

# 道路設備の故障予兆把握手法

坪井真也\*  
藤野友也\*\*

Fault Prognosis Technique for Road Facilities

Shinya Tsuboi, Tomoya Fujino

## 要旨

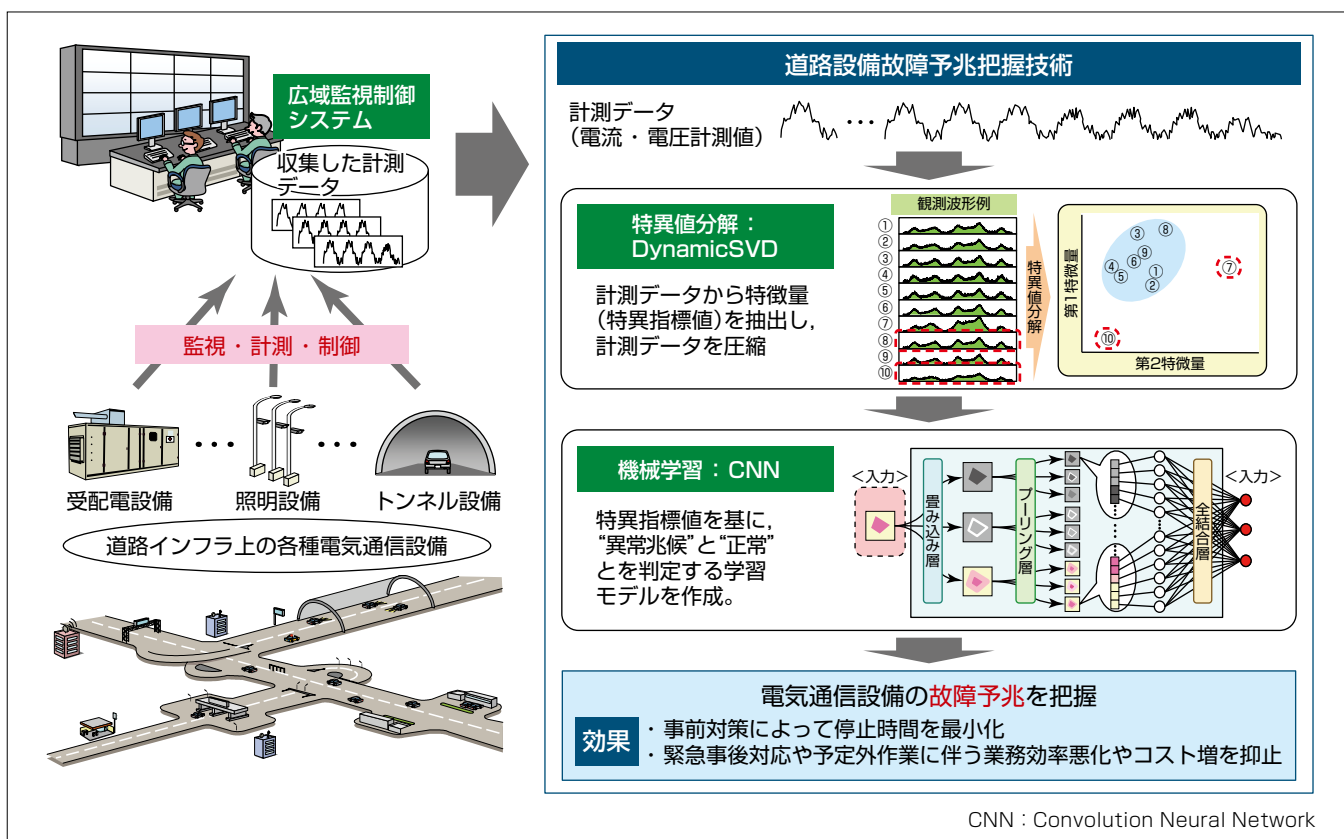
道路インフラでは、円滑な道路交通の提供や安心・安全の確保を目的として、道路照明、情報板を始めとする情報提供設備、トンネル防災のための換気設備や非常用設備、それら設備に電力供給するための受配電設備等の電気通信設備が整備されている。電気通信設備は24時間365日安定した運用が求められる設備であり、システム停止による社会的影響は大きい。よって設備障害が発生した際には迅速に対応し、システム停止時間を最小化する必要がある。

