

人工知能を活用した蓄電池故障の 予兆検知技術の開発

Development of a predictive battery failure detection technology using artificial intelligence

山崎 佳代* 内堀 富勝** 松島 均**
伊藤 浩二*** 切通 恵介*** 横谷 直人***

Kayo Yamasaki Tomikatsu Uchihori Hitoshi Matsushima
Koji Ito Keisuke Kiritoshi Naoto Yokoya

Abstract

A method to predictively detect battery failures automatically has been developed. This has been achieved by using an AI (Artificial Intelligence) technology known as Autoencoder. This technology operates by constructing a model that compares operation data of a normal battery and the subject battery. However, there is need to appropriately reconstruct the AI comparison model by relearning or additional learning when there is normal change in battery characteristics due to battery aging or change in battery operation conditions.

A method to reconstruct comparison model by (1) extracting normal data from operation data of the subject battery and (2) setting a learning period equal to evaluation period has been developed.

Key words : battery, AI, autoencoder

1 はじめに

近年、リチウムイオン電池は、太陽光・風力発電などの再生可能エネルギー用途、電力設備や通信設備などのバックアップ用途、鉄道や船舶、無人搬送車などの移動体用途といった、さまざまな用途に利用されている。

これらの用途において、リチウムイオン電池を安心・安全に使用するため、経年劣化した蓄電池がシステムに必要な容量・出力などの要件を満たしているか、あと何年で蓄電池寿命によって交換が必要になるかを判定・予測、システムダウンの原因となる故障した蓄電池を予兆検知する劣化診断のニーズが高まっている。

従来、さまざまなリチウムイオン電池の劣化診断技術が報告されている^{1,2}。これらの技術は、いくつかの想定される劣化モードの特性データをあらかじめ取得しておき、蓄電池の稼働データから、数式モデルに基づいて劣化診断をおこなうものである。劣化診断対

* 産業電池電源事業部 システムエンジニアリング
本部 技術サービス部

** 産業電池電源事業部 電源システム生産本部
開発部

*** NTT コミュニケーションズ株式会社

象の蓄電池データは、想定内の劣化モードで正常に経年劣化した正常データであることを前提としている。もし、診断対象の蓄電池データに、故障またはその予兆のある蓄電池のデータ（外れ値）が含まれる場合、正常データとの識別をおこない、寿命（容量）マージンによって、正常にシステムが運用している状態で、それを早期に発見してシステムダウンを防ぐ必要があった。しかし、偶発的に発生する故障は、あらかじめ想定してデータを取得することがむずかしく、システムの運用条件によって変化する可能性がある判定しきい値の調整が困難であった。よって、正常な経年劣化のばらつきか故障かの解析は、人の手に頼らざるを得ないところもあった。

今後、大規模な蓄電池システムの導入が見込まれる中、取り扱うデータ量は膨大になる一方であり、蓄電池システムを健全に保持するための解析作業は、さらに困難を極めることとなる。これらの実現・効率化のため、遠隔監視システム³などで収集した蓄電池の稼働データから、人の手をかけずに、正常な経年劣化のばらつきか故障かを見分け、予兆検知する技術が求められている。

本研究では、その予兆検知を自動化・高精度化するため、人工知能（Artificial Intelligence：AI）を活用した蓄電池の故障の予兆検知技術の開発を目指した。その実現により、システム故障の未然防止、事前処置によるシステムダウンタイムの最小化などが期待される。さらに、AIが膨大なデータを解析することで、人による経験やスキルのばらつきも解消され、均一な解析が可能となる。

2 教師なし学習を用いたデータ分析

AIでは故障品の特徴を直接学習させるような教師あり学習の場合、十分な数のデータを学習データとして用意する必要がある。しかし、通常、蓄電池システムにおける蓄電池の故障の発生は極めて少なく、さらに、蓄電池は経年劣化や使用条件によって正常な特性が変化する。そのため、同一条件下における故障が発生したデータを学習データとして用意することはむずかしい。このため、データが持つ特徴を分析可能な、教師なし学習を用いて、蓄電池システムが稼働する際に得られる時系列データの特徴を分析し、正常な蓄電池と異なる挙動を示す蓄電池を特定することを試みた。

2.1 アルゴリズムの選択

AIにおける教師なし学習には、k-means、k-NN、PCA、Autoencoder（AE）といったさまざまな手法が存在するが、本研究では、次節で後述するAEを選定することとした。

