

機械学習によるバッテリー監視データを用いた電池容量劣化の異常検知*

Data-Driven Anomaly Detection of Battery Capacity using Monitoring Data

吉田 周平
Shuhei YOSHIDA

山本 信雄
Nobuo YAMAMOTO

菅家 智子
Tomoko KANKE

There is a growing need for the State of health (SOH) estimation. Among these, the anomaly detection of battery capacity is critical for safe and reliable operation of lithium ion batteries. In this paper, focusing on the relevance between battery monitoring data, the novel Graphical Lasso (GLASSO) through the use of L1 regularization was adopted to be shown the relationship between them. Using this data-driven techniques, detection method of battery sudden deterioration in real time was developed from changes of relationship while moving the data section for acquiring monitoring data.

Key words :

Li-ion battery, battery diagnosis, battery degradation, anomaly detection, machine learning, Graphical Lasso

1. 諸元

環境問題とエネルギー問題の観点で、近年、電気自動車（xEV）のライフサイクルにおいて二酸化炭素（CO₂）排出量評価 LCA（Life Cycle Assessment）が必要不可欠である。その中で、電気自動車のキーコンポーネントであるバッテリーに関しては、電池セルに用いられる原材料の資源性の議論も相まって、各国では、車載用バッテリーのリサイクルやリユースなどの議論がなされている。

一方、自動車以外では、再生可能エネルギーの導入が各国政府主導で進められており、同時に、太陽光発電や風力発電といった変動電源や HEMS（Home Energy Management System）などのエネルギー貯蔵用バッテリーの導入が推進されている。

車載用バッテリーのエネルギー貯蔵用へのリユース活用により、新品バッテリーと比較し、均等化発電原価（LCOE：Levelized Cost of Electricity）は 12～41% 削減、また、地球温暖化係数（GWP: Global Warming Potential）は 7～77% 削減可能という試算もあり¹⁾、各国では車載用バッテリーのリユース活用の実証試験が進んでいる^{2) 3)}。

しかしながら、車載用バッテリーの主流であるリチウムイオン電池は、近年の電池災害事故の問題もあり、車載用バッテリーのエネルギー貯蔵用へのリユースにおいて、リスク管理としてバッテリーの状態・遠隔監視によりリアルタイムで電池診断を行い、異常予兆を検知することが必須になってきている。

デンソーは、経済産業省の次世代エネルギー・社会システム実証（2010 年度）において、HEMS 分野、

*トヨタ自動車（株）の了承を得て、第 53 回オールトヨタ TQM 大会の発表資料より一部加筆して転載

BEMS 分野、商用車分野でプロジェクトに参画し、デンソーの内製 HEMS 用リチウムイオンバッテリーシステムを提供してきた^{4) 5)}。

そこで、本稿では、デンソーの HEMS 用リチウムバッテリーシステムの監視データを活用し、機械学習手法を用いた電池容量の異常劣化検知技術を開発したので紹介する。

2. HEMS用リチウムイオンバッテリーシステム

HEMS 用リチウムイオンバッテリーシステムの外観を Fig. 1 に示す。このシステムは、内製の 20Ah 級オリビン型リン酸鉄リチウムイオン電池セルを 96 直列で構成した定格容量 5kW のバッテリーを用いている。仕様は、定格出力電力 1500W、定格入力電力 2000W (太陽光余剰電力充電モード) で、システム電力効率は 84% 以上、システム作動温度範囲は -5℃ ~ 45℃ である。

使用した電池セルは、実証期間中 (約 4 年)、容量維持率が 70% 以上を確保する寿命設計を行った。リチウムイオン電池の容量は充放電に伴うリチウムイオンの収支で決定され、設計段階で、本セルの劣化



Fig. 1 External appearance of Li ion battery system for HEMS

は、通電や保存の負荷により、リチウムイオンが負極表面で安定な副生成物 (SEI 被膜, Solid Electrolyte Interphase) として消費されるモードと、使用期間に伴い SEI 被膜が壊れ、被膜を修復するためにリチウムイオンの消費が加速するモードがあることを確認している。本稿では、後者の劣化加速モードを電池容量の異常劣化と定義した。

また、このバッテリーシステムは、定期的に満充放電制御にて容量測定を行い、電圧、電流、温度などの 9 項目のデータを、1min 毎でサンプリングし、ECU 仕様に従い RS485 4 線式の通信方式で、遠隔でデータ監視を行った。

