# 畳み込みニューラルネットワーク(CNN)を用いた 軌道状態診断手法の開発

日大生産工(院) (

#### 日大生産工 綱島 均

#### 1. まえがき

鉄道の安全性と快適性を維持,向上させる ためには,軌道の維持管理及び予防保全が必要 不可欠であるが,車輪や軌道などの状態は気象 条件などにより常時変化しているため,高頻度 で監視する事が望ましい.軌道状態の計測や保 守は,保線係員や軌道検測車によるものが一般 的であるが,地方鉄道では人員及び費用の確保 が難しく十分な検査を行えない事業者も少な くない.

この問題に対して、センサ類、GPSなどで構成された装置を営業列車に設置することで安価且つ高頻度で軌道状態の診断ができる、軌道状態診断システムが開発されている<sup>(1)(2)(3)</sup>.車体動揺と軌道の歪みである軌道不整には相関性があるため、このシステムでは車体の上下加速度、左右加速度、ロール角速度から、軌道状態に関する評価値であるRMS(Root Mean Square)値を算出することで、軌道不整の診断を行う.しかし、複数の営業列車から取得できる大量のデータを効率よく計算処理するために、軌道状態の診断・予測の自動化が必要となる.

本研究では、軌道不整の程度の変化を自動で 診断するアルゴリズムを構築した.診断には、 機械学習の手法のひとつである畳みこみニュ ーラルネットワーク(CNN:Convolutional neural network)を用いた画像認識技術を導入 して、測定した実車の加速度データを連続ウェ ーブレット変換した画像を診断し、軌道不整の 時系列変化を診断する方法を提案する.この方 法により、計測した大量のデータに対する自動 的な軌道状態診断が可能になる.また、評価値 による診断より詳細な診断をすることが可能 となる.



Fig. 1 Track condition monitoring system



#### 2. 軌道状態診断システム

軌道状態診断システムの概要を図1に示す. 本システムは,営業列車に設置し車体動揺を計 測する車体動揺計測装置と,計測データから評 価値を算出し軌道状態を診断する診断ソフト で構成される.計測部の車体動揺計測装置は, 軌道異常を検出するための3軸加速度センサお よびレートジャイロ,列車位置や走行速度を検 出するためのGPS受信機,各センサの信号をコ ンピュータに入力するセンサインターフェー スで構成される.計測データは携帯電話回線を 利用して、サーバに送信され迅速な解析が可能 である.解析されたデータは鉄道事業者に送信 されるため,異常が発見された場合に早急な対 応ができる.本システムで軌道状態の常時監視 を行うことにより, 軌道の劣化や異常を早期発 見でき,鉄道事業者は効率的な保守作業を行う ことが可能である.

## Development of Diagnosis Method for Track Conditions using Convolutional Neural Network

### Masashi TAKIKAWA, Hitoshi TSUNASHIMA

<sup>○</sup>滝川 将司 日大生産工

#### 評価値による診断の課題

先行研究における評価値による診断では,計 測した車体振動加速度のRMS値から10[m]ご とに最大値を取得し、その10[m]ごとの最大 RMS値を評価することで軌道の状態の評価を 行っている.しかし、より詳細な軌道状態の評 価を行うためには、振動加速度を直接評価する ことが必要である.本研究では,連続ウェーブ レット変換を用いて車体振動加速度を画像化 したのちにCNNを適用する診断手法を提案す る. CNNによる診断では、軌道状態の良い画 像と軌道状態の悪い画像の2種類を学習させ, 未知データを診断する際にはどちらの画像に 似ているかということをCNNが判断する. そ の判断した結果は0から1までの連続値で出力 されるため,軌道状態の連続的な評価が可能に なると考えられる.

## 4. 畳み込みニューラルネットワーク (CNN)による診断

#### 4.1 CNNの構造

CNNは,機械学習におけるディープラーニ ングと呼ばれる分野の中の手法のひとつであ る<sup>(4)</sup>. 画像認証に特化した手法であり,主に画 像認証の分野を中心に活用がされている<sup>(5)</sup>. CNNの模式図を図3に示す. CNNは,畳み込 み(Convolution), プーリング(Pooling), 全結 合(Fully connected)の三つの処理を行う.畳み 込み処理では,入力画像に対してフィルタと呼 ばれる検出器を適用し,それをスライドさせな がら畳み込み演算を行う.演算結果は行列で出 力され,プーリング処理にて情報圧縮される. 本研究では,特定範囲の最大値を取得するMax pooling処理を採用した.情報圧縮後の値は, 全結合処理によって1つの出力になる.

さらにCNNの特徴として、移動不変性があ る. 読み込んだ画像全体をフィルタが移動する ことで、特徴が画像中のどこにあっても抽出で きるような構造となっている.本研究で取り扱 う車体動揺計測装置に搭載しているGPSでは、 測位誤差によって解析画像には最大20m程度 の誤差が発生する.そこで、元画像全体をフィ ルタがスライドすることである程度の位置ず れを許容しつつ特徴を抽出できるCNNを導入 することで、GPSの誤差に影響を受けない診断 が可能になると考えられる.

4.2 連続ウェーブレット変換による特徴の
 抽出
 連続ウェーブレット変換は、マザーウェー



Fig. 3 Convolutional neural network





ブレットと呼ばれる小さな波を伸縮,移動さ せて,元信号と比較することで時間的変化の 特徴と周波数成分を同時に検出する時間周波 数解析手法である<sup>(6)</sup>.