2.2 Autoencoder（AE）とは

AEは、図1に示すようなニューラルネットワークを用いた次元圧縮手法の一つである。学習データを入力し、入力と出力の差が小さくなるように特徴抽出しモデルを作成する。この学習モデルに学習データと類似した特徴を持つデータをいれると入力と出力の差（再現誤差）が小さくなるが、一方、学習データと類似した特徴を持たないデータを入力すると再現誤差が大きくなる。この性質を用いて、正常な蓄電池の特徴をAEで学習したのち、検知対象であるそれぞれの蓄電池に対して再現誤差を計算する。再現誤差の大きい、すなわち、正常な蓄電池と類似した特徴を持たない蓄電池は、故障などの可能性があるものとして識別する。なお、AEを構成する際の各種パラメータ（時系列データを扱う際の窓幅や正規化方法、ニューラルネットワークの構造など）は、蓄電池特性や蓄電池システムの特徴を考慮し、最適なパラメータを選定した。

2.3 階層クラスタ分析を用いた故障の予兆を示す蓄電池の自動分類

AEを用いて故障の予兆を捉えるための良い特徴が再現誤差として得られたとしても、蓄電池の経年劣化や使用条件の変化にともない、正常状態を含めた蓄電池の挙動が変化するため、再現誤差の値や時系列の推

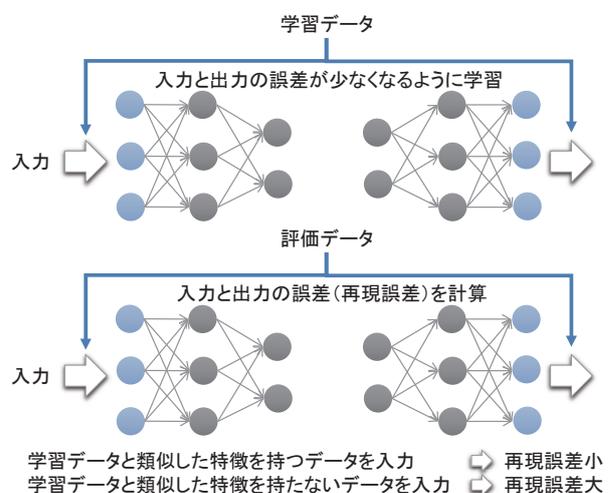


図1 Autoencoder
Fig.1 Autoencoder.

移も時々刻々と変化する。そのため、評価対象期間において、正常な蓄電池の再現誤差との傾向の違いが自動で判定できなければ、実用に適さない。このため、階層クラスタ分析を用いて、各評価期間における正常な蓄電池と故障の予兆を示す蓄電池を、再現誤差の時系列データから分類することを試みた。

階層クラスタ分析とは、対象となる時系列データの任意の組み合わせのうち、もっとも距離が近い組み合わせから順にクラスタを構成していく方法であり、図2に示すように、クラスタの構成を樹形図（デンドログラム）で示すことができる。距離の計算方法として Euclid Distance, Shape Based Distance, KL divergence を比較し、精度、計算速度の観点から Euclid Distance を選定した。本技術では、クラスタ間距離が一定のしきい値を上回り、かつクラスタに属する蓄電池が少ない場合、その蓄電池がほかの蓄電池と異なる特徴を有し、故障の予兆を示す蓄電池である可能性があるものとして分類をおこなった。

3 正常データを用いた AE による故障の検知

3.1 試験方法 1

通常、蓄電池システムにおける蓄電池の故障の発生は極めて少ないため、本試験では、当社内に設けている電力貯蔵装置 (Energy Storage System : ESS)⁴ に、人為的に正常な蓄電池とは異なる特性データを示す仕

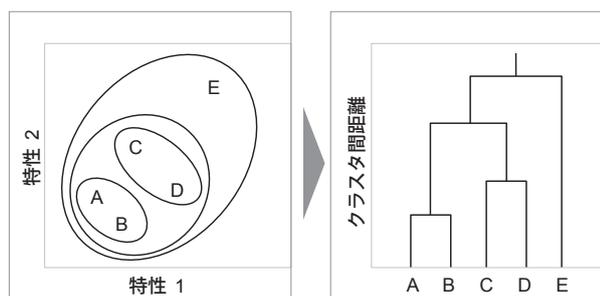


図2 階層クラスタ分析とデンドログラム
Fig.2 Hierarchical cluster analysis and dendrogram.

表2 AEの学習データおよび評価データ(1)
Table 2 Training data and evaluation data of AE (1).

