

電池監視データを活用した機械学習による 電池劣化要因解析技術

Battery Degradation Factor Analysis Technology by Machine Learning Using Battery Monitoring Data

草野 賢和
Yoshikazu KUSANO

鈴木 彰悟
Shogo SUZUKI

山本 信雄
Nobuo YAMAMOTO

柴田 大輔
Daisuke SHIBATA

In order to realize carbon neutrality there is a growing need to improve the reuse rate of batteries. This requires very accurate diagnosis results of the remaining battery life. Since there are multiple degradation mechanisms in batteries, we must understand their main causes to accurately diagnose the remaining life of each battery. We applied logistic regression to develop a technique to extract readable features for degradation factors from battery monitoring time-series data and to analyze the main causes of degradation.

Key words :

Li-ion battery, battery diagnosis, battery degradation factor analysis, machine learning, logistic regression

1. 緒言

近年、カーボンニュートラルの実現を目指して、電動車の普及が進んでおり、電動車のキーコンポーネントである電池の需要が増大している。また、自動車以外の用途においては、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いることから、再生可能エネルギーの変動吸収の用途としても電池は期待されている。このような電池の需要増大に対して、電池材料の資源枯渇や廃棄電池の処分が社会的な問題として懸念されており、電池を有効活用する仕組みが求められている。

その中で車載用電池は、車両としての一次利用を終えた後も、中にはまだ十分に利用できる電池も含まれている。そのため、使用済みの車載用電池を回収・交換・修理し、定置用電池として、二次利用するリユースが求められている。リユースでは用途に応じて求められ

る電池性能が異なるため、使用済み電池を用途に応じて選別する工程が必要である。そのため、使用済みの車載電池を適切に二次利用するためには、電池の余寿命を高精度に推定する技術が必須となると考えている。

そこで、本稿では、電池診断技術の一つとして、電池で常時取得されている監視データを活用し、機械学習手法を用いた電池劣化要因解析技術を開発したので紹介する。

2. 電池劣化の主要因解析技術

電池特性は、使われ方によって劣化度の推移が異なるという特徴をもつ。また、電池は、SEI (Solid Electrolyte interface) 被膜成長、電極や粒子の破壊、Li金属の析出といった、複数の劣化メカニズムが存在することが知られている。

そのため、電池は、使われ方によって劣化メカニズ

ムが異なり劣化度がばらつくと考えられ、将来の余寿命を高精度に推定するには、劣化メカニズムの主要因の把握が必要である。複数存在する劣化メカニズムから主要因を解析する手法としては、破壊分析（電池を解体し、電池の正極・負極・電解液等にそれぞれ分離し、分析する手法）が用いられるが、分析した電池は二次利用することはできない。また、非破壊分析としては、交流インピーダンス法による電気化学評価があるが、測定装置が高価であるため、リユースに向けた電池選別の現場に展開するには課題がある。



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

一方、電池以外の金融、機械工学の分野において、時系列データに対して機械学習手法を適用して要因解析した事例が報告されている。そこで、電池の使い方データ、つまり、常時取得している電池監視データ（時系列）に対して機械学習を活用することで、非破壊かつ安価に、要因解析できる可能性があると考えた。

3. 解析に使用するデータと要因解析の方針

3.1 解析に使用するデータ

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、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。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を使用した際に取得した電池データを活用し、電池の劣化要因解析技術の開発を行った。

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。

このバッテリーシステムは、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、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。このような手法で取得したデータとしては、定期的な容量実測データ（Fig. 2）と装置稼働中に常時センシングされている電池監視データ（Fig. 3）がある。電池の定期的な容量実測データは、実証目的で取得したデータであり、実運用では必ずしも取得できると限らない。そのため、解析に使用しないものとする。ただし、二次利用先の要求性能に対して、各電池が利用可（青色）、利用不可であったか（赤色）の結果は把握できているため、本結果は解析に使用する。装置稼働中の電池監視データは、電池制御をおこなうために実運用でも取得されるデータである。そのため、本解析に使用する。

