

スマートメンテナンスの取組状況について ～データの利活用～

The current status of our efforts to realize smart maintenance

久田 斗志^{*1}

Toshi HISADA

Director of Technical Center, Research and Development Center of JR East Group



Abstract

Transformation of maintenance of railway infrastructure and rolling stock is one of the main challenges JR East Technical Center faces. In recent years, we have been promoting the smart maintenance through the introduction of Condition Based Maintenance and mechanization, and are working to improve the efficiency and reduce the maintenance cost as well. This paper introduces our data utilization efforts toward the realization of smart maintenance.

●**Keywords:** Smart maintenance, Condition based maintenance, Image analysis, Data analysis

*1JR東日本研究開発センター テクニカルセンター 所長

1. はじめに

テクニカルセンターでは1991年4月の発足以来30年間、メンテナンス業務の変革に取り組んでいます。

2020年以降、新型コロナウイルス感染症拡大の影響により、人々のライフスタイルや働き方が大きく変化し、当社は輸送サービス需要の大幅な縮小を経験しました。安全の確保を第一の前提としつつ、ポストコロナ社会におけるお客さま需要の変化に対応できる、より柔軟なコスト構造への「変革のスピードアップ」が求められています。また、労働人口減少という社会的課題に対し、2035年には生産年齢人口が2015年比20%減少すると予想されており、将来にわたってメンテナンスの従事者を確保していくことが次第に困難になることが見込まれます。当社を取り巻く大きな環境変化を踏まえ、今後も当社が抱える膨大なインフラを維持し、より効率的なコスト構造へ変革させるためには、生産性や質の高いメンテナンスを実現し、合わせて設備の安全性・信頼性を向上させることが求められています。テクニカルセンターではCBM導入や機械化を通じたスマートメンテナンス構想を推進し、メンテナンスの効率化、コスト削減に貢献するべく取り組んでいます。本稿では、スマートメンテナンス構想実現に向けた、データ利活用の取組みについて概要を紹介します。

2. スマートメンテナンス

一般的なメンテナンスでは「データ取得」、「データ分析」、「意思決定」、「施工」、「評価」のサイクルを回します(図1)。これまで当社では、長年の実績や故障事例に基づき設定された期間で検査・補修を行う「時間基準保全(TBM: Time Based Maintenance)」が広く採用されてきました。TBMを採用する場合、メンテナンス実施の管理が容易である一方で、対象設備の使用頻度や劣化状況に関係なく一定期間で検査・補修を行うことから、過剰な実施内容となる場合があります。

近年のセンシング、IoT技術の進歩に伴い、高頻度・広範囲の計測データ収集が可能となり、大量の取得データをもとに、機器の状態に基づく最適のタイミングでより効率的な補修を行う「状態基準保全(CBM: Condition Based Maintenance)」が注目されています。CBMの実現に向け、「データ取得」についてはこれまでの開発を経て、設備の状態を監視する大量のデータを取得する

ことが可能になってきています。「データ分析」についても取組みを強化し、設備状態の自動診断や将来予測を行うべく研究開発を進めています。



図1 メンテナンスのPDCAサイクル

3. CBM導入に向けた考察

CBMを導入するにあたって、CBM導入の効果について考察します。一般的に設備の故障モードは、設計・仕様・製造・取付方法などのミスや公差による初期故障、安定稼働期における偶発（突発）故障、環境条件や繰り返し使用などによる腐食や劣化、摩耗等による劣化故障という大きく3つの分類に分けられます。このうち初期故障と偶発故障については、通常のメンテナンスや検査において発見しづらく、CBMや従来のTBMに限らず検査・修繕の計画的な業務構築には向かない故障モードとなります。よって、ここでは計画的なメンテナンスの対象として劣化故障について考察することとします。