	学習データ		評価データ	
	対象期間	対象データ	対象期間	対象データ
条件 1	4月上旬	すべての既設モジュール	4月中旬～7月下旬	すべての電池モジュール
条件 2	4月上旬	すべての既設モジュール	4月中旬～7月下旬 (7月の学習期間除く)	すべての電池モジュール
	7月(2週間分)	一部の既設モジュール		

掛けを施した蓄電池を組み込み、評価をおこなった。

試験に用いた ESS は、図3に示すように、電池セルが12セル直列された電池モジュールが12直列、これが11並列された構成である。以降、電池モジュールが12直列されたグループをバンクとし、各バンクをB1～B12 (B6は対象外)、バンク内のモジュールをM1～M12とあらわす。

ESSに組み込んだ仕掛けを施した試験電池モジュールを表1に、AEの学習および評価データを表2に示す。表1に示す劣化モジュールは、既設の正常モジュールの電池容量が45 Ahであるのに対して、41 Ahにさらに劣化が進行した電池セルに置き換えた電池モジュールであり、蓄電池システム内に経年劣化の度合いが異なる電池モジュールが混在した状態を模擬

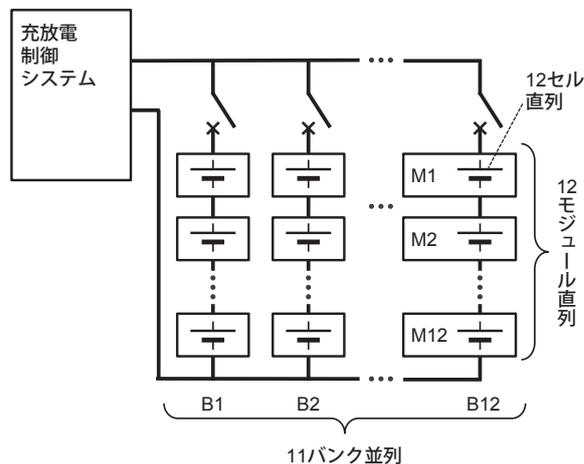


図3 試験に用いた ESS の構成
Fig.3 Configuration of ESS used for the test.

表1 試験電池モジュール(1)
Table 1 Test battery modules (1).

No.	試験電池モジュール	条件
B3M11	劣化モジュール	経年劣化した電池セルを使用したモジュール
B9M11	バランスなしモジュール	バランスを取り外したモジュール
B11M11	抵抗付きモジュール	放電抵抗(抵抗値小)を1セルに取り付けたモジュール
B12M11	新品モジュール	新品の電池セルを使用したモジュール

した。また、電池モジュールには、セルモニタリングユニット (Cell Monitoring Unit : CMU) が内蔵されており、各電池セルの電圧を均等にするためのバランスが設けられている。バランスなしモジュールは、このバランスを取り外したものであり、バランス故障を模擬した。抵抗付きモジュールは、電池モジュール内の1セルが常に放電されるように放電回路を接続したものであり、電池セルの内部短絡や自己放電が大きい場合を模擬した。その際、放電回路はバランスによるバランス機能を上回る抵抗値に設定した。新品モジュールは、経年劣化のない新品の電池セル (電池容量 47.5 Ah 以上) に置き換えた電池モジュールである。

AE による判定モデルの構築および評価において、表 2 に示す条件 1 では、試験電池モジュール組み込み前の既設モジュールの稼働データ (正常データ) で学習し、試験電池モジュール組み込み後の稼働データを評価した。条件 2 では、仕掛けを施した試験電池モジュールのデータを含まない一部の正常バンクだけの 7 月の稼働データ (正常データ) で追加学習し、条件 1 と同様に試験電池モジュールを組み込み後の稼働データを評価した。

3.2 試験結果 1

条件 1 の結果を図 4 に示す。4~6 月は、B11 を除くすべての正常モジュールは、図 4 (a) に示す正常モジュールと同等であり再現誤差は小さい傾向であった。劣化モジュール (図 4 (b)), バランスなしモジュール (図 4 (c)), 抵抗付きモジュール (図 4 (d))

および新品モジュール (図 4 (f)) は正常モジュールと比較して、再現誤差が大きい傾向にあり、単純な再現誤差の絶対値の比較により、すべての試験電池モジュールを識別することができた。また、B11M11 を除くそのほかの B11 の正常モジュール (図 4 (e)) も、再現誤差が大きい傾向にあった。これは、通常、バランスにより、バンク内のすべてのセル電圧は一定となるように制御されるが、そのバランス能力を超える放電が放電付きモジュールで生じたことで、B11 全体でセル電圧のバランスが崩れてしまったためである。6 月中旬に抵抗付きモジュールに接続されている抵抗回路を開放したところ、6 月下旬の再現誤差が小さくなる傾向がみられた。一方で、7 月頃からは、正常モジュールも含め全体的に再現誤差が大きい結果となり、識別することができなかった。これは、夏場になって、電力ピークカットのために ESS の使用条件が判定モデルの構築時から変化したことが原因と考えられる。表 3 正常バンクの電圧範囲に示すとおり、7 月は学習期間の電圧範囲を超えて使用されていることから、4 月上旬に構築した判定モデルでは適しなくなったものと考えられる。そこで、使用条件が変化した場合にも対応するため、7 月の稼働データを追加学習し、判定モデルを再構築して評価をおこなった。

表 3 正常バンクの電圧範囲
Table 3 Voltage range of normal banks.

