

エネルギー工学と機械学習

東京理科大学 創域理工学部 電気電子情報工学科 准教授 **片山 昇** かたやま のぼる

はじめに

当研究室では、エネルギー工学の分野で、近年とくに機械学習を活用した研究に力を入れています。エネルギーデバイスの状態推定、電力変換回路の異常検知・制御、エネルギーマネジメントなど、取り組むテーマは多岐にわたります。本稿ではそのなかからいくつかを選んでご紹介します。

機械学習は、インターネットの普及によって大量のデータを容易に収集できるようになったこと、そしてコンピュータの計算性能が飛躍的に向上したことを背景に、この10年ほどで急速に発展してきました。その中心的な役割を担っているのがニューラルネットワークです。人間の脳の神経回路を模した構造に、入力と出力の組を大量に与えると、その間に潜むルールを自動的に学び取ってくれます。とくに層を深く重ねたものは深層学習（ディープラーニング）と呼ばれ、画像認識や自動翻訳はすでに実用の域に達しており、ここ数年は大規模言語モデルによって私たちと自然な会話を交わし、複雑な質問にも答えてくれるようになりました。まさに人工知能（AI）と呼ぶにふさわしい技術になったと言えるでしょう。


エネルギー分野においても、センサー技術やIoT、高精度なシミュレーションの普及により、動作データを大量に取得できる環境が整いつつあります。カーボンニュートラルの達成に向けて太陽光発電や水素といった新たなエネルギー源の導入が進む中で、個々の機器を安全かつ高効率に運用していくためには、こうしたデータを活かしたきめ細かな監視や制御の技術が欠かせません。

エネルギーデバイスの状態推定


リチウムイオン電池や水電気分解装置は、いずれも内部の電気化学反応によって充放電や水素生成を行う

エネルギーデバイスです。これらを安全かつ長寿命で使うためには、デバイス内部の状態を正しく把握することが欠かせません。電気化学の分野では、古くから交流インピーダンス法という手法が状態計測に使われてきました。デバイスに小さな交流電圧や電流を与え、その応答からインピーダンス（交流に対する抵抗に相当する量）を求める方法です。周波数を変えながら測定したインピーダンスを複素平面上にプロットすると、**【図1】**のような軌跡が得られます。これはナイキスト線図と呼ばれ、デバイス内部の化学反応や物質移動に関する様々な情報を含んでいます。このグラフではリチウムイオン電池の充電量ごとにナイキスト線図をプロットしていますが、非常に複雑な形状になっています。また、測定されるインピーダンスは温度や使用履歴にきわめて敏感で、必要な情報を精度よく取り出すためには、理想的な条件での測定と、デバイスを単純な電気回路に見立てる等価回路への当てはめなど、熟練した解析が求められてきました。

そこで私たちは、リチウムイオン電池を対象に、充放電履歴や温度などさまざまな条件下でインピーダンスと電池状態の組を大量に計測し、ニューラルネットワークに学習させる方法に取り組んでいます**【図2】**。学習がうまく進むと汎化と呼ばれる性質が働き、未知の電池についてもインピーダンスから充電量や健全度を精度よく推定できるようになります。従来のように



【図1】 リチウムイオン電池の充電量とインピーダンス特性（ナイキスト線図）




【図2】ニューラルネットワークによって推定したリチウムイオン電池の温度




【図3】固体高分子形水電気分解スタック

電流を積算して充電量を求める方式では誤差が蓄積してしまいますが、この方法であれば現在のインピーダンスだけから状態を一意に決められます。理想的な測定条件を作り込まずとも、データさえ集まれば現場で使えるため、電気自動車や住宅用蓄電池の運用、さらには一度使った電池を別の用途に活用するリユース電池の状態評価への応用が期待されます。

