

ハイブリッド車両のための深層強化学習を用いた 最適化手法による充放電制御の可視化

横内 俊秀* 近藤 稔 (鉄道総合技術研究所)
神藤 駿介 近藤 圭一郎 (早稲田大学)

Visualization of Charge and Discharge Control for Diesel Hybrid Vehicles using Deep Reinforcement Learning Optimization

Toshihide Yokouchi*, Minoru Kondo, (Railway Technical Research Institute)
Shunsuke Jindo, Keiichiro Kondo, (Waseda University)

Charge and discharge control optimization for diesel hybrid vehicles using deep reinforcement learning reduces fuel consumption and extends battery life. On the other hand, since the control unit made by deep reinforcement learning is represented by a neural network, it is difficult to intuitively understand relationships between driving conditions and the charge and discharge control. In this paper, we propose a method to classify the charge and discharge control using K-means method based on the input-output relationships of the neural networks, and visualize the control in terms of speed and State of Charge (SoC).

キーワード：ハイブリッド車両，充放電制御，強化学習，可視化

(hybrid vehicle, charge and discharge control, reinforcement learning, visualization)

1. 序論

日本の非電化路線では長年、液体式気動車が使用されてきたが、回生ブレーキが使用できない、駆動軸等の保守を必要とする部品を多数有するといった点で課題があった。これらを改善するため、近年では液体式気動車に代わりハイブリッド車両の導入事例が増えてきた。ハイブリッド車両はバッテリーを搭載しており、ブレーキ時に発生する電力を充電することができる。これにより、以降の必要電力をバッテリーから供給できるため、省エネルギーな運転が可能である。また、エンジンを高効率な動作点で運転することも省エネにつながる。近年では、温室効果ガス排出量の削減が要請されており、鉄道における省エネルギー化はより一層必要となる。そのような背景の下、ハイブリッド車両の燃費向上を目的としたバッテリーの充放電制御の研究が行われている⁽¹⁾⁽²⁾。

一方、これまでの充放電制御は設計者の考察に基づき人為的に定義されており、走行路線や列車種別等の条件毎に適切な充放電制御を検討するのは、労力や時間を要する。そのため、実際の運用では必ずしも最適な制御を適用できない。そこで、鉄道車両の更なる省エネルギー化を目指し、深層強化学習を使用して充放電制御を自動的に最適化する手法が提案されている⁽³⁾⁽⁴⁾。しかし、深層強化学習で得られた

充放電制御は、制御がニューラルネットワークで実行されており、制御内容の把握や解釈が困難である。そこで本研究では、これまでに提案されている、速度と SoC (State of Charge) を基準とした充放電制御法⁽¹⁾⁽²⁾を参考に、深層強化学習で得られた充放電制御を速度-SoC マップ上で可視化する手法を提案する。本手法により、制御内容を理解しやすい形に表現でき、さらに既に速度-SoC マップを基に制御する車両には、可視化の結果をそのまま適用できる。なお、本手法は深層強化学習を用いた手法に限定されず、充放電制御部の入出力が得られれば適用可能である。

2. 深層強化学習を用いた充放電制御最適化

〈2.1〉 ハイブリッド車両の充放電制御 本研究の対象であるシリーズハイブリッド車両 (以下、ハイブリッド車両と呼ぶ) の主回路構成を図 1 に示す。ハイブリッド車両は力行時にはエンジンに直結した発電機、およびバッテリーから供給される電力で主電動機を駆動する。また、ブレーキ時には主電動機で発生した電力をバッテリーに充電し、以降の必要電力をバッテリーからも供給する。したがって、バッテリーの充放電を適切に行うことで、省エネルギーな走行が可能になる。




図1 シリーズハイブリッド車両の主回路構成

〈2・2〉 深層強化学習を用いた充放電制御最適化 充放電制御の自動的な最適化手法として、深層強化学習を用いた手法が提案されている。本手法では、Q学習を基本として、Rainbowと呼ばれる手法を適用している。図2に深層強化学習を用いて最適化された充放電制御の概要を示す。充放電制御部はニューラルネットワークを含むため、予め学習させておく必要がある。学習済みの制御部は、速度、必要電力、SoC等からなる車両および走行の状態に応じて最適な発電電力、すなわち発電ノッチを逐次選択する。バッテリーの充放電電力は必要電力と選択された発電電力との差分から計算される。しかし、ニューラルネットワークから制御内容を直接解釈することは困難なため、本研究では制御部の入出力関係に基づき制御内容を可視化する。