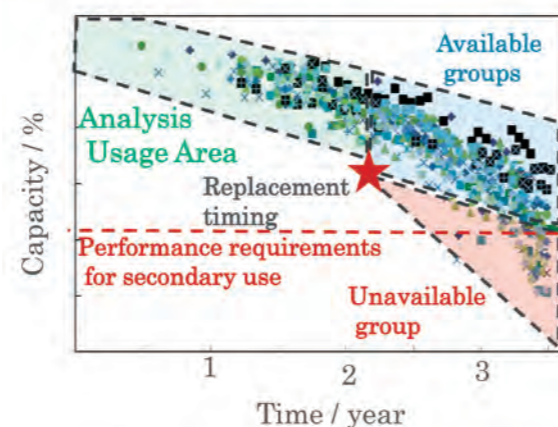


Fig. 2 Actual measured data of battery capacity

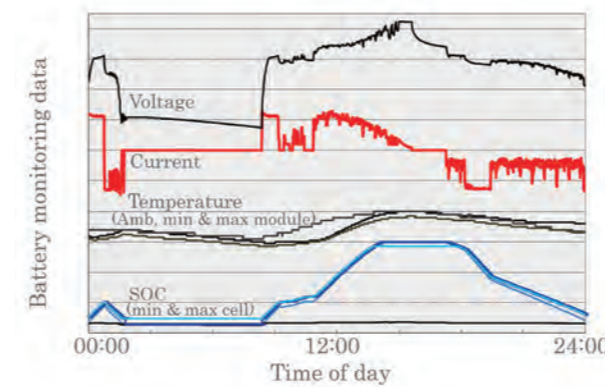


Fig. 3 Battery Monitoring data

3.2 要因解析技術の方針

本稿では、実運用に展開可能な技術とするため、要因解析技術の目標を「電池監視データのみを使用して、複数存在する劣化メカニズムから、特性劣化させる劣化メカニズムの主要因を解析できること」と設定した。また、交換時に劣化メカニズムの主要因を解析する必要があるため、「交換タイミング以前の電池監視データから解析できること」、解析結果の妥当性を確認するため、「可読性のある特徴量を作成し、その寄与度が定量化できること」を解析の要求仕様として設定した。

4. 目的変数と説明変数の設定

目的変数は、交換タイミングにおいて電池が利用可能・不可能の 2 値で設定する。説明変数は、電池監視データを用いて設定する。電池監視データは、(1) 時系列データであり、装置稼働中は値が変動している、(2) 複数の監視項目がある、という特徴がある。そのため、生データのままでデータの特徴がつかみづらい。そのため、時系列データから様々な波形情報を機械的に特徴抽出した場合、劣化要因と特徴量の紐づけが困難となる可能性があった。そこで、電池監視の時系列データを用いて可読性のある特徴量を作成するため、以下の Step を特徴量作成の方針とした。

- Step1：時系列データから機械的に特徴量を抽出してモデル化し、糸口を掴む
- Step2：糸口に基づき、電池固有技術で特徴量の候補を可視化し、考察する
- Step3：可読性のある特徴量を再作成する

5. 特徴量作成

Step1：機械的な特徴量抽出による糸口の取得

Step1-1：機械的な特徴量抽出と解析手法

可読性のある特徴量を作成するため、電池監視データの時系列波形から機械的に特徴量を抽出し、特徴量作成の糸口を掴む。Table 1 に糸口を掴むための解析条件をまとめる。

Table 1 Analysis conditions to get a clue

サンプル数	N=30(全て訓練データに使用)
目的変数	利用可:0、利用不可:1
説明変数	時系列データから自動抽出した特徴量:合計468変数 ※時系列データの各変数に対して、 交換タイミングから4か月前の1か月の固定時間長で抽出し、 各固定時間長に「TSFRESH」を適用して特徴抽出
解析手法	手法:ロジスティック回帰 ・Elastic Netによる正則化回帰 ・L1正則化の割合:0.23 ・Leave-one-out交差検証、 one standard error ruleで罰則値を設定

