

遅延の傾向を反映した LSTM による列車遅延予測手法

辰井大祐¹ 中挾晃介¹ 國松武俊¹ 坂口隆¹

概要：大都市圏内の通勤路線において、小規模遅延発生時に数十分先までの遅延を予測することは、列車運行を管理する指令員の業務の支援だけでなく、利用者への案内という観点からも重要である。遅延の予測は実務上、現在の遅延量がそのまま継続すると仮定して見積もられることが多いが、実際には、列車運行に応じて遅延は複雑に変化するため、精度良く予測することは困難である。筆者らはこれまで、ニューラルネットワーク (NN) や Long Short Term Memory (LSTM) を用いた遅延予測手法を構築した。今回、LSTM への入出力構造を変更することにより遅延の傾向を反映できる手法（提案手法）を構築した。本稿では、新たに構築した手法の概要とともに、提案手法による遅延の予測精度を評価した結果について報告する。

キーワード：列車遅延，ニューラルネットワーク，Long Short Term Memory，時系列データ予測

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、その発生、拡大を極力、防止する対策が鉄道事業者には求められる。遅延の発生を未然に防ぐ方法として、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、遅延の拡大を防ぐため、列車間隔を調整する等の運転整理もあわせて実施される。これには、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的にみて、各列車の現在の遅延が今後拡大するか縮小するかを予測したうえで、適切な運転整理を判断している。

現在の列車の遅延が、今後、拡大するか縮小するか予測可能になれば、指令員の運転整理業務の支援が可能である。また、列車遅延に関する利用者への案内も、品質向上させることができる。そこで筆者らは、これまでに、突発的なトラブルがない数分程度の小規模遅延発生時を対象に、短時間先の列車遅延を予測する手法を提案した[1,2]。具体的には、ニューラルネットワーク (NN) や Long Short Term Memory (LSTM) を用いた予測手法である。今回、LSTM の入出力構造を改良することにより、文献[2]では十分に反映できなかった、過去の遅延の傾向をつかんだ予測を可能とする。

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 16 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。

2. 背景と目的

近年、大都市圏内の通勤路線における遅延が鉄道事業者

の大きな課題となっている。国土交通省の調査[3]によると、東京圏の 45 路線において、2018 年度は 1 か月あたり平均して約 12 日間で最大遅延が 5 分以上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% が混雑のための乗降時間超過が原因であることが報告されている。

2.1 遅延の発生と拡大

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

(1) 初期遅延（一次遅延）の発生

主に、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、最初の遅延が発生する。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) 後続の列車への遅延伝播

(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。

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、遅延発生時には、更なる拡大、伝播を防止するために、数十分先までの遅延を予測したうえで、予測する遅延の大きさに応じて様々な運転整理を行う。この際、今後遅延が拡大するか縮小するかによって運転整理の内容は異なる。例えば、図 1 に示すように、後続列車の現在時刻における遅延が 3 分である場合を考える。後続列車の遅延が一定量以上拡大すると予測される場合は、先行列車の停車時間を例えば 1 分追加すること

¹ (公財)鉄道総合技術研究所
Railway Technical Research Institute




図1 予測遅延量に応じた運転整理

で、列車を適切な間隔になるよう調整する必要があるが、後続列車の遅延が減少する場合は先行列車に対しては特に時間の調整は必要ない。

現状では、このような今後の遅延の変化は指令員が経験的に予測している。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、その後の遅延の正確な予測は重要になる。

しかし、現状では、小規模の遅延が発生した場合においても、そ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も、運行管理システムで実用化されつつある。しかし、前述のように、それらは現行の遅延量が継続する仮定での予測であったり、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、伝搬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[4,5]。しかし、これらは、過去の日々の遅延、乗車率データを直接は反映しておらず、路線固有の状況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、一部路線の運行管理システムで実用化されている[6]。しかし、ユーザが駅、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。