設備の劣化については、性能やパフォーマンスに対して一般的に「劣化曲線」を用いて説明されます。図2は劣化曲線の例を示したのですが、「緩やかに劣化が進む期間」、「劣化加速期」、「劣化が進行し所要の機能・性能を満たさなくなる時期」が存在します。この図における「緩やかな劣化期の性能低下の傾き」、「劣化加速期への移行時期」、「劣化加速の程度や故障までの期間」などは設備や部品それぞれの特性や環境・使用条件によって変わってきますが、これらの特性と時期を把握したうえで適切に検査・補修を行うことがメンテナンスの効率化・合理化に繋がります。これらの劣化曲線の特性や期間、管理値などが明確になっており、かつ個体によって差がほとんど出ない設備や、同じ環境下に同一のものが多く設置されている設備については、補修の時期が予め高い精度で推定できることとなり、従来のTBM的なメンテナンスでも十分に機能するといえます。一方で、個体差や環境・使用条件によって劣化曲線に大きな変化を生じる設備については、高頻度なデータ収集によって設備状態を把握するCBMの効果が出やすくなります。

TBM、CBMに関わらず適切なメンテナンスを行うためには、性能劣化やその加速を検出可能な、若しくはそれを支配する幾つかのパラメーター（特徴量）を特定し、故障までの期間に補修ができるタイミングで検出することが必要です。一部の設備では劣化の程度を測定する項目や補修管理値が設定されていますが、ほとんどの設備ではパラメーターの特定や管理値、劣化故障の限界値が解明できていません。また従来、人の経験に頼った外観検査で実施してきた設備に関しては特に、検査の数値化や判定の明確化ができていないものも多く、本質的に数値化が難しいものもあります。現在は将来的なCBM構築のために、高頻度・広範囲・高精度なデータを取得してパラメーターや管理値の明確化に向けた研究に取り組んでいるところです。

一方で我々は経験則から、重要な設備でかつ劣化故障時期が推定しづらい設備については、できるだけ冗長化・二重化をおこなってきています。もちろん、設備の設置箇所や環境面、経済性などの制約から、必ずしも冗長化されているとは限りませんが、一定の未稼働時期が許容される設備や、多数の同等設備で機能を有している設備（必然的に冗長化されている設備）については、多くの場合で事後保全（故障後の補修）となっており、結果的にCBMが導入されているといっても過言ではありません。

これらのことからCBM導入に最も効果が高いのは、環境・使用条件によって劣化傾向に差がでる比較的大きな設備でかつ冗長化・二重化できない設備であるといえます。個別管理に適さない小さな設備や部品や冗長化・二重化されている設備については、無理なデータ収集や数値化にこだわるのではなく、ロット管理・サンプリング検査にするなど、それぞれに適切な検査手法を模索することも検討すべきと考えられます。

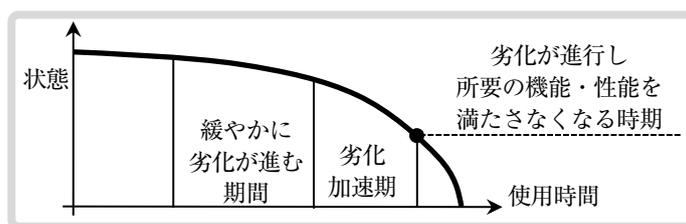


図2 劣化曲線の例

4. データ分析へのAIの導入

近年、膨大な取得データ(ビッグデータ)に対するデータ分析で、AIの活用が実用化されてきており、深層学習(ディープラーニング)による、画像認識・音声認識の分野ですでに人間の認識能力を超える事例も現れてきています。数十から数百以上の高次元のデータをもとに分析する手法を選定した場合、機械が導き出したルールを人間が理解することが困難、かつ学習過程自体も理解できない、いわゆるブラックボックス化が起きます。ブラックボックス化した分析手法でも支障がないと考えられる課題に対しては、効率的・高速な処理が期待できますが、メンテナンス実施要否の「意思決定」を行うにあたり、何を根拠にAIが判断・予測したか、根拠明確化の必要性に対する考察が必要となります。また、適切な回答が得られる深層学習を行うためには、大量かつ正確な学習データ群を用意する必要がありますが、対象となる学習データを集めるために膨大な労力を要する場合があります。加えて、与えた学習データ群に含まれていないような場面に対しては、適切な回答が出来ない可能性を含んでいます。

