

深層学習を用いた列車遅延予測手法

辰井 大祐* 中挾 晃介* 國松 武俊*
坂口 隆* 田中 峻一*

Prediction Method of Train Delay Using Deep Learning Technique

Daisuke TATSUI Kosuke NAKABASAMI Taketoshi KUNIMATSU
Takashi SAKAGUCHI Shunichi TANAKA

In a commuter line within a large metropolitan area, it is important to predict train delay in several tens of minutes after when small train disturbance occurs. In practice, train delay is often predicted on the assumption that the situation continues for several tens of minutes. However it is difficult to accurately predict the delay because it actually changes in a complex way. To build an accurate prediction method, we developed a method using Long Short Term Memory. In this paper, we report the result of the performance evaluation of the improved prediction method.

キーワード：遅延予測，機械学習，深層学習，LSTM，運転整理，運行管理

1. はじめに

列車遅延は利用者の利便性の低下に繋がるため、鉄道事業者は遅延の発生、拡大を極力防止するための対策を実施している。遅延の発生を未然に防ぐ方法としては、ホーム幅を広げる、停車時間を予め長めに設定する等の対策がある。しかし、このような設備改良やダイヤ設定上の対策だけでは、一度発生した遅延の拡大を防ぐことができない。そのため、遅延の発生時には、列車間隔を調整する等の運転整理が実施される。現在は、列車運行を管理している指令員が、路線全体の運行状況を俯瞰して、各列車の今後の遅延の推移を予測したうえで、実施する運転整理を判断している。

遅延の推移を精度よく予測できれば、指令員に掛かる負担を軽減でき、遅延回復や遅延拡大防止の対策を早期に実施することができる。そこで筆者らは、これまでに、ニューラルネットワーク（以下、NN）を用いた短時間先の遅延を予測する手法を提案した¹⁾。同研究においては、基本的な性能を検証するために、第一段階として、数分程度の小規模遅延発生時を対象とした。

今回、さらなる予測精度の向上を目指し、深層学習の一つのモデルである Long Short Term Memory（以下、LSTM）を用いて、列車遅延を予測する手法を構築した。提案した手法の予測精度を評価した結果、NNを用いた遅延予測手法と比較し、予測誤差の絶対値が5秒以内となる割合が22.1%から38.9%に17ポイント上昇したことを確認した。また、現在の遅延がそのまま継続すると仮定して遅延量を見積もる方法（以下、遅延量継続と呼

ぶ）とも比較を行い、提案手法の有効性を評価した。本稿では、その結果について述べる。

2. 背景と目的

2.1 遅延の発生と拡大

近年、大都市圏内の通勤路線における遅延が鉄道事業者の課題となっている。文献2によれば、東京圏の45路線において、最大遅延が5分以上に達した日は、2018年度では1か月あたり平均して約12日であったと報告されている。併せて、10分未満の小規模遅延のおおよそ50%が混雑に伴う乗降時間超過が原因であることが報告されている。

主に、通勤路線のラッシュ時間帯において発生した遅延が他の列車に伝播する流れを下記に示す。

(1) 初期遅延の発生

ホームや列車内の混雑により、駅での乗降時間が所定の停車時間より超過することで、初期遅延が発生する。また、ドア挟みや駆け込み乗車、トラブル等により、偶発的に初期遅延が発生することもある。

(2) 利用者の集中による遅延拡大

初期遅延により、当該列車と先行列車の間隔が拡大するため、次駅で当該列車を待つ利用者が増加し、利用者の集中が起こる。その結果、次駅でも停車時間超過が起こり、遅延がさらに拡大する。

(3) 後続列車への遅延伝播

(1) または (2) による発遅延によって後続の列車は減速もしくは駅間で停止するため、遅延が伝播する。

* 信号・情報技術研究部 運転システム研究室

2.2 現状の運行管理業務と課題

列車の運行を管理する指令員は、更なる遅延の拡大、伝播を防止するために、遅延発生時には、数十分先までの遅延を予測し、遅延の大きさに応じて様々な運転整理を行う。

現状では、このような遅延状況の変化は指令員が経験的に予測を行っている。そのため、運行状況を見誤ると、遅延の更なる拡大を招く可能性がある。特に、列車の運休や順序の変更が起こるような大きな遅延発生時には、その後の遅延状況の正確な予測がより重要になる。