一方で、働き方改革や熟練技術者の高齢化、人員不足の観点から設備運用や設備保全業務の効率化も求められている。

三菱電機ではこれらの課題を解決する技術として“道路設備故障予兆把握技術”の開発に取り組んでいる。道路設

備故障予兆把握技術によって電気通信設備の故障予兆を事前に把握することで、故障発生前の調査・体制確保等の対策によるシステム停止時間最小化や、突発対応や予定外作業に伴う業務効率悪化・コスト増の抑止が期待できる。

道路設備故障予兆把握技術では、維持管理コスト効率化の観点から、故障予兆把握に特化した専用のセンサを新たに導入するのではなく、既存の広域監視制御システムの計測データを活用した手法を目指している。またデータ解析技術として、当社独自の高速の特異値分解技術であるDynamicSVD(Dynamic Singular Value Decomposition)や、機械学習技術を用いることで、計測データが異常兆候を示すか否かを判定する。



## 道路設備の故障予兆把握手法のイメージと適用効果

広域監視制御システムで収集する計測データを活用し、道路上の電気通信設備の故障予兆を把握する手法の開発に取り組んでいる。電気通信設備の故障予兆を事前に把握することで、故障発生前に調査や体制確保等の対策を講じることができ、重要設備である道路上の電気通信設備についてシステム停止時間の最小化が期待できる。また、突発的な対応や予定外作業による業務効率悪化・コスト増の抑止が期待できる。

1. ま え が き

道路での電気通信設備には道路照明、情報板を始めとする情報提供設備、トンネル防災のための換気設備や非常用設備、それら設備に電力供給するための受配電設備等様々な設備があり、これらの設備がインターチェンジやトンネル、路側等に多数整備されている。道路設備故障予兆把握技術は、これら道路での電気通信設備の故障予兆を事前に把握するための技術である。

設備の故障予兆を把握するためには、対象設備の稼働状況や周囲環境等を詳細にセンシングすることが有効であるが、道路上の多数の電気通信設備に対し、故障予兆把握に特化した新たなセンサを取り付けることは、維持管理コスト効率化の観点から望ましくない。よって道路設備の故障予兆把握手法では既存の計測データやシステムを活用した手法を目指す。

道路設備故障予兆把握技術の実現に向け、電気通信設備のうち、道路照明等の各設備に電力を供給する受配電設備の故障と計測データに着目し実現手法の検討を行った。本稿では検討した実現手法について述べた後、この手法を構成する要素技術、また実運用データによる検証結果について述べる。

2. 道路設備の故障予兆把握手法

2.1 広域監視制御システムの計測データの活用

今回の手法では既存の広域監視制御システムで収集する計測データを活用し、故障予兆の把握を行った。

広域監視制御システムは、道路を始めとするインフラ上に多数かつ広域に配置された設備の運転状態等を、遠隔からリアルタイムに監視・計測・制御することで、インフラの安定した運用を支援するシステムである(図1)。当社で




図1. 広域監視制御システムのイメージ

は道路や河川分野を中心に同システムを開発・製品化している。

この手法では、広域監視制御システムで収集する計測データの中から、受配電設備の変圧器二次側の電流・電圧値(1分周期)を抽出し解析を行い、故障信号として各設備向け回路の配線保護用遮断器(Molded Case Circuit Breaker : MCCB)トリップ発生の予兆を判定した(図2)。

また、解析精度を確保するために、対象設備の保守作業時や改造作業時等、通常運用時と異なる期間の計測データを解析対象から除外した。通常運用時か否かの判断にも広域監視制御システムで収集する設備の運転状態等の監視データを活用した。

2.2 機械学習による長期間の計測データの評価

故障予兆把握の手法として、設備の故障発生のメカニズムが明らかであり、異常時の計測データの変動パターンがあらかじめ明らかな場合は、異常パターンとの比較によって故障予兆を判定する手法が考えられる。しかし、道路での多種多様な電気通信設備に対して異常パターンをあらかじめ定義することは困難であることから、今回の手法では広域監視制御システムの長期間の計測履歴データを評価して正常/異常兆候を判定した(図3)。

