

機械学習を用いた設備予兆保全～標準偏差管理と主成分MT法による予兆検出手法の確立～

Predictive maintenance of equipment using machine learning

荒木 直樹^{*1} 永田 陽介^{*1}
Naoki Araki Yohsuke Nagata

^{*1} PE部

1 はじめに

PE部は工場へ電気・都市ガス・エア・蒸気といった生産に使用するエネルギーの供給と排水処理を担当している。そのため、設備の故障は工場全体の生産阻害に直結し、生産設備と比べて影響が大きい。故障発生抑制のため、多くの工数をかけて日々点検や定期整備を行っているが、慢性的に設備故障停止が発生し生産を阻害している。一方で、社会情勢の変化や労働人口減少により生産性の向上が求められていることから、PE部ではデジタル技術を活用した設備の日常点検自動化や機械学習等による予兆保全の開発を進めデジタルツインの実現を目指している(図1)。

今回、標準偏差管理による常時監視によって人が行っていた点検をなくした事例と主成分分析とMT法を組み合わせた多変数解析によってベテラン技能者のように設備故障の予兆を検知した事例を紹介する。




図1 PE部のビジョンマップ
Fig.1 Vision Map of the PE Department

2 標準偏差管理

設備故障を防ぐ基本は日々の点検であり、メーカー推奨周期より毎日1～3回ほど人が実施していた。点検と点検の間は監視システム+監視カメラによるリモート監視を実施し、設備運転状態の把握と操作および故障発生後の復旧時間短縮に使用していた(図2)。そこで、センサを用いて点検項目を取り込み常時監視し点検品質を向上させながら点検をなくす方法を検討した。




図2 人が行う点検とセンサを用いた常時監視の違い
Fig.2 Difference Between Human Inspections and Continuous Monitoring Using Sensors

以下に具体的な方法を記載する。

2.1 センサの増設

規格値、環境仕様、設備運転状態を中心に、故障の経験やドメイン知識から必要な項目に対してセンサを増設した(図3)。なお規格値は超過すると設備が停止する値、環境仕様は設備を正常稼働させるための条件となる値を示す。




図3 センサ設置のイメージ
Fig.3 Image of Sensor Installation

2.2 しきい値の設定

正常状態かつ運転中の値を収集し $\pm 4\sigma$ を算出した。状況に応じて $\pm 4\sigma$ および最大値や最小値からしきい値を選択する(図4)。データを運転中に絞ることで管理幅が小さくなった。

名称	AC7 冷却水1	AC7 冷却水2	AC7 冷却水3	AC7 冷却水4	AC7 冷却水5	AC7 冷却水6	AC7 冷却水7	AC7 冷却水8	AC7 冷却水9
タグ	ND4_W20806	ND4_W20807	ND4_W20808	ND4_W20809	ND4_W20810	ND4_W20811	ND4_W20812	ND4_W20813	ND4_W20814
管理範囲	上限	175	33	170	33	40	38	43	
	下限	140	18	100	16	23	22	30	
遅延タイム	立上	600	600	600	600	600	600	600	
	通常	2	2	2	2	2	2	2	
規格値	上限	210	65	210	—	—	—	65	
	下限	—	—	—	—	—	—	—	
時間平均	平均値	157.5	26.9	94.3	26.0	33.6	29.0	38.2	-1.0
	標準偏差	3.4	1.4	23.6	1.7	1.8	1.4	2.1	0.0
	+4σ	171.2	32.5	188.6	33.0	41.0	34.5	46.6	
	-4σ	143.8	21.2	-0.1	19.0	26.2	23.4	29.8	
最大値		174.1	33.8	169.3	32.5	40.1	40.1	43.3	-1.0
最小値		0.0	0.0	0.0	0.0	0.0	0.0	0.0	

図4 しきい値を設定する際に必要な情報
Fig.4 Information Needed for Setting Thresholds

2.3 ノイズ対策の設定

設備の立ち上がり時と通常時の遅延タイムを設定し、ノイズ等による警報を防止した。立ち上がり後も設備が安定するまで数分かかる場合があるため、通常時の遅延タイムと分けて設定した(図5)。




図5 ノイズ等による警報の防止
Fig.5 Prevention of Alarms Due to Noise and Other Factors

これにより、常時監視となり点検品質が向上するとともに点検工数の削減が可能となる。

3 主成分MT法

標準偏差管理は項目単位での監視であるため、個々ではしきい値未満だが設備全体で評価すると異常が発生している場合に対応できない。そのため、設備の正常状態を総合的に判定するには多変数解析が必要と考えた。一般的な手法を比較すると、MT法は説明変数がおよそ10以上^[1]の場合やデータの相関が強い場合に多重共線性の影響によって精度が悪化し、One-ClassSVMやRNNはハイパーパラメータがあるため、教師なし学習の場合に設定が難しい欠点があった(図6)。

	多変数	予測時間	解釈性	実装性	Hyp	評価
MT法	2	3	4	4	無	18
One-ClassSVM	5	4	3	3	有	15
RNN	5	4	1	1	有	11
SARIMA	5	4	1	1	有	11