しかしながら、小規模の遅延が発生した場合でさえも、上記のような短時間先の列車遅延の予測手法は確立されていない。近年、短時間先の列車ダイヤ、遅延を予測する機能が運行管理システムで実用化されつつある。しかし、それらは現行の遅延量が継続する仮定での予測であるか、または車両や線路の設備の条件をもとに各列車が最速で走行した時の遅延を予測する手法であり、複雑に変化する遅延状況の予測には不十分であった。

2.3 列車運行の予測に関する関連研究

日本国内における列車運行予測に関する研究は、遅延が発生し伝播する様子を、基本的な規則に沿って順次計算し予測するものが提案されている^{3) 4)}。しかし、これらは、過去の遅延、乗車率データを直接に反映しておらず、路線固有の状況を反映して精度良く予測できるとは言い難い。また、岩本らは、短時間先の遅延を予測しダイヤ図を描画する予測ダイヤ機能を開発し、一部路線の運行管理システムで実用化している⁵⁾。しかし、駅、列車種別、時間帯等に応じた多くのパラメータをユーザが設定する必要があり、その適切な設定方法に課題がある。

一方、海外でも、Xavier らによって、NN による各駅の到着時間の予測手法が提案されている⁶⁾ が、利用者の流動や緩急接続による遅延を加味していないため、大都市圏内の通勤路線の複雑な遅延状況の変化を表現することは難しい。また Wang らも実際の遅延データや利用者のデータをもとに機械学習を用いて遅延の予測手法を構築している⁷⁾。しかし、その対象路線は長距離路線であり、最短でも 10 分以上の列車間隔になっている。日本の大都市圏内の通勤路線の朝ラッシュの状況とは大きく異なるため、これを適用するには手法の更なる改良が必要であると考えられる。

2.4 本研究の目的

以上を踏まえ、本研究では、運行体系が複雑な大都市圏の通勤路線を対象に、ラッシュ時間帯の小規模遅延発生時の遅延状況の推移を精度良く予測する手法の構築を目的とする。既に他分野で時系列データの予測等への適用が進められている LSTM を用いて、過去の遅延の傾

向を捉えた予測が可能となるよう、普通や快速などの列車の種類（以下、列車種別）に応じて列車の遅延を予測する LSTM（モデル）を構築する。

3. NN を用いた列車遅延予測手法

本章では、これまでに筆者らが構築した NN を用いた列車遅延予測手法（以下、モデル 1）について概説する。

3.1 NN の構築単位

3 層の階層型フィードフォワード NN を用い、中間層のユニット数は 30 個とする。各列車の各駅の着時点、発時点ごとに NN を用意し、それぞれ独立に学習と予測を行う。NN は、誤差逆伝播法により後述する入力と出力の関係性を事前に学習しておく。そして、予測対象日の予測時点に至るまでに得られた遅延データ、乗車率データを用いて、数十分先までの予測対象列車の発遅延、乗車率を予測する。

3.2 モデル 1 における NN の入出力

モデル 1 における NN の入出力を図 1 に示す。

(1) 入力

予測対象列車と先行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。ただし、図 1 のように後続列車に予測対象列車が追い越される場合は、後続列車の直近 5 駅手前分の遅延を入力とする。

(2) 出力

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、乗車率を出力する。

4. LSTM を用いた列車遅延予測手法

本章では、今回構築した、LSTM を用いた列車遅延予測手法を概説する。




図 1 NN における入出力

4.1 LSTMの構成

LSTMは深層学習のモデルの一つであり、遅延のように時間の経過とともに変化する時系列データの予測に適したモデルである。特に音声認識や自然言語処理の分野への適用が進められている。

LSTMはNNの中間層がLSTMブロックに置き換えられ、現在時刻のLSTMブロックの情報が次の時刻のLSTMブロックへ入力されることにより、それらを以降の予測に反映できるモデルである(図2)。LSTMブロックは忘却ゲート、入力ゲート、出力ゲート、記憶セルで構成されている。各構成要素の役割を下記に記す。

