

畳み込みニューラルネットワークを用いた軌道状態診断に関する研究

○ [機] 滝川 将司 (日本大学大学院)

[機] 綱島 均 (日本大学)

[機] 森 裕貴 (交通安全環境研究所)

[電] 高田 哲也 ((株) 京三製作所)

Track Condition Diagnosis using Convolutional Neural Network

○Masashi Takikawa, (Graduate School of Nihon University)

Hitoshi Tsunashima, (Nihon University)

Yuki Mori, (National Traffic Safety and Environment Laboratory)

Tetsuya Takada, (Kyosan Electric Mfg. Co.,LTD.)

Condition monitoring of railway tracks is effective for the sake of an increase in safety of regional railways. This study propose a new method for automatically classify the type and degree of track fault using Convolutional Neural Network, which is a machine learning method, by imaging car-body acceleration on a time-frequency plane by continuous wavelet transform. As a result of applying this method to the data measured in regional railways, it was possible to classify and extract the sections that need repair according to the degree of deterioration of the tracks, and to identify the track fault in those sections.

キーワード: 鉄道, 軌道, 機械学習, 車体振動加速度, 連続ウェーブレット変換

Key Words: Railway, Track, Machine learning, Car-body acceleration, Continuous Wavelet Transform

1. 緒言

鉄道において軌道の維持管理は安全かつ快適に走行するためには必要不可欠であるため、高頻度で監視することが望ましい。そのため、鉄道事業者では軌道検測車や保線係員により軌道の検測を行っているが、輸送人員の少ない地方の鉄道では、必要な人員や費用などの問題により十分な検測を行えない事業者も多い。

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、安価かつ高頻度で軌道状態を診断するシステムが開発されている¹⁾²⁾(図1参照)。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、RMS(Root Mean Square)値を算出し、数値の高い地点から優先的に補修するという手法が採用されている。しかし、RMS 値による診断手法のみでは周波数情報が欠落してしまうため、軌道異常の種別の特定が困難である。さらに、常時計測により計測されるデータ量は膨大であるため、効率的に軌道状態の診断・予測をするためには、解析の自動化が必要となる。

本研究では、連続ウェーブレット変換を用いて、振動加速度を時間周波数平面で画像化し、機械学習の畳み込みニ



図1 軌道状態診断システム

ューラルネットワークを導入することで、自動で軌道異常の種類を分類する手法を提案し、有効性を検討する。本稿では、構築したアルゴリズムの有効性を検討するため、地方鉄道において計測した車体上下振動加速度データを診断した結果について述べる。

2. 連続ウェーブレット変換

列車が軌道を走行すると、軌道形状に対応した振動が発生する³⁾。そこで本研究では、車体振動加速度から軌道異常の種類と程度を自動的に評価するため、時間周波数解析の手法のひとつである連続ウェーブレット変換を使用し

た。本手法は、マザーウェーブレットという小さな波を伸縮、移動させて元信号と比較することで、非定常信号の周波数と時間の特徴を同時に検出する手法である⁴⁾。実際に地方鉄道で計測した車体上下振動加速度に連続ウェーブレット変換を適用した結果を図2に示す。先行研究により、スペクトルの現れる周波数帯域の違いにより軌道異常を特定できることが示されており、キロ程 25.82km 付近では 10~30Hz にてスペクトルが現れているので、軌道継目部に発生するレール頭頂面の落ち込みである継目落ち、キロ程 25.95 付近では 3Hz 付近でスペクトルが現れているので、レールの上下方向の歪みである高低不整と特定することができる⁵⁾。

3. 畳み込みニューラルネットワークを用いた画像診断

畳み込みニューラルネットワークは、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り、画像認証に特化した機械学習である⁶⁾。本研究では、車体上下振動加速度から取得した連続ウェーブレット変換後の画像について、畳み込みニューラルネットワークを導入した診断アルゴリズムで高低不整と継目落ちを自動で分類することの有効性を検討した。診断の手順を図3に示す。

4. 実測した車体上下振動加速度データの診断

4.1 診断概要

地方鉄道において、車体動揺計測装置を用いて計測した車体上下振動加速度を連続ウェーブレット変換により画像化し、構築した機械学習アルゴリズムにより軌道異常の診断を行った。今回検討する診断は、軌道異常（高低不整）・軌道異常（継目落ち）・正常の3種類とした。さらに、軌道異常（高低不整）、軌道異常（継目落ち）の程度を、正常・中程度・著大の3種類とした。

4.2 高低不整と継目落ちの分類

(1) 学習・評価画像の作成

学習に必要な画像の作成手順を図4に示す。計測データから1枚あたり1000m分の上下振動加速度を、連続ウェーブレット変換により0~30Hzの周波数帯域を含む画像として取得し、正常な画像、高低不整の画像、継目落ちの画像を、学習に最適なアスペクト比1:1でそれぞれ100枚ずつ、合計300枚抽出した。このようにして作成した画像の80%を学習用として使用、20%を評価用として使用した。