3. 監視データと異常検知の方針

3.1 課題の明確化

バッテリーの劣化状態 (SOH: State of Health) を診断する方法は、充放電を伴う測定が一般的であり、充放電曲線から得られた容量や抵抗などの情報から診断を行う。しかし、容量測定のような動特性の測定は時間を要するだけでなく、停止時間の発生などユーザの負担が大きい。また、OBD などを活用した SOH 診断手法は、特定の電流パターンが無ければ測定や推定ができないため、離散的な診断になり、リアルタイムに異常を検知できない問題があった。

また、容量を含む動特性を測定した場合においても、リチウムイオン電池は使用期間に伴い容量は劣化するため、通常使用での連続的に変化する通常の劣化を示す容量低下のデータ群から、異常な劣化を示す容量低下を抽出するのが困難であり、この分離が課題であった。

3.2 現状把握

バッテリーの SOH 診断は電池セル毎の電気化学測定が確実である。具体的には、満充電状態から一定電流での放電により、そのときの実際の容量を取得する方法である。但し、この手法では 10 時間程度の時間を要し、そのタイミングは、夜間等の運転停止が前提になり、実際には、ユーザ負荷を考慮して頻度は 3 ~ 4 ヶ月に 1 回の診断となる。

より簡易な方法としては、電池抵抗や開回路電圧な

ど、常時監視可能な電圧や温度などの監視データの項目毎の数値が規格内におさまっているか否か静特性を検査する手法もあるが、この手法では、異常値を示したときに、実際の容量測定を行うことが必要となる。

このように、容量のような動特性の取得は、測定やユーザの負荷が大きく、また、常時監視可能な静特性からの推定においても、動特性との相関が明確でないため定性的な判断にとどまってしまう問題があった。

3.3 監視データの属性と理解

HEMS 用バッテリーシステムにおいて、40 台のバッテリーを約 3.5 年間、定期的に容量測定した結果を Fig. 2 に示す。また、監視データは電圧、電流、温度などの 9 項目のデータを、1min 毎でサンプリングした。Fig. 3 に、1 日分の監視データ一例を示す。本稿では、監視データのみで、容量急劣化の起点 (異常の起点) を検知することを目標とした。

解析対象である監視データの特徴としては、(i) 監視データの項目 (変数) が多く、変数間に相関関係がある、(ii) 正常の範囲内であっても変化する項目 (変数) がある、ことが挙げられる。(i) については、例えば電流を流せば電圧が変化するという、各変数の相関を利用して、各変数単独の挙動のみで異常を検知することができない。また (ii) については、正常なデータ群から、異常の程度を定量化しても、閾値 (境界) の設定が困難で、異常有無を判別できない。つまり、電池セルの監視データには、変数間の相関性と、正常と異常のデータ群の連続性が混在しており、解析を困難なものにしている。

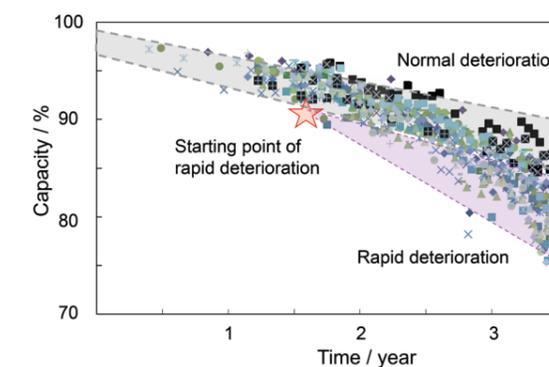


Fig. 2 Variation of discharge capacity during HEMS demonstration

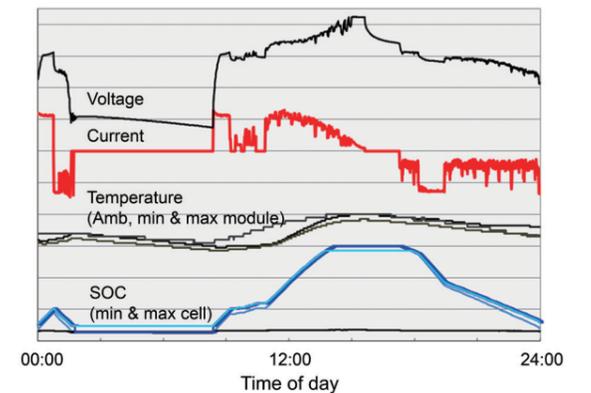


Fig. 3 monitoring data

4. モデリングの手法選定

初期と時間経過後における監視データ間の相関係数のヒートマップを Fig. 4 に示す。それぞれの時点において、変数間の相関関係は認められるが、劣化前後では変数の関係性が異なっていることがわかる。そこで、個々の監視データ値そのものでなく、変数の関係性に着目して異常判定すること、つまり、監視データ間の関連性の崩れを異常として検知することを行った。また、正常な関連性からの逸脱を検知する解析手法としては、結果の関係性が見えやすい相関解析を行うこととした。

