

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

中挾 晃介^{1,a)} 辰井 大祐¹ 國松 武俊¹

受付日 2018年7月5日, 採録日 2019年1月15日

概要: 大都市圏の朝ラッシュ時における小規模な列車遅延発生時（小乱れ時）には、鉄道事業者は運行管理業務の一環として、前後の列車との間隔を調整する、列車の順序を変更する等のダイヤ変更を行い、旅客の利便性確保と、遅延の早期回復を図る。これら一連の変更業務を運転整理と呼ぶ。各列車の現在の遅延が、今後拡大するか、縮小するかを迅速かつ精度良く予測することは、運行管理を担う指令員が運転整理を適切に実施するために重要である。従来、短時間先の列車遅延の予測は、指令員の経験に依存することが多かったが、近年ではコンピュータによる支援も検討され、運行管理システムへの導入も始まっている。しかし、それらは現時点での遅延がそのまま続いていくという前提を置いていたり、過去の遅延や乗車率の傾向を考慮した予測手法とはなっていない等の課題がある。本研究では、将来的には大規模なダイヤ乱れへの展開を念頭に、まずは数分程度の小規模遅延の予測を目的として、時系列予測における非線形モデルの1つであるニューラルネットワークを用い、短時間先の列車遅延および乗車率を予測する手法を考案した。評価実験では、大都市圏における通勤路線の朝ラッシュ時間帯を対象として列車遅延と乗車率を予測した。小乱れ時においては、90%以上の予測対象データに対して遅延の予測誤差が25秒以内に収まることを確認した。

キーワード: 運行管理, 遅延予測, 乗車率予測, 機械学習, ニューラルネットワーク

Prediction Method for Train Delay and Congestion Rate Using a Neural Network

KOSUKE NAKABASAMI^{1,a)} DAISUKE TATSUI¹ TAKETOSHI KUNIMATSU¹

Received: July 5, 2018, Accepted: January 15, 2019

Abstract: For commuter lines in metropolitan areas, when a small disturbance occurs during peak hours, train dispatchers reschedule the train diagram by adjusting the interval of trains or changing the order of trains to keep the convenience of passengers and to recovery the diagram. To control train traffic and command operation arrangements properly, it is important to predict changes in train delay several tens of minutes later quickly and precisely. Train dispatchers predict the train delay by their experience, but nowadays, train delay prediction algorithm is installed in operation control systems. However, these prediction algorithms have some problems in terms of its simplicity and non-consideration of past delay and the congestion rate data. In this study, we developed a prediction method of train delay and the congestion rate at the time of a small disturbance using a neural network, which is one of the nonlinear models to be used for time series data prediction. We applied our method to an actual commuter line in the peak hour, and verified that the difference between the predicted delay and the actual delay is less than 25 seconds for 90% of the target predicted delay data.

Keywords: train traffic control, delay prediction, congestion rate prediction, machine learning, neural network

1. はじめに

鉄道路線において事故や車両故障等が発生すると、列車の正常な運行が妨げられ、ダイヤ乱れが発生する。ダイヤ

¹ 公益財団法人鉄道総合技術研究所
Railway Technical Research Institute, Kokubunji, Tokyo
185-8540, Japan

^{a)} nakabasami.kosuke.39@rtri.or.jp

乱れは、その原因によって遅れの規模や対処法が異なり、たとえば、大乱れ、中乱れ、小乱れのような形に分類できる [1]。大乱れは、人身事故、車両故障、設備故障等に起因するもので、おおむね 30 分程度以上の遅延をともなうダイヤ乱れをいう。中乱れは、朝ラッシュ時の遅延拡大、線路内人立ち入り等に起因するもので、おおむね 10 分～30 分程度の遅延のダイヤ乱れをいう。小乱れは、朝ラッシュ時の旅客混雑にともなう停車時間の拡大等に起因するもので、数分程度の遅延が発生している状況のことをいう。

列車の運行を管理する指令室では、指令員が列車運行状況を監視し、ダイヤ乱れが発生して列車に遅れが生じた際、ダイヤ変更等により旅客への影響を最小限に抑え、遅延を回復させるための手配を行う。この一連の手配は運転整理と呼ばれる。適切な運転整理の実施により、旅客の利便性を確保するほか、駅の混雑にともなう入場規制等のトラブルを防止する必要がある、社会的な責任も大きい業務である。

大乱れや中乱れ時には、ダイヤの変更に加え、車両や乗務員の運用計画の変更、駅や車両基地での構内作業計画の変更も必要となる等影響範囲が広いため、運転整理の計画、実施が難しく、鉄道事業者にとって大きな課題となっている。一方で、小乱れ時は線区の特徴をふまえた対処方法がある程度は確立されているものの、特に高密度運行を行うラッシュ時間帯においては、利用者集中にともなう小規模の遅延が慢性的に発生している。鉄道事業者においても朝ラッシュ時の遅延は、解決すべき重要課題の 1 つと位置付けられており、高頻度に発生する小乱れへの対策の改良も求められている。

小乱れ時に指令員が運転整理を適切に実施するためには、各列車の現在の遅延が、今後拡大するか、縮小するかを迅速かつ精度良く予測する必要がある。従来、短時間先の列車遅延の予測は、指令員の経験に依存することが多かったが、近年ではコンピュータによる支援も検討され、運行管理システムへの導入も始まっている。しかし、それらは予測の精度や運用面で課題がある。

本研究では、将来的には大乱れ時への展開を念頭に、まずは数分程度の遅延時である小乱れ時の予測を目的として、ニューラルネットワークを用いた短時間先の列車遅延および乗車率を予測する手法を考案した。評価実験では、大都市圏における通勤路線の朝ラッシュ時を対象として列車遅延と乗車率を予測し、90%以上の予測対象データに対し、誤差が 25 秒以内となることを確認した。

以降、2 章では、大都市圏の通勤路線における慢性的な遅延の現状と、それに対する指令員の運転整理業務およびその課題について述べるとともに、列車遅延および乗車率の予測に関する関連研究を紹介する。さらに、それらをふまえ、本研究の目的を示す。3 章では、ニューラルネットワークについて説明する。4 章では、ニューラルネット

ワークを用いて列車の遅延と乗車率を予測するための予備実験を示す。5 章では、4 章での予備実験を受けた結果をふまえて構築した、ニューラルネットワークを用いた列車の遅延と乗車率の予測手法について説明する。6 章では、提案手法を実際の路線に適用した際に要する時間や予測精度について評価する。最後に 7 章において、本論文のまとめと今後の課題を示す。