- 忘却ゲート
長期的な記憶を保持し、必要のない過去の情報をリセットする。
- 入力ゲート
現在時刻のLSTMブロックへの入力を、一つ前の時刻のLSTMブロックから受ける影響を加味して決定する。
- 記憶セル
長期的な記憶の保持と更新を行う。
- 出力ゲート
長期的な記憶をもとに、出力値を調整する。

4.2 学習・予測モデルの構築単位

LSTMは時系列データを扱うモデルであるため、遅延予測に用いる際には、モデル1のように列車・駅の着事象、発事象毎にモデルを作ることはできない。

また、深層学習は一般に、学習のために大量のデータを必要とする。文献8によると、過去の深層学習に関するプロジェクトにおいて、活用されたデータ数は数万～数十万セットと報告されている。

列車遅延を予測するLSTMを用いた学習・予測モデルを構築する単位として、①列車毎にLSTMを構築する、②列車種別毎にLSTMを構築する、ことが考えられる。しかし、①の場合は、各モデルに対して活用でき

るデータ数は最大でも日数×駅数でしかない。一方、②であれば、同一種別の列車のデータをまとめて活用できるため、データ数は日数×駅数×該当列車種別の列車本数となり、一定量のデータセット数を活用することができると考えられる。

これを踏まえ、今回は、列車種別毎にLSTMを構築するモデルを構築した。

4.3 LSTMの入出力

4.3.1 先行列車と後続列車の判定手法

モデル1では計画ダイヤ通りに列車が運行されている前提で、計画ダイヤ上の先行列車、後続列車の発遅延を入力としていた。しかし、列車の運休や順序変更が行われた場合には、先行列車や後続列車が計画ダイヤのものから変化し、適切に予測できないという課題があった。そこで本研究では、実績ダイヤにおける先行列車、後続列車の発遅延を入力とすることにした。

これまでの計画ダイヤをベースとした判定方法による先行列車と後続列車、今回の実績ダイヤをベースとした判定方法による先行列車と後続列車の違いを図3と図4に示す。駅7における、計画ダイヤベースの順序関係は(先行列車, 後続列車) = (列車3, 列車7)であるが、実績ダイヤベースの場合、列車順序が入れ替わっており、(先行列車, 後続列車) = (列車1, 列車11)になる。

4.3.2 入力データの異なるモデルの比較

LSTMへの適切な入力方法を決定するため、入出力を以下のように変更した学習・予測モデルを構築した。

- 予測対象列車の発遅延 (以下、モデル2)
 - 予測対象列車の発遅延と着遅延 (以下、モデル3)
 - 予測対象列車の発遅延と先行列車の発遅延 (以下、モデル4)
 - 予測対象列車の発遅延と乗車率 (以下、モデル5)
- 構築した各モデルの概要を表1に示す。

