

Long Short Term Memory を用いた列車遅延予測手法の構築

辰井 大祐[†] 中挾 晃介[†] 國松 武俊[†](公財) 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の朝ラッシュ時において、数分程度の慢性的な遅延が発生するという問題が顕著になってきている。この数分程度の遅延の大きな要因の一つとして、旅客の混雑が考えられる。そのような、最大遅延が数分程度の小規模遅延時においても、詳細に列車遅延を予測する手法は確立されていないのが現状である。そこで筆者らは、将来的な大規模遅延時における列車運行予測手法の構築を念頭に、第一段階として、小規模遅延時を対象に、ニューラルネットワーク（以下、NN と呼ぶ）を用いた遅延や乗車率の予測手法を提案した [1]。今回、時系列データの予測に適した Long Short Term Memory（以下、LSTM と呼ぶ）を用いた列車遅延予測手法を構築し、NN を用いた予測と遅延の精度を比較し LSTM を用いた遅延予測手法の予測精度を検証する。さらに、LSTM の予測の傾向の分析を行うため、遅延量が前後の駅で 60 秒以上変化するような場合について LSTM を用いた予測が有効であることを確認する。

2. 背景と目的

列車の運行を管理する指令員は、遅延の発生時には、遅延の更なる拡大や、その他の列車に遅延が伝播することを防止するために、遅延の大きさに応じて列車のダイヤの変更を行う。遅延が小さい場合は、関係列車に対して列車の間隔が均等になるように停車時間を調整する。

ただ、遅延量によって適切なダイヤ変更方法が異なるため、列車遅延の推移を適切に予測する必要があるにも関わらず、遅延が今後拡大するか、縮小するかの判断は指令員の経験を頼りにしているのが現状である。

本研究では、大都市圏の通勤路線を対象に、NN を用いた予測と比較をすることにより、LSTM を用いた列車の遅延予測手法についての適用可能性を検証する。また、両手法は最終的には、遅延を予測することにより、適切な運行管理、旅客案内に活用することを目的とする。

3. NN を用いた遅延予測手法^[1]

NN を用いた列車遅延予測手法では、運行管

理システムで記録される、前日までの過去複数日の遅延実績データを使用し、学習モデルを事前に作成する。当日は、現在時刻までの列車遅延データを入力し、学習済みのモデルを適用することで、30 分程度先までの遅延の推移を予測、出力する。学習モデルは、列車毎、駅の発着別に 3 層 NN を用意して、実績データをもとに学習させる。入力は「予測対象列車と前列車の現在時刻から 5 駅手前分の遅延、予測対象列車の直前 5 駅手前までの乗車率」とする (図 1)。ただし、対象列車が後列車に追い越される (または待ち合わせをする) 場合には、後列車の遅延も現在時刻から 5 駅手前分入力とする。出力は、現在時刻から指定する時間先までの予測対象列車の発遅延とする。図 1 では後列車が予測対象列車と待ち合わせをする場合を示し、色つきの●が入力、■が出力となる。

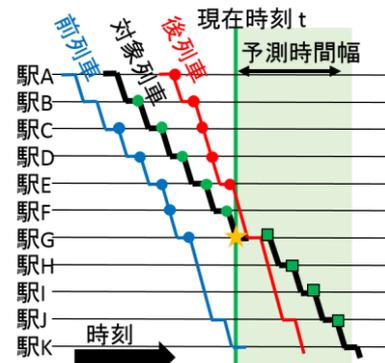


図 1 ニューラルネットワークの入出力

4. LSTM を用いた遅延予測手法

(1) LSTM の概要

時系列データの予測に適した深層学習のモデルの一つであり、中間層に NN のユニットではなく、LSTM ブロックをもつ。各 LSTM ブロックは入力ゲート、出力ゲート、忘却ゲート、記憶セルで構成されており、記憶セルと忘却ゲートの働きにより、長期の記憶が可能であるが不要な情報は忘れることができる構造である。

(2) LSTM を用いた学習・予測

本研究では、列車毎・駅発車事象毎に学習・予測のネットワークを構築する。また、LSTM を用いた場合、駅毎に後列車の遅延を加味する／しないを区別できないため、入力は、NN の入力と合わせ、現在時刻から 5 駅手前分の予測対

象列車と前列車の遅延、予測対象列車の直前 5 駅手前までの乗車率とする。同様の理由で、出力は時間幅ではなく、固定数先までの駅の発遅延を予測する。図 2 は予測対象駅数が 5 の場合を示し、色つきの●が入力、■が出力を表している。

