

鉄道一般
車両
施設
電気
運転・輸送
防災
環境
人間科学
浮上式鉄道

# 深層学習を用いて 列車遅延を予測する

列車の運行を管理している指令員の業務の支援や、遅延情報の提供による旅客サービスの向上を実現するうえで、列車遅延を予測することは重要です。しかし、現状では、現在時刻から短時間先までの遅延でさえ、正確に予測する手法の確立は実現していません。そこで、まずは小規模な遅延を対象として、ニューラルネットワークや深層学習を用いた列車遅延予測手法を構築しました。ここでは、構築した手法の概要と、大都市圏内の通勤路線を対象に遅延予測精度を評価した結果を紹介し



**辰井 大祐**  
Daisuke Tatsui  
信号・情報技術研究部  
運転システム研究室  
副主任研究員



**中挾 晃介**  
Kosuke Nakabasami  
前 信号・情報技術研究部  
運転システム研究室  
研究員



**國松 武俊**  
Taketoshi Kunimatsu  
信号・情報技術研究部  
運転システム研究室  
主任研究員



**坂口 隆**  
Takashi Sakaguchi  
前 信号・情報技術研究部  
運転システム研究室長

## 鉄道事業者の遅延対策

大都市圏内、とくに首都圏において、利用者の混雑にともなう遅延が慢性的に発生しています。文獻1によると、東京圏の45路線で、2018(平成30)年において、1か月の平日20日あたり平均11日間で5分以上遅延が発生しているという集計結果が示されています。

鉄道事業者は、遅延発生・拡大を防ぐために、停車時間が長めになるような列車ダイヤを設定するなどの対策をしていますが、それでも遅延の発生・拡大をゼロにすることは難しい状況です。

そのため、遅延発生時には、指令員が路線全体の運行状況を把握したうえで、乗車率が均等化するように列車の

間隔を調整したり、遅延が大きい場合には列車を運休したりします。これらの一連の業務を「運行管理」とよびます。

## 運行管理業務の課題

運行管理業務においては、列車の運行状況がどのように変わっていくかによって、適切な手配が異なってくるため、指令員は今後の運行状況を予測します。例えば、列車1、列車2、列車3があり、現在時刻で列車3に遅延がある状況を考えます(図1)。

この状況において、列車3の遅延が今後拡大すると予測される場合、例えば列車2の停車時間を調整して列車の間隔を調整します。一方、列車3の遅延が縮小すると予測される場合は、停車時間の調整は不要になります。

現状では、これらの運行状況の予測は指令員の経験に基づいているため、実際の運行状況の変化が異なると、さらなる遅延の拡大を招く可能性があります。そのため、データに基づいて定量的に遅延の変化を予測する手法の確立が望まれます。しかし、現在までに、正確に予測する手法は確立されていません。

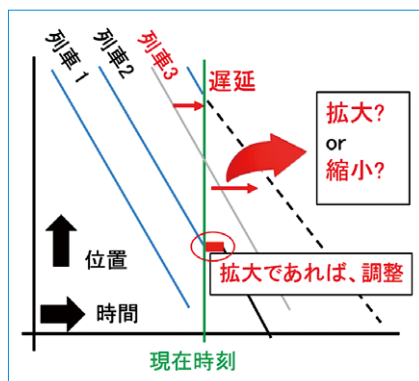


図1 指令員による間隔調整

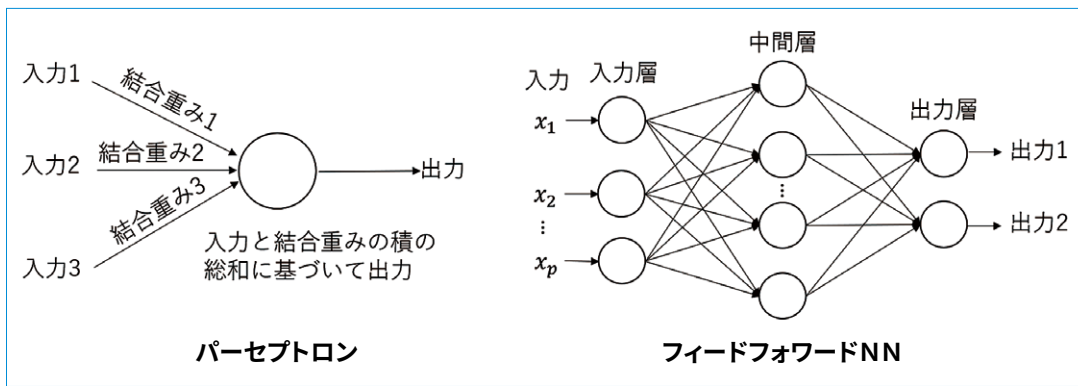


図2 パーセプトロン(左)とフィードフォワードNN(右)