2. 小乱れ時の列車遅延の予測と本研究の目的

2.1 通勤路線における遅延発生と運行管理

朝ラッシュ時間帯における大都市圏の通勤路線では、混雑にともなって旅客の乗降に要する時間が拡大し、駅の停車時間が延びるというメカニズムで、列車遅延が頻繁に発生する。この遅延により、先行列車との間隔が開いた結果、次駅以降での乗車旅客数が増加し、停車時間が延び、さらに遅延が拡大する。また、その後続の列車に対しても、駅間での減速もしくは停車を引き起こし、連鎖的に他列車にも遅延を伝搬させる。これらの遅延の拡大、伝搬が、日々の慢性的な遅延の原因となっている [1]。指令員は、発生した遅延のさらなる拡大、伝搬を防止するため、列車の間隔調整や、列車の順序変更といった運転整理を行う。

2.2 小乱れ時の運転整理業務の課題

遅延発生時に列車の間隔調整、順序変更等を的確に実施するためには、その時点の各列車の遅延状況や、各駅における混雑状況を正確に把握したうえで、それをもとに、短時間先までの各列車の遅延、混雑の推移を正確に予測することが望まれる。しかし、大乱れ時はもちろん、遅延時間が数分程度の小乱れ時においても、利用者の乗降に要する時間の増加や混雑の影響による遅延時間の増減の予測は難しいことが多い。たとえば、ある列車に 3 分の遅延がある場合、それが 5 分に拡大するか、あるいは 1 分程度まで収束するかは状況により異なる。遅延が拡大するか、縮小するかにより、適切な運転整理は異なってくるが、遅延の拡大・縮小は、主に指令員が経験を頼りに予測することが多い。そのため、運行状況の変化を見誤ると、実施した運転整理について期待した効果が得られず、遅延のさらなる拡大や伝搬を招き、旅客の利便性がさらに低下する恐れがある。

また、遅延時における旅客への案内に関しては、鉄道事業者では現状でも、列車の遅延、混雑状況を一定の精度で案内するように努めている。しかしそれは、多くの場合、対象列車の現時点での遅延や混雑状況である。これを案内することも、もちろん重要であるが、対象列車がその後、当駅に到着するまでの間に、遅延や混雑状況が変化する可能性があることを考えると、対象列車が当駅に到着し、旅客が乗車する時点での遅延や混雑状況をなるべく正確に予測し、それを適切に案内することができれば、よりいっそ

う望ましいといえる。

さらに、遅延の予測に関して、必要な精度を検討すると、現状の指令室での運行管理は、各列車の遅延をおおむね分単位で把握し、遅延が拡大した場合には、運転整理の手配を行う。また、旅客案内に関しても、個別の列車の時刻や遅延状況は、現状、分単位で案内されている。したがって、分単位での遅延に基づき、運行管理、旅客案内が行われている現状を念頭に置けば、列車遅延は、30 秒程度以内の誤差で予測できるのが望ましい。

以上をふまえ、短時間先の列車遅延、混雑の高精度な予測により、指令員や駅係員による、適切な運転整理、旅客案内を実現できるものと考えられる。

2.3 関連研究

列車運行予測に関しては、安部、荒屋らにより、プロジェクトマネジメント手法の 1 つである PERT を用いた手法 [2] が提案されている。また、ダイヤデータと自動改札機データを用いる手法として、國松らによる列車運行・旅客行動シミュレータによる乗車率、遅延予測手法 [3] や、辰井らによる対話型ダイヤ作成システムによる乗車率予測手法 [4] が提案されている。しかしこれらは、遅延の発生、伝搬や乗車率を、その基本的なメカニズムに沿って順次計算し予測したもので、過去の日々の遅延、乗車率データを直接反映してはいない。つまり、たとえば特定の駅（乗換駅等）での利用者集中による遅延の頻発等、個別の事情を有する様々な路線、駅に対し、精度良く予測できるとはいえない。また、岩倉らは、列車の遅延時間を、マルチエージェントシミュレーションを用いて再現し、遅延の連鎖を予測する手法を提案している [5], [6]。この手法は、列車の挙動をルールによってモデル化し、遅延をシミュレーションするものであるため、過去の日々の遅延や乗車率のデータを直接反映していないという点で、上記と同じ課題がある。岩本らは、短時間先までの遅延を予測しダイヤ図を描画する機能を開発し、一部路線の運行管理システムで実用化している [7]。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設定する必要があり、その適切な設定方法に課題がある。さらに、高垣らは、類似度計算による乗車率予測手法 [8] を提案している。この手法は、過去の実績データを直接利用するものであるが、遅延の予測は行っていない。

2.4 ニューラルネットワークによる予測技術

近年、計算機の性能向上にともなう大規模なデータの処理技術や、人工知能技術の発展により、深層学習 (Deep Learning) に代表される機械学習 (Machine Learning) による高精度な予測技術が提案されてきている。深層学習の基礎となる技術に、ニューラルネットワーク [9] と呼ばれる認識・予測技術が存在する。ニューラルネットワークの

利点としては、①過去のデータの傾向に基づき予測可能、②非線形なモデルにより、より複雑な状況を予測可能、③少数のパラメータの設定により予測可能、といったことがあげられる。都市鉄道では、旅客混雑や設備条件等、様々な要因により列車遅延が増大する等、遅延の傾向は必ずしも線形になるとは限らず、予測が難しい。そこで、本研究では特に、ニューラルネットワークの非線形性に着目し、線形な手法よりも精度良く予測できることを期待し、予測手法として用いることとした。

ニューラルネットワークに基づく予測手法として、Xavier は、ニューラルネットワークによる各駅の到着時刻の予測手法 [10] を提案している。しかし、旅客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の変化を表現できない。また、Yaghini らはイラン鉄道における列車遅延の概算値を予測する手法 [11] を開発している。しかし、分単位の遅延の推定であり、秒単位の運行管理が求められる日本の大都市圏通勤線区には、そのまま適用できない。以上のように、いくつかのニューラルネットワークを用いた列車遅延の予測の検討がなされているものの、著者らが知る限り、大都市圏の列車遅延および乗車率の予測へ適用できる手法は存在しない。

