

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

旅客の流れを考慮して 列車の流れをみる

列車ダイヤが乱れた場合、列車の運行を管理する指令員は、各列車の遅延や乗車率を予測しながら、列車ダイヤに変更を加えていきます。しかし、各列車の運休をとまなうような大規模な遅延時だけでなく、旅客の混雑から生ずる数分程度の小規模な遅延時であっても、各列車の遅延や乗車率の変化の正確な予測は難しいのが現状です。そこで、まずは小規模遅延時を対象とし、数十分先までの列車遅延および乗車率を予測する手法を考案しました。ここでは、その概要と大都市圏内の通勤路線を対象として検証した結果を紹介します。



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
【専門分野】輸送計画作成・評価, 旅客流動推定



中挾 晃介
Kosuke Nakabasami
信号・情報技術研究部
運転システム研究室
研究員
【専門分野】輸送計画, 運行管理



國松 武俊
Taketoshi Kunimatsu
信号・情報技術研究部
運転システム研究室
副主任研究員
【専門分野】旅客行動分析, 輸送計画作成・評価



平井 力
Chikara Hirai
信号・情報技術研究部
運転システム研究室
室長
【専門分野】数値モデル, 社会情報システム

遅延発生と運行管理業務

近年、大都市圏の通勤路線の朝ラッシュ時において、数分程度の遅延が慢性的に発生しており、旅客の利便性確保という観点から、改善が求められています。このような遅延の原因の一つは旅客の混雑であるという調査結果が、国交省の遅延対策ワーキング・グループの報告資料¹⁾で報告されています。

旅客の混雑に起因する遅延は、具体的には次のような流れで発生します。はじめに、混雑にともなって旅客の乗降に要する時間が拡大します。そして、駅の停車時間が伸びた結果、当該列車に遅延が発生し、前の列車との運転間

隔が増大します。そのため、次の駅で当該列車を待つ旅客が増加し、旅客の乗降に時間を要することから、遅延が拡大します(図1)。

指令室では、指令員が日々の列車運行状況を監視し、遅延が発生した場合には、遅延のさらなる拡大、伝搬を防止するために、さまざまな運転整理を行います。遅延量に応じて、たとえば数分程度の遅れの場合には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順序を変更したり、列車を運休したりします。これらの業務を「運行管理」といいます。