一方、海外でも、Xavier らによって、ニューラルネットワークによる各駅の到着時間の予測手法が提案されている[7]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[8]。しかし、対象路線が長距離路線であり、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、文献[2]で構築した手法における LSTM への入出力構造を改良し、列車種別毎に LSTM を構築して列車の遅延を予測するモデルを構築する。

3. NN を用いた列車遅延予測手法

これまで筆者らが提案した NN を用いた列車遅延予測手法（以下、この予測モデルをモデル 1 と呼ぶ）について概説する。詳細は文献[1]を参照されたい。

3.1 構築した NN

3 層の階層型フィードフォワードニューラルネットワークを用い、中間層のユニット数は 10 層とする。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、後述する入力と出力の関係性を、誤差逆伝播法により事前に学習する。そして、予測対象日の遅延データ、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 NN の入出力

本研究で用いる NN の入力と出力を図 2 に示す。

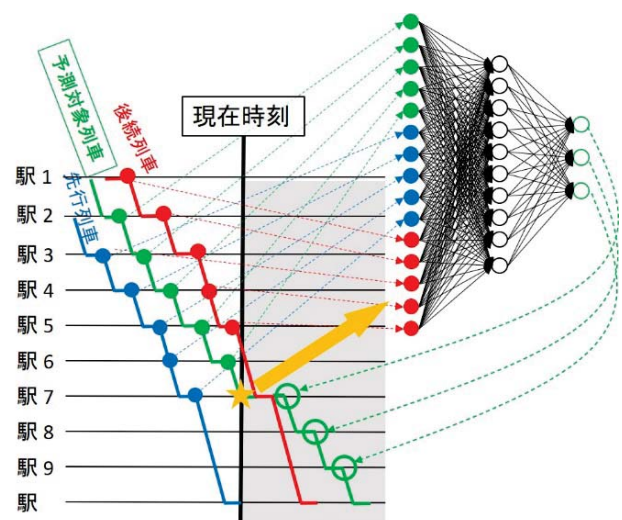


図2 NN (モデル 1) の入力と出力

(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2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. 提案手法

筆者らは、以前に文献[2]においても、LSTMを用いた列車遅延予測手法を構築している。しかし、この時には、(1)教師データが少ないこと、(2)多くの計算時間が必要であること、(3)データの時系列性が十分に反映できていなかった、という3つの課題があった。

そこで、それらの課題に対処するため、本研究では、普通列車、快速列車といった列車種別毎にLSTMを構築して列車遅延を予測する手法(提案手法)を構築する。

4.1 提案手法におけるLSTMの入出力

(1) 先行列車と後続列車の判定方法

これまでの文献[1][2]の予測手法では、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、実績ダイヤをベースとした判定方法による先行列車と列車の違いを図3と図4に示す。駅Gにおいて、計画ダイヤベースでの(先行列車, 後続列車) = (列車3, 列車7)となるが、実績ダイヤベースの場合は、列車の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。

(2) 入力データの異なるモデルの比較

列車種別毎LSTMへの適切な入力の評価をするため、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と呼ぶ)
- 予測対象列車の発遅延と着遅延 (以下、モデル3と呼ぶ)
- 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と呼ぶ)
- 予測対象列車の発遅延と乗車率 (以下、モデル5と呼ぶ)

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図5、図6に示す。モデル3では、




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

着時点と発時点での入出力が異なる。対象列車の発遅延 $d = (d_1, d_2, d_3, \dots)$ 、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) = $\{(a_1, d_1), (a_2, d_2), ((a_1, d_1), (a_2, d_2)), \dots\}$ となる。

なお、後述する予測精度評価試験においては、LSTMの出力する発遅延のみを基準に予測精度を比較する。

5. 予測精度評価試験

5.1 評価試験の概要

本評価試験では、列車種別毎にLSTMを構築する手法における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、NNを用い




