係は小さいことが分かった。

6 まとめ

計測地点の情報から未計測地点の交通状況を予測する問題を定義し、半教師あり学習でモデルを学習する実験を行った。新宿駅周辺の 85 地点のうち 17 地点を未計測地点と仮定し、近傍平均モデル、GCN モデル、ST-GCN モデルについて、MSE を指標に精度を比較した。実験結果から数ステップ先は近傍平均モデルで、1 日分の予測であれば GCN モデルで予測可能であることが分かった。

また剪定実験の結果、入力層の時点で共有パラメータを持つことは、未計測地点の予測精度を悪化する傾向があるものの、計測地点における長期予測の安定に寄与する可能性が示された。

一方で近傍平均モデル、ST-GCN モデルにおいては予測誤

差が発生しており、時系列特性を獲得する機構と、再帰的推論におけるモデルの頑強性の間に強い関係があること、それは単純な平均事情誤差では評価しきれないことが示唆された。

今後の研究では、問題設定に即した精度指標の設定、パラメータ共有が精度差の改善に与える影響の調査、精度改善のための処理機構の作成が課題となる。

文 献

- [1] 断面交通量計測地点位置情報 (詳細版 b, 東京都), 公益財団法人日本交通管理技術協会. <https://www.tmt.or.jp/research/index9.html>.
- [2] 断面交通量情報, 公益財団法人日本道路交通情報センター. <https://www.jartic.or.jp/service/opendata/> (2023/11/4, 2023/12/6 2024/1/10 アクセス).
- [3] Shaked Brody, Uri Alon, and Eran Yahav. How attentive are graph attention networks?, 2022.
- [4] Austin Derrrow-Pinion, Jennifer She, David Wong, Oliver Lange, Todd Hester, Luis Perez, Marc Nunkesser, Seong-jae Lee, Xueying Guo, Brett Wiltshire, Peter W. Battaglia, Vishal Gupta, Ang Li, Zhongwen Xu, Alvaro Sanchez-Gonzalez, Yujia Li, and Petar Velickovic. Eta prediction with graph neural networks in google maps. In *Proceedings of the 30th ACM International Conference on Information & Knowledge Management, CIKM '21*, p. 3767–3776, New York, NY, USA, 2021. Association for Computing Machinery.
- [5] Sepp Hochreiter and Jürgen Schmidhuber. Long Short-Term Memory. *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780, 11 1997.
- [6] Thomas N. Kipf and Max Welling. Semi-Supervised Classification with Graph Convolutional Networks. *arXiv e-prints*, p. arXiv:1609.02907, September 2016.
- [7] Giuseppina De Luca and Mariano Gallo. The use of artificial neural networks for extending road traffic monitoring data spatially: an application to the neighbourhoods of benevento. *Transportation Research Procedia*, Vol. 45, pp. 635–642, 2020. Transport Infrastructure and systems in a changing world. Towards a more sustainable, reliable and smarter mobility. TIS Roma 2019 Conference Proceedings.
- [8] Ryu Shirakami, Toshiya Kitahara, Koh Takeuchi, and Hisashi Kashima. Qtnet: Theory-based queue length prediction for urban traffic. In *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, KDD '23*, p. 4832–4841, New York, NY, USA, 2023. Association for Computing Machinery.
- [9] Petar Veličković, Guillem Cucurull, Arantxa Casanova, Adriana Romero, Pietro Liò, and Yoshua Bengio. Graph attention networks, 2018.
- [10] Yanan Xu, Yanmin Zhu, Yanyan Shen, and Jiadi Yu. Fine-grained air quality inference with remote sensing data and ubiquitous urban data. *ACM Trans. Knowl. Discov. Data*, Vol. 13, No. 5, pp. 1–27, sep 2019.
- [11] Xiangli Yang, Zixing Song, Irwin King, and Zenglin Xu. A survey on deep semi-supervised learning. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 35, No. 9, pp. 8934–8954, 2023.
- [12] Bing Yu, Haoteng Yin, and Zhanxing Zhu. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. In *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence, IJCAI-18*, pp. 3634–3640. International Joint Conferences on Artificial Intelligence Organization, 7 2018.
- [13] Yu Zheng, Licia Capra, Ouri Wolfson, and Hai Yang. Urban computing: Concepts, methodologies, and applications.

ACM Trans. Intell. Syst. Technol., Vol. 5, No. 3, pp. 1 – 55, sep 2014.

- [14] Xingchen Zou, Yibo Yan, Xixuan Hao, Yuehong Hu, Haomin Wen, Erdong Liu, Junbo Zhang, Yong Li, Tianrui Li, Yu Zheng, and Yuxuan Liang. Deep learning for cross-domain data fusion in urban computing: Taxonomy, advances, and outlook, 2024. arXiv:2402.19348.
- [15] 飯田恭敬. 交通工学. オーム社, 東京, 2008.
- [16] 国土交通省道路局. 道路行政の簡単解説, 2024. 国土交通省ウェブサイト.

