

DEN-CHU-KEN

TOPICS

2016 10 October

VOL.22

Central Research Institute of Electric Power Industry

ビッグデータと人工知能による電力設備診断

1. 総括
2. 油中ガス分析データに基づく電力用変圧器の内部不具合診断
3. 大量の運転データに基づく水力発電所の異常予兆発見
4. 大量の送電線ビデオ画像を用いた送電線異常箇所の検出支援

ビッグデータと人工知能による電力設備診断

1.総括

IoT(Internet of Things:モノのインターネット)の進展、ビッグデータ活用の普及・高度化、さらに第2次人工知能ブームを背景に、ビッグデータを活用した電力設備の故障診断、余寿命予測、異常予兆発見が試みられるようになってきました。ただし、これら新技术を電力設備に適用するに当たっては、以下の3点が課題として挙げられます。

- ①設備の正常時のデータは大量に蓄積されているものの、異常時のデータは少量の蓄積しかない(主に3章)。
- ②最も検知したい故障時のデータは、ほとんど蓄積されていない(主に4章)。
- ③設備の正常状態と異常状態とが区別なく混在した大量の設備状態データが蓄積されている(主に2章)。

本TOPICSでは、これら3つの課題の克服に向けて当研究所で取り組んできた研究の成果を紹介します。これらの成果は既に電気事業で活用されていますが、近年のビッグデータや人工知能ブームの到来により、IT業界で再び注目を集めるようになってきています。

エネルギーイノベーション創発センター
上席研究員
堤 富士雄



電力設備の保守業務の自動化を進めることで保全に必要なコストを下げ、利益率を改善できる可能性があります。このため、電力会社では十数年前から、センサデータ、画像データなどの客観的なデータに基づいて電力設備の状態を把握し、安全性が確認できる限り「使用を継続する」という状態基準保守への変更を検討しています。

一方、Googleが大量のデータ(ビッグデータ)を分散蓄積し、それらのデータを分散処理するフリーソフトウェアHadoop^(注)を世の中に提供してから、ビッグデータ分析のブームが始まりました。そして、この分析に役立つ人工知能技術として「機械学習」に注目が集まり、人工知能の研究が1950年代および1980年代に続いて再びブームを迎えています。ただし現在のところ、ビッグデータと人工知能を活用したビジネスでの成功事例の多くは、インターネットのデータやマーケットデータなどを対象にしたもので、設備保守での成功例は多くありません。

本TOPICSでは、ビッグデータブームや第2次人工知能ブーム<1980年代>が訪れる前から当研究所で取り組んでいた3つの研究を紹介します(表1)。

ビッグデータと人工知能による電力設備診断を実現するためには、(1)計測技術、(2)通信技術、(3)蓄積技術、(4)解析技術の4つの技術が重要です。本TOPICSで紹介する研究成果は主として(4)に重点があり、人工知能の基盤技術の進展により、今後さらなる精度向上が見込まれます。さらに、上記(1)(2)に関しては、IoTの進展やドローンなどロボットの活用により、設備に関連する広域のセンサデータを低コストで収集可能となりつつあります。また(3)に関しても、クラウドなどにより低コスト、安全かつ容易に多量のデータを蓄積可能となりつつあります。我々は、このような環境の成熟を背景に、ビッグデータ分析と人工知能を活用した電力設備保全のソリューション構築に取り組んでおり、送配変電設備や火力・水力発電所の経年設備への適用を目指しています。

表1 電力設備の保守高度化への人工知能技術の適用例

研究項目	対象	分析対象のデータ	診断項目	用いた手法	成果・効果
1.油中ガス分析データに基づく電力用変圧器の内部不具合診断(主に課題③)	変電用変圧器	変圧器内部の絶縁油を分析して得られるガスのデータ	変圧器の内部様相(正常、過熱、放電等)	線形サポートカーネルマシンによる内部様相を識別できるガス成分の自動的絞り込み	1000件以上のデータに対し98%の推定正解率
2.大量の運転データに基づく水力発電所の異常予兆発見(主に課題①)	水力発電所の発電機軸受け	回転速度、各部位の温度、振動などのセンサデータ	故障に繋がる異常予兆	線形サポートベクトルマシンをベースとする異常予兆検出手法	1年分のデータから油漏れによる異常事象を発見
3.大量の送電線ビデオ画像を用いた送電線異常個所の検出支援(主に課題②)	送電線(架空地線)	ヘリコプターで撮影した送電線表面のビデオ映像	素線切れなどの表面の損傷	映像中の電線画像の追跡による表面の輝度・形状異常の検知	目視で確認すべき映像を全体の1/3まで低減

