

## 〈特集〉

# 環境システム設備診断へのビッグデータ解析の応用

鈴木 英明

(株)日立製作所 研究開発グループ 制御イノベーションセンター  
(〒319-1292 日立市大みか町7-1-1 E-mail: hideaki.suzuki.qr@hitachi.com)

### 概要

風力や太陽光などの再生可能エネルギーの活用は持続的な発展のために重要である。これらインフラ設備の効率的な運用のための設備診断について紹介する。近年、急速に注目されているIoTデータ・機械学習を活用したビッグデータ解析により、設備の計画外停止を防止するための状態監視保全が注目されるようになってきた。特に故障の予兆段階を捉える異常予兆検知は、設備に関わるライフサイクルコストの最適化に寄与できるため、実際の現場で活用され始めている。本稿では、機械学習による設備診断について風力発電の事例を用いて紹介する。

キーワード：風力発電，異常予兆検知，機械学習，状態監視保全

原稿受付 2019.1.18

EICA: 23(4) 36-39

## 1. はじめに

2015年11月のCOP21（国連気候変動枠組条約第21回締約国会議）にて、2020年以降の温暖化対策の国際枠組み「パリ協定」が正式に採択された。GDP1位のアメリカ合衆国が離脱を表明したものの、アメリカ合衆国に次ぐGDP2位の中国を含むG20の残り19か国は協定を履行することで合意している。近年の異常気象による災害などを考えても地球温暖化防止のための風力や太陽光などの再生可能エネルギーの活用は持続的な発展のためにも必須な施策である。

風力発電に注目すると、多少の変動はあるものの累積導入量は着実に増加しており、2011～2016年の5年間では年率15%の成長を続けている<sup>1)</sup>。これは再生可能エネルギーの約半分を占めており<sup>2)</sup>、今後もエネルギー供給における重要な位置を占めると考えられる。風力は、陸上以外にも洋上（着床式、浮体式）で発電が可能であり、環境省の「再生可能エネルギー導入ポテンシャルマップ（平成21年度）」<sup>3,4)</sup>を見ても周囲を海に囲まれる日本の沿岸に導入の可能性がある。英国では2018年9月に世界最大の風力発電所が完成し、イングランド北部とマン島の間のアイリッシュ海上で659 MWの発電能力で59万戸に電力を供給している。

洋上風力発電の魅力は、陸地に比べて風が強いことと、何よりも土地取得に関わる課題が解決しやすいことにある。国内では実証機が2機存在するのみで、正式導入の実績はないが、英国の例を見ても、英国同様に平地の少ない日本においては有望なりソースである。導入にあたっては、漁業や生態系への影響を考慮する

必要があるものの、データや情報などの開示を通じて「共生」の道を模索することが重要である。

国内における風力発電設備の導入コストは、耐震規制の強化や近年の資材・人件費の高騰の影響で上昇傾向にあるが、固定価格買取制度（FIT）の導入により、日本における風力発電の魅力が上がったため、世界的なタービンコストの下落の恩恵を日本も享受し始めていることがうかがえる。一方で運用コストについては、導入の進んでいるドイツと比較して約2倍となっており、中でも一般運転管理費が半分以上を占め、予定外の修理に起因する修繕費や保険費用なども3割近くを占める<sup>5)</sup>。規模を大きくするとともに、運用の効率化が重要である。

## 2. 状態監視保全と設備診断

### 2.1 状態監視と予防保全

風力発電を始めとしたインフラ設備の効率運用のためには、従来から実施されている定期保全に加えて、IoTデータを用いた状態監視保全を導入することが重要である。従来は、保全を必要としないメンテナンスフリーを志向する傾向にあったが、近年ではコストだけでなく環境負荷など設備のライフサイクル全体で最適化するLCA（ライフサイクル・アセスメント）という考え方が重要になってきている<sup>6)</sup>。状態監視保全により計画外停止の発生を最小化して設備の稼働率を向上させるとともに、大きな故障に至る前の軽微な異常の段階で予防保全することで、故障に伴う修理費用を最小化できる。

洋上風力発電は、海岸線から数十キロ離れたところにあり、加えて冬場は海が荒れるために現地での保全が容易にできる環境ではない。従って、より早い段階で異常を見つけるとともに、できるだけ定期保全に組み入れる形で計画的に予防保全を実施したいというニーズが高い。計画外停止を回避して保全コストを低減するというニーズは、洋上風力に限らず、様々なインフラ設備に言えることである。

