

# 鉄道車両におけるモニタデータを用いた機器の異常検知

横内 俊秀\* 高重 達郎\* 近藤 稔\*

Anomaly Detection for Equipment on Railway Vehicle Using Condition Monitoring Data

Toshihide YOKOUCHI Tatsuro TAKASHIGE Minoru KONDO

In recent years, some railway vehicles are equipped with condition monitoring devices, which constantly record the operating condition of railway vehicle equipment. Thus, we improve the reliability of train operation by learning the data and detecting abnormalities using machine learning. Condition monitoring data is recorded in time-series. Therefore, we propose an anomaly detection method for railway vehicle equipment using Long Short Term Memory (LSTM), which is a deep learning method suitable for learning time-series data. In this paper, we apply the proposed method to data recorded at diesel cars in operation. As a result, it is confirmed that the anomaly scores increase in case of abnormal data using the proposed method and that anomalies are detected in railway vehicle equipment.

キーワード：モニタデータ，異常検知，機械学習，ニューラルネットワーク，LSTM

## 1. はじめに

近年，IT 機器の革新によりコンピュータの演算能力や記憶容量が飛躍的に向上してきた。これを受けて，プラントや工場では稼働する機器状態の膨大なデータがリアルタイムかつ高い時間分解能で記録されるようになった。記録されたデータは，機器状態の監視や機器故障の詳細な原因究明に利用される。特に前者については，様々な効果が期待されており，これらのデータを活用することで，機器状態を常時あるいはより頻繁に確認できるため，故障の予防や故障の影響の軽減が可能になる。そして，機器状態を監視することで，機器で構成されるシステムの信頼性の向上につながることを期待されている。

鉄道車両は多くの機器で構成されている。現在，鉄道事業者は車両機器の故障を予防できるように，多くのリソースをかけて保守・管理している。一方で，運用中の車両機器の故障を完全に防ぐことはできず，運用中の車両機器の故障は運行に大きな影響を及ぼす。そのため，鉄道車両には運行中に車両機器の異常を検知すると，乗務員に警告したり車両機器の機能を停止させたりする機能が備わっている。例えば，主電動機の過電流，電気回路の地絡など，運行に重大な影響を及ぼす故障に対する異常検知機能は古くから導入されてきた。また，同様に運行に重大な影響を与える車軸軸受を常時監視するシステムが実用化されている<sup>1)2)</sup>。これらのシステムは，軸箱に温度センサや振動加速度センサを取り付け，しきい値を超えると警報を発するものである。また，空気バネの圧力センサを用いて台車構造の異常を検知するシステ

ムも実用化されている<sup>3)</sup>。他方で，地上側に装置を設置し，車軸箱，ブレーキディスク，車輪踏面，パンタグラフ等の異常を検知する事例も存在する。

しかし，異常検知の対象となっていない車両機器や，異常検知の対象であっても単純なしきい値では検知できないような故障が発生する車両機器は依然存在している。この課題に対して，近年，欧州の Shift2Rail<sup>4)</sup> や日本における「スマート・メンテナンス」<sup>5)</sup>の試みなどに見られるように，車両機器の状態に関するデータを活用し車両機器の状態管理を高度化することで，運行の信頼性をさらに向上させるための取り組みが盛んになされている。この取り組みの一つとして，車両機器の状態を車上のモニタ装置で常時記録し，そのデータを活用して異常の判断や故障の予兆を把握する方法の導入が挙げられる。このような方法は，新規に異常検知のシステムを設置する場合と比較して，既存の装置を活用するため，新たにセンサ等を取り付けることなく車両機器の動作状態を監視できる。近年の IT 機器の進歩により，モニタ装置はモニタデータを高速かつ大容量で伝送・処理することが可能になり，その結果，多くのデータを記録できるようになった。データの項目は，信号線のオン・オフ，モータの電流値，機関の回転数，空調装置の動作状態等，多岐に渡る。これらのモニタデータを解析することで，車両機器の状態の確認，異常の検知が可能になり，車両の信頼性を向上できる可能性がある。ただし，現場の作業員が日常業務に加えて膨大な量のデータを確認することは作業量の面から現実的ではない。そのため，データに基づいて機器の異常を自動的に検知することが不可欠である。