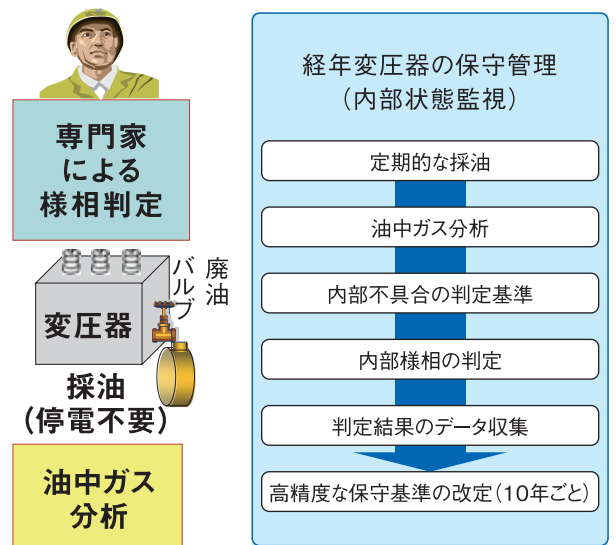
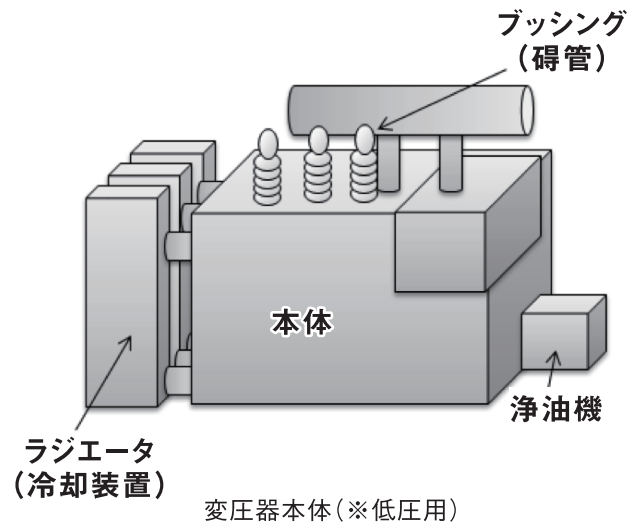
(注)データを複数のサーバに分散蓄積し、並列して処理するソフトウェア基盤。「ビッグデータ」活用における主要技術のひとつです。

ビッグデータと人工知能による電力設備診断

2.油中ガス分析データに基づく電力用変圧

電力用経年変圧器を長期健全運用するには、油中ガス分析による電力用変圧器の内部不具合診断が不可欠です。このため、一般社団法人電気協同研究会(以下、電気協同研究会)では、約10年ごとに油中ガス分析による保守基準の改定を行っています。2010年度の保守基準改定(電力用変圧器改修ガイドライン)に際しては、電力各社から1000台以上の油中ガス分析結果と内部様相(「正常」、「過熱」、「放電」、「過熱+微小放電」、「(隣接機器からの)絶縁油混入」)のデータを収集し、基準の見直しを行いました。しかし、未だ全収集データの様相を正しく判定できる基準は得られておりません。そこで、本章では、当研究所で開発した簡潔で高精度の判定基準を得る汎用的データ分析手法に基づいて、収集済データに対しては100%の精度で、新規データに対しても98%以上の推定判定精度を持つ、電力用変圧器の内部様相判定基準を得る手法について紹介します。本手法は、電力用変圧器のみならず、地中ケーブルの油中分析などにも適用済みで、高い精度の判定を実現しています。

エネルギーイノベーション創発センター
副研究参事
篠原 靖志



油中ガス分析のイメージ

器の内部不具合診断

2.1 はじめに

電力会社では電力用変圧器の内部状態監視のため、定期的に変圧器の絶縁油を一部抜き取り、油中ガス分析により内部不具合の診断を行っています。これは、酸化等による過熱、熱劣化増大、部分放電など、絶縁油の劣化進展にともない、絶縁油から発生するガスの種類・量に変化し、絶縁油中に溶けたガス(二酸化炭素CO₂、一酸化炭素CO、水素H₂、メタンCH₄、エタンC₂H₆、エチレンC₂H₄、アセチレンC₂H₂)に、変圧器の内部劣化状況が反映されるからです。

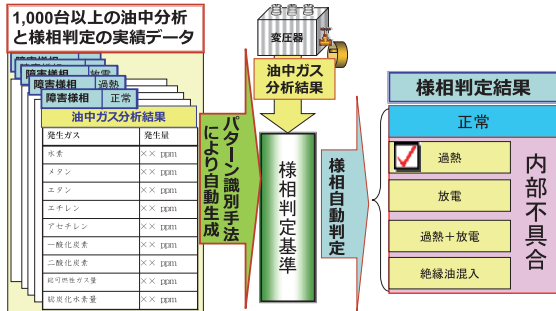


図2-1 油中ガス分析による判定(イメージ)

電気協同研究会では油中ガス分析による内部不具合の保守基準の見直しをほぼ10年ごとに進め、その精度向上を図っています。2010年に同研究会では、約1000台の正常変圧器と約120台の内部不具合変圧器の油中ガス分析結果と内部様相(「正常」、「過熱」、「放電」、「過熱+微小放電」、「絶縁油混入」)のデータを収集し、内部様相の判定基準の見直しを図りました^[1]。しかし、これまで推奨されたいずれの基準も全データ(1000件以上)を正しく判定することはできていませんでした。そこで、当研究所では、収集済データを全て正しく判定でき、かつ未知データに対しても高精度の判定が可能なデータ分析技術と手法の開発に取り組みました(図2-1)^[2]。

2.2 変圧器内部様相判定基準作成の着眼点

代表的推奨手法である異常診断図B(図2-2(a))では、油中ガス成分の中でアセチレン、エチレン、エタンの3ガスの構成比を両対数グラフにプロットし、どの内部不具合(過熱、放電、過熱+放電)領域に属するかに基づいて変圧器内部様相を判定します。しかし、収集データにおいては、過熱(赤点)、放電(ピンク△)、過熱+放電(青○)のプロット点是对応領域外にも多数存在し、判定に不確実性が生じる原因となっています。プロット点に着目すると、正常、過熱、放電、過熱+放電の各点は、図2-2(b)に示すように、様相別に雲状の群れを成しますが、これらが図上で重なるため誤判定が生じています。