2.5 本研究の目的

本研究では、日々の運行実績データと乗車率データを使用し、ニューラルネットワークによって列車遅延、乗車率を予測する手法を提案する。将来的には大乱れ時の予測手法への展開を念頭に、まずは、大都市圏の通勤路線のラッシュ時間帯において、日々発生する数分程度までの小乱れ時の遅延を、30 秒程度以内の誤差で予測することを目標とする。これにより、現在時刻から 30 分程度先までの遅延、乗車率を予測可能とし、適切な運転整理、旅客案内に活用することを目的とする。

3. ニューラルネットワーク

ニューラルネットワーク (Neural Network, NN) は、脳の中にあるニューロン (神経細胞) をパーセプトロンと呼ばれる数学モデルで表現し、ニューロン間における信号の受け渡しを、パーセプトロンを複数結合させたネットワークとして計算機上で表現したものである。ニューラルネットワークの最も単純な構造としてフィードフォワード型ニューラルネットワークがある。これはそのネットワーク内にループを持たず、複数のパーセプトロンが層を成し、入力層、隠れ層、出力層という 3 層で構成されている単一方向のグラフ構造である (図 1 参照)。入力層から順に、入力値に各パーセプトロン間のエッジの重みをかけた値の和を次の層のパーセプトロンの活性化関数に入力し、各パーセプトロンの値を逐次計算することで、出力層における値を計算する。




図 1 パーセプトロンとニューラルネットワークの構造

Fig. 1 The architecture of perceptron and neural network.

ニューラルネットワークにおける代表的な学習アルゴリズムとして誤差逆伝播法がある。これは、ある入力データに対してニューラルネットワークが出力層から出した結果と正解のデータの二乗誤差を計算し、この誤差の値が小さくなるように、パラメータに応じて重みの値を少しずつ調整していく学習法である。これを、大量の教師データに対して行い、出力結果と正解データの誤差が閾値よりも小さくなったところ、もしくは想定する回数の学習が終わった時点で重みの更新を完了し、学習を終了する。

この学習が完了したニューラルネットワークに対して、予測対象となるテストデータを入力し、予測結果を得る。

なお、各層におけるパーセプトロン数、入出力や重みの値設定、出力関数等は、学習に要する時間や予測精度に大きな影響を及ぼすため、問題に応じた詳細なチューニングを必要とする。

4. ニューラルネットワークによる列車遅延・乗車率予測のための予備実験

列車遅延、乗車率をニューラルネットワークで精度良く予測するために必要なデータの事前処理方法、入力すべきデータを明らかにするため、予備実験を実施した。

4.1 仮想データを用いた予備実験

運行実績データに記録されている列車遅延には、急病人対応等、当日限りの突発的なトラブル発生に起因し、多数のデータの傾向とは異なる外れ値が含まれる。本研究の目的は、このような突発的なトラブルの発生自体を予測するものではなく、仮にトラブルなしで標準的な運行をした場合、現在の遅延がどのように推移するかを予測するものである。そこで本節では、ニューラルネットワークによる予測手法の入力データとして、そのような外れ値を事前に除去する必要があるか、あるいはそのような前処理は不要か、予備実験により確認する。

この確認のために、全線で 30 駅存在する仮想の路線における、ある列車の 105 日分の各駅における遅延を模擬する仮想のデータセットを用いる。表 1 に、仮想のデータセ

表 1 予備実験に用いた仮想のデータセット

Table 1 The synthetic dataset using the preliminary experiment.

データセット番号	1 個目	2 個目	...	25 個 目	26 個 目	...	30 個 目
No. 1	0.20	0.20	...	0.00	0.10	...	0.15
No. 2	0.20	0.15	...	0.20	0.10	...	0.10
...	...	...	...	...	...	...	...
No. 100	0.10	0.20	...	0.00	0.10	...	0.00
No. 101	0.00	0.10	...	0.10	1.00	...	0.80
...	...	...	...	...	...	...	...
No. 105	0.10	0.10	...	0.10	0.90	...	1.00

トを示す。データセットは 105 件あり、1 つのデータセットの中には 30 個の要素のデータが含まれ、原則として 0, 0.05, 0.1, 0.15, 0.2 のいずれかの値をランダムに設定する。データセット番号は各日を、1 つ 1 つの要素はその列車の各駅における遅延を [0, 1] の範囲で正規化した値を模擬している。ここでは、このデータセット中の 5 件 (No.101～105) の 26～30 番目の要素のデータ (表 1 における網掛け部分) に限り、0.8, 0.85, 0.9, 0.95, 1.0 のいずれかの値を設定する。これにより、5 日分だけ大規模な遅延が発生した日のデータを含んでいることを模擬している。

ニューラルネットワークの学習では、105 件のデータセットのうちの 1 件分を予測対象とするテストデータとし、残りの 104 件は教師データとして、ニューラルネットワークの学習に用いる。各データセットについて 1～20 番目の要素 (つまり、1 駅目から 20 駅目) を入力データとし、21～30 番目の要素 (つまり、21 駅目から 30 駅目) を予測対象とする。No.101～105 の 5 件のデータセット (大規模な遅延が発生したことを模擬するデータセット) が入力データに含まれることにより、これらが予測にどのような影響を与えているかを検証する。

なお、ニューラルネットワークの構造としては、3 層構造のフィードフォワード型ニューラルネットワークを用いる。活性化関数としてはシグモイド関数を用いる。学習法には誤差逆伝播法を用いる。ニューラルネットワークのパラメータとしては、別途実施した事前検証の結果をふまえ、隠れ層のユニット数を 30 個、学習終了条件となるニューラルネットワークの出力結果と正解データの値の誤差の閾値 (以降では誤差閾値という) を 0.0001、学習の最大繰返し数を 10,000 回、学習率を 0.2 とする。

結果は、予測対象を 1～100 件目のデータセットのいずれか 1 件、他を教師データとした場合において、21～30 番目の要素の予測値は、[0, 0.2] の範囲となるケースがほとんどであった。しかし一方で、少数ではあるが、予測値が [0, 0.2] の範囲から大きく外れたケースが存在した。これを図 2 に示す。たとえば、No.20 を予測対象のデータセット




図 2 ある 2 つの入力データセットにおける出力結果
Fig. 2 The result of outputs for two input datasets.