SUMO を用いたデマンド交通における配車アルゴリズムの シミュレーション評価

楊 美琪[†] 神山 剛[‡]

[†]長崎大学 総合生産科学研究科 〒852-8521 長崎県長崎市文教町 1-14

[‡]長崎大学 情報データ科学部 〒850-0046 長崎県長崎市幸町 7-1

E-mail: [†] bb54124657@ms.nagasaki-u.ac.jp, [‡] kami@nagasaki-u.ac.jp

あらまし 長崎県東彼杵町等の地方自治体では、公共交通の維持に向けデマンド交通（DRT）の導入が進んでいる。しかし、既存の商用システムは即時性を重視した汎用的な配車ロジックを採用しており、地域固有の需要特性に対して必ずしも最適化されていない。本研究では、同町における約1年間の実運行データ（1,131件）を分析し、需要が特定の主要拠点に集中する「ハブ・アンド・スポーク型」構造を明らかにした。この特性を踏まえ、ハブ関連の予約に対して意図的な待機時間を設け、同一方向への乗り合わせを促進する「拠点集約型配車ロジック」を提案する。交通流シミュレータ SUMO を用いた比較実験により、運営方針の優先度に応じて最適な配車手法が異なること、特に配車不能を許容しない運用要件においては提案手法が優位であることを定量的に確認した。

キーワード デマンド交通, マルチエージェントシミュレーション, 配車アルゴリズム, 地理情報, MaaS

1. はじめに

近年、人口減少や高齢化が進む地方自治体において、持続可能な移動手段としてデマンド交通（DRT）の導入が進んでいる[1]。長崎県東彼杵町においても、自治体が導入している商用デマンド交通システムを活用した DRT が運行されている。しかし、既存の商用システムは汎用的な配車ロジックを採用している場合が多く、必ずしも個々の地域の需要パターンやネットワーク特性に最適化されているとは限らない。

特に東彼杵町の実データを分析すると、移動需要は均一に分散しているのではなく、特定の拠点（駅・商業施設・病院等）と各集落を結ぶ放射状の移動（ハブ・アンド・スポーク型）に極端に集中していることが判明した。このような需要構造において、単に発生順に処理する先着順のロジックでは、同一方面への需要をバラバラに輸送することになり、限られた車両数（2台）では非効率な走行が増大する恐れがある。

そこで本研究では、SUMO を用いて東彼杵町の交通環境および実運行データを再現したシミュレーションモデルを構築する。その上で、即時性を重視した「標準的な配車方針（方針 A）」と、拠点への集約を重視した「提案方針（方針 B）」を比較し、運営が重視する目標に応じてどちらの手法が適切かを明らかにする。

2. 関連研究

2.1. DRT における配車アルゴリズム

DRT 配車問題（Dial-a-Ride Problem: DARP）に関する研究は古くから行われており、その手法は「動的ケース」と

「静的ケース」に大別される。動的ケースは、リクエスト発生時に即座に最適な車両へ割り当てる手法であり、計算負荷が低く即時性に優れるため多くの実用システムで採用されている [2]。国内においても、中島ら [3] による SAVS がリアルタイムな全体最適化を実現し、その有効性が示されている。一方、静的ケースは一定時間のリクエストを蓄積し全体最適化を図る手法であるが、利用者の待ち時間が増加する傾向にある。既存の多くの研究 [4] は都市部のような高密度な需要を前提としており、過疎地特有の低密度かつ長距離移動を伴う環境下での配車効率については議論の余地が残されている。

2.2. 地域特性とハブ・アンド・スポーク型モデル

地方部における交通需要は駅や病院、商業施設などの「特定拠点（ハブ）」に集中する傾向がある。こうした地域では、ハブと各集落を結ぶ「ハブ・アンド・スポーク型」のネットワークが効率的であることが知られている [5]。しかし、既存の汎用的な DRT 配車システムは、こうした「特定方向への需要集中」を明示的にアルゴリズムに組み込んでいるケースは少ない。

2.3. SUMO を用いた交通シミュレーション

交通流シミュレータ SUMO（Simulation of Urban Mobility）は、微視的な交通挙動の再現に優れており、DRT の導入効果測定にも広く用いられている [6] [7]。

2.4. 本研究の位置づけ

以上を踏まえ、本研究は以下の点において独自性を有する。(1) 汎用的な動的ケース（方針 A）に対し、

地域のハブ構造を利用して意図的に割当を遅延させる「拠点集約型（方針 B）」を提案する点。（2）仮想データではなく、東彼杵町の実運行データに基づき、需要増加シナリオにおけるシステムの堅牢性を SUMO で定量的に評価する点。（3）単一指標による優劣判定ではなく、運営方針の優先度に応じた配車手法の選択指針を提示する点である。

3. 提案手法

本章では、過去の注文履歴（1,131 件）の分析結果に基づき、提案手法の設計根拠を述べる。全リクエストの乗降地点を集計したところ、利用頻度上位 10 地点（Fig. 1）の延べ乗降回数は全体の約 69%を占めることが判明した。さらに、全リクエストの約 87%がこれら上位 10 地点を起点または終点に含んでおり、需要が特定拠点に極めて高い集中度を示すことが確認された。この分析結果に基づき、上位 10 地点を主要ハブ拠点（Main Hubs）と定義する。




Fig. 1: 停留所別の延べ乗降回数（上位 10 地点）

3.1. 配車計画問題の定式化

$$J = \sum_{i \in R} (\alpha \cdot T_i^{\text{wait}} + \beta \cdot T_i^{\text{ride}}) + \gamma \sum_{k \in V} D_k$$

Alonso-Mora ら [8] が示すように、リクエストを一定時間蓄積し大域的な最適化を図る手法は、高密度な需要に対して高い輸送効率を実現する。本研究ではこの知見を過疎地の拠点集約モデルに応用し、配車計画を上記の目的関数 J を最小化する最適化問題として定式化する。リクエスト集合を R 、車両集合を V とし、各リクエスト i の待ち時間を T_{wait} 、乗車時間を T_{ride} 、車両 k の総走行距離を D_k と定義する。重み係数 α, β, γ はそれぞれ待ち時間・乗車時間・走行距離の優先度を表し、例えば $\alpha = 1, \beta = 0, \gamma = 0$ は待ち時間最小化を最優先する「即時性重視」の運営を意味する。加えて、配車成功率 100% を制約条件とする「堅牢性重視」の観点からも評価を行う。

