

ニューラルネットワークによる列車運行予測手法

辰井 大祐* 中挾 晃介* 國松 武俊*

Predicting Method of Train Delay and Train Congestion Using Neural Network

Daisuke TATSUI Kosuke NAKABASAMI Taketoshi KUNIMATSU

When train delay occurs, train dispatchers conduct railway traffic arrangement while predicting transport status several tens of minutes later based on their experience. Therefore, there are possibilities that train delay increases if they predict the status incorrectly. In order to support dispatchers' decision making, we devised a predicting method based on the neural network, which predicts changes of train delay and train occupancy rate based on the data in the past. Then, we applied our method to an actual commuter line in the peak hour under the conditions that there are no sudden accidents, and verified its accuracy.

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

1. はじめに

列車の遅延時には、旅客の利便性が低下しないよう、遅延の拡大を防ぐ必要がある。そのため、列車運行を管理している指令員は、各列車の現在の遅延が今後拡大するか縮小するかをなるべく正確に予測し、必要に応じて運転整理と呼ばれる一連のダイヤの変更を実施している。従来、そのような短時間先の列車遅延の予測は指令員の経験に基づいていた。近年、計算機を用いて列車運行を予測する手法も提案されてきたが、それらは必ずしも十分な精度とは言えなかった。そこで本研究では、将来的には大規模なダイヤ乱れ時にも対応できることを念頭において、第一段階として、突発的なトラブルがない数分程度の遅延時を対象に、ニューラルネットワークを用いて、短時間先の列車遅延と乗車率を予測する手法を開発した。そして、運行体系が複雑な大都市圏の通勤路線の朝ラッシュ時間帯を対象に、提案手法により列車遅延を予測した結果、85%程度のケースにおいて、誤差が30秒以内であることを確認した。乗車率に関しても、推定値と比較した結果、90%程度のケースにおいて、誤差が10%以内であることを確認した。

2. 背景と目的

2.1 遅延発生と運行管理業務

日々の列車運行状況を監視している指令員は、遅延が発生した場合には、遅延の更なる拡大、伝搬を防止するために、運転整理と呼ばれる一連のダイヤ変更手配を行う。遅延量に応じて、例えば数分程度の遅れの場合には

* 信号・情報技術研究部 運転システム研究室

関係列車の間隔を調整したり、他路線から進入してくる列車が大きく遅延している時には列車の順序を変更したり、場合によっては列車を運休するなどの手配を行っている。

2.2 本研究でターゲットとする運行状況

事故などが発生して運転を見合わせた場合や、一部列車を運休せざるを得なくなった場合、運転再開後の列車運行状況を予測し、それに基づき適切な運転整理を行うことは、指令員にとって重要な業務である。したがって、正確かつ迅速に数十分先の列車運行状況を予測することは、指令員による適切な運転整理判断、手配による運転整理業務の品質向上につながる。また、運行状況の予測結果に基づき、ある程度先の変化も含む、遅延や混雑の見込み情報を旅客に正確に案内することができれば、旅客サービスの向上にもつながる。

ただ、そのような大規模な乱れ時だけでなく、最大で数分程度の小規模な遅延時においても、列車運行を詳細に予測する手法は確立されていないのが現状である。このため、将来的には大規模な乱れ時にも対応できるようにすることを念頭に、第一段階として、小規模な乱れ時を本研究の対象とする。

2.3 運行管理業務の課題

大規模な遅延時はもちろん、数分程度の小規模な遅延時においても、旅客の乗降時間の拡大に起因する遅延の拡大の予測は難しいことが多い。例えば、ある列車に3分の遅延がある場合、今後、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、適切な手配

特集：輸送・交通計画技術

は異なってくるにも関わらず、今後の遅延の拡大・縮小は、主に指令員が経験を頼りに予測しているのが現状である。そのため、運行状況の変化を見誤ると遅延の更なる拡大を招く可能性がある。

また、現状では、指令員は遅延がある程度の大きさに拡大した後に、列車の間隔調整等の手配を行うことが多い。その結果、手配が後手となり、間隔調整の効果が限定的となる場合がある。たとえ現在は遅延量が少なくとも、その時点で短時間先の遅延、混雑の推移を予測し、遅延が拡大すると予測される場合には、先手を打って間隔調整を行うことが出来れば、より効果的と考えられる。

