

電力消費削減に向けた EV 利用状況予測

Predict Electric Vehicle Usage to Save Energy Consumption

久米 洋輝, 阿部 航大, 脇森 浩志

要約 SDGs などによる環境問題への意識の高まりから様々なリソースを用いたエネルギー管理の取り組みが始まっており, 電気自動車 (EV) は移動できる電源として高く期待されている. EV を活用して家庭や法人の事務所, 工場, 店舗などのエネルギー管理を行うには, EV の出発時刻・帰宅時刻や, 各外出で消費する電力量 (SOC) を把握しなければならない.

出発時刻・帰宅時刻の予測は, 機械学習の一手法である RNN を応用して行った. また, 消費電力量の予測では, 出発時刻と帰宅時刻に近い過去の実績データを検索し, 統計的処理を行った. ユーザの行動は不規則で, 完全には予測できないものの, 走行データでの評価を通じて実用への道筋を確認できた.

Abstract Since the awareness for environmental problems is increasing and efforts are being made in energy management with various kinds of resource, EV (Electric Vehicle) is expected to use as a mobile power source. In order to perform energy management in homes, corporate offices, factories, shops, etc. using EVs, it is necessary to know the departure and return times of EVs and the amount of electricity (SOC) consumed during each trip.

The prediction of the departure time and return time is done by applying RNN, a machine learning method. For the prediction of the amount of energy consumption, we searched for past actual data with close departure and return time, and performed statistical processing. Although user behavior is irregular and cannot be predicted completely, we were able to confirm the path to practical use through the evaluation of driving data.

1. はじめに

脱炭素社会の実現に向けて, 多くの家庭や法人企業で太陽光発電をはじめとする再生可能エネルギー (以下, 再エネ) の導入が加速している. 再エネはエネルギー源が無尽蔵かつクリーンであることが特長だが, 天候などに左右されて発電量が変動するため, 有効活用するにあたっては蓄電池や電気自動車 (以下, EV) など, 需要家サイトに導入される分散型エネルギーリソースを活用して変動を吸収する. 分散電源が拡大することは火力などの大規模発電所への依存度を下げるとともに, エネルギーの地産地消や電力会社に頼らないオフグリッドの実現に貢献する. 特に, EV は SDGs をはじめとする環境問題への意識の高まりもあり, 今後は普及が進むとされている. 国が発表した「2050年カーボンニュートラルに伴うグリーン成長戦略」でも「2035年までに, 乗用車新車販売で電動車100%を実現できるよう, 包括的な措置を講じる」とされている^[1]. 普及は段階的に進むと予想されており, まずは環境意識の高い法人企業から導入が進み, 最終的に家庭を含む全てのガソリン車が廃止されることを目指している. また, 搭載するバッテリー容量が年々大きくなっていることから^[2], 蓄電池の代替物としての役

割を担うことができると期待されており、電気自動車を走行以外の用途で活用する Vehicle to X（以下、V2X）と呼ばれる新技術が注目されている。

V2X で家庭や法人の事務所、工場、店舗などのエネルギーマネジメントを行うには、EV の出発時刻・帰宅時刻や、各外出で消費する電力量（SOC）を把握しなければならない。本稿ではこれらを予測するアルゴリズムを紹介する。まず2章でV2X 実現にあたっての課題とそれらを解決するためのシステムの概要、3章でEV 状態予測アルゴリズムについて説明する。4章では評価実験を通じて得られた知見を考察し、5章にて実用への道筋を述べる。

2. V2X の現状と課題

2.1 EV の蓄電池活用

EV は車として移動できることに加えて、蓄電池として活用できる利点がある。電力が余っているエリアに移動して充電することや電力が足りていないエリアで放電するなど、移動電源としての役割を果たす。放電については充放電設備（V2H）を導入することで夜間に電力をシフトして使うことができる他、地震や台風などの自然災害により電力供給が遮断された場合でも、太陽光と組み合わせることで一定の機器や設備を稼働させることが可能となる。また、実量制を採用する高圧法人においては、電力ピークを迎える時間帯にEV から放電することで基本料金の大幅な削減も期待できる。このように様々なシーンでEV をマルチユースすることで利用用途を広げ、導入効果を高めていくことができる。