最近では、水電気分解スタックの状態推定にも挑戦しています¹⁾。固体高分子形水電気分解装置(PEMWE)は、再生可能エネルギー由来の電力から水素を製造する要となる機器です【図3】。多数のセルを積層してスタックを構成しますが、セルごとに温度がばらつくと局所的な劣化の原因となります。ところがスタック全体のインピーダンスは【図4】のようになり、これは各セルのインピーダンスが合成されてしまっているため、通常の等価回路解析では個々のセルの温度を分離することは非常に難しくなります。そこで、一様な温度で測定した二つのスタックのインピーダンスを重ね合わせることで、温度差のあるスタックの挙動を模擬し、この合成データでニューラルネットワークを学習させ、さらに少量の実データで出力層を再学習する転移学習と組み合わせる方法を考案し、【図5】のよ



【図4】水電気分解スタック内に温度差がある場合のインピーダンス特性




【図5】推定した水電気分解スタック内の温度差

うにスタック内の温度差を精度良く推定することに成功しました。本例では温度差を推定しましたが、将来的には局所的な動作不良などの検出への応用が期待されます。また、この研究では、インピーダンスの計測に独立した測定器を使わず、水電解装置を動かすための電力変換回路そのものを利用しています。具体的には、回路の電流制御に小さな交流成分を重ね合わせることでインピーダンスを測定する方式を採用しており、装置を動作させながらリアルタイムで状態を推定できる点も特徴です。


電力変換回路への応用

太陽光発電のパワーコンディショナ、電気自動車の駆動インバータ、家電の電源回路など、私たちの身のまわりのあらゆる電気機器には、電気の形を変える電力変換回路が組み込まれています。これらの回路における故障検知や制御の高度化は、エネルギーの利用効率や安全性を大きく左右します。

一つ目の応用は、オートエンコーダーと呼ばれる機械学習モデルを利用した、サーモカメラで撮影した画像を使った異常検知です²⁾。住宅用太陽光発電の故障の約半分はパワーコンディショナで起きており、火災




【図6】 オートエンコーダーを用いた異常検知の原理




【図7】 実験に用いた電力変換回路

事故につながる可能性もあるため、異常を未然に検知する技術が求められています。ところが電力変換回路は、電力を制御するスイッチング素子自体が発熱するうえ、動作条件や過渡状態も多様です。そのため、たとえばサーモ画像から、「この温度を超えたら異常」といった単純なルールで故障を判定するのは困難でした。


オートエンコーダーは入力された画像をいったん少数の特徴量に圧縮し、そこから元の画像を復元するように学習させるニューラルネットワークです。正常時の熱画像だけで学習させておくと、異常な熱分布が入力されたときにはそのまま復元されないため、入力と出力の差分を異常スコアとして利用できます【図6】。実際に【図7】のように市販のパワーモジュールの基板上に小型の抵抗ヒーターを貼り付けて模擬的な故障を作り、負荷電流を変化させながら撮影したサーモ画像で検証しました。その結果、【図8】の差分画像のように異常部位を明確に検出することができました。サーモカメラの撮影角度や位置の違いに対応するため、オリジナル画像に回転・射影変換・輝度調整といった画像処理を施してデータ量を増やすデータ拡張も、精度向上に大きく貢献しています。この手法は、異常画像を一切用いなくて済むため、設計段階では想定しきれない多様な異常を、正常データだけで検出できることが特徴です。



【図8】 オートエンコーダーによる異常部位の検出



【図9】 深層強化学習を用いた電力変換回路の制御



【図10】 深層強化学習を用いた電力変換回路の制御例

二つ目は、深層強化学習を用いた回路制御です。従来の電力変換回路は技術者が設計したルールに基づき動作していますが、回路や負荷が複雑になるほど、この設計が難しくなります。強化学習は、エージェントが環境と対話しながら行動と報酬の関係を試行錯誤で学び、最適な戦略を自ら獲得していく枠組みです。私たちはこれを電力変換回路に適用し、さらにスイッチ素子のオン・オフそのものを1マイクロ秒ごとにニューラルネットワークが直接決定する Direct Gate Control という方式を提案しました【図9】。行動はオンかオフかの二値、状態は直近の出力電圧誤差・回路素子の状態の履歴、報酬は電圧誤差と不要なスイッチングの両方を抑える形で設計し、深層強化学習で学習させました。シミュレーションの結果、負荷が急変した後の復帰時間は非常に高速であり【図10】、回路に用いられている部品のばらつきや、測定ノイズの重