	4月上旬	5月中~6月中旬	7月
最高セル電圧 (V)	4.102	4.102	4.102
最低セル電圧 (V)	3.636	3.632	3.298

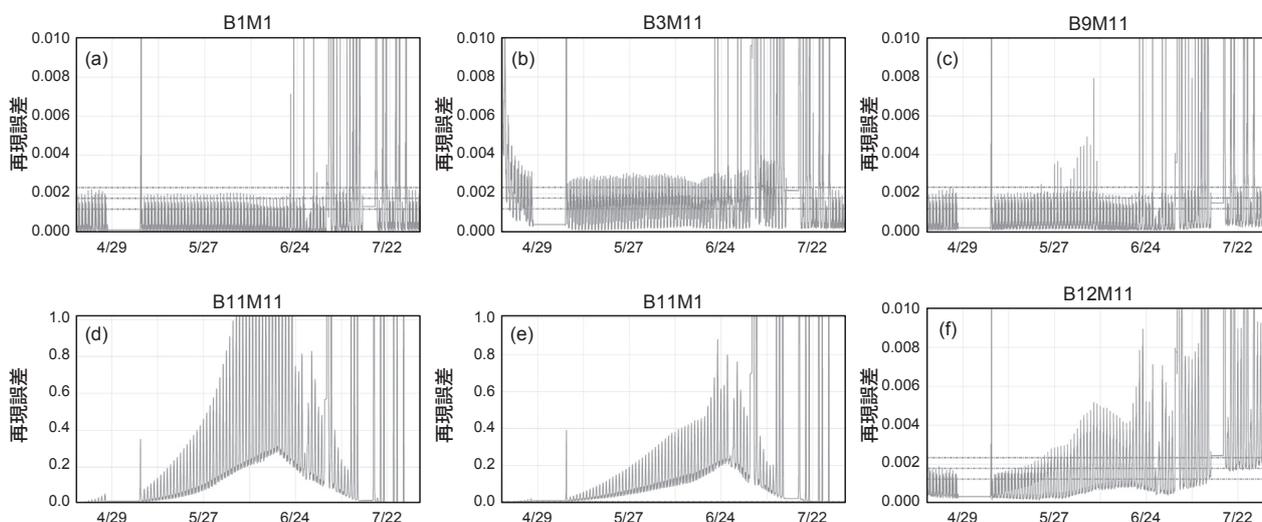


図 4 正常データを用いた AE による評価結果 (条件 1)
Fig.4 Evaluation result by AE using normal data (Term 1).

条件2の結果を図5に示す。図5より、使用条件が変化した7月の正常データを追加学習することで、7月以降の再現誤差の広がりがなくなった。それによって、劣化モジュール（図5 (b)）、抵抗付きモジュール（図5 (d)）および新品モジュール（図5 (f)）については識別可能な再現誤差は保持しつつ、7月以降に全体的に再現誤差が大きくなる現象が解消した。一方で、バラバラなしモジュール（図5 (c)）は、6月中旬頃にあらわれていた再現誤差の傾向がみられなくなった。この原因は、使用時期が異なる稼働データを追加学習したことにより、正常なデータの範囲が広がったことで、判定モデルの精度が若干低下したためではないかと推察する。

以上の結果より、正常な蓄電池を選定し、かつ、評価期間と同等の使用条件の稼働データを学習データとして用意することにより、AEを用いた判定モデルで故障の予兆を検知できることが確かめられた。しかしながら、本試験結果の評価は、再現誤差の絶対値を人為的に比較し、試験電池モジュールの識別をおこなっ

たものであり、実用化するためにはこれらを機械的に自動で分類することが必要とされる。

4 疑似的な正常データを用いたAEによる故障の検知

本技術で故障の予兆検知の自動化を実現するには、判定モデルを、正常な蓄電池の稼働データで学習させ、かつ、経年劣化や使用条件の変化に応じて、適宜、再構築する必要があると考えられる。そこで、つぎのような手法でこの課題の克服を試みた。