とした場合、実線で示される 21～30 番目の要素の値（正解値）と、点線で示されるニューラルネットワークによる各要素の予測値は、21～25 番目の要素ではおおむね一致するものの、26～30 番目の要素では、おおむね 0.2 程度以上の誤差が生じている。このことから、ニューラルネットワークでは、学習データに外れ値を含むデータが存在すると、予測の精度が極端に悪化する場合があることが分かる。

したがって、外れ値を含むデータを使用する場合は、ニューラルネットワークによる予測を行う前に、前処理として、学習データとするデータの値に閾値を設け、この閾値を超えるデータは学習データから除外するのが望ましいといえる。これをふまえ、今後実際の遅延データを使用する際には、設定した閾値以上の遅延データは、本研究では突発的なトラブル発生時のものと解釈して除外する。

4.2 実際の運行実績データを用いた予備実験

短時間先の遅延と乗車率を精度良く予測するために、ニューラルネットワークの入力として、現在時刻までの遅延、乗車率データのうち、どの範囲（列車、駅）の、どのような種類のデータを用いればよいか検討する。単純には、予測対象の列車が、始発駅から今まで通ってきた駅の遅延と乗車率を入力とすることが考えられるが、前後列車の遅延等、予測対象列車の遅延と相関があると考えられるデータも用いることで、予測精度が向上する可能性がある。そこで、入力データの取り方の組合せとして 6 つのケースを検討し、どのケースが適切か検証した。

(1) 検証に用いる対象路線

全 24 駅（駅 A～駅 X）、終日の列車本数が 413 本（平日）の通勤路線である。列車種別は快速、区間快速、各駅停車（各停）の 3 種類で、都心側から 5 つ目の駅（駅 S）で、各停が快速、区間快速を待避する。この路線の 7:00～9:00 の間に、最も都心側の駅（駅 X）に到着する列車 32 本を、検証における予測対象列車とし、都心側の駅から 8 駅（駅 Q～駅 X）を、予測対象駅（区間）とする。対象路線の概要を図 3 に示す。




図 3 対象路線の概要

Fig. 3 The image of the target line.

(2) 使用するデータ

平日 79 日分の運行実績、乗車率データを使用する。運行実績データには、指令室の運行管理システムに記録される、線路上の軌道回路の落下上時刻を補正したデータを使用する。このデータには、各列車、各駅における到着時、発車時の遅延（以下、着遅延または発遅延という）の情報が含まれる。79 日分の中には、運行上のトラブル等がなく遅延が小さい日のほかに、列車運行にトラブルが発生し、大幅に遅れた日のデータが混在する。本研究では、日々慢性的に発生する小規模な遅延の予測を目的としており、また、4.1 節における予備実験から、学習データに外れ値が含まれると精度が悪化することを確認しているため、前処理として、閾値以上の遅延となるデータは除外する。この閾値の具体的な値の決め方については、4.2 節 (3) において示す。

一方、乗車率データには、各列車、各駅間における乗車率の情報が含まれる。このデータには、車両に搭載された応荷重装置による乗車人数データ等の使用を想定している。しかし今回、対象路線の車両から応荷重装置のデータは取得不可能であったため、各駅の自動改札機から取得できる、ある 2 駅間の時間帯ごとの移動人数データ（自動改札機 OD データと呼ぶ）と運行実績データを使用し、文献 [4] の対話型乗車率推定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こととした。

なお、ニューラルネットワークの活性化関数として用いているシグモイド関数は値域が $(0, 1)$ である一方で、予測対象とする列車遅延や乗車率は、 $[0, \infty)$ の値をとる。そこで以降では、ニューラルネットワークに入力する値を、前述の前処理の閾値と同じ値により正規化し、 $[0, 1]$ の範囲を取るようにする。また、出力から予測値を求める際には、出力された $(0, 1)$ の範囲のデータを、この閾値で正規化の逆を行うこととする。

(3) 予測精度の検証方法

79 日分のデータのうちの 1 日分を予測精度検証のためのテストデータとし、残りの 78 日分は教師データとしてニューラルネットワークの学習に用いる。各予測対象列車、各予測対象駅の着事象に対してニューラルネットワークを 1 つ用意し、駅到着時点でその駅以降の各駅の発遅延および各駅間の乗車率を予測する。例として、駅 Q 到着時




図 4 予測対象となる発遅延と乗車率
Fig. 4 The point of output data.

点において予測対象となる発遅延と乗車率を図 4 に示す。

ここで、図 4 は列車運行を示すダイヤ図を簡単に示したものであり、横軸は時刻、縦軸は駅の位置を示す。列車運行は斜めの線で表現されている。以降、図 5、図 7、図 8 についても同様の見方である。

予測対象列車が駅 Q に到着した時点（図 4 の★）を現在時刻とすると、駅 Q から駅 W までの各駅の発遅延と、駅 Q から駅 R 間の乗車率、駅 R から駅 S 間の乗車率、…、駅 W から駅 X の乗車率が予測対象となる。この予測した発遅延および乗車率と、実績値（正解データ）との誤差の絶対値をとることで、精度を検証する。

ニューラルネットワークの構造、学習法、活性化関数、およびパラメータ設定は 4.1 節と同じである。入力データに対する前処理の閾値、および入力データを $[0, 1]$ の範囲に正規化するための除算値については、79 日間の遅延、乗車率データを分析した結果をふまえて設定した。具体的には、トラブルが発生していない日の各列車の遅延、乗車率の値が、列車遅延は 150 秒以内、乗車率は 200% 以内におおむね収まっていたため、閾値となる列車の発遅延は 150 秒、正規化の除算値については、列車遅延は 150 秒、乗車率は 200% とした。つまり、学習対象日のデータにおいて、ある列車（1M とする）の 1 つ以上の駅の発遅延が 150 秒以上の場合、1M の各駅に対応するニューラルネットワークの学習に、その日のデータは用いない。また、予測対象日のデータにおいて、1M の 1 つ以上の駅の発遅延が 150 秒以上の場合、1M の各駅に対応する予測は行わない。

(4) 入力データの違いによる予測精度の比較

ニューラルネットワークの入力データとして、現在時刻までにおける、予測対象列車の発遅延（図 5 の○、(a)）、




図 5 入力データとする発遅延と乗車率
Fig. 5 The point of input data.

表 2 入力データの 6 種類の組合せ
Table 2 Six cases of input data.