2.4 関連研究

列車運行予測については、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¹⁾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²⁾や、筆者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³⁾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おらず、個別の事情を有する様々な路線、駅に対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、その機能は一部路線の運行管理システムで実用化されている⁴⁾。しかし、ユーザが駅、列車種別、時間帯等に応じてパラメータを多数設定する必要があり、適切な設定方法に課題がある。

2.5 本研究に用いる手法

前節までの議論から、列車運行の予測手法には①過去の日々の遅延、乗車率を反映すること、②パラメータの数が少ないこと、③緩急接続など列車ダイヤの特徴を反映すること、④旅客の流動を加味すること、⑤高速に予測結果を得ることができると等が望まれる。さらに、予測精度向上の観点から、列車運行状況の複雑な変化を詳細に予測可能なことも望まれている。

過去のデータを用いて短時間先までの状況を予測する際、重回帰分析が用いられることが多い。しかし、実際の列車運行を考えた場合、重回帰分析のような線形的な手法では、遅延の複雑な変化を表現することが難しい。そのため、本研究では、非線形の手法を用いた予測手法を用いることとした。

非線形の予測手法の一つとして、ニューラルネットワークがあり、応用例として時間の経過とともに変化するデータを予測する取り組み⁵⁾等も行われている。そのニューラルネットワークの汎化性能や学習の効率を向上

させた深層学習が近年、注目を浴びている。特に画像認識、音声認識の分野で顕著な性能を示しており、様々な分野への応用が活発になされている。

上述の要件を最大限満たし、かつ将来的に深層学習の適用可能性を探るために、本研究における列車運行予測手法として、ニューラルネットワークを用いる。

予測の段階において、列車運行は時々刻々と変化していくため、予測結果を逐次、更新する必要がある。ニューラルネットワークでは学習においては大きな計算時間を要するが、学習の結果として得られた予測モデルを用いることで、予測計算は短時間で行えることが期待できる。

2.6 本研究の目的

本研究では、大都市圏の通勤路線のラッシュ時間帯を対象とし、日々発生する数分程度の小規模遅延を予測する手法を構築することを目的とする。これにより、現在時刻から30分程度先までの遅延、乗車率を予測し、列車の間隔調整や順序変更等、適切な運転整理や旅客案内の実現に貢献することを目指す。

3. 列車運行予測のためのデータと予測の枠組

昨今の情報通信技術の発展により、各列車の遅延状況、乗車人数、駅での自動改札機の通過人数など、列車運行に関わる様々な情報が高い精度で取得できる環境が整ってきた。

本章では、列車の運行予測に使用するデータについて述べる。既に実時間で取得可能、活用可能となっているデータだけでなく、将来的に実時間で取得可能になると想定されるデータを含めて記述する。

3.1 列車運行予測に活用するデータの種類

現状の運行管理システム等で取得可能なデータを整理し、列車の運行予測への活用可能性を検討した結果、本研究では、①列車運行の基本計画（列車ダイヤデータ）、②列車ダイヤデータの実績、③各列車の各区間の乗車率データを使用する。①と②を使用することによって、列車の遅延を予測に加味することができ、③を用いることで、旅客の混雑を加味した予測が可能になると考えられる。

ここで、乗車率データには、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する。しかし、6章で述べる本研究の評価試験においては、車両の応荷重装置のデータは使用できなかった。そこで、各駅における自動改札機ODデータと運行実績データから、文献3)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、それを乗車率データの代用とした。

3.2 列車運行予測の枠組

ニューラルネットワークは機械学習の手法の一つであり、列車運行を予測するためには、過去の実績データ（列車遅延や乗車率）をもとに、事前にデータ間の相関・関連性を学習するという処理が必要になる。これにより予測モデルを構築する（図1）。

予測の段階で構築した予測モデルを使用し、これに現在時刻までの列車遅延データや乗車率データを入力して、短時間先までの予測を行う（図2）。

4. ニューラルネットワーク

ニューラルネットワークは、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、人間の神経細胞網を、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