今後、台数や車種が増えていくなかで、それらを統合的にコントロールすることは、エネルギーリソースとしての価値を最大限発揮することに繋がる。それにあたって考慮すべきなのは、EV のモビリティ価値を損なってはならないということである。EV の本来用途は移動手段としての自動車である。そのため、走行に供するバッテリー容量を見極めるとともに、充電待ちが起きないことを前提としながら、エネルギー観点での活用可能性を判断する。

2.2 家庭における V2X

太陽光発電を設置した家庭は、昼間は需要に対して発電が上回り余剰電力が発生するのが一般的である。従来は国が定めた固定価格買取制度（FIT）を活用することで余剰電力を高値で売電することができたが、近年は買取価格が低下しているため、発電した電力を自身で消費する自家消費のニーズが顕在化している。殊に家庭においては高圧法人と比較して電気料金に占める託送料金が高いことより、自家消費は経済性の観点において有効であると言える。

今回日本ユニシス株式会社（以下、日本ユニシス）はEV を蓄電池として扱い、家庭における電気料金の最小化を図ることを最終的な目標とした。EV の充放電タイミングやバッテリー容量を見極めることができれば、自家消費率の向上や電気料金の高騰を回避することに寄与する。判断にあたっては自動車として電欠にならないことを前提にししながら、エネルギー価値も合わせた双方観点で最適なエネルギーマネジメントを行うことが重要である。それを実現するために、EV の状態やエネルギー利用の可能性を予測するEV 状態予測アルゴリズムを開発するに至った。尚、本稿で説明する技術は家庭をターゲットにしているが、事務所や工場、店舗などの高圧法人にも応用できるものである。

2.3 エネルギーマネジメントで把握すべき要素

家庭における EV を活用した電気料金最小化にあたり、以下の要素を把握する。

① EV 接続状態

EV が充放電器に接続されていない場合には、蓄電池として扱うことができない。そのため、外出計画を得ることで、EV が充放電可能な時間帯を把握する。

② 外出時の必要 SOC 量

本来の EV 用途は移動手段であるため、EV から放電をしすぎたり、充電をしなかったりすると、外出したいときに SOC 量が足りず、走行できない可能性がある。そのため、外出に必要な SOC 量を事前に把握しておく。蓄電池として扱うことは、少なからずモビリティとしての利便性を損なう可能性がある。そのリスクをどの程度許容し電気料金削減を図りたいかはユーザの志向に委ねるのが望ましい。

③ 太陽光発電量

太陽光発電の発電量は、天候や日射量に大きく影響を受けるため、日によってばらつきがある。太陽光で発電した電力を効率よく使うために、発電量を予測する。

④ 電力需要量

家庭や法人事務所などでの人の過ごし方や気温によって電力需要は変化する。電力の過不足が発生する時間帯を把握し、EV の充放電計画を作成するために、建物側の電力需要も予測する。

本稿では EV の制御に関連する①と②を課題として着目し、それらを解決する状態予測アルゴリズムを 3 章で説明する。

2.4 課題解決のためのシステム

ユーザはコンピュータが自身の行動をすべて予測し、電気料金が最小になる充放電制御を自動で実施することを望む。しかし、ユーザの行動は不規則な用事などがあり完全に予測できるものではない。そこでコンピュータからユーザへ、予測に基づいた EV の外出計画案を日ごとに複数提示し、選択させるような方法を検討している。ユーザは選択肢から自身の予定に近いものを選ぶだけでよいので、煩わしさを感じることはない。ユーザが外出計画を選択しなければ、予測を信頼して制御する仕組みにしてもよい。もし、コンピュータが提示した外出計画案の中に適切なものがなければ、ユーザが修正できるように工夫する。

EV の状態予測を基にコンピュータは充放電計画を作成する。作成にあたっては、EV 状態予測の他、建物の需要予測や太陽光の発電予測など、各予測結果をインプットデータとして取り込む。そうして作成された計画に基づいて、図 1 に示すように EV を含むエネルギーリソースを最適制御していくことを検討している。