3.2. 具体的な処理プロセス

提案手法（方針 B）は以下の手順で実行される。① 空間的フィルタリング：新規リクエスト発生時、その起終点が主要ハブに含まれるかを判定する。含まれない場合は即時配車プロセス（方針 A と同様）へ移行する。② バッファリング：ハブ関連リクエストと判定された場合、即座に車両へ割り当てず、待機リストに一時保管する。同時に待機タイマー（300 秒）を作動させる。③ 二段階マッチング探索：待機リスト内を每秒走査し、同一方向の需要が 2 件以上検出された場合に即時配車を確定する。条件未達の場合、タイムアウト時に単独で配車を確定する。

4. シミュレーション

4.1. 環境構築

交通流シミュレータ SUMO を用い、東彼杵町の交通環境を再現した。道路ネットワークには OpenStreetMap（OSM）を使用し、実際の山間部の道路形状や集落の配置を反映させている。車両モデルは、実際に現地で運行されているワゴン車の性能（定員 8 名、最高速度 50km/h）に準拠したパラメータを設定した。停留所は 126 箇所を配置し、そのうち主要ハブ 10 地点は Fig. 1 に示す利用頻度上位の拠点である。

4.2. 入力データ

シミュレーションの需要データとして、同町で実際に運行された 2024 年 3 月 1 日から 2025 年 4 月 17 日までの約 13 ヶ月間の予約記録（計 1,131 件）を使用した。代表的な 5 日間の実績データを選定し、各日のリクエストを実際の発生時刻、乗車地点、降車地点、人数に基づき SUMO 上で再現した。

5. 評価実験

5.1. 比較手法の設定

方針 A（即時配車型）：新規リクエスト発生時に即座に最適な車両を選択し配車する。車両に既存の乗客がいる場合は、経路への挿入（insert 方式）により乗り合わせを自然に発生させる。標準的な FCFS（First Come, First Served）ロジックに基づく。

方針 B（拠点集約型）：3.2 節で述べたアルゴリズムに基づき、ハブ関連予約に対してバッファ時間（300 秒）を設け、同一方向の乗り合わせを積極的に探索する。Phase 1（同方向 2 件以上で即時配車）と Phase 2（タイムアウト時の単独配車）の二段階制御を行う。

5.2. 実験シナリオと評価指標

実データ（需要×1）に加え、将来的な利用促進を見据え、ポアソン分布を用いて需要密度を「×2」「×5」「×10」に拡大したストレスシナリオを作成した。各シナリオは代表 5 日間の実績データを基にそれぞれ生成し、計 40 実験（5 日間×4 倍率×2 方針）を実施し

た．評価指標は，平均待ち時間，平均乗車時間，総走行距離，配車成功率の4指標を用いた．これらの指標は，Papanikolaou ら[9]による DRT 評価フレームワークに基づき選定したものである．

5.3. 実験結果

Table 1 に全実験結果の平均値と標準偏差を，Fig. 2～5 に各指標の比較グラフを示す．なお，Fig. 4（平均乗車時間）における需要×1の標準偏差は，1日あたりのリクエスト数が10～16件と僅少であることに起因して平均値を上回っており，統計的な安定性が十分ではないため，参考値に留める．

Table 1: 需要倍率別の実験結果（5日間平均±標準偏差）

倍率	方針	待ち時間 (分)	乗車時間 (分)	総距離 (km)	成功率 (%)
×1	A	4.35±0.39	3.97±4.86	91.17±25.98	100.0
	B	6.16±1.22	3.80±4.66	93.38±24.62	100.0
×2	A	4.26±0.66	7.00±3.55	202.31±56.19	98.5±3.08
	B	6.16±0.96	7.02±3.65	197.66±53.64	100.0
×5	A	3.80±0.38	7.91±1.70	328.44±69.69	100.0
	B	5.65±0.99	10.09±0.92	338.77±69.04	100.0
×10	A	4.04±0.47	9.68±0.47	393.94±91.16	99.8±0.4
	B	5.19±0.69	9.02±0.93	404.18±94.29	100.0




Fig. 4: 平均乗車時間の比較




Fig. 5: 配車成功率の比較

6. 考察

6.1. 実験結果の概要

実験結果から以下の4つの傾向が確認された．

第一に，総走行距離については両方針間で大きな差は見られなかった．需要×2では方針Bが約5km短い結果となったが，×5および×10では方針Bが約10km長くなっており，両方針は距離効率においてほぼ同等であるといえる．方針Aにおいてもinsert方式で自然に乗り合わせが発生しており，需要×5で約40%，×10で約45%のリクエストが乗り合わせで処理されていた．

第二に，平均乗車時間については，低需要時（×1，×2）では両方針間でほぼ同等であった．高需要時には傾向が分かれ，×5では方針Bが約2.2分長く（10.09分 vs 7.91分），×10では方針Bが約0.7分短い（9.02分 vs 9.68分）結果となった．総じて，乗車時間に関しては一貫した優劣は認められなかった．

第三に，平均待ち時間については方針Bが方針Aより約1.2～1.9分長い結果となった．ただし，需要が増加するにつれてこの差は縮小する傾向が見られた（×1: 1.81分差→×10: 1.15分差）．これは高需要時にPhase 1の発動頻度が増加し，バッファ満了を待たずに配車が確定するケースが増えるためである．

第四に，配車成功率については明確な差が現れた．方針Bは全40実験において成功率100%を達成したのに対し，方針Aは需要×2で98.5%，需要×10で99.8%




Fig. 2: 総走行距離の比較




Fig. 3: 平均待ち時間の比較

と、需要増加時に配車不能が発生した。これは即時配車により車両が同時に遠方へ向かい、次のリクエストに対応できない状況が生じたことに起因する。

6.2. 運営方針別の評価

6.1 節の結果を踏まえ、目的関数の重み設定を変化させた場合の方針 A・B の優劣を Table 2 に整理した。

Table 2: 運営方針別の最適手法

運営方針	×1	×2	×5	×10	特記事項
即時性重視	A	A	A	A	全シナリオで A 優位
快適性重視	同等	同等	A	B	一貫した優劣なし
距離重視	A	B	A	A	×2 のみ B 優位
バランス型	A	同等	A	同等	×1,×5 で A 優位
堅牢性制約	A	B	A	B	A は×2,×10 で配車不能