評価には画像認識等の分野で活用が進んでいる機械学習を適用した。故障発生前の一定期間の計測データに基づく特異指標値を故障発生の“異常兆候”候補として、故障発生日とも異常兆候候補とも重複しない一定期間の計測データに基づく特異指標値を“正常”候補として機械学習によって学習させ、“正常”と“異常兆候”を判定した。特異指標値の抽出については3.1節で述べる。

2.3 解析対象データの特徴量抽出・圧縮による処理の高速化

長期間の1分周期データを解析する場合、解析対象の




図2. 解析対象計測データ

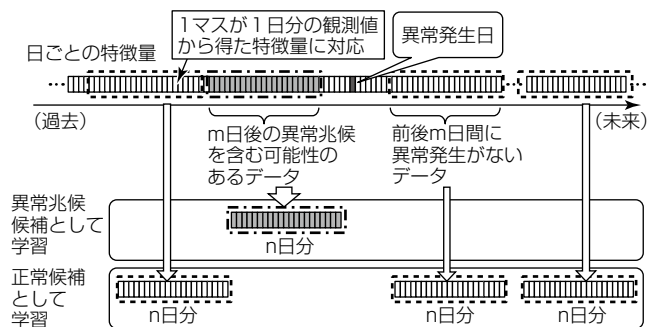


図3. 学習データ抽出の考え方

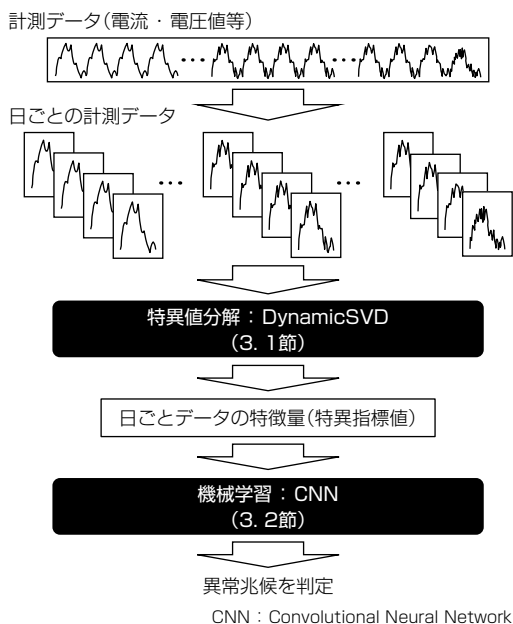


図4. 故障予兆把握の処理フロー

データ量が多量(1計測点でも約50万点/年)になり、処理の高速化が課題になる。

よって今回の手法では、計測データをそのまま処理するのではなく、圧縮してから処理を行うことで、処理の高速化を図った。具体的には、特異値分解(Singular Value Decomposition: SVD)技術によって、計測データから特徴量として特異指標値を抽出し、抽出した特異指標値を機械学習によって解析して評価を行った。これによって解析対象である計測データを、特徴量を損なうことなく圧縮することが可能になる。

特異値分解技術としては当社独自の高速の特異値分解技術である“DynamicSVD”を適用した。DynamicSVDによって日ごとの計測データから抽出した特異指標値を機械学習によって評価し、計測データの変動パターンが正常であるか異常兆候であるかを判定した(図4)。

今回の手法の要素技術である特異値分解技術を3.1節で、機械学習技術を3.2節で述べる。

### 3. 道路設備故障予兆把握の要素技術

#### 3.1 特異値分解技術

特異値分解は、複数の指標を持つデータを、より特性を顕著に表す特徴量で表現する数学手法である。例えば、小学校の身体測定結果の分析で、“身長”“体重”という2種類の指標を、より効率的に特性・傾向の違いを表現できる“体格”“体型”の2種類の特徴量に変換することで、特性・傾向を確認しやすくする(図5)。

