

博士論文

自動車走行ログを使用した電気自動車
消費エネルギーデータベースに関する研究

An Energy Consumption Database of Electric Vehicle

Utilizing Vehicle Driving Logs

横浜国立大学 大学院環境情報学府
情報環境専攻

植村 智明

UEMURA Toshiaki

2021年3月

要約

本研究では、自動車走行ログを使用した電気自動車（EV）消費エネルギーデータベースを構築する。ユーザが現在所有する自動車のセンサデータを走行ログとして気軽に収集し、EVの消費エネルギーを推定することで、「今の車に乗ったまま」で「EVに乗り換えた未来の消費エネルギー」を予測可能にする。また、このデータベースは、大量かつ多変量となるセンサデータに対してアドホックなクエリを実行可能とし、「ユーザが必要な有用なデータ」の取得を可能にする。本論文では、自動車走行ログによりEV特有の問題が解決可能であることを示すために、データベースで取得したEVの消費エネルギーに関するデータを有用に利用する実例を示す。そのため、本研究では、以下の三つの課題に取り組む。第一に、自動車走行ログからEVの消費エネルギーの推定手法を定義した。これにより、一定の精度でEVの消費エネルギーが推定可能であることを示した。第二に、関係代数演算がGUI上で実行可能な多変量データ解析支援システムを構築した。実際のEVのデータを使用した有用な解析例を示し、解析支援システムによって、EVの消費エネルギーログを利用した有用なデータ解析が可能であることを示した。第三に、推定したEV消費エネルギーデータを蓄積したデータベースを構築した。加えて、多変量データ解析支援システムを利用し、大量かつ多変量な推定EV消費エネルギーデータの有用なデータ解析例を示した。これにより、ユーザがEVがなくとも、自動車走行ログを集めるだけで、ユーザの運転や状況を反映した「EVに関する有用な情報を提示可能であること」を示した。

目次

第 1 章	序論	4
1.1	研究背景	4
1.2	本研究における課題	5
1.2.1	自動車走行ログを使用した電気自動車消費エネルギー量の推定	5
1.2.2	多変量データ解析支援システムと電気自動車消費エネルギーデータへの応用	5
1.2.3	電気自動車消費エネルギーデータベースの構築と応用	6
第 2 章	関連研究	7
2.1	EV の消費エネルギー推定と自動車走行ログの活用	7
2.1.1	EV の消費エネルギー推定	7
2.1.2	EV の消費エネルギー最適化	8
2.1.3	自動車走行ログの活用	8
2.2	データ可視化とデータ解析支援	9
2.2.1	平行座標プロット (PCP) とデータ操作	9
2.2.2	データ解析支援	10
第 3 章	自動車走行ログを使用した電気自動車消費エネルギー量の推定	13
3.1	はじめに	13
3.2	EV モデルによる消費エネルギー推定	14
3.3	正解データの定義	15
3.3.1	実車 EV を用いた CAN データの取得	15
3.3.2	EV モデルの精度検証における正解データ	17
3.3.3	エアコン推定モデルの精度検証における正解データ	17
3.4	EV モデルの入力データと精度検証	17
3.4.1	GPS 位置データ補正	17
3.4.2	車速データの取得	20
3.4.3	EV モデル推定精度検証：入力データ	23
3.5	正解データのクレンジングと精度検証	23
3.5.1	EV モデル推定精度検証：正解データクレンジング	27
3.6	EV モデル推定精度検証：総合評価	27
3.7	エアコン推定モデルの精度検証	29
3.7.1	エアコン推定モデル	29
3.7.2	エアコン推定モデル精度検証実験	33
3.7.3	エアコン推定モデルの精度検証	36
3.8	まとめと今後の課題	36
3.8.1	まとめ	36
3.8.2	今後の課題	38

第 4 章	多変量データ解析支援システムと電気自動車消費エネルギーデータへの応用	40
4.1	はじめに	40
4.2	データ解析支援システムと (PC) ² L の拡張	41
4.2.1	データ解析支援システム拡張の概要	41
4.2.2	データ可視化機能	41
4.2.3	(PC) ² L の文法拡張	43
4.2.4	実装システムの表示例	43
4.3	解析例で使用するデータセット	45
4.3.1	データ取得環境	45
4.3.2	CAN データ	45
4.3.3	GPS データ	45
4.3.4	気象データ	46
4.4	データ解析例: EV のエネルギー消費要因の特定と可視化	46
4.4.1	EV の走行ログデータ解析で立証する仮説	46
4.4.2	使用するリレーション	46
4.4.3	解析プロセス例	46
4.5	まとめと今後の課題	56
4.5.1	まとめ	56
4.5.2	今後の課題	56
第 5 章	電気自動車消費エネルギーデータベースの構築と応用	58
5.1	はじめに	58
5.2	EV 推定消費エネルギーデータ解析	59
5.3	ECOLOG システム	59
5.3.1	ECOLOG テーブル	59
5.3.2	ECOLOG データベース	60
5.3.3	Semantic Editor	60
5.4	データ解析例	60
5.4.1	データ解析例 1:EV とガソリン車の特性の比較	63
5.4.2	データ解析例 2:EV の消費エネルギーの要因解析	66
5.5	まとめと今後の課題	69
5.5.1	まとめ	69
5.5.2	今後の課題	69
第 6 章	結論	74
付 録 A	解析例で示した STEP ごとの (PC)²L	84

第1章 序論

1.1 研究背景

近年、スマートフォンやウェアラブルデバイスなどの普及により、日常をデータとして記録する「ライフログ」を、個人でも気軽に取得・蓄積することが可能となった。これらのデバイスをデータロガーとして利用すれば、センサデータを自動的に取得・蓄積できる。すなわち、ユーザは無意識かつ手間無くライフログを収集することができる。さらに、ユーザ自らに限らず、他ユーザとデータを共有しあうことにより、多様で有用なライフログの利用が可能になる。しかしながら、蓄積したライフログは膨大かつ多様な多変量データであるため、必要な情報を取り出すには適切なクエリを適用する必要がある。そのため、多変量データに対して、アドホックなクエリを適用し「ユーザが求めている有用なデータ」の取得を支援することは重要なことと言える。

一方、地球温暖化対策として、電気自動車（EV）が次世代自動車として注目されている。EVは、走行中の温室効果ガスの排出物が無いゼロエミッション車（ZEV: Zero Emission Vehicle）の一種であり、Well-to-Wheel(エネルギー製造から走行まで)の二酸化炭素排出量削減への貢献が可能である。加えて、比較的大型な二次電池を持つことから、分散型エネルギー社会に参画し、エネルギーの効率的利用や、非常時のエネルギー供給の確保などに貢献することができる。しかしながら、EVは、認知度が上がっている一方で、価格の高さ、航続距離の短さ、充電設備の不十分さなどの要素から、未だ消費者から購入が敬遠される傾向がある [1]。加えて、ドライバーの視点に立った時に「自分がEVに乗り換えたとしたら、自身の生活にEVはマッチするか」が明確でないことも理由として考えられる。例えば、カタログスペック上でのEVの電費は知ることができるが、実際の電費はそのEVの走行状況や運転の違いによって変化する。そのため、ドライバー自身が「自分の生活にEVがマッチするか」を判断するのは難しい。この問題を解決する方法の一つとして、「今の車に乗ったまま」で「EVに乗り換えた未来の日常」を予測する、すなわち「EVへの置き換え効果」を定量的に提示することが考えられる。

そこで本研究では、GPSを搭載しているスマートフォンをロギングデバイスとして既存の車両に搭載することで、GPSから得られる自動車走行ログをドライバーの負担なく蓄積できることに着目した。すなわち、自動車による日常的な移動のライフログを用いて、EVに乗り換えた際のエネルギー消費予測を実現することを目指す。このとき、EVはICVやHV(ハイブリッド自動車)と比較して内部構造が単純であることから、運動方程式を用いて走行で消費するエネルギー量を推定することが可能である [2, 3]。そこで、本研究では自動車走行ログから「その人の運転を反映したEVに乗り換えたときの消費エネルギー」を推定する。また、推定したEV消費エネルギーログを蓄積したデータベースシステム、ECOLOG(Energy CONsumption LOG)システムを構築する。これにより、EVの電力消費に関する多様でアドホックな検索を実現する。

1.2 本研究における課題

本研究では、自動車走行ログから推定した EV 消費エネルギーログを蓄積したデータベースを実装し、実データを元に EV 消費エネルギーログの活用例を示す。そこで、本研究における課題は、以下の3つに大別される

1.2.1 自動車走行ログを使用した電気自動車消費エネルギー量の推定

本課題では、データベースに蓄積する自動車走行ログを使用した EV 消費エネルギーデータの推定方法を定義する。加えて、センサデータ・正解データの収集したデータのクレンジング・推定モデルの構築・推定精度検証までの一連の流れを確立することを目指す。ECOLOG システムに蓄積する EV 消費エネルギーログの推定方法を示し、その推定精度の検証を行うことで、一定の精度で推定 EV 消費エネルギーログが利用可能であることを示す。

推定モデルについては、EV 電力消費の大部分を占める走行とエアコンに関してそれぞれ推定モデルを構築した [4]。走行の推定モデルは、EV の消費エネルギーの要因を分析可能とするために、運動方程式を基にした推定モデルを使用した。これにより、データ解析者やユーザーに対してより有用なデータを提示することが可能になると考えられる。また、エアコンについては、EV の車種ごとにエアコンの機種が異なるため、走行の推定モデルのような理論に基づく推定モデルを構築することが困難である。そのため、機械学習を利用したモデルを構築し、車両ごとに収集したデータを学習に利用することとした。

走行の消費エネルギー推定のための入力データには、GPS (位置, 速度) ログを使用する。さらに、GPS から取得した位置データに対し、マップマッチングなどの補正アルゴリズムを適用することで推定精度向上を行う [5, 6, 7]。また、精度検証のための正解データとして、実際の EV による走行実験により、走行中の CAN から消費エネルギーに相当するデータを取得した。EV の CAN データ独自のノイズが含まれていることから、長期間に及ぶ EV の実験データを収集した経験を基にデータクレンジングを施す [4]。

エアコンの消費エネルギー推定のための入力データには、照度ログ、および、気象庁から取得した天気データを利用する。エアコンの消費エネルギー量の正解データには、走行消費エネルギー量と同様に CAN よりエアコンの出力データを取得した。

本課題の詳細については、3章に記述する。

1.2.2 多変量データ解析支援システムと電気自動車消費エネルギーデータへの応用

本課題では、先行研究で実装した多変量データ解析支援システム [8] の機能拡張を行った。さらに、この解析支援システムを利用したデータ分析例を示すことで、多変量な EV 消費エネルギーデータの有用な利用方法を確立することを目指す。本課題では、推定した消費エネルギーデータを利用せず、実際の EV から取得した消費エネルギーログを利用し、電気自動車 (EV) 特有の問題に対する EV の消費エネルギーデータの解析手順例を実践的に提示する。

本研究で利用する解析支援システムは、GUI 上で関係代数演算を可能にし、インタラクティブでアドホックなクエリを GUI で実行可能にする。そのため、多変量データを可視化し、クエリ (データ操作) を実行するための GUI として Parallel Coordinates Plot (PCP) を利用する。そのデータ

操作結果を任意の手法で可視化することで解析を進める。その過程において、PCP 上のデータ操作と可視化の状態を SQL ライクな言語表記形式で保存できる。言語形式で保存することで、解析途中の試行錯誤を支援する。これらの機能により、リアルタイムにユーザーの操作が反映される GUI と、データの操作過程を論理的に記述できる言語形式という両者の利点を活かした解析を可能にする。本課題では、我々が長期に渡り収集した EV の走行ログに対し、実装システム上で、アドホックなクエリを試行錯誤しながら適用するようなデータ解析をおこなう例を提示した。これにより、EV 特有の複合したエネルギー消費要因を特定するデータ分析や、多様な条件で走行ログを絞り込むデータ処理などの問題を解決する。

本課題の詳細については、4 章に記述する。

1.2.3 電気自動車消費エネルギーデータベースの構築と応用

本課題では、1.2.1 項の課題にて定義する手法から推定した EV の消費エネルギーデータに合わせたデータベーススキーマを定義し、ECOLOG データベースの構築を行う。EV の消費エネルギーは道路毎に異なる特性を持ち、道路区間ごとにデータを集計することで有用な可視化が可能であることが、我々の先行研究 [9] で示されている。それに対し、有意な道路区間で集計可能なデータベースとして ECOLOG データベースを構築する。

また、ECOLOG データベースと 1.2.2 項で構築した多変量データ解析支援システムを連携したデータ解析フレームワークを示すことで、実際的な ECOLOG システムの利用法を示す。さらに、実際に収集した自動車走行ログから推定したデータの解析例を示し、「EV の推定消費エネルギーデータ」を利用したからこそ可能なデータ利用法を示す。

本課題の詳細については、5 章に記述する。

第2章 関連研究

本研究においては、大きく以下の2種類の関連研究が挙げられる。

- (1) EVの消費エネルギー推定と自動車走行ログの活用
- (2) データ可視化とデータ解析支援

以下の節でそれぞれ説明する。

2.1 EVの消費エネルギー推定と自動車走行ログの活用

本節では、走行データを活用したEVの消費電力や電費の推定手法と自動車の走行ログの活用に関する関連研究について言及する。

2.1.1 EVの消費エネルギー推定

EVのV2Xへの効果や消費エネルギー量・航続距離を評価するために、走行データを活用したEVの消費電力や電費推定の研究が盛んにおこなわれている。EVは運動方程式を用いることで、EVの消費電力や電費推定を行うことが可能である[2, 3]。岩坪らは、EVの電費シミュレーションモデルを開発し、実際の走行ログを元に電池容量増加によるEVの航続距離の変化がシミュレーションできることを示した[10]。Grubwinklerらは、収集した多様な車両の走行データを元に統計的に車両走行データを生成し、その生成データを入力としてEVの消費エネルギー推定を行った[11]。Itoらは、EVを含めたプローブカーデータベースを元に、速度や加速度に対するエネルギーの期待値のMAPを生成することで、EVの航続距離推定を行った[12]。Zhangらは、自車の走行ログや走行時の交通状況、天気情報を使用して、精度と計算資源を考慮したEVの航続距離推定方法を提案した[13]。それに対して我々は、運動方程式を利用したモデル[3]や[2]を利用し、具体的なEVのデータ解析やデータ利用を想定したデータベースを構築することとした。我々の研究は、「実際のデータを利用した、消費エネルギー量推定モデルの実践的な応用方法」に取り組んでいる点で、以上の研究と異なる。また、3章で提示するEV消費エネルギー量の推定においては、実際のデータを使用し、既存のマップマッチングアルゴリズムによる位置データの補正や、推定精度評価のための正解データにクレンジングを施す。そのため、EVの推定モデルの提案ではなく、実際のデータを元に生成したEVの消費エネルギーデータを利用するために必要な知見を示すことに、我々の研究の独自性がある。

一方で、機械学習を利用したEVの消費電力推定の研究もおこなわれている。Felipeらは、人工ニューラルネットワークにドライバーの運転スタイルと走行ルートの特徴を入力することで、EVの走行時の消費電力量推定をおこなった[14]。FeiらとMartinezらは、運動方程式を利用した消費電力量推定モデルに、機械学習を利用したモデルを組み合わせたハイブリットモデルの提案を

行った [15, 16]. 一方で, Yang らは自動車にはセンサを設置せずに, 交差点に車の通過を感知するセンサを設置することで, 道路毎の平均速度や停止頻度から区間ごとの消費エネルギー推定や二酸化炭素排出量を推定する手法を提案した [17]. これらの研究の目的は, EV のバッテリー残量や航続距離や運転スタイルなどの推定のみで, エネルギーの消費要因を細かく分析を行うことを考慮していない. そのため, 走行データの応用先が限られてしまうことが考えられる.

また, これらの手法は, 取得したデータをライフログとして蓄積し, 後から運転者や車両, 時間, 道路区間, 車両の速度や加減速などの走行状況を元に分析することを考慮していない.

2.1.2 EV の消費エネルギー最適化

そのほかに, EV の消費エネルギー最小化を目的とした EV の制御手法や経路決定問題を扱った研究も存在する. これらの研究は, 運動方程式を基にした消費電力量推定モデルを利用している. Styler らは, プローブカーデータを元に REX (レンジエクステンダー) EV の消費電力量を推定した上で, 省エネルギーなレンジエクステンダーの制御方法の提案を行った [18]. Karbowski らは, 交通情報や道路データ, マルコフ連鎖により生成した仮想車速データを入力として, PHEV の消費エネルギーシミュレーションとそれを基にした制御方法を提案した [19]. Kurtulus らは, 交通情報や天気, 地図情報, 目的地を入力として, REXEV 向けの消費エネルギーとバッテリー損耗を考慮した経路決定アルゴリズムを提案した [19]. De Souza らは, EV の走行時間と消費エネルギーを最小化するような交通量分配問題を解くアルゴリズムの提案を行った [20]. しかし, これらの研究は個々の車両の走行データの使用は想定しておらず, 個人の運転や車両の特性によっては, 最適解とは異なる結果となる可能性がある.

2.1.3 自動車走行ログの活用

また, 自動車より収集した走行ログを活用する研究も盛んにおこなわれている. 特に, 交通データの可視化 [21] は注目されており, 多くの研究がみられる. しかし, その多くは移動時間に関する可視化に関するもので, EV の消費エネルギーに着目した可視化に関する研究は行われていない. それに対し, 我々は今後の EV 社会を見据え, EV の消費エネルギーに関する有用なデータ可視化を提案していく必要があると考える.

他の自動車の走行ログの可視化に関する研究として, 飯島らは, プローブカーで収集した道路状況を元に, 渋滞状況を地図の色分けで可視化するシステムを構築した [22]. Komamizu らは, EV の運転軌跡をドライバーの属性情報と共に表示し, 道路を走行する EV の数を可視化するフレームワークを提案した [23]. これらの研究は, 渋滞情報の可視化に着目しており, 消費エネルギーの可視化に着目する我々の立場と異なる.

Wilmink らは, 情報提示による運転の改善が二酸化炭素の排出を削減することをシミュレートした [24]. この研究は, ドライバーへのデータフィードバックを主な目的としており, データ管理手法やデータ応用を提案する我々と立場が異なる.

自動車より収集した走行データをログとして蓄積し, そのログをデータ管理する仕組みの提案も行われている. 矢野らは, プローブカーデータを基に推定した EV の消費エネルギーを分散処理基盤上で管理し, EV のバッテリー残量を考慮した EV 経路探索プラットフォームの提案を行った

[25]. Fouladgar らは、道路ネットワーク上を移動する移動オブジェクトとして自動車を扱い、その GPS ログを空間、時間、ID での検索が可能な DB の構築とクエリの定式化を行った [26]. これらの研究は、EV の消費エネルギーデータに対してアドホックなクエリを可能にする我々の研究とは立場が異なる。

それに対し、我々の先行研究として、既存の自動車の走行ログから EV の消費エネルギーを推定し、EV なしで未来の EV を予測するデータベースシステム (ECOLOG システム, 図 2.1) を構築してきた [4]. このシステムを使用したデータ利用例として、道路特有の通過時間と消費エネルギーの可視化 [9, 27] を行ってきた。これらの研究により、有意な道路区間による消費エネルギーデータを集計を行い、EV の消費エネルギーに関する有用な可視化が可能という知見を得ることができた。本論文では、この有意な道路区間で集計可能なデータベースを構築することで、有用な EV の消費エネルギーデータ解析が可能であることを 5 章で示す。

この有意な道路区間による時空間データの検索は、文献 [26] によると、指定した経路 (Path) 上を移動したデータを結果として返す Path-based Query に相当すると考えられる。Krogh らは、Path-based Query を GPS などの軌跡データに対し高速に実行するためのインデックスを提案した [28]. 本論文の目的は、有意な道路区間を利用したデータ解析が有用であることを示すことであり、この研究とは立場が異なる。そのため、クエリ応答時間などのデータベースの性能評価については、本論文の対象外とし今後の課題とする。また、これらの先行研究では、EV の消費エネルギーの推定において、入力データ (GPS ログ) の補正方法や正解データのクレンジングが不十分であり、正しく推定や精度検証が行えていたとは言い難い。これらの問題を解決するために 3 章で記述する課題「自動車走行ログを使用した電気自動車消費エネルギー量の推定」に取り組む。また、先行研究においては、有用な可視化が可能であることを示すことに留まり、どのように EV の消費エネルギーログという多変量データから、ユーザーやデータ解析者が有用な情報を取得するかに関して十分に論じているとは言い難い。そこで 4 章では、データ解析を支援するシステムを構築し、そのシステムにより EV 消費エネルギーデータの解析支援を行う課題「多変量データ解析支援システムと電気自動車消費エネルギーデータへの応用」に取り組む。

2.2 データ可視化とデータ解析支援

本節では、本研究の 1.2.2 項に記述した多変量データ解析支援システムで着目したデータ可視化手法である平行座標プロット (PCP) とデータ解析支援に関連する研究について言及する。

2.2.1 平行座標プロット (PCP) とデータ操作

1985 年、Inselberg によって初めて PCP の概念が定義された [29]. それ以来、PCP に関する様々な議論がされてきており、情報可視化の分野において重要なトピックの 1 つとなっている [30]. Johansson らによれば、PCP の研究は次の 4 つに分類される [30]: (1) PCP の (属性) 軸レイアウト, (2) PCP の Clutter 軽減方法, (3) PCP の実応用例の提示, (4) PCP と他のデータ解析手法との比較。上記の通り、ほとんどは PCP の見せ方に関して議論がされているものがほとんどであり、操作の過程に着目した議論はされていない。また、可視化と同時にデータに SPJ¹ のような演

¹SPJ: Selection(選択), Projection(射影), Join(結合)。いずれも関係データベース固有のデータ操作演算。

算を加えることは議論されていない。

また、Bouali らは、対話型遺伝的アルゴリズムを使用することで、可視化手法の推薦を行うシステムを構築した [31]。これは、データや利用者の要求に応じてより適切な可視化手法 (散布図行列や PCP など) の選択を支援するものである。我々の提案システムは関係代数における SPJ 質問に相当する表現力を持つような可視化システムを構築するため、タプルが 1 つの線で明示され、詳細に参照・分析可能である PCP が適切である。

一方で、インタラクティブに操作しながら PCP による分析を支援するシステムの提案もされている。Itoh らは、属性軸間の相関に基づいてインタラクティブに次元削減を行い、PCP から所望する情報の発見を支援するシステムを構築した [32]。Zhou らは、エントロピーの概念を導入することで、PCP の属性軸の整列順序をクラスタに基づいて決定する手法の提案をした [33]。