### 研究の目的と効果

この研究では、小規模遅延発生時を対象として、列車遅延の予測手法の構築を目標としています。数十分先の遅延を精度よく予測することが可能になれば、前述のような指令員の判断を支援することができるとともに、利用者へ遅延情報を提供することによって旅客サービスの向上も図ることが可能になります。このような効果を生み出すための技術の構築がこの研究の最終目的になります。

### 研究のアプローチ

これまでさまざまな列車遅延の予測手法が提案されてきました。しかし、それらは現在の遅延量が継続する前提での予測、または車両や線路の物理的な条件のもとで列車が最速で走行した場合の遅延を予測する方法であり、複雑に変化する実際の遅延を精度よく予測するのは困難でした。

この研究では、実績の遅延データと乗車率のデータのみを活用し、複雑に変化する遅延の予測に適する、機械学習を用いた遅延予測手法を構築するアプローチをとりました。今回用いる手法では、過去の遅延や乗車率のデータをもとに、列車遅延を予測するモデルを事前に学習させたうえで、予測対象日当日の遅延や乗車率をモデルに入力し、現在時刻から数十分先までの列車遅延を予測します。

予測に使用する機械学習の手法とし

て、今回、これまでの研究では用いられなかったニューラルネットワーク(以下、NN)と、深層学習の手法であるLong Short Term Memory(以下、LSTM)の2種類を検討しました<sup>2)</sup>。そして、大都市圏内の通勤路線を対象に、NNとLSTMを用いた予測手法の精度を評価しました。

### NNと深層学習

NNは人の脳の神経回路網を計算機上で表現する数学的なモデルです。一つ一つの神経細胞の働きをパーセプトロンとよばれる計算モデルで表現し、それらが層状に積み重なることでNNが構成されます。広く用いられているNNは入力層、中間層、出力層の3層構造になっており、フィードフォワードNNとよべます(図2)。入力層のパーセプトロンの出力は中間層のパーセプトロンに影響を与え、中間層のパーセプトロンは出力層のパーセプトロンへ影響を与えます。この影響の大きさは、パーセプトロン間の結合の重みとして表現されます。このモデル構造を使い、入力に対して正しい出力値がわかっているデータをもとにNNやLSTMなどの出力が正しい値に近づくよう、内部のネットワークの結合の重みを調整します。一般的に、この結合の重みの調整を学習とよびます。

このNNを応用した深層学習が昨今、注目を浴びています。深層学習はNNの中間層の数を増やした多層NNを使

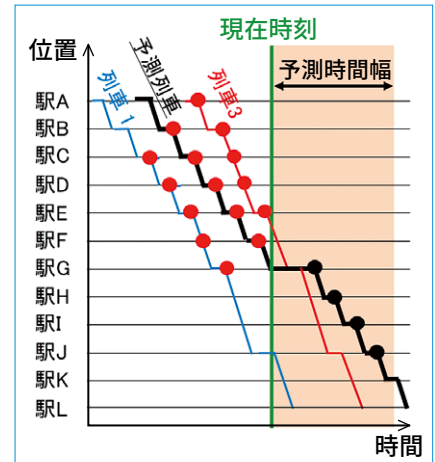


図3 NNの入出力

用します。多層NNに対してさまざまな技術改良がおこなわれた結果、とくに画像認識の分野で圧倒的な性能を示すようになりました。また、LSTMは深層学習の中でも、列車遅延のように時間の経過とともに変化するデータの予測に適用される手法です。

### NNを用いた列車遅延予測手法

まず、遅延と乗車率を入力とし、数十分先までの列車遅延と乗車率を予測する手法を、NNを用いて構築しました<sup>2)</sup>。具体的には、予測する列車の前を走行する列車の5駅前までの発遅延、予測する列車の5駅前までの発遅延を入力とします。なお、予測列車を追い越す列車がある場合は、追い越す列車の5駅前までの発遅延を入力に追加します。出力は、予測する列車の数十分先までの発遅延、乗車率になります(図3)。図3の中の●時点の遅延が

