

# IoTによる発電機保全データ収集と故障予兆診断の取り組み

佐野慎一 Shin'ichi Sano  
挾間洋平 Yohei Hasama  
澤田宗基 Hiroki Sawada

キーワード インフラ、発電機、IoT、M2M、TBM、CBM、センサ、故障予兆診断、機械学習

## 概要

IoT (Internet of Things), M2M (Machine to Machine) 技術の発達によって、インフラ設備に設置したセンサから常時かつ容易にデータを収集できるようになり、今日のインフラ設備のメンテナンスは、従来のTBM (Time Based Maintenance) からCBM (Condition Based Maintenance) になってきている。

当社は、2015年度に稼働率向上を目的としたお客様施設上でのデータ収集検証を開始し、実際に稼働中の水力発電所設備を対象にセンシングシステムを構築するとともに、発電機各部位の状態データを継続的に収集・蓄積・分析する取り組みを行っている。発電機に設置したセンサは全て後付けで、既設設備とは完全に独立した構成とした。配電盤上の発電出力メータをネットワークカメラで撮影・画像解析することで発電機の稼働状況を常時収集する。本検証では、機械学習手法を応用して軸受付近の振動データを事後解析し、実際に故障が発生する約12日前に機械的故障の予兆発生タイミングを検出できた。

## 1 まえがき

当社の主力製品であるインフラ設備が突発的な故障で停止すると、多大な人的・経済的損失が発生する。このような故障を未然に防ぐためには設備診断技術が必要不可欠である。従来の診断は定期的にメンテナンスを実施するTBM (Time Based Maintenance) が主流であったが、今日ではIoT (Internet of Things), M2M (Machine to Machine) 技術の発達によって、インフラ設備に設置したセンサから常時かつ容易に発電機各部位の状態データ (以下、保全データ) を収集できるようになり、今日では納入製品の使用状況や維持管理状況を考慮したCBM (Condition Based Maintenance) によるメンテナンスができるようになってきている。

本稿では、稼働中の水車発電機設備に各種センサを取り付けて保全データを継続的に収集・蓄積・

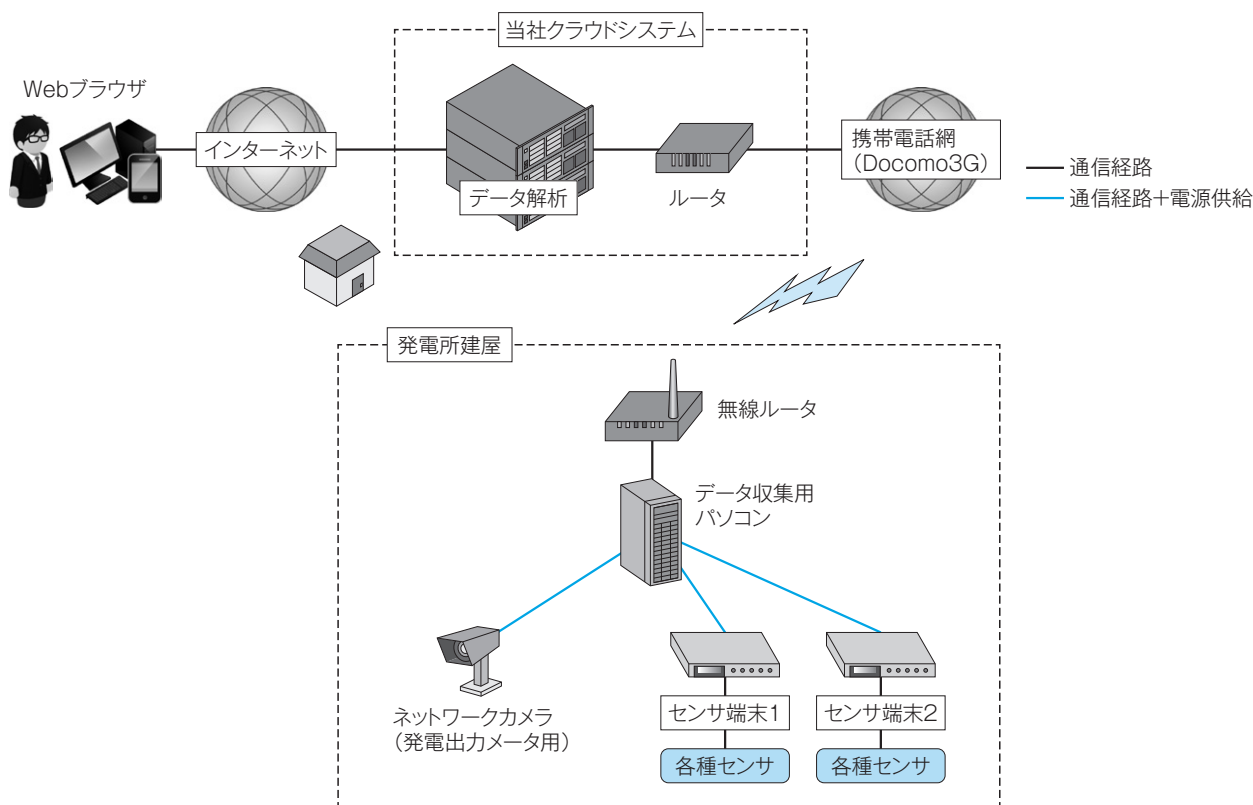
分析し、設備の故障につながる予兆 (通常時との違い) を早期に検出して対策を図ることで、設備稼働率向上を図る一連の取り組みを紹介する。