特異値分解を適用することで、例えば時系列の計測データのように多数の計測値からなる観測波形に対しても、特徴量に変換して評価することが可能である。

日ごとに周期性を持つ観測波形を複数日にわたり特異値




図5. 特異値分解による特徴量の表現例

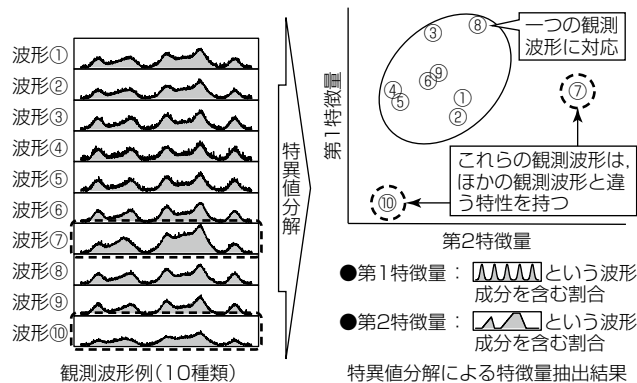


図6. 時系列波形に対する特異値分解による特徴量の表現例

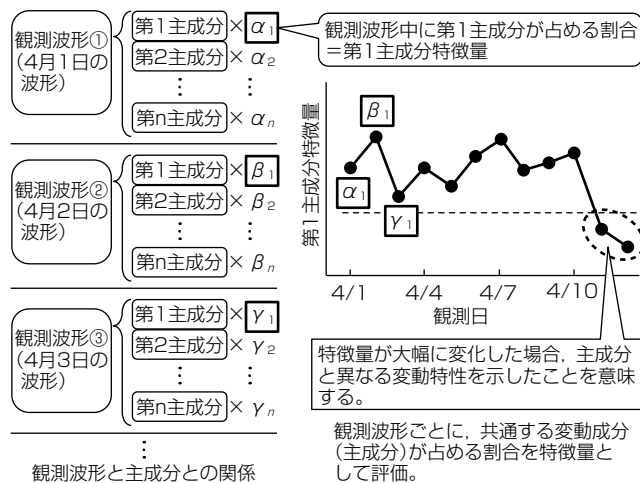


図7. 観測データと主成分に対応する特徴量

分解した場合、各観測日の観測波形から、波形データ中の主成分と、波形データ中にその主成分が占める割合を算出することができる(図6)。ここで主成分とは、複数日のデータに共通して含まれる時系列波形の成分のことを指す。

今回の手法では、このようにして得られる主成分に対し、その主成分が占める割合を、日ごとの計測データの特徴量として着目し、さらに特徴量変動の全体からの外れ度を特異指標値として算出した(図7)。

特異値分解技術には、高速での特異値分解を可能にする当社独自技術であるDynamicSVDを適用した。DynamicSVDはデータの差分だけを逐次的に計算することで、一般的な特異値分解手法(Lanczos法と呼ばれる数学手法)

