

電気転てつ機モニタリング

Monitoring of motor point machine



新野 善行*



鈴木 雅彦*



小林 巧*

The motor point machine is very important equipment for train operation system. Failure of the machine is directly linked with transport disorder. Therefore, to prevent failure of the machine is desired. We examined some methods, in order to detect the signs of failure and to maintain the machine before failure occurrence. With some failure prediction methods by using the monitoring data from motor point machine, we constructed the analysis equipment, the test was carried out. As a result, we found to necessary of correction in the analysis result due to external factors.

●キーワード：電気転てつ機、モニタリング、転換不能、異常検出、要因解析

1. はじめに

1.1 背景と目的

転てつ機は分岐器を転換させることで、列車進路を構成する重要設備であり、図1に示すようにトングレールを左右どちらかのレールに密着させ、不正に動くことが無いように鎖錠(ロック)を行う。

分岐器の転換が不可能となる故障(以下 転換不能)は輸送障害に直結する。そのため、転換不能発生前のメンテナンスにより未然に防ぐこと、また転換不能発生時の早期復旧が望まれている。

現在、分岐器の転換には電気転てつ機が主に使われている。電気転てつ機は電気信号により制御され、モータの動力をトングレールに伝えることによって分岐器を転換させる装置であり、転換不能の発生時にはモータトルクなどが正常状態に比べて変動している傾向がある。例えば、異物介在による転換不能の場合はモータトルクが増大する傾向を示す。

本研究ではモニタリングデータを活用して、統計的数値解析(機械学習)を含む複数の論理について検討を行い、解析装置を構築した。また、解析装置の精度向上のため、営業線における実機での現地試験を実施し、転換不能の未然防止への有効性を検証した。




図1 分岐器の構成

1.2 ES II 形電気転てつ機の概要

ESII形電気転てつ機(図2)はサーボモータ採用による動作制御の安定化を図ると同時に、従来から多く使用しているNS形電気転てつ機の利点である歯車制御機構やリレー接点による状態出力などを取入れた、次世代分岐器用の電気転てつ機である。また、ESII形電気転てつ機は転換動作をモニタする機能を備えており、転換時にトルク・ストロークなどのデータを自動記録している。



図2 ES II 形電気転てつ機

2. 異常検出に向けた解析手法の概要

これまでの研究において、ESII形電気転てつ機のモニタリングデータを解析することで、転換不能発生前の異常検出の可能性を検討してきた。ここでは、トルク変化解析、ウェーブレット解析、密度比推定、1-classSVMについて、それぞれの解析手法について概要を説明する。

2.1 トルク変化解析による異常検出

2.1.1 トルクピーク値の監視

図3にESII形電気転てつ機における転換時間とトルク値の関係を示す。トルク値は電流から換算した値となっており100(%)は定格電流での動作を意味している。トルクピーク値の監視は転換時間におけるトルクピーク値をあらかじめ設定した閾値と比較し、閾値を超えた場合は異常と判定する。




図3 トルクピーク値の監視

2.1.2 トルク平均値からの変化量監視

過去の転換からトルク平均値を求め、検証するトルクデータと比較し変化量を求める。閾値はトルクピーク値の監視と同様にあらかじめ設定する。変換量を閾値と比較し、閾値を超えた場合は異常と判定する(図4参照)。




図4 トルク平均値との変化量監視

2.2 ウェーブレット解析とベイズ推定による異常検出

ウェーブレット解析は転換トルクデータをウェーブレット変換することによって微細な波形の違いを検出する手法である。学習データとしてあらかじめ用意した過去の正常データをウェーブレット変換し、特定の周波数成分のスカログラムを切り出し、正常時スカログラムの分布範囲から閾値を算出する。検証データにおいて閾値からの逸脱量を周波数成分ごとに算出し平均値を計算する(図5参照)。

そして、ウェーブレット解析から求めた逸脱量を用いてベイズ推定により正常と異常を確率的に推定する。また、算出された正常および異常確率を用いてベイズ更新することで、各電気転てつ機の個体差に応じて、異常検出の精度を向上させることができる。

