

機械学習を用いたセンサデータ解析の可能性

Machine Learning Applied to Sensor Data Analysis

高見 豪 ^{*1}	徳岡 萌 ^{*1}
Go Takami	Moe Tokuoka
後藤 宏紹 ^{*1}	野坂 祐一 ^{*1}
Hirotsugu Goto	Yuuichi Nozaka

IoT (Internet of Things), ビッグデータというキーワードが多くのメディアで取り上げられている中, 集められた多くのデータをどのように活用するかという点に注目が集まっている。一方で第3次人工知能ブームと呼ばれる時代が到来しており, 人工知能・機械学習の分野での技術の進化はすさまじい勢いで進んでいる。我々はこの機械学習の技術に着目し, この技術をIA分野のセンサデータに適用した場合に, 従来と比較してさらに高度なセンサの劣化診断やメンテナンス予測などの保全業務に活用できる可能性があると考えている。本稿では機械学習の理論の概要と, 機械学習の理論をpHセンサに適用した事例を紹介する。

IoT and big data have already become household words and people are becoming increasingly interested in how to effectively use enormous amounts of collected data. Meanwhile, the third boom of artificial intelligence has emerged, and relevant technologies including machine learning are evolving rapidly. Yokogawa believes that technologies for machine learning can enable advanced maintenance such as degradation diagnosis and maintenance prediction by being applied to sensor data analysis in the field of industrial automation. This paper outlines the theory of machine learning and introduces an application example of analyzing the data of pH sensors.

1. はじめに

近年, IoT (Internet of Things) という言葉に代表されるように, GPSによる位置情報や家電の使用状況など様々な「もの」(Things)のデータがデジタル通信を介して取得できるようになってきている。さらに, それらのデータをクラウドなどに集めて, 簡単に保管できる環境が競うように整備されている。集められた膨大なデータはビッグデータと呼ばれ, ビッグデータをどのように活用するかという点に注目が集まっている⁽¹⁾。一方で, 第3次人工知能ブームと呼ばれる時代が到来しており⁽²⁾⁽³⁾, 人工知能が囲碁のプロ相手に勝利を収めるまでに人工知能・機械学習の分野は進化してきている⁽⁴⁾。この機械学習の技術を利用して, 膨大なデータからパターンを習得し, そのパターンから人間の力では気付けない新しい事実を見つけてソリューションへと展開する流れが, 様々な産業の分野で起きている。IA分野においてもIoTの技術が注目されている。例えば, 無線デバイスをプラント内に多数設置し, 設備の振動や温度などの多くのデータを取

得できるようになってきており, そのデータを解析して, 安定したプラント操業へとつなげていく試みが始まっている⁽⁵⁾。

我々はプラント内に配置されているセンサの測定データに着目し, ディープラーニング⁽⁶⁾と呼ばれる機械学習の技術を応用することで, センサの新しい予知保全が行えるのではないかと考えている。現状の保全作業では, 作業員の経験と勘によるところが大きい, この技術を応用することで, センサの高度な劣化診断や, メンテナンス予測など, 保全業務に新しい波が生まれることを期待している。本稿では, 機械学習の概要と機械学習を使った実験例を紹介し, センサの高度な劣化診断の可能性を示す。

2. 機械学習の概要

ここでは一般的な解析技術と機械学習との違いを説明する。一般的な解析技術では, 解くべき問題に対して, 人間が「モデル」を考える。「モデル」の一例として, パラメータA, B, Cに線形の関係があると推測されるときに線形モデルを適用し, パラメータDの予想を行う線形解析がある。また品質工学においては, サンプルとなるデータからバラつきを計算し, ベルカーブの端に位置する点を異常な点と推測する「モデル」を人間が設定する

^{*1} IAプラットフォーム事業本部 新分野開発センター
フィールドデジタルイノベーション部

解析手法がよく知られている。一方、機械学習の場合、機械（プログラム）がデータの集合から何らかのパターンを学習することで「モデル」を自動的に生成する。「モデル」を自動生成するとき、機械学習では「オッカムの髭剃り」と呼ばれる原理（最少の仮定で説明できるものが真実に近いという原理）を用いて「モデル」が学習される。その結果、できあがった「モデル」は抽象的なものが多い。例えば、ディープラーニングで生成された「モデル」が、実際に何を示しているのかを人間が解釈することは困難であることが多い、と言われている（表1）。しかし、それゆえに、機械学習はデータの集合から人間が気付くことのできない事象を学習・発見できる可能性があり、経験と勘といった定式化し難いものに対しても「モデル」を生成できるのではないかと考えている。