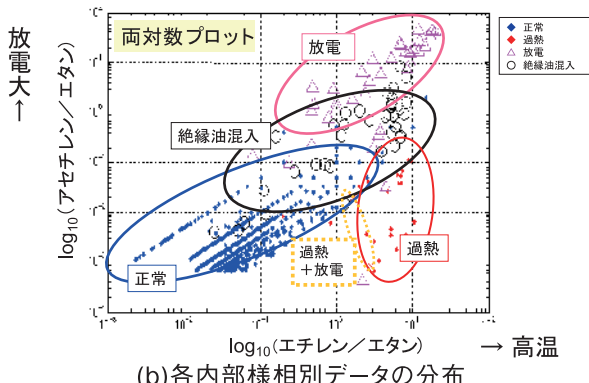



図2-2 従来基準と収集データ(異常診断図B)

そこで、主要ガス7ガス量および2通りの特定ガスの総量を各成分とする全9成分で構成されるデータ空間でデータをプロットし、重なりを持たない雲群として内部様相に対応した領域に切り分けることで、高精度の判定を可能としました。(図2-3は、例えば3次元のデータ空間内で、内部様相に応じて曲面で囲まれた領域が分離して存在することを模式的に示した図)。

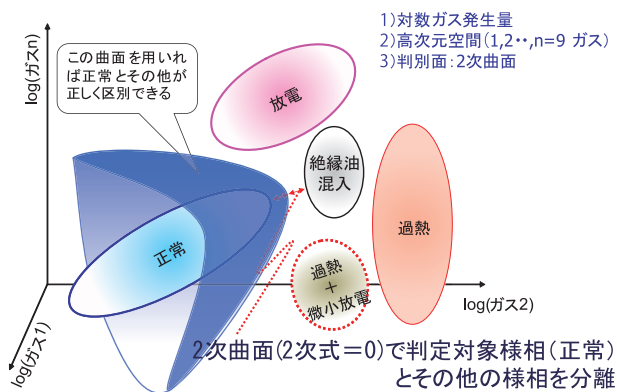


図2-3 開発手法の判定イメージ

2.3 判定基準作成手法

(1) 判定原理

判定基準作成に用いた線形サポートカーネルマシン^(注1)(以後、線形SKM^[2])は、2000年代から広く使用されている線形サポートベクトルマシン(以後、線形SVM^[3])と呼ばれる高精度の判定基準作成手法を当研究所で拡張したものです。まず、SVMを用いる場合の考え方について説明します。

たとえば、図2-4に示すように収集データのエチレン量を横軸、アセチレン量を縦軸にとると、正常事例(★)と内部不具合事例(●)は2つの群れを成します。正常・内部不具合の各領域を切り分ける判定基準として図中の黒太線を考えます。この時、線と最も近い事例との距離(マージン)が短い

黒線では、少しのノイズ混入で簡単に誤判定が生じます。そこで、SVMでは、マージンが最大となる線(赤太線)を判定基準とします。SVMにより正常か否かを判定する以下の基準が得られます^[1, 3]。

$$\text{判別基準: } Z = -0.061 \times (\text{エチレン量}) - 11.214 \times (\text{アセチレン量}) + 5.826$$

()に示す各ガス発生量を入れた評価値Zが正ならば正常、負ならば内部不具合と判定します。

ただし、SVMでは、縦軸・横軸の倍率を変えると、得られる判定基準が変化し、判別結果や判別能力も変わります。そこで、判別能力が最大となるように各軸の倍率を自動的に調整する手法を付加したのが線形SKMです^[2, 4, 5]。この結果、例えば図2-5に示す例では、項目1・2の両者を使うSVM判定基準(図2-5(a))ではなく、横軸を0倍すなわち、縦軸(項目1)のみを使用するSVM判定基準(図2-5(c))が得られ、より簡潔(少項目)でありながら判別能力のより高い(マージンが大きい)判定基準を得ることができ、判定の信頼度が向上します。

現在、線形SKMは正常・異常の2クラス判定だけでなく、5種類の内部様相の判定など多クラス判定にも適用できるように拡張されており、データ項目やデータ数が膨大でも、効率的に簡潔で高精度の判定基準が得られる解法となっています。

(2) 油中ガス分析での適用方法

前節の図2-3で述べたように、9種のガス発生量^(注2)の対数を各軸とするデータ空間では、放物面や楕円などの2次曲面により正常か否かの判定ができます。

(注1) 学習用データに基づいて、与えられた多数の候補変数の中から判定に有効な変数を自動的に絞り込み、簡潔な線形評価式による、高い判定精度を持つ判定基準を作成する手法

(注2) $H_2, CH_4, C_2H_6, C_2H_4, C_2H_2, CO, CO_2$,
可燃性ガス総量TCG(=H₂+CH₄+C₂H₆+C₂H₄+C₂H₂+CO),
炭化水素ガス総量TCnHm(=H₂+CH₄+C₂H₆+C₂H₄+C₂H₂)

