

# ニューラルネットワークを用いた 車輪・レール間の接線力の推定

喜納 大貴\* 遠藤 靖典 (筑波大学)  
中澤 伸一 土方 大輔 (鉄道総合技術研究所)

## Estimation of Tangential Force between Wheel and Rail using Neural Networks

Hiroataka Kina\*, Yasunori Endo (Tsukuba University)  
Shin-ichi Nakazawa, Daisuke Hijikata (Railway Technical Research Institute)

Wheel slip can occur during braking because the wheels and rails are made of metal. Wheel slip causes extension of braking distance and damaging the wheels. Occurring wheel slip depend on tangential force between the wheels and rails. Tangential force is fluctuated greatly by various factors, so it is difficult to estimate the tangential force. Neural networks have the characteristic of understanding and expressing complex phenomena. Therefore, we consider a method of estimating the tangential force using neural networks. By accumulating learning, the neural network can acquire an internal representation suitable for the task from the observed data. Taking advantage of this fact, we attempted to estimate the tangential force coefficient from the speed information and braking force of railcars based on the data obtained by actual measurement using a full-scale brake test apparatus.

キーワード：ブレーキ, 接線力推定, ニューラルネットワーク (Brake, Estimation of tangential force, Neural networks)

### 1. はじめに

鉄道は一度に多くの人や物を運ぶことができる優れた輸送機関であり、公共交通システムとして広く普及している。さらに、鉄道は移動手段として多くの人々に利用されているため、輸送力や定時性だけでなく、安全が第一に求められる。これらを実現するためにブレーキは必要不可欠なシステムである。

鉄道車両の車輪とレールの接触部分は金属製なので、自動車のゴムタイヤに比べ滑りやすいという性質がある。そのためレール湿潤時などのブレーキでは滑走が発生しやすく、ブレーキ距離の延伸や、車輪の固着による車輪の擦傷がおこる可能性がある。

これに対して、現行の鉄道車両では滑走によるブレーキ距離延伸抑制と車輪固着防止を目的とした滑走制御 (Anti-lock Braking System: ABS) が広く実用化されている。ただし、ABS は発生した滑走に対してブレーキ力を変化させることで、滑走が発生していない状態へ復帰させるシステムであり、滑走の発生自体を防止することはできない。ABS では車両の速度情報などから滑走制御を行っているが、滑走の発生に大きく関わる車輪とレール間に働く接線力は用いていない。速度情報の他に、減速に関わる物理量を用いることができれば、滑走を未然に防ぎつつ減速に必要なブレーキ

力を得ることができ、より効率的な滑走制御の実現が期待できるが、車輪とレール間に発生する接線力は、車輪とレールの接触荷重や車輪とレールの接触面の状態など様々な要因で大きく変動するため、定量的に把握することが難しい。

そこで我々は、ニューラルネットワークを用いたブレーキ中の接線力の推定方法を検討している。ニューラルネットワークは与えられた様々なデータを学習することで、ネットワーク内のパラメータを最適化し、観測したデータからタスクに適した内部表現を獲得することができる。これを利用して、本稿では実物大ブレーキ試験装置で実測して得られたデータから、性質の異なる複数のニューラルネットワークモデルを構成し、各モデルによる接線力係数の推定を試みた。

### 2. 階層型ニューラルネットワーク

ニューラルネットワーク (以下、NN) の特徴として、経験を積むことで処理能力を適応的に変化させて、様々な事象を表現・理解することが可能になることが挙げられる。

われわれの脳はニューロンと呼ばれる神経細胞がシナプスと呼ばれる結合部位を介して多数結合してできているネットワークであり、NNはその脳神経系を模擬した情報処理

の数理モデルである。NN ではニューロンをノードと呼ばれる多入力 1 出力のしきい素子でモデル化し、複数のノードを結合することで任意の論理関数を表現可能にしている<sup>(1)</sup>。

NN の一種である階層型 NN (Hierarchical Neural Network: HNN) は入力層、隠れ層、出力層と複数の層があり、各層はそれぞれ後ろの層と結合している。それぞれの結合には結合の重みが割り当てられていて、入力層の信号は複数の隠れ層を通過し、出力層へと伝播されていく。

今回接線力の推定を行った NN モデルには簡易的な構造の HNN と、回帰結合型 NN の 1 つである長・短期記憶ネットワーク、畳み込み NN を使用している。

〈2・1〉 簡易階層型ニューラルネットワーク

入力層、隠れ層、出力層の 3 層からなる基本的な構造 (図 1) をしている NN モデルである。本稿では、他の NN モデルと区別するため、簡易階層型 NN (Simple-HNN: S-HNN) と呼ぶ。




図 1 S-HNN 例

〈2・2〉 回帰結合型ニューラルネットワーク

回帰結合型 NN (Recurrent Neural Network: RNN)<sup>(2)</sup> は、ある時刻 t における隠れ層の出力を次の時刻 t+1 の隠れ層へ伝播する構造 (図 2) を持つ。この構造により前の時刻からの入力が伝播されることによって、時刻間の影響を考慮できるようになっている。