一方、多変量データを可視化するその他の有名な手法として、複数の散布図を表示する散布図行列が挙げられる [34]。しかし、散布図行列は、属性同士の相関を直感的に把握できるが、散布図数が属性数の 2 乗に比例して増加する。そのため、データの操作過程で SPJ (特に Join) を適用することには不向きであるといえる。

以上の関連研究に対して、我々の先行研究 [8] では、PCP 上で関係代数演算に相当するインタラクティブな操作を可能にし、その操作を SQL に類似した言語 $(PC)^2L$ で保存する多変量データ解析支援システムを実装した。しかしながら、先行研究では、PCP によるインタラクティブな操作と言語による保存のみに着目しており、データ解析者が求める有用なデータ取得の支援を行えていない。それに対し、本研究ではデータ可視化も併せて支援することを可能にし、データ解析プロセス全体の支援を行う。

2.2.2 データ解析支援

他の研究として、データやシステムの操作過程を管理する研究 (Provenance) が行われている [35]。特にデータやシステム、プログラミングコードなどの操作過程や意図を保存することは、複雑なデータ処理を支援するために重要なことであるといわれている。さらには、解析結果データの操作過程や意図を示すことは、SQL のような関係代数演算をサポートする問い合わせ言語で記述することが有効であるともいわれている。その点で、我々が定義した操作言語を用いて、可視化システムによるデータの操作過程を保存することは有効な手段であるといえる。

システムの操作過程を保存してユーザのタスクを支援する手法として、Waldner らは、PC のアプリケーション操作ログを記録し、そのログを時系列が理解できるように可視化することで、ユーザが過去に行った意思決定の検証やデータソースの再取得の支援を行った [36]。Mindek らは、画像データに分析過程に利用する他のデータソースのデータを同時に表示し、分析者の文脈を保存したスナップショットを保存することで、シミュレーションデータの可視化や文書分析の支援を行った [37]。Gratzl らは、PCP やヒートマップ、散布図行列など様々な可視化手法を組み合わせることで複数のデータソースから得られたデータとその解析過程を可視化し、データ解析の支援を行った [38]。これらの手法と比較して我々のデータ分析手法は、「可視化システムのデータ解析過程を可視化して見せる」のではなく、「SQL に類似した言語を用いてデータ解析の途中結果を保存し、問い合わせ言語として一般的な SQL に親しみのあるデータ解析者を支援する」ものであり、立場が異なる。また、言語を用いて操作過程を保存する利点として、言語の一部を書き換えるだけで

データ解析の改善をすることが容易であり，その点でこれらの研究と比較して優位性をもつ．

また，大量のデータを対象とし，インタラクティブにデータ可視化を行う研究については多くの事例が見られる [39]．中でも，関係データベーススキーマに基づくデータに対し，GUI上でクエリの記述や複数の可視化の連携を可能にし，データ解析を支援する研究も複数行われている．Derthickらは，データオブジェクトを可視化しつつ，インタラクティブにGUIでクエリが表現可能な環境を構築した [40]．Northらは，データの可視化と，表示した複数の可視化間の連携をユーザーが自由に変更可能なインターフェースの構築を行った [41]．杉渕らは，クエリフローモデルによる直感的かつ段階的なクエリが構築可能なGUIを機能として備えた，可視化フレームワークを実装した [42]．これらの研究は，可視化とクエリをGUI上で連携させることで，インタラクティブなデータ解析を支援する点では，我々と立場が同じと言える．その一方で，これらの研究は，「データベースに習熟していないデータ解析者を支援する」点を重視している．本研究における多次元データ解析支援システムは，「データ解析過程と可換なSQLに類似した言語により，データベースやSQLに習熟した解析者を支援する」ことを目的としており，これらの研究とは立場が異なる．

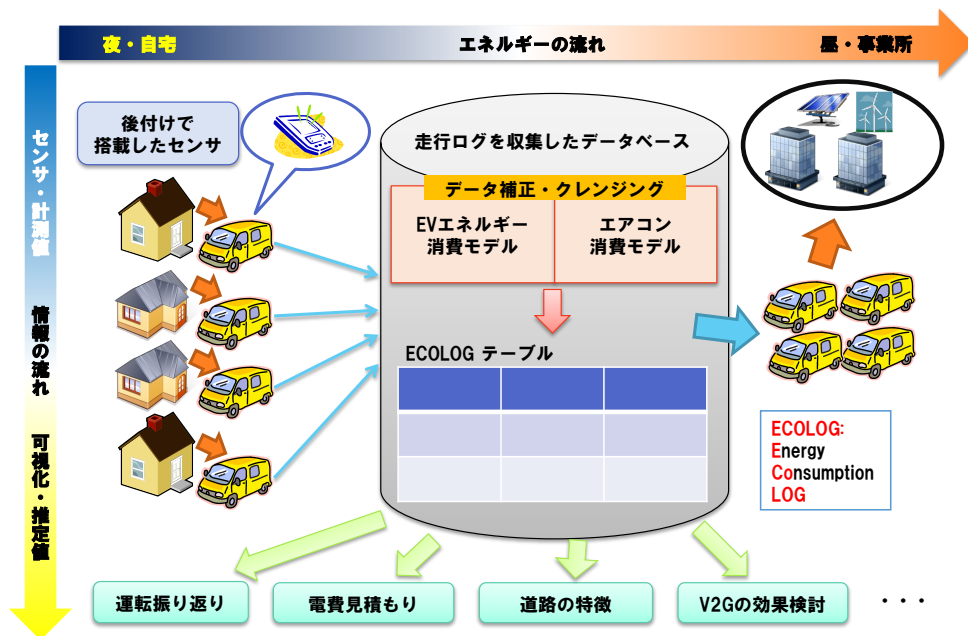


図 2.1: ECOLOG システムのコンセプト図

第3章 自動車走行ログを使用した電気自動車消費エネルギー量の推定

3.1 はじめに

本章の目標は、自動車走行ログを使用した電気自動車消費エネルギー量の推定方法の確立、すなわち、センサデータ・正解データの収集・それら収集したデータのクレンジング・推定モデルの構築・推定精度検証までの一連の流れを確立することにある。

推定モデルにおいては、EV 電力消費の大部分を占める走行とエアコンに関してそれぞれ推定モデルを使用した [4]。

走行に使用した推定モデルについては、EV の電費や消費エネルギーの要因を分析可能とするために、運動方程式を基にした推定モデルを使用した。この推定モデルは、GPS の計測値から計算した勾配、速度データを入力し、瞬間の EV の走行に関する消費エネルギーの推定を行う。勾配データについては、GPS により計測された位置データから地図標高データを参照し、標高の差分値を求めることで計算する。ただし、GPS 位置データには多くの計測誤差が含まれる。そのため、従来のマップマッチングアルゴリズム [43] を位置データに適用し、補正を行う。また、速度データの取得には、位置データの差分から速度を求める方法や、その速度にローパスフィルタを適用することで計測誤差を低減する方法、GPS が計測するドップラーシフト速度などの複数の手法が存在する。そのため、これらの複数の補正手法や取得方法を検討し、正解データと比較した推定精度評価を行うことで、最も精度良く EV の消費エネルギーが推定可能な手法を検討する [5, 6, 7]。

EV の走行に使用した消費電力量の正解データに関しては、EV の CAN データ独自のノイズが含まれていることから、長期間に及ぶ EV の実験データを収集した経験を基に、ノイズが含まれているデータを排除するデータクレンジングを施す [4]。このデータクレンジング前後で、精度評価が正しく行えているかについての評価を行う。

エアコンの推定モデルについては、EV の車種ごとに性能や動作が異なる。そのため、走行に使用した消費エネルギー量の推定と同様の理論に基づいたモデルにより、消費エネルギーやその要因を分析可能にすることが難しい。そこで、一度の走行（今後、トリップと呼ぶ）で使用されるエアコンに使用した消費エネルギー量を推定し、EV の車種ごとにデータを収集すれば構築可能なモデルとして、人工ニューラルネットワークを利用したモデルを構築した。なお、走行とエアコンに使用した消費エネルギー量を全て合算した、総合の推定精度評価は本論文では行わない。総合的な精度評価には、走行とエアコンの消費エネルギー量と同じ集計単位で集計する必要がある。すなわち、トリップ単位での集計が必要となる。しかしながら、走行に使用した消費エネルギー量の正解データは、データクレンジングによりデータの一部を排除している。そのため、走行に使用した消費エネルギー量のデータは一部欠損しており、トリップ単位で集計した走行とエアコンに関する消費エネルギー量の、公平な評価は行うことが出来ない。また、このニューラルネッ

トワークモデルは、ベースラインモデルであり、今後の課題として、より粒度が細かく消費エネルギーの要因が推定可能なモデルを構築することが考えられる。

ただし、本章で使用したデータ補正およびデータクレンジング手法は、従来手法、もしくは、簡易な方法を用いており、その手法自体に独自性はない。ガソリン車などのEV以外の自動車の走行ログからEVの消費エネルギーを推定する手法に対し、実践的にこれらの補正やクレンジングを適用して評価したことに本研究の独自性がある。

3.2 EVモデルによる消費エネルギー推定

本節では、瞬間の走行に関するEVの消費エネルギーを推定するためのEVモデルを式(3.1)に記述する。EVの消費電力 $P_e(t)[W]$ は、空気抵抗により消費されるエネルギー $P_{AIR}[W]$ 、タイヤの変形などにより生じる転がり抵抗により消費されるエネルギー $P_{ROLL}[W]$ 、坂道の勾配によって発生する登坂抵抗により消費されるエネルギー $P_{SLOPE}[W]$ 、自動車の加減速に応じて発生する加速抵抗により消費されるエネルギー $P_{ACC}[W]$ の総和($P_d(t)[W]$)と変換効率 η の積で求めることができる。式における各パラメータを表3.1に示す。

$$\begin{aligned}
 P_e(t) &= (P_{AIR} + P_{ROLL} + P_{SLOPE} + P_{ACC}) \\
 &\quad \times \frac{1}{\eta(v(t), P_d(t))} \\
 &= \left(\frac{1}{2} \rho C_d A v(t)^2 \times v(t) + \mu M g \cos \theta \times v(t) \right. \\
 &\quad \left. + M g \sin \theta \times v(t) + \frac{1}{2} (M + M_i) \frac{dv(t)}{dt} \times v(t) \right) \\
 &\quad \times \frac{1}{\eta(v(t), P_d(t))} [W]
 \end{aligned} \tag{3.1}$$

また、EVは減速時に運動エネルギーの一部を電気エネルギーに変換して充電を行うエネルギー回生技術が用いられている。実際のEVの回生は安全を考慮して以下のように制限されている[2]。ただし、 G は重力加速度を表す。

- 加速度が $-0.15G$ 以下の際には、 $-0.15G$ 分の運動エネルギーが回生される。
- 速度が 7km/h 以下であれば回生は行われぬ。

したがって、実際の回生時における $P_e(t)$ は式(3.2)のようになる。ただし、回生の際のエネルギー変換効率は η と同等とする。また、 P_0 は加速度 $-0.15G$ のときのモータの仕事率である。

$$P_e(t) = \begin{cases} P_d \times \eta [W] (P_d(t)/(Mv(t)) > -0.15G \\ \quad \text{かつ } v(t) > 7\text{km/h}) \\ P_0 \times \eta [W] (P_d(t)/(Mv(t)) \leq -0.15G \\ \quad \text{かつ } v(t) > 7\text{km/h}) \\ 0 [W] \quad (v(t) \leq 7\text{km/h}) \end{cases} \tag{3.2}$$

$P_e(t)[W]$ を時間積分することで消費電力量 $E_e[kWh]$ を求めることができる。

$$E_e = c \int_{t_{start}}^{t_{end}} P_e(t) dt \quad [kWh] \quad (3.3)$$

式 (3.1), 式 (3.2), 式 (3.3) を基に EV の消費電力 (瞬時値) について説明する. 図 3.1 は実際の走行における発進から停止までの走行ログから EV モデルでの推定値を示したグラフであり, 横軸は時刻, 縦軸が推定した消費電力である. 図 3.1 ではまず, 加速時に自動車を加速させるために P_{ACC} (緑色) を消費した. 次に一定速度を維持したまま坂道を上る際に P_{SLOPE} (青色) を消費した. その後減速時にブレーキによりエネルギーを回生 (黄緑色) したが, 強い減速を行ったために回生ブレーキの他に摩擦ブレーキを併用したのでエネルギー損失 (桃色) も発生した. 図 3.1 においては P_{SLOPE} と P_{ACC} が瞬間の消費電力として示されるが, これらの電力は減速時や坂道を下るときに回収される. したがって, 最終的なエネルギー消費量に影響するのは転がり抵抗, 空気抵抗, エネルギー変換による損失 (赤色), 摩擦ブレーキによる損失, エアコンや電装品による消費である.

3.3 正解データの定義

本節では, EV モデルとエアコン推定モデルそれぞれの精度検証に必要な正解データの定義を行う. まず, 正解データを定義するために必要な CAN データについて述べる. 次に, CAN データから EV モデルの精度検証のための正解データを定義する. また, 同様にエアコン推定モデルの精度検証のための正解データを定義する. 本章で用いられている記号の定義を表 3.2 に示す.

3.3.1 実車 EV を用いた CAN データの取得

CAN(Controllor Area Network) は, 車載 ECU(Electric Control Unit) 間での通信を行うために開発されたシリアルバス通信規格である. 現在では国際規格 (ISO11898[44] 及び ISO11519[45]) として, ほぼすべての自動車に採用されている. CAN バスを流れるデータはメーカーや車種によって異なるが, ICV なら燃料噴射量, EV ならバッテリー残量といったデータなどのデータを取得することができる.

本研究では, 機械学習モデルにおける学習や推定精度の評価を行うために EV の CAN データを使用した. 実験用の EV として日産 LEAF(ZAA-ZE0 型 2011 年式) を用いた. CAN データの取得には Android アプリ Leaf Spy Pro¹と OBD2(On Board Diagnosis Second Generation) 接続用の Bluetooth 通信端末として PLX Devices Kiwi Bluetooth Wireless Trip Computer and OBDII Scanner を使用した. Leaf Spy Pro を用いて取得した CAN データの例を図 3.2 に示す. Leaf Spy Pro を利用することにより, バッテリー残量やエアコン, 電装品の各出力, 車両に搭載されているリチウムイオンバッテリーの状態のデータを取得することができる.

¹”Leaf Spy Pro”, Google Play, https://play.google.com/store/apps/details?id=com.Turbo3.Leaf_Spy_Pro, 参照 Jan 11, 2021.

表 3.1: EV モデルのパラメータ

パラメータ	単位	意味	取得方法
g	m/s^2	重力加速度	定数
ρ	kg/m^3	空気の密度	定数
μ		転がり抵抗係数	定数
C_d		空気抵抗係数 (CD 値)	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	定数
θ	rad	坂路勾配	地図データから
v	m/s	自動車の走行速度	GPS より取得

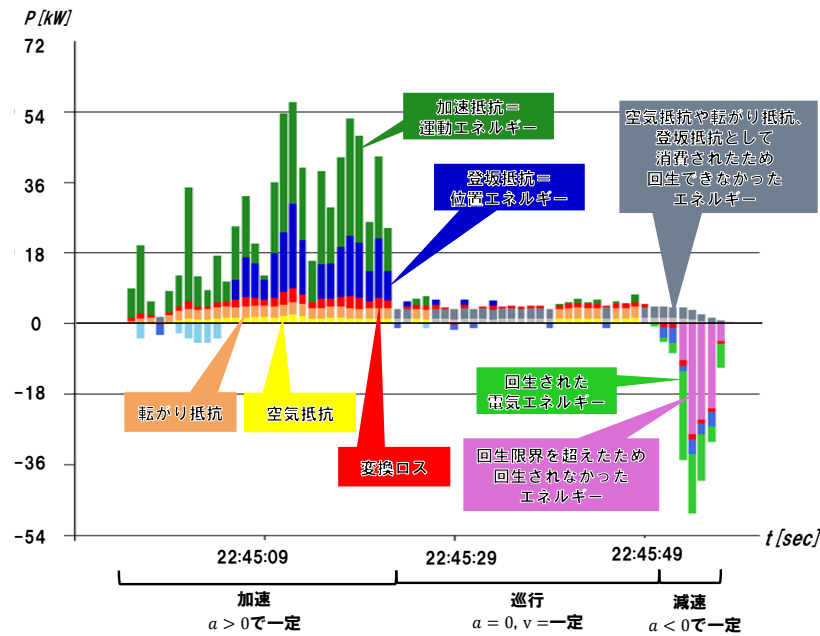


図 3.1: EV モデルによる電力消費推定の例

表 3.2: 記号の意味

記号	単位	意味
E_{motor}	kWh	正解データ (EV モデル)
E_{ac}	kWh	正解データ (エアコン消費モデル)
GID_{start}	GIDs	指定した道路区間に入った時の GIDs 値
GID_{end}	GIDs	指定した道路区間から出たときの GIDs 値
P_{ac}	W	エアコンの消費電力 (瞬時値)
P_{aux}	W	電装品の消費電力 (瞬時値)

3.3.2 EVモデルの精度検証における正解データ

本項では、EVモデルの精度検証における正解データを定義する。EVモデルの精度検証には、Leaf Spy Proで取得できるバッテリー残量を用いた。Leaf Spy Proにおけるバッテリー残量はGIDsという独自の単位で表される。通常、バッテリー残量はバッテリーを出入りした電荷量[Ah]に基づき、満充電容量に対する現在の電荷残量の割合で表される。それに対してGIDsはバッテリーに残されたエネルギーの絶対量を表し、 $1[\text{GIDs}] = 0.0775[\text{kWh}]$ と定義されている。GIDsは整数値であることから、 $GIDs_{start} - GIDs_{end}$ が最大で1GIDs分(0.0775kWh)の誤差を含む。そのため、ある程度大きな単位で精度検証を行う必要がある。一方で、EVモデルは毎秒推定を行うことを想定しており、精度検証においては、可能な限り細かい単位で精度検証をすることが望ましい。そこで、本章での精度検証は、トリップ単位や、実験に使用したルートをある程度の大ききで排他分割した道路区間を単位として、精度検証を行うこととした。

EVの電力消費要因は走行、電装品、エアコンの3つであることから、走行で消費した電力量 $E_{motor}[\text{kWh}]$ は(3.4)式で算出することができる。

$$E_{motor} = (GIDs_{start} - GIDs_{end}) \times 0.0775 - c \left(\int P_{ac} dt + \int P_{aux} dt \right) [\text{kWh}] \quad (3.4)$$

(3.4)式において、 $P_{ac}[\text{W}]$ および $P_{aux}[\text{W}]$ はそれぞれ、CANデータより取得されるエアコンおよび電装品の消費電力(瞬時値)を表す。また、 c は[J]から[kWh]への単位変換のための定数($1/(3600 \times 1000)$)である。

3.3.3 エアコン推定モデルの精度検証における正解データ

Leaf Spy Proによりエアコン出力の瞬時値 $P_{ac}[\text{W}]$ を取得することができる。 P_{ac} を時間積分することで正解データ $E_{ac}[\text{kWh}]$ とした。つまり、(3.5)式で算出できる。

$$E_{ac} = c \int P_{ac} dt [\text{kWh}] \quad (3.5)$$

E_{ac} について正解としての妥当性は未検証であるが、今回は正しいものとして扱った。

3.4 EVモデルの入力データと精度検証

本節では、EVモデルの入力に利用する、GPS位置データの補正手法と、車速データの取得方法について記述する。

3.4.1 GPS位置データ補正

EVモデルにはGPSから取得した車速データと道路勾配データを入力する。本項では、道路勾配データ参照に利用するGPS位置データの補正アルゴリズムに関して説明する。

GPSによる位置計測データより、速度の算出と道路勾配の参照を行う。

しかし、GPSによる位置データには、マルチパスや電離層遅延などの影響で大きな誤差が含まれる。このため、位置データに加え、そこから参照、計算される道路勾配と速度にはそれぞれ、次の(A)、(B)に示されるような誤差が含まれる。結果として、これらの誤差は消費エネルギーの推定の誤差につながる。

(A) GPS計測による位置の誤差

GPSによって、車両の位置を計測すると、実際は道路を走っているにも関わらず、道路から外れた位置が計測されることがある(図3.3左)。

(B) 道路勾配の参照誤り

道路勾配は、GPSで計測された位置から、国土地理院の基盤地図情報数値標高モデル²を参照し、標高値の差分から道路勾配を求める。そのため、道路が高架になっていたり、橋が架けられた場所では、正確な道路勾配を示さない場合がある。その例として、図3.4左に高架の道路での実際のGPS軌跡を示す。このとき、計測車両は高架の道路上を走行していた。しかしながら、誤差が含まれるGPSで計測された位置を基に標高を参照し、勾配を計算してエネルギー推定に用いると、「高架下に急降下し、高架上に急上昇する」ような運動に必要なエネルギーを計上されることになる。図3.4右に見られる推定された消費エネルギー量の瞬時値の乱高下は、以上の誤った道路勾配を用いた推定により算出された値であり、誤りである。

マップマッチングによる位置・道路勾配の修正方法

以上で述べた誤りを改善するために、GPS軌跡データを補正することを考える。一般的な手法として、マップマッチング[43]を用いる。マップマッチングによって(A)GPSによる位置の誤差を低減することが見込まれる。ただし、このマップマッチングアルゴリズム[43]は、車両が走行する可能性が高い道路リンクデータを予め絞り込まなければ、性能を発揮しない。本研究で対象とする軌跡データは、日常的に同じ道路を利用する通勤データを対象とする。そのため、対象となる道路リンクを容易に絞り込むことができる。

そこで本研究では、(B)道路勾配の参照誤りを解消し、EVモデルによる推定精度向上のため、以下のマップマッチングアルゴリズムを適用する。

(Algorithm1) リンク絞込マップマッチング

一般的なマップマッチングである[43]。具体的なマップマッチングの流れを以下に示す。

- (1) 道路リンクデータから、通勤ルート上にあるものを絞り込む
- (2) GPS座標から近い距離にある近傍の道路リンクを絞り込む

²<https://fgd.gsi.go.jp/download/menu.php>, 参照 Jan 11, 2021

TRIP_ID	DATETIME	GIDS	AC_PWR_250W	AUX_PWR_100W
134	2017-01-19 08:47:12.000	188	0	2
134	2017-01-19 08:47:16.000	188	0	2
134	2017-01-19 08:47:20.000	188	1	2
134	2017-01-19 08:47:24.000	188	2	2
134	2017-01-19 08:47:28.000	188	3	2
134	2017-01-19 08:47:32.000	188	3	2
134	2017-01-19 08:47:36.000	188	4	2
134	2017-01-19 08:47:40.000	188	6	2
134	2017-01-19 08:47:44.000	188	7	2
134	2017-01-19 08:47:48.000	188	7	2
134	2017-01-19 08:47:52.000	188	8	2
134	2017-01-19 08:47:56.000	188	8	2

