

都市間高速道路の交通状態変化を考慮した LSTM による旅行時間予測手法

田子 裕亮¹・中西 雅一²・菅 芳樹³・西田 匡志⁴・山下 和彦⁵・日下部 貴彦⁶

¹正会員, 株式会社 地域未来研究所 (〒530-0003 大阪府大阪市北区堂島 1 丁目 5-17)

E-mail:tago@refrec.jp

²正会員, 株式会社 地域未来研究所 (〒530-0003 大阪府大阪市北区堂島 1 丁目 5-17)

³非会員, 株式会社 地域未来研究所 (〒530-0003 大阪府大阪市北区堂島 1 丁目 5-17)

⁴非会員, 中日本高速道路株式会社 八王子支社 (〒192-8648 東京都八王子市宇津木町 231)

⁵非会員, 中日本ハイウェイ・エンジニアリング東京株式会社

(〒160-0023 東京都新宿区西新宿 1 丁目 23-7)

⁶正会員, 東京大学 空間情報科学研究センター (〒277-8568 千葉県柏市柏の葉 5-1-5)

本研究では, 車両感知器等で計測された交通量や速度等のデータから, 数分先から数時間先までの旅行時間を予測する手法を構築した. 構築したモデルの特徴は, 区間流入・流出交通量と旅行時間変動の関係性を表現した交通流モデルをベースとし, そこに深層学習手法の一つである LSTM を組み入れた点である. 交通モデルにより単位時間後の旅行時間変動を現在の区間流入・流出交通量および旅行時間で表現した上で, 深層学習によりモデルの前提条件の緩和が及ぼす影響等を学習し, またデータドリブンな予測モデルとすることで, 精度を担保しつつも容易かつ柔軟なモデル構築が可能となることを意図している. 本手法を, 小仏トンネルなどのボトルネックが存在し, 休日の渋滞時には 100 分以上かかることもある中央自動車道上り約 35km の区間を対象として検証した結果, 旅行時間の変動が大きい渋滞発生時でも 4 時間先の予測旅行時間の精度は MAE (Mean Absolute Error) で約 15-20 分となり, 比較的良好な精度となっていることを確認した.

Key Words: 旅行時間予測, 深層学習, LSTM, 車両感知器

1. はじめに

近年, 高速道路などの道路交通分野でもセンシング技術の発達および蓄積により, 交通量・速度・旅行時間などのビッグデータと呼べる規模のデータが活用可能になっており, これらをより良い交通サービスの提供に有効活用できる手法の開発が求められている. 例えばある路線について, 現在から数時間先までの予測旅行時間を情報提供することができれば, 利用者により適切な経路選択および出発時刻選択を促し, 渋滞の緩和に繋がることを期待できる. これまでも NEXCO 中日本ではお盆などの交通混雑期に渋滞予測を提供しているが, これは過去 3 年間に発生した渋滞実績を, 直近の交通動向や道路状況の変化によって経験をもとに人為的に補正することで行われていた. この予測に蓄積データを活用できれば, より効率的に即時性の高い予測が可能となり, サービスの向上が期待できる.

将来の旅行時間の予測手法はこれまでに多くのモデルが提案されており, 大別すると, 交通シミュ

レーションを用いるアプローチと, 過去のデータに基づく統計的なアプローチが存在する. 交通シミュレーションを用いるアプローチは現実の交通状態を表現するモデルを用いて模擬的に将来の状態を再現するものである. 交通状態の特性や因果関係を明示的に扱うことができる一方で, 精緻な予測を行うには多くのパラメータを外生的に与えることが求められ, キャリブレーションの困難さが課題となる. 対して後者の手法は過去のデータから入力値と出力値の関係を直接的に表現するモデルを構築し, これに現在の状態を入力して予測を行うものである. 特に深層学習を用いたアプローチは, 近年の計算機科学の発展に伴い注目されている. 深層学習にも様々な手法が存在し, 現在と似た過去の交通状況をパターンマッチングする方法¹などがあるが, ここで交通流の性質をより表現できるようなモデルを構築することができれば, 根拠を持ってモデルを解釈し, 改良も行いやすくなることを期待できる.