また、説明変数の設定は以下の手順で行った。①交換タイミング（現時点）から4か月前までの各電池の監視データを1か月の固定時間長（窓）で切り出す、②各変数の固定時間長の時系列データに対して特徴抽出する、③抽出された特徴量を説明変数として設定する（Fig. 4）。

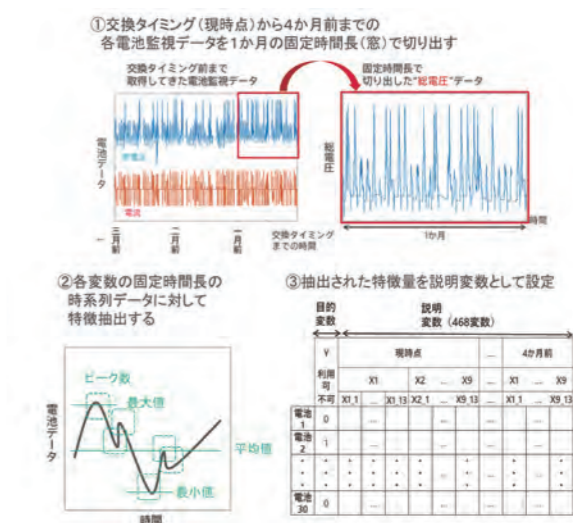


Fig. 4 Flow of setting explanatory variables in mechanical analysis

なお、時系列波形から様々な特徴量を機械的に抽出する手法として、Python のモジュール「tsfresh」を採用した。Table 2 に、「tsfresh」で時系列から抽出した

特徴量をまとめる。

Table 2 List of feature quantities extracted by tsfresh

変数名	内容
X1	mean abs change 時系列値間の絶対差の平均
X2	first location of max 最大値の最初の位置
X3	first location of min 最小値の最初の位置
X4	variance 分散
X5	variance coefficient 分散係数
X6	number peak ピーク数
X7	skewness サンプル歪度
X8	ratio beyond 2sigma 平均から2σを越える値の比率
X9	ratio beyond 3sigma 平均から3σを越える値の比率
X10	mean 平均値
X11	median 中央値
X12	max 最大値
X13	min 最小値

抽出した特徴量の項目数は、サンプル数に対して高次元である、つまり、疎なデータ構造であるため、Elastic Netによる正則化回帰を実施した。

Step1-2: 解析結果による糸口の取得

Fig. 5にElastic Netによる正則化回帰の結果について、温度変数に関する特徴量の選択結果を示す。




Fig. 5 Selection result of features on temperature variables

交換タイミングの1カ月前だけでなく、2, 3カ月前の時系列データから抽出した特徴量が選択されていることを確認した。ゆえに、温度変数に関しては、「過去の情報が必要ではないか」という糸口を掴んだ。