一般に、データから変数間の相関関係から疑相関を取り除いた偏相関係数の関係性をみる手法としてガウシアン・グラフィカル・モデリング (Gaussian Graphical Model 以下, GGM) が挙げられる。この時、偏相関係数を求めるためには相関係数の逆行列を求めなければならないが、バッテリー監視データのように変数間に強い相関をもつデータの場合、逆行列を正しく求められないといった問題があったため、今回、GGM でなく、機械学習手法である L1 正則化を活用したグラフィカルラソー (Graphical Lasso 以下, GLASSO) を適用した。

Fig. 5 に GLASSO を監視データに適用した結果を示す。ここでは、各頂点が変数を、辺が偏相関係数を、辺の太さが関係性の強弱を表している。この時、変数選択により、真の関係性がある変数間では非ゼロの偏相関係数となり、弱い関係性しかもたない変数間においてはゼロとし、辺は結ばれない。

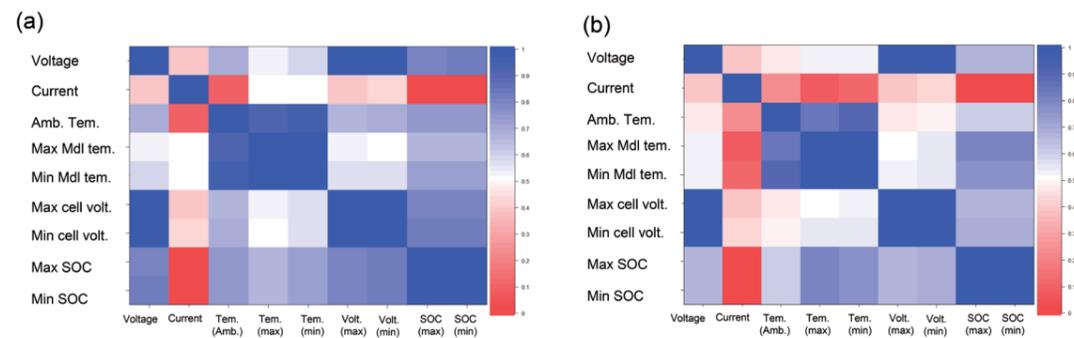


Fig. 4 Heatmap of correlation coefficient matrix (a) initial and (b) after the elapse of a certain period of time

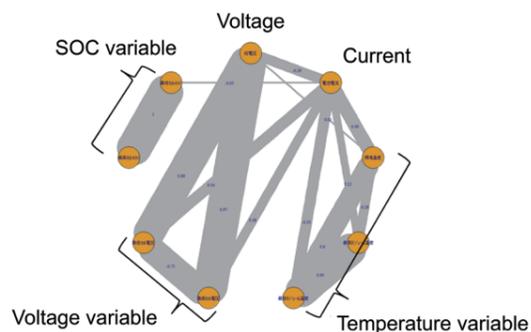


Fig. 5 Relationship between monitoring data using Graphical Lasso (GLASSO)

5. モデル化

GLASSO を活用し、異常検知の概要および異常検知モデルの作成ステップを Fig. 6 に示す。監視データからの (Step1) 過去・現在の一定区間の監視データを用い関係性を可視化、(Step2) 過去と現在の相関の差を異常度とし定量化、(Step3) 直近監視データに移動して Step1～2 を繰り返し監視データの異常を判定、の3つのステップで異常検知の解析を行った。

Step1: 関係性の可視化

解析ソフトウェア“R”の glasso パッケージを用い、監視データの可視化を行った。監視データを取得するデータ区間 (窓) を移動させながら GLASSO で関係性を示し、前後の関係性が崩れないか確認し、常時変動する監視データからのリアルタイム異常検出を行った。