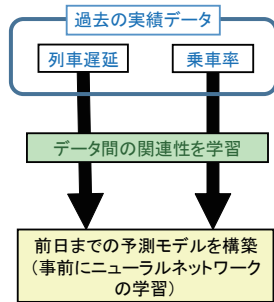


図1 学習に用いるデータとモデルの構築

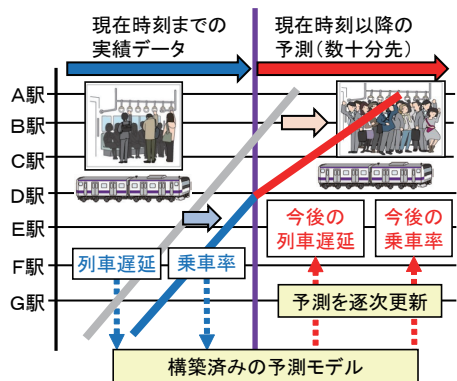


図2 構築済みの予測モデルを用いた予測




図3 パーセプトロンとニューラルネットワークの構造

である。構造の違いにより多くの種類のニューラルネットワークが提案されているが、本研究では、最も単純な構造である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。これは、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一つの層を成し、入力層、隠れ層、出力層という3層で構成されている単方向のグラフ構造である（図3）。入力層から順に、入力値に各パーセプトロン間の結合の重みをかけた値の和を次の層のパーセプトロンの出力関数に入力し、各パーセプトロンの出力値を逐次計算することで、出力層における値を計算する。

本研究では、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である誤差逆伝播法を用いる。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重みの値を調整していく学習法である。これを大量の教師データ（入力と、それに対する正解の組み合わせ）に対して行い、出力結果と正解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、学習のための教師データの与え方等は、学習に要する時間や予測精度に影響を及ぼすため、問題に応じた調整が必要になるものの、調整するパラメータの数は2.4節に記した手法ほどは多くはない。

5. ニューラルネットワークでの列車運行予測

5.1 ニューラルネットワークの構造と学習・予測

(1) 用意するニューラルネットワーク

各列車、各駅の発着事象それぞれについて、1つずつ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意する。予測を行うタイミングは列車が駅に到着および発車する時点とする。

(2) ニューラルネットワークの学習

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オンライン学習と呼ばれる一般的な学習手続きにより、パーセプトロン間の結合の重みを決定する。

(3) ニューラルネットワークでの予測と出力

予測対象日において、各列車が各駅に到着、発車した時点を中心時刻とし、それに対応する学習済みのニューラルネットワーク、つまり、構築した予測モデルを用いて予測する。その日の現在時刻までの発遅延と乗車率を入力とし、現在時刻以降、一定時間幅先までの予測対象列車の発遅延、乗車率の予測値を出力とする。

特集：輸送・交通計画技術

5.2 ニューラルネットワークの入出力データ

予測時に使用する入力データに関し、様々な取り方を試行した予備実験の結果を踏まえ、入力データの対象範囲を「予測対象列車およびその前後の列車の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。例えば、図4において、予測対象列車の列車2が駅G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 内にある列車2の発遅延、乗車率を予測することを考える。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。

予測対象列車の遅延や乗車率に影響を及ぼすと考えられる入力データは、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全ての駅を入力とする。図4において、●で示した列車2の駅B～駅Fの発遅延、発時点での乗車率が入力となる。

(2) 先行列車のデータ

当該駅において、計画ダイヤ上で当該列車の直前に発車した列車の当該駅における発遅延、および当該列車の直前に到着した列車の、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4では、現在時刻 t で駅Gにおいて列車2の直前に到着する列車、発車する列車とともに列車1のため、列車1の駅Cから駅Gの発遅延（▲で示す）が入力データとなる。

(3) 後続の列車のデータ

現在時刻 t から時刻 $t+T_w$ 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後続の列車について、現在時刻 t 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本を入力データとする。ただし、待避がない場合は後続の列車は入力データとしない。図4において、列車2は時間幅 T_w の間に駅Gで列車3を待避する。各待避駅で最後に待避した列車の発遅延を入力データとするため、列車3における現在時刻から遡って5駅分の、駅A～駅Eの発遅延が入力データ（◆で示す）となる。