モデル3を例に、駅の着時点での予測と発時点での予測のための入力と出力を示す。モデル3では、着時点と

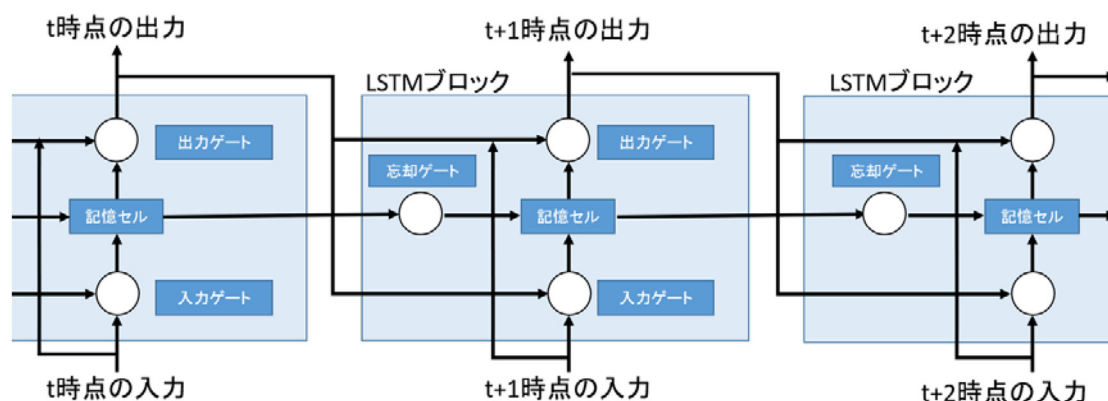


図2 LSTMの内部構造とデータの流れ

表1 構築した各モデルの概要

手法	NN	LSTM			
モデル名	モデル1	モデル2	モデル3	モデル4	モデル5
入力データの 種類	<ul style="list-style-type: none"> 先行列車・後続列車の発遅延 予測対象列車の発遅延 予測対象の乗車率 	<ul style="list-style-type: none"> 予測対象列車の発遅延 	<ul style="list-style-type: none"> 予測対象列車の着遅延 予測対象列車の発遅延 	<ul style="list-style-type: none"> 先行列車の発遅延 予測対象列車の発遅延 	<ul style="list-style-type: none"> 予測対象列車の乗車率 予測対象列車の発遅延
先行・後続列車の 判定基準	計画ダイヤ	実績ダイヤ			




図3 計画ダイヤを基にした先行列車・後続列車

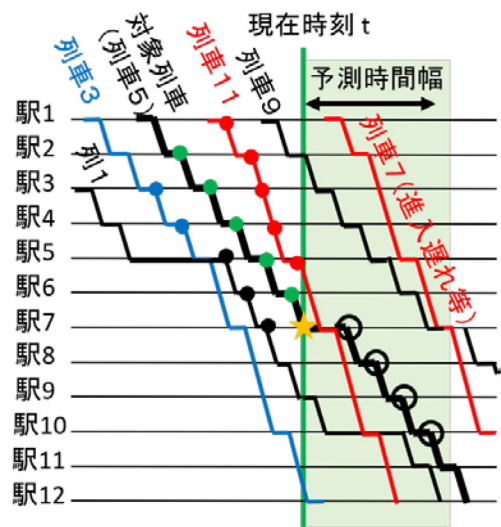


図4 実績ダイヤを基にした先行列車・後続列車

発時点で入出力が異なる。対象列車の各駅における発遅延を $d = (d_1, d_2, d_3, \dots)$ ，対象列車の着遅延 $a = (a_1, a_2, a_3, \dots)$ と表すと，着時点での予測の場合，(入力，出力) = $\{([d_1, a_2]), [d_2, a_3]), ([d_2, a_3], [d_3, a_4]), \dots\}$ となり，発時点での予測の場合，(入力，出力) = $\{([a_1, d_1]), [a_2, d_2]), ([a_2, d_2], [a_3, d_3]), \dots\}$ となる。

なお，次章の予測精度評価においては，LSTM の出力する発遅延のみを評価対象として予測精度を比較する。

5. 予測精度の評価

5.1 評価方法の概要

本評価では，列車種別毎に構築する LSTM への入力を変化させ，予測誤差（予測遅延量－実績遅延量）の絶対値の累積比率を基準に，モデル1と予測精度の比較を行った。併せて，冒頭（1章）で述べた遅延量継続の場合と比較し，提案手法の有効性を検証した。

5.2 対象路線と対象列車

大都市圏内の20駅からなる路線を対象とした。当該路線では，複数種別の列車（普通，快速等）が運行されており，列車ダイヤ上は追い越しが無い並行ダイヤになっている。また，他線との直通運転も実施している。

なお，今回の予測精度評価の対象となる列車は，乗降人員が最大である駅13において，朝ラッシュの7:00～9:00の間に到着または発車する全67列車とする。

5.3 使用データ

遅延データは，2015年9月，10月，2016年1月，2月の平日79日の実績遅延データのうち70日分を学習データ，残りの9日分を予測精度評価に用いた。

現状ではリアルタイムに各列車の各区間の乗車率を取得することができないことから，乗車率は推定値を用いた。各駅の自動改札機で取得することができる時間帯別ODデータ（出場駅，出場した時間帯，入場駅，人数の