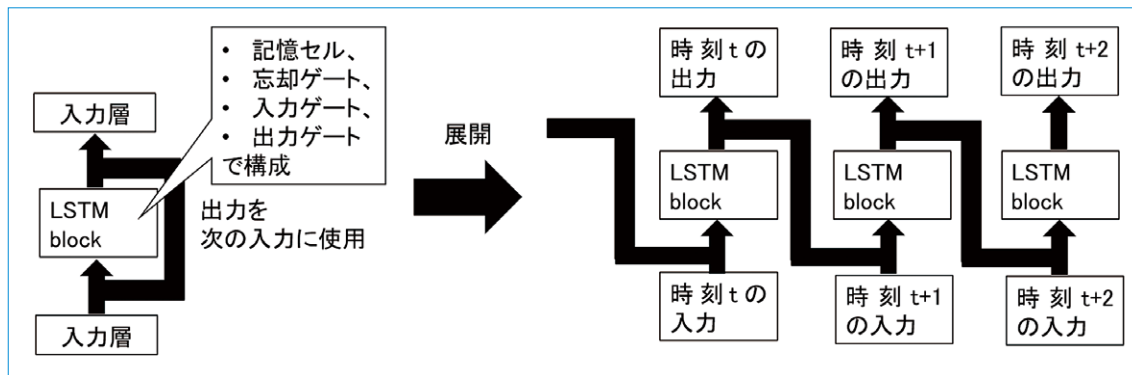


図4 LSTMの構造と入出力の関係

表1 構築したLSTMの列車遅延予測モデル

モデル名	モデル1	モデル2	モデル3	モデル4
入力データの種類	予測対象列車の発遅延	予測対象列車の着遅延 予測対象列車の発遅延	先行列車の発遅延 予測対象列車の発遅延	予測対象列車の乗車率 予測対象列車の発遅延

入力、●時点の遅延が出力を表しています。このような入出力となるNNを各列車の各駅着時点、発時点ごとに構築して列車遅延を予測します。

### LSTMとは

LSTMは、NNの技術を応用した深層学習のモデルであり、短期的なデータの傾向だけでなく、長期的なデータの傾向も反映した予測が可能という特徴をもちます。

LSTMに関しては、さまざまな構造のものが提案されているのですが、今回は、広く用いられている基本的なLSTMを活用しました。

今回用いたLSTMでは、NNにおける中間層が一つのLSTM Blockに変わっており、LSTM Blockの出力が次の予測時刻のLSTM Blockへの入力になっています(図4)。このように、ある時点のLSTMの出力が次の時刻のLSTMへの入力となることで、過去の情報を反映した予測が可能になります。また、LSTMは、現在時刻の予測に必要な昔の情報については、その情報を保存しない機能もあります。

以上の機能をもつことで、短期的なデータの傾向だけでなく、長期的なデータの傾向を適切に反映した予測が可能になります。

### LSTMを用いた列車遅延予測手法

現在時刻以降の発遅延に影響を及ぼすと考えられる予測対象列車の着遅延、発遅延、乗車率、先行列車の発遅延の組み合わせ中から、LSTMを用いた遅延予測に適する入出力データを選定するために、入出力データが異なるLSTMモデルを4つ構築しました(表1)。例えば、予測する列車の着遅延、発遅延をLSTMの入出力とするモデル2の入出力を図5に示します。現在時刻にもっとも近い着遅延、発遅延を入力とし、次の着遅延、発遅延を出力します。その出力をLSTMへの

入力とし、その次の着遅延、発遅延を出力します。このような処理を予測対象となる着遅延、発遅延がすべて出力されるまで繰り返します。

今回構築したLSTMモデルでは、運行する列車の種類(快速や各駅停車など)ごとに1つずつ構築して列車遅延を予測します。

### 実路線を用いた予測精度評価

大都市圏内の通勤路線(全20駅)を対象に、朝ラッシュ時間帯(7:00~9:00)にもっとも乗降の多い駅に到着/発車し、30秒以上遅延がある列車を対象に予測精度を評価しました。

用いるデータは平日79日分で、NNとLSTMの学習のために70日分を用い、残りの9日分を予測精度検証用に用いました。LSTMの学習に関するパラメーター(☞参照)は学習の誤差の

#### ☞学習に関するパラメーター

NNやLSTMを用いた学習を行う際、一回の学習における結合重みの調整量を表す指標である学習率と、最大学習回数、学習の誤差がどの程度になれば学習を終了するかのしきい値があります。学習率については、学習状況に応じて適用的に変化させる方法も広く用いられています。