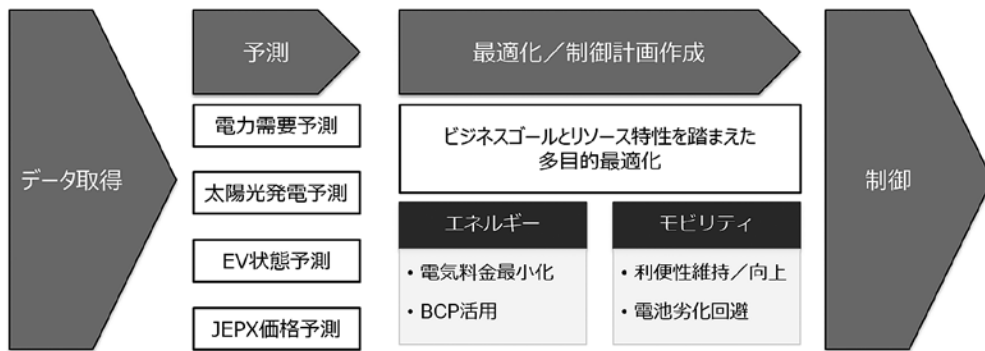


図1 システム処理のイメージ

3. EV 状態予測アルゴリズム

本章ではEV 状態予測の概要とアルゴリズムについて述べる。EV 状態予測は、外出予測と消費SOC 量予測の二つからなる。3.1節でEV が外出する時刻を予測する外出予測について、3.2節で外出で消費するSOC 量を予測する消費SOC 量予測について説明する。

3.1 外出予測

機械学習を用いて複数の外出計画を予測する。これらはユーザーに提示する際、極力バリエーションに富んでいることが望ましいため、集約およびソートを行う。

3.1.1 機械学習の適用

1日の外出計画を予測して、可能性が高いパターンを複数出力する。その実現に、蓄積された実績データから複雑な傾向を見出して精度の高い予測を行うことができる機械学習技術を応用した。

機械学習の適用にあたり、1日を30分単位などのコマに分け、各時刻の「在宅」、「出発」、「外出中」の状態を推測する。この時、直前の状態を考慮に入れず、それぞれの時刻を独立に予測すると図2の中段のように外出と在宅を繰り返す出力が得られてしまう。通常、自動車のこうした利用は稀であり、現実に沿わない。そこで、1日分のデータを系列として扱い、直前の時刻の状態を考慮に入れながら次の状態を予測できるRNN^[3]（再帰ニューラルネットワーク）と呼ばれる手法を採用した。RNNを用いることで図2の下段のようなまとまった時間の在宅や外出が出力できる。




図2 予測結果の比較

「在宅」「出発」「外出中」には図3のような遷移関係がある。ある時刻が「在宅」である場合、次の時刻も「在宅」の可能性はある。しかし「外出中」とは直接ならず、必ず「出発」を経由する。RNNではこうした関係性も取り込むことができる。




図3 状態の遷移図

RNNの模式図を図4に示す。RNNはディープラーニングの一種であり、層と呼ばれるモジュールが積み重なって、相互に計算結果を送受信しながら結果を導き出す。早い時刻のコマから予測が行われ、季節、曜日、天気、時間帯といった予測の手がかりとなるような情報を入力にしつつ、順に結果を出力する。ニューラルネットワーク部分は各時刻で同じものである。LSTM^[4] (Long Short-Term Memory) 層を用いてRNNを構築した。入力に直前の状態が含まれることに加え、LSTM層内で以前の情報も引き継ぐので、外出と在宅を繰り返す出力を抑制できる。

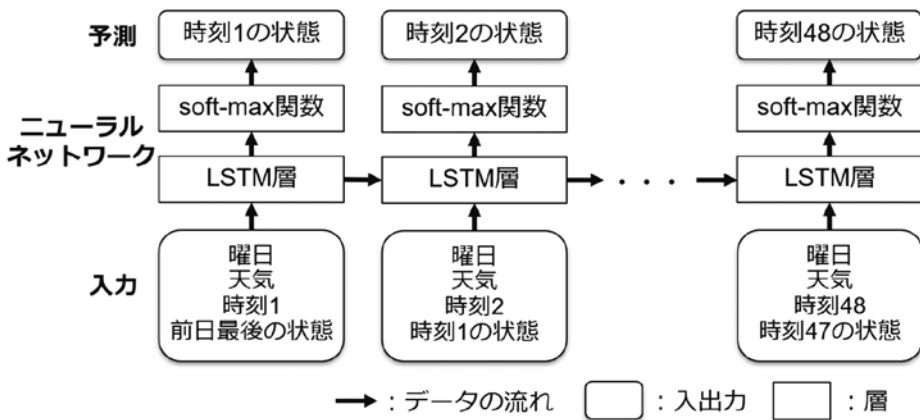


図4 RNN 模式図

RNNから可能性が高いパターンを複数取得するにはビームサーチと呼ばれるアルゴリズムを併用する。ここからは説明を分かりやすくするため、「出発」と「外出中」を「外出」にまとめ、「在宅」「外出」のみで話を進める。