曇といった条件でも安定に動作することを確認しています。固定の変調周期を前提としないので、より複雑な回路や高速な応答が求められる用途への展開が期待されます。

エネルギーマネジメントへの応用

太陽光発電、蓄電池、燃料電池などが各家庭や施設に設置され、電力システムは大規模発電所から一方的に電気を送る形から、消費地で発電と蓄電を行う分散型の形へと変わりつつあります。消費地の近くで発電できるので送電ロスを減らせますし、災害時にも電力を確保しやすくなるなど利点は多いのですが、その一方で、誰がどのように運用するのかというエネルギーマネジメントの問題が新たに生じます。太陽光発電の売電価格と買電価格の関係、蓄電池の充放電サイクルによる劣化、ダイナミックプライシングのように時々刻々と変動する電気料金など、考慮すべき要素は多岐にわたり、すべてを人手で最適化することはほぼ不可能です。

ここでも強化学習が活躍します。先ほど紹介したりチウムイオン電池の状態推定では、インピーダンスと電池状態の正解の組を教師データとして学習させる教師あり学習の枠組みを用いていましたが、エネルギーマネジメントでは、どの時間帯にどれだけ充放電するのが正解であるかを事前に用意することができません。強化学習ではコンピュータ上のシミュレータで何年分もの試行錯誤し、利益を最大化する行動を自ら獲得します。行動は蓄電池の充放電電力、状態は各機器の出力・電気料金・時刻、報酬は月ごとの経済性として設計します。

住宅用の太陽光発電と蓄電池を想定し、深夜の電気料金が昼より安いプランを与えてみたところ、太陽光発電の出力が弱まる夕方から深夜までの間に蓄電池を放電し、明け方までの電気料金が安い時間に蓄電池を充電して電気料金が高くなる時間に備えるという細かな運用方針を、ルールを全く教えることなく獲得することができました【図 11】。日射量や気温、天気予報などを状態に加えればさらに賢くすることもでき、現在は実際の住宅を想定したシステムでの実証試験も進めています。将来このような仕組みが普及すれば、各需要家の装置を賢く動かすことを通じて、太陽光発電



【図 11】 深層強化学習を用いたエネルギーマネジメントの例

の余剰電力の活用や電力システムの安定化にも貢献できるのではないかと期待しています。

おわりに

本稿では、エネルギーデバイスの状態推定、電力変換回路の異常検知と自律制御、住宅のエネルギーマネジメントと、エネルギー工学のさまざまな階層で機械学習が力を発揮しつつあることを紹介してきました。共通しているのは、理論モデルを作り込まなくても、データやシミュレーションを与えれば複雑な関係をまとめて学んでくれるという点です。まだ、課題は山積しており、さまざまな分野の大量のデータで事前に学習したモデルを取り入れ多様な機器の診断に展開していくことや、シミュレーション上で学んだ制御を実機に安全に移す sim-to-real、そしてニューラルネットワークの判断根拠を人間が理解できる形で示す説明性の確保などが、重要なテーマになってきます。

当研究室では、本稿で紹介したエネルギー工学への機械学習の応用のほかに、燃料電池や水素貯蔵など幅広いテーマに取り組んでおり、科学フォーラムの過去号³⁾で紹介しています。また、当研究室の研究員のウェブサイト³⁾や技術ブログ⁴⁾でも情報公開していますのでご覧ください。

参考文献

- 1) N. Katayama et al., "Data-Driven Temperature Deviation Estimation of a Proton Exchange Membrane Water Electrolyzer Stack from Electrochemical Impedance Using Machine Learning," *IEEE Transactions Elec Engng*, vol. 20, no. 9, pp. 1488–1496, Sep. 2025.
- 2) N. Katayama et al., "Fault Detection Method for Power Conversion Circuits Using Thermal Image and Convolutional Autoencoder," *IEEE Access*, vol. 13, pp. 189028–189036, 2025.
- 3) 理大 科学フォーラム 404 号, pp. 32–37, 2018 年 4 月
- 4) 片山研究室ウェブサイト, <https://energylab.jp/>
- 5) 片山研究室 note, <https://note.com/energylab/>