- ① 検知対象の蓄電池の稼働データから、疑似的な正常データを用意する。
- ② 学習期間と評価期間を同じとする。

さらに本試験では、AEによって得られた再現誤差の時系列データを階層クラスタ分析することにより、正常な蓄電池の再現誤差との傾向の違いを自動で判定することを試みた。

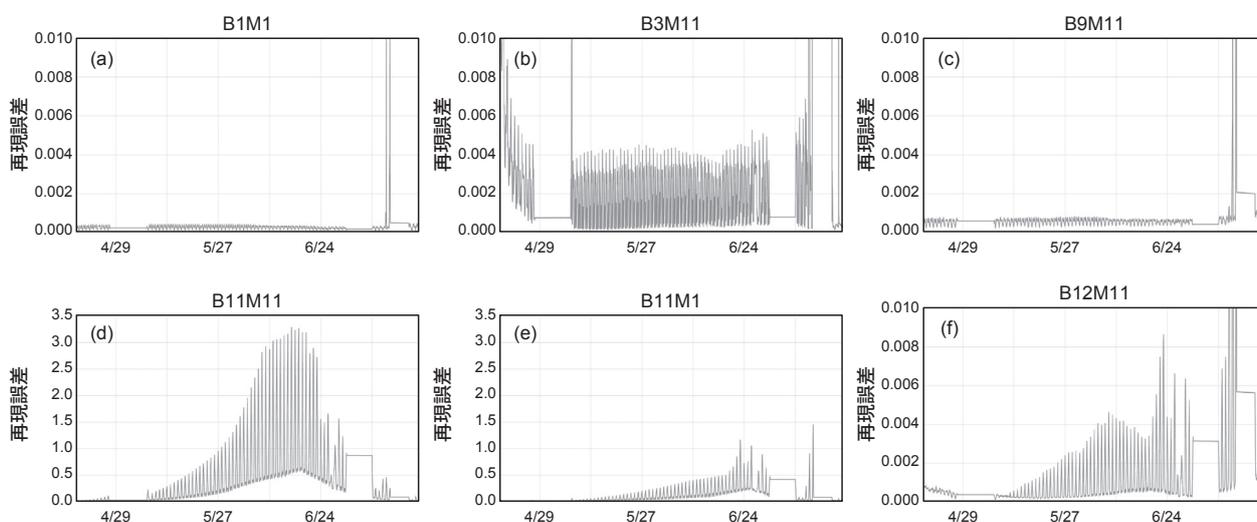


図5 正常データを用いたAEによる評価結果（条件2）
Fig.5 Evaluation result by AE using normal data (Term 2).

表4 試験電池モジュール(2)
Table 4 Test battery modules (2).

No.	試験電池モジュール	条件
B3M2	新品モジュール	新品の電池セルを使用したモジュール
B3M8	抵抗付きモジュール	放電抵抗（抵抗値大）を1セルに取り付けたモジュール
B9M5	バラバラなしモジュール	バラバラを取り外したモジュール
B9M11	4セル新品モジュール	12セル中4セルを新品にしたモジュール
B11M11	抵抗付きモジュール	放電抵抗（抵抗値小）を1セルに取り付け、一定期間後に放電回路を開放したモジュール
B12M5	8セル新品モジュール	12セル中8セルを新品にしたモジュール
B12M8	抵抗付きモジュール	放電抵抗（抵抗値中）を1セルに取り付けたモジュール

4.1 試験方法 2

試験方法 1 と同様に，ESS を用いて評価をおこなった．ESS に組み込んだ試験電池モジュールを表 4 に，AE の学習および評価データを表 5 に示す．

表 4 に示す B3M8 および B12M8 の抵抗付きモジュールは，試験方法 1 よりも抵抗値を大きくし，放電回路による放電量を少なくしたものであり，故障の度合いをより軽微にした．これらの抵抗付きモジュールが含まれた B3 および B12 は，試験電池モジュールが組み込まれてから約 2 か月後に電圧ばらつきがしきい値以上となり，警報が発報した．B9M11 の 4 セル新品モジュール，B12M5 の 8 セル新品モジュールは，電池モジュール内の 4 セルまたは 8 セルを新品の電池セルに置き換えたもので，電池モジュール内で経年劣化の度合いにばらつきが生じ

た状態を模擬した．

学習データは，試験電池モジュールを含むすべての稼働データを所定の分類方法で平均値をとることにより，疑似的な正常データを作成した．さらに，学習期間と評価期間を同じ期間とすることで，使用期間にともなう経年劣化による特性変化や，使用条件の違いによる学習期間と評価期間との差異の影響を除いた．条件 3 は試験電池モジュール組み込み後 1 週間を対象とし，条件 4 は ESS の使用頻度の少ない 1 週間を対象として，それぞれ評価をおこなった．

4.2 試験結果 2

条件 3 および条件 4 の結果を図 6～図 8 に示す．また，図 7 および図 8 でほかの電池モジュールとの類似度が低く，故障の予兆があると識別された電池モジュールを表 6 に示す．

表 5 AE の学習データおよび評価データ (2)
Table 5 Training data and evaluation data of AE (2).

