

ResNet を用いた軌道状態診断に関する研究

日大生産工（院） ○上田 雄也

日大生産工 綱島 均

1. 緒言

軌道検査は鉄道を走行させる上で欠かせない作業である。その種類としては軌道検測車や人の目による目視などによる方法が挙げられるが、地方鉄道などではコストや人員不足の問題から十分な軌道検査が行えていないのが現状である。

これに対し営業列車の車体動揺加速度を解析して軌道状態を診断するシステムが開発されている¹⁾。このシステムでは、営業車両の車体の動揺の10m区間ごとの最大値から軌道の状態を評価している。しかし、この手法では周波数情報が欠落するため軌道異常の種類を特定することは出来ない。さらに、計測されたデータは膨大な量となるため、効率的にデータから軌道異常の有無を診断するためには解析の自動化が必要となる。

本研究では、計測した上下振動加速度を、連続ウェーブレット変換を用いて時間周波数平面上画像化に変換し、多重層化した畳み込みニューラルネットワーク(CNN)を用いて、軌道状態の自動識別を行うことを検討する。

先行研究では、CNNを用いて軌道異常の種別を分類することが可能であることを示した¹⁾が、診断に使用する画像によっては、診断が困難となる場合があることも分かった。そこで、本研究では残差ネットワーク(ResNet)と呼ばれる多重層化したCNNを用いることで、診断精度の向上が可能かどうか検討した。

2. 軌道状態診断システム

本システムは、営業列車の車室内に小型レール診断装置を設置することで列車の車体動揺を計測し、振動加速度、角速度から軌道状態を診断している。軌道状態診断システムの概要を図1に示す。

診断する軌道異常の例を図2に示す。軌道継目部に発生する頭頂面の落ち込みを継ぎ目落ち、軌道の上下方向の変位を高低不整と呼んでいる。

3. 連続ウェーブレット変換による軌道異常の検出

連続ウェーブレット変換(CWT)は、非定常の信号に対しマザーウェーブレットと呼ばれる関数を時間軸方向に伸縮・移動して信号の類似度を求める時間周波数解析を行う手法である。

列車の車体上下振動加速度にCWTを適用した時間周波数画像の例を図3に示す。




図1 軌道状態診断システム




図2 軌道異常の例




図3 車体振動加速度の連続ウェーブレット変換




図4 畳み込みニューラルネットワーク

図3の赤枠で囲った26.4km地点の10～30Hzに、継ぎ目落ちの影響であるインパルス状の振動加速度の影響が表れている。26.2～26.6[km]地点の0～7Hzに、高低不整の影響が表れている。カラーバーは振幅の大きさを表す。

列車の上下振動加速度を時間周波数平面で画像化することで、軌道異常の種類と異常程度が可視化されるため、時間周波数画像が軌道診断に有効であることがわかる。

4. 軌道状態診断のアルゴリズム

4.1 畳み込みニューラルネットワーク

CNNは、画像認識の分野で広く用いられている機械学習の一種である。一般的に、畳み込み(Convolution)層、プーリング(Pooling)、層全結合(Fully connected)層の3層から構成されている。

畳み込み層では、入力された画像が複数のフィルタによって、その特徴を強調した複数の画像に変換される。プーリング層では、畳み込み処理された画像をある領域毎に分割し、各領域の最大値(特徴)を抽出して新たな画像としている。全結合層では、その二層から出た数値から演算を行い一つの出力としている。CNNの構成を図4に示す。

4.2 残差ネットワーク (ResNet)

CNNのネットワークモデルの一種としてResNetがある。機械学習において層を深くすれば画像の特徴量を詳細に学習できるため、単純に層を増やせば精度が向上すると考えられていた。しかし、多重層のモデルよりも浅い層のモデルの方が性能は高く、層を重ねると精度が劣化する問題が提起された。

そこで、ショートカットコネクションと呼ばれる入力から出力までの迂回路を設け、出力と入力の差である残差を学習させることで、層を深く多重化させながら精度を向上させたResNet²⁾が提案された。

なお、ResNetでは、CPUで使用できるCNNと異なり、計算負荷が大きいためGPUが必要となる。

5. 診断手順

5.1 診断手順

軌道状態診断システムを用いて実測した鉄道車両の上下振動加速度を連続ウェーブレット変換することで画像化する。この画像をResNetに学習させることで機械学習アルゴリズムを構築した。構築した機械学習アルゴリズムを用いて自動で高低不整の診断を行った。診断手順を図5に示す。




図5 診断手順




図6 学習画像の作成




図7 診断画像の作成

5.2 学習画像の作成

学習画像の作成方法を図6に示す。地方鉄道で実測した車体上下振動加速度から生成した、時間周波数画像を用いて学習画像を作成した。学習画像は軌道異常を示すスペクトルの特徴が含まれるようにして分割する。分割する正方形の大きさは規定していないが、機械学習に適した

アスペクト比として1:1(150px:150px)で画像を分割した。

高低不整の異常程度毎に、800枚ずつ計2400枚を学習画像として使用した。高低不整の異常程度は、振動加速度の片側振幅値が、正常の画像は0~0.5m/s²、中程度の画像は0.8~1.2m/s²、著大の画像は1.5m/s²以上とした。