図2 充放電制御部の機能

3. 充放電制御の可視化手法

〈3・1〉 速度-SoC マップの可視化 充放電制御の可視化の概要を図3に示す。

まず、速度およびSoCについて格子状の組み合わせを考える。組み合わせごとに、複数種類の必要電力に対する最適な発電電力（以降、「発電パターン」と呼ぶ）を充放電制御部から得る。この時、充放電制御部への入力に速度、SoC、および必要電力以外の項目がある場合には、①当該項目の値を固定して発電パターンを得る、または②当該項目と必要電力を組み合わせで発電パターンを得る。①の場合、発電パターンの解釈は容易であるが、当該項目は特定の値の場合を前提とすることになる。②の場合、当該項目についても一般性があるが、発電パターンは2つ以上の項目が組み合わせるため解釈が困難になる。

次に、速度およびSoCの組み合わせ毎に得られた発電パターンを多次元空間上の一点とみなし、任意の数分にクラスタリングする。まず、前処理として標準化を行い各軸のスケールを揃える。次に、K-meansによりクラスタリングを行う。本稿ではK-meansをベースに最適解への収束性を高めた改良手法であるK-means++を使用する。これにより、速度およびSoCの組み合わせに対応する発電パターンがいくつかのクラスタに分類される。

最後に、クラスタ毎に色分けして速度-SoCのコンターマップ上に表示する。このように、速度-SoCマップ上で発電パターンを表現できるため、充放電制御を把握しやすくなる。

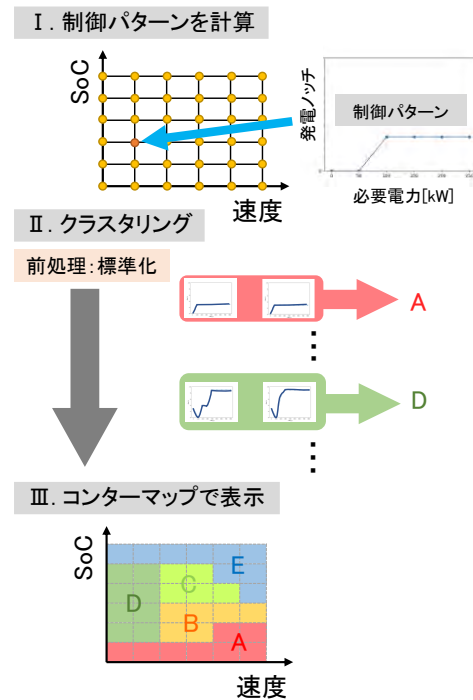


図3 充放電制御の可視化

〈3・2〉 発電パターンの可視化 各クラスタにおける発電パターンの傾向を把握するため、可視化を行った。本稿では、①Hex-bin、②平面ヒストグラムを使用した。いずれも、各クラスタに所属する発電パターンを必要電力-発電電力マップ上に重ねてプロットし、プロットの密度を色で表示したものである。Hex-binは、平面を六角形の集合に分割し、各六角形内のプロット数に応じて色を付ける表示法である。平面ヒストグラムは、平面を格子状に分割し、各格子内のプロット数に応じて色分けする表示法である。

〈3・3〉 クラスタ数の妥当性評価 K-meansは、手法の性質上、クラスタ数を予め設定しておく必要があり、クラスタ数が適切でないと発電パターンを明瞭にクラスタリングできない恐れがある。そこで、分布から適切なクラスタ数が判断できない場合に、それを評価する手法として、シルエット法が一般的に使用されている⁽⁵⁾。シルエット法では、各点に対し、所属するクラスタ内の他の点との平均距離 a と最近傍のクラスタに所属する各点との平均距離 b から式(1)のように計算されるシルエット係数 (SC: Silhouette coefficient) を計算する。

$$SC = \frac{b - a}{\max(a, b)} \quad (1)$$

シルエット係数は-1 から 1 の範囲の値をとり、1 に近いほど他のクラスタと離れていることを意味する。クラスタ毎にシルエット係数が大きい順に並べ、ナイフ状に表示したグラフがシルエット図である (図 4)。シルエット図では、各クラスタのナイフが同様の長さであれば、良いクラスタリングと判断される。また、グラフには図 4 中の赤破線のようにシルエット係数の全点平均値が表示されており、全クラスタのナイフがその値を上回っているのが望ましいとされる。