表1 一般的な解析技術と機械学習の違い

	一般的な解析技術	機械学習
モデルを考える主体	人間	機械（プログラム）
モデルの例	線形モデル 多項式モデルなど	直感的に理解できないモデル (ニューラルモデルなど)

2.1 機械学習の利用

一口に機械学習といっても、多くの手法が知られている⁷⁾。どの機械学習の手法を選択するかは利用目的によるが、一般的に、機械学習を利用する際には大きく分けて2つのステップがある。1つ目は、データの集合からパターンを見つけるための学習ステップ、2つ目は、学習した結果を利用して未知のデータを推定する評価ステップである。

学習ステップでは、機械学習のアルゴリズムを利用して、データの集合からパターンを学習し、モデルを生成する（図1）。図1の学習器は機械学習の手法ごとに用意されている。利用者が学習させたいデータ（教師データ）を学習器に与えることで、それぞれの学習器が持っているアルゴリズムを利用して、モデルを生成する。




図1 学習ステップの動作

評価ステップでは、評価対象となる未知のデータ（評価データ）と、モデルが学習したパターンとを比較する（図2）。評価ステップで登場するのが推定器であり、推定器もまた機械学習の手法ごとに用意されている。推定器は学習したモデルを利用して、評価データが学習したパターンと似ているかどうかの判断を行う。




図2 評価ステップの動作

3. センサデータの判別実験

ここでは、前章で紹介したステップを踏まえて、pHセンサの計測値に機械学習を適用した実験を紹介する。

3.1 実験環境

実験では、表2に示す3つのpHセンサを用意した。

表2 センサと測定溶液の一覧

センサ名	測定溶液
センサA	水道水
センサB	アルカリ溶液
センサC	評価対象溶液

センサAは水道水に、センサBはアルカリ溶液に浸した状態とし、センサCは水道水またはアルカリ溶液のどちらかの溶液に浸しておいた（図3）。




図3 実験環境

約2ヵ月間それぞれのセンサを測定溶液に浸した状態とし、図4に示す構成で、pHセンサの測定原理に関わる3つのパラメータ（ガラス電極抵抗、比較電極抵抗、温度）を1時間周期で取得した。取得したデータの一部を図5に示す。pHセンサの詳細に関する説明は本稿では

割愛するが、アルカリ溶液を測定し続けると、水道水と比較して、ガラス電極や比較電極に微小な変化が生じることが分かっている。しかし、図5のデータを一見するだけでは、センサCがどちらの溶液を測定しているかを人間が判別することは困難である。そこで、図5のデータを使って、機械学習技術により測定溶液が何かを判断できるかどうかの実験を行った。