本研究では, 旅行時間予測手法として深層学習を用いたモデルを提案する. データドリブンにすることで汎用的で扱いやすいモデルとしつつ, ベースに

交通流モデルの考え方をを用いることで解釈・改良が行いやすくなることを意図している。深層学習モデルには LSTM (Long Short-Term Memory)²⁾を用いる。交通状態は時間方向の依存性を持っているが、LSTM は深層学習の中でもそのような時系列データの予測に適しているモデルである。また、予測値を利用者への情報提供に活用することを想定した場合、予測対象とする時点は将来の一時点のみではなく、選択肢として数時間にわたる複数時点の予測値があることが望ましいが、このように連続した時間の予測が可能であるという面からも LSTM は目的に合致している。

2. 既往研究

小川ら³⁾は、LSTM を用いて鎌倉市の観光交通を対象とした 60 分後の交通量予測を行っている。観光交通は通勤や通学による定常的な利用と異なり天気や季節などの特性を包括的に考慮する必要があるが、これに対するアプローチとして入力を多変量とし、降水量やイベントデータも入れることで、複数の要因による交通量の変化を予測できるモデルとなっている。

寺前ら⁴⁾は、阪神高速道路に設置された車両検知器で取得された 5 分間車両台数、時間占有率などのデータから、GCN (Graph Convolutional Networks) を用いて 10 分後の渋滞発生を予測するモデルを構築している。GCN は高速道路のようなグラフ状の接続関係を表現できる深層学習モデルであり、分合流における路線の相互影響を考慮できるモデルとなっている。

実務では NEXCO 東日本と NTT ドコモが 2018 年より「高速道路 AI 渋滞予知」として東京湾アクアラインや関越道などの一部路線について、当日午後から 30 分毎の通過所要時間を Web で提供している。寺田ら⁵⁾によると、これにはドコモの携帯電話ネットワークの運用データから統計的に算出された人口分布を元として、将来の交通需要や渋滞の発生時刻を予測する AI モデルが用いられている。

本研究では、キャリブレーションのしやすさやモデルの解釈性の観点から、交通流モデルの特徴をとらえた旅行時間予測方法論を構築することが要件になる。この観点で各既往研究を見ると、小川らの研究は交通状態を明示的に構造内に持つモデルではないため、渋滞の発生有無などは予測交通量から推定することとなり、旅行時間予測に用いるのは難しい。寺前らの手法は、渋滞の発生有無を予測する二値分類モデルであり、具体的な所要時間および数時間先の予測は行われていない。寺田らの研究で用いられているデータは 10 分毎の 250-500m メッシュの人口分布であり、直接旅行時間を観測できるわけではないため、交通流として表現することが難しい。

交通流モデルをベースとした機械学習のアプローチとして、日下部ら⁶⁾の研究が挙げられる。日下部らは Wei ら⁷⁾の構築した、道路区間におけるボトル

ネックの性質に基づいた旅行時間予測モデルをベースとした機械学習モデルを構築している。Wei らのモデルでは、「区間中にボトルネックは 1 つである」「ボトルネック容量が一定である」などの前提条件の下で、ドライバーが渋滞区間に到達するまでの渋滞の延伸・収縮の状態変化を考慮することで予測を行っている。このモデルの特長として、非渋滞時の速度など容易に取得可能なものを除き外生的に与えるパラメータが不要であることが挙げられる。一方で前述の前提条件から、ある程度の長さを持った一般の道路区間への適用が難しいという課題がある。日下部らはこのモデルの考え方をもとに、機械学習の 1 つであるランダムフォレストを用いた旅行時間の短期予測手法を構築している。Wei らのモデルが持つ課題に対し、前提条件を緩和することで生じる旅行時間の増減の非線形性や非連続性を学習させることで、交通流の性質を考慮しつつも適用可能範囲を広げたモデルとなっている。一方で、ITT (Institutional Travel Time, 瞬間旅行時間)、つまり現在の小区間毎の所要時間の総和が既知であることを前提とし、ITT からの差異として所要時間を予測しているため、現時点で区間上流端を通過した車両が経験する旅行時間を推定するモデルとなっており、数時間先などの旅行時間は直接予測できない。

これらの既往研究を踏まえ、本研究では日下部らのアプローチを参考に、Wei らのモデルの考え方に LSTM を組み入れることで、車両検知器などで取得可能なデータを入力として、数時間先までにわたる複数時点の旅行時間予測が可能なモデルを構築することを試みる。