## 2 センシングシステムの構築

稼働中設備の保全データを収集するため、2015年度から稼働率向上を目的としたお客様施設上でのデータ収集検証 (以下、フィールド検証) を開始した。フィールドとして当社製発電機を納入している水力発電所を選定し、センシングシステムを構築した。

### 2.1 センシングシステム

第1図にセンシングシステムの基本構成を示す。発電機に各種センサを設置し、センサで計測したデータをネットワーク (有線) 経由でデータ収集用パソコンへ一時的に保存する。一次診断後のデータ



第1図 センシングシステムの基本構成

いずれの発電所でも基本構成は同じである。

を携帯電話網（無線）経由でクラウドシステムへ送信・蓄積・分析している。保全データは1時間に1回、5秒間の波形データレベルで収集し、センサは全て後付けとすることで既設設備とは完全に独立した構成とした。

なお、全ての設備・部位にセンサを常設することが困難であることを想定し、同様のセンサー式とデータ収集用パソコンを組み合わせたオフライン計測用の簡易システムも構築し、各所でのメンテナンス業務に活用している。

## 2.2 適用センサ

第1表に本検証で適用したセンサを示す。発電機の稼働状況を把握するためには発電出力などの情報が必要となる。しかし、既設システムと接続してそれらの情報を得るには改造を要してしまうため、本システムでは配電盤上の発電出力アナログメータをネットワークカメラで撮影して画像を取り込み、画像解析によってデジタル化した。軸受付近の機械

的故障を検出することを目的に、振動センサ・音響センサ・赤外線センサ・熱電対を設置した。さらに絶縁劣化などの状態を把握することを目的に、接地線へ電流センサを設置した。温湿度センサは設置場所の環境と設備故障の相関関係を解析するために必要である。第2図に各種センサの設置状況を示す。

## 3 発電機の故障予兆診断

発電機などの電気設備は多様な形式や容量が存在し、また多くの部品から構成され故障原因も多岐にわたるため、故障判別ルールを人の手で決定するのは困難である。そこで、本検証では発電機軸受付近の振動データから機械的故障の予兆を捉えることを試みた。

### 3.1 故障予兆の検出 (A 発電所)

A 発電所の水車発電機は横軸タイプで、計測開始から約1か月で実際に故障（軸受損傷）が発生した。


### 第1表 適用センサ

本検証で適用した各種センサの設置目的・仕様・外観を示す。


センサ	設置目的	仕様	外観
ネットワークカメラ	対象設備のアナログメータ (kWなど) をデジタルデータ化し、その運転状態を把握	約130万画素カラーナイトビューモード付き	
振動	軸受付近の振動を計測し、主軸及び軸受の機械的故障・傷の有無・アンバランスなどを検出	マグネットベース X・Y・Zの3軸方向	
音響 (マイク)	軸受付近の音を計測 (周波数分析) し、地絡・短絡・絶縁破壊・機械的故障 (金属音) などを検出	マイクロホンプリアンプ	
赤外線	軸受付近の表面温度や主軸 (露出部) の表面温度を計測	サーモパイル (非接触) 式	
熱電対	軸受付近の表面温度を計測し、振動や音との相関関係を解析 (冷却水配管などの入る側と出る側で表面温度を計測し、温度差の兆候を監視することも可能)	長さ: 10m 計測範囲: 0 ~ 200°C	
環境 (温湿度)	現場内の温湿度を計測し、振動や音、表面温度との相関関係を解析 (表面温度との比較で結露発生条件を把握することも可能)	計測範囲: -20 ~ 80°C / 0 ~ 100% RH	
電流	接地線に設置し、絶縁劣化によって発生する漏れ電流を検出	定格電流: ±1000mA	