	学習データ		評価データ	
	対象期間	対象データ	対象期間	対象データ
条件 3	10 月上旬 (1 週間)	すべての電池モジュール (疑似的な正常データ)	10 月上旬 (1 週間)	すべての電池モジュール
条件 4	10 月下旬 (1 週間)	すべての電池モジュール (疑似的な正常データ)	10 月下旬 (1 週間)	すべての電池モジュール

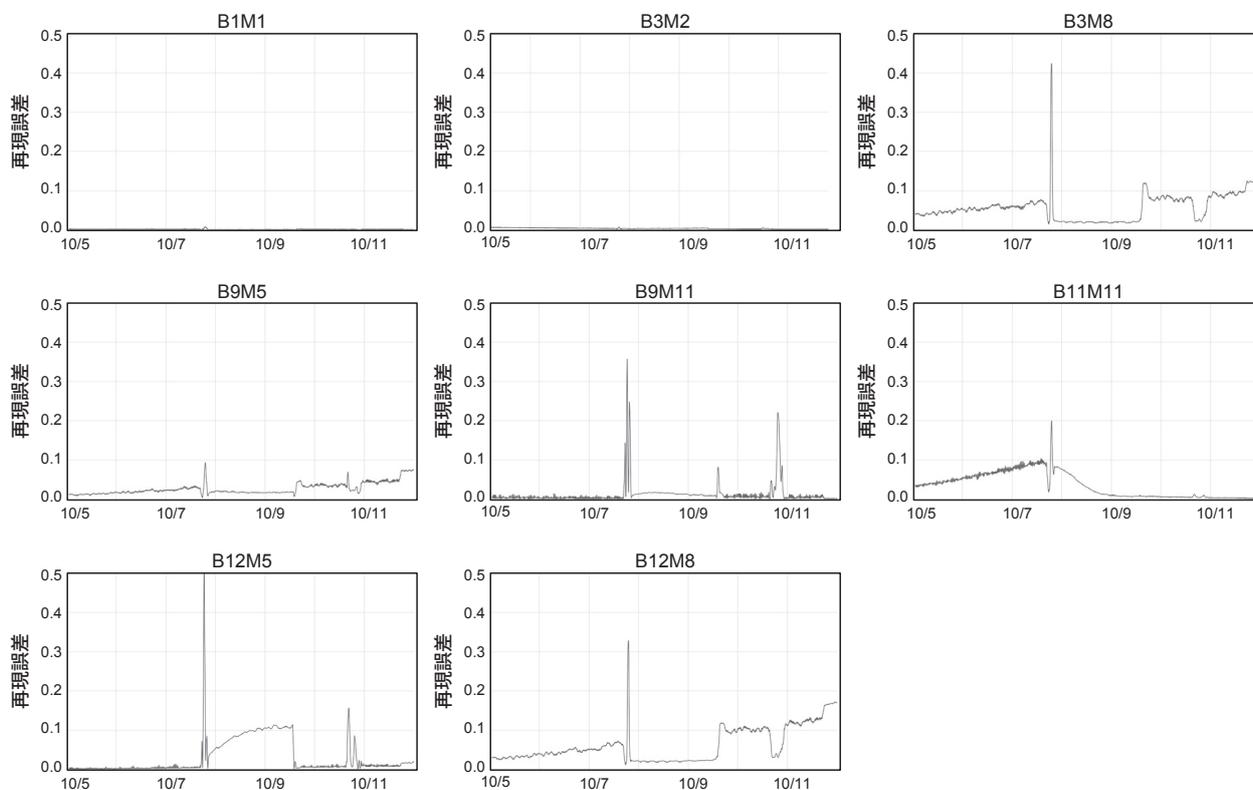


図 6 疑似的な正常データを用いた AE による評価結果 (条件 3)
Fig. 6 Evaluation result by AE using simulated normal data (Term 3).

すべての正常モジュールは、図6(a)に示す正常モジュールと同等であり再現誤差は小さい傾向であった。経年劣化の少ない新品モジュール(図6(b))は、正常モジュールと同等に再現誤差が小さい傾向であっ

た。また、図7より、すべての正常モジュールと新品モジュールは類似度の高いクラスタに属しており、正常な電池モジュールとして機械的に分類された。B3M8(図6(c))およびB12M8(図6(h))の抵抗