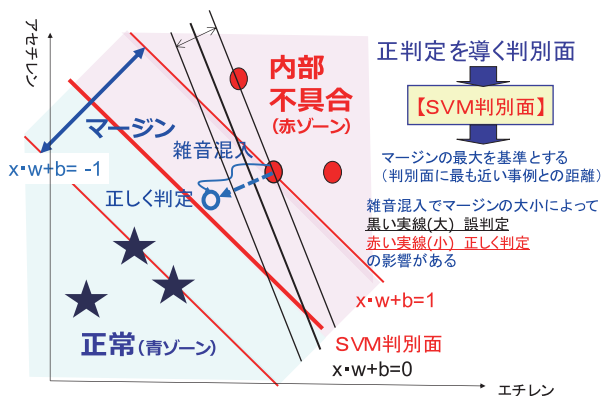


図2-4 線形SVMの考え方




図2-5 線形SKMの考え方

そこで、空間の2次曲面に対応する判定基準に対応する、55項の2次多項式の係数を線形SVM、線形SKMにより求めました。この結果、各様相を正しく判定できる最適な判定基準が得られ、空間での各様相は重なりを持たない群を成すことが明らかになりました。また、線形SVMでは55項のほぼ全てがゼロでない複雑な2次式となるのに対して、線形SKMでは、例えば、正常か否かの判定はエチレン、アセチレンの2ガスのみ、過熱+微小放電か否かはメタン、炭化水素ガス総量の2ガスのみから可能であることがわかり、簡潔で効率的な判定基準が得られました。その結果、収集済データに対して100%正しく判定できました^[3]。

次に、運用で問題となる未知事例に対する判定精度を「一抜き法^(注3)」により評価しました。表2-1は、このときの正解判定と自動判定結果の組の発

表2-1 様相判定基準の判定精度

	総数	自動判定結果						
		正解率	正常	過熱	放電	過熱+放電	絶縁油混入	合計
正解	正常	1029	99.8%	1027		1	1	1029
	過熱	23	78.3%		18	2	3	23
	放電	39	79.5%		2	31	1	39
	過熱+放電	3	66.7%		1		2	3
	絶縁油混入	37	86.5%	1	1	3		32
	合計	1131	98.1%	1028	22	37	7	37

生件数を示します。表2-1より未知データに対する推定正解率は約98%、内部不具合事例に限ると平均で約80%となりました。過熱+放電の正解率は2/3で低くなっていますが、これは3事例しかないためであり、今後の改善が期待されます。

本手法は、地中送電線などで使用される油入(OF)ケーブルの油中ガス分析による異常ランク・部位判定にも適用され、他にも鉄塔の表面画像と塗装劣化度のデータから、典型的錆色・めっき色の出現量などに基づく高精度の劣化度判定基準を自動作成するなど多方面で活用しています^[6]。

(注3) 収集済データから任意のデータを未知データとして1つ除き、残りのデータで判定基準を作成し、その判定基準を用いて、除いた未知データの内部様相を判定します。

<参考文献>

- [1] 電気協同研究会:電力用変圧器回収ガイドライン,電気協同研究第65巻1号, 2010.
- [2] 篠原靖志「油中ガス分析データによる電力用変圧器の様相判定手法」電力中央研究所報告R10030, 2011.
- [3] 小野田 崇、村田 博士、小枝 啓一、小木曾 慶治:油中ガス分析データの多変量解析手法による電力用変圧器の良否判定,電力中央研究所研究報告R07001, 2007.
- [4] 篠原靖志、鶴見剛也、嘉屋健、松谷悠司:油中ガス分析によるOFケーブル接続部の異常判定手法-サポートベクターマシンを活用した判定基準の提案-,電中研報告R13002, 2013.
- [5] 篠原靖志、嘉屋健、松谷悠司:油入ケーブル接続部の線形サポートカーネルマシンによる異常判定,電気学会電子情報システム部門論文誌Vol. 134 No.8,1138-1147, 2014.
- [6] 篠原靖志、中島慶人:状態監視保全のための設備画像に基づく良否判定基準の自動生成手法-主要な画像特徴の自動抽出手法-,電力中央研究所研究報告R10004, 2010.

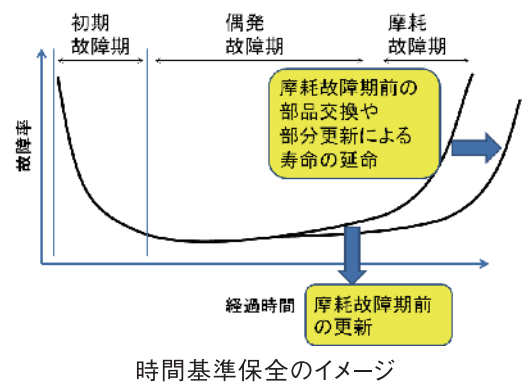
ビッグデータと人工知能による電力設備診断

3.大量の運転データに基づく水力発電

電力会社では、保守費用を低減し、設備・機器を効率的に使用するために、これまでの使用時間に基づいて機器を修理・交換する「時間基準保全」から、機器異常の発生やその予兆を把握して修理・交換する「状態監視保全」への移行を検討しています。電力設備の故障等による供給支障を防ぐために、早期に設備異常の予兆を発見し、運転計画に支障がないときに点検・補修することは重要です。故障はまれにしか生じませんが、発生すると機器を長期間停止させたり、その原因究明や緊急の修理手配が生じたりといった大きな影響が出るからです。そこで当研究所では、「大量の運転データに基づいて異常判定や異常予兆検出を行う手法」の開発を行っています。

本章では、水力発電所における発電機軸受を対象とした異常予兆発見支援手法、異常予兆発見に影響の大きいセンサの絞り込み手法、および異常予兆の原因分類手法を紹介します。