近年は機械学習によるデータの学習や異常検知手法が

\* 車両制御技術研究部 動力システム研究室

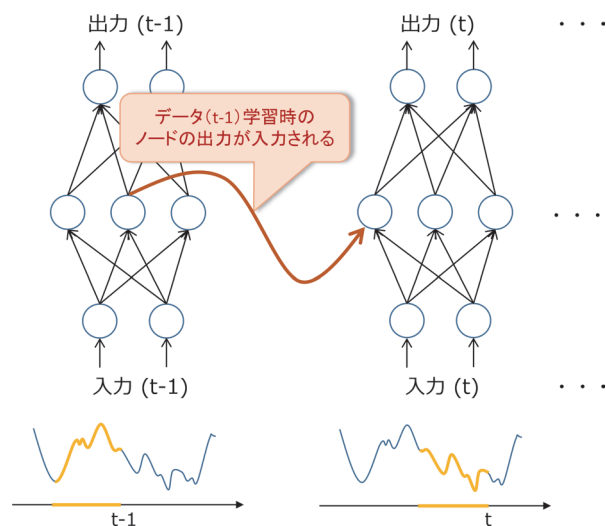
発達し、機械学習により複雑なデータ中の特徴を学習できるようになった。そこで本報告では、ディープラーニング手法の一つである Long Short Term Memory (以下、LSTM) を用いてモニタデータから車両機器の異常を自動的に判断する手法を提案する。また、営業車両で記録されたモニタデータに提案手法を適用し、手法の有効性を評価する。

## 2. ニューラルネットワーク

### 2.1 RNN

ニューラルネットワークはノードとエッジの組み合わせにより、入出力間の関係性を学習・再現できる。ニューラルネットワークは複雑な関係性を柔軟に学習できることから、近年、様々な分野で使用されるようになった。

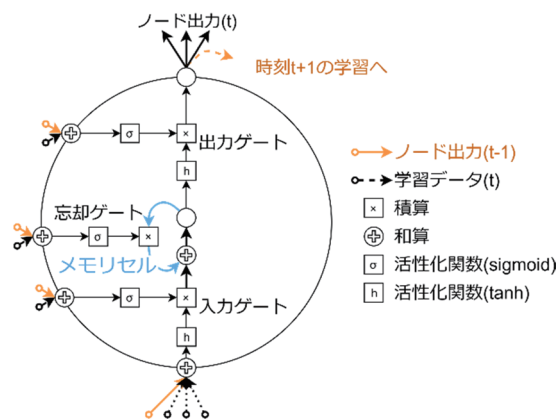
しかしながら、通常のニューラルネットワークでは時系列情報を効率的にモデル化することが困難だった。そこで考案されたのが Recurrent Neural Network (以下、RNN)<sup>6)</sup>である。RNN は隠れ層に1つ前の時刻の隠れ層の出力を入力する機能を持つニューラルネットワークである。図1に示すように、RNN に時系列の時間ステップ  $t$  の学習データを学習させる際、隠れ層のノードには時間ステップ  $t$  のデータに加え時間ステップ  $t-1$  のノードの出力が入力される。以前の時刻のデータを含めることで、時系列データの履歴を学習に反映させることができる。



しかし RNN には、学習の過程で過去の値になるほど重みの値が著しく減少するという問題があるため、時系列データの長期間の履歴を学習に反映させることは困難であった。この問題に対して、ノードの入出力値を制御できるように改良することで対処した手法が LSTM である。