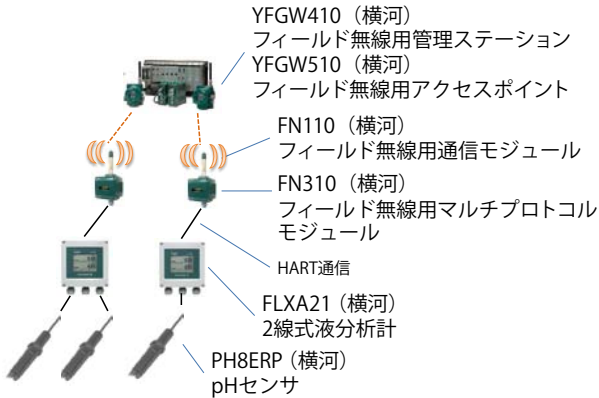


図4 データ取得時の構成

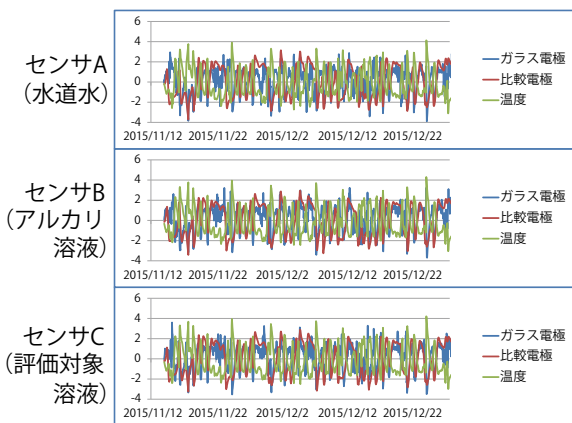


図5 取得したセンサデータ

3.2 機械学習の判定

今回判定のために用いる機械学習の手法は、ディープラーニングと呼ばれる手法である。はじめに学習ステップでは、ディープラーニングの学習器に水道水とアルカリ溶液のパターンを学習させる。学習においては、ほぼ中性の水道水を測定しているセンサAのデータに“1”とラベルを付け、アルカリ溶液を測定しているセンサBのデータに“-1”とラベルを付けた教師データを作成する。作成した教師データをディープラーニングの学習器に与え、図6に示すように水道水のパターンとアルカリ溶液のパターンを学習したモデルXを生成する。次に評価ステップに移り、対象となるセンサCのデータを評価データとし、推定器に入力する。推定器はモデルXで学習されたパターンと、評価データを比較する。こうして比較

した結果を図7に示す。

図7のグラフはセンサCのデータを1点ずつ推定器に入力して、センサAのデータに近いと判断されたものを1、センサBのデータに近いと判断されたものを-1としてプロットしたものである。この推定結果の傾向を見ると、推定器はデータ取得開始時期こそセンサAに近い、つまりセンサCのデータが水道水の測定パターンに近いと判定していた。しかし、それ以降の点では、センサCのデータはほぼすべての点でアルカリ溶液の測定パターンに近いという判定結果を出力した。実際にセンサCが測定していた溶液はアルカリ溶液であり、機械学習の推定結果と事実が合致している結果が得られた。

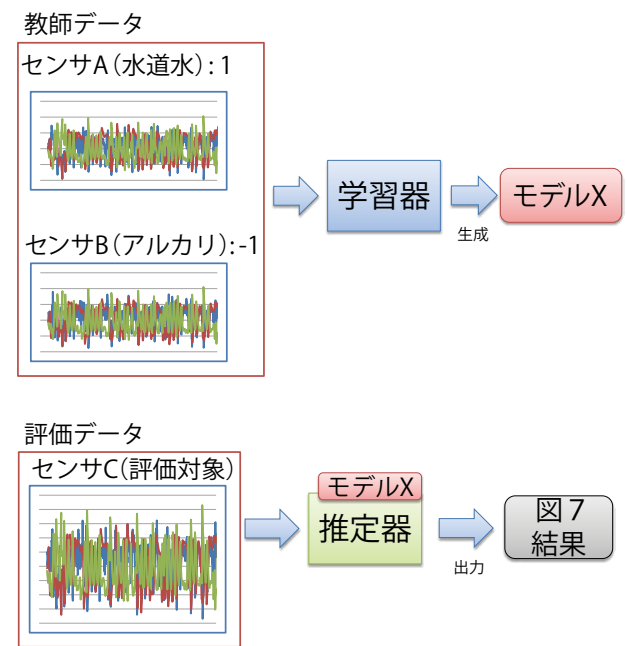


図6 モデル生成と推定イメージ




図7 推定結果

4. 劣化解析への期待

前章の結果から、機械学習は水道水のパターンとアルカリ溶液のパターンを学習して、人間が見るだけでは判断が難しいようなデータであっても、微小なパターンの違いを見つけることができることがわかった。このことから、時間の経過とともに発生する電極などの変化などによりセンサの性能が劣化してきたときに、人間の目で

は見つけられない微小な変化も、機械学習であれば数値化できる可能性があると考え、次の実験を行った。

4.1 劣化判定実験

先ほどの実験で利用したセンサ B, C を利用して、**図 8** に示すように学習・評価を行う。はじめに学習ステップでは、劣化（時系変化）を判断できるモデルを作成するために、センサ B のデータ前半部分を“1”（正常）とラベルを付け、データ後半部分を“-1”（劣化）とラベルを付けた教師データを用意する。作成した教師データをディープラーニングの学習器に与え、**図 8** に示すようにデータ前半部分とデータ後半部分のパターンを学習したモデル Y を生成する。次に評価ステップに移り、対象となるセンサ C のデータを評価データとして推定器に入力する。このとき、推定器が出力した結果を**図 9** に示す。