エネルギーイノベーション創発センター
上席研究員
村田 博士



発電プラント

センサデータの
収集



運転状態の
データベース

データ分析

異常予兆発見

通常の状態

交換・更新

状態監視保全のイメージ

所の異常予兆発見

3.1 水力発電所における発電機軸受の異常予兆発見支援手法

電力会社に蓄積されている水力発電所などの発電プラントの運転データは、正常状態のデータが大多数で、異常状態のデータはほとんどありません。そのため、異常予兆の発見の手がかりを、大量に収集される正常状態のデータの中から見つけ出す事が必要となります。

当研究所では、水力発電所で通常運転中の発電機軸受の状態を監視する各種センサ項目からなるデータを用いて、水力発電所における「異常予兆の発見を支援する手法」を開発しました(図3-1)^[1]。

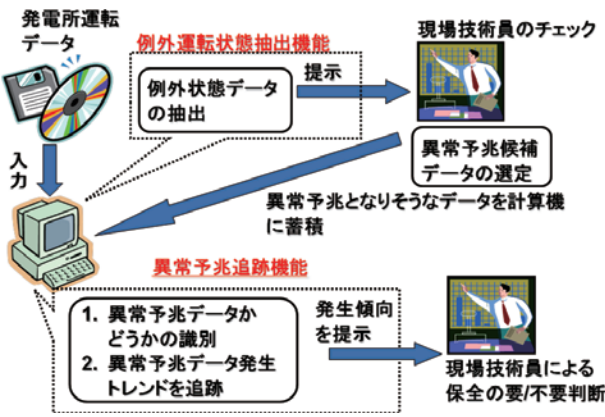


図3-1 異常予兆発見支援手法

この手法は以下の2つの機能から成ります。

① 例外運転状態抽出機能

正常運転中の発電機軸受のセンサから得られる大量のデータを用いて、通常の運転状態と異なる例外運転状態を抽出する機能。

② 異常予兆追跡機能

抽出した例外運転状態の中から、現場技術員が選んだ異常予兆候補データについて、その発生傾向を追跡する機能。

たとえば、1年間の正常状態データから例外運

転状態データを抽出するイメージを図3-2に示します。ピンクの円領域が覆う範囲にあるデータは、すべて正常状態のデータです。例外運転状態抽出は、正常状態データの99.99%を覆う円を線形SVM法^[1]で発見し、この領域から外れた星印の0.01%のデータを見つけることになります。こうすることで、現場技術員が保安を判断するうえで適切な量(1年分のデータ400万セットに対して400セットくらい)を選定でき、無作為に選ぶよりも異常予兆の発見確率を高められます。

■ 例外検出: 正常の中から仲間外れを検出

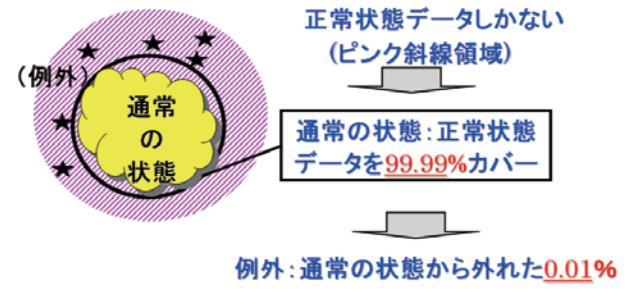


図3-2 例外運転状態抽出のイメージ

例外運転状態抽出機能については、実際の水力発電所の発電機運転データ1年分に適用し、油漏れを発見した時点のデータを抽出できることを確認しました。

3.2 異常予兆発見に影響の大きいセンサの絞り込み手法

前節で述べた線形SVM法に基づく例外運転状態抽出機能では、回転速度や水車軸受温度などの各センサ項目(電気系、機械系、温度系、水系等)が例外状態抽出にどの程度関連するかを表す「係数」が示されます。この係数が0に極めて近い場合、異常予兆に関連しない項目と見なしうるかを現場技術員が判断しにくいという課題がありました。

また、抽出された例外運転状態を詳細に分析してみると、異常ではなく単に気温が高だけで抽出されたと疑われる事例が混入していることがわかりました。このことは、例外状態抽出に關与するセンサ項目を、更に適切に絞り込む必要があることを意味します。

そこで当研究所では、線形SKM法を用いて、異常予兆への影響が小さいセンサ項目を排除し、重要センサのみに絞り込みながら異常予兆発見を行う手法を開発しました^[2]。

開発した新手法を水力発電所の発電機運転データ1年分に適用したところ、これまでは、異常予兆データを抽出する際に、13個すべてのセンサ項目を使用したのに対して、新手法では「係数」が0に近い5個のセンサ項目は不使用で、8個のセンサ項目のみで異常予兆データを抽出することができました。また、これまでと同様に、油漏れを発見した時点のデータを抽出できることも確認しました。

図3-3に例外運転状態の月別分布を示します。従来手法では抽出された例外運転状態が夏季に偏りやすいのに対して、新手法ではその傾向が低くなっているのがわかります。新手法では、温度に關連する3つのセンサ項目の「係数」が0となり、例外運転状態に關与していない一方、これまでは、これらの「係数」が小さいながらも例外状態抽出に關与します。これらのセンサ項目は夏季には値が大きくなり、冬期には値が小さくなるため、これまでは夏季のデータが例外運転状態として抽出されてしまいます。新手法ではそのようなことはなく、より適切な絞り込みが可能となっています。