Hyp:ハイパーパラメータ、無は5点追加
図6 多変数解析 評価
Fig.6 Multivariate Analysis Evaluation

そこでMT法と主成分分析を組み合わせることで、欠点をなくした解析手法となる主成分MT法を、実機による疑似故障データを用いて説明する。

3.1 データの準備

今回使用するデータは、意図的にエア供給設備の冷却水用バルブを閉めていくことで、故障発生までの異常データサンプルを生成したものである(図7)。本来であれば、実際に発生した異常データを使用するが、十分に必要項目が計量されている設備において異常実績がなかったため疑似故障データを準備した。




図7 疑似故障データ
Fig.7 Simulated Fault Data

3.2 前処理

まずデータの中にある空欄や異常値を含む行を削除した。その後、エア供給設備が停止もしくは電動モータは運転し続けるがエアを圧縮しない状態のデータを削除し、エア供給設備が負荷運転中のデータのみ残した。無負荷運転中の故障は生産阻害に直結しないため除外とした。

3.3 解析

図8のように第一ステップでドメイン知識より説明変数を5個(回転、圧縮、空気、冷却、潤滑)の機能別グループに分けた。目的はMT法の弱点である説明変数がおよそ10以上の際に発生する精度悪化防止であるため、機能別グループ数は10個未満にする必要があった。なお、疑似故障データ取得のために操作した冷却水用バルブの機能別グループは冷却とした。また、外乱になる説明変数はグループ分けの時点で除外した。第二ステップで、各グループごとに主成分分析を実施した。このステップによって多重共線性の影響を小さくした。第三ステップで、算出した各グループと同じ次元の主成分得点同士でMT法を実施しマハラノビス距離を算出した。




図8 主成分MT法のステップ
Fig.8 Steps of Principal Component Analysis (PCA) MT Method

マハラノビス距離と各グループの主成分得点を図9に示す。図9より第二主成分と第三主成分はマハラノビス距離が上昇し続けているが、第一主成分のマハラノビス距離は途中で下降していることが分かった。このことから、各主成分ごとにマハラノビス距離を算出することが重要となった。




図9 マハラノビス距離と主成分得点
Fig.9 Mahalanobis Distance and Principal Component Scores

3.4 予兆結果

異常と判断するしきい値を一般解とされるマハラノビス距離4以上^[2]とすると、第二主成分において設備停止の45分前に予兆できた。また、各グループごとに算出した主成分得点グラフを見ると、意図的に操作した冷却水用バルブの機能別グループである冷却のマハラノビス距離に上昇がみられ、異常部位の特定も可能であり初動対応を素早く実施できると分かった(図10)。




図10 主成分MT法による予兆結果
Fig.10 Prediction Results Using Principal Component Analysis (PCA) MT Method

以下にフローを記載する(図11)。




図11 主成分MT法の全体フロー図
Fig.11 Overall Flowchart of Principal Component Analysis (PCA) and MT Method

3.5 One-ClassSVMとの比較

同じデータを使用してOne-ClassSVMとの予測時間を比較した。One-ClassSVMと主成分MT法の大きな違いは、ハイパーパラメータの有無で、主な項目は異常の割合を示すnuと決定境界の複雑性を示すgammaの2個である。今回使用したデータは教師あり学習であるため、主成分MT法よりも予兆時間が早くなるように、ハイパーパラメータを選定した。その結果、主成分MT法よりも15分早い60分前に異常を検出した(図12)。




図12 主成分MT法とOne-ClassSVMの予測時間比較結果
Fig.12 Comparison of Prediction Times between Principal Component Analysis (PCA) MT Method and One-ClassSVM

ただし、教師なし学習の場合、根拠を持ってハイパーパラメータを設定することが困難で、過検知や無反応になる可能性が生じる。よって異常データが無い場合には主成分MT法が有利となる。

4 標準化と今後の方針

4.1 標準化

前章で得られた知見から学習モデルの標準選

定フローを作成した。まずは主成分MT法とMT法のどちらかで解析し予測時間を確認、遅い場合にOne-ClassSVMを選択しハイパーパラメータを十分な予測時間が得られるまで調整するフローである(図13)。




図13 学習モデルの選定フロー
Fig.13 Selection Flow of Learning Models

4.2 今後の方針

故障予兆に一定の目途がついたため、今後は最適制御による安定安価なエネルギー供給および排水処理を目指す。特に排水処理にかかわる規制は厳しく基準遵守が第一優先のため、過剰な対応や設定となっている。また、処理水質の結果が出てから対応するしかない場合も多いことから、排水処理設備に対してセンサだけでなく画像認識を組み合わせたフィードバック制御を計画している(図14)。




図14 フィードバック制御
Fig.14 Feedback Control

並行して経済産業省が推奨するスマート保安^[3]に追従し保安点検の合理化を進める。具体的には、センシングとデータ解析によって保安レベルを向上させることで保安規程を見直し、月次および停

電点検周期延長を目指す。上記には、監督官庁へ申請が必要であるため技術検証を計画している。図15はスマート保安キュービクル(最新の技術を活用して遠隔で監視や点検ができる電気設備。現場への移動負担を軽減し、効率的な保守管理を実現するのに有効)のイメージ図となる。




図15 スマート保安キュービクル
Fig.15 Smart Safety Cubicle

参考文献

- [1]井出剛：入門 機械学習による異常検知、コロナ社、2015年、初版、P52
- [2]田口玄一：品質工学便覧、日刊工業新聞社、2007年、初版、P135
- [3]経済産業省 ニュースリリース

著者紹介



荒木 直樹

永田 陽介