一方で出力は、現在時刻から時刻 $t+T_w$ 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4では、列車3が時間 T_w の間に発車する駅G～Jの発遅延、発時乗車率が出力（○で示す）となる。

6. 予測精度の評価

本章では、大都市圏内の通勤路線を対象に、学習に関

するパラメータを変化させながら、提案手法の予測精度を比較・検証した結果について述べる。

6.1 評価の概要

(1) 対象路線の概要

ここでの試行では全20駅（駅Aから駅T）からなる通勤路線を対象とした。この路線では、両端の駅で他路線と直通運転をしており、途中の駅Gでも他路線へ直通運転をしている。この路線で最も乗降客数が多いのは駅Jであり、駅T方向の列車は、駅Aと駅Jの間で、一部快速運転が行われている。なお、列車の待避は設定されていない。

(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た。教師データとして70日分を、検証データとして9日分を用いた。前述のように、今回の対象路線では乗車率データとして応荷重装置による乗車人数データが使用できなかったため、各駅における自動改札機ODデータと運行実績データから文献3)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した。

ここで、ニューラルネットワークを特徴付ける活性化関数としてシグモイド関数を用いているが、この値域が(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、ニューラルネットワークに入力する値を正規化し、 $[0, 1]$ 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)の範囲のデータに、正規化時に除算に使用した値を乗じることにより求める。今回の対象路線では、列車遅延は300秒、乗車率は200%で正規化した。

(3) 対象列車

本研究では、小規模乱れが発生しやすい朝ラッシュ時

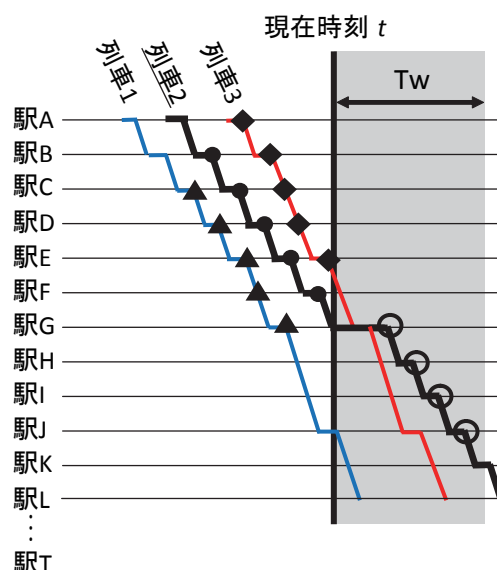


図4 入出力データとなる遅延量、乗車率

表1 発遅延と乗車率の予測結果

	学習パラメータ			試験結果				
	誤差の 閾値	最大学習回数	学習率	学習時間 (時間)	精度(1)：全列車		精度(2)：30秒以上遅延がある列車	
					発遅延(%)	乗車率(%)	発遅延(%)	乗車率(%)
Case 1	0.01	100	0.01	0.28	62.72	72.06	66.86	73.77
Case 2	0.01	1,000	0.01	0.33	69.55	74.53	70.14	74.45
Case 3	0.001	100	0.01	1.07	75.49	81.46	73.20	81.26
Case 4	0.001	1,000	0.01	9.08	88.23	87.85	83.68	85.73
Case 5	0.01	100	0.001	1.20	26.64	39.94	35.88	40.46
Case 6	0.0001	1,000	0.01	11.07	88.23	87.85	83.80	86.37
Case 7	0.0001	10,000	0.01	99.45	91.69	92.47	86.02	89.76

間帯の7:00～9:00の間に、最も乗降客数の多い駅Jを発着する全67列車をターゲットとした。

(4) ニューラルネットワークの構造

隠れ層の数に関するチューニング結果を反映し、本研究では隠れ層のユニット数を30個とした。

(5) ニューラルネットワークの入力

本手法は待避がある場合も想定したものとなっているが、今回の予測精度評価試験の対象とした路線では待避がないため、ニューラルネットワークへの入力、どの列車についても、予測対象列車と先行列車のみになる。