ケース	予測対象列車 車の発遅延 (a)	予測対象列車 車の着遅延 (b)	予測対象列車 車の乗車率 (c)	前後列車の 発遅延 (d)
(i)	○	×	○	×
(ii)	○	○	○	×
(iii)	○	×	○	○
(iv)	5 駅分	×	5 駅分	×
(v)	5 駅分	5 駅分	5 駅分	×
(vi)	5 駅分	×	5 駅分	5 駅分

予測対象列車の着遅延（図 5 の△、(b)）、予測対象列車の乗車率（図 5 の○から△までの間、(c)）、前後列車の発遅延（図 5 の◇、(d)）の 4 種類を想定する。なお、図 5 は予測対象列車が駅 Q に到着した時点（★で示した部分）を現在時刻とした図である。これらの中から、入力データの取り方として表 2 の 6 つの組合せを検討した。

ケース (i) は、予測対象列車の始発駅から現在時刻の駅までの発遅延と駅間の乗車率を入力データとする。ケース (ii) は、ケース (i) に予測対象列車の着遅延も含めるケースである。ケース (iii) は、ケース (i) に予測対象列車の前後列車の発遅延も入力データに含めるケースである。2.1 節で述べたように、ある列車の遅延が後続の列車の減速もしくは駅間での停車を引き起こし、連鎖的に他列車の運行に影響を及ぼすことが頻繁に発生する。そこで、予測対象列車の前列車の発遅延も入力データに含める。また、ある駅において列車が後続の列車を待避して先に通す場合、後続列車に遅延があると、自列車にも遅延が発生する。そのため、待避がある場合は、後続列車の発遅延も入力データに含める。

表 3 発遅延の予測誤差の累積比率

Table 3 The cumulative ratio of delay prediction error between six cases.

ケース	発遅延における予測誤差			
	5 秒以下	10 秒以下	15 秒以下	20 秒以下
(i)	60.51%	81.20%	88.79%	92.59%
(ii)	62.76%	82.50%	89.47%	93.03%
(iii)	60.95%	80.41%	87.66%	91.54%
(iv)	60.46%	82.13%	89.76%	93.43%
(v)	63.01%	83.43%	90.50%	93.89%
(vi)	62.06%	81.82%	88.85%	92.53%

表 4 乗車率の予測誤差の累積比率

Table 4 The cumulative ratio of the congestion rate prediction error between six cases.

ケース	乗車率における予測誤差			
	2%以下	4%以下	6%以下	8%以下
(i)	63.05%	85.17%	92.97%	96.25%
(ii)	61.49%	84.07%	92.14%	95.74%
(iii)	59.43%	82.10%	90.88%	95.03%
(iv)	65.28%	86.59%	93.93%	96.83%
(v)	63.88%	85.75%	93.33%	96.48%
(vi)	62.56%	84.12%	92.09%	95.76%

ケース (iv), (v), (vi) は、入力データの範囲を絞ったケースである。ケース (i) から (iii) では、現在時刻から遡って始発駅までの全駅の遅延、および全駅間の乗車率を含んでいた。しかし、ある列車のある駅における発遅延や乗車率は、直近の駅における発遅延や乗車率ほど影響が大きいと考えられる。また、ニューラルネットワークでは、入力データが多いほど入力層のノード数が多くなり、学習すべき重みの数が多くなり計算時間が増えてしまう。そこで、入力データとする駅の発遅延、および駅間の乗車率を、予測対象列車が現在時刻にいる駅(図 5 の★)から手前数駅のみに絞ることを検討する。ケース (i) に対応し、発遅延、乗車率を手前 5 駅分に限定したものをケース (iv)、ケース (ii) に対応し、同じく手前 5 駅分に限定したものをケース (v)、ケース (iii) に対応し、同じく手前 5 駅分に限定したものをケース (vi) とする。

予備実験の結果を表 3 および表 4 に示す。表 3 は、予測対象列車の駅 Q~X の各駅着時点における、その駅以降の各駅の発遅延の予測値と実績値との誤差が、5 秒以下となった件数、10 秒以下となった件数というように 5 秒間隔ごとに算出した累積値の、全予測件数に対する割合(以下、誤差の累積比率という)を示す。ケース (v) が最も良い結果となったが、各ケース間での割合の差はわずかであり、大きな精度の差がないことが確認された。一方、必要な入力データの範囲、種類が少なく済むという観点からは、




図 6 2 ケース間の発遅延予測結果

Fig. 6 The result of delay prediction between two cases.

ケース (iv) が望ましい。しかし、各ケースにおける予測結果の詳細を分析したところ、少数ではあるものの、前後列車の発遅延を入力データとして入れることで、予測の精度が大きく改善する例も確認された。図 6 にその例を示す。図 6 は、ある日のある列車の駅 Q 着時点における、駅 Q~駅 X までの発遅延の予測結果を、ケース (iv), (v), (vi) で比較したものである。この列車は駅 S で快速列車を待避する普通列車であり、この日は待避する快速列車が遅れていたため、駅 S で発遅延が大きくなった。前後列車を入力データに含めないケース (iv), (v) の予測では、この遅延を予測できていないが、前後列車を入力データに含めるケース (vi) の予測では、この遅延を予測できている。このことから、全体の精度に関する統計値ではケース (v) が良いものの、ケース (vi) との差はわずかであり、一方で、前後列車を入力データに含めることで、図 6 のように、大幅な精度向上が可能なケースがあるといえる。また今後、本手法を列車密度や乗車率がより高く、待避の多い他路線へ展開することを考えた際、前後列車を考慮した予測手法とする方が、汎用性が高いと考えられる。

表 4 は、乗車率における 2% 間隔の誤差の累積比率である。こちらは、ケース (iv) が最も良い結果となったが、乗車率の 2% は実際の人数では約 3 人であり、各ケース間での割合の差はわずかであるため、大きな精度差がないことが確認された。そのため、上述したように、遅延の予測においては前後列車を考慮した予測手法とする方が良いことをふまえ、入力データの与え方としてはケース (vi) の、「予測対象列車およびその前後列車の 5 駅手前までの発遅延、および予測対象列車の 5 駅手前までの乗車率」を採用する。

なお、本研究では、列車別駅別にニューラルネットワークを構築しているが、同じ列車種別の列車について共通のニューラルネットワークを構築し、学習および予測を行うモデルも考えられる。このような列車種別別駅別のモデルにすることにより、構築するニューラルネットワークの数が削減され、入力とするデータのサンプル数を増やすことができる。また、ダイヤ改正によりダイヤが変更されて