図5 モデル3における駅発時点での入出力

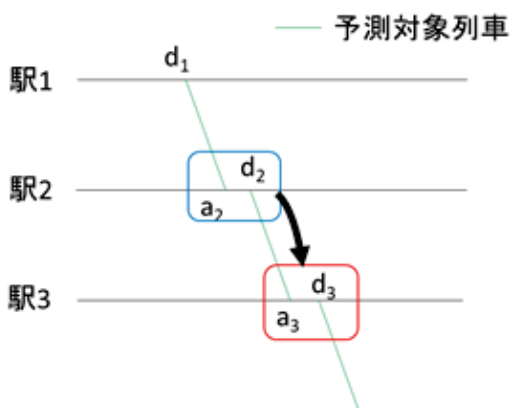


図6 モデル3における駅発時点での入出力

た予測手法(モデル1)と予測精度の比較を行う。併せて、前述した遅延量継続の場合と比較することにより、提案手法の有効性を検証する。

また、提案する予測手法では、各列車の各駅の着時点、発時点で予測が変化するため、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。本評価試験では、そのような個別の予測精度ではなく、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する。

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を活用した。そのうち70日分

を教師データ、残りの9日分を予測精度評価に用いた。

乗車率は、現状では全列車の各区間の乗車率を活用することが現実的でないことから、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]で構築したシステムをもとに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、出力されたデータを、この閾値で正規化の逆を行うことで、予測値を取得する。

5.4 各手法における学習方法

本評価試験では、提案する列車種別毎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。

列車種別毎LSTMのモデル2~モデル5については、活性化関数はReLUとし、学習はAdamによる最適化を行っており、学習誤差閾値0.001とする。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。モデル3における普通列車のLSTMについて、学習誤差(二乗平均平方根誤差)の変化を図7に示す。

NNについては、活性化関数はシグモイド関数、学習率0.01、訓練誤差閾値0.001とし、最大学習回数は列車種別LSTMと合わせ200回とした。

本評価に用いた各モデルの概要を表1に示す。

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、予測と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秒単位で予測誤差の絶対値の累積比率を確認した(表2)。

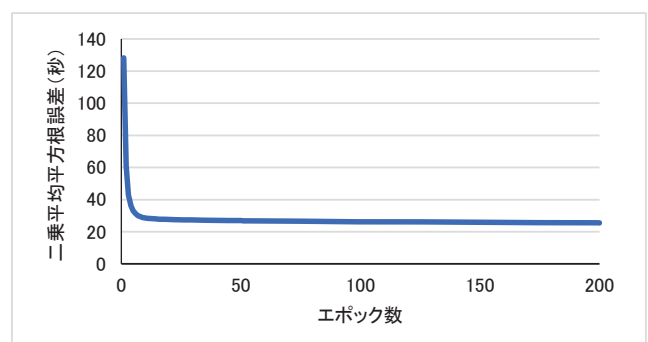


図7 学習誤差の変化

表 1 構築した各モデルの概要

手法	NN	LSTM(列車種別毎に構築)			
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
先行列車・後続列車の判定基準	計画ダイヤ	実績ダイヤ			
モデル名	モデル 1	モデル 2	モデル 3	モデル 4	モデル 5

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
5	22.14%	38.10%	38.88%	36.17%	38.11%
10	41.80%	57.48%	58.45%	56.20%	57.89%
15	58.67%	68.13%	69.49%	67.29%	69.45%
20	72.01%	75.51%	76.53%	74.76%	76.86%
25	80.39%	80.62%	81.23%	79.87%	81.41%
30	85.59%	84.59%	84.97%	83.59%	85.13%