### 2.2 LSTM

LSTM は入力、出力、忘却ゲートとメモリセルから構成されており、長期の時系列データを学習できる<sup>7)</sup>。LSTM ブロックの概要を図2に示す。まず、各ゲートは、時間ステップ  $t$  の入力と時間ステップ  $t-1$  のノードの出力に基づき、ゲートを通過する値を制御する。次に、メモリセルは、時間ステップ  $t-1$  の内部状態を時間ステップ  $t$  まで保持する。状況が変化した場合や外れ値を入力した場合、すなわち、従来とは異なる傾向のデータが入力された場合には、メモリセルの中身をリセットする必要がある。しかし、LSTM の提案当初は、メモリセルの中身を永遠に保持したまま学習が進む仕組みであったため、手動でのリセットが必要になるという問題があった。そこでデータの傾向の変化に応じてメモリセルの中身を自動的にリセットする仕組みとして忘却ゲートが提案された<sup>8)</sup>。忘却ゲートによってメモリセルの中身に0から1の値をかけ、内部状態を引き継ぐか引き継がないかを定めることができる。これらの機能により、1000 ステップ単位という長期の時系列データの履歴の学習が可能となる (RNN では10 ステップ程度<sup>6)</sup>)。



### 2.3 学習時のパラメータ

ニューラルネットワークの学習精度や重み更新の収束性を向上するために、学習方法を適切に検討しなければならない。本報告では、学習に関するパラメータのうち Batch size, Lookback, Dropout について説明する。

Batch size とは、重みの更新に必要な予測誤差を計算する際のサンプル数である。Batch size が小さいほど頻繁に重みを更新するので細かな特徴を学習するが、重みの更新回数が増加するため計算時間がかかる。

Lookback とは、ニューラルネットワークの入力において一度に読み込む時間ステップ数のことである。Lookback が大きいほどより長期の過去に遡ったデータを入力するため、過去の特徴を参照しながら予測するようになるが、計算時間がかかる。

Dropoutとは、入力層または隠れ層のノードを一定の割合でランダムに無効化して学習する方法である。Dropout rateは、無効化する割合である。ネットワークを学習する場所が変わるため、過学習の抑制が期待される。

### 3. 車両機器の異常検知手法

モニタデータは、時刻と共に車両機器の動作状態が記録されているデータ、すなわち時系列データである。時系列データを対象とした異常検知は、瞬時値だけでなく時系列データの時間的特徴（波形や履歴）に基づくのが有効であると考えられる。時系列データの時間的特徴に基づく異常検知手法は、鉄道以外の分野でも幅広く提案されている<sup>9)10)</sup>。本報告では、時系列データの学習に有効な手法として、LSTMを組み込んだニューラルネットワークにモニタデータを学習させる手法を提案する。本手法は以下の3つのステップから構成される<sup>11)</sup>。

- (1) 正常時のモニタデータを学習し、学習済みモデルを作成する → 3.1 節
- (2) 学習済みモデルを用いて正常時のモニタデータ予測時の予測誤差（基準誤差）を得る → 3.2 節
- (3) 学習済みモデルを用いてテストデータ予測時の予測誤差を基準誤差と比較し異常度を計算する。異常度が大きい場合に異常判定する → 3.3 節

#### 3.1 正常時のモニタデータの学習

正常時のモニタデータの学習の概要を図3に示す。正常時のモニタデータの学習では、正常時のモニタデータを入力項目と出力項目に分けてニューラルネットワークに学習させる。この時、入力項目は出力項目を予測可能な情報が含まれる項目である必要がある。正常時のモニタデータを学習したニューラルネットワークは、車両機器が正常に動作している状態を再現して入力項目から出力項目（図3では機関の『冷却水温度』）を予測する学習済みモデルとなる。学習済みモデルに対して正常時のモニタデータが新規に入力されると、比較的小さい誤差で出力項目を予測することが期待される。本報告では、時系列データを扱うのに適したLSTMを組み込んだ