図3-3 水力発電所の例外運転状態の月別分布

3.3 異常予兆の原因分類手法

一方、これまでは、ある一つのセンサ項目だけが大きく変動する場合、複数のセンサ項目が同時に大きく変動する場合など様々な状態が抽出され、例外運転状態データがどのセンサ項目に対応して検出されたのかを確認するのが容易ではないという問題点がありました。しかし、異常予兆発見後の対応までを考慮すると、電気系・機械系等、どの種類の異常予兆であるかを絞り込めれば、關連するセンサ項目に応じて点検や保守範囲を限定できるため、早急な修繕が可能となります。

そこで、大量の正常運転時のセンサデータの分析に基づいた「異常予兆の原因種別を分類できる手法」を提案しました^[3]。

図3-4に提案手法の概念図を示します。水力発電所の各センサは様々な変動原因により生じた事象を測定しています。ここで変動原因と呼んでいるものには、例えば、出力変動や気温変化のように日常的に変動しているものや、軸受振動や油

漏れのように突発的に起こるものなどがあります。一方、センサ側から見ると、例えば、軸受温度は、発電機の出力変動などの動作状況の他に、軸受の潤滑油の状況や気温などにも影響されます。このように、各センサは変動原因に応じて測定を行うため、複数のセンサが変動原因に応じて同じように連動すると考えられます。

異常予兆の種別を分類するには、センサ項目の中でどれとどれが連動しているかを判定することで、対応する変動原因の絞り込みを行います。多数ある各センサ項目を、変動原因ごとに連動する測定値を持つセンサ群に分解し、その中のどの群のセンサが異常予兆と関連しているかを見れば、変動原因がわかるという理屈です。

水力発電所運転データへ提案手法を適用した

結果、変動原因に対応するセンサ群として、25群が得られました。また、各センサ群に対応するセンサ種別から、電気系、機械系、温度系、水管理系、複合系の5種別に整理できることを確認しました。

さらに、例外運転状態抽出により自動検出された軸受振動に関する異常予兆を分析しました。その結果、異常予兆29事例は軸受振動に関する独立した5つのセンサ群により特徴づけられました。そのうち、25事例は4つの単独の振動センサ項目に対応し、4事例は水車軸振と発電機電圧、発電機電流を主なセンサ項目とする複合系の異常予兆であることがわかりました。

現在、他分野に適用範囲を拡大する方向で研究を推進しています。

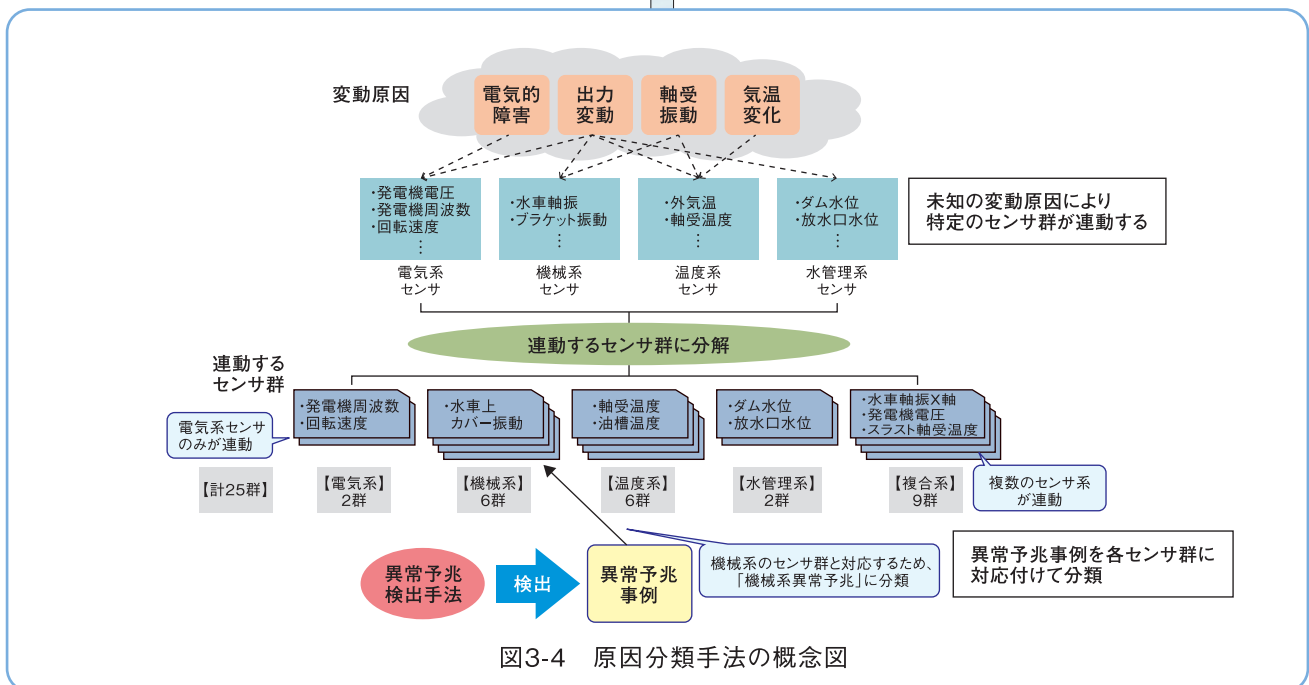


図3-4 原因分類手法の概念図

<参考文献>

- [1] 小野田, 伊藤, 是枝: 水力発電所における異常予兆発見支援方法の開発, 電力中央研究所報告R08030, 2009.
- [2] 村田, 篠原: 水力発電所の異常予兆発見に影響を与えるセンサの絞り込み方法の開発, 電力中央研究所報告R11019, 2012.
- [3] 村田, 篠原: 水力発電所運転データからの異常予兆の原因分類, 平成25年電気学会電子・情報・システム部門大会GS8-3, 2013.