即時性重視 ($\alpha = 1, \beta = 0, \gamma = 0$) の場合、全需要シナリオにおいて方針 A が優位であった。方針 A の平均待ち時間は 3.80~4.35 分であり、方針 B の 5.19~6.16 分と比較して約 1~2 分短い。

快適性重視 ($\alpha = 0, \beta = 1, \gamma = 0$) の場合、乗車時間に関しては一貫した優劣が認められなかった。バッファリングの有無だけでは乗車時間を体系的に改善できないことを示している。

堅牢性制約 (配車成功率 100% 必須) を課した場合、方針 A は需要×2 および×10 において配車不能が発生するため、方針 B が唯一の選択肢となる。実際の DRT 運営においては予約拒否はサービス信頼性を著しく損なうため、需要増加が見込まれる局面では方針 B が合理的な選択となる。

6.3. 地域特性に適した運用への示唆

以上の分析から、東彼杵町のような「拠点集中型」の需要を持つ地域においては、配車手法の選択は単一の指標では判断できず、運営が何を優先するかによって最適解が異なることが示された。また、方針 A においても insert 方式により高需要時に約 45% の乗り合わせが自然発生していた事実は、動的配車アルゴリズムの有効性を示す重要な知見であり、今後の配車アルゴリズム設計において考慮すべき点である。

7. まとめと今後の課題

本稿では、長崎県東彼杵町の実運行データに基づき、地域特性を考慮した DRT 配車ロジックの評価環境を SUMO 上に構築した。汎用的な即時割当ロジック (方針 A) に対し、ハブ拠点への集約を重視した提案手法 (方針 B) を定式化し、需要×1~×10 の 4 段階のストレスシナリオにおける比較評価を行った。

実験の結果、以下の知見が得られた。(1) 総走行距離および乗車時間については両方針間で同等であり、FCFS でも高需要時に insert 方式により約 40~45% の乗

り合わせが自然発生することが確認された。(2) 方針 B は全シナリオで配車成功率 100% を達成し、堅牢性において明確な優位性を示した。(3) 目的関数の重み設定に応じて最適な方針が異なり、特に配車不能を許容しない運用要件においては方針 B が合理的な選択となる。

今後の課題として、バッファ時間や最大待ち時間などのパラメータに関する感度分析、時間帯や需要密度に応じたパラメータの動的最適化、および車両台数を増加させた場合のスケラビリティ検証が挙げられる。これらを通じて、持続可能な地域交通の実現に向けた具体的な運用指針の確立を目指す。

参考文献

- [1] 竹内龍介, 吉田樹, 尾崎光政, “地方自治体によるデマンド交通及びコミュニティバスの導入効果の発現要因に関する研究”, 土木学会論文集 D3, Vol. 78, No. 5, pp. I_627--I_637, 2023.
- [2] J.-F. Cordeau and G. Laporte, “The dial-a-ride problem: models and algorithms,” *Ann. Oper. Res.*, Vol. 153, No. 1, pp. 29--46, 2007.
- [3] 中島秀之, 松原仁, 平田圭二, 白石陽, 佐野渉二, 金森亮, 小柴等, 野田五十樹, “Smart Access Vehicle System : フルデマンド型公共交通配車システムの実装と評価”, 情報処理学会論文誌, Vol. 57, No. 4, pp. 1290--1302, 2016.
- [4] M. Diana and M. M. Dessouky, “A new regret insertion heuristic for solving large-scale dial-a-ride problems with time windows,” *Transp. Res. Part B*, Vol. 38, No. 6, pp. 539--557, 2004.
- [5] M. Yajima, K. Sakamoto, and H. Kubota, “Efficacy of bus service reorganization utilizing a hub-and-spoke topology and DRT to meet community needs,” *IATSS Res.*, Vol. 37, No. 1, pp. 49--60, 2013.
- [6] D. Krajzewicz, “Traffic simulation with SUMO -- Simulation of Urban Mobility,” in *Fundamentals of Traffic Simulation*, Springer, 2010.
- [7] J. Bischoff, M. Maciejewski, and K. Nagel, “City-wide shared taxis: A simulation study in Berlin,” *Proc. of IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, pp. 275--280, 2017.
- [8] J. Alonso-Mora, S. Samaranayake, A. Wallar, E. Frazzoli, and D. Rus, “On-demand high-capacity ride-sharing via dynamic trip-vehicle assignment,” *Proc. Natl. Acad. Sci. U.S.A.*, Vol. 114, No. 3, pp. 462--467, 2017.
- [9] A. Papanikolaou, S. Basbas, G. Mintsis, and C.

Taxiltaris, "A methodological framework for assessing the success of Demand Responsive Transport (DRT) services," Transportation Research Procedia, Vol. 24, pp. 393--400, 2017.