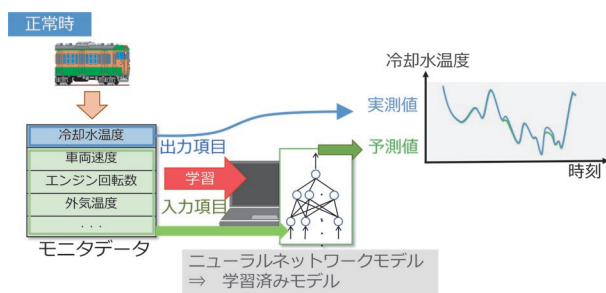


図3 正常時のモニタデータの学習

ニューラルネットワークを用いる。

#### 3.2 基準誤差の作成

基準誤差の作成方法の概要を図4に示す。正常時のモニタデータであり判定の基準となる『基準データ』を、学習済みモデルに入力し、予測値を出力として得る。得られた予測値に基づき、各時刻の予測値と実測値との誤差（以下、予測誤差）を計算し、予測誤差の分布（以下、基準誤差）を取得する。この場合、正確な予測が可能なので、基準誤差は0を中心とした分布になる。

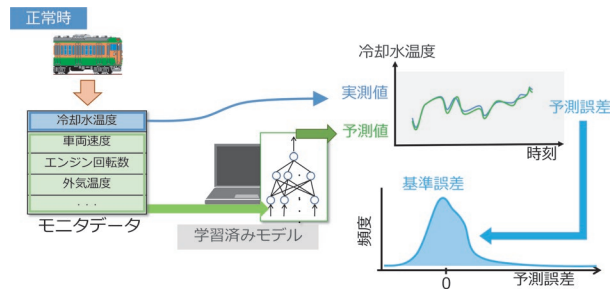


図4 基準誤差の作成

#### 3.3 異常度計算および異常判定

異常度計算および異常判定の概要を図5に示す。異常度計算では、異常度の計算対象となるモニタデータである『テストデータ』をニューラルネットワークに入力として与え、予測値を出力として得る。次に、得られた予測値から、各時刻の予測誤差を計算する。そして、予測誤差の分布が基準誤差とかけ離れている場合に異常と判定する。以下に、詳細な異常判定方法を説明する。

異常度計算では、図5に示すようにテストデータの予測誤差から異常度を計算する。異常時のモニタデータを予測した場合の予測誤差は、出力項目が異常の影響を受けている場合、正常時のモニタデータの場合と比べ大きな値になると考えられる。そこで、基準誤差に基づき、異常時の予測誤差、すなわち正常時には出現頻度が低いような予測誤差に対しては高い数値となる異常度を定義する。以下に、異常度の詳細な計算方法について述べる。

図6に異常度計算の詳細を示す。まず、基準誤差にお

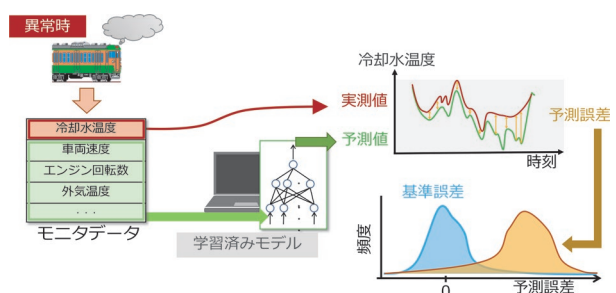


図5 異常度計算




図6 異常度計算の詳細

ける誤差  $d_n$  の確率密度分布  $p_n(d_n)$  をカーネル密度分布推定法等の適切な分布推定法により求める。その後、予測誤差  $d_t$  が正常時に発生しうる確率  $p_n(d_t)$  を各時刻について求める。最後に、式 (1) で定義した異常度  $a$  を計算する<sup>12)</sup>。異常度  $a$  は、予測誤差が正常時の分布から大きく外れた場合に大きな値を示す。すなわち、異常時における予測誤差に対して大きな異常度を示す。

$$a(d_t) = -\log p_n(d_t) \tag{1}$$

異常判定では、予測誤差の95パーセンタイルにおける発生確率を基にする等、異常度に対してしきい値を設定し、異常度がしきい値を超過した場合に異常と判定する。ただし、瞬時の超過による異常判定で検知が過剰になることを防ぐため、異常度にローパスフィルタをかけることで、瞬時の超過を異常と判定しないようにする。