図 2 RNN 模式図

〈2・3〉 長・短期記憶ネットワーク

長・短期記憶ネットワーク (Long Short-Term Memory: LSTM)<sup>(3)</sup> は RNN の一種であり、過去のデータを保持する仕組みを利用して勾配消失、勾配爆発問題を回避する特徴を持っている。LSTM は通常の RNN とは違い、隠れ層が LSTM ブロック (図 3) というもので構成されている。LSTM ブロック内では入力ゲート、忘却ゲート、出力ゲート、Constant Error Carousel (CEC) と呼ばれるユニットがあり、記憶の保持や忘却などを調整する役割を持っている。

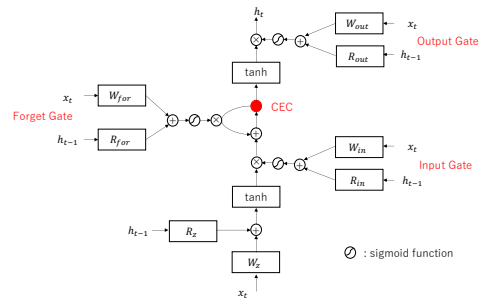


図 3 LSTM 模式図

〈2・4〉 畳み込みニューラルネットワーク

畳み込み NN (Convolutional Neural Network: CNN)<sup>(4)</sup> は、画像認識の分野を中心に利用されており、特徴抽出に長けている。CNN は入力層、畳み込み層、プーリング層、全結合層、出力層から構成されている。畳み込み層は入力データの局所の特徴を抽出し、その特徴量をプーリング層では情報をあまり失うことなく、データの次元削減を行っている。

3. 接線力係数の推定

実際の鉄道車両では直接計測することが難しい車輪・レール間に働く接線力を実測することができる「粘着試験ユニット」 (図 4) による実験を利用する。そして、粘着試験ユニットによって得られた接線力を真値として、NN で接線力係数の推定を行う。




図 4 粘着試験ユニット写真と模式図

〈3・1〉 使用データとモデルの概要

粘着試験ユニットで実測された接線力係数を教師データとして、NN モデルを構成し、実車でも測定できる値を入力として学習を行う。

今回 NN モデルの学習に使用した教師データは、粘着試験ユニットによる 130km/h から 50km/h までのブレーキ試験合計 15 回分である。その一例を図 5 に示す。また、教師データには条件が異なる 4 種類のデータ群を使用した (表 1)。滑走制御方法  $\alpha$  はすべりをある程度許容しながらブレーキを行うもので給気・排気の頻度が比較的少ない。一方、滑走制御方法  $\beta$  はすべりに応じて給気、排気を頻繁に繰り返す制御になっている。




図 5 ブレーキ試験結果例

表 1 使用データ群

	輪重 (kN)	滑走制御方法	滑走	データ数
データ群 A	40	$\alpha$	有	3
データ群 B	30	$\alpha$	有	6
データ群 C	30	$\beta$	有	3
データ群 D	30	$\alpha$	無	3

そして、作成した NN モデルの評価のために各データ群から各 1 個を検証データとして使用した。NN モデルへの入力値としては、軌条輪速度、車輪周速度、軌条輪減速度、車輪周減速度、BC 圧、すべり率を与え、接線力係数を出力値とするように構成した (図 6、表 2)。




図 6 NN モデル図

表 2 学習条件

入出力データ	入力値	軌条輪速度、車輪周速度、軌条輪減速度、車輪周減速度、BC 圧、すべり率		
	出力値	接線力係数		
学習	学習データ	ブレーキ試験結果 15 回分		
	テストデータ	条件の異なる 4 種類のブレーキ試験結果		
	epoch 数	100		
	最適化手法	adam		
NN の形状		S-HNN	LSTM	CNN+LSTM
	層数	3	3	4
評価値		平均絶対誤差		

〈3・2〉 推定結果と考察

推定精度の評価値として平均絶対誤差を図 7 に、接線力係数の推定結果をテストデータごとにまとめたものを図 8 に示す。

今回提案した NN モデルでは、LSTM が S-HNN より検証データ A、B、C において推定精度が高い。しかしながら、検証データ D においては、S-HNN がどの NN モデルよりも推定精度が高い。また、CNN+LSTM は検証データ B と C において他の NN モデルよりも推定精度が高いが、検証データ A と D においては他の NN モデルよりも推定精度は低い。さらに、各データで比較すると、どの NN モデルでも検証データ B、C、A、D の順で推定精度が低い。

LSTM が S-HNN より検証データ D を除いて推定精度が高いことから、速度情報などから接線力を推定するには、時間を考慮する必要があると考えられる。これは、LSTM が S-HNN と違い、時間の影響を考慮できるという特徴があるためである。また、検証データ D において LSTM の方が S-HNN よりも推定精度が低いのは、LSTM が滑走の有るデータ群についてうまく学習できたためだと考えられる。したがって、滑走の無いデータ群 D に対して相対的に適応できず推定精度が低くなったと考えられる。