また、Fig. 6にElastic Netによる正則化回帰の結果について、SOC変数に関する特徴量の選択結果を示す。

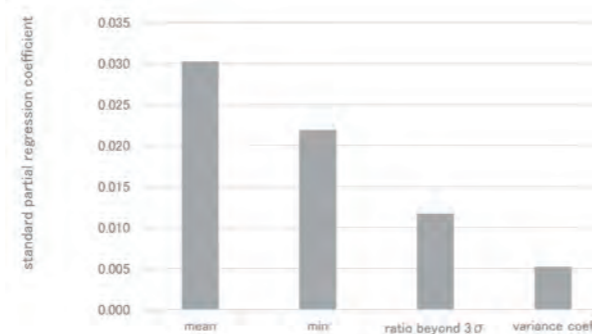


Fig. 6 Selection result of features on SOC variables

平均、最小値、3σ超過回数の特徴量が選択されていることを確認した。ゆえに、SOC変数に関しては、「振幅・範囲」の情報が必要ではないかという糸口を掴んだ。

以上より、①温度変数に関しては「過去」の情報、②SOC変数に関しては「振幅・範囲」の情報が必要ではないかという糸口を掴んだ。

Step2: 固有技術での可視化

Step1で掴んだ糸口に基づいて固有技術の知見で可視化し、特徴量に必要な情報を抽出する。温度変数に関する劣化の固有技術の知見としては、保存劣化に関して「過去」情報を「積算」情報として定量化されることが多い。そのため、温度に関するデータは、積算頻度データとして、表現することを考えた。

Fig. 7に「積算」情報を温度-SOC頻度としてヒートマップで定量化し、利用可・利用不可電池の群間で比較した結果を示す。

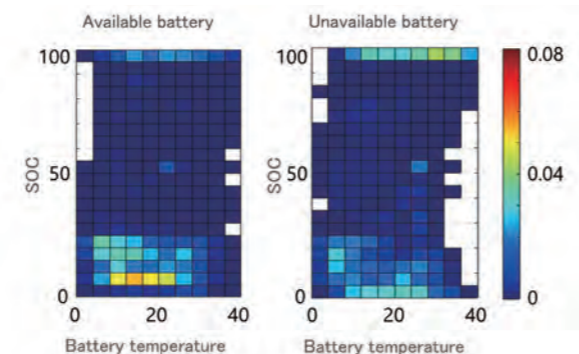


Fig. 7 Comparison "accumulated" information between available and unavailable groups

利用可の電池と利用不可の電池は、使用されている領域に差異があることが確認できる。Fig. 8に「積算」情報を利用不可の電池の群内で比較した結果を示す。

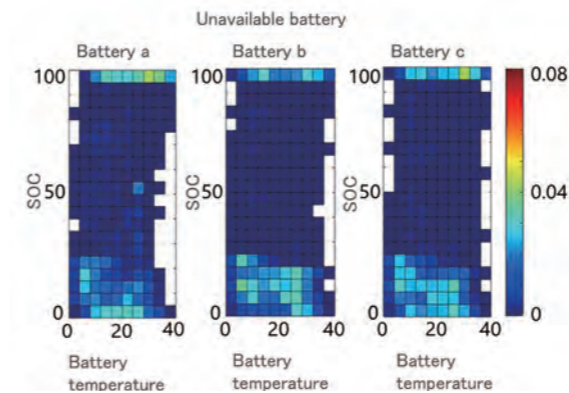


Fig. 8 Comparison "accumulated" information in unavailable groups

利用不可の電池の群内では、多少のバラツキが確認できるものの、使用されている領域の傾向が近いことが確認できた。

また、SOC変数に関する劣化の固有技術の知見としては、充放電(サイクル)劣化は、「振幅・範囲」を「変動」情報として定量化されることが多い。そのため、SOCに関するデータは、SOC変動の頻度データとして、表現することを考えた。

Fig. 9に、「変動」情報をSOCのサイクルカウントとしてヒートマップで定量化し、利用可・利用不可の電池の群間で比較した結果を示す。

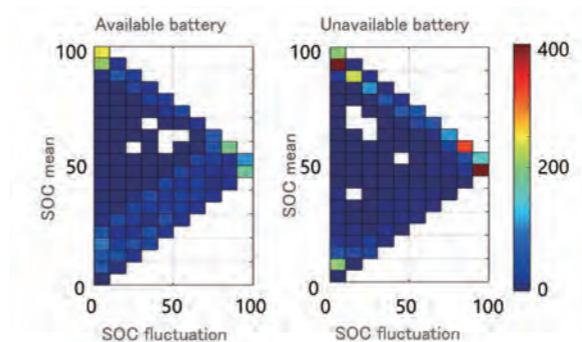


Fig. 9 Comparison "fluctuating" information between available and unavailable groups