ANCOVA 型回帰によるガソリン価格反映特性の地域比較

堀内 敬太[†] 佐野 光希[†] 山崎綾一郎[†] 山岸 祐己^{†,††,†††} 祝田 実^{††††}

祝田 龍一^{††††}

[†] 静岡理科大学 〒420-0857 静岡県静岡市葵区御幸町 20 M20 11F

^{††} 浜松医科大学 〒431-3129 静岡県浜松市中央区半田山 1-20-1

^{†††} 株式会社良品計画 〒112-0004 東京都文京区後楽 2-5-1

^{††††} 株式会社ジャストサービス・ネット 〒434-0003 静岡県浜松市浜名区新原 5810

E-mail: [†]{2318141.hk,2318064.sk,2421028.yr,yamagishi.yuki}@sist.ac.jp, ^{††}{minoru,r.hoda}@hoda-oil.co.jp

あらまし 全国のガソリン価格（現金レギュラー）の地域別変動特性を把握するため、ガソリン価格比較サイトの各給油所の価格情報を利用し、政策的な価格引下げ局面の前後 2 時点（2025 年 10 月上旬と 12 月上旬）を対象に分析手法を提案する。まず、各給油所の過去価格を説明変数、現在価格を目的変数とし、ターゲット地域（8 地方または都道府県）を処置群、その他を対照群として ANCOVA 型の回帰モデルを推定する。次に、過去価格に対する現在価格の反映率差（連動の強さの差: すなわち ANCOVA における交互作用項の係数）を指標化してランキングし、地域ごとの反応特性を比較する。

キーワード 社会インフラデータ、都市データ、地理データ、地域分析

1 はじめに

日本のガソリン価格は、家計・企業の移動コストや物流費を通じて消費活動に波及しやすく、物価動向の一要因としても継続的に観測されている。実際、総務省統計局の消費者物価指数（CPI）ではガソリン指数の推移が公表されており、エネルギー関連価格の変動が物価に与える影響を把握できる枠組みが整備されている [22]。加えて、資源エネルギー庁は給油所小売価格（ガソリン等）の週次調査結果を継続的に公表しており [14]、ガソリン価格は政策・統計の両面で重要な監視対象となっている。

この背景には、日本のエネルギー供給構造が国際情勢の影響を受けやすい点がある。日本は原油の大部分を輸入に依存し、とりわけ中東地域への依存度が高いことが指摘されている [8], [16]。国際原油市況や為替変動、地政学リスクの高まりは国内燃料価格の上昇圧力となりうるため、政府は燃料油価格の急激な変動を緩和する措置を講じてきた。2025 年には燃料油価格に対する「定額」支援が実施され、さらに 2025 年 11 月中旬以降、段階的な拡充により（ガソリンは 12 月中旬頃）暫定税率相当の引下げ効果を見込む説明がなされている [17]。また、定額引下げ措置の設計（例：12 月下旬時点の支給単価の提示）も公表されている [19]。同時期には、全国平均価格を一定水準付近に抑える方針が報じられるなど [9]、政策的な価格引下げ局面が形成された。

一方で、こうした価格支援の効果は全国一律に現れるとは限らない。地域ごとの需給・流通制約、競争環境、価格設定行動の差により、政策や外生ショックが小売価格へ「どの程度・どの速さで」反映されるか（パススルー）が異なる可能性がある。資源エネルギー庁の資料でも、地域燃料流通の課題や価格の状況が整理されており [18]、地域差の定量評価は政策運用上も実

務上も重要である。さらに、ガソリン市場における補助政策の帰結（厚生面を含む）を検討する研究も現れており [10]、支援策の評価には、価格の水準変化だけでなく「反映のされ方（連動の強さ）」の検証が求められる。

そこで本研究では、ガソリン価格比較サイトの給油所単位の価格情報を用い、政策的な価格引下げ局面の前後 2 時点（2025 年 10 月上旬と 12 月上旬）に着目して、地域別の価格反映特性を比較するための分析手法を提案する。具体的には、各給油所の過去価格を共変量、現在価格を目的変数とし、ターゲット地域を処置群、その他を対照群として、ANCOVA 型回帰を推定する。交互作用項の係数により「過去価格に対する現在価格の反映率差（連動の強さの差）」を指標化し、地域のランキングとして提示することで、(i) 政策局面における地域別の反応特性の可視化、(ii) 価格支援の効果の不均一性の検出、(iii) 継続的なモニタリングに資するスケーラブルな比較枠組みの提供、を狙う。

2 分析手法

2.1 問題設定

本研究では、ガソリン価格比較サイトに掲載された給油所単位の価格情報を用いて、政策的な価格引下げ局面の前後 2 時点における「過去価格から現在価格への反映特性」の地域差を比較する。

a) 観測単位と時点

給油所（店舗）を $i \in \mathcal{I}$ とし、分析対象とする 2 時点を t_0 （2025 年 10 月上旬）、 t_1 （2025 年 12 月上旬）とする。給油所 i の時点 t における現金レギュラー価格（円/L）を $x_{i,t}$ と表す。回帰モデルの記述の都合上、目的変数を $y_i = x_{i,t_1}$ 、共変量（ベースライン）を $x_i = x_{i,t_0}$ と定義する。ANCOVA (analysis

of covariance) は、ベースラインを共変量として事後値を回帰する枠組みであり、古典的な整理と実務上の論点が議論されてきた [2], [3].

b) 地域カテゴリーの定義 (拡張可能な設計)

給油所集合を \mathcal{I} とし、各給油所 $i \in \mathcal{I}$ が属する地域カテゴリーを $g(i) \in \mathcal{G}$ とする。地域 $g \in \mathcal{G}$ に属する給油所の集合を $\mathcal{I}_g = \{i \in \mathcal{I} \mid g(i) = g\}$ と定義し、そのサンプルサイズを $n_g = |\mathcal{I}_g| = \sum_{i \in \mathcal{I}} \mathbb{I}\{g(i) = g\}$ とする。また、全体のサンプルサイズを $n = |\mathcal{I}|$ とすれば、 $n = \sum_{g \in \mathcal{G}} n_g$ が成り立つ。すなわち、地域 g を処置群、それ以外を対照群とするモデルでは、処置群サイズは n_g 、対照群サイズは $n_{-g} = n - n_g$ と表せる。