その結果、モデル 2 からモデル 5 を比較した場合、累積比率に大きな差は見られなかった。したがって、LSTM の入力データの種類を変えても、精度はほぼ変化しないことを確認した。また、モデル 2 からモデル 5 の計算時間についても対象列車全ての学習時間は最大で 2 時間 55 分 (モデル 4) となり、実用に耐えうる計算時間となることを確認した。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 秒未満の予測誤差となる割合が 16 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 秒までの累積比率についても、モデル 3 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 より予測精度が高くなるケースも存在する。例えば、予測当日の遅延の傾向と、教師データの平均的な傾向が似ている場合は、NN の方が精度が高いケースが存在した。ある日における各駅停車の列車 1 の駅 9 着時点での予測 (駅 9~駅 2 まで) 結果を挙げる (図 8)。図 8 では実績遅延は黒色、教師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。この場合、モデル 1 の方が駅 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と




図 8 NN の方が精度が高かったケース

ら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 の場合の教師データは、列車 1 の駅 9 着時点に特化するため、過去の日の列車 1、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なるためと考えられる。

LSTM の方が NN より予測精度が高いケースについても一例を示す。例えば、ある駅で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挙げる (図 9)。図 9 では実績遅延は黒色、モデル 1 の予測が青色、モデル




図9 LSTMの方が精度が高かったケース




図10 遅延量継続の場合、1、モデル3の予測誤差の累積比率との比較

3の予測は赤色で示されている。駅6着時点での予測では、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、列車種別毎にLSTMを構築した予測モデルの中で予測誤差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の予測精度、遅延量継続の場合と比較した。結果を図10に示す。図10は、まず、(1)遅延量継続の場合の予測誤差の絶対値の累積比率、(2)モデル3の予測誤差の絶対値の累積比率、(3)モデル1の予測誤差の絶対値の累積比率を算出したうえで、(2)-(1)、および(3)-(1)により、遅延量継続の場合と比較した、予測誤差の改善度合いを示すものである。この結果から、モデル3については、予測誤差の絶対値が少ない時の累積比率が高いということがわかる。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。同様に、モデル1と比較しても、モデル3は全体として高い予測精度をもつと考えられる。

一方、図10から、モデル1に関しては、遅延量継続の場合と比較すると、30秒以上の予測誤差になる累積比率が高くなっている。また、モデル3とも比較した場合にも、30～60秒以内の予測誤差になることが多いことが確認でき

る。モデル1に関しては、教師データの平均化した傾向に合うように学習したため、結果として予測精度もモデル3ほどは高くないという結果になった可能性がある。

6. まとめと今後の展開

本研究では、列車種別毎に構築したLSTMを用いた列車遅延予測手法を提案した。さらに、提案した手法について、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、遅延の予測精度や学習に要する時間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種類とすることにより、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16ポイント程度増加し、精度が向上することを確認した。これに関し、列車種別STMを構築した列車遅延予測手法において、予測対象列車の着発を入力とする場合に最も予測精度が高かった理由について、今後詳細に分析したいと考えている。

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を評価、(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を構築、(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。

参考文献

- [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の直通路線への適用. 平成29年電気学会電子・情報・システム部門大会講演論文集, 2017, p. 1209-1213.
- [2] 辰井大祐, 中挾晃介, 國松武俊. Long Short Term Memoryを用いた列車遅延予測手法の構築. 第81回情報処理学会全国大会講演論文集(3), 2019, p. 41-42.
- [3] 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
- [4] 安部恵介, 荒屋真二. 最長径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, 1986, vol. 27, no. 1, p. 103-111.
- [5] 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), 2010, vol. 130, no. 4, p. 459-467
- [6] 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, 2014, vol. 51, p. 5
- [7] Xavier Chapuis. Arrival Time Prediction Using Neural Networks. proceedings of 7th International Conference on Railway Operations Modeling and Analysis, 2017.
- [8] Wenjia Wang, Gerard Parr, Douglas Graser. A feasibility study on developing an intelligence ensemble system for predicting and preventing train delays. 2019, project report of Data Sandbox launched by RSSB
- [9] 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. 電気学会電気鉄道研究会資料, 2012, vol.48, p. 23-28