RNNでは時刻1の予測を「在宅」が80%、「外出」が20%のような確率で出力できる。時刻1が「在宅」かつ時刻2が「外出」といった組み合わせの確率は、時刻1が「在宅」である確率に、時刻1が「在宅」である場合の時刻2が「外出」である確率を掛けたものである。1コマを30分単位とすると1日は48コマであり、これを時刻48まで繰り返すことで1日分の

パターンの確率を計算できる。

すべてのパターンから確率が上位である M 件のパターンを選び出す際、総当りの計算を試みると、状態数 (2) のコマ数 (48) 乗である 281 兆のパターンを調べなくてはならず、高性能なコンピュータを用いても実用的な時間で計算できない。ビームサーチは対象パターンを効率的に絞り込みながら、上位のパターンを探索する方法である。M はシステム管理者が与えるパラメータである。以降、アルファベット大文字 1 字でパラメータを表す。

図 5 にビームサーチの概略を示す。図中の線は状態の組み合わせを表しており、数値はその確率である。ビームサーチでは各時刻において上位 N 件 (ビーム幅) だけを残しつつ、RNN で次の時刻の確率を得ていく。最後の時刻まで到達したら、パターンを確率の降順で並び替えて上位 M 件を得る。

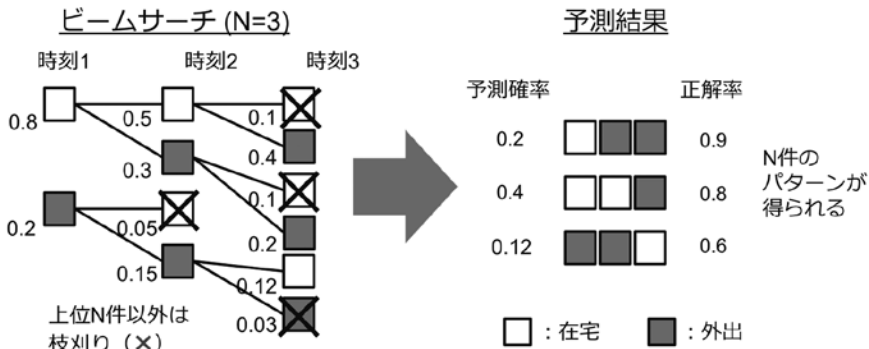


図 5 ビームサーチ

3.1.2 結果と集約のソート

ビームサーチで得られた結果には、1 コマだけが異なるといった差の小さいパターンが多く含まれる。ユーザに翌日の行動予定に近いものを選ばせることができるように、可能な限りバリエーションに富んだパターンを提示したい。そこで互いの類似性に基づくパターンの集約と並び替えを行う。図 6 に概要を示す。

左側のパターン 1 ~ 10 はビームサーチの出力であり、最初のステップで以下のアルゴリズムに従って中央の 4 件に集約される。(1, 2, 4, 9), (3, 6), (5, 7), (8, 10) はもとのパターン番号と対応する。パターン 2, 4, 9 は 1 と、6, 7, 10 はそれぞれ 3, 5, 8 と類似するため集約 (削除) された。




図 6 ビームサーチ出力の集約と選択

集約アルゴリズム

1. N 件のパターンを実績データにおける正解率（時刻ごとの外出・在宅の一致数）の降順でソートする。
2. まだ選択も削除もされていないパターンのうち、正解率が最も高いものを選択する。
3. 選択したパターンに類似したパターン（後述）をすべて削除する。
4. 選択も削除もされていないパターンが無くなるまで手順 2 と手順 3 を繰り返す。