組み合わせのデータ)と実績ダイヤをもとに、文献9のシステムを用いて各列車の各区間の乗車率を推定し、それを実績の乗車率とみなして代用した。

また、遅延、乗車率のデータについて、データの幅が[0, 1]の範囲になるよう正規化してLSTMの学習・予測に用いた。本研究では、遅延は300秒、乗車率は200%で正規化した。そのため、出力から予測値を求める際には、出力されたデータに上記の換算率を乗算することにより、予測値を取得する。

5.4 各手法における学習方法

本評価では、提案するLSTM(モデル2~5)、NN(モデル1)、遅延量継続の場合を対象に、予測精度の比較を行う。本節では、各手法における学習条件をまとめる。

LSTMのモデル2~モデル5については、LSTMの出力値を決定する関数をReLU(0以下なら0, 0以上なら入力値と同じ値を返す関数)とし、学習率を適応的に変化させるAdamを用いて学習を行い、学習誤差閾値は0.001とする。Adamは、学習初期における重みの更新量は大きく、学習終盤における重みの更新量は小さくなるように学習率を変化させる等の特徴をもち、学習の収束が早いことが知られている。なお、学習回数については、モデル2~モデル5までの学習誤差の変化を踏まえ、全モデルで200回とした。

NNについては、活性化関数はシグモイド関数、学習率0.01、学習誤差閾値0.001とし、最大学習回数は1000回とした。

5.5 評価結果

予測性能の評価として、運行区間内で30秒以上遅延が発生した列車を対象に、全ての予測発遅延における実績の誤差の絶対値を指標として、モデル1からモデル5について、5秒単位で全ての予測における誤差の絶対値の累積比率を確認した(表2)。表2から、モデル1(NN)とそれ以外(LSTM)とではやや異なる傾向がみられる。一方、入力データが異なるLSTM間に差はほとんどみられなかった。したがって、LSTMの入力データの種類を変えても、精度は同程度であることを確認した。そこ

で、以降の考察では、モデル2~5の中で、予測誤差5秒以内の累積比率が最も高かったモデル3と、モデル1または遅延量継続の場合との比較を中心に行う。

LSTMのモデル3とNNのモデル1を比較した場合、5秒以内の予測誤差となる割合が22.1%から38.9%に17ポイント増加した(表2の黄色のセルと青色のセル比較)ほか、誤差15秒以内の予測誤差となる割合についても、モデル3の方が予測精度が高いことがわかる。以上から、全体として、NNよりもLSTMの方が精度良く予測できることが分かった。

しかし、モデル1の方がモデル3より優位なケースも存在する。例えば、予測当日の遅延の傾向と、学習データの平均的な傾向が似ている場合に、NNの方が精度が高いケースが存在した。例として、ある日における普通列車1の駅9着時点での予測(駅9~駅2まで)結果を図5に挙げる。図5では実績遅延は黒色、学習データの中央値が緑色、モデル1の予測が青色、モデル3の予測が赤色で示されている。同図において、モデル1は駅9までの遅延状況から駅9以降の遅延について実際の遅延の傾向を捉えて予測できていることがわかる。一方、モデル3では遅延が減少すると予測している。モデル1の学習データは列車1の駅9着時点に特化するため、過去の日々の列車1について、駅8~駅2の遅延実績の平均的な値に近い予測となる。一方で、モデル3は列車種別毎にモデルを構築しているため、同一列車種別である別の列車や、別の駅での遅延の推移の影響を受けた予測と




図5 モデル1の方が精度が高かったケース

表2 予測誤差の絶対値の累積比率

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	遅延量継続
5	22.1%	38.1%	38.9%	36.2%	38.1%	38.0%
10	41.8%	57.5%	58.5%	56.2%	57.9%	52.4%
15	58.7%	68.1%	69.5%	67.3%	69.5%	63.5%
20	72.0%	75.5%	76.5%	74.8%	76.9%	71.6%
25	80.4%	80.6%	81.2%	79.9%	81.4%	77.7%
30	85.6%	84.6%	85.0%	83.6%	85.1%	82.5%