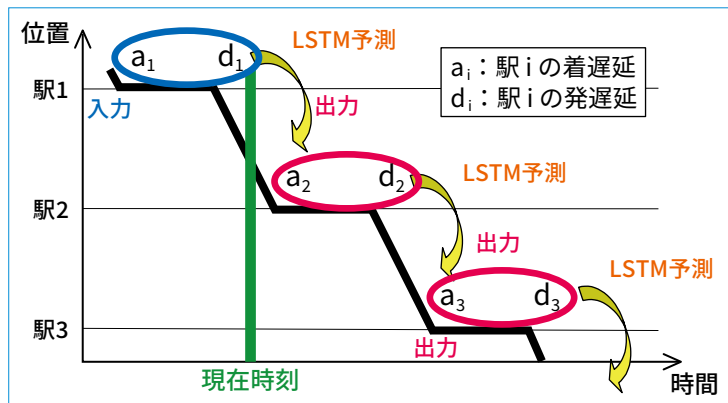


図5 着遅延・発遅延を入力とした場合のLSTMの入出力

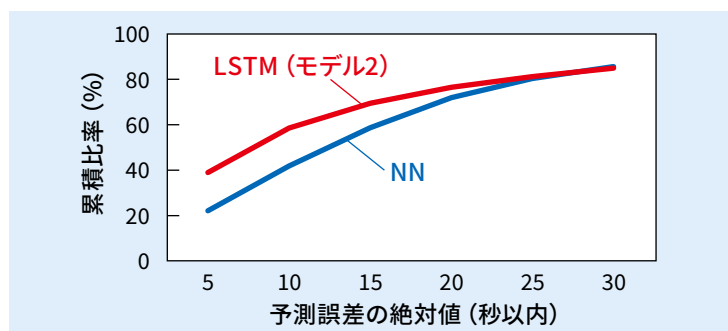


図6 NNとモデル2の予測精度比較

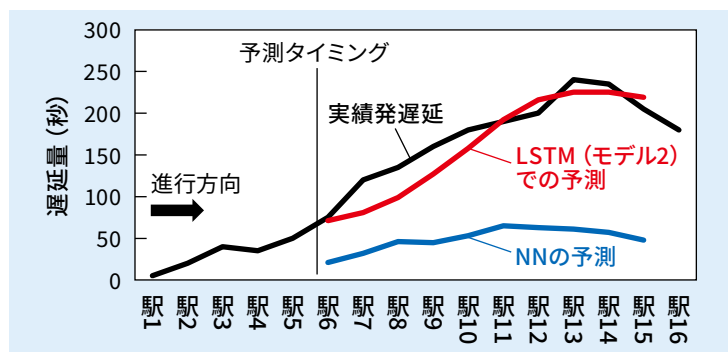


図7 LSTMの方が精度が高いケース

変化を確認して決定しました。

予測精度は、実際の発遅延と予測発遅延の差（以下、予測誤差）を基準に評価しました。予測誤差の絶対値が小さい時の累積比率が高いほど、予測精度が高いことを表します。

### 予測精度評価結果

LSTMを用いたモデルのうち、誤差10秒以内でみた時、もっとも予測精度が高かったのは、入出力を予測する列車の着遅延と発遅延とした場合のモ

デル2でした。

また、NNとモデル2の予測誤差の絶対値の累積比率の比較結果を図6に示します。NNとモデル2を比較した場合、予測誤差が25秒以内となる割合の観点では、モデル2のほうが予測精度が良好なことがわかりました。

LSTMの4つのモデルにおける予測精度比較、NNとの予測精度の比較結果から、今回構築したNNとLSTMのモデル4つのうち、予測誤差10秒以内となる件数を最大化したい場合は、

LSTM（モデル2）を用い、入出力を予測対象列車の着遅延・発遅延とするのがよいことがわかります。

LSTMがNNと比較して、精度よく予測できたケースを図7に示します。図7では、実績発遅延を黒線、NNを用いた予測発遅延を青線、LSTMを用いた予測発遅延を赤線で示しています。LSTMを用いた予測では、遅延が急増したという過去の傾向を反映した予測ができていくことがわかります。

### おわりに

ここでは、深層学習の一つのモデルであるLSTMを活用して、小規模な遅延が発生した時に数十分先の列車遅延を予測する手法を紹介しました。

構築した予測手法を大都市圏内の通勤路線を対象に適用し、予測精度を評価したところ、NNを用いた予測と比較して、LSTMを用いた予測手法の精度が高いことを確認しました。今後、さらに分析を進め、LSTMを用いた列車遅延予測手法の特徴を確認したいと考えています。具体的には、LSTMの方が予測の精度が高かった列車、駅の特徴を分析することを考えています。

また、別の大都市圏内の通勤路線において今回紹介した列車遅延予測手法を適用したうえで、手法の汎用性を評価したいと考えています。さらに、大規模遅延発生時において機械学習を用いた列車遅延の予測手法の適用性を評価したいと考えています。[RRR]

### 文献

- 1) 国土交通省鉄道局：東京圏の鉄道路線の遅延「見える化」（平成30年度）、<https://www.mlit.go.jp/report/press/content/001328948.pdf>（入手日：2021/05/19）
- 2) 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