図 3.2: Leaf Spy Pro で取得できるデータの例




図 3.3: GPS の生データ用いて推定した ECOLOG データ

- (3) 道路リンクの線分上の最も近い点へとマッチングさせる
- (4) (2) ~ (3) を GPS 軌跡データの全ての点に適用する

図 3.4 に示した GPS 軌跡データをリンク絞込マップマッチングによって修正し、エネルギー消費量を推定しなおしたデータを図 3.5 に示す。マップマッチングによって GPS 軌跡データが道路上を走行するデータに修正され、推定エネルギーの大きなエラーが見られなくなっている。3.4.3 項で、マップマッチング前後の推定精度を定量的に評価する。

3.4.2 車速データの取得

3.4.1 項では、GPS の位置情報の補正アルゴリズムの検討を行った。本項では、車速データの取得方法の検討を行う。

車速 1：位置データの差分

車速データの取得方法の一つとして、GPS の位置情報の差分（車速 1）として計算することを考えた。しかし、誤差が含まれる位置情報の差分から求めた車速データは、実際は存在しない加減速が含まれたデータとなりうる。図 3.6 は、ICV の CAN から取得した車速と GPS の生データを時間に対してグラフ化したものである。

また、図 3.7 は、図 3.6 と同じ運転ログに Algorithm1 を適用した際の車速データを示している。位置の差分として求めた車速データは、CAN から得られた車速には見られない加減速が存在しており、これは GPS の計測誤差によるものである。

そこで、この車速の誤差を改善するために車速データにローパスフィルタを適用する補正手法（以下 Algorithm2）を提案する。図 3.6、図 3.7 で示したように GPS の誤差は車速データには強い加減速としてあわられる。つまり周波数空間に車速データを展開した場合、高周波成分が車速の誤差に相当する。そのため、ローパスフィルタを車速に適用することで車速データの誤差が改善されることが見込まれる。

Algorithm2 の流れを以下に示す。

- (1) 1 トリップ分の GPS 座標データに対し、Algorithm1 を適用（すなわち、マップマッチングを適用）。
- (2) (1) を適用した 1 トリップ分の車速データを高速フーリエ変換。
- (3) フーリエ変換後のデータに対し、カットオフ周波数以上の高周波成分を 0 に。
- (4) (3) を適用したデータを逆フーリエ変換。

(1) から (4) の処理を図 3.6、図 3.7 と同じデータに適用した車速を図 3.8 に示す。Algorithm2 適用後の車速データを生データ、Algorithm2 適用後と比較すると、実際には存在しない加減速が速度データからなくなり、最も CAN データ（正解データ）に近い推移を示している。すなわち、Algorithm2 により (B) 車速の誤差を改善できたことが期待される。しかし、このアルゴリズムの問題点として、実際に強い加減速をした場合にも高周波成分がカットされてしまうことで、実際

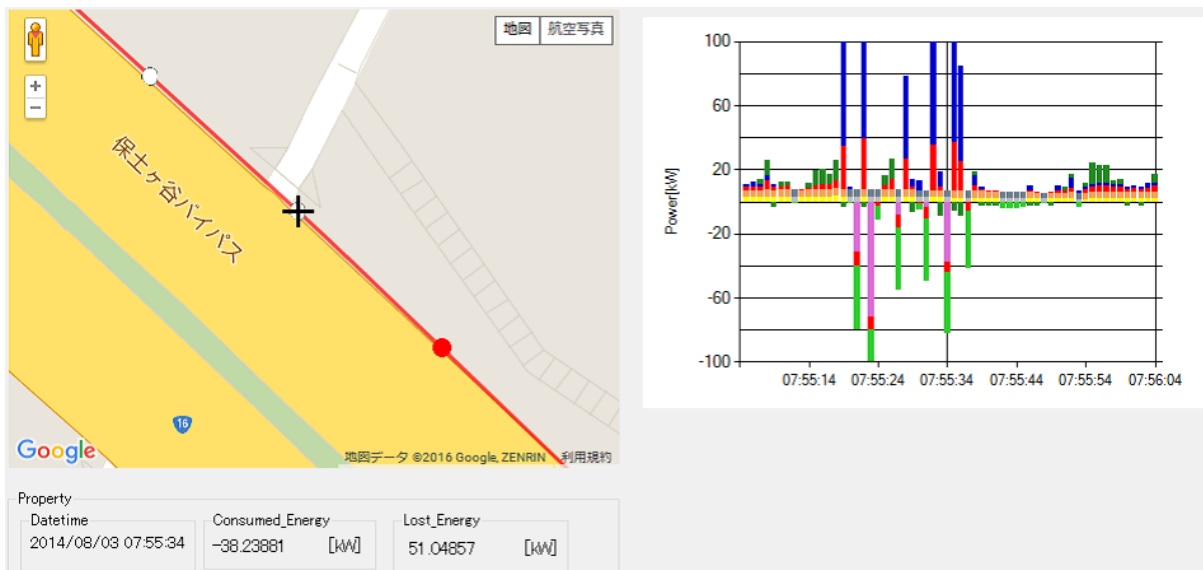


図 3.4: GPS の生データ用いて推定した ECOLOG データ

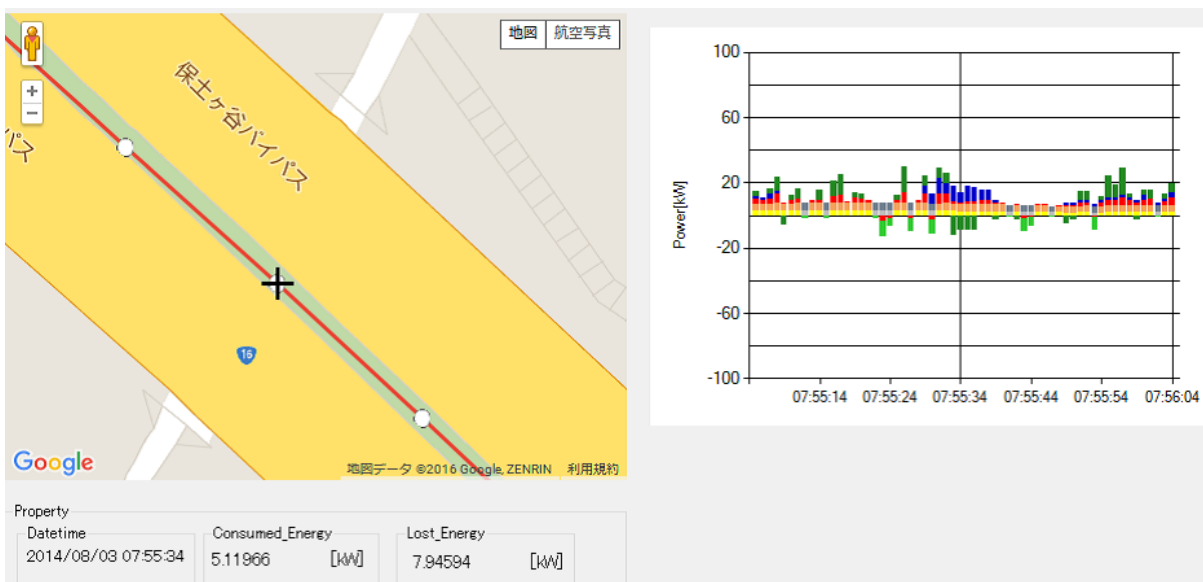


図 3.5: マップマッチング後の ECOLOG データ




図 3.6: GPS の生データから取得された車速と CAN から取得された車速




図 3.7: Algorithm1 適用後の車速と CAN から取得された車速

にあった加減速がデータから消えてしまう可能性が存在する。このことは、運転時の加減速の特徴が消えてしまうことから、消費エネルギーの消費要因を分析することが難しくなることを意味する。すなわち、ローパスフィルタにより補正した車速データはEVモデルの入力には不向きである。

車速2：ドップラーシフト車速

一方で、GPSデータの中にドップラーシフトにより計測された車速データ（車速2）が存在する。この車速データは、スマートフォンでも利用できるようなSPS（Standard Positioning Service）において、データの95%が0.2m/s程度の精度が確保できるといわれる[46]。実験として、ICVにスマートフォンを搭載してGPS走行ログを取得した。計測条件は、表3.3に示す。図3.9に実際に取得した車速1（赤）、車速2（緑）、CANから取得した車速（青）の一例を示す。CANデータによる車速はスピードメータのデータであり、一定割合の誤差を含むことを考慮すべきである。車速1は、加減速が多く暴れやすいデータとなっている一方で、車速2はCANデータの車速に加減速の傾向がよく一致していることがわかる。CANデータの車速と車速1、2それぞれとの差の標準偏差を実験データ全体で計算し、比較することで、定量的に車速の精度評価をする。結果として、車速1は、 $\sigma = 2.87[km/h]$ 、車速2は、 $\sigma = 2.73[km/h]$ となった。これにより、車速2の方が精度が高い車速データを取得できることが分かった。3.4.3項では、車速1、車速2を使用した場合のEVモデルによるエネルギー推定の精度評価を行う。

3.4.3 EVモデル推定精度検証：入力データ

本項では、GPSデータへの補正やドップラーシフトによる車速（車速2）を利用した際の消費エネルギー推定精度を検証する。精度検証のためにEVを使用した走行実験を行い、GPSログから取得した推定消費電力量とCANデータから得た消費電力量 ($E_{motor}[kWh]$) を取得した。実験条件は表3.4に示す。

図3.10に精度検証の結果を示す。横軸 x は E_{motor} 、縦軸 y はEVモデルで推定した消費電力量をそれぞれ表しており、直線 $y = x$ に近いほど正確に推定できているということになる。本実験では、表3.5に示した4つのGPSを元にしたログを利用した1トリップにおける推定エネルギーと、CANから得た消費エネルギー量 ($E_{motor}[kWh]$) を正解としたRMSE（Root Mean Squared Error）を比較した。

1トリップにおけるRMSEは、それぞれ(1) 1.03[kWh]、(2) 3.26[kWh]、(3) 0.82[kWh]、(4) 0.81[kWh]となり、マップマッチングで位置情報を補正し、ドップラーシフトによる車速を入力とした(4)が最もエネルギー推定の精度が高いことが確認された。

3.5 正解データのクレンジングと精度検証

一方、我々は正解データとしてGIDsを扱う上で考慮すべき事項としてGIDs値の非線形性と建物への給電の2つがあることを確認した。我々は、被験EVを使用した放電実験を行うことによりバッテリー残量の非線形推移特性の存在を確認した[4]。また、建物の給電(V2B:Vehicle to




図 3.8: Algorithm2 適用後の車速と CAN から取得された車速

表 3.3: 車速データ精度評価 計測条件

日程	2017年01月23日～2017年1月25日	
被験者	1名	
EV利用状況	通勤トリップ	
トリップタイプ	神奈川県内の一般道及び高速道	
走行条件	往路	約30km, 70分程度
	復路	約25km, 50分程度
センサデータ 取得端末	Android タブレット端末 Google Nexus7(2013)	
CAN データ計測	Android アプリ “Torque Pro” [47]	
トリップ件数	3件	
データ件数	3543レコード	




図 3.9: 車速計算方法の比較

表 3.4: EV モデルの入力データ精度評価 計測条件

日程	2016年05月16日～2017年01月17日	
使用車両	日産 LEAF ZAA-ZE0 型 2011 年式	
被験者	1 名	
EV 利用状況	通勤トリップ	
トリップタイプ	神奈川県内の一般道及び高速道	
走行条件	往路	約 30km, 70 分程度
	復路	約 25km, 50 分程度
センサデータ 取得端末	Android タブレット端末 Google Nexus7(2012), Google Nexus7(2013)	
CAN データ計測	Android アプリ "Leaf Spy Pro"	
収集データ	53 件	

表 3.5: 入力とする GPS データの違い

名前	位置データ	車速データ
(1)ECOLOG	GPS 生データを使用	車速 1 を使用
(2)ECOLOG with MapMatching	GPS マップマッチング済みデータを使用	車速 1 を使用
(3)ECOLOG with LowPassFilter and MapMatching	GPS マップマッチング済みデータを使用	ローパスフィルタ適用した車速 1 を使用
(4)ECOLOG from DopplerSpeed with MapMatching	GPS マップマッチング済みデータを使用	車速 2 を使用

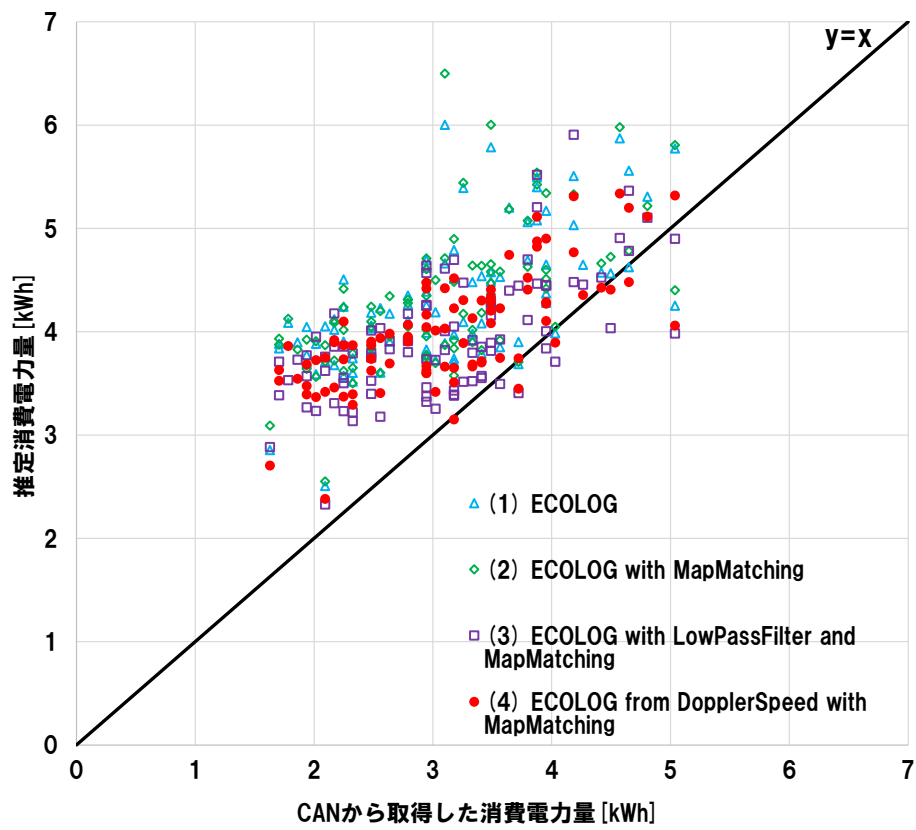


図 3.10: 推定精度検証結果：入力データ

Building) を行った直後は GIDs 値が乱れることを我々は確認した。この2つの影響を受けているデータは精度検証のために利用することはできないが、実際の走行から取得されたデータにはこれらの影響を受けているものも含まれている。そこで我々は、EV モデルのより正確な精度検証のためにデータクレンジングを行った。

データクレンジングとして、以下の条件のいずれかに当てはまる指定した道路区間を走行したデータを精度検証の正解データとした。

- (1) バッテリー残量の非線形推移を示さないデータである。
- (2) 建物などへの給電を行った直後に走行する道路区間以外のデータである。
- (3) 欠損やその他エラーを含まないデータである。

3.2 節で述べた EV モデルの推定精度を検証するため、我々は実際の EV を用いて実験を行った。本節ではその実験と精度検証について述べる。図 3.11 にデータクレンジング処理前後のデータトリップ数、道路区間毎の正解データ数、取得データ合計の秒数をそれぞれ示す。ただし、ここでの道路区間は、実験に使用したルートをある程度の大ききで排他分割したものである。データクレンジングにより、道路区間毎に集計した正解データが、合計 6,286 件あった内、精度検証に適さないデータを排除した結果、1,922 件のデータとなった。実験条件を表 3.6 に示す。以下、道路区間単位で集計した推定精度検証結果を示すことで、道路区間ごとの推定誤差の傾向を把握する。

3.5.1 EV モデル推定精度検証：正解データクレンジング

3.4 節で記述した入力データ (4)ECOLOG from DopplerSpeed with MapMatching によるエネルギー推定を行い、加えてデータクレンジングを施した道路区間単位での精度検証結果を図 3.12 に示す。プロット 1 つは実験用走行ルートを排他分割した道路区間上を一回走行したデータに対応している。精度検証の結果、RMSE (Root Mean Squared Error: 平均二乗誤差) は $\sigma = 0.092 \text{ kWh}$ であった。図 3.12 を見ると、 $+2\sigma$ を超えて Over Estimate、もしくは、 -2σ を下回り Under Estimate しているデータが存在する。特に Over Estimate しているデータを見ると、高速道路の合流区間、上り坂での発進がある区間などの強い加速をする区間が多くを占めていることが今回のデータを詳細に分析することで、把握することができた。この事実は、加速時に発生する変換ロスのパラメータである変換効率 η の設定により誤差が生じている可能性を示唆していると考えられる。これにより、道路区間特有のエネルギー消費要因の傾向から、推定誤差の要因を確認できた。

3.6 EV モデル推定精度検証：総合評価

本節では、クレンジングを施した正解データを利用し、3.4.3 項で行った精度検証と同様に、1 トリップごとの集計した入力データごとの EV モデル推定精度評価を行う。実験条件と精度検証の結果を表 3.7 と図 3.13 にそれぞれ示す。1 トリップにおける RMSE は、それぞれ (1) $0.33[\text{kWh}]$, (2) $0.50[\text{kWh}]$, (3) $0.23[\text{kWh}]$, (4) $0.27[\text{kWh}]$ となり、(3) が最もエネルギー推定の精度が高いことが確認された。しかしながら、3.4.2 項で考察したように、ローパスフィルタによる車速データの補正は、EV モデルの入力に使用するには不向きである。そのため、(3) をエネルギー推定に

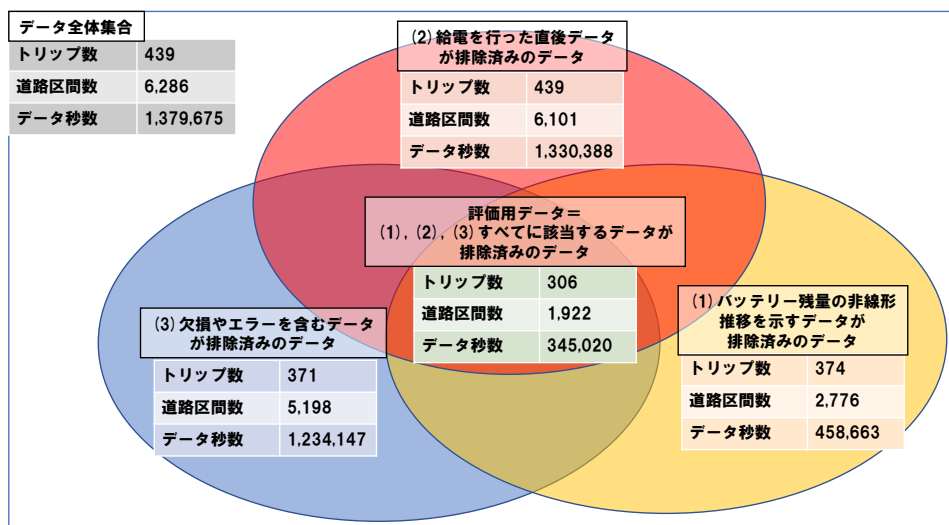


図 3.11: データクレンジング結果

表 3.6: EV モデル精度評価 実験条件

日程	2016年7月22日～2018年12月18日	
使用車両	日産 LEAF ZAA-ZE0 型 2011 年式	
被験者	1 名	
EV 利用状況	通勤トリップ	
トリップタイプ	神奈川県内の一般道及び高速道	
走行条件	往路	約 30km, 70 分程度
	復路	約 25km, 50 分程度
センサデータ取得端末	Android タブレット端末 Google Nexus7(2013)	
CAN データ計測	Android アプリ ”Leaf Spy Pro”	
収集データ	往復トリップ 308 件	

利用することは適切ではない。そのため、(3)に次いで推定精度が高い(4)をエネルギー推定に利用することが適切である。

(4)を利用した場合の走行による消費電力量推定の誤差範囲は $\pm 2\sigma = \pm 0.54\text{kWh}$ と考えると誤差は大きい。しかし、日々のデータを大量に蓄積して利用するという観点においては、実測値に近い値を導出できている。本研究の目的である自動車走行ログのEVへの応用の観点からすれば、例えば大量のEVを利用したスマートグリッドに関する情報提示[48]などの、大きい単位でのEV消費エネルギーログの集計では十分な精度であり、用途によってはこの程度の誤差であっても有用な情報提示が可能であると考えられる。これらの誤差要因を考えると、現在のEVモデルでは、自然風の影響、回生ブレーキや転がり抵抗の計算に温度特性が考慮されていないこと、適切な変換効率 η が設定されていないことが考えられる。これらを考慮したEVモデルを構築することでより高精度なEVの消費電力量推定が可能であると考えられる。

これらの実験結果により、1台、1運転者のデータを同一道路条件でディープに収集することにより、これらのデータは誤差を含むが、結果として誤差範囲を定量化することができたため、統計的な傾向を把握するには有用である。このEVモデルが汎用性を有することを検証するために、今後は他車種のEVや異なる被験者に対して、今回行った方法と同様の手段に則り再評価する必要がある。

3.7 エアコン推定モデルの精度検証

本節では、EV電力消費要因のうちエアコンについてその消費電力量推定の精度検証を行う。まず、エアコン推定モデルについて説明する。そして、エアコン推定モデルの精度検証を行う。

3.7.1 エアコン推定モデル

3.2節では走行に関するエネルギー消費について述べた。しかし、実際の運転では走行以外にもエアコンや電装品の使用によって消費されるエネルギーも存在する。ある被験者の月ごとのEVエネルギー消費量の平均を要因別に示したグラフを図3.14に示す。緑色が走行による消費、赤色が暖房による消費、青色が冷房による消費、黄色が電装品による消費をそれぞれ表している。図3.14から、エアコンによるエネルギー消費は他の要因と比較して変動が大きく、かつEV全体の消費のうちに占める割合が大きいことがわかる。したがってエアコンによるエネルギー消費を無視することはできず、個々人の状況に応じた消費電力量を推定する必要がある。本項ではその推定モデルについて説明する。