こうしたことから、深層学習はデータ分析の非常に有用な手段となり得ますが、解決課題に対する適切な手法を選定する必要があること、どの場面においても適切な回答が保証できる万能の手法ではないことを理解したうえで、運用場面を想定した開発を進める必要があると考えられます。

5. 画像解析の適用事例

ここでは画像解析の適用事例を紹介します。画像解析では一般的に、取得画像に対して上下振動・速度変化による伸縮の補正、エッジ抽出に代表されるような特徴抽出を行った後、補正画像の中から目標とする対象物の照合を行います。照合には、プレートマッチングのようなパターン認識による方法、AIの機械学習から導出された画像認識モデルによる方法などがあげられます。

(1) 車両外観検査装置

作業者の目視により行われてきた車両の外観検査を、画像処理技術を用いて代替する「車両外観検査装置」の開発に取り組んでいます。撮影装置にはラインセンサカメラを使用し、25km/h以下で入換運転する車両の床下側面、床下直下などを、地上固定されたカメラから撮影します。車両の上下振動・速度変化による伸縮の補正を取得画像に行い、補正画像から抽出したエッジとあらかじめ記憶している基準画像のエッジを比較し、差分がある場合には異常と判定します。これまでに、床下側面のカメラから撮影された機器取付ボルトのゆるみ、機器点検フタ固定ハンドルの変位、空気ばね高さ調整棒受けの変位では、必要な異常検出精度を達成しており、現在、床下直下の取得画像から異常判定する方法の開発を進めています。

(2) 画像式パンタグラフすり板測定装置

在来線車両のパンタグラフのすり板の厚さ管理に使用されてきた測定装置には、従来超音波センサが使用されてきましたが、高コスト・悪天候時のすり板検出率が低下する課題がありました。新たに撮影装置としてステレオカメラを使用した画像式の測定装置を開発しました。超音波式と同程度の計測精度を持ち、維持コストの面で優位となる装置とし、現在は実導入されています。

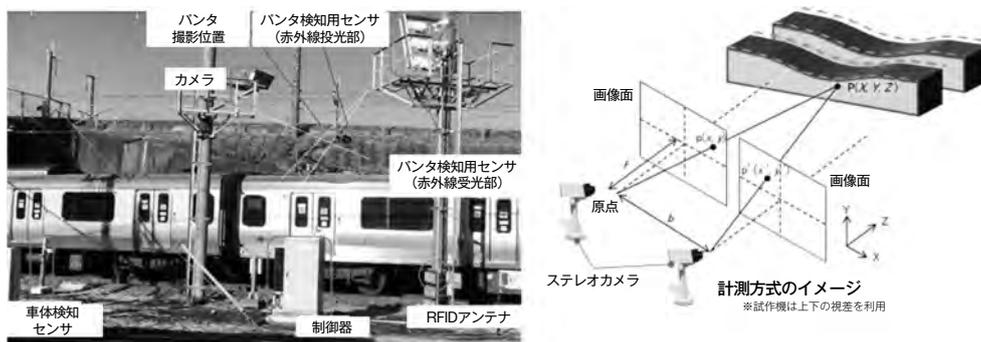


図3 画像式パンタグラフすり板測定装置

(3) 架線設備モニタリングシステム

線路に載せた高所作業車を使用して電車線設備の外観検査を行う「至近距離検査」を、当社では1年に1回実施しています。これを撮影画像による検査に置き換えるため、検測車 (East-i) の屋根上に搭載したラインセンサカメラにより画像取得する架線金具検査装置を開発しました。大量の取得画像のすべてを検査者が確認するのは大きな労力を要するため、AIによる自動診断で正常な金具を検出し確認対象から外すことができるシステムの開発を行いました。自動診断処理は、取得画像から架線や金具を検出するフェーズ、検出した架線や金具の正常・異常を判定するフェーズの2つに分かれており、いずれも深層学習による処理を行っています。