類似判定

- 1 日の外出回数が同じ
- 外出における出発時刻と帰宅時刻の差がそれぞれ ± 1 時間以内、かつ 1 回の外出時間の差が ± 1 時間以内
- 1 日に複数回の外出がある場合は、それぞれの外出で上記の条件を満たす

最後に、集約したパターンが多彩になるように以下のアルゴリズムでソート（並び替え）を行った後、上位 M 件を抽出する。最上位であるパターン 1 がまず選択され、それと最も差が大きいパターン 8 が 2 番目に選ばれた。さらにこれらのパターンとの差が大きいパターン 5 が選ばれている。

ソートアルゴリズム

1. 実績データでの正解率が最も高いパターンを「リスト」に加える。
2. まだリストに載っていないパターンのうち一つを選択する。
3. 既にリストに載っている各パターンとの一致率（時刻ごとの外出・在宅の一致数）を計算し、最高値をリストとの「重複度」とする。
4. 選択していないパターンが無くなるまで手順 2 と手順 3 を繰り返す。
5. 重複度が最小のパターンをリストに加える。この時、複数のパターンが同じ値の場合は正解率が最上位の 1 件を加える。リストが M 件未満の場合は手順 2 に戻る。
6. リストに追加された順にパターンを出力する。

3.1.3 機械学習の更新

機械学習が実績データから予測のための傾向を事前に見出すことを「学習」と呼ぶ。3.1.2 項の RNN には対象とする家庭の外出実績を学習させる。この際、古い時期のデータより直近の時期のデータを重視させた方が予測の精度を高めやすい^{*1}。そこで直近 L 日分のデータだけを使って、1 週間ごとに RNN の学習を実施し直すことにした。

3.2 消費 SOC 量予測

3.1 節で出力した外出ごとの消費 SOC 量を予測するために、出発時刻と帰宅時刻に近い過去実績を利用する。図 7 に概要を示す。まず予測対象日以前の D 日の実績データから出発時刻・帰宅時刻の差が予測対象とそれぞれ 1 時間以内である外出を抽出する。次に予測対象と時刻の重なり（例：13:00～17:00 と 12:30～16:00 の場合、13:00～16:00 の 3 時間）が大きい順に K 件を抜き出す。最後に K 件の外出の消費 SOC 量の中央値を結果とする。なお、最初の条

件に合致する外出が1件もない場合、直近30日の外出のうち、予測対象との時刻の重なりが一番大きい外出の消費SOC量を結果とする。

3.1節の外出予測と異なり、機械学習ではなく統計ベースによる予測を採用したのは計算コストに見合うだけの精度が得られなかったためである。外出予測では曜日、時間帯といった情報が機械学習による予測の有効な手がかりとなったが、消費SOC量予測には役立たず、統計ベースの方法と精度が変わらなかった*2。




図7 消費SOC量予測

4. 評価実験

本章では、前章で説明した外出予測と消費SOC量予測のアルゴリズムの精度を評価する。429台のEVを実際に利用して採取したテレマティクスデータを加工し、395日分の実験データを用意した。

4.1 外出予測

4.1.1 実験概要

毎日同じ時刻に外出を繰り返すユーザーや対象期間を通じて外出が少ないユーザーなど、外出の規則性や時間の大小でユーザーを分類し、それぞれの代表ユーザーを抽出して、アルゴリズムの妥当性と予測精度を確認した。RNNに入力した情報は曜日、時間帯、1時刻前の状態の三つである。3.1.3項で述べた1週間ごとのRNNの学習は行わず、データの前半305日分をRNNの学習用データとし、後半の90日分を検証用データとして実験を行った。

予測結果は、正解率、適合率、再現率の三つの指標を用いて評価した。正解率は、在宅、または外出を正しく予測できたコマの割合である。適合率は、外出と予測したコマのうち、実際に外出していた割合で、誤って外出と予測したコマの少なさを表す。再現率は実際に外出していたコマのうち、外出と予測できた割合で、実際の外出をどれだけ漏れなく拾うことができたかを表す。EVは外出時に充電が難しく、それまでに必要なSOC量を確保しておかなければならない。外出時刻を網羅的に予測できていることが重要であるため、実験では適合率よりも再現率を重視した。