カーエアコンは温度や湿度などの気象状況によって制御されている[49]。さらに、外気温度とエアコンの消費電力の関係を示した図3.15のグラフから、エアコンは温度のみならず日射の状況によっても制御されていることがわかる。また、エアコンの挙動は車内温度を目標温度まで上昇あるいは下降させる高出力モードと目標温度に達した車内温度を一定に保つ低出力モードの2つに大別される。ある被験者が寒い冬の朝にEVで出勤したトリップにおけるエアコンの消費電力の推移を表したグラフを図3.16に示す。図3.16のグラフは3.3.1項で述べたCANデータから作成しており、高出力モードを橙色、低出力モードを緑色で示している。




図 3.12: 推定精度検証結果：正解データクレンジング

表 3.7: EV モデル精度評価：総合評価 実験条件

日程	2016年7月22日～2018年12月18日	
使用車両	日産 LEAF ZAA-ZE0 型 2011 年式	
被験者	1 名	
EV 利用状況	通勤トリップ	
トリップタイプ	神奈川県内の一般道及び高速道	
走行条件	往路	約 30km, 70 分程度
	復路	約 25km, 50 分程度
センサデータ 取得端末	Android タブレット端末 Google Nexus7(2013)	
CAN データ計測	Android アプリ "Leaf Spy Pro"	
収集データ	往復トリップ 237 件	




図 3.13: 推定精度検証結果：総合評価




図 3.14: 月別・要因別の平均消費電力量




図 5.147 車両熱負荷と必要能力

図 3.15: 外気温とエアコンの消費電力 ([50] より引用)




図 3.16: あるトリップにおけるエアコン出力の推移

以下で、図 3.16 について説明する。最初の約 10 分間は車内温度が設定温度よりも低い状態であったため、エアコンは高出力モードだった。そのままの状態で一時的に停車し、エアコンを停止した。約 20 分経過時にエアコンを再始動させたが、エアコンが停止した間に車内温度が下がったため、エアコンは再度高出力モードで制御された。25 分経過時に設定温度に達したため、低出力モードへ移行した。50 分経過時に再度車両は停車し、約 2 分間のエアコン停止を行った。その結果、52 分経過時から約 5 分間高出力モードとなった。

このように、一時停止が長いと外気温に応じて車内温度が低下し、再始動した際には設定温度に達するまで高出力モードとなることをくり返す。また、停止した時間に応じてエアコンで消費されるエネルギーが変化する。すなわち、エアコンの消費電力量を推定するには、気温や湿度に加え、運転時間や停車時間を入力する必要がある。

エアコンの消費エネルギーは、以上のような特性を持つ。しかしながら、スマートフォン等で簡易に取得できるセンサデータやオープンデータから、消費エネルギー推定を行うには、車両に搭載される異なるエアコンごとの特性を考慮する必要がある。そこで、我々はエアコン消費電力量の推定モデルを入力（気象状況など）と出力（消費電力量）との対応付け問題であると考え、人工ニューラルネットワークを用いて解決することを考えた。なお、本モデルの出力は、1 トリップのエアコンの消費電力量であり、瞬間の消費電力量を出力する EV モデルと比較して非常に粒度が荒い。なお、本モデルは、EV のエアコンに関する消費エネルギーを推定するための簡易的なモデルである。そのため、今後の課題として、粒度が細かく、消費電力量の要因も可視化できる推定モデルを構築する必要がある。

人工ニューラルネットワークにより構築した推定モデルを図 3.17 に示す。EV の車種ごとに学習データを収集し、車種ごとの推定モデルを構築することを想定している。推定モデルは、シンプルな 3 層の人工ニューラルネットワークとし、隠れ層のユニット数は 4 つとした。また、推定モデルの入力、ハイパーパラメータをそれぞれ表 3.8, 表 3.9 に示す。我々の提案手法は、トリップ全体を停車に基づいて分割し、分割したそれぞれに対して t_{trip} と t_{drop} を設定する。これらを推定モデルの入力データとすることで、上述した一時停止時間に応じて変化する高出力モードのエネルギー消費量の特徴を考慮できる。その概念図を図 3.18 に示す。 t_{start} は推定対象トリップの開始時刻、 t_{end} はトリップ終了時刻、 $t_{lastEnd}$ は推定対象トリップの 1 つ前のトリップの終了時刻、またはタイマーエアコンの終了時刻である。時刻 t_{start} に出発したドライバーが、時刻 t_1 に一時停車をした。その後時刻 t_2 に運転を再開し、時刻 t_3 に一時停車をした。最後に時刻 t_4 に運転を再開し、時刻 t_{end} に目的地に到着、運転を終えた。このとき、 $[t_{lastEnd}, t_1], [t_1, t_3], [t_3, t_{end}]$ の 3 つの区間にトリップを分割する。そして分割したそれぞれについて、 $t_1 - t_{start}, t_3 - t_2, t_{end} - t_4$ をそれぞれ t_{trip} 、 $t_{start} - t_{lastEnd}, t_2 - t_1, t_4 - t_3$ をそれぞれ t_{drop} と設定する。分割後のそれぞれについて推定モデルにより推定消費電力量 Q_t を出力し、最後にトリップ単位に集約した Q_{trip} を計算する。

3.7.2 エアコン推定モデル精度検証実験

3.7.1 項で述べたエアコン推定モデルの推定精度を検証するため、我々は実際の EV を用いて実験を行った。本項ではその実験について述べる。実験条件を表 3.10 に示す。

また、取得したデータを以下に示す。

- 入力として用いるデータ




図 3.17: エアコン消費電力量推定モデル

表 3.8: エアコン推定モデルの入力

記号	単位	意味
T_{start}	°C	運転開始時の気温
H_{start}	%	運転開始時の湿度
T_{trip}	°C	運転時の平均気温
H_{trip}	%	運転時の平均湿度
I_{start}	lx	運転開始時の照度
t_{trip}	s	運転時間
t_{drop}	s	停車時間

表 3.9: エアコン消費電力量推定モデルのハイパーパラメータ設定

パラメータ	数値
活性化関数	シグモイド関数
出力関数	一次関数
誤差関数	二乗誤差関数
最適化関数	MomentumSGD
学習率	0.3
モーメンタム	0.2

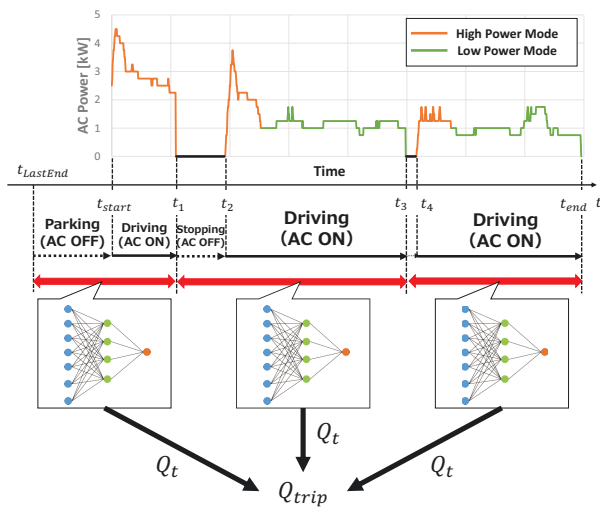


図 3.18: 停車によるトリップの分割

表 3.10: エアコン推定モデル精度評価 実験条件

日程	2017年1月6日～2017年12月4日	
使用車両	日産 LEAF ZAA-ZE0 型 2011 年式	
被験者	1 名	
EV 利用状況	通勤トリップ	
トリップタイプ	神奈川県内の一般道及び高速道	
空調設定	25°C オートエアコン	
走行条件	往路	約 30km, 70 分程度
	復路	約 25km, 50 分程度
センサデータ 取得端末	Android タブレット端末 TOSHIBA REGZA Tablet AT570	
CAN データ計測	Android アプリ "Leaf Spy Pro"	
収集データ	往復トリップ 167 件	

- オープンデータ …… 気温 [°C], 湿度 [%]
- センサデータ …… 照度 [lx]
- 正解として用いるデータ
 - CAN データ …… E_{ac} [kWh]

このうち、気温と湿度は気象庁³公表のオープンデータを用いた。また、Driving Logger により取得したセンサデータは、Android 端末単体で簡易かつ安定的に取得できる照度センサに限定して取得した。センサデータ取得端末は図 3.19 のように、照度センサにフロントガラスから直接日光が当たるように設置した。

3.7.3 エアコン推定モデルの精度検証

3.7.1 項で述べた推定モデルに基づいてデータセットを作成した。作成したデータセットを用いて 10 分割交差検定による精度検証を行った。推定結果を図 3.20 に示す。横軸 x は E_{ac} 、縦軸 y は Q_{trip} である。データ件数は 167 件である。プロット 1 つが 1 トリップに対応している。精度検証の結果、RMSE は $\sigma = 0.24 \text{ kWh}$ であった。

以上より、エアコン消費電力量の推定は走行消費電力量の推定 (3.6 節) よりも少ない誤差で実現された。この推定精度は有効な用途 [48] における判断基準となり得る。例えば、大量の EV をスマートグリッドで利用する場合には、EV の利用形態が多様である。そのために実際の消費電力量の変動も大きい。このような用途では多少誤差があっても全体的な傾向をつかむのに十分である。有効な用途は既にいくつか検証しているが [51, 52]、今後の課題とする。また、EV の置き換え効果を示すことを考えると、今回の評価で十分な推定精度が得られる可能性があることが示唆された。しかし、1 車種 1 被験者のデータによって得られた結果であることから、推定モデルの十分な汎用性があるとは言い難い。そのため、同一車種の別個体のデータや異なる車種のデータに提案エアコン推定モデルを適用した際の精度評価を行う必要があると考えられ、今後の課題とする。

3.8 まとめと今後の課題

3.8.1 まとめ

データの取得からクレンジングとデータ補正、推定モデル構築、精度評価までの一連の EV の消費電力量推定モデルの精度検証手法の提案を行った。

第一に、EV モデルに入力する GPS データ補正手法、速度データの利用の検討を行った。第二に、精度検証のための正解データのクレンジング方法を定義した。走行に使用した消費エネルギーの正解データにノイズが含まれていることを確認し、それらのデータが取り除くデータクレンジングを行った。データクレンジングを行った結果、道路区間ごとの評価では、道路区間 (特に強い加速を行う区間) 特有の走行消費電力量の誤差があることが確認された。道路区間ごとの推定精度改善および、EV のエネルギー消費の要因として存在するものの、EV モデルにおいて考慮されていない自然風の影響や温度特性などの考慮を行っていく必要がある。また、トリップ単位での精度検証

³気象庁, <http://www.jma.go.jp/jma/menu/report.html>, 参照 Jan 12, 2020.




図 3.19: 照度を取得する端末の設置状況

の結果、位置データに対し、マップマッチングアルゴリズムを適用し、速度データは、ドップラーシフト車速を利用した消費エネルギー推定が適切であることを確認した。また、RMSE0.27kWhで推定可能であることが示された。このことから、トリップ単位などの大きな単位での走行消費電力量の推定精度は十分な精度であることが確認できた。

エアコンモデルは、車種ごとに異なるエアコンの特性をデータを元に考慮する簡易的なモデルとして、ニューラルネットワークによるモデルを構築した。精度検証の結果、エアコン消費電力量はRMSE0.24kWhで推定可能であることが示された。

3.8.2 今後の課題

今後の課題として、異なる車両・異なる運転者のデータを収集し、消費電力量推定の精度評価を行うことで、今回提案した精度検証方法・EVモデルの汎用性を示していくことが挙げられる。

また、本研究で使用したEVモデルのパラメータは全て固定値を用いている。しかし、実際には、転がり抵抗係数や車両重量などの定数は車種や車両の個体、路面状況などの外部要因に依存する。そのため、今後の課題として、これらのパラメータを実データを用いた回帰分析で求めた推定モデルの構築が挙げられる。

また、本研究では、スマートフォンのGPSデータをEVモデルの入力データとした。現在のスマートフォンで計測したGPSデータは、補正情報を用いない低精度なGPSデータが一般的である。補正情報を利用したGPSデータを利用した実験を行うことで、GPSの測位精度がおよぼすEVの消費エネルギー推定精度の検討も、今後の課題として挙げられる。

エアコンモデルについては、道路区間単位などのより細かい単位でのエネルギー推定や、消費エネルギーの要因を把握することが可能な推定モデルを構築していく必要がある。




図 3.20: エアコン消費電力量の推定結果

第4章 多変量データ解析支援システムと電気自動車消費エネルギーデータへの応用

4.1 はじめに

我々の先行研究 [8] では、多変量データに対して、関係代数演算を GUI 上のアドホックなクエリとして実行可能なデータ解析システムを実装した。加えて、そのデータ操作過程を SQL に類似した $(PC)^2 L^1$ の言語表記形式で保存する機能により、データ分析の試行錯誤の支援をおこなうことを考えた。データ操作を行う GUI には、多変量データを一覧に可視化可能で、選択・射影・結合などの関係代数演算の基本的な演算が GUI 上で表現可能な Parallel Coordinates Plot (PCP) を利用した。この先行研究 [8] により、GUI 上におけるデータベースに問い合わせるような宣言的アドホックなクエリの記述や、言語による論理的なデータ解析過程の保存が可能になる。しかし、我々の先行研究では、GUI 上でのデータ操作と言語による保存に留まり、具体的なユースケースに基づいた可視化の支援をおこなうことが十分にできているとは言い難い。

一方、EV には、ガソリン車にはない特徴がある。たとえば、減速時にエネルギー回生を行うことや、低温時にはエネルギー消費量が多くなることがある。すなわち、ドライバーの個人差だけでなく地域差や季節差によってもエネルギー消費が変化する。そのため、EV の走行データを利用せずに、EV のメリット・デメリットを明確に把握することは難しいといえる。これらのことから、その人・その場・その時の EV のライフログ（走行時データ）を分析し、データからエネルギー消費の要因を特定することや、EV の固有のメリット・デメリットを定量化することは重要となる。しかしながら、このような走行ログは多種のセンサから得られる多変量データであり、データ解析の支援が必要となる。

そこで我々は、EV の走行ログ解析の支援として、我々の先行研究 [8] のデータ解析支援システムを利用することを考えた。

本章におけるデータ解析プロセスのイメージを図 4.1 に示す。図 4.1 における (1) EV の走行ログでは、我々が長期間にわたり収集し続けた実際の EV の走行ログ (CAN, GPS) を利用する。これにより、実践的なデータ解析例を示すことを目指す。図 4.1 における (2) 解析プロセスでは、今回扱うプロセスを、以下の 3 つを試行錯誤しながら繰り返し、データによる仮説検証や説明を目指すものとした。

- 仮説を立てる。
- データ操作 (アドホックなクエリの適用) を行う。
- 可視化を行うことでデータの傾向を把握する。

この試行錯誤を支援するために、先行研究 [8] の解析支援システムの機能拡張をおこなった。具体的には、すでに実装していた「PCP 上でのアドホックなクエリ実行」機能と「PCP 可換言語

¹Parallel Coordinates Plot Commutative Language の頭文字より。

(PC)²Lによるデータ操作過程の保存」機能に加えて、「リアルタイムなPCPでの操作結果の任意のグラフによる可視化」機能の実装と「(PC)²Lの任意のグラフ可視化に対応する文法拡張」をおこなった。これらによって、リアルタイムにユーザーの操作が反映されるGUIと、データの操作過程を論理的に記述できる言語形式という両者の利点を活かした解析を可能にする。なお、本章の目的は、解析支援システムにより、データベースやSQLに習熟した解析者が求めるデータ解析や可視化を自由に実行可能な環境を与えることにある。また、図4.1における(3)ユースケースでは、データ解析者が試行錯誤しながら、EV特有の複合したエネルギー消費要因を特定していく解析プロセス例を示す。それにより、本支援システムを利用することで、EVの消費エネルギーに関する有用な解析が可能であることを示す。

4.2 データ解析支援システムと(PC)²Lの拡張

本節では、我々の先行研究[8]に対して、拡張を行った部分を中心に説明する。

4.2.1 データ解析支援システム拡張の概要

データ解析支援システムの概要を図4.2に示す。本研究では、先行研究[8]で実装したシステムに対して、図4.2赤枠で示したVisualization(可視化)機能、(PC)²LのVISUALIZE WITH句の追加を行った。

このシステムでは、以下で示す想定する操作を可能にし、図4.1で示した解析プロセスを支援することを想定する。

- (1) 1つのリレーションをPCPにより可視化する。
- (2) PCPを補完する形で、任意のグラフの可視化を行う。
- (3) 可視化をもとに、PCP上でインタラクション(データ操作)を行う。その際、データ操作の結果をリアルタイムに(2)で表示したグラフに反映する。
- (4) 分析者が所望するときに、(2),(3)の解析過程のスナップショットを(PC)²Lで保存する。
- (5) (2)-(4)を繰り返す。その際、過去のスナップショットに戻る必要がある場合は該当する(PC)²Lを入力し、システム上にデータ解析過程を再出力する。
- (6) データ解析者が所望の可視化結果を獲得する。

PCP上で可能なインタラクション機能は、先行研究[8]で示したものを利用する。本項で述べる機能拡張は、上記の(2)グラフによるデータ可視化、および、それに伴う言語表記形式の文法拡張に大別される。

4.2.2 データ可視化機能

本項では、本研究で解析システム上に新たに実装したデータ可視化機能について述べる。

この機能は、PCP上のデータ操作によって得られたデータセットを任意のグラフで可視化する機能である。本章では、選択できる可視化手法として棒グラフ、線グラフ、散布図、ヒートマップ、

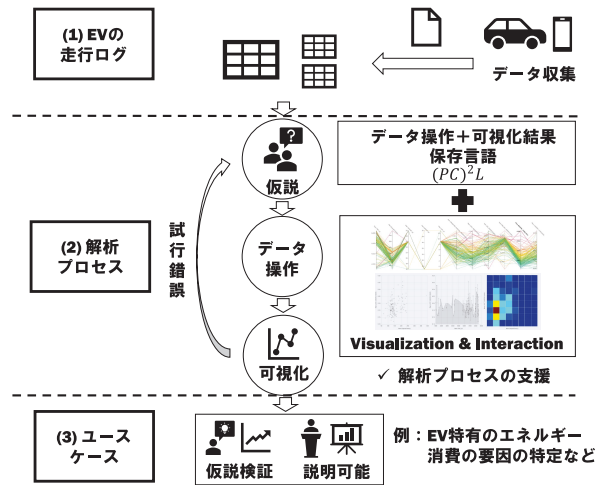


図 4.1: データ解析プロセスのイメージ

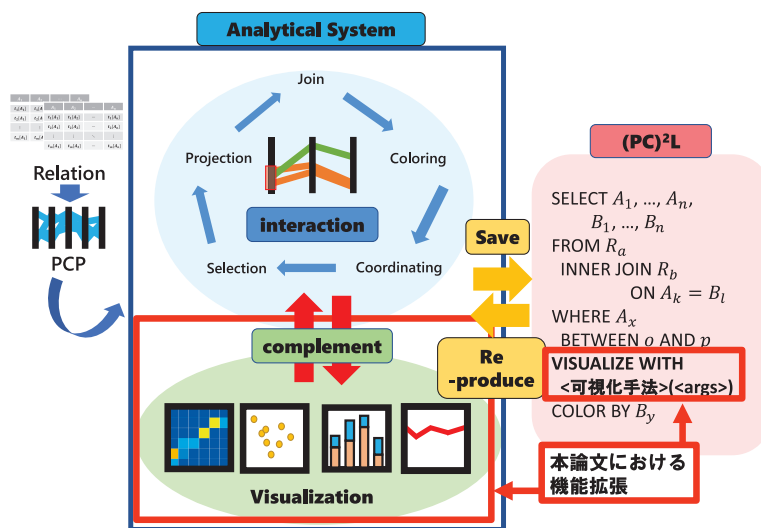


図 4.2: データ解析システムの概要図

バイオリン図の実装を行った。今後の課題として、有用な可視化手法を自由に追加することを想定している。

また、データ可視化に、PCP のインタラクションの結果をリアルタイムに反映する。これにより、PCP の選択操作によってデータ可視化を行いたいデータセットを絞り込むなどの操作が、GUI 上でシームレスに実行可能になる。

また、より有用なデータ可視化を行うため、散布図に回帰直線とその決定係数を描画する機能を追加した。この機能により、軸間の相関のより簡単な把握が可能になることが期待される。

4.2.3 (PC)²L の文法拡張

本項では、先行研究 [8] で定義した、PCP に対する 5 種類のインタラクションの状態を保存・再現するための言語形式である (PC)²L の文法拡張について述べる。

本研究では、データ可視化の状態（使用する可視化手法、グラフ軸に表示する属性）を保存するため、VISUALIZE WITH 句の追加を行った。これにより、(PC)²L を利用することで、システム上の解析過程の中でも、PCP 上の操作だけでなく、任意のグラフによる可視化の状態を言語形式で論理的に保存することが可能になった。

以下に、VISUALIZE WITH 句によるデータ可視化機能の表現方法を記述する。

- データ可視化機能: VISUALIZE WITH 句に「< 可視化手法名 > (< args >)」と記述。

< 可視化手法名 > に指定可能な可視化手法及びその引数を表 4.1 に示す。例えば、SCATTER(A_1 , A_2) と記述すれば、X 軸が属性 A_1 、Y 軸が属性 A_2 の散布図を表示することが可能である。なお、PCP による Selection を適用したデータのみを表示し、軸に対応する属性値の最大値、最小値が収まるように、軸の表示範囲を自動的に変更することとした。また、BAR(A_x , < Func >, A_y^1 , ..., A_y^n) における < Func > は属性 A_y^1 , ..., A_y^n の値に適用する集約関数を示す。AVG: 平均, SUM: 合計, MAX: 最大, MIN: 最小 などの一般的な集約関数が利用可能である。集約単位は 第一引数の A_x の値である。

加えて、回帰直線を描画状態を保存するため、SCATTER の引数 Regression を追加した。ただし、Regression は bool 値 (true or false) である。たとえば、SCATTER(X , Y_1 [, Y_2 , ...], Regression=true) と記述すれば、回帰直線を描画した状態を表す。

4.2.4 実装システムの表示例

実装システムの画面の例を図 4.3 に示す。実装システムは、先行研究 [8] と同様に、環境を問わず利用できるようにするため、Web ブラウザを通して多くの端末から利用できるように構築した。

図 4.3 の A: PCP View では、指定したリレーションのデータを可視化した PCP が表示され、先行研究 [8] で定義したデータに対するインタラクションの中でも、Selection, Coloring, Coordinating が可能である。