も、停車駅の変更等の大幅な変更でなければ、改正前と同じニューラルネットワークを使用できるというメリットがある。一方で、同じ列車種別であっても、特定の駅を出発、到着する時刻や、途中駅での他列車、他路線、他交通モードとの接続のタイミング等により、遅延が大きくなりやすい駅や混雑が大きくなりやすい駅間は列車によって異なり、それぞれの列車が個別の性質を持っていると考えられる。さらに、誌面の都合上省略するが、列車別駅別のモデルと、列車種別別駅別のモデルについて、予測精度を比較する予備実験を行ったところ、列車別駅別のモデルの方が、列車種別別駅別のモデルよりも精度が良いという結果が得られた。そのため本研究では、列車別駅別にニューラルネットワークを構築するモデルを採用する。

また、列車の遅延や乗車率には、曜日や天候の影響も考えられ、それらを考慮したモデルの構築も考えられる。しかし、たとえば曜日ごとにモデルを構築すると、月～金曜日の平日の場合、単純には、学習に用いるデータの日数が1/5になる。今回の場合、15日分程度でモデルを構築することになり、精度の面で課題がある。また、天候についても、79日間で、降水が観測された日は数日しかなかったため、降水量のような変数を入力とする構造とすると、同様に精度面の課題が懸念される。以上をふまえ、本研究では、曜日や天候による影響を陽に反映したモデルは採用しない。一方で、本研究の結果をふまえ、今後、十分な日数のデータが取得された段階で、曜日や天候を考慮したモデルを検討することにしたい。

4.3 重回帰分析による予測との精度比較

本研究において、非線形モデルのニューラルネットワークを採用したことによる効果を検証するため、線形なモデルの1つである重回帰分析による予測を実施し、その精度を比較した。

検証に用いる対象路線、使用するデータについては、4.2節と同様とする。予測精度の検証方法は、対象区間内の主要な3駅（駅Q、駅S、駅X）到着時点で、その駅以降の各駅の発遅延および各駅間の乗車率を予測し、精度を比較する。

重回帰分析による予測手法では、回帰式の目的変数を、予測対象となる発遅延または乗車率とする。説明変数は、前節のケース(vi)に対応する入力データとする。図7に、予測対象列車が駅Qに到着した時点(★で示した部分)を現在時刻としたときの、目的変数、説明変数となるデータを示す。説明変数は、図7の○と◇、(a)、(b)、(c)で示される発遅延および乗車率である。一方、目的変数は、図7の□、(d)で示される発遅延、および□と□の間、(e)で示される乗車率である。つまり、図7では、駅Qから駅Tまでの間に各駅の発遅延を求める回帰式が4つ、乗車率を求める回帰式が4つ存在する。また、79日分のデータのう




図 7 重回帰分析における説明変数、目的変数となる点
Fig. 7 The point of explanatory and objective variable of multiple regression analysis.

表 5 2 手法間の遅延予測誤差の累積比率
Table 5 The cumulative ration of delay prediction errors between two prediction methods.

予測手法	発遅延の予測誤差			
	5 秒以下	10 秒以下	15 秒以下	20 秒以下
ニューラルネットワーク	59.03%	80.65%	88.15%	92.13%
重回帰分析	50.94%	75.44%	86.20%	91.65%

ちの 78 日分を用いて、各説明変数の係数（偏回帰係数）を決定し、回帰式を求める。残りの 1 日分を予測精度検証のためのテストデータとする。

重回帰分析による予測と、ニューラルネットワークによる予測の誤差の累積比率を表 5 に示す。たとえば、予測の誤差が 10 秒以内に収まったものの割合は、ニューラルネットワークが約 81%、重回帰分析が約 75%と、ニューラルネットワークの方が予測の精度が良いという結果になった。この傾向は、予測誤差を 5 秒以内、15 秒以内、20 秒以内としても同様であった。

5. ニューラルネットワークによる列車遅延および乗車率予測手法

本章では、前章における予備実験によって得られた結果をふまえた列車遅延と乗車率の予測手法を述べる。具体的には、ある路線の各列車に対して発遅延、乗車率を予測するための、ニューラルネットワークの学習・予測手法、入力データ決定手法、および出力データについて整理する。




図 8 入出力データとなる発遅延と乗車率

Fig. 8 Delay and congestion rate data for input and output.

5.1 ニューラルネットワークの学習・予測

予測を行う日の前日までのデータを用いて、各列車、各駅の着発事象それぞれのニューラルネットワークについて学習を行い、パーセプトロン間のエッジの重みを決定する。

予測対象日において、各列車が各駅に到着、発車した時点現在時刻とし、それに対応する学習済みのニューラルネットワークを用いて予測する。その日の現在時刻までの発遅延と乗車率を入力し、現在時刻以降、一定時間幅における列車の発遅延、乗車率の予測値を出力する。

5.2 ニューラルネットワークの入出力データ

入力データを「予測対象列車およびその前後列車の5駅手前までの発遅延、および予測対象列車の5駅手前までの乗車率」とする。具体的には、図8に示すとおり、予測対象列車の列車3が駅Sに到着したタイミングを現在時刻 t とし、そこから予測時間幅 T_w について、列車3の発遅延、乗車率を予測する。この場合に入力となる発遅延または乗車率を●印で、出力となる予測対象の発遅延、乗車率を○印で示す。入力データは、以下の3種類に大別される。

(1) 予測対象列車のデータ

予測対象列車の現在停車中の駅（以下、当該列車、当該駅という）から遡って5駅分の発遅延、乗車率を入力とする。ただし、当該列車の始発駅から当該駅まで5駅未満の場合、始発駅から当該駅までのすべての駅を入力とする。図8において、●印で示した列車3の駅N~Rの発遅延、発時乗車率が入力となる。

(2) 予測対象列車の前列車のデータ

当該駅において、計画ダイヤ上、当該列車の直近に発車した列車の発遅延、および当該列車の直近に到着した列車

の、当該駅を除いて4駅分遡った各駅の発遅延を入力データとする。図8では、列車3の直近に発車した列車は列車1のため、列車1の駅Sの発遅延が入力データとなる。また、列車3の直近に到着した列車は列車2のため、列車2の駅Sを除いて4駅分遡った駅である駅O~Rの発遅延が入力データとなる。

(3) 予測対象列車の後列車のデータ

もし現在時刻から時間 T_w までの間に、当該列車が他の列車を待避する駅がある場合、その各待避駅で最後に待避した列車（以下、後列車という）について、現在時刻 t の時点で走行/停車中の駅から遡って5駅分の発遅延を入力データとする。待避駅が複数ある場合は、それらの待避駅それぞれについて、最後に待避した列車各1本ずつについて、上記入力データを設定する。待避がない場合は後列車のデータは入力としない。図8において、列車3は時間 T_w の間に駅Sで列車4を待避する。列車4は計画ダイヤ上、現在時刻 t では、駅Q~R間を走行中である。したがって、列車4の駅Q~R間から遡って5駅分の、駅M~Qの発遅延が入力データとなる。