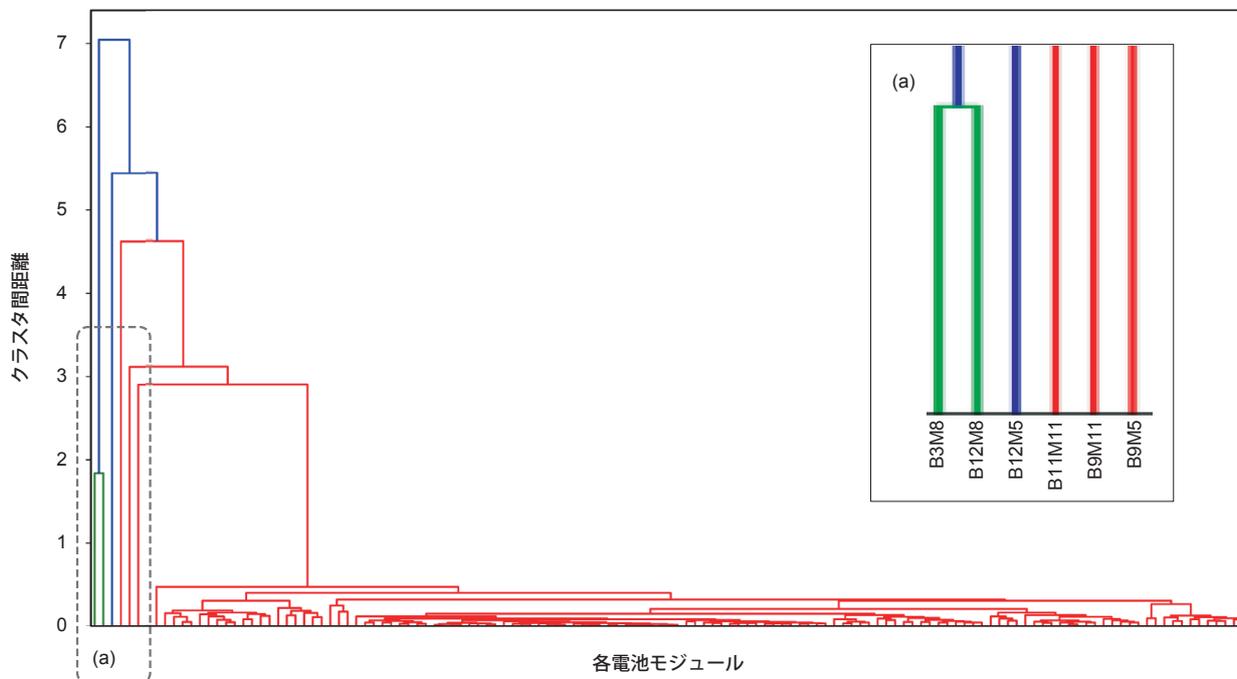


図7 階層クラスタ分析結果のデンドログラム(条件3)
Fig.7 Dendrogram of hierarchical cluster analysis results (Term 3).

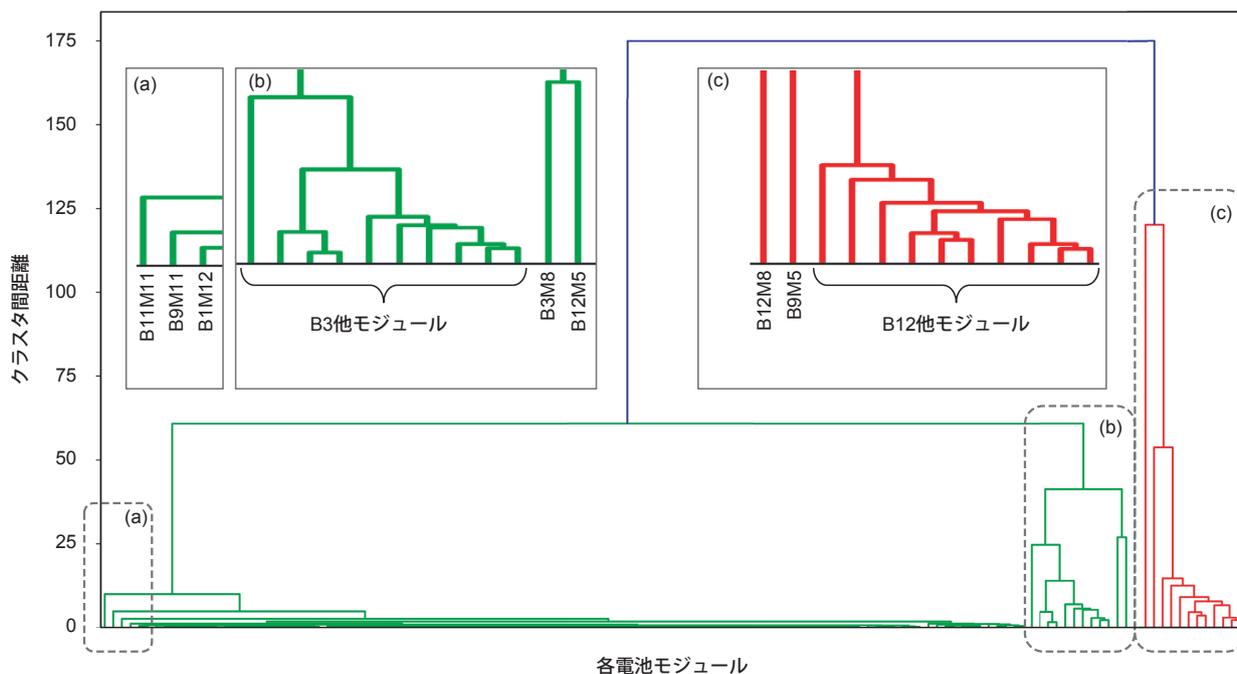


図8 階層クラスタ分析結果のデンドログラム(条件4)
Fig.8 Dendrogram of hierarchical cluster analysis results (Term 4).

