

機械学習を用いた高頻度路線における遅延予測手法の構築

辰井 大祐[†] 中挾 晃介[†] 國松 武俊[†] 坂口 隆[†]公益財団法人鉄道総合技術研究所[†]

1. はじめに

近年、大都市圏の通勤路線において旅客の混雑が原因の小規模な遅延が発生し、鉄道事業者は余裕のある停車時間を設定する等の事前の対策を施している。しかし、それらの対策だけでは遅延の発生や拡大を防ぐことが困難である。

列車の運行を管理する業務を担当する指令員は、路線全体の状況を見て、今後の遅延の変化を予測し、その結果に応じて列車間隔を調整する等の運転整理が実施している。しかし、遅延の変化の予測を見誤ることがあれば、遅延の拡大を招き、結果として指令員の負担も増加する。

このような指令員の負担の軽減を目的に、これまで筆者らは、小規模遅延時を対象にニューラルネットワーク (NN) や Long Short Term Memory (LSTM) を用いた遅延予測手法を構築し、有効性を示した[1][2]。しかし、文献[1][2]における予測精度の評価対象路線は、朝ラッシュ時の平均運転間隔が3分30秒程度であり、旅客の混雑が原因の遅延が起こりづらい環境であった。そのため、本稿では、平均運転間隔が3分未満と短く、混雑による遅延が起こりやすい路線を対象に、NNとLSTMの予測性能を評価する。

2. NNを用いた遅延予測手法

文献[1]における予測手法では、計画ダイヤ上の全列車の着時点・発時点ごとに3層フィードフォワード型のNNを構築し、学習・予測を行う。NNの中間層は30個のユニットで構成される。

NNの入力は、予測時点を基準として、予測列車と先行列車の5駅前までの発遅延、予測列車の5駅手前までの乗車率とする。さらに、予測時点の駅で後続列車に予測列車が追い越される場合は、予測時点を基準に後続列車の5駅前までの遅延を入力とする。

一方、文献[1]における出力は、現在時刻から指定する時間先までの予測列車の発遅延、乗車

率である。しかし、乗車率について、文献[1]では自動改札機のデータから推定した値を用いており、リアルタイムに取得できる精緻な値ではないため、本稿の路線に適用する際には、発遅延データのみを用いて学習・予測を行う (モデル1)。モデル1における入出力データの関係を図1に示す。図1において、●が入力、●が出力を表す。

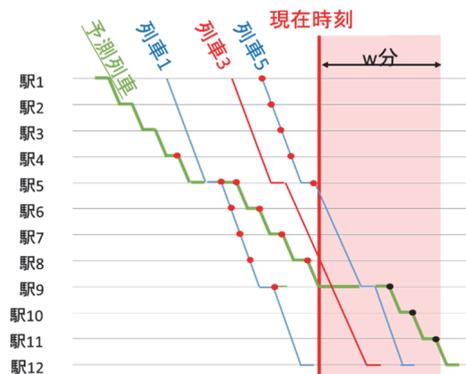


図1 モデル1の入出力

NNは事前に誤差伝播法により入出力データの関係性を学習する。そして、予測時点において入力データの対象となる遅延をもとに、数十分先までの発遅延と乗車率予測する。

3. LSTMを用いた遅延予測手法

文献[2]における手法では、列車の種類 (快速、普通等) ごとにLSTMを構築し、学習・予測を行う。

LSTMの入力は、予測列車の発遅延のみ、予測列車の着遅延と発遅延、予測列車と先行列車の発遅延、予測列車の発遅延と乗車率、という4パターンである。しかし、今回、NNと同様の理由により、LSTMについても遅延データのみで学習・予測を行うモデルを構築する。具体的には、予測列車の発遅延のみ (モデル2)、予測列車の着発遅延 (モデル3)、予測列車と先行列車の発遅延、(モデル4)、の3種類の学習・予測モデルを構築する。

Prediction method of train delay on high frequency line using machine learning

[†]Daisuke Tatsui, [†]Kosuke Nakabasami,

[†]Taketoshi Kunimatsu, [†]Takashi Sakaguchi

[†]Railway Technical Research Institute

モデル3を例に、LSTMの入出力データを図2に示す。モデル3では、現在時刻直前の着発遅延を入力し、LSTMは直後の予測着発遅延を出力する。その出力を入力とし、LSTMは直後の着発遅延を予測する。以上を繰り返し、出力対象となる全予測遅延を出力する。