ビッグデータと人工知能による電力設備診断

4.大量の送電線ビデオ画像を用いた送電線

電力会社では、電力を安定供給するために、送電線の損傷を早期に発見し修繕しています。損傷の早期発見のため、巡視用ヘリコプターによって点検したり、飛行困難な箇所では、カメラを搭載した観測装置を電線に走行させ、電線表面の状態をビデオに記録するなどして得た映像に対して、損傷の有無を目視確認しています。しかし、損傷箇所は多くないため、映像の殆どは健全な電線の画像となります。大量の単調な映像を長時間真剣に目視確認する作業は負担が多く、効率的な目視確認方法が求められています。

当研究所では、自走式点検装置で撮影された映像を対象に、あらかじめ画像中での損傷の色パターンを「機械学習」により計算機に学習させ、目視確認作業前に、「損傷を含んでいると考えられる画像だけを集約する手法」を開発しています。本章では、その手法の内容と実業務で活用可能とするために開発したソフトウェア(電線異常検出ソフト)について紹介します。

エネルギーイノベーション創発センター
上席研究員
石野 隆一



機械学習を利用した電線異常検出ソフトウェアの実行画面

上段は素線切れ(赤枠内)
下段は変形(緑枠内:素線1本が変形し、青線をはみ出している)を検出したことを示す

異常箇所の検出支援

4.1 電線点検の現状

送電線の不具合を見つけるために、ヘリを使った空撮映像による点検、ヘリによる空撮が不可能な地域では、カメラを内蔵した電線上を自走する自走式点検装置で撮影した映像による点検が行われています。具体的には、撮影した映像を目視確認し、溶痕、素線切れなどの損傷を発見しています。記録装置の制約により、映像の記録時間は80分ですが、その間上述のような異常はほとんどなく、目視確認作業は、健全な電線の映像を見続けるという単調な作業です。当研究所では、この作業を軽減するために、空撮映像を計算機に取り込んで、目視確認作業の前に、計算機が80分の映像中に損傷を含んでいると判定した画像だけを含むように編集した映像を作成するソフトウェアを開発しました(図4-1)^[1]。これにより、従来は10時間要していた目視確認時間を1/3に短縮できるようになりました。

一方、自走式点検装置(自走機)の多くは、図4-2に示す構造を持ちます。ヘリによる空撮映像は1本の電線が映るだけですが、自走機で撮影した映像は、1本の実像に加え2枚の鏡像により裏面が




図4-1 空撮画像映像を使った電線異常検出

映った計3方向面での電線が映る画像となるため、一度に複数面の電線を目視することにより、空撮映像以上に目視確認作業の負荷が大きくなります。ただ、空撮の場合と異なり、自走機映像ではカメラと電線の位置関係は常に一定です。そこで、当研究所では自走機で撮影した映像の特徴を活かした損傷検出手法を考案し、空撮映像と同様に、目視確認前に、損傷を含んでいると考えられる画像だけからなる映像に自動的に再編集するようにしました^[2]。

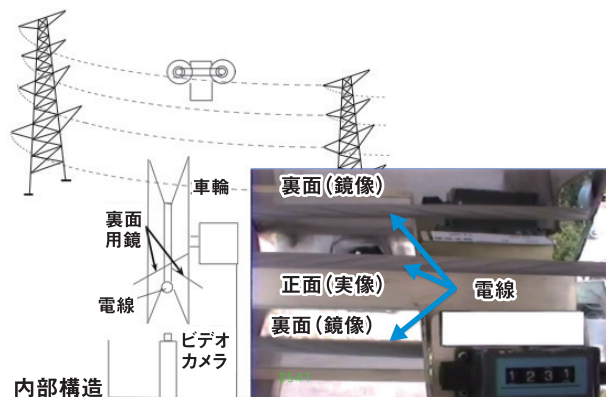


図4-2 自走式点検装置の構造と撮影画像

4.2 損傷および損傷以外の異常の検出

損傷は電線表面に傷を付けるため凹凸ができます(図4-3)。4.1節で述べたように、自走機の映像では、電線とカメラの距離が近く、電線表面の状態が空撮に比べ鮮明に見えるという特徴があります。その特徴を利用し、電線表面に凹凸があると、画像中の電線表面の明るさの変化傾向が単調でなくなることを利用して電線表面の損傷を検出する手法を開発しました。その上で4.1節で記したような損傷を含んだと考えられる画像だけを

残すように再編集するソフトウェアを実行させた場合、4時間分の映像が約5分に短縮できることを確認しました。

また、自走機のカメラと電線の距離は近いため、電線の変色も把握できます。実際、電線内部の腐食進行により、電線表面に腐食による白色の生成物析出が疑われる事例が得られました(図4-4)。電線を切断し、内部を観察すると腐食が進行した電線であることが確認できました。このことは、凹凸として表れる損傷検出に加えて白色個所の検出の必要性を示唆しています。