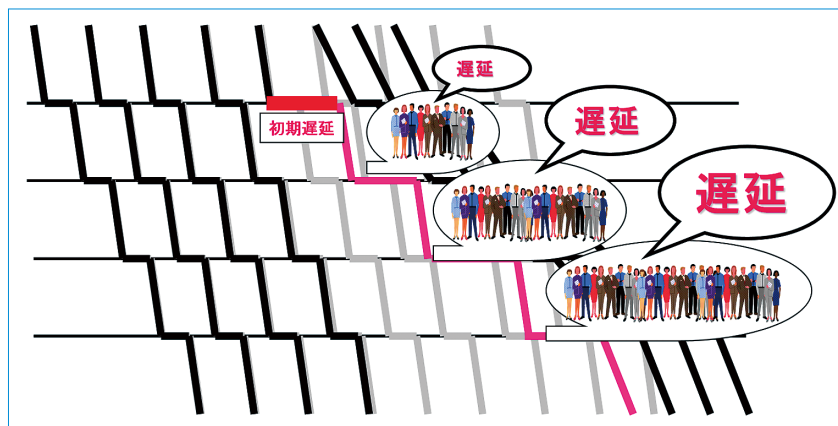


図1 旅客の乗降による遅延の拡大の様子

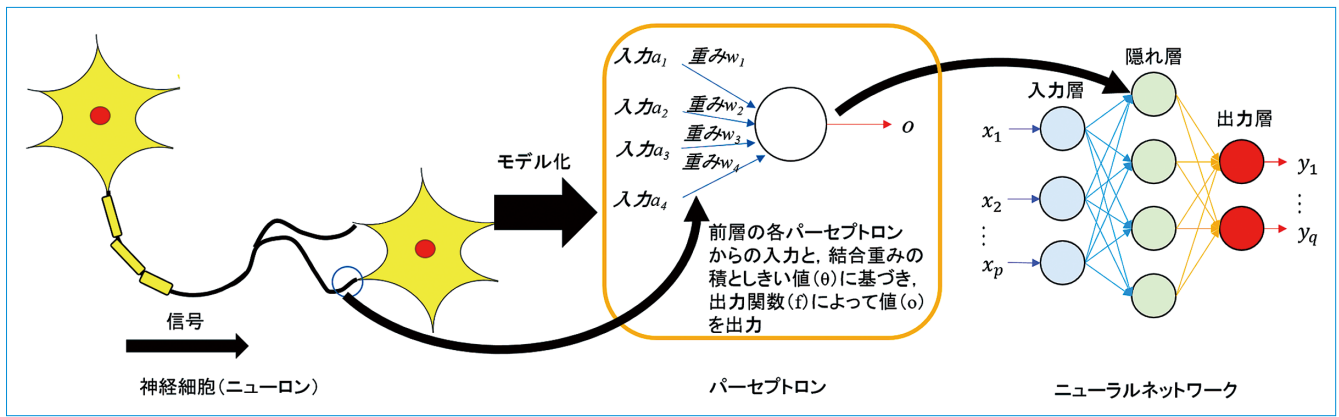


図2 神経細胞(ニューロン)とパーセプトロンとニューラルネットワークの構造

運行管理業務の課題

列車の運休が必要になる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、乗降時間の増加に起因する遅延の拡大を予測することは困難です。そのため、ここでは、将来的には大規模な遅延時にも対応することを念頭に、研究の第一段階として小規模遅延時を対象に遅延の予測手法を検討しました。

小規模遅延時であっても、現在時刻以降に遅延が拡大するか縮小するかにより、適切な手配は異なります。この遅延の拡大、縮小の予測は、現在、指令員が主に自身の経験に基づいています。この遅延の予測に関し、運行管理システムなどで正確に予測、提示することができれば、指令業務の支援につながります。さらに、仮に短時間先に発生する「混雑」や「遅延」を事前に予測できれば、ある列車が混雑して遅延が発生し始めそうな段階で先手を打って時間調整を行うなど、より効果的な運行管理手配が可能になると考えられます。

これまでの列車運行予測手法

これまでも列車運行を予測するための手法がいくつか提案されてきました。たとえば、短時間先の遅延を予測しダイヤ図を描画する、予測ダイヤ機能が

開発されています²⁾。しかし、これらの手法はユーザーが線区、駅、停車番線、列車種別などに応じて、多くのパラメータを適切に設定しなければなりません。たとえば列車の時間的な運転間隔や、折り返しに要する時間、朝ラッシュ時間帯の旅客の乗降時間などがあります。そのため、複数の要因が重なり合い、複雑に変化する列車遅延の実情をつかんだ予測をすることは困難です。

ニューラルネットワークを用いた列車運行予測手法

これまでの手法の課題や、実使用場面での使い方を考慮すると、列車運行の予測手法には、①過去の日々の遅延、乗車率を反映した手法であること、②パラメータの数が少ない手法であること、③緩急接続など列車ダイヤの特徴を反映した手法であること、④短時間で予測可能であること、⑤複雑に変化する実際の列車遅延の特徴をつかんだ予測が可能であることなどが望まれます。

上記の条件を最大限満たす手法の一つとして、近年、画像認識や音声認識の分野で圧倒的な性能を示している深層学習を利用する方法があげられます。この深層学習は、さまざまな分野に応用する取り組みが活発になされており、

時間の経過とともに変化するデータの予測手法への適用も検討されています。

深層学習は、ニューラルネットワークと呼ばれる、実データをもとに入力と出力の対応関係をコンピューターに学ばせる技術を応用した技術です。そこで、将来的に深層学習が列車運行予測に対して適用可能かどうかを探るために、第一段階として、ニューラルネットワークを用いた予測手法を構築しました。また、旅客の流れも加味した予測を行うため、各列車の遅延だけでなく、各列車の各駅間の乗車率データも入力データとして活用することにしました。