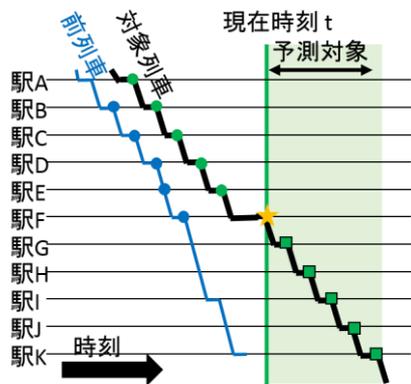


図 2 LSTM の入出力

5. 評価試験

5.1 対象路線の概要

全 20 駅（駅 A から駅 T）の路線で、駅 A、駅 G、駅 T で他路線と直通運転をしている。最も乗降客数が多いのは駅 J であり、快速運転も設定されている。

5.2 使用データ

79 日分の平日の発遅延、乗車率データを用いる。教師データとして 70 日分を、検証データとして 9 日分を用いる。なお、今回の対象路線では、乗車率が直接は取得できなかったため、各駅における自動改札機の旅客通過データと運行実績データを使用し、文献[2]のシステムにより各列車各駅間の乗車率を推定した値で代用する。

5.3 対象列車

小規模遅延が発生しやすい朝ラッシュ時間帯の 7:00~9:00 の間に、最も乗降客数の多い駅 J に到着する列車（駅 A 方向 34 本、駅 T 方向 33 本）とする。ただし、今回は 300 秒以上の遅延がある列車は評価の対象外としている。

5.4 ネットワークの構造と学習パラメータ

NN、LSTM とともに、入出力層の間に 1 層、30 ユニット（LSTM の場合は LSTM block 数 30）の構造とする。また、両モデルの学習パラメータはともに、学習率 0.001、学習誤差閾値 0.001、学習回数 1000 回とし、活性化関数については、NN はシグモイド関数、LSTM は ReLU を用いる。

6. 評価結果

30 秒以上の遅延列車に対する予測について、誤差の絶対値の累計比率の比較を図 3 に示す。

全体としては、NN での予測と LSTM での予測で大きな差は見られなかった。しかし、前後の駅で 60 秒以上遅延が変化する場合のみを抽出すると、図 4 のように LSTM の方が高い精度となる結果が得られた。これは、LSTM の構造上、忘却ゲートの存在により、遅延が大きく変化をする場合にも学習・予測しやすいという特徴があるためだと考える。

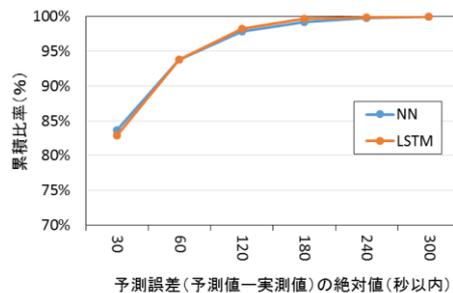


図 3 30 秒以上遅延時の予測精度比較

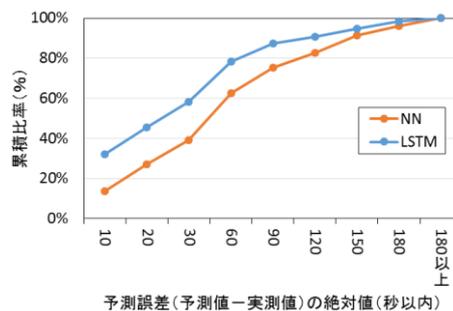


図 4 突発的な遅延発生直後の予測精度比較

7. おわりに

今回、大都市圏内の通勤路線の朝ラッシュ時間帯を対象に、LSTM を用いた遅延の予測の精度検証を行った。結果として、NN での予測と比較して同等の精度を得ることが出来た。また、遅延が変化する駅での予測については、LSTM での予測が有効であることを確認した。

今後の検討課題として、列車の種別毎にネットワークを構築する等により、教師データ数を増加させることを検討したい。

参考文献

- [1] 中挾晃介、辰井大祐、國松武俊：「ニューラルネットワークを用いた列車運行予測手法」、第 23 回鉄道技術連合シンポジウム（J-RAIL2016）予稿集、S5-2-3、pp.241-244 (2016)
- [2] 辰井大祐、國松武俊、石原裕介、坂口隆：「乗車率推定機能を有する対話型ダイヤ作成システムの構築」、電気学会研究会資料、TER、交通電気鉄道研究会、Vol.48、pp.23-28 (2012)