3. モデル

(1) 概要

まず、本研究におけるモデルの予測フローを図-1 に示す。本モデルは「需要予測モデル」および「交通状況予測モデル」の 2 つの LSTM モデルを組み合わせる形となっている。組み合わせた総合的なモデ

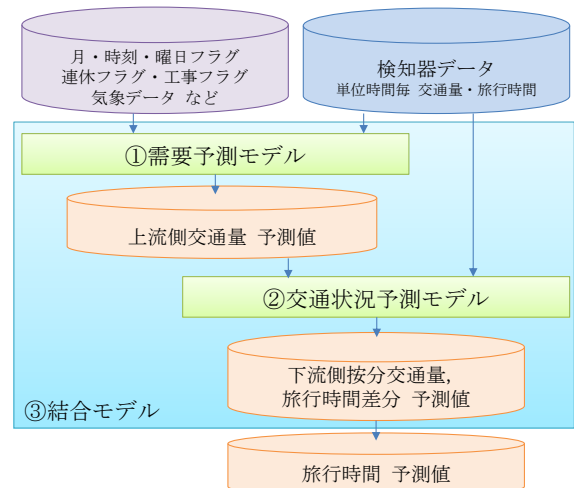


図-1 提案モデルの予測フロー




図-2 基本モデルの想定する交通状態の模式図




図-3 渋滞長と流入出交通量の関係

を説明上「結合モデル」と称する。先に交通状況予測モデルについて説明する。交通状況予測モデルは本章(2)節にて後述する交通流に関する基本モデルの考え方をういたモデルである。基本モデルは上流側・下流側交通量と旅行時間の関係性を表すものであるため、この関係性を LSTM で学習させ旅行時間を予測するモデルとなる。ただし将来の旅行時間予測を行うには、上流側・下流側交通量の将来値が必要となる。下流側交通量は現在の交通状況に大きく依存するため交通状況予測モデルで同時に予測できると考えられるが、上流側交通量は区間外のような要因に影響を受けるため、これを別に予測するモデルが必要となる。これが需要予測モデルであり、曜日・時刻や降水量などの入力から上流側交通量を予測するモデルとなる。

このように、交通状況予測モデルでは基本モデルをベースとすることによって理論的根拠のある方法で旅行時間が予測可能となる。一方で変動要因の異なる上流側交通量は別のモデルに分け個々に予測することで、結果を解釈しやすくなり、また独立にモデルを改良できるなど柔軟な運用が行いやすくなると考えられる。

(2) 基本モデル

本節では、交通状況予測モデルのベースとなる、交通状態と旅行時間の関係についての基本モデルを決定する。基本モデルは解釈の容易なものとするため、単純な道路構造を仮定する。具体的には、Wei

らのモデルのように、以下の前提条件を仮定している。

- ① 区間中にボトルネックは1つである
- ② ボトルネック容量が一定である
- ③ 区間途中に流入出がない
- ④ 自由流区間と渋滞流区間の速度がそれぞれ安定している

①～④の仮定を元に、車両感知器で観測可能な交通量や速度データから、交通量と区間に流入する車両が経験する旅行時間の関係性を記述するモデルを説明する。変数として、予測を行う単位ステップ時間を Δt 、時刻 t_1 から t_2 の間に上流端を通過した交通量を $q_u(t_1, t_2)$ 、同下流端を通過した交通量を $q_d(t_1, t_2)$ とする。時刻 t に上流端を通過した車両が経験する旅行時間を $T(t)$ とする。また、渋滞区間のボトルネック容量を C で既知とする。上記の変数を模式的に表した図を図-2 に示す。