表6 故障の予兆があると識別された電池モジュール
Table 6 Battery modules identified as having a sign fail-
ure.

No.	試験電池モジュール	識別 (あり：○/なし：-)	
		条件3	条件4
B1M12	- (仕掛けなし)	-	○
B3M8	抵抗付きモジュール	○	○
B3 その他	- (B3M8の影響あり)	-	○
B9M5	バランスなしモジュール	○	○
B9M11	4セル新品モジュール	○	○
B11M11	抵抗付きモジュール	○	○
B12M5	8セル新品モジュール	○	○
B12M8	抵抗付きモジュール	○	○
B12 その他	- (B12M8の影響あり)	-	○

付きモジュールは、正常モジュールと比較して、再現誤差が大きい傾向にあり、警報発報よりも2か月程度早く識別することができた。また、図7より、正常な電池モジュールとは異なる特徴を有すると分類され、かつ、B3M8およびB12M8は類似した故障の予兆があるものとして同じクラスタに分類された。バランスなしモジュール（図6(d)）も識別することができ、これは、条件1における試験結果1と比較して正常モジュールの再現誤差との差が大きい傾向にあった。これは、本手法で疑似的な正常データを学習データに使用したこと、および、学習期間と評価期間を同じにし、また、期間を1週間としたことにより、学習範囲が適正に制限され、判定モデルの精度が向上したものと考えられる。そのほかの試験電池モジュールも、再現誤差が大きい傾向にあり、階層クラスタ分析により故障の予兆があるものとして識別することができた。

使用条件の異なる条件4においても条件3と同様に、新品モジュールを除くすべての試験電池モジュールを識別することができた。また、抵抗付きモジュールの影響のあるB3およびB11の正常モジュールも故障の予兆があるものとして識別されたが、この理由は試験結果1と同様ではないかと考える。また、図8より、B3およびB11の正常モジュールは、バンクごとに類似度の高いクラスタとして機械的に分類することができた。一方、仕掛けを施していない正常モジュールであるB1M12が故障の予兆があるものとして識別された。これは、使用頻度が少なく、正常モジュールと試験電池モジュールの評価データの挙動の差がわずかであったことにより、誤検知したものと考えられる。

以上の結果、検知対象の蓄電池の稼働データから、仕掛けを施した試験電池モジュールのデータを除かずに、平均値によって作成した疑似的な正常データを学習データに使用する手法により、AEで故障を予兆することができた。また、学習期間と評価期間を同じとする手法により、蓄電池の劣化状態、使用条件によらず、故障を予兆することができた。これにより、判定モデルを構築するための特性データをあらかじめ取得する必要がなく、また、使用用途、故障モード（原因）、電池セルの型式などによらず本技術を適用できる可能性が示唆された。さらに、AEにより得られた再現誤差を階層クラスタ分析することにより、再現誤差の絶対値を人為的に比較することなく、故障の可能性が高いものを自動で抽出することができた。

5 まとめ

本技術は、蓄電池システムを健全に保持するために、AI技術の一つであるAEを用いた判定モデルによって故障を予兆検知することを実現したものである。また、本技術では、正常に経年劣化した特性データや、同一条件下における故障が発生したデータを学習データとして用意する必要がなく、検知対象の蓄電池の稼働データから学習データを抽出し、適宜、判定モデルを再構築する。

現在は小規模システムを対象にした試験で、判定モデルによる再現誤差の類似度が低いデータを故障の予兆があるものとして識別する機能にとどまっている。今後、検知された故障品の調査データを蓄積することで、故障モード（原因）も推定する機能を追加していき、世界中に点在して延べ容量でG(ギガ)Whを超える膨大な蓄電池に対して、低コストで効率よく予兆検知をおこなうシステム技術を確立し、さらに蓄電池システムの保守・保全の向上に役立たせていく。

参考文献

1. 河本真理子, 安富実希, 尾崎哲也, 人見周二, 稲益徳雄, 吉田浩明, *GS Yuasa Technical Report*, **11**(2), 1(2014)
2. *GS Yuasa Technical Report*, **15**(1), 29(2018)
3. *GS Yuasa Technical Report*, **16**(1), 45(2019)
4. 美馬正明, 電気評論, **661**, 38(2015)