外出予測アルゴリズムのパラメータは、ビームサーチによって得られる予測件数Nを100、ユーザーに提示する外出予測Mを5とした。2.4節で述べた通り、ユーザーに複数の外出計画を提示し、選択してもらうことを想定しているため、予測パターン上位5件の中で最も正解率が高いものが選ばれると仮定して前述の三つの指標を算出した。

4.1.2 結果

1) 予測結果の集約と選択アルゴリズムの妥当性評価

機械学習を使って予測した結果の集約・選択アルゴリズム (3.1.2 項) の妥当性を確認する。図8は外出の規則性が高い代表ユーザでの結果である。曜日ごとに図示しており、黒が外出、白が在宅である。各グラフの横軸は時刻で、左端は0時00分、右端は23時30分を示す。「集約前」はビームサーチによって得られた100件の外出予測、「集約後」は100件の外出予測のうち類似するものをまとめた結果である。「予測系列」はユーザに提示する5件を表している。「実績」は過去90日分のデータであり、縦軸が下に向かうほど新しい。

図8の、集約後の結果より、集約前の外出パターンが狙い通りにまとまっていることがわかる。また、集約後と予測系列の比較により、ユーザに提示する5件が、1コマだけが異なるといった差の小さいパターンだけでなく、バリエーションに富んでいることがわかる。本稿では割愛するが、他の代表ユーザにおいても同様の結果が得られた。

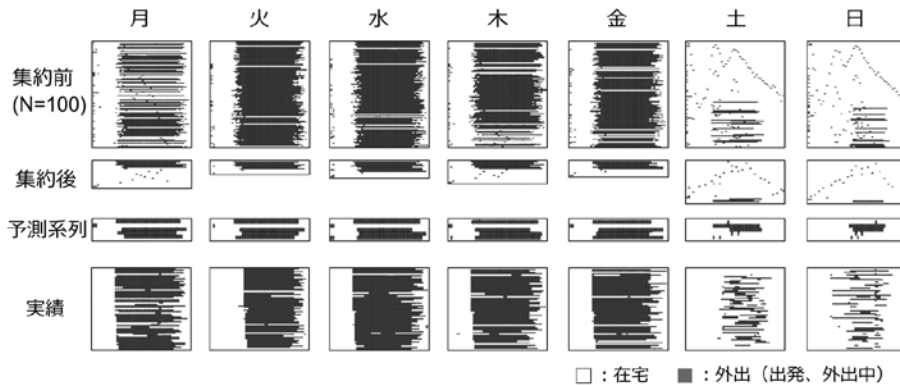


図8 外出予測の結果 (規則性高)

2) 予測結果の精度評価

表1～5に外出の規則性や時間が異なる代表ユーザの結果を示す。外出の規則性が高いユーザ (表1) では、正解率がすべての曜日で90%を超えている。平日は特に予測が容易で適合率・再現率ともに80%以上の結果を得ている。一方、土日は外出をあまり捕捉できておらず、再現率が30%程度である。外出の規則性が中程度のユーザ (表2) でも日曜日以外のすべての指標で80%以上と良好な結果を得ている。外出の規則性が低いユーザ (表3) では指標が若干悪化し、それに外出時間が少ないという条件が加わる (表4) と顕著に劣化する。一方、外出の規則性が高いユーザでは、外出時間が少なくても高い精度が維持される (表5)。

表 1 外出予測の精度 (規則性高)

	月	火	水	木	金	土	日	平均
正解率	0.93	0.95	0.94	0.94	0.95	0.92	0.93	0.94
適合率	0.82	0.79	0.91	0.78	0.75	0.33	0.61	0.71
再現率	0.83	0.83	0.98	0.82	0.74	0.29	0.38	0.70

表 2 外出予測の精度 (規則性中)

	月	火	水	木	金	土	日	平均
正解率	0.96	0.93	0.95	0.97	0.96	0.95	0.92	0.95
適合率	0.97	0.90	0.88	0.97	0.87	0.81	0.75	0.88
再現率	0.95	0.96	0.87	0.97	0.89	0.80	0.72	0.88

表 3 外出予測の精度 (規則性低)

	月	火	水	木	金	土	日	平均
正解率	0.87	0.82	0.82	0.81	0.87	0.84	0.80	0.83
適合率	0.71	0.51	0.64	0.70	0.63	0.67	0.67	0.65
再現率	0.77	0.51	0.67	0.93	0.70	0.73	0.65	0.71