\mathcal{G} は分析目的に応じて任意の粒度で定義できる。例えば、(i) 8 地方 $\mathcal{G}^{(8)}$ (北海道, 東北, 関東, 中部, 近畿, 中国, 四国, 九州・沖縄), (ii) 47 都道府県 $\mathcal{G}^{(47)}$, のいずれも \mathcal{G} として採用可能である。一般には、都道府県 $pref(i)$ を与えたときに写像 $g(i) = \phi(pref(i))$ で地域粒度を切り替える実装 (例: ϕ を「都道府県 \rightarrow 地方」へ写像, または恒等写像) とすることで、地域カテゴリーの拡張に対応する。

c) 本稿での前提 (制御変数を用いない)

本稿の実験設定では、給油所属性などの追加的な制御変数は用いず、ベースライン価格 x_i のみを共変量として用いる。したがって、以下のモデルは $\{(x_i, y_i, D_i)\}$ のみで定義される単純な仕様とする。

d) 目的

地域 $g \in \mathcal{G}$ ごとに「過去価格 x_i に対して現在価格 y_i がどの程度連動するか (反映率)」を推定し、その地域差 (反映率差) を指標化してランキングとして提示する。

2.2 ANCOVA 型回帰モデル

a) 基本モデル (1 地域 vs その他)

ターゲット地域 $g \in \mathcal{G}$ を 1 つ固定し、その地域に属する給油所を処置群、それ以外を対照群とする。処置指示変数を

$$D_i^{(g)} = \mathbb{I}\{g(i) = g\} \quad (1)$$

と定義する。このとき、交互作用項を含む ANCOVA 型回帰モデルとして次を推定する:

$$y_i = \alpha + \beta x_i + \gamma_g D_i^{(g)} + \theta_g (D_i^{(g)} \cdot x_i) + \varepsilon_i. \quad (2)$$

ここで ε_i は誤差項である。交互作用を含む回帰の係数解釈は「条件付き効果」として整理することが重要である [1].

b) 係数の解釈 (反映率差の定義)

式 (2) より、対照群 ($D_i^{(g)} = 0$) の条件付き期待値は

$$\mathbb{E}[y_i \mid x_i, D_i^{(g)} = 0] = \alpha + \beta x_i, \quad (3)$$

処置群 ($D_i^{(g)} = 1$) の条件付き期待値は

$$\mathbb{E}[y_i \mid x_i, D_i^{(g)} = 1] = (\alpha + \gamma_g) + (\beta + \theta_g) x_i \quad (4)$$

で与えられる。したがって、

- 対照群の「反映率 (過去価格に対する現在価格の連動の強さ)」は傾き β ,

- ターゲット地域 g の反映率は傾き $\beta + \theta_g$,

- 反映率差 (連動の強さの差) は θ_g

として解釈できる。本研究では θ_g を地域 g の価格反映特性指標とみなし、 $\hat{\theta}_g$ を用いて地域ランキングを作成する。

c) 推定と推論

式 (2) のパラメータは、外れ値の影響を低減するためロバスト回帰 (M 推定) により推定する [6], [7]. 計算は反復重み付き最小二乗法 (IRLS) として実装でき、推定された交互作用項の係数 $\hat{\theta}_g$ を地域 g の価格反映特性指標として用いる。推論にはロバスト回帰に基づく標準誤差を用い、必要があれば $\hat{\theta}_g$ の不確実性 (信頼区間や t 値とその p 値など) を併記する。

d) 実装上の補足: 中心化

交互作用項の解釈を容易にするため、 x_i を中心化した $x_i^c = x_i - \bar{x}$ を用いる実装も有用である [1]. このとき γ_g は「平均的なベースライン価格における水準差」として解釈しやすくなる (θ_g の解釈自体は不変)。

e) 地域ランキングの作成

地域集合 \mathcal{G} の全ての g について、(i) $D_i^{(g)}$ を定義し、(ii) 式 (2) を推定し、(iii) $\hat{\theta}_g$ (必要に応じて信頼区間や t 値) を算出する。得られた $\{\hat{\theta}_g\}_{g \in \mathcal{G}}$ を降順に並べることで、政策的な価格引下げ局面における「価格反映 (連動) の強さ」の地域差をランキングとして提示する。

3 実験結果とまとめ

今回、ガソリン価格比較サイト gogo.gs¹ から取得したデータを用いて、47 都道府県 $\mathcal{G}^{(47)}$ の粒度で価格反映特性指標 $\{\hat{\theta}_g\}_{g \in \mathcal{G}^{(47)}}$ を求めた (表 1). 以下では、特徴的な都道府県に着目しつつ、3 つの観点から考察を行う。



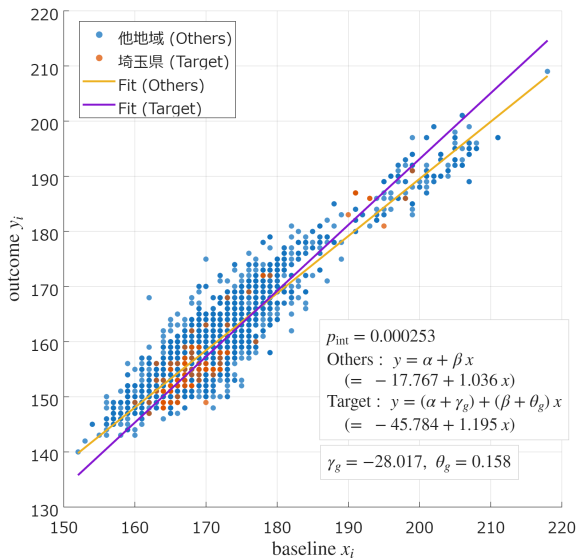

a) 大標本で有意な都道府県 (千葉・埼玉・愛知・北海道)