CNN+LSTM においては、隠れ層の数が多くことを考慮すると学習の計算量が他の NN モデルに比べて多くなるので、全てのデータにおいて推定精度が高くなると考えられた。しかしながら、他のモデルに比べて検証データ A と D は推定精度が低い。これには 2 つの要因が考えられる。

まず 1 つは、CNN が持つ入力値と出力値の間にある特徴を抽出する特徴が表れている点である。今回の接線力係数の推定では滑走制御方法の違いによる大きな影響はなく、

輪重と滑走の有無の影響が相対的に大きいと考えられ、輪重と滑走の有無条件が同じである検証データ B と C の特徴を捉えて類似したデータとして学習したため、これら 2 つの検証データに対する推定精度が相対的に他の検証データに比べて高いと考えられる。

次に教師データの大きさによる学習の偏りが挙げられる。今回用意したデータは、初速度 130km/h から 50km/h まで減速する間の時系列データで、データ群 A と D に比べ、データ群 B と C はブレーキ試験時間が長い。そのため、サンプリング数も多くなり、NN モデルを学習する際にデータ群 B と C において学習回数が多いためと考えられる。




図 7 平均絶対誤差

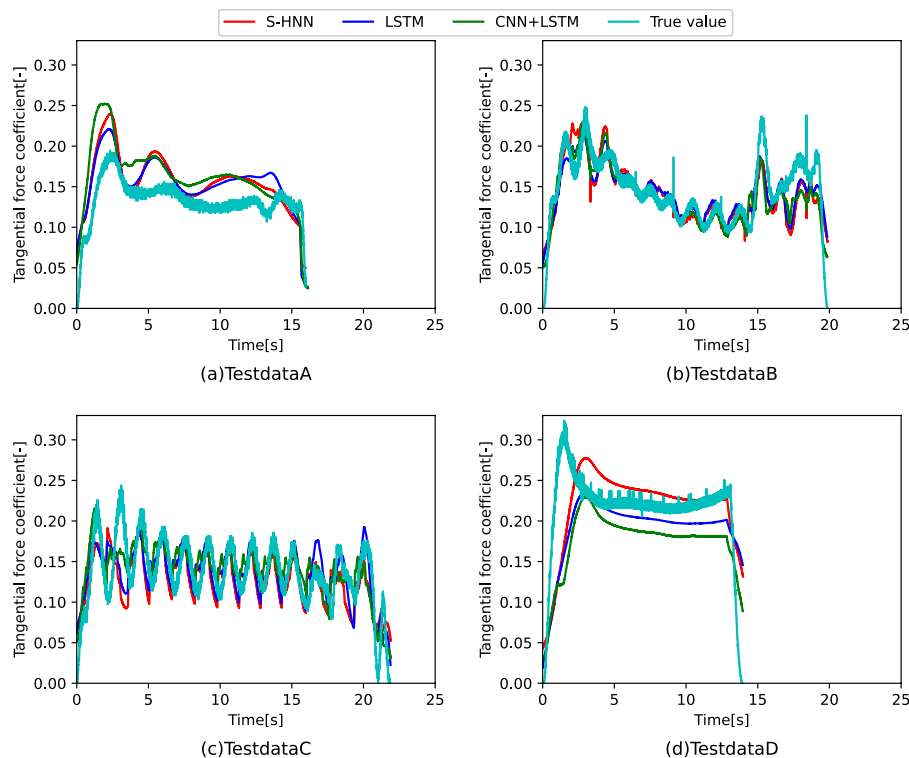


図 8 各検証データの推定結果

#### 4. おわりに

本稿では、NN を用いて車輪とレール間の接線力係数の推定をおこなった。推定結果は全体の傾向を捉えており一定の精度を有していたものの、課題も見られた。今後は学習に用いるデータの偏りを考慮した NN モデルと教師データの事前処理を適切に行う手法について検討を行う。また、今回使用した NN モデルは非常に簡易的なものであるため、隠れ層の数や組み合わせるモデルの数などを調整することでその推定精度を改良する取り組みも重要であると考えている。

#### 文 献

- (1) F. Rosenblatt: "The perceptron: a probabilistic model for information storage and organization in the brain.", *Psychological review*, Vol.65, No.6, pp.386-408 (1958)
- (2) J. L. Elman: "Finding structure in time.", *Cognitive science*, Vol.14, No.2, pp.179-211 (1990)
- (3) S. Hochreiter and J. Schmidhuber: "Long short-term memory", *Neural computation*, Vol.9, No.8, pp.1735-1780 (1997)
- (4) Y. LeCun, L. Bottou, Y. Bengio and P. Haffner: "Gradient- based learning applied to document recognition." *Proceedings of the IEEE*, Vol.86, No.8, pp.2278-2324 (1998).