図 4 シルエット図

4. 可視化

〈4.1〉 対象とする充放電制御 仮想的な路線データを基にハイブリッド車両を想定した走行シミュレーションを行った。得られた評価データに対して、深層強化学習による最適化手法⁽⁴⁾を改良した手法を用いて得られた充放電制御を可視化する。評価データの一部区間の様子を図 5、全区間の速度および SoC の推移を図 6 に示す。また、評価データの概要を表 1、充放電制御部の入出力を表 2 に示す。勾配も入力項目であるが、可視化にあたり 0 (平坦区間) に固定した。

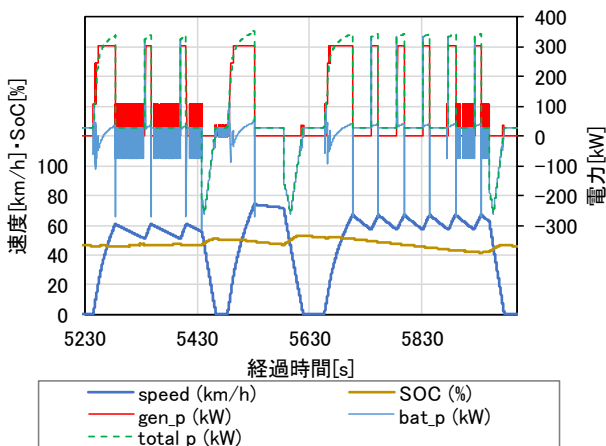


図 5 評価データ (一部区間)

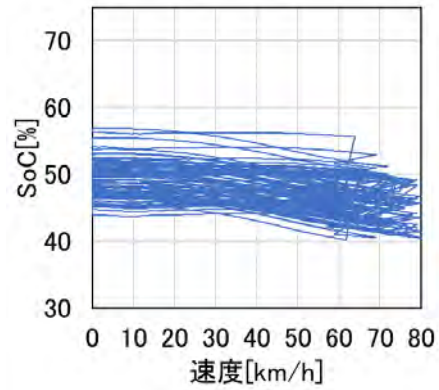


図 6 速度・SoC の推移 (全区間)

表 1 シミュレーションモデル・評価データ

項目	値
走行時間	11569.6 秒 (57849 サンプル)
サンプリング時間	0.2 秒
最高速度	80km/h
発電電力	0~336kW (10 段階)

表 2 充放電制御部の入出力

項目	値
入力	速度, SoC, 必要電力, 勾配
出力	発電電力

※可視化にあたり勾配は 0 に固定

〈4.2〉 クラスタリングの評価 本稿ではまず、適切なクラスタ数を評価するため、シルエット法を適用した。適用結果を図 7 に示す。シルエット係数の平均値が 0.4 付近と低く、直線状のクラスタ境界では明瞭な分類が難しいことが分かる。一方、シルエット図からは、クラスタ数 2 および 4 が全てのクラスタで SC 平均値 (赤破線) を超えていることが分かる。さらに、SC 平均値はわずかにクラスタ数 4 の場合で大きいので、適切なクラスタ数は 4 と判断する。

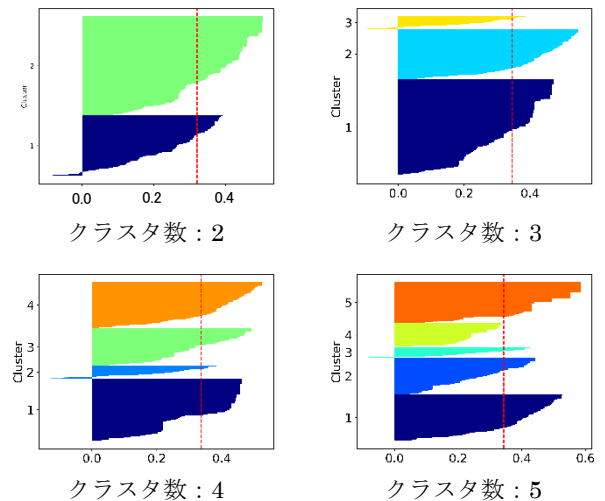


図 7 シルエット法による評価 (クラスタ数 2~5)