## 2.2 設備診断と機械学習

近年、人工知能・機械学習の発展により、IoT データを活用したビッグデータ解析が実用フェーズに入っている<sup>7,8)</sup>。従来の監視は、主として閾値判定をベースとしたアラーム検知が中心であり、各種センサの計測値は収集されるものの、主としてコストの問題で、蓄積されることなくそのまま捨てられることが多かった。計測データとして収集してトレンド監視のような形で活用されることもあったが、多数ある設備の監視は依然としてアラームが起点となって、多数の計測値の解釈は人に依存した運用であった。機械学習を用いた状態監視は、このような人に依存したやり方ではなく、大量のデータと計算パワーを活用することで設備診断を自動化するものである。さらに、機械学習による設備診断は、方式によって多少異なるが、アラームのような故障検知が目的ではなく、その前兆である異常予兆を捉えることに重点を置く。これにより、設備が故障に至る前に、事前に手当をする予防保全に繋げることができる。

機械学習を応用した異常予兆検知は、**Fig. 1** のようなイメージで捉えることができる。様々な設備の IoT データは、各時刻の計測データを組みとすベクトルと解釈でき、これは多次元空間上の点を表している。従って、時系列データは各時刻の点群によって構成される分布と解釈できる。機械学習は、選択したアルゴリズム (学習器) を用いて、できるだけ元の分布との

誤差が最小化されるように、この多次元空間上の分布を再構成するものである。

学習器としては k-means, SVM, Random Forest, XG-boost など様々なものが活用できる<sup>9,10)</sup>。学習が正しく行われると、学習データとの再構成誤差は小さくなり、学習していないデータで元の分布から外れたデータとの再構成誤差は大きくなる。この学習結果 (以下、学習モデルと呼ぶ) との再構成誤差は、多次元空間における元の分布との距離と解釈して良く、これを 1 つの指標 (以降、異常度と呼ぶ) として状態監視を行うことが可能となる。

## 3. 実機データによる設備診断

### 3.1 設備診断の事例

**Fig. 2** に風力発電設備の異常予兆検知の事例を 3 つ示す。3 つの事例は、すべて異なる部位の故障である。いずれも異常度の推移と故障停止が発生したタイミングとの間に連関が見て取れるのが分かる。(a) の事例では、故障停止の約 5ヶ月前、(b) の事例では 1 年以上前、(c) の事例では約 1ヶ月前に異常予兆を捉えることができている。いずれも複数のデータ項目に基づいているため、個別のデータ項目で閾値判定するよりも異常度で判定する方が感度が良いと理解できる。(c) の事例では、わずかな温度変化を捉えられている。

事例の (b) (c) をみると、風車の稼働が止まっている期間があることが分かる。風車に限らず、設備機器は停止を含む様々な運転状態を持っている。空調機器であれば、ON・OFF だけでなく、暖房モードと冷房モードで運転そのものが変わる。加えて、設備の制御ロジックによって制御方法も変化する。このような様々な状態変化に追従するためには、設備の状態変化に対応する必要がある。機械学習には、**Fig. 3** に示すように、このような複数のデータ分布を学習する仕組みがあり、個々のデータ分布は部分空間と呼ばれる。部分空間は設備の状態に対応し、予兆検知ではこれらの部分空間を用いて、設備の状態変化を推定しながら各部分空間との距離 (異常度) を計算する。事例 (b) (c) では運転中と停止中で異なる部分空間が割り当てられており、それぞれの空間からの距離に応じて異常度が算出されている。

機械学習を用いた診断で重要となるのは、**Fig. 4** に示すように、その診断対象の部位あるいは故障モード (壊れ方・故障事象) ごとにデータ項目を選択する必要があることである。これは特徴選択と呼ばれる。データ項目が 10 や 20 であれば、そのまますべてのデータ項目を機械学習にかけてもよいが、これが数百とか数千・数万になるとすべての項目を入力することはできない。これは「次元の呪い」と呼ばれ、データ