Fig. 7 に、代表的な正常と異常の容量推移と監視データの GLASSO 関係性を示す。異常を示す容量推移

のデータにおいて、窓を移動させながら関係性の比較を繰り返すと、容量の急劣化を示す近傍で、監視データの関係性が変化することが確認された。この時、異常前後での偏相関関係が変化している部分は温度と電流であり、異常前後で発熱と充放電効率の関係性に变化があったことがわかった。これは、異常劣化を示す劣化加速モードにおいて、負極 SEI 被膜の修復でリチウムイオンの消費が増加し、発熱増加や充放電効率の低下をもたらしたと推察される。

Step2: 異常度の定量化

Step1 で学習した監視データの相関について、過去と現在の相関を比較するための最適な定量化パラメータを、訓練データを用いてチューニングした。異常度の検知性能を最大化するためには、(i) 監視データの取得する区間である窓幅、(ii) 解析期間を移動する窓移動量、(iii) 異常度を表す統計量、(iv) 比較区間の最適化が必要である。ここで、(iii) では、異常度を定量化に用いる値として、前後の差のずれを数値化したカイ 2 乗値と、前後の確率分布の差異の尺度であるカルバックライブラー疑距離 (Kullback-Leibler divergence) を用いた。また、(iv) では、定量化値の比較区間として、初期のデータと現在を含む直近データとの関係性との差分を検討対象とした。

検討結果を Fig. 8 に示す。窓幅や窓移動量が短時間だと敏感に異常として検知しやすく、長くなると異常検知の感度が鈍くなることがわかった。また、異常度の統計手法や比較区間なども異常検知感度の観点より決定し、最も正常時のノイズが少なく、異常度の上昇を

見逃さないパラメータとして、(i) 7日分、(ii) 3日移動分、(iii) 前回比較、(iv) カイ 2 乗値と、決定した。

Step3: 異常検知

実証試験の監視データの正常と異常のデータ群を対象として、訓練データによるパラメータチューニングしたモデルを用い、Step1～2 を経過期間とともに、解析区間を移動しながら繰り返し、相関の崩れ、つまり、バッテリーの異常を監視し、変動する監視データから異常を検出した。

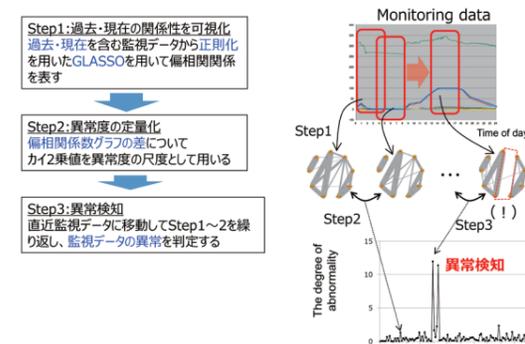


Fig. 6 Outline of anomaly detection method and procedure of making anomaly detection model

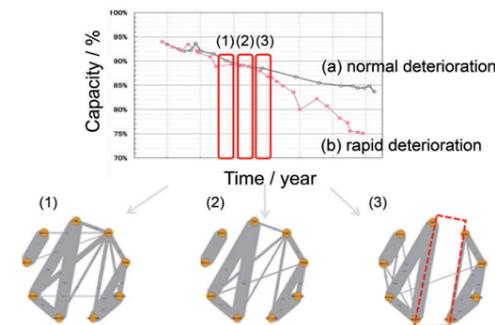


Fig. 7 Discharge capacity behavior of (a) normal deterioration and (b) rapid deterioration. And relationship behavior between (b) monitoring data

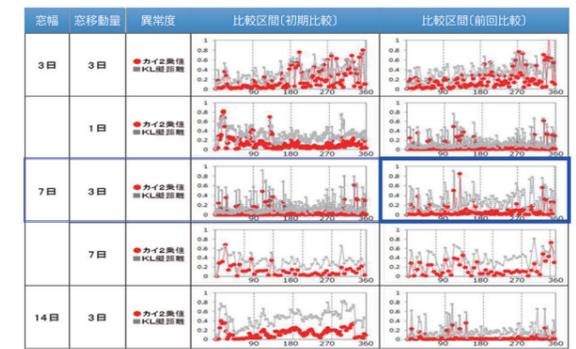
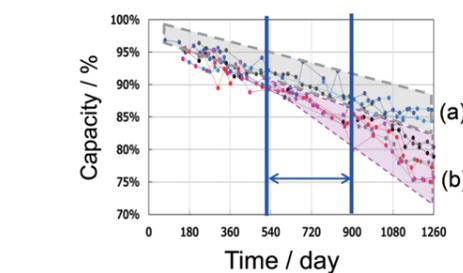