(4) 線路設備モニタリング装置

在来線の線路の軌道変位やレール締結装置などの脱落を遠隔監視する装置として、営業車の車体に搭載可能な「線路設備モニタリング装置」を開発し、2020年度末までに50線区、当社の線路延長の約70%をカバーする範囲に導入してきました。線路設備モニタリング装置は「軌道変位モニタリング装置」、「軌道材料モニタリング装置」で構成されています(図4)。「軌道変位モニタリング装置」は、ジャイロ、加速度計およびレーザ変位計を使用して、慣性正矢法(低速走行時は差分法を併用)により軌道変位を測定します。「軌道材料モニタリング装置」は、軌道材料の写真画像を撮影する濃淡画像撮影装置(ラインセンサカメラ)、レール近辺の標高情報を取得するための距離画像撮影装置(プロファイルカメラ)から構成され、取得された距離画像からレール締結装置、継目板ボルトの異常状態の自動判定を行います。

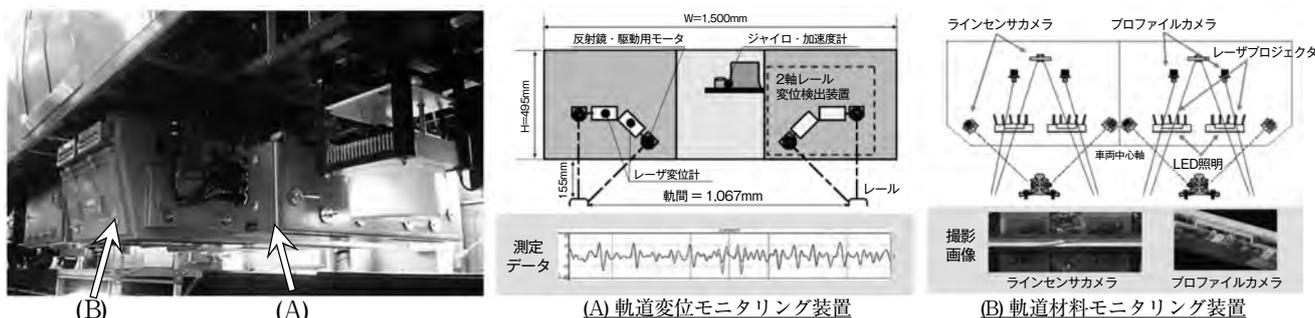


図4 線路設備モニタリング装置

(5) 軌道回路送着ボンドモニタリング装置

軌道回路送着ボンドや踏切制御子送着ボンドは、機器劣化に伴う脱落が発生すると、輸送障害への直結や、踏切が鳴動し続け踏切通行に支障を及ぼします。当社では、首都圏では年3回、そのほかの地域では年1回の目視検査を実施しており、作業可能時間帯が営業列車の走行しない夜間に限られることもあり、負担の大きいことが課題でした。「軌道材料モニタリング装置」(5項(4)参照)で取得された撮影画像を元に、画像処理技術やAIによる機械学習を用いて、送着ボンドを画像から自動抽出し、正常・異常の判定を行う「ボンドモニタリング装置」の開発に取り組んでいます。

6. 数値データの分析の適用事例

ここでは数値データ分析の適用事例を紹介します。モニタリングされたデータから異常状態を判定するためには、多くの場合、取得データに何らかの前処理を行い、特徴量を抽出する手法が用いられます。精度の高い異常の判定・予測を行うにあたり特徴量の設計は重要であり、対象設備の運用中の知識の活用、理論や経験を踏まえた設定がポイントとなります。対象設備間での特徴量の比較や、統計的なしきい値の設定により異常を判別するシンプルな手法を採用した場合、何を根拠に判断・予測したか理解が比較的容易で、導入事例の多い検知手法と考えられます。また、異常の予測にあたっては、AIの機械学習による判定手法も開発されています。