図 4.3 の C: Join & Projection Button では、横一行がリレーション一つに対応するトグルボタンが表示される。このボタンにより、先行研究 [8] で定義したデータに対するインタラクションの Join と Projection が利用可能である。ボタン最左部には、Join のためのリレーション名が表示さ

表 4.1: VISUALIZED WITH 句で指定できる可視化手法

可視化手法	引数	説明
BAR(A_x , $\langle Func \rangle$, A_y^1 , ..., A_y^n)	A_x : X 軸に対応する属性名 $\langle Func \rangle$: Y 軸に積み上げる属性値に適用する集約関数 A_y^1 , ..., A_y^n : Y 軸に積み上げる属性名	積み上げ棒グラフ
LINE(A_x , A_y)	A_x : X 軸に対応する属性名 A_y : Y 軸に対応する属性名	折れ線グラフ
SCATTER(X , Y_1 [, Y_2 , ...], Regression=regression)	X : X 軸に対応する属性名 Y_1 , Y_2 : Y 軸に対応する属性名 regression: 回帰直線の描画状態	散布図
HEATMAP(A_x , A_y , d)	A_x : X 軸に対応する属性名 A_y : Y 軸に対応する属性名 d : ヒートマップの分割数	ヒートマップ
VIOLIN(A)	A : 属性名	バイオリン図

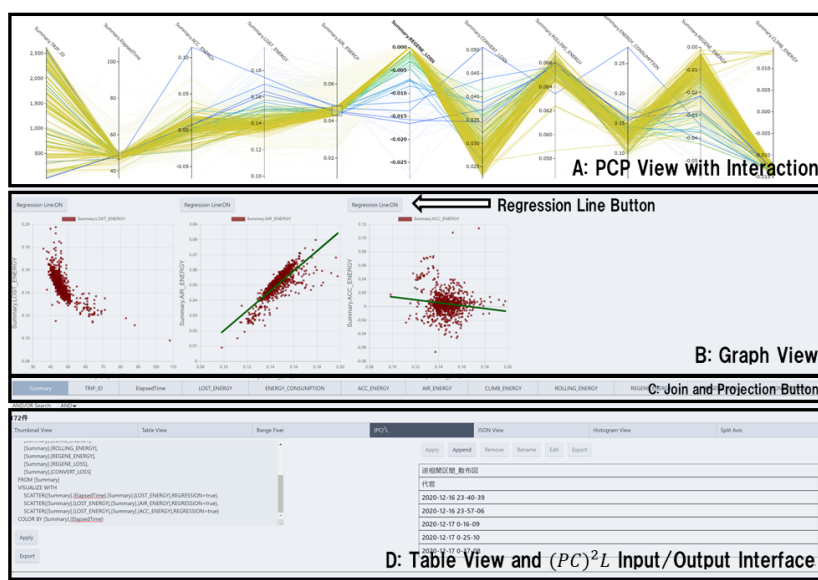


図 4.3: 多変量データ解析支援システムの表示例

れたりレーションボタンが配置されており、クリックすることで結合条件を選ぶための画面が表示される。そこで指定した結合条件に応じた Join を実行することが可能である。なお、すでに Join されているリレーションボタンを再度クリックすると、Join が解除できる。リレーションボタンより右側には、Projection のための軸ボタンが配置されており、クリックすることで軸の表示/非表示を切り替えることができる。

図 4.3 の D: Table View & (PC)²L Input/Output Interface では、A, C でのインタラクションを反映したデータセットのテーブル表示と (PC)²L の入出力を受け付ける UI を持つ。

図 4.3 の B: Graph View では、(PC)²L の VISUALIZE WITH 句で指定したグラフが表示される。A, C 上のインタラクションを反映したデータセットのみがグラフ上に表示される。先行研究 [8] と比較すると、特に B: Graph View が本研究による拡張部分である。

4.3 解析例で使用するデータセット

本節では、後述するデータ解析例で利用するデータセットについて記述する。データセットに含まれるデータ件数と期間を表 4.2 に示す。

4.3.1 データ取得環境

走行ログは、EV による被験者一名の通勤時のデータを継続して取得したものを利用する。また、データ取得用の EV として、日産 LEAF(ZAA-ZE0 型 2011 年式) を利用した。取得したデータは CAN データと GPS データの 2 種類に分かれる。これらのデータを利用したデータ解析例を後の節で示す。以下の項で詳細を説明する。

4.3.2 CAN データ

CAN データの取得には Android アプリ Leaf Spy Pro と OBDII(On Board Diagnosis Second Generation) 接続用の Bluetooth 通信端末として PLX Devices Kiwi Bluetooth Wireless Trip Computer and OBDII Scanner を利用した。Leaf Spy Pro を利用することで、バッテリー残量 (GIDs²)、バッテリー健全度 (SOH)、累計回生エネルギー量 (REGENWh)、エアコン、ヒーター、電装品それぞれの消費電力などのデータを最短 2 秒おきに取得することが可能である。

4.3.3 GPS データ

GPS データは、Android 上で動くロギングアプリを実装し、Android 端末を EV に搭載することでデータの取得を行った。また、サンプリングレートは 1Hz で取得した。GPS では、(時間、位置、対地速度) が取得できる。

また、GPS データから、OD(Origin-Destination) トリップ (今後、単にトリップと呼ぶ) の算出を行った。トリップは、トリップの ID、ドライバーの ID、出発地座標、目的地座標、出発時刻、到着時刻、向き (往路 or 復路) の組として定義した。

²GIDs は Leaf Spy の独自単位であり、バッテリー残量を示す値である。Leaf Spy の仕様によれば、1GIDs=0.0775kWh とされる。

4.3.4 気象データ

気象データは、気象庁から10分ごとの過去の気象データ³を取得した。このデータでは、観測地点ごとの気温、湿度、風向き、風速などを利用することができる。

4.4 データ解析例: EVのエネルギー消費要因の特定と可視化

本節では、EVの走行ログを用いたデータ解析の事例を提示する。

4.4.1 EVの走行ログデータ解析で立証する仮説

被験者であるエキスパートドライバーは、「冬のEVは電費が悪い。その原因として、エアコンや回生ブレーキなどの複合した原因が考えられる」という意見を持っていた。実験車両である日産LEAFの情報表示パネルでは、「平均電費 [km/kWh]」、「エアコンON時の航続可能距離 [km]」、「エアコンOFF時の航続可能距離 [km]」、「モーターの瞬間出力 [kW]」、「エアコン・電装品の瞬間出力 [kW]」などを見ることができる。エキスパートドライバーは長期間に及ぶEVの運転経験とこれらの情報フィードバックを通じて、以上のような意見を持つようになったと考えられる。しかし、一般のドライバーにとっては、このような知見を正確なデータに基づいて定量的に提示されなければ、納得を持ってEVのメリット・デメリットを把握することは難しいと考えられる。すなわち、本解析例では、エキスパートドライバーの知見を定量化する目的で実際のEVの走行ログを使用し、「冬のEVの消費電力量は悪化する。また、その要因として、冬のエアコンの消費電力量の増加と回生エネルギーの減少が存在する」という仮説をデータで説明可能とすることを目指す。

4.4.2 使用するリレーション

解析例で使用するリレーションを、表4.3~4.6に示す。リレーションLEAFSPY(表4.3)は、4.3.2項で示したCANデータのトリップ毎の集約値を属性として持つ。今回扱うデータは通勤時のデータであるため、トリップの出発地および目的地は、被験者宅と勤務先の2つに限定される。リレーションAVG_TEMP(表4.4)は、4.3.4項で示した気象データの中でも、走行地点から最も近い観測地点の気温をトリップ毎に集約した値を属性として持つ。リレーションSUMMARY_MONTH(表4.5,表4.6)は、4.3.3項で示したGPSデータのトリップ毎の集約値を属性として持つ。

4.4.3 解析プロセス例

本項では、解析プロセス例を以下で順を追って説明する。データ解析の流れを図4.4に示す。図4.4には解析STEPに対応した、解析システム上に表示されたPCPと任意のグラフを示している。また、各STEPを保存した(PC)²Lを付録Aに示す。

³”過去の気象データ検索”, 気象庁, <https://www.data.jma.go.jp/obd/stats/etrn/index.php>, 参照 Jan 11, 2021.

表 4.2: 解析例で使用するデータセット

属性	値
取得期間	2016-07-22 ~ 2020-01-28
トリップ数	1,379
GPS データレコード数	5,850,794
CAN データレコード数	755,806

表 4.3: リレーション LEAFSPY の属性

属性名	説明
TRIP_ID	トリップの ID
START_GIDS	トリップ開始時 のバッテリー残量 [GIDs]
END_GIDS	トリップ終了時 のバッテリー残量 [GIDs]
GIDS_DIFFERENCE	トリップ開始時と終了時 のバッテリー残量の差 [GIDs]
GIDS_DIFFERENCE_BY_kWh	トリップ開始時と終了時 のバッテリー残量の差 [kWh]
START_REGENWh	トリップ開始時の累計回生エネルギー量 [Wh]
END_REGENWh	トリップ終了時の累計回生エネルギー量 [Wh]
REGENWh_DIFFERENCE_kWh	トリップ開始時と終了時の 回生エネルギー量の差 [kWh]
AC_ENERGY	トリップのエアコンによる 総消費電力量 [kWh]
EST_AC_ENERGY	トリップのヒーターを除いた エアコンによる 推定総消費電力量 [kWh]
EST_HTR_ENERGY	トリップのヒーターによる 推定総消費電力量 [kWh]
AUX_ENERGY	トリップの電装品による 総消費電力量 [kWh]

表 4.4: リレーション AVG_TEMP の属性

属性名	説明
TRIP_ID	トリップの ID
AVG_TEMP	トリップの走行時の平均気温

表 4.5: リレーション SUMMARY の属性

属性名	説明
TRIP_ID	トリップの ID
ENERGY_CONSUMPTION	トリップの走行による EV の総消費電力量 [kWh]
TRIP_TIME	トリップが開始してから 終了するまでの時間 [s]
COUNT_LOGS	トリップのデータ数
DISTANCE	トリップの走行距離 [m]

表 4.6: リレーション MONTH の属性

属性名	説明
TRIP_ID	トリップの ID
MONTH	トリップの走行開始時の月

最初に、気温とEVの総消費電力量間、気温と回生エネルギー量間、気温とエアコンの消費電力量間、気温と電装品の消費電力量間の相関を散布図によって可視化する。そのために、最初の解析ブランチAとしてSTEP 0から解析をスタートし、STEP A-1からSTEP A-4の順でデータ解析を進める。

次に試行錯誤の一つとして、STEP A-4よりも仮説検証に適した可視化があるかを確認するため、散布図とは異なる可視化を行う。具体的には、月別に、平均総消費電力量、平均回生エネルギー量、エアコンの平均消費電力量、電装品の平均消費電力量を棒グラフで可視化する。特にエアコンは、ヒーターの消費電力量とヒーターを除くエアコンの消費電力量を棒グラフに積み上げることで、冷房、暖房それぞれの使用割合も可視化する。そのために、STEP A-1から派生した新しい解析ブランチBとしてSTEP B-1を示す。

STEP 0: 初期表示

解析システムのPCP Viewを図4.5に示す。STEP 0では、最初に表示するリレーションとしてリレーションLEAFSPYの全レコードをそのままPCPに表示した。

STEP A-1: 軸の削除と色分け

STEP 0でそのまま表示されたPCPでは属性が多く、分析が難しい。そこで、STEP A-1では、今回の仮説に必要なと考えられる属性のみを残してProjectionを行った。STEP A-1の結果を示す解析システムのPCP Viewを図4.6に示す。Projectionの結果として、トリップの総消費エネルギー量に相当するGIDS_DIFFERENCE_BY_kWh、トリップの回生されたエネルギー量に相当するREGENWh_DIFFERENCE_kWh、エアコンの消費電力量を示すAC_ENERGY、EST_AC_ENERGY、EST_HTR_ENERGY、電装品の消費電力量を示すAUX_ENERGYのみが表示された。また、PCPのインスタンスを示す線の色は、GIDS_DIFFERENCE_BY_kWhの値を基準にして色分け(Coloring⁴)した。

STEP A-2: 気温軸の追加と散布図の表示

STEP A-2の結果を示す解析システムのPCP ViewとGraph Viewを図4.7⁵に示す。STEP A-2では、STEP A-1に対して、PCPにトリップの平均気温を示す軸を追加し、気温と消費電力量間の相関を見たい。そこで、リレーションLEAFSPYとリレーションAVG_TEMPを内部結合し、リレーションAVG_TEMPからは属性AVG_TEMPのみを残してProjectionした。また、PCPで相関を見やすくするために、属性AVG_TEMPの値を基準にColoringを行った。これにより、各軸に表示される線の配色の順番を見ることで、平均気温に対する相関が把握できる。その結果として、図4.7上部のPCPが表示された。左から二、三番目の軸AC_ENERGY、AVG_TEMP(図4.8)に着目すると、軸間の線同士の交差が多くみられ、平均気温AVG_TEMPに対して、エアコンの消費電力量AC_ENERGYが逆相関を示していることが推察できる。しかし、PCPは相関を推察することは可能であるものの、データ全件を正確に視認することが難しい欠点

⁴PCPの線の色が、基準とした値が大きいほど赤く、小さいほど青くなる。

⁵図中の黒枠、青枠は説明の便宜上、書き入れたものである。実装システムの画面では表示されない。

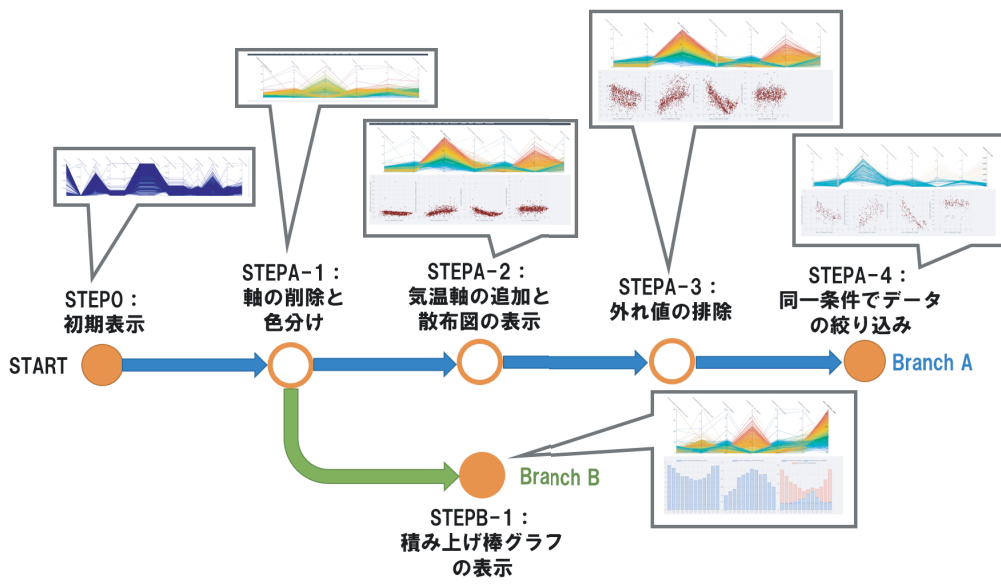


図 4.4: データ解析の流れ

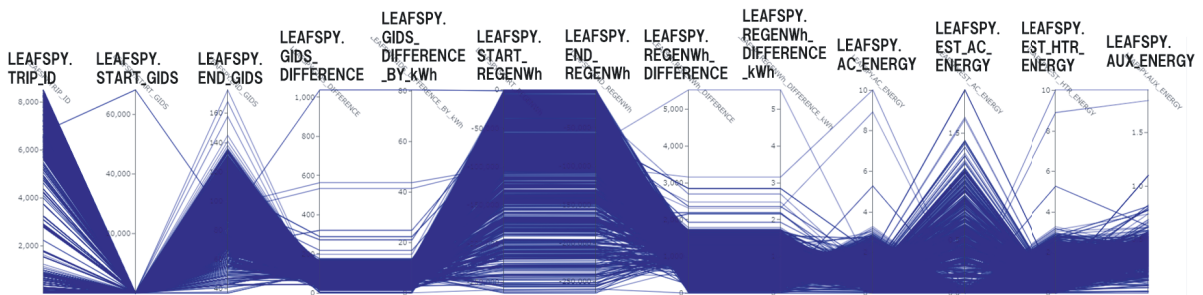


図 4.5: データ解析例 (STEP 0:初期表示)




図 4.6: データ解析例 (STEP A-1:軸の削除と色分け)

を持つ。そこで、平均気温と消費電力量との相関を把握しやすくするために、4つの散布図（Y軸はそれぞれ GIDS_DIFFERENCE_BY_kWh, REGENWh_DIFFERENCE_kWh, AC_ENERGY, AUX_ENERGY）を表示することとした。ここで、図 4.7 の青枠内の点群に注目する。電力量が主なデータクラスから大きく外れた値が存在し、有効な可視化ができていないことがわかる。

STEP A-3: 外れ値の排除

STEP A-3 の結果を示す解析システムの PCP View と Graph View を図 4.9 に示す。STEP A-3 では、有効な散布図を作成するために、消費電力量が非常に大きい値を外れ値として、外れ値を排除するようにデータを Selection した。属性 GIDS_DIFFERENCE_BY_kWh および属性 REGENWh_DIFFERENCE_kWh の軸を PCP View 上で範囲選択することで、外れ値排除を行った。この PCP での Selection 操作中、Graph View もリアルタイムに同期し、Selection されたデータのみが表示される。そのため、データ解析者がインタラクションを行いながら、適切にデータ選択されているかを確認することは容易である⁶。

図 4.9 下部の Selection 後の散布図を見ると、データのばらつきが大きく、相関があると十分に言い難い。データのばらつきの要因として、収集した EV の走行ログの走行条件が均一でないことが挙げられる。実際、通勤に使用した走行ルートは同一であるものの、交通や天気などのその日の状況によって、消費エネルギーが大きく変化していることが考えられる。特に、エアコンは車内温度をキープするために、定常的に電力を使用し続けることから、トリップに要した時間に比例してトリップの消費電力量が増加していくことが予想される。

STEP A-4: 同様な条件でデータの絞り込み

STEP A-4 の結果を示す解析システムの PCP View と Graph View を図 4.10 に示す。STEP A-4 では、リレーション SUMMARY を利用して、同一条件のデータを絞り込むことで、より正確に温度と消費電力量との相関を把握することをねらう。そのために、リレーション LEAFSPY に対し、リレーション SUMMARY を内部結合を行い、リレーション SUMMARY の属性の中でも、TRIP_TIME のみを残して Projection を行った。STEP A-4 では、エアコンへの影響が大きいと考えられるトリップに要した時間 TRIP_TIME が近いデータのみを選択し、同一条件のデータを絞り込むこととした。

その結果として、図 4.10 下部の Graph View を見ることで、以下のことがわかる。

- 平均気温 AVG_TEMP に対して、総消費エネルギー量 GIDS_DIFFERENCE_BY_kWh は逆相関の傾向がある。すなわち、低温であればあるほど、EV の消費電力量は増大し、電費が悪化する。(図 4.10 下部左から 1 番目)
- 平均気温 AVG_TEMP に対して、回生エネルギー量 REGENWh_DIFFERENCE_kWh は正相関の傾向がある。すなわち、低温であればあるほど、EV の回生されるエネルギーが減少し、結果として総消費電力量が増加する。(図 4.10 下部左から 2 番目)

⁶視認性を重視するために、Graph View 内の各グラフの軸範囲が自動設定されるように実装した。一方で、PCP の軸範囲は固定である。このような仕様にしたのは、PCP を操作入力インターフェース、グラフ表示を出力インターフェースと位置づけたためである。データ可視化の自由度を上げるために、PCP の軸範囲を修正する機能や、グラフ表示の軸範囲を固定する機能の追加も考えられる。このような操作支援に関する仕様拡張は今後の課題とする。

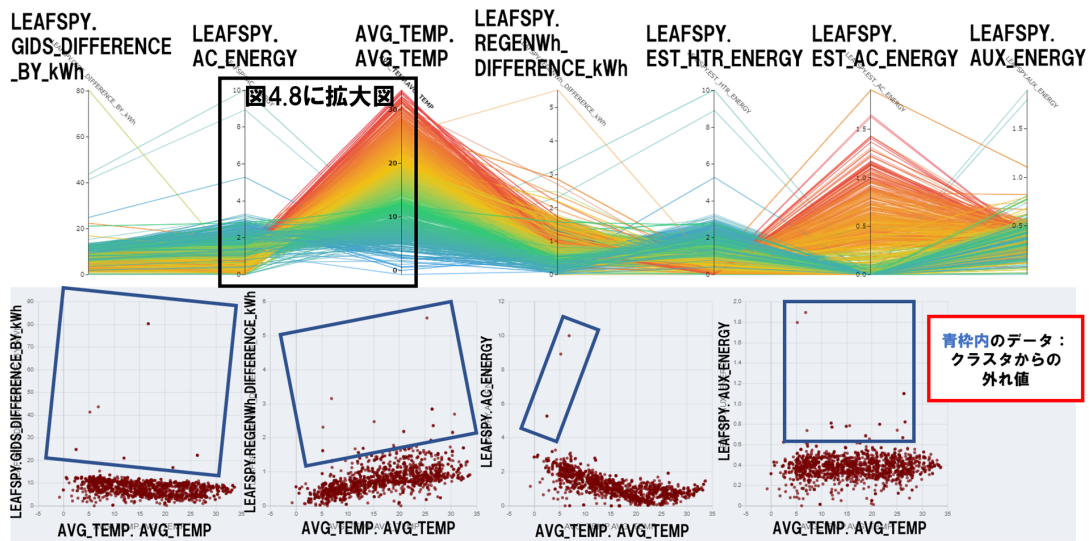


図 4.7: データ解析例 (STEP A-2: 気温軸の追加と散布図の表示)