利用可の電池と利用不可の電池を比較すると、それぞれ高頻度で使用されている変動幅、変動中心の領域に差異があることが確認できる。Fig. 10に「変動」情報を利用不可の電池の群内で比較した結果を示す。

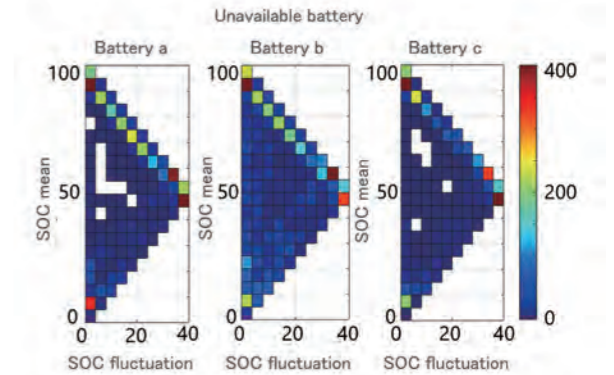


Fig. 10 Comparison "fluctuating" information in unavailable groups

利用不可の電池は、温度変数の場合と同様に多少のバラツキが確認できるものの、使用されている変動幅、変動中心の領域の傾向が近いことが確認できた。

以上をまとめると、温度変数の「積算」、SOC変数の「変動」情報は、群間では差異があり、群内では傾向が近いことが確認されたため、特徴量に必要な情報であると考えた。

Step3: 特徴量の再作成

Step2の結果を含め、掴んだ糸口と固有技術を紐づけることで、可読性のある特徴量を再作成する。劣化メカニズムに対する環境因子と糸口を基に、電池監視データを加工して可読性のある特徴量を再作成した(Table 3)。

Table 3 Summary of recreated feature quantities

劣化メカニズム	環境因子	糸口	特徴量表現	変数の数
電極・粒子破壊	SOC	変動	SOC変動表現の特徴量	200
SEI被膜成長	温度	積算	温度-SOC積算表現の特徴量	400
	SOC	積算	温度-SOC積算表現の特徴量	400
Li析出	温度	積算	温度-電流積算表現の特徴量	100
	電流値	積算	温度-電流積算表現の特徴量	100

6. モデル作成と効果検証

6.1 モデリング

再作成した可読性のある特徴量と充・放電積算量を説明変数とした。モデルの解析条件をTable 4にまとめる。

Table 4 Analysis conditions for model building

サンプル数	N=30(全て訓練データに使用)
目的変数	利用可:0、利用不可:1
説明変数	再作成した特徴量+充・放電積算量:合計702変数
解析手法	手法:ロジスティック回帰 ・Elastic Netによる正則化回帰 L1正則化の割合:0.5 ・Leave-one-out交差検証 one standard error ruleで罰則値を設定