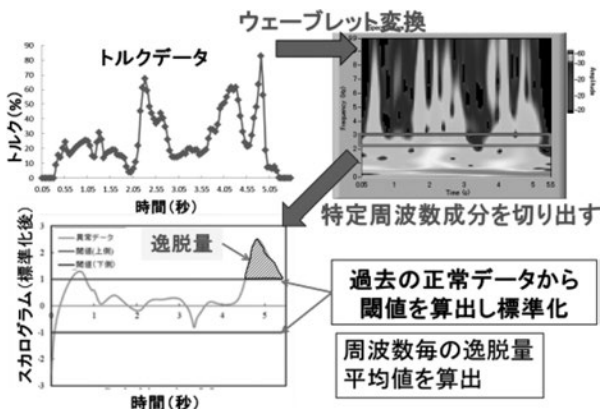


図5 ウェーブレット解析

2.3 密度比推定による異常検出

密度比推定は、正常データの確率密度分布と検証データの確率密度の比を見れば、検証データに異常データが含まれるか否か検知できる性質を利用した手法である。図6のように、正常データの確率密度分布と検証データの確率密度分布の比を取ると、正常データの分布では見られない検証データの分布の範囲で密度比が1から大きく外れ、異常が見られるということが明確に表れる。あらかじめ用意した学習データから直接密度比を算出し、検証データに対する密度比が定められた閾値を上回れば正常、下回れば異常と判定する。

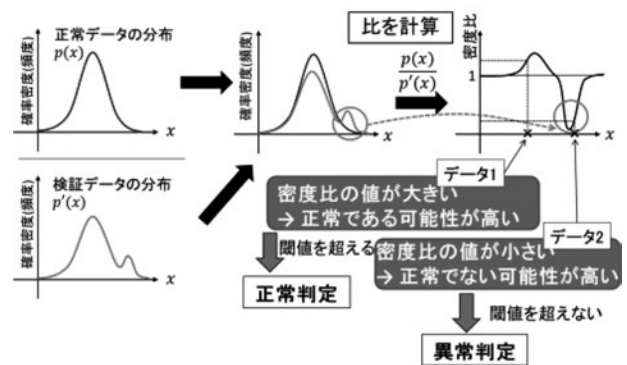


図6 密度比推定

2.4 1-class SVMによる異常検出

1-class SVM (One Class Support Vector Machine) は元の空間にある正常データを特徴空間に写像し、「離れている」データを異常データとして扱い、境界を設定して異常検出を行う手法である。あらかじめ用意した学習データを基に正常な範囲を設定し、検証データが正常範囲にあれば正常、外れていれば異常と判定する(図7参照)。




図7 1-ClassSVM

3. 解析手法における論理の検証

各手法の論理を解析装置として組み込むにあたり、正常な転換データを異常データと判断してしまうという課題が出てきた。そこで本章では学習データに着目し、その課題解決手法について検討した。

3.1 学習データの定期的な更新

密度比推定など機械学習を用いる際、正常な転換データ学習データを作成する必要があるが、転てつ機の経時的な変化により正常データの傾向が変化する場合がある。そこで学習データを1か月ごとに定期更新することで経時的影響を受けることはないと考え検討を行った(図8参照)。




図8 学習データ更新例

定期的なモデル更新の実施の有無の違いを図9に示す。横軸は時間を表し、正常データを異常データと判定した場合は濃い線で表現される。モデル更新を実施した場合は、異常判定数は色が薄くなり正常データを正しく判定していることがわかる。




図9 モデル更新実施の有無による異常判定の違い
(上:未実施、下:実施)

3.2 データの位置合わせ

これまでの転てつ機の動作指示のタイミングで位置合わせを行っていたが、転てつ機の内部機構の処理時間に誤差が生じるとデータに時間的なずれが生じる。時間的なずれを補正せずに解析すると、全く同じ波形でも異常と判定してしまう。ずれが発生しているのは、ストローク開始前の内部処理部分であるため、ストローク開始位置によってデータの位置合わせを行った(図10参照)。




図10 データのずれ

位置合わせ実施の有無の違いを図11に示す。位置合わせを実施しない場合と比較すると、異常判定数は減少していることがわかる。




図11 位置合わせ実施の有無による異常判定の違い
(上:未実施、下:実施)

4. 営業線の実機への現地試験の実施

各手法の論理が組み込まれた解析装置を試作し、営業線に試行導入している。システム構成を図12に示す。機器室に以前から設置されているモニタ装置を解析装置として改修し、結果の異常検出情報は事務所に既存してある監視装置にデータ伝送しモニタリングできるように改修した。