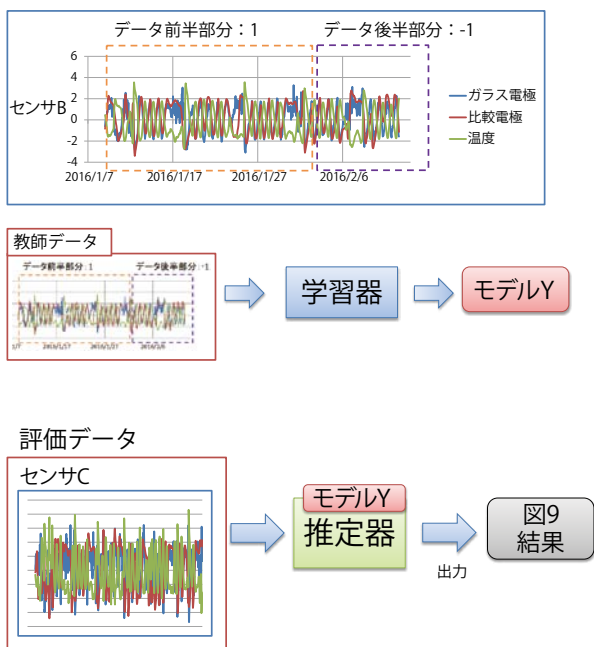


図 8 劣化推定用モデルの作成と推定器による評価




図 9 推定結果

図 9 のグラフは、センサ C のデータを 1 点ずつ推定器に入力して、ディープラーニングの出力値をプロットしたものである。推定結果の移動平均に着目すると、はじ

め 0.5 付近を推移していることから、センサ C の評価データは学習データ後半部分（-1：劣化）のパターンよりも、学習データ前半部分（1：正常）のパターンに似ていると判断されている。そしてデータが後半に進むと、出力値が徐々に下がっている。これは、時間が進むにつれて、センサ C の評価データが、学習データ後半部分（-1：劣化）のパターンへと、徐々に似てきているという判断をしていることを意味している。この結果から、劣化したセンサデータと劣化していないセンサデータを利用することで、センサの劣化を推測できるモデルが作成できる可能性があると言える。

5. おわりに

本稿では、機械学習の簡単な概要と、センサ判別の実験、ならびにセンサの劣化現象を捉えることができる可能性を示唆している劣化判定実験の結果を紹介した。センサデータを機械学習の手法で解析することで、センサの劣化推測など予知保全に利用できる可能性は大いにありと考えている。また、今回紹介している機械学習の手法は、pH センサ特有の知識やノウハウを一切考慮していないため、様々なセンサデータに対して、汎用的に応用できる技術と考えている。

今後はセンサの劣化事象の例を増やしていくとともに、メンテナンス・補修時期の予測など、これまで人による経験と勘で賄われてきた事象に対して機械学習を応用していき、将来的には ISA100 産業無線を使った IoT デバイスとともに、機械学習を利用した保全機能を市場に投入していくことを考えている。

最後に本プロジェクトのプログラム作成にあたり、YTI (Yokogawa IA Technologies India Private Limited) の Satish Godachikonda 氏に多大な協力をいただいたことに対し、心から謝意を表したい。

参考文献

- (1) 城田真琴, ビッグデータの衝撃, 東洋経済新報社, 2012
- (2) 松尾豊, 人工知能は人間を超えるか ディープラーニングの先にあるもの, KADOKAWA, 2015
- (3) 比戸将平, 馬場雪乃, 他, データサイエンティスト養成読本 機械学習入門編, 技術評論社, 2015
- (4) GOOGLE INC., AlphaGo, 2016, <https://deepmind.com/alpha-go.html>
- (5) ARC WHITE PAPER, "Process Automation and the IoT : Yokogawa's VigilantPlant Approach to the Connected Industrial Enterprise," ARC Advisory Group, 2015
- (6) 岡谷貴之, 機械学習プロフェッショナルシリーズ 深層学習, 講談社, 2015
- (7) Mariette Awad, KhannaRahul, Efficient Learning Machines, Apress Media, 2015

* YFGW, FLXA は、横河電機株式会社の登録商標です。