そこで、色パターンを手がかりに、異常の有無を検出する手法を新たに検討する必要がでてきました。当研究所では、これまで、錆の色の進行を「機械学習」で分類する手法を開発していたため^[3]、既開発の手法を拡張すれば、損傷固有の色、腐食生成物由来の白色、健全電線の3状態を分類することが可能となります。

正常ならば素線長手方向に沿って明るくなるため、明るさの変化方向は素線長手方向




図4-3 素線表面の凹凸検出による異常検出



図4-4 腐食生成物由来の白色と電線内部

4.3 「機械学習」による色パターンに基づく異常検出の可能性検討

本節で対象とする異常な色パターンとは、溶痕や素線切れに起因する黒色、腐食生成物による白色です。また、健全な電線の主たる色は灰色です。本検討では、一般的に用いられるR,G,Bの組み合わせではなく、色味をよりよく表現できるH,S,Vという指標^(注)を利用しました^[4]。対象とする画像を異常、正常を含むH,S,Vの組み合わせ(色パターン)で「機械学習」により求めました。試験用として用意した画像を対象に正しく判定できるか否かを調べることで、「機械学習」による色パターンに基づく異常検出の可能性を調べました。以下に、具体的な実験方法について記します。実験は3つから構成されています。

- ①実験データの作成
- ②異常な色パターンと健全な色パターンの学習
- ③異常な色パターンと健全な色パターンとの判別実験

①において、損傷由来(黒色)、腐食生成物由来(白色)の異常を含む画像から、各異常を含む領域と含まない領域を20画素×20画素の大きさで切り取ります。異常の色パターンを含む画像の大きさは種々あるため、一つの異常を含んだ画像から複数の画像を切り取っています(図4-5)。切り取ったデータのうち10%は検出実験用とし、残りの90%を②でのそれぞれの色パターンの学習に利用します(図4-6)。②の学習結果に基づき、検出実験用として用意した10%のデータが正しく判別できたかどうかを③で調べました。

結果を表4-1に示します。白色の色パターンと健全な色パターンでは、約91%の画像について正しく

(注)HSVモデル(英:HSV model)は、色相(Hue)、彩度(Saturation)、明度(Value)の3成分からなる色の指標

判別でき、黒色の色パターンと健全な色パターンでは89%の画像について正しく判別できました。なお、異常を含むにも拘わらず誤って正常と判別された画像は、他方の色パターン画像では異常として検出できているため、未検出が発生することはありませんでした。


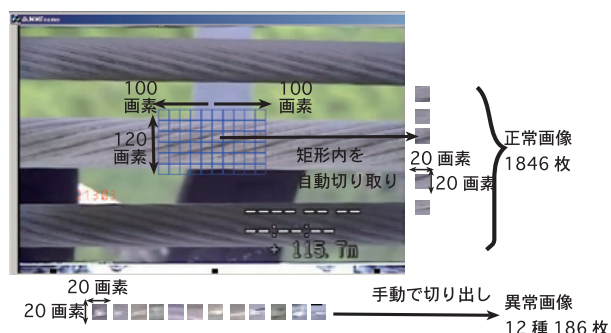


表4-1 判別実験の結果

	総枚数	正しく判別できた枚数	誤判別枚数	正しく判別できた枚数 / 総数 * 100 (%)
腐食生成物を含む画像	186	169	17	90.8
健全地線画像	1846	1742	104	94.3
損傷を含む画像	100	89	11	89.0
健全地線	1345	1331	14	98.9

4.4 自走機で撮影した映像を利用した機械学習による異常検出ソフトウェアの作成と実務への適用

4.1～4.3節の成果に基づき、実業務で記録されている映像(動画)に適用可能なソフトウェアを作成しました。本章のp.11の写真がその実行画面です。上段中の赤枠は素線切れを検出していることを示しています。また、色パターンだけでなく形状の変形検出も可能です。下段に示した健全な電線の輪郭は、画面中では直線(青線)となりますが、変形していると直線にならないため、その部分を検出し緑枠で表示しています。

本ソフトウェアにより、大量の送電線記録ビデオ中から、異常を含んでいると自動判定された画像だけを含んだ映像に再編集し、目視確認の必要なビデオ量を減らした結果、作業負荷の大幅な低減が可能となりました。

現在、電力送電線での実際の点検記録(25例)に適用し、電力各社の現場での実用化を推進するとともに、新たに自走機の導入を計画している電力会社での活用を可能とするため、技術協力を行っています。

<参考文献>

- [1] 石野, 上野: 空撮画像による架空地線点検作業量削減システム, DIA2008, 137-142, 2008.
- [2] 石野: 自走式点検装置で撮影した架空地線映像からの異常検出手法, 電力中央研究所研究報告R09016, 2010.
- [3] 篠原, 中島: 状態保全のための設備画像に基づく良否判定基準の自動生成手法, 電力中央研究所研究報告R10004, 2010.
- [4] 石野, 篠原, 大和: 架空地線を自走するカメラで撮影した画像への機械学習適用による地線異常検出の可能性, DIA2014, 107-112, 2014.

DEN-CHU-KEN
TOPICS

発行：一般財団法人 電力中央研究所 広報グループ

〒100-8126 東京都千代田区大手町1-6-1 (大手町ビル7階)

TEL:03-3201-6601 FAX:03-3287-2863

<http://criepi.denken.or.jp/>