ニューラルネットワーク

ニューラルネットワークは、人間の脳の中にある多数のニューロン(神経細胞)間の信号の受け渡しを計算機上で表現した計算モデルです。代表的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り、複数のパーセプトロン(計算機上でニューロンをあらわすもの)が層を成し、入力層、隠れ層、出力層という3層で構成されます(図2)。入力層の各パーセプトロンの出力は隠れ層の各パーセプトロンの入力となって影響を与え、隠れ層の各パーセプトロンの出力は出力層の各パーセプトロンの入力となって

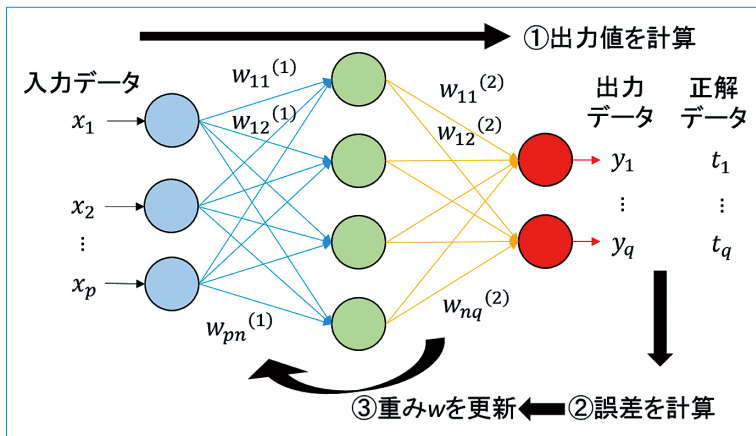


図3 誤差逆伝播法のイメージ図

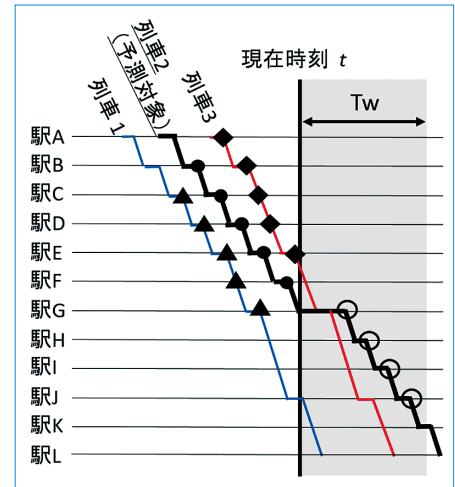


図4 ニューラルネットワークの入出力

影響を与えるというモデルになっています。各層のパーセプトロン間の影響の大きさは、パーセプトロン間の結合の重みとして表現されます。

ニューラルネットワークの代表的な学習方法として、誤差逆伝播法があります。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誤差を計算し、この誤差の値が小さくなるように、結合重みの値を調整していく学習方法です(図3)。これを、入力と、その入力に対する正解がわかっている大量のデータに対して行い、出力結果と正解データの誤差が想定するしきい値よりも小さくなる、また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、学習を終了します。

学習が終了したニューラルネットワークに対し、予測を行いたいテストデータを入力とすれば、予測結果を得ることができます。

ニューラルネットワークの入出力

ニューラルネットワークへの入力データの種類、範囲については、データの種類や量を変更させながら予測精度を比較した結果、「予測対象列車およびその前後の列車の5駅手前まで




図5 対象路線の運行形態

の発遅延、および予測対象列車の5駅手前までの乗車率」を入力データとすることとしました。図4は列車2の駅G以降の発遅延と乗車率を予測する際の入出力を表しており、入力となる発遅延または乗車率を●、▲、◆で、出力となる予測対象の発遅延、乗車率を○で示します。●、▲、◆はそれぞれ、予測対象列車の5駅分の各駅の発遅延と発時点の乗車率、前の列車の5駅分の発遅延、後ろの列車の5駅分の発遅延を表しています。なお、後ろの列車については、予測対象列車が他の列車を待避する場合にのみ考慮することとしています。

実路線を用いた評価

構築した手法を大都市近郊路線に適応し、数分程度の小規模遅延時の運行実績データと乗車率データ79日分を用いて予測精度を検証しました。70日分をニューラルネットワークの学習に用いて、残りを予測精度の検証に用