6.2 学習パラメータごとの予測精度比較

学習に関するパラメータ(学習の終了条件となる誤差の閾値、最大学習回数、学習率：学習における結合重みの更新量の係数)を変化させて予測精度を比較した。試行したパラメータの組合せと結果を表1に示す。なお、実験に使用した計算機環境は、CPUがIntel® Core™ i7-6700、クロック数が2.60GHz、メモリが64.0GB、OSがWindows 10 Professional(64bit)である。

予測精度を議論するにあたり、精度(1)を、全列車に対して発遅延予測値と実績値との誤差が30秒以内に収まる割合とする。乗車率については、予測値と実績値との誤差が10%以内に収まる割合とする。一方で、精度(2)は30秒以上の遅延があった列車のみを対象とした場合に、誤差が上記範囲内に収まる割合とする。これを算出する理由は、精度(1)の対象列車の中には予測するべき発遅延の実績値が0秒に近い列車も多く含まれているからである。これを除外するため、30秒以上の遅延があった列車のみを対象を限定した精度(2)を算出し、遅延が生じている場合にも、良好な予測精度であるか否かを確認した。

結果として、詳細なパラメータを設定するほど発遅延、乗車率共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るというトレードオフの関係があることが分かる。これを踏まえ、例えば、

比較的短時間である程度の精度で予測する場合には、学習により長い時間を要するCase6ではなくCase4を採用することが考えられる。一方、高い予測精度が必要な場合は、ハイスペックの計算機を用意し、Case7のパラメータを採用することも考えられる。

6.3 予測結果の詳細

例として、Case7の結果について、予測対象日のある日の駅A方向のある2列車(列車①と列車②)に対して駅Tに到着した時点での、駅Sから駅Jまでの発遅延の予測結果を図5に示す。この場合、各駅の予測値と実績値の誤差の平均はそれぞれ8.6秒、および5.3秒となり、精度よく予測できていることがわかる。

図6に9日分の全予測対象列車について、対象区間の各駅の着時点と発時点において、その駅以降の各駅発遅延の予測値と実績値の誤差の累積比率を示す。図6の青線は全列車分の累積比率を示し、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赤線で示す。列車に小規模の遅延が発生しても、30秒以内の誤差のデータが全体の85%程度であることが確認できた。

乗車率も同様に、全対象列車について対象区間の各駅の着時点と発時点において、以降の各駅発時点での乗車率の予測値と推定値の誤差の累積比率を図7に示す。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10%以内となるデータが全体の90%程




図5 2列車の予測結果




図6 発遅延についての累積比率




図7 乗車率についての累積比率

度であり、予測精度が良好なことがわかった。

7. プロトタイプシステムの構築

本研究で開発した予測手法による予測結果を可視化するため、列車運行予測システムのプロトタイプを構築した。表示画面の例を図8に示す。現在時刻を挟んで左側に実績部分が青色の列車スジで、右側に予測部分が赤色の列車スジで表示される。列車スジの太さは遅延量または乗車率の値に対応し、ユーザ側で表示の切替が可能である。このような表示画面により、適切な運転整理や旅客案内への活用が期待できる。

8. おわりに

本研究では、大規模なダイヤ乱れへの将来的な展開を念頭に、まずは小規模の遅延時を対象として、ニューラルネットワークを用いて短時間先の列車遅延と乗車率を予測する手法を開発した。そして、大都市圏内の通勤路線に適用し、予測精度を確認した。突発的なトラブルが




図8 プロトタイプシステムの画面例

ない小規模な遅延時においては、列車遅延の予測誤差が30秒以内となるデータが85%程度であり、乗車率に関しても、推定値との比較になるが、10%以内の予測誤差となるデータは90%程度であった。

今後の課題として、乗車率を実際の応荷重データに変更した場合の精度検証や、大規模乱れ時への適用、学習データ量と精度のバランスの検証がある。さらに、近年、注目を集めている深層学習を列車運行予測に適用することも検討したい。

文献

- 1) 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
- 2) 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
- 3) 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
- 4) 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, 51, p.5, 2014
- 5) Xavier Chapuis, Arrival Time Prediction Using Neural Networks, Proceedings of 7th International Conference on Railway Operations Modeling and Analysis, 2017.