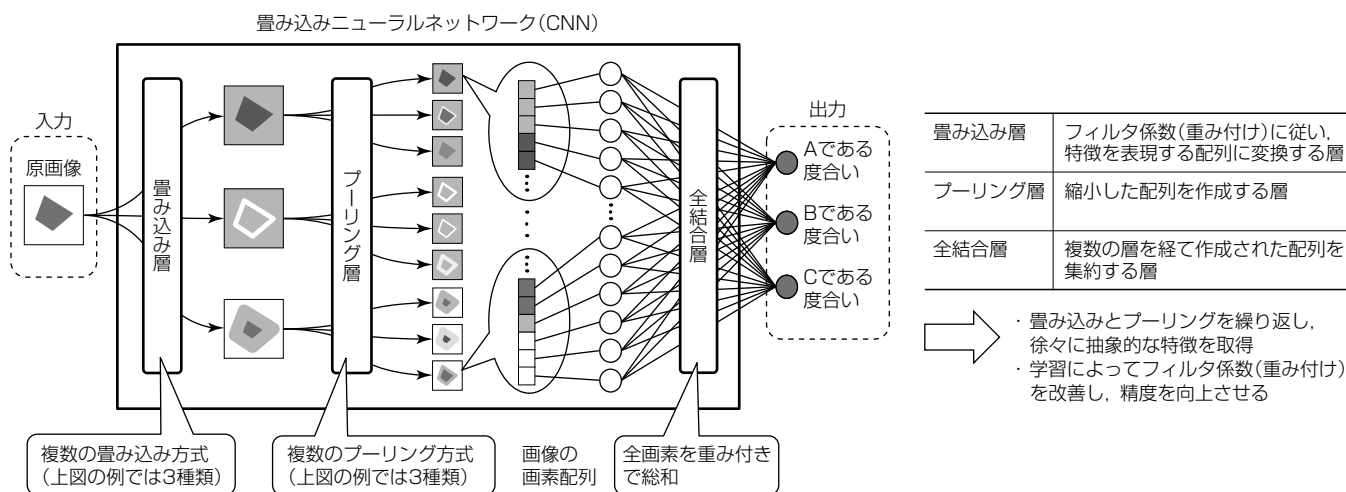


図8. CNNの概念図




図9. CNNへの入力信号のイメージ

表1. MCCBトリップ発生予兆把握の実データでの評価結果

評価指標	精度	備考
適合率	91%	兆候を検知し、7日後に事象が発生する確率(誤検知の少なさ)
再現率	80%	事象発生の7日前に兆候を検知した確率(見逃しの少なさ)

に対して100倍高速に特異値分解を可能にする技術であり、特に時系列データのように、逐次的にデータが追加される場合に対して有効な技術である。

### 3.2 機械学習技術

DynamicSVDによって算出した特異指標値を機械学習によって評価し、日ごとの計測データが異常兆候を示すかを判定した。機械学習の方式として、今回の手法ではCNN(Convolutional Neural Network: 畳み込みニューラルネットワーク)を用いた。CNNはDNN(Deep Neural Network: ディープニューラルネットワーク)の一種であり、画像認識などによく利用される技術である。

CNNは、入力信号に対し、畳み込みとプーリングを繰り返し、徐々に抽象的な特徴を取得していくアプローチの学習方式である。学習によってフィルタ係数(重み付け)を改善し、識別精度を向上させる(図8)。

今回の手法では、一定期間の特異指標値を、1行が1日分の特異指標値からなる行列(1日分の特異指標値×日数の二次元配列)とし、CNNへの入力信号とした(図9)。

故障発生前の一定期間の特異指標値を故障発生の“異常兆候”候補として、故障発生日とも異常兆候候補とも重複しない一定期間の特異指標値を“正常”候補としてCNNによって学習させ、“正常”と“異常兆候”を判定する学習モデルを作成した。

### 4. 実データでの評価

本稿で述べた手法を道路管理設備での実際の計測データで評価を行った(表1)。

対象の故障としては照明設備向け電力系統のMCCB(Molded Case Circuit Breaker: 配線保護用遮断器)のトリップ発生、計測データとしては同電力系統に対する変圧器の二次側の電流・電圧値とし、約2年分の1分周期データを解析した。また事象発生前の事前調査や作業員の手配、交通規制の準備に要する期間等の実運用への適用を考慮し、最大で7日後の故障予兆を推定することを条件として評価を行った。

結果としては、三相4線式の配電方式の設備で、事象発生の7日前に、適合率・再現率共に80%以上の確率で異常兆候検知が可能であることを確認した。

## 5. むすび

道路での電気通信設備の故障予兆を把握する手法の開発を進めており、既存の広域監視制御システムの計測データで検証し、一定の成果を確認できた。

一方で、広域監視制御システムで収集する計測データの多くは、複数設備を集約する受電箇所(受電所)の計測データに限定されるケースも多く、設備ごとの運転状況を把握するためには、より設備と対応付く詳細な計測データの取得等、データの充実が課題と言える。

計測データの充実に向けては、昨今導入事例が増えている電力メータ検針業務自動化を目的としたメータリングシステムのデータの活用や、IoT(Internet of Things)技術や5G(第5世代移動通信システム)技術等の活用による計測データ整備が期待できる。

引き続きこの手法の開発を進め、道路を始めとするインフラ設備運用や保全業務の迅速化・効率化に貢献する。