(2) 学習環境

使用したネットワーク構成を図5に示す。図中の各層の上数字は、演算の処理名とサイズ(縦×横×チャンネル)を示し、下数字はその層での処理後の出力サイズを示している。Convolution層では、畳み込み演算により画像の特徴が行列形式で表され、Max pooling層では情報の圧縮が行われる。全結合層であるAffineにて各情報の結合が行われ、Outputでは3種類の教師画像のどの画像に似ているかを確率で出力するように設定した。学習回数は50回とした。




図2 連続ウェーブレット変換




図3 診断手順




図4 学習画像作成手順（高低不整と継目落ちの分類）




図5 ネットワーク構成

(3) 診断結果

評価用の画像を用いて、軌道異常（高低不整）・軌道異常（継目落ち）・正常を診断した結果を表 1 に示す。全体としての正解率は 98.3%と高い確率となった。このことから、軌道異常の分類に畳み込みニューラルネットワークが有効であることが示された。

4.3 高低不整の程度分類

(1) 学習・評価画像の作成

高低不整の程度を正常・中程度・著大の 3 種類に分類するため、図 6 に示すような画像を合計 300 枚作成した。3 種類の異常程度を診断するために、振動加速度の片側振幅が正常の画像は $0\sim0.5\text{m/s}^2$ 、中程度の画像は $0.8\sim1.2\text{m/s}^2$ 、著大の画像は 1.5m/s^2 以上の画像を使用した。また、作成した画像のうち 80%を学習用、20%を評価用として使用した。

(2) 学習環境

学習環境は、4.2 節(2)項と同様とした。

(3) 診断結果

学習済のモデルを使用して診断した結果を表 2 に示す。全体としての正解率は 98.3%と高い確率となった。したがって、高低不整の程度を正常・中程度・著大に高精度で分類できることがわかった。

4.4 継目落ちの程度分類

(1) 学習・評価画像の作成

継目落ちの程度を正常・中程度・著大の 3 種類に分類するため、図 7 に示すような手順で画像を合計 300 枚作成した。診断精度を向上させるために、計測データから取得する画像の距離を、1 枚あたり 1000m から 250m に変更した。3 種類の異常程度を診断するために、振動加速度の片側振幅が正常の画像は $0\sim1\text{m/s}^2$ 、中程度の画像は $2.5\sim3.5\text{m/s}^2$ 、著大の画像は 4.5m/s^2 以上とした。また、作成した画像のうち 80%を学習用、20%を評価用として使用した。

(2) 学習環境

学習環境は、4.2 節(2)項と同様とした。

(3) 診断結果

学習済のモデルを使用して診断した結果を表 3 に示す。正常と中程度の継目落ちの画像において誤診断が発生したが、全体としての正解率は 96.7%となり、継目落ちの程度を分類するのに十分な精度となった。したがって、継目落ちの診断においても構築した診断アルゴリズムが有効であることが示された。

5. 結言

本研究では、車体振動加速度を時間周波数解析の手法である連続ウェーブレット変換により画像化し、畳み込みニューラルネットワークを用いて、自動で軌道異常の種類や程度を分類する手法を提案した。構築した診断したアルゴリズムを用いて、実測データに対して軌道状態診断を実施

表 1 軌道異常分類の診断結果

Input image	Number of evaluation images	Correct answer rate(%)
Normal	26	100
Joint depression	13	92.3
track irregularity	21	100




図 6 高低不整の程度分類に使用する画像

表 2 高低不整の程度分類診断結果

Input image	Number of evaluation images	Correct answer rate(%)
Normal	17	100
Medium degradation level	21	100
Large degradation level	22	95.2




図 7 継目落ちの程度分類に使用する画像

表 3 継目落ちの程度分類診断結果

Input image	Number of evaluation images	Correct answer rate(%)
Normal	16	93.8
Medium degradation level	19	94.7
Large degradation level	25	100

した。

その結果、高い精度で軌道異常の種類と異常程度を診断することができることがわかった。

今後の研究課題としては、実測データにおける軌道異常の位置を精度よく推定できるようにアルゴリズムを改良し、より詳細に軌道状態を診断できるようにする予定である。

参 考 文 献

- 1) 荻野誠之，綱島均，森裕貴，浅野晃，地方鉄道用レール状態診断システムを用いた軌道の診断事例，日本大学生産工学部第 48 回学術講演会，2015.
- 2) 小田嶋舞，林田悠一，綱島均，森裕貴，高田哲也，地方鉄道を対象とした軌道状態監視システムの開発と運用，第 24 回鉄道技術・政策連合シンポジウム，2017
- 3) Akos Vinko, Peter Bocz : Experimental Investigation on Condition Monitoring Opportunities of Tramway Tracks, Periodica Polytechnica Civil Engineering, 2017.
- 4) Luis Aguiar-Conraria, Maria Joana Soares, The Continuous Wavelet Transform: moving beyond uni and bivariate analysis, pp.4-7, 2012.
- 5) 廣瀬亮太，綱島均，車体振動加速度を用いた軌道異常の検出，第 26 回鉄道技術連合シンポジウム，2019.
- 6) 西銘大喜，遠藤聡志，當間愛晃，山田孝治，赤嶺有平，畳み込みニューラルネットワークを用いた表情表現の獲得と顔特徴量の分析，人工知能学会論文誌 32 巻 5 号 F, 2017.