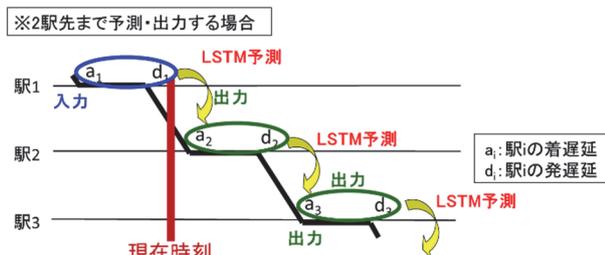


図2 LSTMの入出力

4. 予測精度評価

4.1 予測精度評価の概要

遅延予測について、現在、実務上用いられている代表的な方法が、現在の遅延量が継続するという前提での予測方法（モデル5）である。

本稿では、最大遅延量が300秒以内である小規模遅延時を対象に、構築した手法の有効性を評価するため、モデル1～モデル4と、モデル5の予測精度を比較する。

4.2 対象路線と使用するデータ

大都市圏において、旅客の混雑が原因となる小規模遅延が多く発生する路線を対象とする。

対象路線は28駅からなり、旅客の乗降が集中する駅も多い。さらに、朝ラッシュ1時間当たりの列車本数も特に多い路線になる。

遅延データは、2018年の中でダイヤ改正を実施した日以降、69日分のデータを活用した。そのうち、60日分を学習用に、残りの9日分を予測精度の評価に用いた。

また、遅延データについて、データの幅が[0,1]の範囲になるよう正規化して学習・予測に用いた。本研究では、遅延は300秒で正規化した。そのため、出力から予測値を求める際には、出力されたデータを、上記の値で乗算することにより、予測値を取得する。

4.3 学習方法

文献[2]における学習方法と同様に、モデル1～モデル4について、学習誤差閾値は0.001、最大学習回数は200回とする。活性化関数については、モデル1がシグモイド関数、モデル2～モデル4はReLU関数とした。なお、モデル1の学習率は

0.01、モデル2～モデル4について、学習はAdamによる最適化を行っている。

4.4 評価結果

30秒以上遅延が発生した列車を対象とし、5秒単位で予測遅延と実績遅延の差の絶対値の累積比率を求めた。そして、モデル1～モデル5について、累積比率を基準に比較した。結果を表1に示す。表1から、予測誤差が20秒以内となる予測の割合が最も高いのはモデル4であることを確認できる。LSTMを用いることで予測誤差の絶対値が少ない時の累積比率が高くなることは文献[2]と同様の結果である。一方で、文献[2]では、LSTMへの入力を予測列車の着発遅延とするモデル3の予測精度が高いことを示した。今回、モデル3ではなく予測列車と先行列車の発遅延を入力とするモデル4の予測精度が高くなった理由は、対象路線の運行頻度の違いが考えられる。本稿における対象路線のように列車間隔が短い場合、予測列車は先行列車の遅延の影響を大きく受ける。そのため、本評価試験においても、先行列車との相互関係を考慮しているモデル4の予測精度が高い結果が得られた可能性がある。

表1 モデルごとの累積比率の比較

予測誤差 (秒以内)	モデル 1	モデル 2	モデル 3	モデル 4	モデル 5
5	19.4%	25.9%	23.4%	26.2%	23.3%
10	34.8%	40.2%	37.9%	42.3%	37.9%
15	48.5%	50.6%	47.7%	52.9%	48.5%
20	60.3%	58.6%	55.4%	60.9%	56.3%
25	69.5%	65.0%	61.8%	67.4%	62.5%
30	76.5%	70.3%	67.2%	72.6%	67.5%
30以上	100.0%	100.0%	100.0%	100.0%	100.0%

5. まとめ

本稿では、小規模遅延時を対象に、NNとLSTMを用いた遅延予測手法と、実務上用いられる方法と比較することにより、LSTMを遅延予測に適用することの有効性を示した。

今後は、LSTMの予測が有効である列車や駅について等、詳細な分析をするとともに、大規模遅延時を対象とした予測手法の構築に取り組む。

参考文献

- [1]中挾晃介ほか：ニューラルネットワークを用いた列車遅延・乗車率予測手法、情報処理学会論文誌, Vol.60, No.4, pp. 1129-1140
- [2]辰井大祐ほか：遅延の傾向を反映したLSTMによる列車遅延予測手法、情報処理学会第83回ITS研究会, 2020