ここで、旅行時間 $T(t)$ と $T(t + \Delta t)$ の差分について考える。

$$G(t, t + \Delta t) = T(t + \Delta t) - T(t) \quad (1)$$

渋滞時には、自由流速度と渋滞流速度が一定であるという仮定の下で、旅行時間は渋滞長に比例するため、 $G(\cdot)$ は時刻 t に上流側を通過した車両と $t + \Delta t$ に通過した車両が経験する渋滞長の差分に比例する。この差分は t から $t + \Delta t$ にかけての流入交通量 $q_u(t, t + \Delta t)$ および流出交通量 $\Delta t \cdot C$ の関係性によって表現できる。相対的に前者が大きければ渋滞は延伸局面にあり、後者が大きければ解消局面にある。この関係性を図-3 に示す。渋滞時の旅行時間の増減は以下で表現できる。

$$G(t, t + \Delta t) \propto q_u(t, t + \Delta t) - \Delta t \cdot C \quad (2)$$

式(2)に示すように、 $G(\cdot)$ は流入交通量 $q_u(\cdot)$ と流出交通量 $\Delta t \cdot C$ の差分に比例する値として表すことができる。ここで、ボトルネック容量 C は渋滞時のボトルネック直下流の交通量を計測することにより得られる。したがって、①～④の仮定が満たされる区間では、上流部およびボトルネック直下の交通量の蓄積データが存在すれば、データに基づいて旅行時間の差分を求めることが可能である。

(3) 予測モデルに適用する Neural Network

基本モデルでは単純化のため道路区間に前提条件を仮定したが、一般的な道路状況では必ずしも先述の前提は保証されず、区間中にボトルネックが複数ある、途中で流入出がある、ボトルネック容量が変化するという状況が想定される。前提条件が満たされないことによって生じる基本モデルと実際の旅行時間との差異は、現在の交通状況に対して非連続的かつ非線形の関係となると想定されることから、単純な回帰式で表現することは困難となる。そこで、差異を含めた現在の交通状態と旅行時間の関係を過去の蓄積データから学習することができれば、前提条件を満たさない区間にも基本モデルの考え方が適




図-4 LSTMモデルの概略

用可能となると考えられる。

前節の基本モデルの仮定を緩和したモデルを考える。仮定の緩和により直接的に表現することが難しくなった交通状態を蓄積データから求めるアプローチとして、LSTMによる学習を行う。LSTMはRNN(Recurrent Neural Network)の一種であり、過去の連続した時系列データを入力とすることが可能なため、時間方向に依存性を持つ交通状況予測に適している。またRNNは学習ステップ数の増加に伴い勾配が消失する問題が指摘されているが、LSTMはそれを解消したモデルである。モデルの概略を図-4に示す。ループ構造が備わっているため、ある時点 t のブロックは同時刻の入力 x_t と一時刻前の隠れ層の出力 h_{t-1} から信号を受け取り、 h_t を出力する。最終的な h_t を出力層に通すことで、予測値 y_t が得られる。LSTMブロックの内部にはメモリーセルと呼ばれる過去の情報を保持する機構があり、これが過去から現在に至るまでの状態を保持することで、時系列的な予測を精度良く行うことが可能となる。 x_t は特徴量(入力変数)の個数分の長さを持つベクトルであり、全時刻にわたる入力 $x = (x_1, x_2, \dots, x_t)$ は2次元テンソルで表現される時系列データである。

なお図-4に示すような単純なLSTMにより予測されるのは、与えた入力時系列の末尾時点における結果 y_t のみである。しかし本研究ではドライバーへの情報提供を目的の1つとするため、数時間先までの予測を行えることが望ましい。ここで、LSTMでは1つ前の予測値を次の入力として逐次的に予測を行うことが可能であるため、これを繰り返すことで所定の時間 L にわたり、時刻 t から $t+L$ までの Δt 周期の予測値を出力するものとした。なお予測単位時間 Δt は、道路利用者が認識できる時間単位を想定し、両モデルで5分と設定した。

LSTMモデルの入力としては、予測開始時点から遡って所定の長さの過去データを与える必要がある。加えて逐次的な将来予測を行うには、予測対象以外の特徴量について予測時間 L にわたる将来データを与える必要があるため、将来の値の入手可能性を考慮しなければならない。

(4) 需要予測モデル

需要予測モデルは、将来の上流側交通量を予測するLSTMモデルである。入力値としては上流側交通量の過去データに加え、需要に影響を与えると想定されるカレンダーデータおよび降水量データのそれぞれ過去・将来データを与えることとした。カレンダーデータは、月・時刻・曜日の時節変動を表すデータと、集中工事期間や長期休暇などの特異日であることを示すフラグデータからなる。なお、入出力



図-5 対象区間(中央道上り大月IC~八王子JCT)