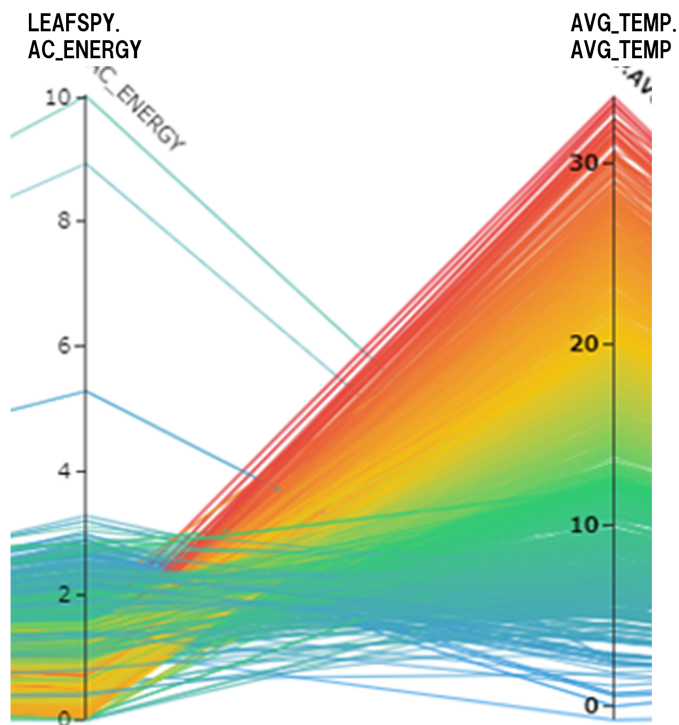


図 4.8: 図 4.7 の拡大図

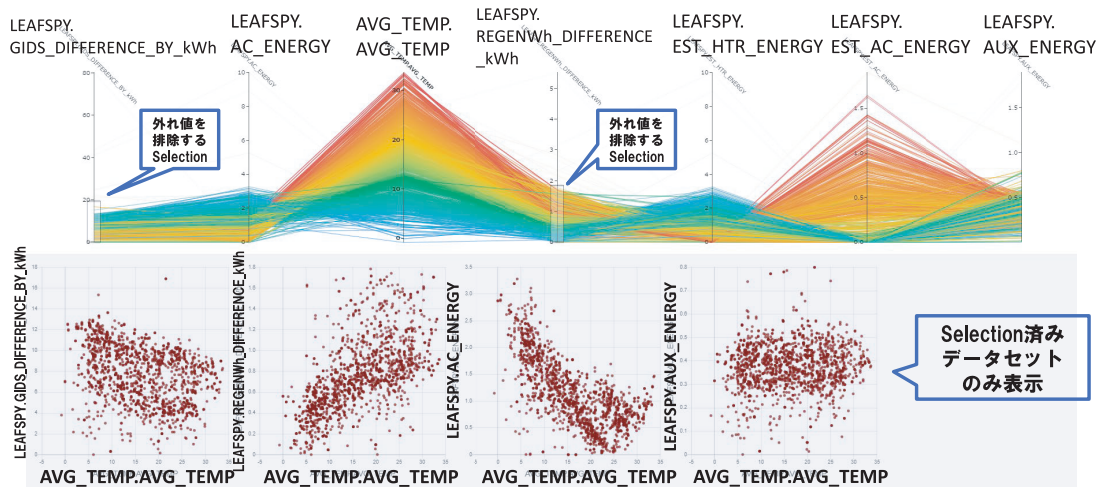


図 4.9: データ解析例 (STEP A-3: 外れ値の排除)

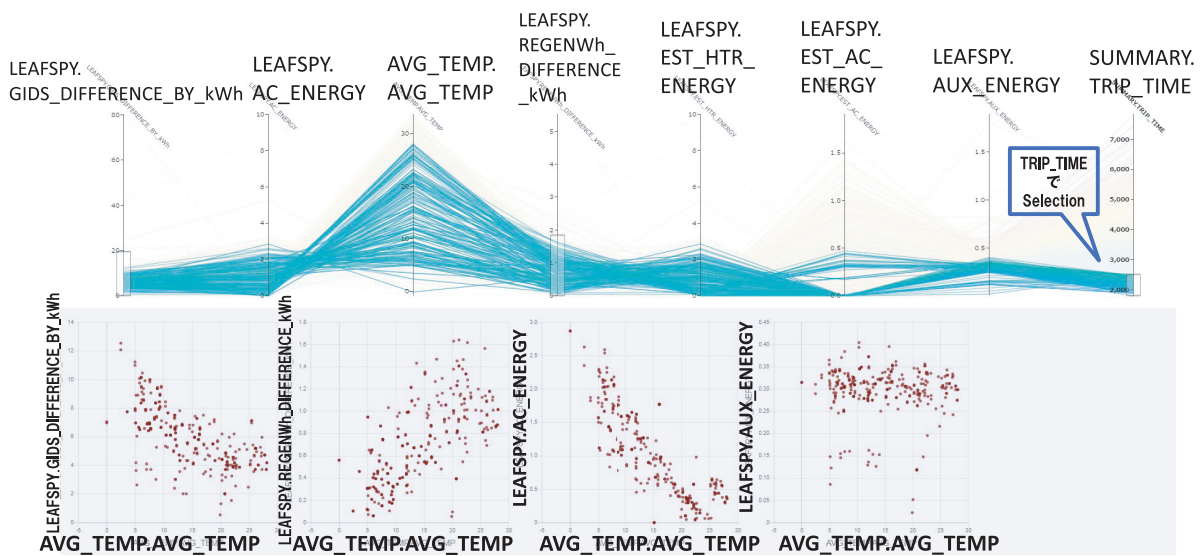


図 4.10: データ解析例 (STEP A-4: 同様な条件でデータの絞り込み)

- 平均気温 AVG_TEMP に対して、エアコンの消費エネルギー量 AC_ENERGY は逆相関の傾向がある。すなわち、低温であればあるほど、エアコンによる消費エネルギー量が増加している。(図 4.10 下部左から 3 番目)
- 平均気温 AVG_TEMP に対して、電装品の消費エネルギー量 AUX_ENERGY は無相関の傾向がある。すなわち、電装品の消費エネルギー量は、気温によって変化しない。(図 4.10 下部左から 4 番目)

STEP A-4 における同一条件の絞り込み方として、例えば平均加速度などの他の条件にして絞り込むことも考えられる。実装した解析システム上では、複数の条件を試して比較するような試行錯誤も (PC)²L の保存により支援することが可能である。

以上の STEP 0–STEP A-4 のプロセスにより、「気温が低い冬の EV の消費電力量は悪化する。また、低温時は冬のエアコンの消費電力量の増加と回生エネルギーの減少が存在し、これらが総消費電力量の悪化に影響を及ぼしている」ことが示唆される。

STEP B-1: 積み上げ棒グラフの表示

保存した (PC)²L を利用して過去の STEP (STEP A-1) に遡り、その STEP から新しく分岐して分析を進める STEP B-1 を示す。

STEP B-1 では、STEP A-4 の結果によって示された EV の消費エネルギー量の気温に対する特性を、別の方法を用いて可視化する。具体的には、季節と EV の消費エネルギー量間の相関を可視化する。そのために、Projection 済みのリレーション LEAFSPY のみが表示されている STEP A-1 に一度遡った。そして、リレーション LEAFSPY に対し、リレーション MONTH を内部結合を行い、リレーション MONTH の MONTH 軸を追加した。加えて、X 軸に MONTH、Y 軸には MONTH を単位として集計したエネルギー量の平均値を表示する棒グラフを追加した。STEP B-1 の結果を示す解析システムの PCP View と Graph View を図 4.11 に示す。追加した棒グラフの拡大図を、図 4.12、図 4.13、図 4.14 に示す。また、付録 A のリスト A.1 に、STEP A-1 を保存した (PC)²L と、また、リスト A.5 に STEP B-1 における (PC)²L を示す。リスト A.5 における 8 行目以降が、STEP A-1 の (PC)²L における 8 行目以降を加筆・修正した部分に該当する。

図 4.12 は、図 4.11 の下の Graph View 左にある、月別の総消費電力量 GIDS_DIFFERENCE_BY kWh の平均値の棒グラフを示す。図 4.12 より、取得期間全体の消費電力量の傾向として、1 月から 7 月まで平均総消費電力量は減少し続け、8 月以降は 12 月まで増加し続けることが読み取れる。

図 4.13 は、図 4.11 の下の Graph View 中央にある、月別の回生エネルギー量 REGENWh DIFFERENCE.kWh の平均値の棒グラフを示す。図 4.13 より、1 月から 7 月まで平均回生エネルギーは増加し続け、8 月以降は 12 月まで減少し続けることがわかる。回生エネルギーの増加は、ブレーキによって回収されるエネルギーが増加することから、EV の総消費電力量が減少することを意味する。すなわち、回生エネルギーの季節による変化は、総消費電力量に影響を及ぼしている可能性が示唆される。

図 4.14 は、図 4.11 の下の Graph View 右にある、月別の電装品 AUX_ENERGY、エアコン (ヒーターを除く) EST_AC_ENERGY、ヒーター EST_HTR_ENERGY の消費電力量の平均値を下から順に積み上げた棒グラフを示す。図 4.14 より、エアコン全体と電装品を合わせた (EST_AC_ENERGY + EST_HTR_ENERGY + AUX_ENERGY) の消費電力量は、1 月から 6 月にかけて減少し、6 月




図 4.11: データ解析例 (STEP B-1: 積み上げ棒グラフの表示)

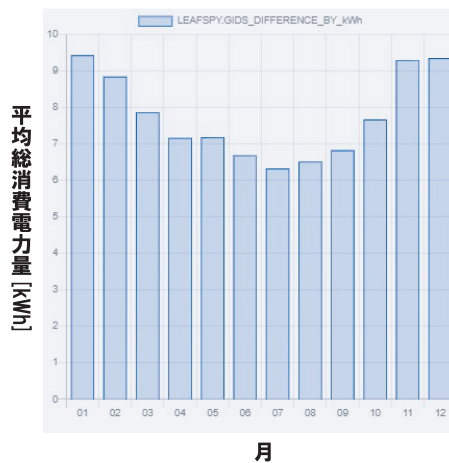


図 4.12: 月別平均総消費電力量 (STEP B-1)




図 4.13: 月別平均回生エネルギー (STEP B-1)




図 4.14: 月別平均電装品・エアコン (ヒーターを除く)・ヒーター消費電力量 (STEP B-1)

から8月まで増加，その後，再度9月に減少してから，12月まで増加し続けるという傾向があることがわかる．この要因として，冬には暖房による消費電力量が増大し，夏には冷房による消費電力量が増大することが考えられる．これは，エアコン（ヒーターを除く）とヒーターの消費電力量の月別の割合の変化によって読み取ることができる．

これらのSTEP B-1の結果から，「冬のEVの総消費電力量は大きい．また，冬のエアコンのヒーターの消費電力量の増大および冬の回生エネルギーの減少が存在し，総消費電力量に影響を及ぼしている」ことが示唆される．

解析例まとめ

STEP A-4とSTEP B-1の結果は，両者ともに仮説「冬のEVの消費電力量は悪化する．また，その要因として，冬のエアコンの消費電力量の増加と回生エネルギーの減少が存在する」という仮説をグラフ形式で定量的に示唆できる結果となった．さらには，散布図を示したSTEP A-4は，気温に対する消費電力量の相関を可視化できる一方，棒グラフを示したSTEP B-1は，エアコンのヒーターとそれ以外が占める割合を可視化できるというそれぞれの可視化ごとの長所がある．そのため，データ解析者が示したい仮説に適した結果を選択することが重要である．

このように，我々の解析システム上で，データ解析者が，(PC)²Lによって途中の解析過程を復元し，それぞれの結果を長所を検討しながら試行錯誤する例を示すことができた．

これらは，実装した解析システムのインタラクションと可視化機能，(PC)²Lによる保存・復元機能により実現した．

4.5 まとめと今後の課題

4.5.1 まとめ

PCP上のインタラクションとその結果をリアルタイムに反映する可視化機能，インタラクションと可視化の状態を保存・復元する(PC)²Lが利用可能なデータ解析支援システムの実装を行った．また，EV特有の問題に対し，実装システムを利用した走行ログ解析例を示した．解析例では，長期間収集した実際の走行ログに対し，アドホックなクエリを試行錯誤しながら適用する例として，EVのエネルギー消費要因の特定を行うデータ解析例を示した．これにより，実装システムによりデータ解析者を支援しながら，EVの走行ログの有用なデータ解析例を示すことができた．

4.5.2 今後の課題

今後の課題として，解析システム上で実行可能なデータ操作として，集計クエリやサブクエリなどの実行可能なアドホックなクエリの機能を増やしていくことが挙げられる．ほかにも，更新や挿入機能により，データ操作後のデータをデータベースに反映し，その後のデータ解析作業の簡略化なども考えられる．

また，複数のデータ群の比較や，SelectionされたデータとSelection外のデータ間の比較が可能なインターフェースの拡張なども今後の課題として挙げられる．

さらには、位置情報を含む時空間データを可視化可能な地図による可視化により、EV消費エネルギーデータ特有のデータ解析を可能にすることなども今後の課題として考えられる。

第5章 電気自動車消費エネルギーデータベースの構築と応用

5.1 はじめに

大量に収集したライフログを利用する際には、そのデータの特性や利用目的などに適したクエリを実行する必要がある。それに対し、データに適したクエリの実行を想定した関係データベースを構築することで、ライフログの有用なクエリを実行可能にすることが一つの解決法として考えられる。本章の目的は、3章で確立した自動車走行ログから推定したEVの消費エネルギー量データの有用なクエリが実行可能なデータベースを構築することにある。また、データ解析者がデータから有用な情報を発見するには、多数のクエリの実行結果をグラフなどによって可視化しながら、試行錯誤を繰り返すことが必要となると考えられる。

それに対し、有意な道路区間で集計可能なEVの推定消費エネルギーデータベースとそれを利用するためのECOLOGデータ解析フレームワークを構築する。本フレームワークは、(1)「推定消費エネルギーデータを蓄積するデータベース (ECOLOG)」と(2)試行錯誤の過程をSQLに類似した言語形式で保存可能な「多変量データ解析支援システム (4章)」から構成される。

(1)については、3章で「EVに乗り換えた場合の推定消費エネルギー」の推定方法を確立した。それにより推定したEVの消費エネルギーデータを蓄積、有用な検索が可能なECOLOG(Energy Consumption LOG)データベースを構築した。ECOLOGシステムにおいて、我々は、有意な道路区間で消費エネルギーデータを集計することで、道路ごとに異なるEVの消費エネルギーの特性[9]の把握が出来ることに着目した。有意な道路区間とは、データ分析者やそのデータを深く知る熟練者などが持つ仮説に基づいた意味が有ると考える道路区間のことである。しかしながら、実際のデータ解析においては、設定した道路区間で集計した結果の可視化を行い、データ解析者が求める適切かつ有意な道路区間が設定できたかを確認する必要がある。

そこで可視化の支援のため、4章に記述した多変量解析支援システムを利用する。本章では、この解析支援システムの機能を利用し、EVの推定エネルギーの有用なデータ解析を支援する。

本章の最後では、実際に収集した自動車走行ログをデータベースに格納し、ECOLOGデータ解析フレームワークを利用したデータ解析例を示す。データ解析例では、実際に蓄積した自動車走行ログと本システムを用い、EVとガソリン車の消費エネルギー比較によるそれぞれの特性の比較や、EVのエネルギー消費要因を特定する例を示す。それにより、自動車に関するライフログの有用性を示すことを目指す。

5.2 EV 推定消費エネルギーデータ解析

本節では、ECOLOG データ解析フレームワーク (図 5.1) について説明する。本フレームワークは、EV の推定エネルギーデータを格納するデータベースである ECOLOG システムと ECOLOG システムにより集計したデータを解析するための多変量データ解析支援システムで構成される。本フレームワークの想定される利用の流れを以下に説明する。

- (1) 既存の自動車にスマートフォンを搭載し、自動車の走行ログを収集する。
- (2) 収集した走行ログから EV の消費エネルギーデータの推定を行い、ECOLOG データベースに蓄積する。
- (3) データ解析の目的やデータ解析者の仮説に基づき、専用の UI (Semantic Editor) を用いて有意な道路区間 (Semantic Link) をデータベース内に作成する。
- (4) ECOLOG データベースを利用して、Semantic Link (以後、SL) による EV の推定消費エネルギーデータの集計を行う。
- (5) SL による集計結果を多変量データ解析支援システムで表示する。
- (6) 多変量データ解析支援システム上で、可視化、データ操作をインタラクティブに行いながらデータ解析を進める。
- (7) 作成した SL による集計結果で所望の結果が得られなければ、再度 Semantic Editor を利用し、SL を新たに作成、もしくは、既存の SL の編集を行う。
- (8) データ解析者が満足する結果が得られるまで、(4) から (7) を繰り返す。

なお、ECOLOG システムの詳細については、5.3 節に後述する。多変量データ解析支援システムについては、4 章に記述したものを利用する。

5.3 ECOLOG システム

本節では、ECOLOG システムについての説明を記述する。ECOLOG システムは、スマートフォンを用いて収集した走行ログより推定した EV の消費エネルギーデータを蓄積し、EV の消費エネルギーに関する有用な検索が可能なデータベースである。走行ログから消費エネルギーデータを推定する方法については、3 章に記述した。以下には、ECOLOG データベースのスキーマ設計や、SL を作成・編集するための UI、Semantic Editor についても説明する。

5.3.1 ECOLOG テーブル

EV モデルによって推定されたエネルギー消費量はセンサデータとともにデータベース内に蓄積される。このテーブルを ECOLOG テーブルと名付けた。ECOLOG テーブルでは 1 秒ごとに時間正規化したデータを蓄積する。これにより EV エネルギー消費量 (積算値) を求める時間積分 (式 (3.3)) を、式 (5.1) に示す単純な加算集約により計算できるようになる。

$$E_e = c \sum_{t=t_{start}}^{t_{end}} P_e(t) \Delta t \quad (\text{ただし, } \Delta t = 1 \text{ sec.}) \quad (5.1)$$

ECOLOG テーブルに蓄積される主なデータ要素としてはセンサから取得した時刻，緯度，経度，車速，地図データから取得される標高，EV モデルにより計算される P_{AIR} , P_{ROLL} , P_{SLOPE} , P_{ACC} , μ , $P_e(t)$ などが含まれる。

5.3.2 ECOLOG データベース

図 5.2, 図 5.3 に ECOLOG システムにおけるインスタンス図, スキーマ図をそれぞれ示す。

ECOLOG データベースにおいて, ある時刻に運転者が車を運転して, ある場所から別の場所へと移動することを 1 回のトリップと定義する。例えば, 「運転者 A」が「車 1」を運転して時刻「2018/12/18 08:34:48」に「運転者 A 自宅」を出発し, 時刻「2018/12/18 09:44:49」に「運転者 A オフィス」に到着したという移動は, 「往路」のトリップであるといえる。ECOLOG テーブルに対する検索では, キーとしてトリップやセンサはもちろん, トリップテーブルを介して運転者や車, 時間, 場所が利用可能である。

また, 検索や集約の単位として利用できる地図情報として道路リンクや有意な道路区間 SL, 道路セグメントがある。このうち, 道路リンクは国土交通省が公開している数値地図 2500 (空間データ基盤) [53] であるが, SL と道路セグメントは我々が定義したものである。SL は, 「任意の道路リンクの集合」としてデータベース内に定義される [9]。SL により, 高速道路や渋滞が起こりやすい区間といった「運転者やデータ解析者にとって有意な道路区間」という単位での集計を高速に行うことができる。さらに, 道路セグメントを「SL を等間隔に分割した道路データ」と定義する。本論文では, SL を用いた有用な EV の推定消費エネルギーデータの活用事例を示すことが主な目的であるため, 本論文の範疇外の道路セグメントに関する説明は省略する。

なお, 本研究の実験環境として, Microsoft SQL Server 2019 を利用し, このデータベーススキーマを反映したデータベースを構築, 運用を行っている。

5.3.3 Semantic Editor

本項では, ECOLOG データベース内に SL を作成・編集するための UI である, Semantic Editor (図 5.4) について説明する。

図 5.4 で示すように, Semantic Editor には地図上に道路リンクデータが表示される。SL を作成する時点では, 全ての道路が未登録道路となっている。表示された地図上の道路をクリックすることで, 編集中の SL にその道路リンクを登録するか否かを選択することが出来る。地図上の道路が赤色であれば編集中の SL にその道路が登録されている, 青色であれば編集中の SL にその道路が登録されていないことを示す。

この Semantic Editor は, 環境を問わず気軽に利用できるようにするため, Web アプリケーションとして実装を行った。この UI により, データ解析者が求める SL を自由に作成・編集が可能になる。

5.4 データ解析例

本節では, 構築した ECOLOG データ解析フレームワークを用いたデータ解析例を示す。解析例に使用するデータセットは, ある被験者の通勤時に収集したものを利用する。以下の項で示す 2