一方で出力は、現在時刻 t から時間 T_w までの間に当該列車が発車する駅の発遅延、乗車率とする。図8では、列車3が時間 T_w の間に発車する駅S~Vの発遅延、発時乗車率が出力となる。

6. 評価実験

提案手法を実装したプログラムを作成し、ニューラルネットワークのパラメータを変更しながら、学習時間と予測精度を比較、検証した。

6.1 実験概要

対象路線は、4.2節で説明した路線に加え、この路線が直通する路線も加えた全32駅、終日の列車本数413本を対象とする。この路線の終日の上下線全列車、全区間に対して学習、予測を行う。使用データは、平日79日分の発遅延、乗車率データとする。

検証方法は、79日分のデータのうちの70日分を教師データとしてニューラルネットワークの学習に用い、残りの9日分を予測対象とするテストデータとし、精度の検証に用いる。予測時間幅 T_w は30分と設定する。予測精度の比較対象については、小乱れが発生しやすい朝ラッシュ時間帯の7:00~9:00の間に、最も都心側の駅に到着する列車32本とする。

隠れ層のユニット数を30個で固定し、入力データの前処理の閾値となる列車遅延については150秒、入力データを $[0, 1]$ の範囲に正規化するための除算値については、4.2節と同様、列車遅延は150秒、乗車率は200%とする。なお、本章の評価実験では、閾値の適用条件を整理し、ある列車、駅に対応するニューラルネットワークの学習時に、

表 6 発遅延，乗車率予測結果の精度および学習時間

Table 6 The result of delay and the congestion rate prediction accuracy and learning time.

	パラメータ			実験結果				
	誤差閾値	最大学習回数	学習率	学習時間 (時)	精度 (1) : 全列車		精度 (2) : 30 秒以上の 遅延があった列車	
					遅延 (%)	乗車率 (%)	遅延 (%)	乗車率 (%)
Case 1	0.01	100	0.01	0.23	29.04	67.25	37.67	76.33
Case 2	0.01	1,000	0.01	0.52	29.51	67.59	39.06	73.91
Case 3	0.001	100	0.01	0.92	72.10	90.50	58.23	92.72
Case 4	0.001	1,000	0.01	8.67	75.47	95.17	61.38	96.46
Case 5	0.01	100	0.001	1.00	15.45	47.73	29.32	51.23
Case 6	0.0001	1,000	0.01	9.28	75.50	95.20	61.38	96.46
Case 7	0.0001	10,000	0.01	88.80	82.29	97.76	68.74	97.89

入力データの中に（前後列車も含めて）150 秒以上の発遅延が 1 つでもある場合には，その日のデータは学習に用いないこととした．また，予測時においても，入力データの中に（前後列車も含めて）150 秒以上の発遅延が 1 つでもある場合には，そのニューラルネットワークを使用した予測は行わない．

さらに，ニューラルネットワークのパラメータである，誤差閾値，学習の最大繰返し数，および学習率の組合せを変更した計 7 ケースを用意し，それぞれの条件で実験を行った．使用した計算機の環境は，CPU が Intel® Core™ i7-4790，クロック数が 3.60 GHz，メモリが 4.00 GB，OS が Windows7 Professional (32 bit) である．

6.2 結果の概要

試行したパラメータの組合せと結果を表 6 に示す．表 6 の学習時間は，全ニューラルネットワークの学習にかかる時間であり，単位は hour である．一方，全ニューラルネットワークによる予測にかかる時間は，いずれのケースにおいても約 3 分であった．

予測精度を議論するにあたり，「精度 (1)」を，9 日分の 32 列車を対象として，発遅延予測値と実績値との誤差の累積比率をとった際に，誤差が 10 秒以内に収まる割合として定義する．乗車率についても同様に，精度 (1) は乗車率予測値と実績値との誤差の累積比率をとった際に，誤差が 10% 以内に収まる割合とする．一方で，精度 (1) で対象とする列車の中には，予測すべき発遅延の実績値が 0 秒に近い列車の予測結果も含まれている．これを除外するために，30 秒以上の遅延があった列車のみを対象とした累積比率についても計算し，精度 (1) と同様の割合を算出している．これを精度 (2) とする．

実験の結果，Case 7 が最も精度が良く，Case 4 や Case 6 がそれに次ぐ形となった．学習時間は逆に，Case 7 が最も時間を要し，Case 4 や Case 6 がそれに次いでいる．誤差閾値と最大学習回数の関係を見ると，誤差閾値は同じ値と

し，最大学習回数を 10 倍とした，Case 3 と Case 4 では，予測の精度が向上している．一方で，最大学習回数は同じ値とし，誤差閾値を 10 分の 1 とした，Case 4 と Case 6 では，予測の精度はほぼ同じとなっている．これは，誤差閾値が 0.01 よりも小さい場合，学習が誤差閾値に達することによってではなく，最大学習回数に到達することで終了しているためである．以上から，学習の最大繰返し数を高く設定するほど，発遅延，乗車率ともに精度が良くなる一方で，ニューラルネットワークの学習に要する時間が長くなり，予測の精度と学習にかかる時間がトレードオフの関係であることが分かる．実際にパラメータを設定する際には，求められる精度と学習に利用可能な計算時間を勘案する必要はあるが，たとえば，比較的短時間である程度の精度の予測を行う場合には Case 3 を，前日の終電後，翌日の初電までの間に学習を済ます場合には，ハイスペックの計算機を用意したうえで，Case 6 のパラメータを検討する，といったことが考えられ，本手法が実際の運用場面においても適用可能であると考えられる．

6.3 予測結果の詳細

例として，Case 6 の結果の中から，予測対象日の 9 日分の中の，ある日のある快速 1 本と各停 1 本について，駅 Q に到着した時点での，駅 Q から駅 X の発遅延を予測した結果を図 9 に示す．快速を●，各停を▲で示し，遅延の実績値を実線で，予測値を点線で示す．図 9 から，快速の各駅の予測値の差（絶対値）の平均は 6.75 秒，各停の各駅の予測値の差（絶対値）の平均は 3.50 秒であり，精度良く予測ができていることが分かる．

次に，図 10 に Case 6 の 9 日分の全列車を対象に，駅 Q～X の各駅発着時点において，その駅以降の各駅発遅延の予測値と実績値との誤差の累積比率を示す．図 10 の実線は，全列車分の累積比率である．誤差が 15 秒以内となるデータが全体の 90% 程度であり，精度良く予測ができていくことが分かる．当初，30 秒程度の予測誤差を目標とした




図 9 ある 2 列車の発遅延予測結果

Fig. 9 The result of delay prediction for two trains.