に用いた具体的なデータの内容は4(2)節にて説明する。

(5) 交通状況予測モデル

基本モデルは流入交通量 $q_u(t + \Delta t)$ 、ボトルネック容量 C によって定義されるものであった。ここで、 C に関しては蓄積データの下流部の交通量 $q_d(t + T(t), t + \Delta t + T(t + \Delta t))$ から求められるため、 C を直接計算する代わりにこれをLSTMモデルへの入力とし、上流側交通量 q_u および下流側交通量 q_d から旅行時間差分を求めるモデルとすることができると考えられる。ただし、下流側交通量は時刻 $t, t + \Delta t$ のそれぞれに上流端を通過した車両の下流端通過時刻間の交通量を用いるため、車両感知器の計測データからそれぞれの旅行時間を考慮して再集計が必要となる。これによって再集計された下流側交通量を、下流側按分交通量 q'_d とする。したがって交通状況予測モデルの入力は、下流側按分交通量、旅行時間差分の過去データと、上流側交通量の過去・将来データとなる。

4. データ

(1) 対象路線と期間

本研究では、図-5に示すように、中央道上り線小仏トンネル付近を含む、大月IC~八王子JCTの約35km区間を対象として旅行時間予測の検証を行う。当区間は特に休日の午後に渋滞が発生しやすい箇所であり、非渋滞時の通過所要時間は25分程度だが、渋滞発生時には100分を超えることもある。データ期間は、2017年1月1日~2019年12月31日の1095日間を対象とした。

(2) 使用データ

a) 交通量・旅行時間

対象区間にはおよそ1~2km間隔で車両感知器が設置されており、交通量、速度などのデータが定期的に取得されている。本研究では上流側交通量として最上流地点の感知器の5分間交通量、下流側交通量として最下流地点の感知器の5分間交通量を用いた。次に、タイムスライス法を用いて各時刻に上流端を通過した車両の下流端までの所要時間を算出し、これを旅行時間の真値として扱うこととした。

b) 降水量データ

需要予測モデルへの入力として、気象庁より1時間単位の降水量データを取得した。一般に旅行計画を立てる際、道中よりも目的地の天候情報がより重

要視されると考えられることから、本研究では東京の1時間降水量を用いた。

c) カレンダーデータ

需要予測モデルへの入力として、交通需要は1年および1日を周期として同様の状態が再現されやすいため、月および時刻を入力に採用した。また曜日の情報として、該当する曜日のみ”1”が立てられた7種類の曜日フラグを採用した。なお休日は日曜日扱いとした。

また、特異日を示すフラグデータを整理した。今回の対象期間では計4回の集中工事が実施され交通規制が行われており、工事期間に集中工事フラグを設定した。さらに、年末年始・GW・お盆・SWの長期休暇には例年NEXCO中日本が渋滞予測を公表しており、これらの期間は通常よりも混雑しやすいと考えられるため、長期休暇フラグを設定した。

なお、時刻など周期性のあるデータでは、そのままの値を使うと23:55と0:00などの実際には連続している値が数値上乖離してしまう問題がある。よって本研究では月と時刻のデータについて、1周期を2次元座標上の単位円1周に当てはめ、その位置をx,yの2変数で表現することでこの問題を回避した。

d) 事故イベントデータ

事故による渋滞は突発的なものであり、交通量などから説明できるものではなく現時点では予測不可能と考えられる。したがって訓練データおよび検証データから除外するため、交通管制データから、当該区間内で事故が発生していた日時を整理した。

5. 個別モデルの予測性能

(1) 概要

先に述べたとおり、提案モデルでは需要予測モデルと交通状況予測モデルの2つのLSTMモデルを組み合わせて旅行時間を予測する。それぞれのモデルの予測性能の向上が、全体の予測性能の向上に繋がると考えられる。したがって、まず各モデルについて適切な設定を検討することとした。具体的には後述する複数の入力パターンを設定し、これらについてモデル学習を行い、その精度を確認・比較した。

(2) 入力パターン

LSTMをはじめとする深層学習では、モデル自体で最適化することができず、モデル作成者があらかじめ設定する必要のある項目があり、入力時間長、予測時間長、特徴量の選択、ハイパーパラメータなどがこれに該当する。本検証で試行した主な入力パターンを表-1および表-2に示す。

a) 入力時間長

入力時間長とは訓練時および予測時に入力として与える過去の時系列データの長さを指し、現在の交通状況がどの程度前の状況から影響を受けているとするかの設定となる。長くすればより以前の交通状況を勘案できる一方、データを欠損無く揃えること