第3図にセンサの設置位置を、第4図に発電出力の推移を示す。第4図は縦軸が発電出力 (kW)、横軸が計測開始日からの経過日数 (最小単位は1時間) を示している。


計測開始から7日間のデータを学習データとして



(a) 軸受付近に設置した振動センサ・音響センサ・赤外線センサ



(b) 接地線に設置した電流センサ



(c) 温湿度センサとセンサ端末




(d) ネットワークカメラで撮影した発電出力メータ画像からアナログ値をデジタル化




### 第2図 各種センサ設置状況

振動センサはマグネットで固定し、音響センサと赤外線センサはマイクスタンドを利用した。




### 第3図 A水車発電機のセンサ設置位置

負荷側軸受上部に振動センサを設置した。




### 第4図 A水車発電機の発電出力推移

データ計測期間 (約1か月) の発電出力推移を示す。



第5図 A水車発電機の異常率

計測開始後7日間を学習データとした異常率を示す。




第6図 B水車発電機のセンサ設置位置

スラスト軸受付近に振動センサを設置した。

異常率を算出した。第5図に異常率の時系列グラフを示す。縦軸が異常率(%), 横軸が計測開始日からの経過日数を示している。故障発生の約12日前から異常率が増加傾向にある。すなわち学習データに含まれない振動パターンが表れたことになり、故障の予兆と考えられる。ただし第4図の発電出力に着目すると、異常率が高い期間は1000kW前後の低発電出力が継続しており、学習データが不足しているのかの見極めも必要である。


### 3.2 学習期間の選定 (B発電所)

B発電所の水車発電機は立軸タイプで、計測開始から約4か月間正常に稼働している。第6図にセンサの設置位置を、第7図に発電出力の推移を、第8図に異常率の推移を示す。計測開始から1か月のデータを学習データとして異常率を算出した。計測開始から90日前後で、実際には故障が発生していないにもかかわらず、異常率の高い状態が多くなっている。第7図の発電出力に着目すると、異常




第7図 B水車発電機の発電出力推移

データ計測期間(約4か月)の発電出力推移を示す。



第8図 B水車発電機の異常率その1

学習期間を計測開始後1か月とした場合の異常率を示す。全体的に異常率が高くなっている。



第9図 B水車発電機の異常率その2

学習期間を次の1か月とした場合の異常率を示す。異常率の高い状況が改善された。

率が高い箇所の発電出力は12MW前後で、学習期間には含まれていないデータである。

そこで、12MW前後の発電出力を含みかつ学習データ数が多い次の1か月間を学習データとして異常率を算出した。第9図にその結果を示す。90日前後を含め、全体的に異常率が低い結果となった。この結果から、第9図の学習期間データは、評価期間の振動パターンをほぼ網羅していると考えられる。

## 4 むすび

本検証では、水車発電機の振動データから機械学習のようなデータ駆動型的手法によって故障予兆を検出する方法を検討し、実際に機械的故障の予兆発生タイミングを検出できた。一方で、解析結果に大きく影響する学習データの期間や網羅性の考察をさらに深める必要がある。

今後は振動データのみならず、音響データの分析や複数データの相関関係などによって、多様な形式・容量の回転機における機械的故障の予兆診断精度向上を図るとともに、例えば変位センサなど新しいセンサの適用も進めていく。さらには適用センサのコスト削減（スペック・価格）、常時監視サービスの提供、メンテナンス業務へのフィードバックなどにも取り組む予定である。

最後に、本検証の実施にあたり、検証フィールドをご提供していただいたお客様、技術開発を支援し

ていただいた大学関係者に深く謝意を表する次第である。

- ・本論文に記載されている会社名・製品名などは、それぞれの会社の商標又は登録商標である。

### 《執筆者紹介》



佐野 慎一  
Shin'ichi Sano

ICT 製品・サービス統括本部企画部  
ICT 関連製品の営業企画に従事



狭間 洋平  
Yohei Hasama

ICT 製品・サービス統括本部企画部  
ICT 関連製品の営業企画に従事



澤田 宗基  
Hiroki Sawada

ICT 製品・サービス統括本部企画部  
ICT 関連製品の営業企画に従事