千葉県 (図 1, $n_g = 162$) および埼玉県 (図 2, $n_g = 123$) では $\hat{\theta}_g > 0$ かつ有意であり、10 月時点の給油所間の価格差が 12 月にも相対的に「維持」されやすい (反映率が高い) 傾向が示唆される。とくに千葉県は、京葉臨海部に石油コンビナートが集積し、原油精製能力の規模や全国シェアが大きいことが公的資料で示されている [20], [21]. 首都圏需要地に近接する供給拠点の存在は、卸・物流面の安定性を通じて、給油所ごとの相対価格が政策局面でも保たれやすい可能性がある。一方、愛知県 (図 3, $n_g = 281$) は $\hat{\theta}_g < 0$ で有意であり、供給拠点 (愛知事業所) を有するにもかかわらず、政策局面で価格差が相対的に「圧縮」される方向が観測された [20]. この点は、供給拠点の有無だけでは反映特性が一意に定まらず、地域の競争環境や流通経路等が複合的に作用し得ることを示す。北海道 (図 4, $n_g = 183$) も $\hat{\theta}_g < 0$ で強く有意であり、寒冷地における暖房需要 (灯油需要) が大きいことや季節要因が需要構造に影響する点 [12], [23] が、ガソリン価格の調整過程 (価格差の縮小を含む) に波及している可能性がある。

b) 供給拠点が挙動が意外な都道府県 (岡山)

岡山県は $\hat{\theta}_g < 0$ かつ有意 ($n_g = 15$) であり、反映率差が

1: <https://gogo.gs/>

図1 $\mathcal{G}^{(47)}$ における対照群「千葉県」の結果 ($n_g = 162$)図3 $\mathcal{G}^{(47)}$ における対照群「愛知県」の結果 ($n_g = 281$)図2 $\mathcal{G}^{(47)}$ における対照群「埼玉県」の結果 ($n_g = 123$)図4 $\mathcal{G}^{(47)}$ における対照群「北海道」の結果 ($n_g = 183$)

負方向に推定された点が注目される。岡山県（水島）には国内最大級の原油処理能力を持つ製油所が立地し、コンビナート中核として広域に出荷していることが明示されている [5], [20]。一般に供給拠点は価格変動の伝播を強めると予想される一方、本結果は、政策局面では給油所間の価格差が相対的に縮小する（ベースライン差が残りにくい）調整も起り得ることを示唆する。ただし n_g が小さいため、サンプル拡充や期間追加による頑健性確認が必須である。

c) 物流・制度が特殊で要追加検証（沖縄・離島／SS過疎地）

沖縄県は $\hat{\theta}_g > 0$ だが有意ではなく ($n_g = 10$)、現時点では探索的解釈に留めるべきである。ただし沖縄では、復帰特別措置法に基づく揮発油税等の軽減措置が継続していることが自治体・法令で明示されており [4], [11]、制度面で価格形成が本土と

異なる可能性がある。さらに国は、離島における実質的なガソリン価格の低減や安定供給を目的とした支援制度（流通コスト対策等）を運用しており [15]、また SS 過疎地対策として地域の燃料供給体制維持に関する施策や整理を提示している [13]。これら物流・制度要因は、ベースライン価格と政策後価格の単純な比例関係を崩し得るため、(i) 対象期間の追加、(ii) 離島・SS 過疎地の識別に基づく層別・感度分析、等による追加検証が望ましい。

文献

- [1] Thomas Brambor, William Roberts Clark, and Matt Golder. Understanding interaction models: Improving empirical analyses. *Political Analysis*, Vol. 14, No. 1, pp. 63–82, 2006.

表 1 都道府県粒度 ($G^{(47)}$) における価格反映特性指標 $\hat{\theta}_g$ (ANCOVA 型回帰 (式 (2)) の交互作用項係数) と検定結果. n_g は当該都道府県 (処置群) の給油所数, p 値は $H_0: \theta_g = 0$ に対する t 検定の p 値. $\hat{\theta}_g$ の降順に掲載.

順位	都道府県	n_g	$\hat{\theta}_g$	p 値
1	島根県	10	0.6459	0.0703
2	沖縄県	10	0.2941	0.162
3	千葉県	162	0.2155	8.17×10^{-5}
4	愛媛県	14	0.1666	0.0206
5	埼玉県	123	0.1581	2.53×10^{-4}
6	和歌山県	32	0.1228	0.0408
7	栃木県	75	0.1209	0.0440
8	滋賀県	14	0.0977	0.139
9	鹿児島県	165	0.0903	0.0250
10	茨城県	131	0.0826	0.0594
11	新潟県	49	0.0463	0.263
12	大分県	11	0.0454	0.698
13	岩手県	25	0.0274	0.611
14	香川県	26	0.0140	0.827
15	福島県	315	0.0070	0.845
16	三重県	82	0.0067	0.855
17	宮城県	59	0.0038	0.945
18	石川県	49	0.0026	0.967
19	群馬県	142	-0.0009	0.983
20	大阪府	269	-0.0122	0.754
21	富山県	107	-0.0148	0.714
22	東京都	188	-0.0210	0.669
23	岐阜県	33	-0.0224	0.575
24	福井県	52	-0.0303	0.639
25	静岡県	90	-0.0312	0.357
26	神奈川県	178	-0.0337	0.565
27	奈良県	8	-0.0394	0.589
28	福岡県	43	-0.0435	0.272
29	長野県	139	-0.0481	0.203
30	兵庫県	124	-0.0527	0.0320
31	広島県	29	-0.0612	0.0852
32	宮崎県	5	-0.0718	0.486
33	山口県	9	-0.0922	0.358
34	岡山県	15	-0.1116	0.0216
35	愛知県	281	-0.1207	7.98×10^{-5}
36	熊本県	15	-0.1237	0.0351
37	山形県	13	-0.1243	0.323
38	秋田県	51	-0.1464	0.214
39	京都府	31	-0.1550	0.297
40	山梨県	9	-0.1884	0.00407
41	北海道	183	-0.2671	3.08×10^{-6}
42	佐賀県	3	-0.5424	0.902
43	青森県	7	-0.6424	0.121