〈4・3〉 可視化結果 可視化結果を図 8 に示す。また、発電パターンの可視化結果を Hex-bin および平面ヒストグラムについて図 9 および図 10 にそれぞれ示す。クラスタ 1 および 3 は特定の発電電力を境に発電停止と最高出力運転が切り替わる。クラスタ 2 では最高出力運転を基本としている。クラスタ 4 では最高効率点での運転を行っている。このように各クラスタで発電パターンに特徴がある。充放電制御の解釈としては、速度が高く SoC が低いクラスタ 3 の領域では、SoC の低下を防ぐためにバッテリーからの出力を抑え、ほぼ常に発電機を最高出力で運転していると考えられる。一方、速度が低い、または、速度が低く必要電力が小さい場合が多いクラスタ 4 の領域では、発電機側もバッテリー側も比較的余裕があるため、発電機側では省エネな運転につながる最高効率点で運転すると考えられる。なお、速度-SoC マップから、クラスタ境界が斜めに引かれていることが分かる。図 6 から速度および SoC の推移とクラスタ境界は直交する傾向を示しており、力行時にはクラスタ 4→3→1→2、ブレーキ時にはクラスタ 2→1→3→4 の順番で発電パターンを切替えている傾向が確認された。

既存のハイブリッド車両のうち、速度および SoC に基づき充放電制御を行っている車両については、速度-SoC マップおよび各クラスタの発電パターンを適用することで、深層強化学習で得られた充放電制御を適用できる。また、クラスタ内で、ある必要電力に対して複数の発電電力が選択されている場合には、より頻度の高い発電電力を使用すれば良いと考えられる。

5. 結論

ハイブリッド車両のための深層強化学習を用いた最適化手法による充放電制御に対して、クラスタリング手法を用いた速度-SoC マップ上での可視化手法を提案した。また、各クラスタの発電パターンの可視化を検討した。その結果、充放電制御を可視化するとともに、速度および SoC に応じて最高効率点や最高出力を使い分けるような解釈しやすい結果となることを確認した。これにより、充放電制御の解釈が容易になると共に、既存のハイブリッド車両への充放電制御の適用が可能になると考えられる。

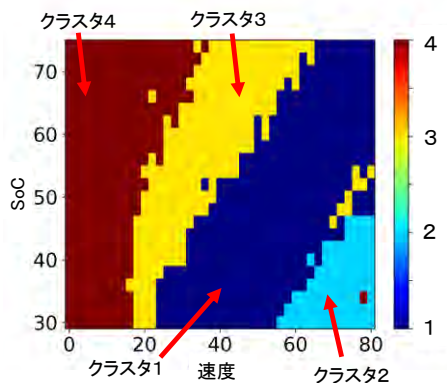


図 8 速度-SoC マップ

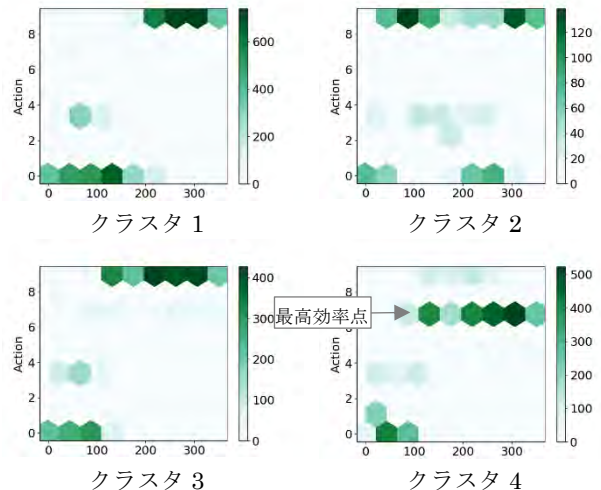


図 9 発電パターン (Hex-bin)
(横軸：必要電力[kW] 縦軸：発電ノッチ)




図 10 発電パターン (平面ヒストグラム)
(横軸：必要電力[kW] 縦軸：発電ノッチ)

文 献

- (1) 白木ら：「キハ E200 形ディーゼル気動車のハイブリッドシステム」, 第 17 回鉄道技術連合シンポジウム (J-RAIL2010) 講演論文集, No.SS4-2 (2010)
- (2) 高草ら：「運用負荷が大きいディーゼルハイブリッド車における最適充放電制御の開発」, 電気学会論文誌 D, Vol.138, No.4 pp.340-345 (2018)
- (3) Yokouchi et al.: "Optimization of Power Generation for Diesel Hybrid Train with Deep Reinforcement Learning", presented at the WCCR2022, Birmingham, UK, 2022.
- (4) 神藤ら：「ハイブリッド鉄道車両の充放電制御に向けた強化学習モデルの構築」, 2022 年電気学会応用部門大会論文集 (2022)
- (5) Turelien Geron: 「Scikit-learn, Keras, TensorFlow による実践機械学習」, 第 2 版, オライリー・ジャパン, pp.247-250 (2020)