図 10 予測結果と実績の遅延との誤差の累積比率

Fig. 10 The cumulative ratio of delay prediction errors.

が、その目標は達成された。また、30 秒以上の遅延があった列車のみを対象とした累積比率も点線で示している。この結果から、列車に小規模の遅延が発生しても、25 秒以内の誤差のデータが全体の 90% 程度であることが分かる。なお、予測の精度を列車種別別や駅別に見た場合、異なる列車種別の間で予測の精度に大きな差はないが、駅については、快速列車の停車する比較的大きな駅の予測精度が、その他の駅よりも落ちることを確認している。これは、快速列車の停車する駅では緩急接続を行い、またその駅自体の乗降客数も多いことから、旅客の行動の変化が遅延や乗車率に与える影響が大きく、その他の駅との予測の難易度に差がでているためと思われる。各列車の短時間先の遅延を迅速かつ精度良く予測するためには、たとえば、乗降客数の多い大きな駅については、学習に用いるデータの種類を増やし、逆に乗降客数の少ない駅については、学習に用いるデータの種類を絞ることで、ネットワークの規模を学習に用いるデータの種類に比例して大きくすることなく高い精度で予測ができるようになることが期待される。

次に、図 11 に乗車率の予測結果を、図 9 で示した快速 1 本と各停 1 本について示す。図 11 では、乗車率の実績値（実際には、文献 [4] の対話型乗車率推定システムによる推定値で代用）を実線で、予測値を点線で示している。図 11 から、快速の各駅間の予測値の差（絶対値）の平均は 1.25%，各停の各駅間の予測値の差（絶対値）の平均は 1.50% であり、差は小さいことが分かる。




図 11 ある 2 列車の乗車率予測結果

Fig. 11 The result of the congestion rate prediction for two trains.




図 12 予測結果と推定乗車率との誤差の累積比率

Fig. 12 The cumulative ratio of the congestion rate prediction errors.

最後に、図 12 に図 10 と同様に 9 日分の全列車を対象に、駅 Q～X の各駅発着時点において、その駅以降の各駅間の乗車率の実績値と予測値との差（絶対値）の累積比率を実線で、また、30 秒以上の遅延があった列車のみを対象とした累積比率を点線で示す。結果から、30 秒以上の遅延があった列車のみを対象とした累積比率においても、差が 5% 以内となるデータが全体の 80% 程度であり、差は小さいことが分かる。

7. まとめ

本研究では、ニューラルネットワークを用いた列車遅延と乗車率の予測手法を提案した。将来的には大規模なダイヤ乱れへの展開を念頭に、数分程度の小乱れ時を対象として短時間先の列車遅延と乗車率を予測する手法となっている。評価実験から、小乱れ時においても 25 秒以内の予測誤差となるデータが全体の 90% 程度であることを確認した。

今後の課題として、他路線での検証や、乗車率データに実際に取得された応荷重データを使用した場合の検証があげられる。また、曜日や天候情報のモデルへの反映や、ダイヤ改正直後の、学習に使用可能なデータが少ない状況での予測手法の検討があげられる。さらに、ニューラルネットワークを多層化し、過学習や局所最適解に陥る問題の解決が図られた深層学習への提案手法の応用を検討し、より

高い予測精度の実現を目指したい。

参考文献

- [1] 電気学会・鉄道における運行計画・運行管理業務高度化に関する調査専門委員会：鉄道ダイヤ回復の技術，オーム社 (2010).
- [2] 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.1, pp.103–111 (1986).
- [3] 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).
- [4] 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).
- [5] 岩倉成志，高橋郁人，森地 茂：都市鉄道の遅延連鎖予測のためのエージェントシミュレーション：田園都市線および半蔵門線を対象に，運輸政策研究，Vol.15, No.4, pp.31–40 (2013).
- [6] 小林 渉，岩倉成志：駅構造を組み込んだ列車遅延シミュレーションの開発，土木学会論文集 D3 (土木計画学)，Vol.72, No.5 (土木計画学研究・論文集第 33 巻)，pp.I.1067–I.1074 (2016).
- [7] 岩本章寛，佐藤剛士，弓田康弘，溝口和人，安河内崇，福井清純：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, p.5 (2014).
- [8] 高垣良宏，荻原 崇，倉林修一，清水 康：鉄道における乗車率予測手法とグリーン車の乗車予測データを用いた実証実験，第 8 回データ工学と情報マネジメントに関するフォーラム (DEIM 2016) D1-4 (2016).
- [9] 熊沢逸夫：学習とニューラルネットワーク，森北出版 (1998).
- [10] Chapuis, X.: Arrival Time Prediction Using Neural Networks, *Proc. 7th International Conference on Railway Operations Modeling and Analysis (RailLille 2017)*, pp.1500–1510 (2017).
- [11] Yaghini, M., Khoshraftar, M.M. and Seyedabadi, M.: Railway passenger train delay prediction via neural network model, *Journal of Advanced Transportation*, Vol.47, No.3, pp.355–368 (2013).



中挾 晃介 (正会員)

2015 年 3 月筑波大学大学院システム情報工学研究科コンピュータサイエンス専攻博士前期課程修了。同年 4 月 (公財) 鉄道総合技術研究所入所。現在，同所信号・情報技術研究部運転システム研究室研究員。輸送計画，運行管理に関する研究開発に従事。



辰井 大祐 (正会員)

2008 年 3 月東京大学大学院工学系研究システム量子工学専攻修了。同年 (財) 鉄道総合技術研究所入所。現在，(公財) 鉄道総合技術研究所信号・情報技術研究部運転システム研究室副主任研究員。鉄道の輸送計画・評価，旅客流動分析に関する研究に従事。



國松 武俊

2004 年 3 月京都大学大学院情報学研究科システム科学専攻修了。同年 (財) 鉄道総合技術研究所入所。現在，(公財) 鉄道総合技術研究所信号・情報技術研究部運転システム研究室副主任研究員。博士 (工学)。鉄道の旅客行動分析，旅客流動推定，輸送計画作成・評価，シミュレーション，スケジューリングアルゴリズムに関する研究開発に従事。