図12 システム構成

4.1 試行導入後の状況

試行導入後、各解析論理を組み込んだ解析装置については、故障や異常解析などは発生せず、順調に機能している。また、試行導入以降(2015.12~2016.5時点)、転換不能となるような異常転換は発生していないものの、いくつか異常と判定された。異常検出状況を解析した結果、転てつ機の違いによって異常検出に差があることが分かった。この原因は、現場では正常に転換されているにもかかわらず、異常と解析されるためである。以下に、トルク変化解析と1-class SVMの異常検出の例を示す。

4.2 トルク変化解析による異常検出結果

図13にトルク変化解析による異常検出結果を示す。横軸は年月日、縦軸は異常検出の総数を表している。解析開始以降、異常検出が頻発していたが、これは図14のような一般的な転換におけるトルク波形には見られない、図15のよう




図13 トルク変化解析による異常検出結果




図14 一般的なトルク波形




図15 当該転てつ機のトルク波形

な特有なトルクピークが発生することが原因であると分かった。これは、当該の分岐器の特徴により一時的にピークが生じるためであったが、このピークがすぐに転換不能につながるものではないため、試行期間中にパラメータ（一時的なピークの変動値）を修正した。その結果、パラメータ修正後は図13のとおり、異常検出の回数が減少した。

4.3 1-class SVMによる異常検出結果

図16に1-class SVMによる異常検出結果を示す。横軸は年月日、縦軸は異常検出の総数を表している。解析開始以降、異常検出の回数は少なかったが、4月中旬に一時的に異常が頻発した。これは、分岐器のレール交換を実施したため、転てつ機のトルク波形に変化が発生し、異常と判断されたと推測される。

また、図16とは異なる転てつ機においても、降雨・降雪による気候変化や周囲の温度変化によって、異常検出が一時的に増加することが確認された。




図16 1-class SVMによる異常検出結果

レール交換や気候変動のような外部要因により異常検出が増加した場合は、転換データが学習データと異なる波形になることが考えられるため、学習データを更新させることで、異常は検出されにくくなる。

4.4 考察

解析装置の試行導入により、解析装置自体は問題なく稼働しているものの、分岐器や転てつ機自体に問題は無いにもかかわらず個体差や周囲環境によって、一時的に異常を多く検出することがある。

トルク変化解析については、転てつ機の通常の転換状態を把握しパラメータを適正に設定することが必要であることがわかった。また、1-class SVMについては、分岐器のレール交換や気温変動や保守作業などの外部要因変化に伴って学習データを更新することの有用性が確認された。

以上より、これまでの営業線の実機への現地試験の実施の結果、個体差に応じたパラメータの設定手法や学習データの期間など、異常検出手法の深度化をさらに行うことで、転換不能の未然防止に向けた意思決定の材料として有効であると考えられる。

5. まとめ

ESII形電気転てつ機のモニタリング機能を活用して、転換不能の異常検出を行うため、各手法について実機データを用いて検討を行い、実用化の可能性を検証した。その結果、各解析手法において概ね良好な結果となった。しかしながら、正常データを異常と判定してしまう課題があることが分かった。なお、これらの課題については、異常検出の状況を把握し対処することで、精度向上につながることも分かった。今後は現地試験のデータ解析を行いながら、個体差、外部要因、学習データの期間、そして各解析論理の有効性や複合的な利用方法について検討を行い、より精度向上を図ることで、意思決定の材料として有効になっていくと考える。

また、ESII形以外の転てつ機についても、同様なモニタリング機能を活用させ、転換不能の異常検出を行うことを検討している。

参考文献

- 1) 新野善行・鈴木雅彦・小林巧：「電気転てつ機の故障予兆検出論理の実用化に関する研究」, 電気学会全国大会 (2016)
- 2) 樋口博俊・鈴木雅彦・加藤尚志：「転てつ機モニタリングデータを用いた故障予測手法に関する研究」, JR EAST Technical Review, No.48 (2014)
- 3) 小幡信夫・森健司・市倉庸宏：「次世代分岐器対応新型電気転てつ機の開発」, JR EAST Technical Review, No.32 (2010)