表 4 外出予測の精度 (規則性低, 外出少)

	月	火	水	木	金	土	日	平均
正解率	0.92	0.89	0.93	0.86	0.90	0.97	0.89	0.91
適合率	0.00	0.07	0.29	0.58	0.00	0.00	0.00	0.14
再現率	0.00	0.08	0.27	0.65	0.00	0.00	0.00	0.14

表 5 外出予測の精度 (規則性高, 外出少)

	月	火	水	木	金	土	日	平均
正解率	0.95	0.96	0.93	0.98	0.95	0.98	0.96	0.96
適合率	0.53	0.88	0.79	0.92	0.84	0.83	0.79	0.80
再現率	0.57	0.85	0.72	0.98	0.80	0.80	0.78	0.79

4.1.3 考察

規則性が高いユーザでは正解率、再現率が優れており、高い精度で予測ができています。規則性が低いユーザでは規則性が高いユーザほどの精度が得られず、その向上が今後の課題である。適合率についても同様の傾向が見られる。

一部のユーザで土日の精度が平日に比べて低いのは、土日は定時通勤のような決まった行動をせず、レジャーなどで不定期に外出したことが原因と考えられる。今回の結果からは、外出時間の大小よりも規則性の高低が予測精度に直結しているように見える。これは機械学習が過去の実績データから傾向を学習することが影響している。

今回は用意できたデータの期間が短く、対応できなかったが、季節性などの情報も考慮していくことで、こうしたユーザの外出も精度良く予測できる可能性がある。

4.2 消費 SOC 量予測

4.2.1 実験概要

外出予測と同様に、外出の規則性や時間に特徴を持つ代表ユーザを抽出して消費 SOC 量予測の実験を行った。全 395 日分のデータのうち、直近 95 日分の外出データに対して消費 SOC 量の予測を行い、実績との差を比較した。

まず、予測対象日以前の $D=300$ 日の実績データから類似の外出 $K=10$ 件を抽出することで、予測の精度を確認した。次に D を下げながら予測を行うことで、十分な精度を得るために何日分のデータがあればよいかを確認した。

4.2.2 結果

ユーザごとの予測結果を表 6 に示す。各指標の定義は以下の通りである。

- 実績平均
実績値の平均。
- 予測平均
予測値の平均。
- 平均誤差
実績値と予測値の誤差の平均。誤差が平均してどの程度かを表す。
- 平均誤差率
実績値と予測値の差を実績値で割った値の平均。平均誤差を実績値との相対率で表した指標。
- 誤差標準偏差
実績値と予測値の差の標準偏差。誤差がどの範囲に収まるかを統計的に表す。
- 10 件偏差平均
抽出した類似外出の偏差平均。

予測平均は実績平均と非常に近い値になっているが、平均誤差や平均誤差率が大きい。特に平均誤差率はすべてのユーザで 40% を超えており、精度の高い予測が行えたとは言い難い。誤差標準偏差と同様の性質を持ち計算コストの小さい 10 件偏差平均は誤差標準偏差と近い値となっている。

図 9 に D を 30, 60, 100, 200, 300 と変化させた際の平均誤差を示す。一部のユーザを除いて、 $D = 300$ の場合と $D = 30$ の場合で大きく変わらない結果となった。

表6 消費SOC量の精度

ユーザ	実績平均	予測平均	平均誤差	平均誤差率 (%)	誤差標準偏差	10件偏差平均
規則性高	12.23	12.46	5.54	68.04	6.70	4.89
規則性中	25.05	27.64	7.98	41.47	5.98	9.35
規則性低	17.91	19.23	11.11	187.06	8.07	10.69
規則性低外出少	12.65	11.36	5.13	56.85	5.71	5.45
規則性高外出少	5.71	5.75	2.32	63.60	2.56	2.03




図9 実績データ数Dによる、消費SOC量予測精度の変化

4.2.3 考察

平均誤差率が大きいことから、個々の予測は真の値と乖離していることがわかる。しかし、誤差標準偏差から、消費SOC量の予測で見込まれる誤差を推定できる。これを踏まえ、リスクを回避した充放電計画を立てることにより、モビリティを損なわずにEVを活用することが可能となる。例えば、実際に発生しうる誤差の範囲を検討し、消費SOC量が最大となる場合でも成り立つような充放電計画を立てればよい。一方、誤差標準偏差は計算コストが大きく、即時性が求められるシーンでは利用しづらい。そこで、より計算が容易で、近い値が得られた10件偏差平均を近似値として代用することにより、そうした場面でも消費SOC量の予測誤差を考慮できる。