- [5] ENEOS 株式会社. 水島製油所 (概要). <https://www.eneos.co.jp/company/about/branch/mizushima/refinery/>.
- [6] Paul W. Holland and Roy E. Welsch. Robust regression using iteratively reweighted least-squares. *Communications in Statistics - Theory and Methods*, Vol. 6, No. 9, pp. 813–827, 1977.
- [7] Peter J. Huber. *Robust Statistics*. John Wiley & Sons, 1981.
- [8] International Energy Agency. Japan oil security policy. <https://www.iea.org/articles/japan-oil-security-policy>, August 2022.
- [9] Reuters. Japan will mitigate potential gasoline price spike, prime minister says. *Reuters*, June 2025.
- [10] Eiji Satoh, Kaho Hirano, Taiga Sato, Eiki Shimada, Ayana Sumiyoshi, Satoshi Takahashi, Hiroshi Tamaki, Sora Yamamoto, and Kakeru Yamaguchi. Welfare impact of subsidies in oligopolistic markets: Evidence from Japan's gasoline market. *Energy Policy*, Vol. 206, p. 114768, 2025.
- [11] 沖縄県. 揮発油税等 (ガソリン税) の軽減措置. <https://www.pref.okinawa.jp/kurashikankyo/zeikin/1003660/1003670/1023844/1003975.html>.
- [12] 環境省. 家庭の中からの co2 排出量 (家庭部門の co2 排出実態統計調査). <https://www.env.go.jp/earth/ondanka/kateico2tokei/co2/detail/02/>.
- [13] 資源エネルギー庁. Ss 過疎地対策について. https://www.enecho.meti.go.jp/category/resources_and_fuel/distribution/sskasochi/.
- [14] 資源エネルギー庁. 石油製品価格調査 (給油所小売価格調査) 調査の結果. https://www.enecho.meti.go.jp/statistics/petroleum_and_lpgas/pl007/results.html.
- [15] 資源エネルギー庁. 令和 7 年度「石油製品販売業構造改善対策事業費補助金 (離島のガソリン流通コスト対策事業等)」公募. https://www.enecho.meti.go.jp/appli/public_offer/2024/0207_09.html.
- [16] 資源エネルギー庁. 令和 4 年度エネルギーに関する年次報告 (エネルギー白書 2023) 第 2 節 日本の経済・社会に与える影響 (html 版). <https://www.enecho.meti.go.jp/about/whitepaper/2023/html/1-2-2.html>, 2023.
- [17] 資源エネルギー庁. ガソリンの暫定税率 (当分の間税率) の廃止でガソリン代はどのようなもの? (q&a). <https://www.enecho.meti.go.jp/about/special/johoteikyozanteizeiritsu.html>, November 2025.
- [18] 資源エネルギー庁. 地域燃料流通に関する現状と課題 (資料). https://www.enecho.meti.go.jp/category/resources_and_fuel/distribution/sskasochi/ryutsukenkyukai/01/0105.pdf, October 2025.
- [19] 経済産業省資源エネルギー庁. 燃料油価格定額引下げ措置. <https://nenryo-teigakuhikisage.go.jp/>.
- [20] 石油連盟. 製油所の所在地と原油処理能力 (2025 年 3 月末現在). https://www.paj.gr.jp/sites/default/files/2025-06/paj-04_refining%20capacities_202503_0.pdf.
- [21] 千葉県. 京葉臨海工業地帯を支える各企業群 (資料). <https://www.pref.chiba.lg.jp/kouwan/news/documents/25chiba11.pdf>.
- [22] 総務省統計局. 2020 年基準 消費者物価指数 全国 2025 年 (令和 7 年)11 月分. <https://www.stat.go.jp/data/cpi/sokuhou/tsuki/pdf/zenkoku.pdf>.
- [23] 北海道経済産業局. 資料 2 (灯油需要と気温 (北海道) 等). <https://www.hkd.meti.go.jp/hokno/20241122/data02.pdf>.

- [2] William G. Cochran. Analysis of covariance: Its nature and uses. *Biometrics*, Vol. 13, No. 3, pp. 261–281, 1957.
- [3] D. R. Cox and P. McCullagh. Some aspects of analysis of covariance. *Biometrics*, Vol. 38, No. 3, pp. 541–561, 1982.
- [4] e-Gov 法令検索. 沖縄の復帰に伴う国税関係法令の適用の特別措置等に関する政令 (揮発油税及び地方揮発油税の軽減等). <https://laws.e-gov.go.jp/law/347C00000000151/>.

一般発表 | Track 5: 高度なデータ利活用・ドメイン応用 (医療情報, 教育, 地理情報等)

2026年2月28日(土) 9:30 ~ 11:40 | K会場

[1K] モビリティ

座長: 山本 修平(筑波大学) コメントータ: 渡辺 陽介(名古屋大学)

11:00 ~ 11:25

[1K-05] [技術報告] モビリティデータ利活用の現状と展望—自動車業界における生成AI/AIエージェントの活用—

*笹井 健行¹ (1. トヨタ自動車株式会社)

発表者区分: スポンサー

種別: 技術報告

インタラクティブ発表: あり

キーワード: モビリティ、生成AI、大規模データ

コネクティッドカー等から収集される大規模な運転・車両挙動データに対し、機械学習・データマイニングを用いた解析・サービスへの活用が進んできた。近年では、生成AIの急速な進展に伴い、モビリティ分野における生成AIの技術の応用やAIエージェントの活用なども現実的となりつつある。本発表では、AD/ADAS（自動運転、先進運転支援）、AIガーディアン（特に安全に関する支援）などの具体的なユースケースを題材に、生成AIを組み合わせた新しい解析・開発プロセスなどを紹介する。