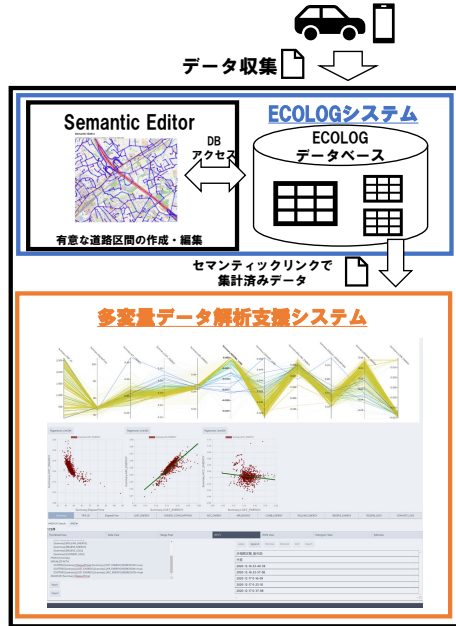


図 5.1: ECOLOG データ解析フレームワーク

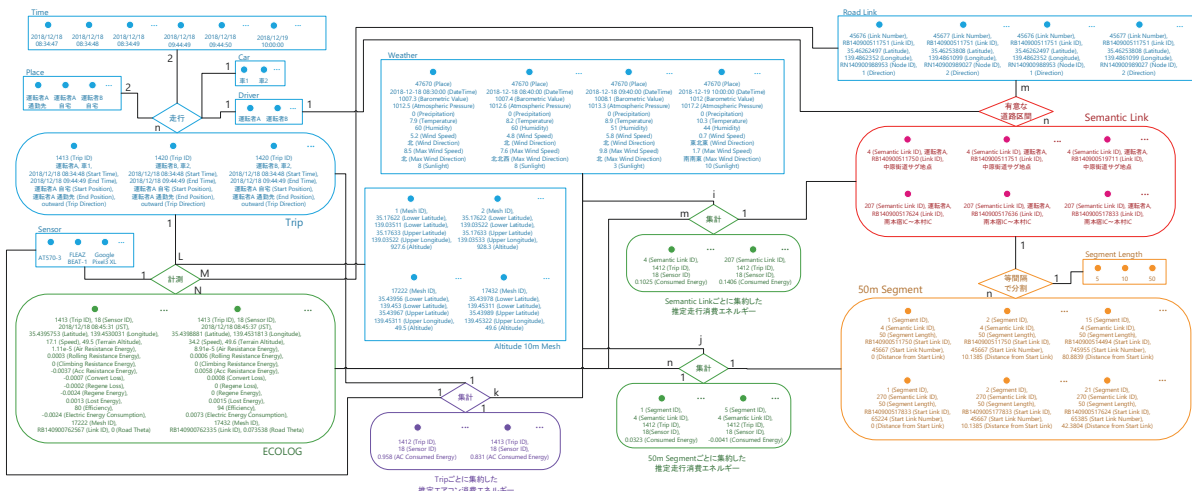


図 5.2: ECOLOG システムのインスタンス図

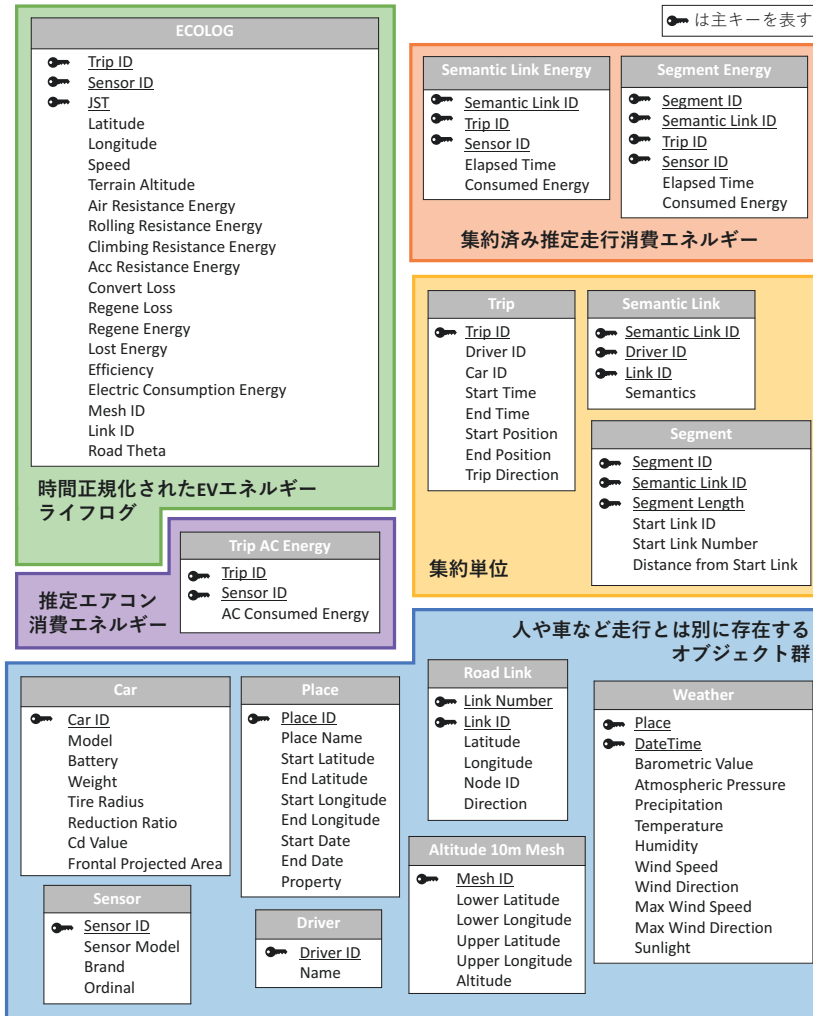


図 5.3: ECOLOG システムのスキーマ図

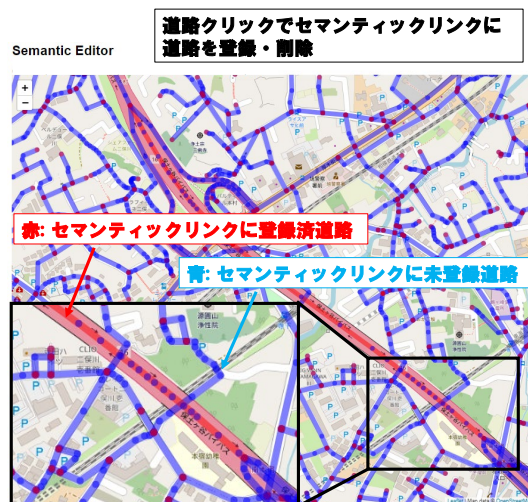


図 5.4: Semantic Editor の表示例

つの解析例により、本フレームワークを利用した、SLによる集計を行ったEVの推定エネルギーデータ解析が有用であることを示す。

5.4.1 データ解析例 1:EV とガソリン車の特性の比較

解析例1では、ECOLOGデータをSLで集計したデータを解析し、EVとガソリン車の消費エネルギーに関する特性を明らかにする。利用したデータセットは、表5.1に示す。また、ECOLOGでは取得できないガソリン車の燃料消費量(L)を取得するため、AndroidアプリTORQUE PRO[47]を用いてCANデータを取得した。データの集計に利用したSLについては、表5.2、表5.3に示した。被験者復路が一般道路、高速道路区間という意味を理解しやすい形での分割が容易だったため、以上のような形で2つのSLをSemantic Editorを用いて作成した。使用したリレーシオンを表5.4に示した。EVとガソリン車の消費エネルギーを公平に比較するために、ECOLOGデータベースによるデータ集計時に、WtW換算¹を行った。すなわち、推定エネルギー損失にはEVのWtW換算係数、CANデータから取得したガソリン車の燃料消費量にはICVのWtW換算係数を乗算し、リレーシオン”EVvsICV”として多変量データ解析支援システムで表示した。

まずは、時間とエネルギーの散布図により、ガソリン車とEVの消費エネルギーの違いを可視化した。その結果を図5.5に示す。図5.5では、VISUALIZE WITH句に2つの散布図を指定した(PC)²Lを入力して散布図を表示した。表示した散布図は、今回作成した高速道路区間Highwayのデータを表示する散布図と一般道区間Generalのデータを表示する散布図の二つである。また、PCPを用いて、散布図で表示するデータから今回の対象外データを除外する(TRIP_DIRECTIONが復路以外のデータを除外する)処理を行った。図5.5で表示した2つの散布図の拡大図をそれぞれ図5.6、図5.7に示す。図5.6には、X軸がTRIP_TIME_Highway、Y軸にCONSUMED_FUEL_W2W_BY_L_Highway、LOST_ENERGY_W2W_BY_L_Highwayを指定した散布図、すなわち、高速道路区間のICVとEVの消費エネルギーデータを可視化した散布図を示す。「もしガソリン車(ICV)と同じ運転のままEVに乗り換えた場合」の消費エネルギーデータが図5.6中の青点、ICVの消費エネルギーデータが図5.6中の緑点として表示されている。この散布図を見ると、EVは0.2から0.4L付近、ICVは1.4から1.6L付近に主に分布していることがわかる。そのため、この被験者の高速道路区間における消費エネルギーは、ICVのほうがEVと比較して約4倍から7倍の違いがあることが図5.6から読み取れる。図5.7には、X軸がTRIP_TIME_General、Y軸にCONSUMED_FUEL_W2W_BY_L_General、LOST_ENERGY_W2W_BY_L_Generalを指定した散布図、すなわち、一般道路区間のICVとEVの消費エネルギーデータを可視化した散布図を示す。図5.7の消費エネルギー量を見てみると、ICV、EVともに図5.6で示す値と大きく変わらないことが視認できる。以上のことから、WtW換算を行ったエネルギー消費量では、被験者のICVはEVに乗り換えることで、最小7分の1に消費エネルギーが小さくなるという知見が示された。これは、車両走行ログを実際に収集し、個人のデータに合わせた有用な結果が得られたといえる。

また、図5.6、図5.7から、ICVは時間に対して消費エネルギーが正相関を持つこと、EVは時間に対して消費エネルギーの相関が少ないことが推察される。そこで、図5.6、図5.7のICVのデー

¹Well-to-Wheel換算。原油の採掘から走行までに利用したすべてのエネルギー量をガソリンの熱量に換算したもの。単位は、ガソリンの量に換算したため、L。「平成30年度省エネルギー政策立案のための調査事業(自動車におけるエネルギー性能の評価方法に関する調査検討事業) https://www.meti.go.jp/medi_lib/report/H30FY/000787.pdf」の値を利用。換算係数として、EVは0.875/8700*1000/0.653 L/kWh、ガソリン車は、1/0.875 L/Lをそれぞれ利用。

表 5.1: 解析例 1 で使用するデータセット

属性	値
取得期間	2013-01-07 ~ 2013-07-25
トリップ数	174
取得データ	GPS データ, CAN データ

表 5.2: 解析例 1 で使用する SL "General"

属性	値
走行距離	約 10km
説明	被験者復路の一般道区間

表 5.3: 解析例 1 で使用する SL "Highway"

属性	値
走行距離	約 13km
説明	被験者復路の高速道路区間

表 5.4: リレーション EVvsICV の属性

属性名	説明
LOST_ENERGY_W2W_BY_L.Highway	WtW 換算後の区間 Highway を走行したときの推定エネルギー損失 [L]
TRIP_TIME.Highway	区間 Highway を走行するのにかかった時間 [s]
CONSUMED_FUEL_W2W_BY_L.Highway	WtW 換算後の区間 Highway を走行したときのガソリン車の燃料消費量 [L]
TRIP_DIRECTION	TRIP の方向 (復路 or 往路 or その他)
CONVERT_LOSS.Highway	区間 General を走行したときの推定変換ロス [kWh]
TRIP_TIME.General	区間 General を走行するのにかかった時間 [s]
LOST_ENERGY_W2W_BY_L.General	WtW 換算後の区間 General を走行したときの推定エネルギー損失 [L]
CONVERT_LOSS.General	区間 General を走行したときの推定変換ロス [kWh]
CONSUMED_FUEL_W2W_BY_L.General	WtW 換算後の区間 General を走行したときのガソリン車の燃料消費量 [L]




図 5.5: 解析例 1:EV とガソリン車の消費エネルギー比較




図 5.6: 解析例 1:高速道路区間の EV とガソリン車の消費エネルギー比較



図 5.7: 解析例 1:一般道路区間の EV とガソリン車の消費エネルギー比較

た、EV のデータそれぞれを別々の散布図に分割して表示し、回帰直線と決定係数を描画する機能を使用して、相関を確認することとした。なお、多変量データ解析支援システムの状態は、随時(PC)²Lで保存することが出来る。そのため、PCPで行ったデータ選択をそのままに、VISUALIZE WITH 句だけを書き換えるだけで、この変更が可能である。

新たに描画した4つの散布図をそれぞれ図5.8、図5.9、図5.10、図5.11に示す。図5.8、図5.9の決定係数を見ると、それぞれ約0.02、約0.05である。すなわち、この2つのSL(Highway, General)においては、時間に対してEVの推定エネルギー損失は無相関であることが確認できた。一方、図5.10、図5.11の決定係数を見ると、それぞれ約0.52、約0.60である。すなわち、この2つのSL(Highway, General)においては、時間に対してのガソリン車の燃料消費量は一定の正相関を示していることが確認できた。以上のことから、ICVは道路が走行する時間が短くする(すなわち、高速に走る)ほど、消費エネルギーを少なく走行できることがわかる。その一方で、EVは走行時間とは違う要因で消費エネルギーが変化するということが推察される。このことから、ICVとEVでは、消費エネルギーを少なくする運転をする上で意識する点が異なるという知見を示すことができた。

5.4.2 データ解析例2:EVの消費エネルギーの要因解析

データ解析例2では、データ解析例1で明らかにすることが出来なかった、EVの消費エネルギーの変化する要因を明らかにするデータ解析を示す。利用するデータセットは、表5.5に示す。使用するSLは、表5.3で示した道路区間内にある、2つのあるインターチェンジ間の道路区間である(表5.6)。このデータ解析2の結果として、走行時間に対し推定エネルギー損失が逆相関という、解析例1で示したICVとは逆の相関を示したため、このSLを対象としたデータ解析例を示す。使用したリレーションを表5.7に示す。解析例1と同様にリレーション Summary を多変量データ解析支援システム上でデータ解析を行った。

図5.12に、表示したリレーション Summary を表示し、線の色を属性 ElapsedTime で色分け²したPCPを示した。ElapsedTime以外のPCPの各軸の色の順番を見ることにより、ElapsedTimeと各軸間の相関を何気なく把握することが出来る。図5.12中の左から3(ACC_ENERGY)、4(LOST_ENERGY)、6(AIR_ENERGY)番目の軸上の線が、おおむね上から(もしくは、下から)順番に赤→黄→緑と推移しており、ElapsedTimeと相関がある可能性が高いと見当をつけることが出来る。

その後、相関がある可能性が高い各軸とElapsedTimeの散布図を描画することで、より正確な相関を把握することが出来る³。属性間の相関を発見するその他の手法として、散布図行列が候補として挙げられる。散布図行列は属性数の2乗に比例して散布図を描画するため、属性数が多いリレーションでは、非常に大きい画面空間を使う必要がある。そのため、PCPによって相関の有無をある程度把握し、描画したい散布図の優先順位を決めることは、データ可視化を伴うデータ解析にとっては非常に有用である。

²赤に近いほど値が大きく、青に近いほど値が小さい

³PCPは、データ全体を把握することが難しいため、軸間の関係を正確に把握することが難しいと考えられる。そのため、「データ全体を視認することができる散布図で補完することで、より正確な軸間の関係を把握することが望ましいといえる。




図 5.8: 解析例 1: 高速道路における走行時間に対する EV の推定エネルギー損失の相関




図 5.9: 解析例 1: 一般道における走行時間に対する EV の推定エネルギー損失の相関

表 5.5: 解析例 2 で使用するデータセット

属性	値
取得期間	2016-05-16 ~ 2020-12-14
トリップ数	923
取得データ	GPS データ

表 5.6: 解析例 2 で使用する SL "ICs"

属性	値
走行距離	約 1km
説明	SL "Highway" の経路中から、ある二つのインターチェンジ間の経路を SL としたもの




図 5.10: 解析例 1:高速道路における走行時間に対するガソリン車の燃料消費量の相関




図 5.11: 解析例 1:一般道における走行時間に対するガソリン車の燃料消費量の相関

図 5.13, 図 5.14, 図 5.16 に, ElapsedTime を X 軸, PCP で ElapsedTime と相関がある可能性が高いと見当をつけた LOST_ENERGY, AIR_ENERGY, ACC_ENERGY をそれぞれ Y 軸とした 3 つの散布図を示した。図 5.13 によると, 時間と LOST_ENERGY 間の決定係数は約 0.51 である。そのため, この道路区間 ICs においては, 時間に対して EV のエネルギー損失は一定の逆相関を示すことがわかる。すなわち, EV は走行する道路次第で, 時間に対して ICV とは逆の特性, 逆相関を示すことがこの散布図から示唆される。また, 図 5.14 によると, 時間と AIR_ENERGY 間の決定係数は, 約 0.84 である。そのため, 道路区間 ICs においては, 時間に対して空気抵抗による消費エネルギーが強い逆相関を示す。この現象は, ElapsedTime が小さいほど, ICs を走行する際の平均速度が上がり, 空気抵抗が増えるためと説明ができる。さらに, X 軸に AIR_ENERGY, Y 軸に LOST_ENERGY の散布図(図 5.15)を作成した。図 5.15 によると, ほぼ $y=x$ の回帰直線かつ決定係数は 0.66 であるため, 道路区間 ICs においては, エネルギー損失のほとんどが空気抵抗成分であることが推察される。一方, 図 5.16 を見ると, 相関係数は約 0.09 と, ACC_ENERGY は時間に対して相関があまりないことが確認できる。

以上のことから, SL を適切に作成することにより, ガソリン車とは異なる, 時間に対する EV の消費エネルギーの相関を知ることができた。すなわち, 現在の ICV における消費エネルギーの通説「渋滞などにより走行時間がかかるほど, 燃費が悪化する」とは異なる特性を EV は持っているという知見を示すことができた。以上のように, 有用な結果を得るためには, 本システムを利用して, SL の編集やデータ操作, データ可視化を組み合わせた試行錯誤を行う必要がある。なお, エアコンモデルでは, SL ごとの細かい単位で, エアコンの消費エネルギー量を推定することが出来ないことから, エアコンによる消費電力の分析を省略した。実際の EV では, 温度と走行時間に依存するエアコンという消費要因が存在するため, ICV と比べて多くの要因によって消費エネルギーが変化する特性があると考えられる。エアコンを含めたデータ解析については, 今後の課題とする。

5.5 まとめと今後の課題

5.5.1 まとめ

本章では, EV の推定消費エネルギーデータを SL で集計可能な ECOLOG データベースと, それをデータ解析するための ECOLOG データ解析フレームワークを構築した。本フレームワークと実際に収集したログを用いた解析例により, ガソリン車や EV の消費エネルギーの差や時間に対する特性の違いや EV の消費要因など, 推定消費エネルギーデータを利用したからこそ得られた知見を示すことができた。これにより, 自動車走行ログから推定した EV の消費エネルギーの有用な応用が可能であることを示した

5.5.2 今後の課題

今後の課題として, 構築したデータベースの性能評価により, 収集したライフログが膨大となった場合でも高速にデータ集計が可能であることを示すことが挙げられる。

また, 今後の課題として, 複数ユーザー間のデータ比較や, 一定距離ごとの消費エネルギー集計, エアコンの消費電力も含めたデータ集計による, EV 消費エネルギーデータの有用な応用例の

提示などが挙げられる。他にも、ナビゲーションシステムなどのユーザーが利用する従来サービスに、EVの消費エネルギーという新たな評価軸を追加する ECOLOG の有用例の提示なども考えられる。さらに、データベースに蓄積したデータを機械学習や自動運転などに対して応用するなども考えられる。以上のような、多様で有用なデータ応用により、ECOLOG システムが有用であることを示すことが重要である。

表 5.7: リレーション Summary の属性

属性名	説明
TRIP_ID	走行トリップの ID
ElapsedTime	区間 ICs を走るために要した時間 [s]
ACC_ENERGY	区間 ICs を走るために要した加速抵抗による消費エネルギー [kWh]
LOST_ENERGY	区間 ICs を走るために要したエネルギー損失 [kWh]
ENERGY_CONSUMPTION	区間 ICs を走るために要した消費エネルギー [kWh]
AIR_ENERGY	区間 ICs を走るために要した空気抵抗による消費エネルギー [kWh]
CLIMB_ENERGY	区間 ICs を走るために要した登坂抵抗による消費エネルギー [kWh]
ROLLING_ENERGY	区間 ICs を走るために要した転がり抵抗による消費エネルギー [kWh]
REGENE_ENERGY	区間 ICs を走るために要した回生エネルギー [kWh]
REGENE_LOSS	区間 ICs を走るために要した摩擦ブレーキによるエネルギー損失 [kWh]
CONVERT_LOSS	区間 ICs を走るために要した変換ロス [kWh]




図 5.12: 解析例 2:属性 ElapsedTime で PCP を色分け

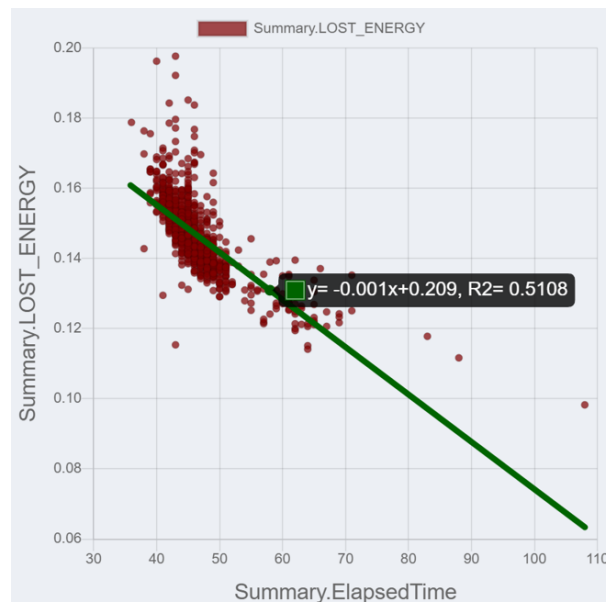


図 5.13: 解析例 2:ElapsedTime に対する推定エネルギー損失の散布図




図 5.14: 解析例 2:ElapsedTime に対する空気抵抗による推定消費エネルギーの散布図




図 5.15: 解析例 2:空気抵抗による推定消費エネルギーに対する推定エネルギー損失の散布図




図 5.16: 解析例 2:ElapsedTime に対する加速抵抗による推定消費エネルギーの散布図

第6章 結論

本論文では、自動車走行ログを使用した EV 消費エネルギーデータベースの構築と、そのデータベースを利用したデータ解析例を示すことで、構築データベースの有用性を示した。

1章では、本研究の研究背景と、本研究で達成すべき3つの課題を記述した。また、3つの課題それぞれの詳細を3章、4章、5章に示した。

2章では、本研究に関連する「EVの消費エネルギー推定と自動車走行ログの活用」と「データ可視化とデータ解析支援」に関連する研究とそれらの研究の本研究との差異を示した。

3章では、自動車走行ログを利用したEVの消費エネルギー量の推定方法と推定精度検証方法の確立を行った。推定精度向上のため、入力データの補正手法や取得方法の検討を行った。また、精度検証の正解データクレンジングにより、より正しい精度評価を可能にした。推定精度検証の結果、トリップ単位で走行消費電力量はRMSE0.27kWhで推定可能であることが示された。また、トリップ単位でエアコン消費電力量はRMSE0.24kWhで推定可能であることが示された。これらにより、トリップ単位などの大きな単位のエネルギー推定精度は、十分利用可能な一定の精度があることが確認された。

4章では、多変量データに対し、GUI上で関係代数演算などのデータ操作と、そのデータ操作をリアルタイムに反映したデータ可視化、そのデータ操作と可視化の状態をSQLライクな言語による保存、という3つの機能が利用可能なデータ解析支援システムの構築を行った。また、実際に収集したEVの消費エネルギーログを使用し、この解析支援システムによる有用なデータ解析例を示した。EV特有の複合したエネルギー消費要因を特定するデータ解析例により、構築した多変量データ解析支援システムが有用なEV消費エネルギーデータ解析に利用可能であることを示した。

5章では、有意区間による集計が可能なECOLOGデータベースの構築と、4章で構築したデータ解析支援システムを組み合わせたデータ解析フレームワークを利用し、有用なデータ解析例を示した。このフレームワークは、有意区間による集計を可能なECOLOGデータベースと、有意区間を作成・編集が可能なSemantic Editor、データ解析支援システムで構成した。実際に収集した自動車走行ログから推定したEV消費エネルギーデータを使用し、構築したフレームワークによる有用なデータ解析例を示した。データ解析例では、EVとガソリン車の特性の比較や、消費エネルギーの要因解析を行い、ECOLOGシステムを利用することで、推定消費エネルギーデータを有意区間ごとに集計したからこそ得られる、有用な知見が提示できることを示した。