図6 モデル3の方が精度が高かったケース

なるためと考えられる。

モデル3の方がモデル1より予測精度が高いケースについても例を示す。例えば、ある駅において遅延が急増する場合は、モデル3の方が予測精度が高いケースが存在した。ある日における列車3の駅6着時点での予測結果を図6に示す。図6では実績遅延は黒色、モデル1の予測が青色、モデル3の予測は赤色で示されている。駅6着時点の予測結果を確認すると、モデル1は遅延が急増することを予測に反映できていないが、モデル3はその傾向を掴んだ予測ができています。前述のように、モデル3は同一種別の他の列車や他の駅における遅延の推移も反映したモデルになっており、このケースについては、遅延が急増することも加味した予測をすることができたと考えられる。

また、表2から、モデル3の予測精度を遅延量継続の場合と比較した場合、モデル3については、予測誤差の絶対値が小さい階級の累積比率が高いということを確認することができる。すなわち、遅延量継続の場合と比較して、全体として高い予測精度をもつと考えられる。

6. まとめと今後の課題

本稿では、列車種別毎に構築したLSTMを用いた列車遅延予測手法について、列車の追い越しが無い並行ダイヤの路線の小規模遅延発生時を対象に、遅延の予測精度について評価を行った。その結果、入力データを着遅延と発遅延の2種類とすることで、予測誤差が5秒以内となる割合がNNを用いた遅延予測と比較して22.1%から38.9%に17ポイント程度上昇し、精度が向上することを確認した。また、遅延量継続の場合、NNを用いた予測手法、提案手法の3つを比較した場合、提案手法が全体として予測精度が高いことを確認した。

今回の予測精度評価では、全ての予測タイミング、全

ての対象駅についての予測精度を同一に取り扱い、全体としての予測精度を評価した。しかし、実際には、各列車の各駅の着時点、発時点で予測は変化するため、予測のタイミングにより精度も変化する。さらに、予測対象が遠くの駅ほど精度が低いことが考えられる。予測対象駅が何駅先かによって分けて評価する等の詳細な分析については、今後の課題となる。

今後の展開として、(1)小規模遅延発生時において、列車の追い越しがある路線での予測精度の評価、(2)列車の運休や順番が変更するような遅延発生時において、追い越しのない路線での予測手法の構築、(3)(2)と同様の状況で追い越しのある路線での予測手法を構築する必要があると考えている。

文献

- 1) 辰井大祐, 中挾晃介, 國松武俊: ニューラルネットワークによる列車運行予測手法, 鉄道総研報告, Vol.31, No.10, pp.29-34, 2017
- 2) 国土交通省鉄道局報道発表資料: 東京圏の鉄道路線の遅延「見える化」(平成30年度), 2020
- 3) 安部恵介, 荒屋真二: 最長経路法を用いた列車運行シミュレーション, 情報処理学会論文誌, Vol.27, No.10, pp.103-111, 1986
- 4) 國松武俊, 平井力, 富井規雄: マイクロシミュレーションを用いた利用者の視点による列車ダイヤ評価手法, 電気学会論文誌D(産業応用部門), Vol.130, No.4, pp.459-467, 2010
- 5) 岩本章寛ほか: 予測ダイヤからの運転整理入力機能の開発, 鉄道サイバネ・シンポジウム論文集, Vol.51, PP.5, 2014
- 6) X. Chapuis: Arrival Time Prediction Using Neural Networks, proceedings of 7th International Conference on Railway Operations Modeling and Analysis, 2017.
- 7) W. Wang, et al.: A feasibility study on developing an intelligence ensemble system for predicting and preventing train delays, Project Report of Data Sandbox launched by RSSB.
- 8) ライオンブリッジジャパン株式会社 機械学習にはどのくらいの学習データが必要か, <https://lionbridge.ai/ja/articles/how-much-ai-training-data-do-you-need/> (参照日: 2020年11月11日)
- 9) 辰井大祐ほか: 高速な乗車率推定機能を組み込んだ対話型ダイヤ作成システムの開発, 鉄道総研報告, Vol.27, No.9, pp.29-34, 2013