#### 4. 気動車モニタデータを用いた評価

気動車で取得されたモニタデータを用いて提案手法の有効性を評価した。本報告では運用中に発生した機関停止事象および機関オーバーヒート事象発生時のモニタデータへの適用事例について述べる。なお、各事象は異なる車両形式で発生したものである。

##### 4.1 機関停止事象

###### 4.1.1 使用データおよび評価条件

本データは項目の多くが0または1の二値データであるのが特徴である。学習用のモニタデータは4日間分、基準データは1日間分とした。異常度を評価するテストデータは正常時と異常時について各1日間分とした。異常時のモニタデータは走行中に機関停止事象が発生したものである。事象発生後に調査が実施され、燃料タンク取り出し管内部又は燃料送油管に異物が詰まり燃料供給不足となったことが原因と推定されている。

学習条件を表1に示す。最適化手法は重みの更新度合いを調整する手法であり、一般的に使用されるAdamを使用した。ニューラルネットワークの構造および入出力項目を表2および図7に示す。機関停止事象に注目

するため、出力項目には「機関回転数」、入力項目には機関回転数に影響すると考えられる項目を選んだ。なお、学習の繰返し数は200回とした。また、異常度の計算にあたり、基準誤差の分布推定としてカーネル密度推定法<sup>13)</sup>を用い、ローパスフィルタとして20サンプル分(20秒分)の移動平均を行った。

表1 学習条件

最適化手法		Adam
ミニバッチの生成	Batch size	256
	Lookback	30
	scaling	MinMaxScaler <sup>13)</sup>
評価指標		loss (最小二乗誤差)

表2 ニューラルネットワークの入出力項目 (機関停止事象)

入力 (連続値)	変速機回転数, 速度
入力 (二値データ)	ノッチ等のリレー情報 (53項目)
出力	機関回転数




図7 ニューラルネットワークの構造

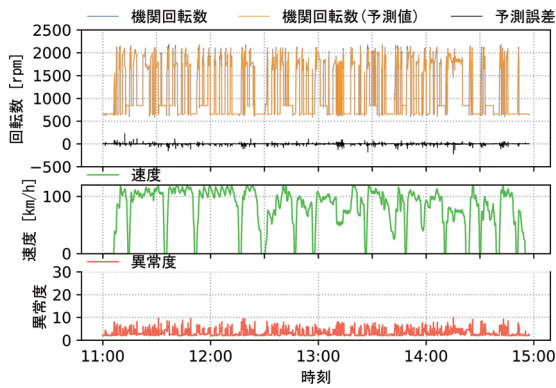
##### 4.1.2 結果

テストデータの異常度の計算結果を図8に示す。正常時には異常度は概ね10以下を示す一方で、異常時には異常度が正常時と比較して大きく、事象発生以前からスパイク状の著大値が確認できる。機関回転数に着目すると、異常時にはノッチオフ直後にアイドル回転数(約650rpm)に推移する過程でアイドル回転数を大きく下回る現象が認められる。同様の現象は正常時のモニタデータでも確認できるが、その程度が異常時において顕著であるため、ノッチオフ直後の予測誤差が大きくなり、結果的に異常度が大きくなる。以上から、適切なしきい値を設定することで機関停止事象発生時の検知および事象発生以前の異常を把握できると考えられる。


##### 4.2 機関オーバーヒート事象

###### 4.2.1 使用データおよび評価条件

本データは多くの項目が連続値データであるのが特徴である。学習用のモニタデータは約5ヶ月分、基準データも約5ヶ月分とした。異常度を評価するテストデータ



(a) 正常時



(b) 異常時 (6時過ぎに事象発生)