5.3 診断画像の作成

診断画像の作成方法を図7に示す。診断画像は学習画像と同じ2019年1月~10月に計測した振動加速度の時間周波数画像を使用した。

診断画像に用いる画像は、図7の様に高低不整の特徴的な振動が検出される0~7Hzの周波数帯域から連続的に画像を分割した。その中から無作為に高低不整を示す正常の画像35枚、中程度の画像40枚、著大の画像40枚を選定し、115枚の診断画像とした。

本研究では、軌道状態診断を自動化する上で、実用的な診断画像を作成した。ResNetによって診断アルゴリズムを構築し、高低不整の異常程度を分類する事で、ResNetの有用性を検討した。

6. 実測値を用いた軌道状態診断

6.1 CNN による軌道状態診断

(1) ネットワークの構成

高低不整の異常程度を正常・中程度・著大の3区分に部類するため、高低不整の正常・中程度・著大の画像を800枚ずつ用意し、計2400枚の学習用とした。診断用の画像は0~7Hzの周波数帯域から連続的に分割した高低不整の画像115枚を診断用として使用した。

学習に用いたネットワーク構成を図8に示す。入力された画像は、畳み込み層において、画像の特徴を特徴量として抽出される。プーリング層では、抽出した特徴量が強調され、情報として圧縮される。全結合層において、全ての情報が一つに結合され、入力された画像がどのカテゴリーに類似しているかを確率として出力する。学習回数は50回とした。




図8 CNNの構成

(2) 診断結果

学習して構築した学習済みのモデルを使用して診断した結果を図9に示す。全体としての正答率は71.3%であった。しかし、著大な画像の正答率は42.5%と低く、診断精度が十分ではないことが分かった。




図9 各軌道異常程度の正答率

6.2 ResNet による軌道状態診断

(1) ネットワークの構成

6.1節(1)項で使用した学習画像2400枚と診断画像115枚を用いて、18層・32層・50層の深さを持つResNetを用いて診断を行った。層を構成する数はCNNと異なるが、入力された画像の処理は6.1節(1)項と同様とした。ResNetの学習回数は20回とした。

(2) 診断結果

学習済みのモデルを使用して診断した結果を図10に示す。50層からなるResNetが91.8%と全体正答率が最も高かった。CNNと比較すると全体正答率が20.5%向上した。

この結果からネットワークパラメータを調整するモデルとしてResNet-50が最も適していることがわかった。




図10 ResNet モデルの比較

6.3 最適化アルゴリズムの設定

最適化アルゴリズムとは、機械学習が学習する時に用いる修正用の関数である。この関数は、機械学習が予測値と正解値の差である誤差を修正するときに用いられている。学習の効率や精度に大きな影響を与えるため、最適化アルゴリズムの検討を行った。

図11は18・34・50層のResNetに各最適化アルゴリズムを適用して行った診断結果である。6.2節(1)項で使用した学習済みモデルを用いた。最適化アルゴリズムの中で、平均正答率93%と正答率が最も高いNesterovを最適化アルゴリズムとして選定した。




図 11 最適化アルゴリズムによる正答率の変化

6.4 Image Augmentation 層の実装

(1) 学習画像の修正

Image Augmentation層とは、複数の設定値に従って、入力画像にランダムな変化を加え、学習画像に出力する層である。ResNetの様な深層学習は大量の教師画像が必要となるため、Image Augmentation層をResNetに実装した。

機械学習に不適切な画像が元画像に混入すると、精度が劣化することから、予め用意していた修正用の学習済みモデル(学習画像450枚・診断画像115枚)を用いて、学習画像から各異常区分の画像であると99%診断された学習画像を集め2329枚収集した。

(2) 診断結果

学習画像が0.8～1.1倍の範囲で拡大縮小し、ランダムに左右反転されてから学習されるようImage Augmentation層を設定した。

6.2節で選定したResNet-50と6.3節で選定したNesterovを用いて、学習画像を削減して学習させた。作成した学習済みのモデルで診断を行った結果を図12に示す。

正答率がどのモデルにおいても精度が2～3%ほど向上した。学習画像を半分以下の1000枚に削減したモデルの正答率が91%であった。このことから、Image Augmentation層が精度の向上と学習画像の削減に効果があることがわかった。




図 12 Image Augmentation 層の効果

6.5 誤診断の例

誤診断した画像の例を図13に示す。いずれの画像も中程度異常と診断されているが、著大な異常が含まれている。どちらも著大を示す赤いスペクトルが薄く、特徴が小さいことがわかった。この様な画像に対してResNetが誤診断をすることがわかった。




図 13 中程度と誤診断した画像

7. 結言

本研究では、鉄道の車体動揺から得られた上下振動加速度を、CWTを用いて時間周波数画像に変換し、ResNetを用いて軌道異常の診断を行った。

その結果、各種パラメーターを調整することで正答率95%という高い精度で高低不整の異常程度を診断できることがわかった。

今後は、継ぎ目落ちなど他の軌道異常に対してResNetが有効かどうかを検証する必要がある。

参考文献

- 1) 滝川将司, 機械学習を用いた軌道状態の診断手法の開発, 日本大学生産工学部第52回学術講演会, 2019 pp.38-54.
- 2) Kaiming He 他, Deep Residual Learning for Image Recognition, CVPR, (2016) pp. 1-4.
- 3) Andreas Veit 他, Residual Networks Behave Like Ensembles of Relatively Shallow Networks, 第30回神経情報システム国際会議予稿集, 2016, pp.2-8.
- 4) Furong Huang 他, Learning Deep ResNet Blocks Sequentially using Boosting Theory, 第35回機械学習国際会議予稿集, 2018, pp.2-8.