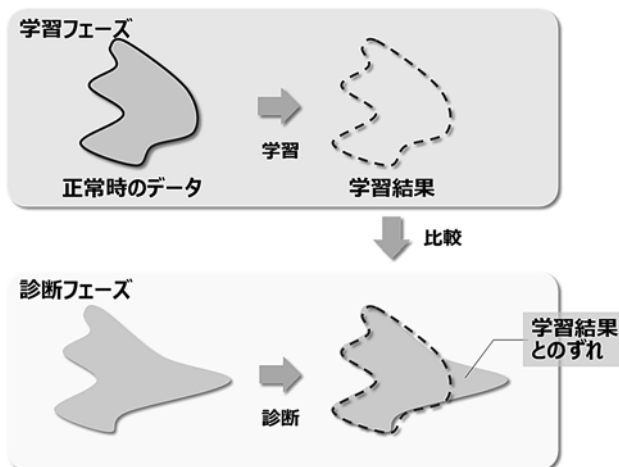


Fig. 1 Anomaly detection by machine learning

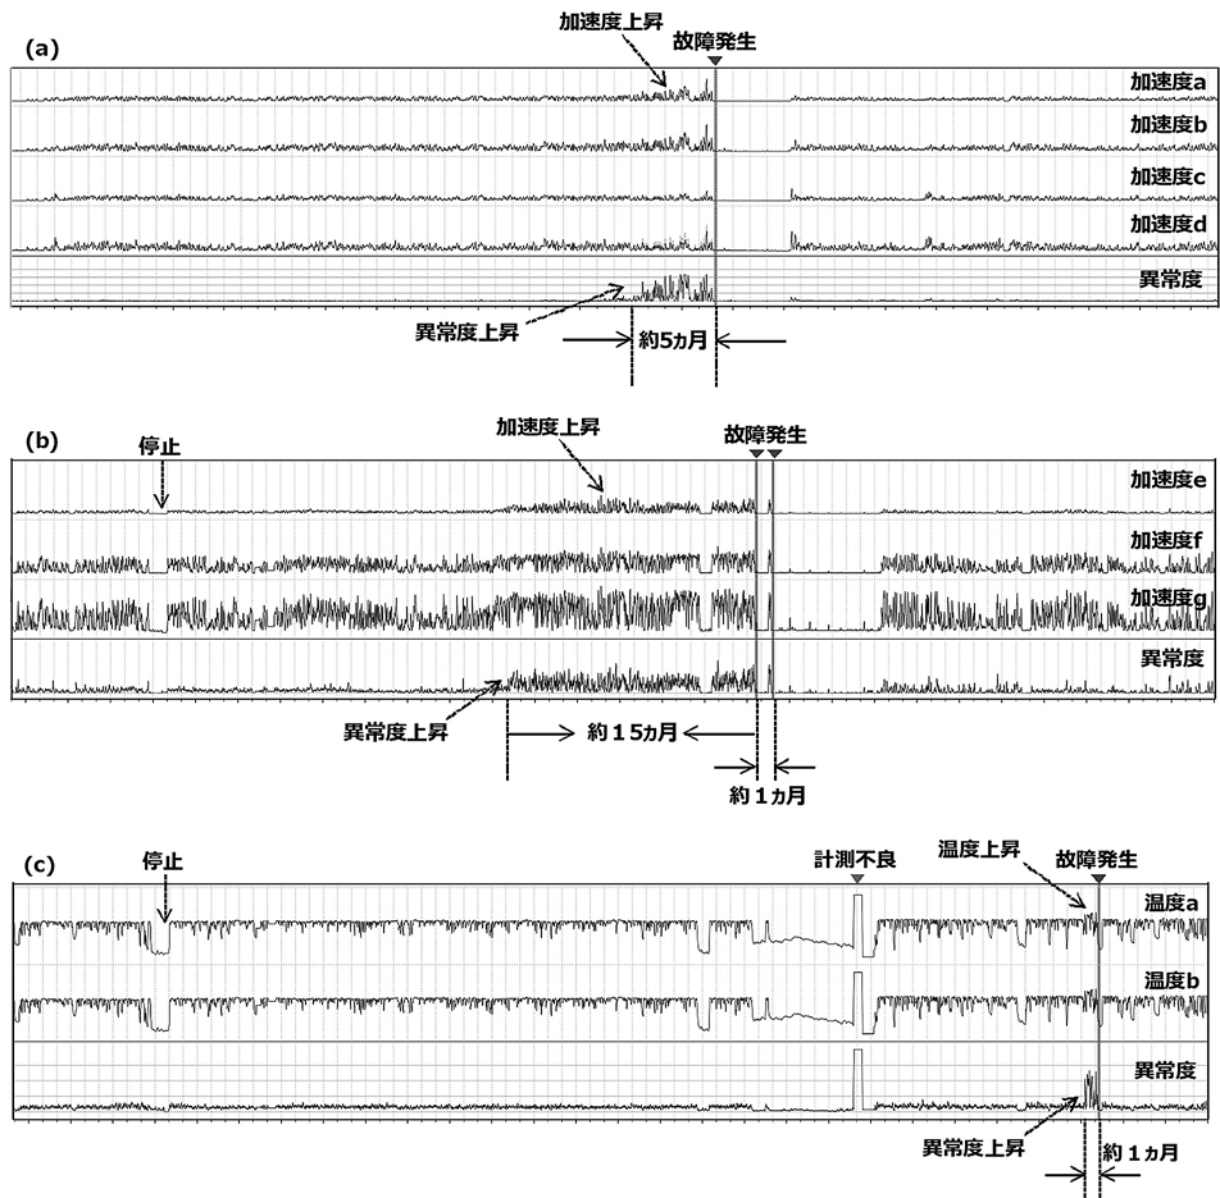


Fig. 2 Examples of predictive diagnosis




Fig. 3 Local subspaces and anomaly measure

項目数（次元数）を増やすと，異常に直接関係しないデータ項目が逆に阻害要因になって，データ分布のわずかな違いが見えづらくなるためである。従来は，経験則からこのデータ項目の選択が行われたが，近年では機械学習・深層学習技術の発展により，この特徴選択そのものを計算機が行ってくれるようになってきている。抽出できたデータ項目の組合せは，同じデータ項目を持つ同型の風車に適用することができるため，1つの