(1) E235系モニタリングデータの有効な分析方法の開発

E235系車両では、特定のサンプリング周期でドア装置、コンプレッサ、空調装置、主回路制御、列車情報管理装置などの運転状況の連続的なモニタリングデータを記録しています。本開発では、少量のデータに対して現車試験やモックアップ試験を活用し、有効な分析方法を設計・検証する第1段階と、現車から取得される大量のデータに対して、分析手法の有効性を確認する第2段階の2つに分けて、データ分析方法の開発を進めています。ドア装置のモニタリングデータの例(図5)では、ドアの開閉動作抵抗の増大を検出するために、モックアップ試験装置での試験で、開閉動作時の平均電流値が特徴量として有効であることを確認し、第2段階の現車での有効性確認を進めています。大量データを迅速に分析するため、入力データはデータベース化し、データ処理はサーバ上で実施、処理後のデータはBIツールにより可視化する分析環境を構築しています。これにより、運用中の車両搭載機器の状態がリアルタイムで確認可能となり、機器の状態評価からメンテナンスのタイミングと内容の判断を可能としています。

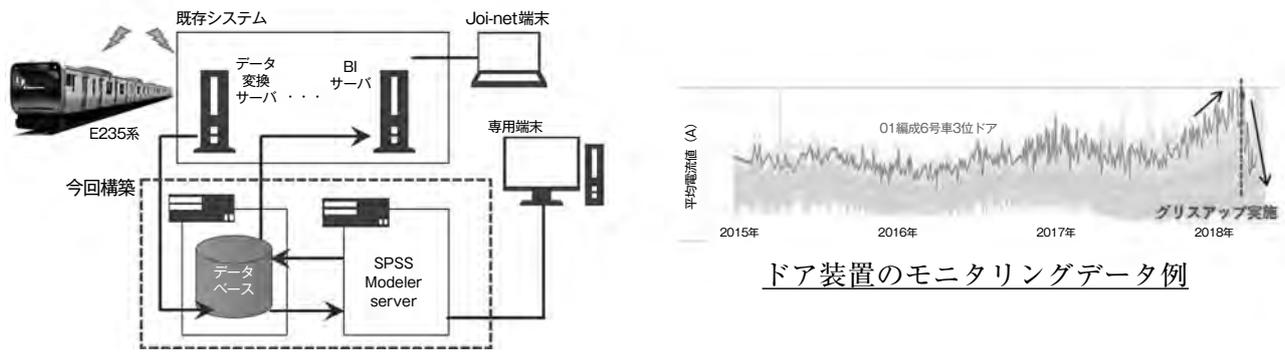


図5 E235系モニタリングデータの分析環境

(2) 変電設備の異常音検知

現地で変電設備の健全性確認を行う「保全巡回検査」の項目の一つである「異音の有無」を自動的に判断するツールとして、変電設備を構成する変圧器や遮断器などの機器動作音を集音・解析し、音の変化から機器の状態を把握する開発を進めています。本開発では、取得された音響データを周波数解析して得られたスペクトログラムをもとに特徴量抽出を行います。あらかじめ健全状態の機器から動作音を集音、その特徴量から正常・異常の判別境界を作成し、機器を運用中の動作音から抽出された特徴量が判別境界を逸脱した場合、異常と判別します。

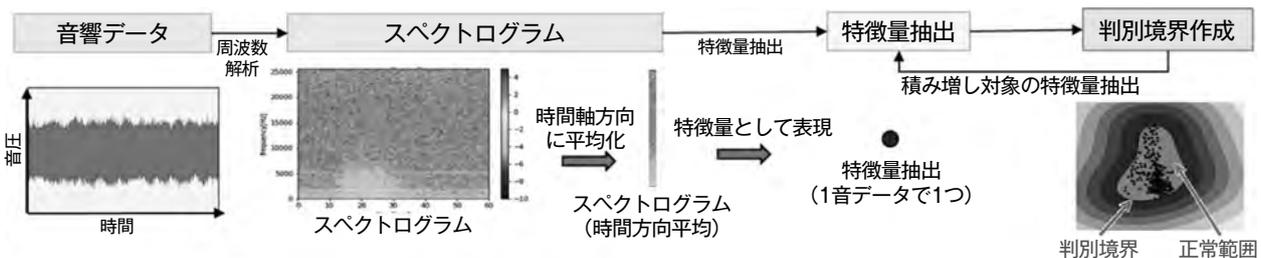


図6 変電設備の異常音検知

(3) 線路設備モニタリング装置 (CBM支援システム)