実績データ数Dを少なくしても予測精度は大きく変わらないことから、本アルゴリズムによる消費SOC量予測には1か月程度のデータがあれば十分だと考えられる。

5. 実用際に際して

4章の評価実験では利用できるデータが約1年分であったため、季節性を考慮せず曜日や時刻などの情報を基に予測を行った。複数年のデータが蓄積できていれば、季節性などの傾向を考慮でき、外出予測・消費SOC量予測ともに精度向上が期待できた。また、本実験ではEV

の位置情報が得られなかったため、天気の情報予測を組み込むことができなかった。雨の日は EV を利用して、そうでない日は徒歩で外出するといった行動パターンも考えられるため、天気は予測の重要な手掛かりとなる。天気で気温が上下し、冷暖房の利用に伴い消費 SOC 量にも影響を及ぼすであろう。

実際の適用シーンでは、EV の利用場所が特定され天気を考慮できることが多いため、より精度の高い予測が行える。EV を長期保有することでデータが蓄積され、精度が次第に向上する。

6. おわりに

本稿では、EV を蓄電池として活用する際に用いる EV 状態予測アルゴリズムを検討し、その評価を行った。ユーザの行動は不規則で、完全には予測できないものの、曜日や時間帯といった限られた情報をインプットにすることで一定の成果が得られた。本アルゴリズムを活用することで、最終目標である電気料金の最小化を実現できると考える。今後は EV 状態予測を、家庭や法人の電力需要予測、太陽光発電量予測、買電価格、蓄電池、自家発電機などの変動要素と組み合わせることで、電力を自動制御するアルゴリズムを検討したい。

EV は普及の途上にあるが、本技術をエネルギーマネジメントだけではなくモビリティサービス領域にも活用し、EV 化社会の実現に貢献できるよう、周辺技術の確立や関連企業とのアライアンス締結などを行い、地盤を固めていきたい。


-
- * 1 EV 所有者の転勤や子供の卒入学・長期休暇などのライフイベントに伴う日常行動の変化から容易に想像がつくであろう。
 - * 2 無条件に最新の手法を信じることなく、先入観を除いた評価を行うことがデータサイエンス案件では重要である。

- 参考文献**
- [1] 2050 年カーボンニュートラルに伴うグリーン成長戦略, 経済産業省, 2020 年 12 月
<https://www.meti.go.jp/press/2020/12/20201225012/20201225012.html>
 - [2] 定置用蓄電池の普及拡大及びアグリゲーションサービスへの活用に関する調査, 株式会社三菱総合研究所, 2017 年 7 月
https://www.data.go.jp/data/dataset/meti_20171206_0290 (デジタル庁データカタログサイト)
 - [3] David E. Rumelhart, Geoffrey E. Hinton, Ronald J. Williams, Learning representations by back-propagating errors, nature 323 533-536, 1986
 - [4] S Hochreiter, J Schmidhuber, Long short-term memory, Neural computation, 1997

※ 上記参考文献に含まれる URL のリンク先は、2021 年 10 月 25 日現在の存在を確認。

執筆者紹介 久米 洋輝 (Hiroki Kume)

電気通信大学にて情報理工学を専攻し、2019 年日本ユニシス(株)入社。入社後は機械学習に関する業務を担当し、本アルゴリズムを提案。現在は本アルゴリズムを活用した電気料金最適化実証において、最適化に関する業務も合わせて担当。



阿部 航大 (Kodai Abe)

2015年日本ユニシス(株)入社。電力領域におけるビジネス企画・実行、新規サービス開発など主にエネルギー関連プロジェクトを担当。2018年より電気自動車関連の業務に従事。



脇森 浩志 (Hiroshi Wakimori)

2003年日本ユニシス(株)入社。自然言語処理・統計解析・画像処理・数理最適化などのデータサイエンス領域における技術研究やソリューション開発、ビジネス適用に従事。