Fig. 4 Feature Selection

風車で起きた故障あるいは異常の経験を他の風車の監視に横展開することができる。

### 3.2 機械学習を用いた設備診断の課題

機械学習を活用した設備診断では，いくつかの留意点が存在する。活用を企図しながら，うまく行かない例では，これらのポイントを理解しないまま進めている場合が多い。

### (1) 大量のデータが必要

機械学習は、データドリブンのアプローチであり、設備の挙動全体を表現できるだけの十分なデータが必要である。様々な運転状態や季節変動などの環境影響全体をカバーするためである。また、サンプリング定理に従い、設備挙動の細部を捕捉できるだけのデータ密度が必要である。さらに、すべての故障モードをカバーするには、学習モデルの妥当性を検証するために、それぞれに対応した異常時データが必要である。

### (2) データモデリングが必要

一般に、機械学習は「教師なし学習」と「教師あり学習」に分けられる。深層学習の事例として良く用いられる犬や猫を分類する例は「教師あり学習」であり、これを活用するためには分類ごとに「教師情報」と対応するデータを準備する必要がある。異常予兆検知の場合は、正常時データと異常時データが必要になる。一方、「教師なし学習」では、正常時データのみで機能するが、前述の通り十分なデータが必要である。

### (3) 学習モデルの管理が必要

機械学習による異常予兆検知は、学習したデータとの差異を捉える。ある時点で十分なデータで「正常」状態を学習できたとしても、経年変化にともなう設備そのものの状態変化まで学習することはできない。これは設備を適切に保全していたとしても基幹部品や構造部品など取り換えの難しい部位が存在するためである。人而言えば、年を重ねた年々の「健康状態」が存在するが、若いころとは異なっている。従って、保全実施後など、適切なタイミングで影響評価を行うとともに、再稼働後のデータを加えて再学習・追加学習するなど、学習モデルの継続的な管理が必要である。

### (4) データには計測の誤差や不良が含まれる

センサには元々の計測誤差が含まれる。また、センサそのものの状態変化（ドリフト）により、取得するデータ値が変化することがある。さらに、**Fig. 2**の事例(c)にあるように、センサ・計測機器・通信などの故障により計測不良が発生することがある。実際に

は、設備そのものに異常は発生しておらず、観測上の問題ではあるが、異常には違いないため、保全によって速やかに原状回復する必要がある。

## 4. おわりに

風力発電を事例に、機械学習を活用した設備診断について紹介した。資源エネルギー庁の長期エネルギー需給見通し（エネルギーミックス）でも、再生可能エネルギーは重要な位置を占めており<sup>11)</sup>、洋上風力のポテンシャルを含めると、今後ますます伸びていくものと期待される。設備の有効活用およびライフサイクルコストの最適化のためには、機械学習技術を応用したIoTデータなどのビッグデータ解析技術に対するニーズもますます増えていくと思われる。そのためにも、製品や設備の構想・設計段階からデータ活用を視野に入れておくことが重要と考える。

### 参考文献

- 1) [http://jwpa.jp/pdf/20171208\\_FranceFloating.pdf](http://jwpa.jp/pdf/20171208_FranceFloating.pdf)
- 2) <https://sustainablejapan.jp/2016/05/06/wind-power-market/11154>
- 3) <http://www.env.go.jp/earth/report/h22-02/04-chpt4.pdf>
- 4) <http://www.mlit.go.jp/common/001000883.pdf>
- 5) [https://www.renewable-ei.org/activities/reports/img/20170614/20170614\\_JapanWindPowerCostReport.pdf](https://www.renewable-ei.org/activities/reports/img/20170614/20170614_JapanWindPowerCostReport.pdf)
- 6) 高田祥三, ライフサイクル・メンテナンス——LCCを最適化する論理的・合理的設備管理, 日本能率協会コンサルティンク
- 7) 杉山将, 統計的機械学習——生成モデルに基づくパターン認識 (Tokyo Tech Be-TEXT)
- 8) 井手剛, 入門 機械学習による異常検知——Rによる実践ガイド
- 9) C. M. ビショップ, パターン認識と機械学習 上・下
- 10) Tianqi Chen, Carlos Guestrin, <https://arxiv.org/abs/1603.02754> (2016)
- 11) [http://www.enecho.meti.go.jp/committee/council/basic\\_policy\\_subcommittee/022/pdf/022\\_006.pdf](http://www.enecho.meti.go.jp/committee/council/basic_policy_subcommittee/022/pdf/022_006.pdf)