Fig. 8 Summary of tuning quantification parameters

6. モデル検証

実証試験の監視データを用いたモデル検証において、定期的に取り得た容量測定の結果をもとに、容量の急劣化が認められない正常データと、容量の急劣化が認められた異常データのテストデータを抽出して、訓練データによりモデル化した解析を行った。解析期間を 540～900 日とし、その解析結果を Fig. 9 に示す。予め容量測定により約 700 日近傍より容量の急劣化を示すバッテリーにおいて、監視データでも同タイミングで異常度が極端に大きな値を示し、監視データのみで、訓練データとは異なるテストデータでも、容量の急劣化を検知することができた。

7. まとめ

本稿では、経年劣化する性質を持つバッテリー容量の急劣化の検知という問題に対し、機械学習手法による

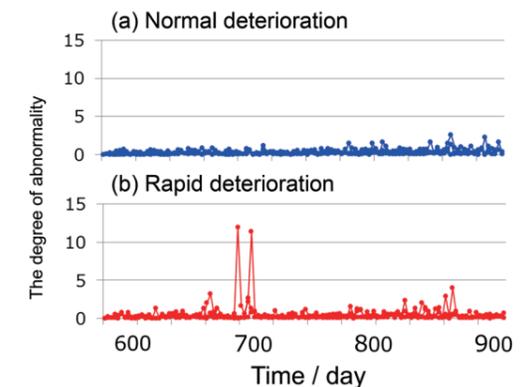


Fig. 9 The behavior of abnormality degree from 540 to 900 day; (a) normal deterioration and (b) rapid deterioration

相関解析を適用した。バッテリーの監視データのように、変数間に強い相関を含んでいる場合でも、監視データ間の関係性に着目し、L1 正則化を活用したグラフィカルラスー（GLASSO）により異常度を定量化することができた。これにより、ユーザ負荷の高い定期的な容量測定に頼らない、バッテリー監視データのみから、電池容量の急劣化を異常として検知することができた。

実装に向けては、モデルチューニング精度の向上や簡素化、異常度判定の閾値設定、他のバッテリー系への適用などの課題はあるものの、今後のビッグデータ活用時代には、本稿のようなバッテリー監視データの解析技術の役割は重要となると考えている。

また、デンソーでは、その他にも SOH 診断や劣化予測診断などのバッテリー診断関連の技術開発を進めており、エネルギーマネジメントや熱マネジメントによるバッテリー使いこなしや、リユース活用やバッテリー運用サービスによるバッテリー使いきりを通じて、環境問題とエネルギー問題に貢献していく。

参考文献

- 1) Dipti Kamath, Economic and Environmental Feasibility of Second-Life Lithium-Ion Batteries as Fast-Charging Energy Storage, Environ. Sci. Technol. 2020, 54, 11, 6878–6887
- 2) World Economic Forum, A Vision for a Sustainable Battery Value Chain in 2030, Insight Report, 2019, http://www3.weforum.org/docs/WEF_A_Vision_for_a_Sustainable_Battery_Value_Chain_in_2030_Report.pdf
- 3) HILL N, Circular Economy Perspectives for the Management of Batteries used in Electric Vehicles, Final Report for the European Commission, Joint Research Centre, 2019, ISBN 978-92-76-10937-2ISBN, https://publications.jrc.ec.europa.eu/repository/bitstream/JRC117790/jrc117790_jrc_circular_econ_for_ev_batteries_ricardo2019_final_report_pubsy_online.pdf
- 4) 金森, デンソーテクニカルレビュー Vol.16, マイクログリッドにおける蓄電池応用システムの開発, <https://www.denso.com/jp/ja/-/media/global/business/innovation/review/16/16-doc-15-ja.pdf>
- 5) 山田, デンソーテクニカルレビュー Vol.22, ISS システムとマイクログリッドの蓄電技術, <https://www.denso.com/jp/ja/-/media/global/business/innovation/review/22/22-doc-paper-06-ja.pdf>

著者



吉田 周平
よしだ しゅうへい

環境ニュートラルシステム開発部
博士（工学）
電源システム関連の基盤技術研究・開発に従事



山本 信雄
やまもと のぶお

環境ニュートラルシステム開発部
電源システム関連の基盤技術研究・開発に従事



菅家 智子
かんげ ともこ

品質管理部
SQC・機械学習推進, 人材育成に従事