図8 異常度計算結果 (機関停止事象)

は11日分とした。なお、学習用データ、基準データ、テストデータは同一形式の異なる車両にて記録されたものである。

異常時のモニタデータは走行中に機関のオーバーヒート事象が発生したものである。事象発生後に調査が実施され、冬季にラジエータファンに徐々に雪が詰まったことによる機関冷却水の熱交換不良が原因と推定されている。徐々に雪が詰まっていくことから、事象は漸次的に進展したことが推察される。

4.1節の事例と同様に学習条件を表1に、ニューラルネットワークの入出力項目を表3に示す。ニューラルネットワークの構造は図7を基本とし、LSTM層のブロック数および全結合層のノード数を30とした。オーバーヒート事象に注目するため、出力項目には機関の「冷却水温度」、入力項目には機関の冷却水温度に影響すると考えられる項目を選んだ。なお、学習の繰返し数は10回とした。また、異常度の計算にあたっては、データ量が大きいため基準誤差を正規分布とみなして推定し、ローパスフィルタとして100サンプル分(100秒分)の移動平均を行った。

#### 4.2.2 結果

テストデータのうち、正常時および事象発生当日の異常度の計算結果を図9に示す。なお、図9の正常時ま

表3 ニューラルネットワークの入出力項目 (機関オーバーヒート事象)

入力 (連続値)	車両速度, アクセル位置, 機関回転数, 潤滑油圧力, 燃料流量, 大気圧, 外気温度
入力 (二値データ)	ラジエータ稼働中
出力	冷却水温度

たは異常時として示したデータは同じ走行区間である。ただし、外気温度が正常時では約0℃、異常時には約-5℃と、異常時において気温が低かったため、雪によるラジエータファンの閉塞が発生しやすい状況だったと言える。予測値から、正常時には概ね正確に予測されたことが分かる。一方、異常時には事象発生の1時間半程度前から断続的に実測値が予測値を上回っている。これは、運行ダイヤや線形の関係で継続的に機関を稼働したために、ラジエータによる熱交換が追いつかず、正常時と比較して冷却水温度が上昇したためと考えられる。

上記の傾向は異常度に反映されており、正常時の異常度は、多少の変動は認められるものの概ね2程度を示しているのに対し、事象発生の1時間半程度前からは異常度の急激な上昇が断続的に認められる。

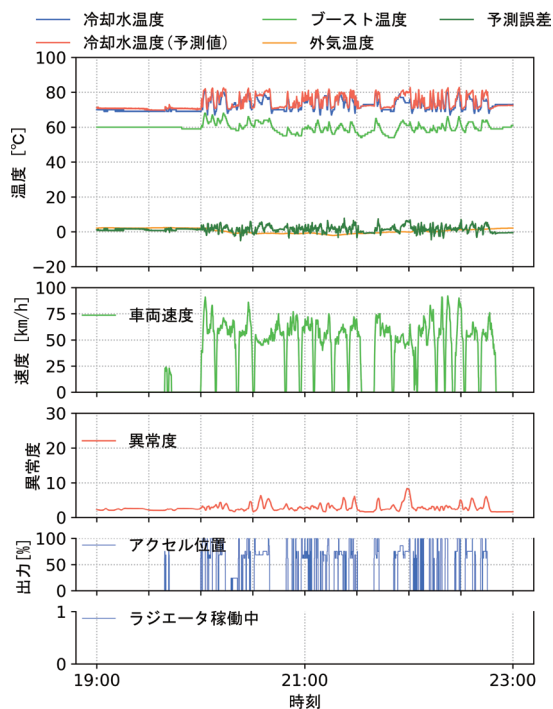
なお、本分析にあたり正常時においてもスパイク状の異常度の上昇が認められた。これは、機関停止に伴うセンサ類の停止により冷却水温度が測定不能になったためであり、異常事象に起因するものではなかった。このようなセンサの稼働状況を理由とする異常度の上昇は、今後、データ前処理により除去できるようにする予定である。