いました。

対象路線は全20駅(駅Aから駅T)からなり、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ます(図5)。

今回の対象路線では、乗車率データとして、各駅における自動改札機時間帯別ODデータ(※参照)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を用いました。もし、乗車率を計測できる仕組みがあれば、その計測値を直接使用することもできます。

ニューラルネットワークの予測性能は学習のパラメーターに大きく依存するため、その調整が必要になります。パラメーターとして学習の終了条

※ 自動改札機時間帯別 OD データ

ある一定幅の時間帯の中に、どの駅から来た旅客の何人が、どの駅にある自動改札機を通過したかというデータをいいます。




図6 発遅延の誤差の累積比率(左)と乗車率の誤差の累積比率(右)

件(誤差のしきい値, 最大学習回数), 学習における結合重みの更新量の係数(学習率)があり, それらを変化させて予測精度を比較しました。

ここでは, 対象区間の各駅の着時点と発時点において, その駅以降の各駅の発遅延や乗車率の予測値と実績値の誤差について, 最も予測精度が高かった場合の累積比率を紹介します(図6)。青線は全列車分の累積比率を示し, 30秒以上の小規模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しています。全列車を累計比率の集計対象とすると, 遅延が全くない列車の予測精度も集計の対象になってしまうため, 一定以上遅延があるという観点から, 30秒以上の遅延がある列車のみを対象に集計して累積比率を求めました。その結果, 小規模な遅延が発生しても30秒以内の誤差のデータが全体の85%程度であることを確認しました。また, 乗車率に関して, 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%程度であり, 予測精度が良好なことがわかりました。

列車運行予測システムのプロトタイプ

今回紹介した手法により列車の遅延を予測し, その結果を可視化するシステムのプロトタイプを開発しました

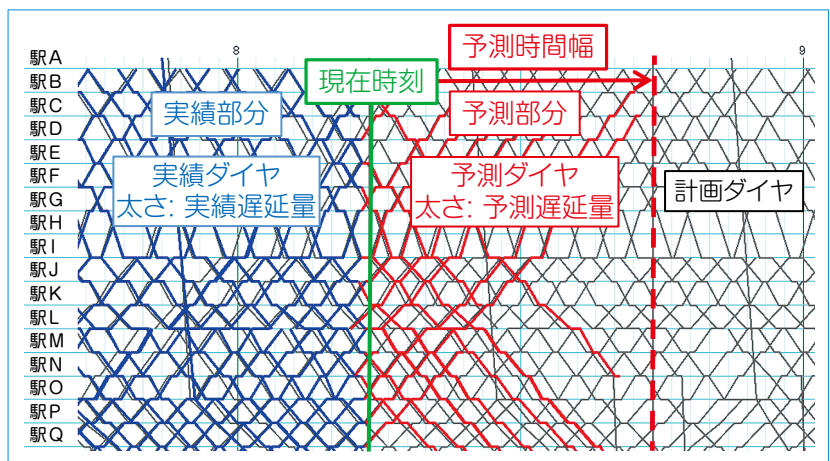


図7 プロトタイプ画面例

(図7)。現在時刻を挟んで左側が実績部分で青色表示, 右側が予測部分で赤色表示となっています。

予測結果を視覚的にわかりやすく表示することで, 指令員の業務の支援が可能になります。具体的には, 遅延が拡大する列車が事前にわかるため, 遅れが拡大する前に, 遅れそうな列車への旅客集中を防ぐために, 前を走行する列車に対して運行間隔の調整指示をすることができるようになります。さらに, 遅延が予測される列車については, 旅客に早目に周知・案内することも可能になります。

おわりに

ここでは, 数分程度の小規模遅延時にニューラルネットワークを用いて列車運行を予測する手法について紹介し

ました。

今後は, 深層学習の適用可能性を検討するとともに, 最終的には列車の運休がともなうような大規模な遅延時の列車運行予測手法の構築に取り組んでいきたいと考えています。[RRR]

文献

- 1) 国土交通省: 遅延対策ワーキング・グループ報告資料, 2016
- 2) 岩本章寛, 佐藤剛志, 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
- 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