本研究で連続ウェーブレット変換を用いて, 車体上下振動加速度の時系列信号を時間周波 数平面の画像(以下,解析画像とする)に変換 し,識別することを試みた. CNN に使用す る学習データとして,区間 100[m],走行速度 55[km/h]前後で直線の振動加速度を使用し た.また,高低不整が大きい軌道を走行した 場合の解析画像に「1」,高低不整が小さい 軌道を走行した場合の解析画像に「0」の値 を与えて学習させた.高低不整が小さい場合 の解析画像の例を図 4(a),高低不整が大きい 場合の解析画像の例を図 4(b)に示す.

#### 4.3 診断の流れ

本研究で提案する大まかな診断の流れを図 5 に示す.まず,前述の車体振動加速度の RMS 値を用いて,詳細な診断が必要な区間 を抽出する.次に,車体振動加速度を連続ウ ェーブレット変換して画像化し,CNN を用 いて診断を行う.診断は未知データ画像1つ に対して0から1までの連続値で評価され, 1 に近づくほど高低不整量が大きいというこ とを表している.

- 5. 未知データ診断による軌道状態の時 系列変化の評価
- 5.1 診断目的および条件

本研究では、地方鉄道で計測した車体動揺デ ータを使用し、2019年の1月から3月までの軌 道状態を診断することで、軌道状態の時系列変 化の評価におけるCNNの有効性を確認するこ とが目的である.

診断条件としては、学習データの画像が時速 55キロで直線区間を走行中のときの100m区 間分の画像なので、未知データについても同様 の条件を満たす区間とした.よって本研究で診 断した区間は、キロ程26.58~26.68[km]の 100mである.

5.2 診断結果および考察

診断結果である出力数値はひとつの未知デ ータに対して0から1までの連続値で出力され る.出力数値は日ごとにばらつきがあるため, 軌道状態の時系列推移を評価するにあたり1か 月間の平均値を取得する統計処理を行った結 果を図6に示す.図6より,軌道状態が1月から 2月にかけて劣化し、2月から3月にかけて改善 していることがわかる.これらの結果より,車 体振動加速度の連続ウェーブレット変換画像 を基にした,畳み込みニューラルネットワーク による軌道状態診断手法の有効性を確認した.

## 人為的測位誤差画像による診断の許 容範囲検証

#### 6.1 測位誤差画像の作成

CNNの特徴のひとつとして,画像のずれに 対して頑強であるとう特徴がある.本研究では, GPSによる測位誤差の許容範囲の検証を行う ため,ひとつの計測データから人為的に測位誤 差を発生させた画像を2種類作成し,CNNに診 断させた.移動させる距離は計測に使用してい るGPSの測位誤差の距離を考慮して,基準とな る画像に対して,右側方向にそれぞれ10mと



Fig. 5 Diagnostic process



Fig. 6 Evaluation result (by month)



Fig. 7 No misalignment image



20m移動させた画像を作成した. 基準となる画 像を図7,右側に10m移動した画像を図8,右 側に20m移動した画像を図9に示す.

6.2 測位誤差許容範囲の検証および考察

人為的に測位誤差を発生させて作成した3種 類の画像をCNNに診断させた結果を図10に示 す. 図10より, 測位誤差無しの元画像と10m 測位誤差がある場合を比べるとその差は 21.6%であるが、元画像と20m測位誤差がある 場合を比べるとその差は65.5%となった.本研 究の目標として10%以下の誤差を目安にして いたが、今回行った診断では良好な結果が得ら れなかった.このような結果となった背景には, 畳み込み処理にて使用するフィルタの大きさ が関係していると考える. 今回の診断では, 120×400ピクセルの画像に対して8×8ピク セルのフィルタを適用していたが,フィルタの 大きさが抽出する特徴に対して小さすぎたた め,特徴を十分に検出することができず,出力 数値の誤差が大きくなってしまったと考えら れる. フィルタの大きさについては、おおよそ の適正サイズが式により示されている(7).しか し,診断する対象によって出力が大きく左右さ れる場合もあり、今後はそれらを考慮したうえ でフィルタの大きさを再検討していく.

7. まとめ

本研究では,軌道不整の程度変化の診断を自 動化するため,解析結果に対しCNNを導入し, さらに位置ずれの許容性を検証した.

その結果, CNNにより高低不整の時系列変 化を自動で診断することができた. 測位誤差の 許容性については良好な結果が得られなかっ た...

今後の課題は、CNN内のフィルタの大きさ 等のパラメータを検討し評価精度を向上させ るとともに、学習データを充実させることであ る.







Fig.11 Misalignment data output

参考文献

- 荻野誠之,綱島均,柳沢一機 他,小型レ ール診断装置を用いた軌道の状態診断装 置ソフトの開発,電気学会論文誌D(産業 応用部門誌), Vol.135, No.4, (2015)pp.395-402.
- Mori, H., Ohno, H., Tsunashima, H., et al. Development of Compact Size Onboard Device for Condition Monitoring of Railway Tracks, Journal of Mechanical Systems for Transportation and Logistics, Vol. 6, No.2, pp.142-149, 2013
- 3) 小田嶋舞他,地方鉄道を対象とした軌道 状態監視システムの開発及び評価,第24 回鉄道技術・政策連合シンポジウム,2017
- 4) 我妻幸長,はじめてのディープラーニング, SB ク リ エ イ テ ィ ブ 株 式 会 社 , 2019,pp234-244.
- 5) 池田宥一郎,飯塚博幸,山本雅人,畳み込 みニューラルネットワークによるチンパ ンジーの個体識別,第32回人工知能学会 全国大会,2018
- 6) 廣瀬亮太 他,車体振動加速度を用いた軌 道異常の検出,第25回鉄道技術連合シン ポジウム,2018.
- 7) 関野雅則,木村俊一,越裕,視覚情報処理 モデルに基づいて改良した畳込みニュー ラルネットワーク文字認識,第27回人工 知能学会全国大会,2013