基準誤差の作成時と異常度計算時に異なる車両のモニタデータを用い、事象発生に伴う冷却水温度の上昇を捉えることが可能であった。このことから、同一車両形式であれば、基準誤差の作成に用いるデータは同一のものを利用可能であり、汎用性のあるモデルの作成が可能であることが分かった。


## 5. まとめ

時系列データであるモニタデータを用いた車両機器の異常検知手法の実現を目指し、LSTMを組み込んだニューラルネットワークを用いた異常検知手法を提案した。また、適用例として提案手法を二つの事象に対する場合を示した。

機関停止事象については、正常時と異常時の機関回転数の違いが異常度の差異として確認され、異常度にしきい値を設定することで機関回転数の異常を検知できることが分かった。また、機関オーバーヒート事象については、オーバーヒートが発生した機関の冷却水温度における異常度が、事象が発生するまでの間に増大することが



(a) 正常時



(b) 異常時 (19 時付近で事象発生)

図9 異常度計算結果 (オーバーヒート事象)

確認された。これらの評価より、提案手法の有効性が確認された。

## 文献

- 1) perpetuum: Track Defect and Wheel Damage: Detection and Location: <https://perpetuum.com/download/track-defect-and-wheel-damage-detection-and-location/> (参照日: 2021年6月21日)
- 2) knorr brake: Comoran: Condition Monitoring for Railway Applications: [https://www.knorr-bremse.com/remote/media/documents/railvehicles/product\\_broschures/brake\\_systems/Comoran\\_P\\_1215\\_EN.pdf](https://www.knorr-bremse.com/remote/media/documents/railvehicles/product_broschures/brake_systems/Comoran_P_1215_EN.pdf) (参照日: 2021年6月21日)
- 3) 喜多ほか: 空気ばね圧を用いた台車異常検出手法, 第25回鉄道技術連合シンポジウム (J-RAIL2018) 講演論文集, No.1213, 2018
- 4) Shift2Rail: Delivery of new smart maintenance concept & global safety framework!: <https://shift2rail.org/news/read-about-the-latest-results-coming-from-cca/> (参照日: 2021年6月21日)
- 5) 穴見: スマートメンテナンスの取り組み状況について, JR EAST Technical Review, No.62, pp.5-10, 2019
- 6) A. Singh, "Anomaly Detection for Temporal Data using Long Short-Term Memory (LSTM)," Master's thesis at KTH Royal Institute of Technology, 2017.
- 7) Sepp Hochreiter, and Jürgen Schmidhuber, "Long short-term memory," Neural Computation, Vol.9, No.8, 1735-1780, 1997.
- 8) Felix Gers, J. Schmidhuber and Fred Cummins, "Learning to Forget: Continual Prediction with LSTM," Neural Computation, Vol.12, No.10, pp.2451-2471, 2000.
- 9) L. Guo, N. Li, F. Jia, Y. Lei and J. Lin, "A recurrent neural network based health indicator for remaining useful life prediction of bearings," Neurocomputing, Vol.240, pp.98-109, 2017.
- 10) Georg Helbing and Matthias Ritter, "Deep Learning for fault detection in wind turbines," Renewable and Sustainable Energy Reviews, Vol.98, pp.189-198, 2018.
- 11) 横内俊秀, 近藤稔: 鉄道車両における LSTM を用いた機器の異常検知, 第26回鉄道技術連合シンポジウム (J-RAIL2019) 講演論文集, No.S8-3, 2019
- 12) 井出剛: 入門 機械学習による異常検知—R による実践ガイド—, コロナ社, p.9, 2015
- 13) Pedregosa, et al., "Scikit-learn: Machine Learning in Python," JMLR, Vol.12, pp.2825-2830, 2011.