以上のことから、本研究により、ユーザがEVを持っていなくとも、自動車走行ログを集めるだけで、「ユーザの運転や状況を反映したEVに関する有用な情報」を提示可能であることを示すことができた。

本論文では、ECOLOGシステムの応用先がデータ解析に限定されていた。3章、4章、5章で記述した今後の課題に加え、個人のユーザへのデータ可視化やフィードバックや、スマートグリッドシミュレーションのためのEV充電電状況の把握など、有用な応用先を増やしていくことが、今後の課題として挙げられる。また、応用先を増やすためにも、消費エネルギーデータのより高精

度，高粒度な推定を実現することが期待される。

謝 辞

本論文は、多くの皆さまのご助力のもと、完成することが出来ました。

指導教員である富井尚志准教授には、6年もの間、研究の推進や論文執筆等に対して多くの協力をいただきました。心から感謝申し上げます。

また、本論文の審査を担当頂いた岡嶋克典教授、田村直良教授、松井和己准教授、森辰則教授より、貴重なご助言、ご指導を賜りました。感謝申し上げます。

さらに、私と共に論文を執筆いただいた川沼大輝さん、柏原勇太さん、磯部康太くん、齋藤祐亮くん、濱崎裕太くん、石原有紗さん、河西秀作くん、有長拓海くん、吉瀬雄大くん、吉田顕策くん、能條太悟くんには、色々な形でご尽力いただきました。他の富井研究室メンバーにも、論文執筆や研究の議論などで多くのご協力をいただきました。深く感謝いたします。

最後に、自由奔放な私を、博士課程修了まで暖かく見守ってくれた家族に、心から感謝いたします。

参考文献

- [1] デロイトトーマツグループ. 次世代車に関する消費者意識調査 2019. <https://www2.deloitte.com/jp/ja/pages/about-deloitte/articles/news-releases/nr20190919.html>. 参照 Jan 11, 2021.
- [2] 廣田幸嗣, 船渡寛人, 三原輝儀, 出口欣高, 初田匡之. 電気自動車工学. 森北出版, 2017.
- [3] Mehrdad Ehsani, Yimin Gao, and Ali Emadi. *Modern electric, hybrid electric and fuel cell vehicles 2nd. Edition*. Power electronics and applications series, CRC press, 2010.
- [4] 齊藤祐亮, 植村智明, 富井尚志. EV 消費エネルギーログデータベースにおける消費電力量推定の精度検証. 情報処理学会論文誌データベース (TOD), Vol. 12, No. 4, pp. 40–52, 2019.
- [5] T. Uemura, Y. Kashiwabara, D. Kawanuma, and T. Tomii. Accuracy evaluation by gps data correction for the ev energy consumption database. In *Adjunct Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services*, MOBIQUITOUS 2016, pp. 213–218. ACM, 2016.
- [6] 植村智明, 川沼大輝, 磯部康太, 齋藤祐亮, 富井尚志. EV エネルギー消費ログ DB のための GPS データ補正による走行消費電力量推定の精度向上. 第9回データ工学と情報マネジメントに関するフォーラム (DEIM2017), pp. 1–8, 2017.
- [7] 植村智明, 石原有紗, 磯部康太, 齋藤祐亮, 河西秀作, 富井尚志. 正規化道路データに基づく EV エネルギーライフログの可視化と精度検証. 第10回データ工学と情報マネジメントに関するフォーラム (DEIM2018), pp. 1–8, 2018.
- [8] 濱崎裕太, 植村智明, 富井尚志. 多変量データを SPJ 質問により統合する平行座標プロット型情報可視化システムと操作言語. 情報処理学会論文誌データベース (TOD), Vol. 12, No. 4, pp. 27–39, 2019.
- [9] Daiki Kawanuma, Yuta Kashiwabara, Toshiaki Uemura, and Takashi Tomii. Data analysis framework for visualizing correlation of energy consumption and transit time in road sections using the ecolog database. *Adjunct Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services*, pp. 207–212, 2016.
- [10] 岩坪哲四郎, 池谷知彦. 電気自動車の性能評価技術-電費シミュレーション基本モデルの開発-. *Energy Engineering Research Laboratory, Rep.No.M11023, August*, pp. 1–19, 2012.

- [11] S. Grubwinkler, M. Hirschvogel, and M. Lienkamp. Driver- and situation-specific impact factors for the energy prediction of EVs based on crowd-sourced speed profiles. In *IEEE Intelligent Vehicles Symposium Proceedings*, pp. 1069–1076, 2014.
- [12] M. Ito, T. Shimoda, and K. Maema. Prediction Method of Cruising Range using Probe Data for Electric Vehicle. In *20th ITS World Congress*, pp. 1–10, 2013.
- [13] Y. Zhang, W. Wang, Y. Kobayashi, and K. Shirai. Remaining Driving Range Estimation of Electric Vehicle. In *2012 IEEE International Electric Vehicle Conference*, pp. 1–7, 2012.
- [14] J. Felipe, J. C. Amarillo, J. E. Naranjo, F. Serradilla, and A. Diaz. Energy consumption estimation in electric vehicles considering driving style. In *2015 IEEE 18th International Conference on Intelligent Transportation Systems*, pp. 101–106, 2015.
- [15] Y. Fei, W. Guoyuan, K. Boriboonsomsin, and M. Barth. A hybrid approach to estimating electric vehicle energy consumption for ecodriving applications. *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, pp. 719–724, 2016.
- [16] M. Martínez, A. Gardel, A. Wefky, F. Espinosa, J. Lázaro, I. Bravo, and P. Revenga. Electric Vehicle Consumption Estimation based on Heuristics and MLP Artificial Neural Network. *EEVC European Electric Vehicle Congress*, No. November, pp. 1–7, 2012.
- [17] Q. Yang, K. Boriboonsomsin, and M. Barth. Arterial roadway energy/emissions estimation using modal-based trajectory reconstruction. In *2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, pp. 809–814, 2011.
- [18] A. Styler, A. Sauer, I. Nourbakhsh, and H. Rottengruber. Learned Optimal Control of a Range Extender in a Series Hybrid Vehicle. In *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, Vol. 2015-October, pp. 2612–2618, 2015.
- [19] D. Karbowski, V. Sokolov, and A. Rousseau. Vehicle Energy Management Optimisation through Digital Maps and Connectivity. In *22nd ITS World Congress*, pp. 1–10, 2015. paper#1952.
- [20] M. De Souza, M. Ritt, and A. Bazzan. A Bi-objective method of traffic assignment for electric vehicles. In *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, pp. 2319–2324, 2016.
- [21] W. Chen, F. Guo, and F. Wang. A survey of traffic data visualization. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 16, No. 6, pp. 2970–2984, 2015.
- [22] 飯島護久, 堀口良太. プローブデータに基づくエリア流動性情報提供に関する研究. 第9回 ITS シンポジウム 2010 論文集, pp. 1–4. 2010.
- [23] Takahiro Komamizu, Toshiyuki Amagasa, and Hiroyuki Kitagawa. Visual spatial-olap for vehicle recorder data on micro-sized electric vehicles. In *Proceedings of the 20th International Database Engineering & Applications Symposium, IDEAS ' 16*, p. 358–363, 2016.

- [24] Isabel Wilmlink, Johan Olstam, Martijn van Noort, and Charisma F Choudhury. Microscopic simulation of eco-driving systems using real-world vehicle models. In *22nd ITS World Congress, Bordeaux*, pp. 1–12, 2015.
- [25] 矢野純史, 西村茂樹, 福永邦彦, 中島正浩, 山田浩之, 森口雅弘. プローブ情報を活用した EV 電費推定と経路探索への応用. *SEI テクニカルレビュー*, No. 184, pp. 24–29, 2014.
- [26] M. Fouladgar and R. Elmasri. Formalization of network-constrained moving object queries with application to benchmarking. *Proceedings of the 7th ACM SIGSPATIAL International Workshop on GeoStreaming - IWGS '16*, pp. 1–10, 2016.
- [27] 出縄誠, 出口達, 富井尚志. EV エネルギー消費ログ DB を用いた多様な可視化システムと運転状況に基づく情報の提示. *日本データベース学会論文誌*, Vol. 12, No. 1, pp. 127–132, 2013.
- [28] Benjamin Krogh, Nikos Pelekis, Yannis Theodoridis, and Kristian Torp. Path-based queries on trajectory data. *SIGSPATIAL '14*, p. 341–350, 2014.
- [29] Alfred Inselberg. The plane with parallel coordinates. *The Visual Computer*, Vol. 1, No. 2, pp. 69–91, 1985.
- [30] Jimmy Johansson and Camilla Forsell. Evaluation of parallel coordinates: Overview, categorization and guidelines for future research. *IEEE Trans. on Visualization and Computer Graphics (TVCG)*, Vol. 22, No. 1, pp. 579–588, 2016.
- [31] Fatma Bouali, Abdelheq Guettala, and Gilles Venturini. VizAssist: An interactive user assistant for visual data mining. *The Visual Computer: Int'l Journal of Computer Graphics*, Vol. 32, No. 11, pp. 1447–1463, 2016.
- [32] Takayuki Itoh, Ashnil Kumar, Karsten Klein, and Jinman Kim. High-dimensional data visualization by interactive construction of low-dimensional parallel coordinate plots. *Journal of Visual Languages & Computing*, Vol. 43, pp. 1–13, 2017.
- [33] Z. Zhou, Z. Ye, J. Yu, and W. Chen. Cluster-aware arrangement of the parallel coordinate plots. *Journal of Visual Languages & Computing*, Vol. 46, pp. 43–52, 2018.
- [34] G. Grinstein, M. Trutschl, and U. Cvek. High dimensional visualizations. In *In Proceedings of KDD Workshop on Visual Data Mining*, 2001.
- [35] Melanie Herschel, Ralf Diestelkämper, and Housseem Ben Lahmar. A survey on provenance: What for? what form? what from? *The VLDB Journal*, Vol. 26, No. 6, pp. 881–906, 2017.
- [36] Manuela Waldner, Stefan Bruckner, and Ivan Viola. Graphical histories of information foraging. *Proc. of the 8th Nordic Conf. on Human-Computer Interaction: Fun, Fast, Foundational(NordiCHI '14)*, pp. 295–304, 2014.

- [37] Peter Mindek, Stefan Bruckner, and M. Eduard Gröller. Contextual snapshots: Enriched visualization with interactive spatial annotations. *Proc. of the 29th Spring Conf. on Computer Graphics(SCCG '13)*, pp. 49–56, 2013.
- [38] S. Gratzl, N. Gehlenborg, A. Lex, H. Pfister, and M. Streit. Domino: Extracting, comparing, and manipulating subsets across multiple tabular datasets. *IEEE Trans. on Visualization and Computer Graphics(TVCG)*, Vol. 20, No. 12, pp. 2023–2032, 2014.
- [39] P. Godfrey, J. Gryz, and P. Lasek. Interactive visualization of large data sets. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 28, No. 8, pp. 2142–2157, 2016.
- [40] Mark Derthick, John Kolojejchick, and Steven F. Roth. An interactive visual query environment for exploring data. In *Proceedings of the 10th Annual ACM Symposium on User Interface Software and Technology, UIST '97*, p. 189–198, 1997.
- [41] Chris North and Ben Shneiderman. Snap-together visualization: A user interface for coordinating visualizations via relational schemata. In *Proceedings of the Working Conference on Advanced Visual Interfaces, AVI '00*, p. 128–135, 2000.
- [42] 杉渕剛史, 田中讓. 関係データベースモデルに基づくデータベース可視化フレームワークの提案と実装. 電子情報通信学会論文誌. D, 情報・システム = The IEICE transactions on information and systems (Japanese edition), Vol. 90, No. 3, pp. 918–932, 2007.
- [43] S. Brakatsoulas, R. Salas, and C. Wenk. On Map-Matching Vehicle Tracking Data. pp. 853–864, 2005.
- [44] International Organization for Standardization. ISO 11898, road vehicles - interchange of digital information - Controller Area Network(CAN) for high-speed communication, 1993.
- [45] International Organization for Standardization. ISO 11519, road vehicles- low-speed serial data communication, 1994.
- [46] U.S. Coast Guard. *NAVSTAR GPS : User Equipment Introduction*. 1996.
- [47] Torque Pro. <https://play.google.com/store/apps/details?id=org.prowl.torque&hl=ja>. Google Play, 参照 Jan 11, 2021.
- [48] 茨木隆兵, 田中雄哉, 富井尚志. エネルギーライフログデータベースと V2G 技術を用いた再生可能エネルギーとピーク需要を平衡させるシミュレーションシステム. 第 15 回 ITS シンポジウム 2017, pp. 1–6, 2017.
- [49] 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, 2009.
- [50] 電気自動車ハンドブック編集委員会. *電気自動車ハンドブック*. 丸善, 2001.

- [51] 磯部康太, 有長拓海, 植村智明, 齋藤祐亮, 吉瀬雄大, 富井尚志. 未知道路に対する EV の消費電力量推定システムの実走行データを用いた評価. 第 11 回データ工学と情報マネジメントに関するフォーラム (DEIM2019), pp. 1–8, 2019.
- [52] Toshiaki Uemura, supervised by Takashi Tomii. Pre-estimation of electric vehicle energy consumption on unfamiliar roads and actual driving experiments. Vol. 2399, No. 6, pp. 1–4, 2019.
- [53] 国土地理院. 数値地図 2500 (空間データ基盤). <http://www.gsi.go.jp/geoinfo/dmap/dm2500sdf/>. 参照 Jan 11, 2021.

関連発表文献

国際会議発表

1. Toshiaki Uemura, Yuta Kashiwabara, Daiki Kawanuma, and Takashi Tomii, “Accuracy Evaluation by GPS Data Correction for the EV Energy Consumption Database”, In Adjunct Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services (MOBIQUITOUS 2016), Workshop MUSICAL2016, Hiroshima, pp.213–218, 2016.11.
2. Toshiaki Uemura, supervised by Takashi Tomii, “Pre-Estimation of Electric Vehicle Energy Consumption on Unfamiliar Roads and Actual Driving Experiments”, Proceedings of the VLDB 2019 PhD Workshop, co-located with the 45th International Conference on Very Large Databases (VLDB 2019), Los Angeles, CEUR Wrokshop Proceedings Vol.2399, paper06, pp.1–4, 2019.8.

査読付き論文誌

3. 植村智明, 吉田顕策, 吉瀬雄大, 富井尚志, “試行錯誤を許容するデータ解析支援システムと電気自動車の走行ログ解析”, 情報処理学会論文誌データベース (TOD), Vol.13, No.4, pp.13–26, 2020.10.
4. 齊藤祐亮, 植村智明, 富井尚志, “EV 消費エネルギーログデータベースにおける消費電力量推定の精度検証”, 情報処理学会論文誌データベース (TOD), Vol.12, No.4, pp.40–52, 2019.10.
5. 濱崎裕太, 植村智明, 富井尚志, “多変量データを SPJ 質問により統合する平行座標プロット型情報可視化システムと操作言語”, 情報処理学会論文誌データベース (TOD), Vol.12, No.4, pp.27–39, 2019.10.

国内会議発表

6. 植村智明, 吉瀬雄大, 吉田顕策, 富井尚志, “車載 GPS ログの多変量データ可視化手法を用いた情報分析と電気自動車への応用”, 第 12 回データ工学と情報マネジメントに関するフォーラム (DEIM2020), A8-2, pp.1–8, 2020.3.
7. 植村智明, 濱崎裕太, 齊藤祐亮, 吉瀬雄大, 磯部康太, 有長拓海, 富井尚志, “EV 消費エネルギーデータベースの構築と連続する道路間の相関を考慮したデータ分析手法”, 第 11 回データ工学と情報マネジメントに関するフォーラム (DEIM2019), E7-5, pp.1–8, 2019.3.

8. 植村智明, 石原有紗, 磯部康太, 齋藤祐亮, 河西秀作, 富井尚志, “正規化道路データに基づくEV エネルギーライフログの可視化と精度検証”, 第10回データ工学と情報マネジメントに関するフォーラム (DEIM2018), H7-2, pp.1-8, 2018.3(学生プレゼンテーション賞).
9. 植村智明, 川沼大輝, 磯部康太, 齋藤祐亮, 富井尚志, “EV エネルギー消費ログDBのためのGPSデータ補正による走行消費電力量推定の精度向上”, 第9回データ工学と情報マネジメントに関するフォーラム (DEIM2017), E4-2, pp.1-8, 2017.3.

付録 A 解析例で示した STEP ごとの (PC)²L

以下に、4.4 章の解析例で示した解析 STEP ごとの結果を保存した (PC)²L を以下のリストに示す。

リスト A.1: STEP A-1 の結果を保存した (PC)²L

```
1 SELECT
2   [LEAFSPY].[GIDS_DIFFERENCE_BY_kWh],
3   [LEAFSPY].[AC_ENERGY],
4   [LEAFSPY].[EST_AC_ENERGY],
5   [LEAFSPY].[EST_HTR_ENERGY],
6   [LEAFSPY].[AUX_ENERGY],
7   [LEAFSPY].[REGENWh_DIFFERENCE_kWh]
8 FROM [LEAFSPY]
9 COLOR BY [LEAFSPY].[GIDS_DIFFERENCE_BY_kWh]
```

リスト A.2: STEP A-2 の結果を保存した (PC)²L

```
1 SELECT
2   [LEAFSPY].[GIDS_DIFFERENCE_BY_kWh],
3   [LEAFSPY].[AC_ENERGY],
4   [AVG_TEMP].[AVG_TEMP],
5   [LEAFSPY].[REGENWh_DIFFERENCE_kWh],
6   [LEAFSPY].[EST_HTR_ENERGY],
7   [LEAFSPY].[EST_AC_ENERGY],
8   [LEAFSPY].[AUX_ENERGY]
9 FROM [LEAFSPY]
10 INNER JOIN [AVG_TEMP] on
11   [AVG_TEMP].[TRIP_ID] = [LEAFSPY].[TRIP_ID]
12 VISUALIZE WITH
13   SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[GIDS_DIFFERENCE_BY_kWh], regression=false),
14   SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[REGENWh_DIFFERENCE_kWh], regression=false),
15   SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[AC_ENERGY], regression=false),
16   SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[AUX_ENERGY], regression=false)
17 COLOR BY [AVG_TEMP].[AVG_TEMP]
```

リスト A.3: STEP A-3 の結果を保存した (PC)²L

```
1 SELECT
2   [LEAFSPY].[GIDS_DIFFERENCE_BY_kWh],
3   [LEAFSPY].[AC_ENERGY],
4   [AVG_TEMP].[AVG_TEMP],
5   [LEAFSPY].[REGENWh_DIFFERENCE_kWh],
6   [LEAFSPY].[EST_HTR_ENERGY],
7   [LEAFSPY].[EST_AC_ENERGY],
8   [LEAFSPY].[AUX_ENERGY]
9 FROM [LEAFSPY]
10 INNER JOIN [AVG_TEMP] on
11   [AVG_TEMP].[TRIP_ID] = [LEAFSPY].[TRIP_ID]
12 WHERE
13   ([LEAFSPY].[GIDS_DIFFERENCE_BY_kWh] BETWEEN 0 AND 19.427258269720102) AND
14   ([LEAFSPY].[REGENWh_DIFFERENCE_kWh] BETWEEN 0 AND 1.8423333333333334)
15 VISUALIZE WITH
16   SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[GIDS_DIFFERENCE_BY_kWh], regression=false),
17   SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[REGENWh_DIFFERENCE_kWh], regression=false),
18   SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[AC_ENERGY], regression=false),
19   SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[AUX_ENERGY], regression=false)
20 COLOR BY [AVG_TEMP].[AVG_TEMP]
```

リスト A.4: STEP A-4 の結果を保存した (PC)²L

```
1 SELECT
2   [LEAFSPY].[GIDS_DIFFERENCE_BY_kWh],
3   [LEAFSPY].[AC_ENERGY],
```

```

4      [AVG_TEMP].[AVG_TEMP],
5      [LEAFSPY].[REGENWh_DIFFERENCE_kWh],
6      [LEAFSPY].[EST_HTR_ENERGY],
7      [LEAFSPY].[EST_AC_ENERGY],
8      [LEAFSPY].[AUX_ENERGY],
9      [SUMMARY].[TRIP_TIME]
10 FROM [LEAFSPY]
11 INNER JOIN [AVG_TEMP] on
12      [AVG_TEMP].[TRIP_ID] = [LEAFSPY].[TRIP_ID]
13 INNER JOIN [SUMMARY] on
14      [SUMMARY].[TRIP_ID] = [LEAFSPY].[TRIP_ID]
15 WHERE
16      ([SUMMARY].[TRIP_TIME] BETWEEN 1809 AND 2515.0356234096694) AND
17      ([LEAFSPY].[GIDS_DIFFERENCE_BY_kWh] BETWEEN 0 AND 19.427258269720102) AND
18      ([LEAFSPY].[REGENWh_DIFFERENCE_kWh] BETWEEN 0 AND 1.8423333333333334)
19 VISUALIZE WITH
20 SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[GIDS_DIFFERENCE_BY_kWh], regression=false),
21 SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[REGENWh_DIFFERENCE_kWh], regression=false),
22 SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[AC_ENERGY], regression=false),
23 SCATTER([AVG_TEMP].[AVG_TEMP],[LEAFSPY].[AUX_ENERGY], regression=false)
24 COLOR BY [SUMMARY].[TRIP_TIME]

```

リスト A.5: STEP B-1 の結果を保存した (PC)²L

```

1 SELECT
2     [LEAFSPY].[GIDS_DIFFERENCE_BY_kWh],
3     [LEAFSPY].[AC_ENERGY],
4     [LEAFSPY].[EST_AC_ENERGY],
5     [LEAFSPY].[EST_HTR_ENERGY],
6     [LEAFSPY].[AUX_ENERGY],
7     [LEAFSPY].[REGENWh_DIFFERENCE_kWh],
8     [MONTH].[MONTH]
9 FROM [LEAFSPY]
10 INNER JOIN [MONTH] on
11     [MONTH].[TRIP_ID] = [LEAFSPY].[TRIP_ID]
12 VISUALIZE WITH
13     BAR([MONTH].[MONTH], AVG, [LEAFSPY].[GIDS_DIFFERENCE_BY_kWh]),
14     BAR([MONTH].[MONTH], AVG, [LEAFSPY].[REGENWh_DIFFERENCE_kWh]),
15     BAR([MONTH].[MONTH], AVG, [LEAFSPY].[AUX_ENERGY], [LEAFSPY].[EST_AC_ENERGY], [LEAFSPY].[
16     EST_HTR_ENERGY])
16 COLOR BY [MONTH].[MONTH]

```