糸口をつかむための解析時と同様に、サンプル数に対して説明変数の数が高次元であるという疎なデータ構造であるため、Elastic Netによる正則化回帰を実施する。

最適な正則化の罰則値を設定するため、Leave-one-out 交差検証で評価した結果を Fig. 11 に示す。

また、本解析の罰則の設定方針として、one standard error rule (1se ルール) で設定した。

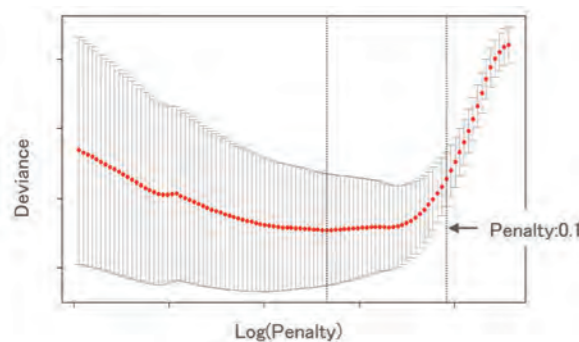


Fig. 11 Evaluation in cross-validation

変数選択の結果、702 変数から 10 変数に削減されていることを確認した。

訓練データを使用し、作成したモデルの性能を ROC 曲線で評価した結果を Fig. 12 に示す。

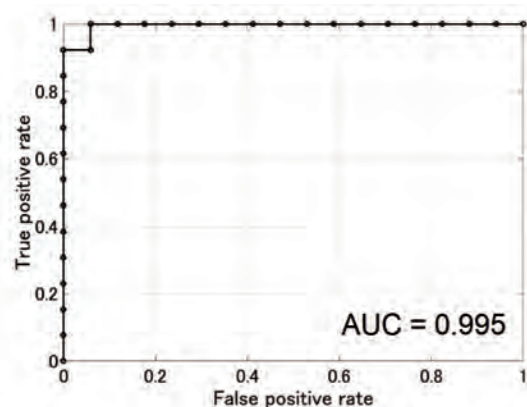


Fig. 12 Confirmation of model performance by ROC curve

出力された ROC 曲線の AUC を算出した結果 0.995 である事を確認した。

以上より、「説明変数の数がサンプル数の 1/3」「AUC が 0.9 以上」であることから、過学習していない、高精度なモデルが作成できたと判断した。

7. 固有技術による考察

Fig. 13 に前節で作成したモデルにおいて、目的変数に対する説明変数の寄与度を表す標準偏回帰係数の結果を示す。




Fig. 13 standard partial regression coefficient of the model

寄与度が大きかった因子は、「温度-SOC 積算表現の特徴量」「SOC 変動情報の特徴量」であった。以上の結果から、解析対象の電池について劣化メカニズムの主要因は、「SEI 被膜成長」と「電極・粒子破壊」であることが示唆される。

次に、モデルの出力結果の妥当性を判断するため、固有技術との整合を確認する。

今回、寄与度が大きいと出力された「温度-SOC 積算表現の特徴量」「SOC 変動情報の特徴量」の因子は、固有技術で既知とされている劣化促進領域と一致することから、モデルの出力結果が固有技術と整合がとれることを確認できた。

8. まとめ

常時取得している電池監視の時系列データに対して機械学習を活用することで、劣化の主要因を解析する技術を開発した。

- ① 機械的解析によって特徴量を抽出しモデル化することで糸口を掴み、固有技術の知見を活用することで、交換タイミング前の電池監視データから可読性のある特徴量を作成できた。
- ② 作成した可読性の特徴量を説明変数とし、1se ルールの罰則のもと Elastic Net による正則化回帰を実施した結果、過学習していない、かつ高精度なモデルが作成できた。
- ③ 目的変数に対する説明変数の寄与度を検証し、本解析の対象電池の劣化主要因は「SEI 被膜成長」と「電極・粒子破壊」であることが示唆された。また、モデルの出力結果は固有技術と整合がとれていることを確認できた。

今後は、最適なモデルを探索するため、その他の機械学習手法の適用と、汎用性を高めるため、その他劣化メカニズムの特徴量化と他電池への適用を検討していく。


参考文献

- 1) J.Vetter(2005),「Ageing mechanisms in lithium-ion batteries」, Journal of Power Sources
- 2) Moneta(2012),「Causal Inference by Independent Component Analysis: Theory and Application」, Oxford Bulletin of Economics and Statistics
- 3) 下出ら (2019),「機械学習を活用したエンジン起動時振動のばらつき要因解析」, 自動車技術会論文集
- 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



草野 賢和
くさの よしかず
まちづくり企画室
電源システム関連の基盤技術開発に従事



鈴木 彰悟
すずき しょうご
まちづくり企画室
電源システム関連の基盤技術開発に従事



山本 信雄
やまもと のぶお
まちづくり企画室
電源システム関連のサービス企画に従事



柴田 大輔
しばた だいすけ
まちづくり企画室
電池 3R および BaaS 開発に従事

特
集