線路設備モニタリング装置 (5項 (4) 参照) で高頻度で取得された軌道変位データを活用し、保守管理を支援するCBM支援システムの開発を進めており、主に以下の機能を有しています。

①軌道変位予測

軌道変位の進みが大きな箇所を抽出し、過去の推移から整備目標値や整備基準値に到達する日を統計的に予測します。予測手法にはベイズ推定を活用し、急激な変化にも対応した予測結果を得ることができます。

②マルチプルタイタンパ (MTT) 計画支援・施工後評価

線路補修用大型機械のMTTの使用の効率化を目的に、軌道変位の状態や、機械運用などの条件を加味したうえで、軌道状態が最適となる保守計画 (最大1年) を作成します。また、施工前後の軌道変位データから箇所・線区・作業別の軌道変位の標準偏差の改善度合いが確認でき、施工結果の評価を可能としています。

③列車動揺管理支援

列車上下動揺と高低変位の線形依存性を利用して、取得された高低変位から列車上下動揺の推定及び任意の位置における将来の列車上下動揺を予測する機能です。これにより、列車上下動揺の超過箇所に対する計画的かつ抜本的な修繕を支援します。

(4) ESII形電気転てつ機のモニタリング

ポイント故障は輸送障害に直結するため、ポイントを制御する電気転てつ機の転換不能を未然に防ぐことが求められています。次世代分岐器用の電気転てつ機として開発された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、転換時のトルクストロークなどのデータの特徴量として自動記録しています(図7)。取得されたデータを用いて、トルクの急変を捉える「トルク変化解析」、トルクの全体的変化を捉える「密度比推定解析」の2つの機械学習を行い、転換不能の予兆検知をしています。

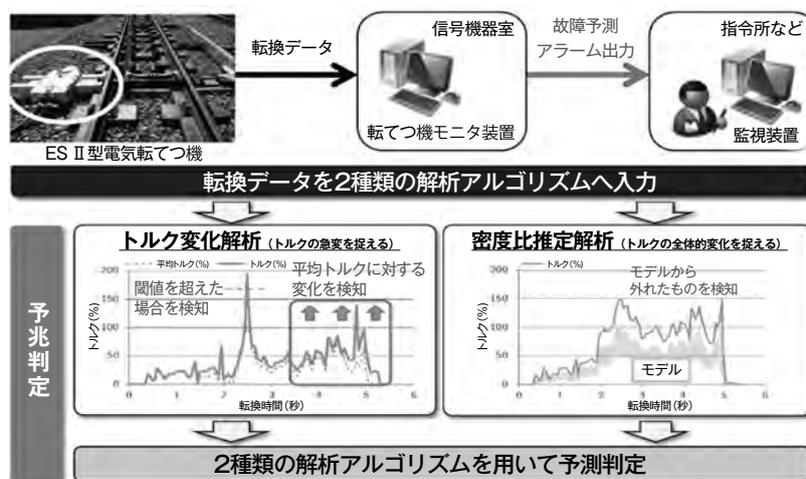


図7 ESII形電気転てつ機のモニタリング

7. おわりに

新型コロナウイルス感染症拡大による輸送サービス需要の急激な変容、生産年齢人口の急激な減少に代表されるように、鉄道を取り巻く環境は目まぐるしく変化しています。それらに柔軟に対応して、鉄道というインフラを持続的に維持、発展させていくためには、メンテナンスの変革が必要不可欠です。我々は、オープンイノベーションで世の中の先進的な技術を積極的に求めるとともに、ユーザーニーズ主導でスピード感をもって、新たな仕組みの開発、実務への展開を進めてまいります。関係の方々の引き続きの御指導、御支援をよろしく願いいたします。