が難しくなり、また長すぎると予測性能を低下させる原因ともなる。需要予測モデルでは2時間、6時間、12時間の3パターンを試行した。本検証の時間単位は5分のため、これらはそれぞれ24, 72, 144レコードの時系列データとなる。交通状況予測モデルでは、車両が対象区間を通過する所要時間があれば十分と考えられるため、2時間と設定した。

b) 予測時間長

予測時間長は、モデルが予測結果として出力する時系列データの長さを指す。訓練時にはこの誤差を最小化するように調整されるため、長く設定すればより将来の交通状況の予測にも適合したモデルとなる一方、直近の将来の精度が低下する恐れがあり、バランスの取れた調整が重要となる。ここでは需要予測モデル、交通状況予測モデルとも3時間、6時間の2パターンを試行した。これらはそれぞれ36, 72レコードの時系列データとなる。

c) 特徴量

需要予測モデルでは表-1に示す通り、上流側交通量、降水量、カレンダーデータを入力とした。また、将来交通量はそれまでの累積交通量に影響を受ける傾向があり、これを特徴量に加えることで入力時間超が短くても十分な予測性能を得られる可能性があるため、その日の午前4:00からの累積交通量を特徴量に加えた上で入力時間長を2時間とするパターン(表-1⑦⑧)も考慮した。

交通状況予測モデルでは表-2に示す通り、基本モデルに従い上流側交通量、下流側按分交通量および旅行時間差分を特徴量とした。

d) ハイパーパラメータ

隠れ層の数やユニット数などのハイパーパラメータに関しては、両モデルとも固定値で検証を行った。隠れ層数は1、LSTMユニット数は64、学習率は0.001、バッチサイズは300と設定した。損失関数はMSE (Mean Squared Error)を採用した。y_iは真値、ŷ_iは予測値を表している。

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3)$$

表-1 需要予測モデルの入力パターン

種類	内容	入力パターン								
		①	②	③	④	⑤	⑥	⑦	⑧	
入力時間長	2時間	○	○						○	○
	6時間			○						
	12時間					○	○			
予測時間長	3時間	○		○		○		○		○
	6時間		○		○		○		○	○
特徴量	累積交通量								○	○
	共通：上流側交通量、月、時刻、曜日フラグ、集中工事フラグ、長期休暇フラグ、降水量									

表-2 交通状況予測モデルの入力パターン

種類	内容	入力パターン	
		①	②
入力時間長	2時間	○	○
予測時間長	3時間	○	
	6時間		○
特徴量	上流側交通量	○	○
	下流側按分交通量	○	○
	旅行時間差分	○	○

表-3 需要予測モデルのデータセット数

入力パターン	訓練用データセット数			検証用データセット数		
	クレンジング		残存率	クレンジング		残存率
	前	後		前	後	
①	210,180	200,242	95.3%	105,060	97,535	92.8%
②	210,144	195,803	93.2%	105,024	95,118	90.6%
③	210,132	194,351	92.5%	105,012	94,337	89.8%
④	210,096	189,999	90.4%	104,976	91,997	87.6%
⑤	210,060	185,701	88.4%	104,940	89,659	85.4%
⑥	210,024	181,440	86.4%	104,904	87,401	83.3%
⑦	210,180	200,242	95.3%	105,060	97,535	92.8%
⑧	210,144	195,803	93.2%	105,024	95,118	90.6%

表-4 交通状況予測モデルのデータセット数

入力パターン	訓練用データセット数			検証用データセット数		
	クレンジング		残存率	クレンジング		残存率
	前	後		前	後	
①	210,180	197,733	94.1%	105,060	94,560	90.0%
②	210,144	192,687	91.7%	105,024	91,539	87.2%

(3) 学習用データの加工

a) データセットの分割

一般に深層学習の精度検証では未知のデータに対する汎化性能を評価するため、モデルの訓練に用いたデータとは異なるデータを用いる必要がある。本検証では、学習用データのうち 2017-01-01~2018-12-31 を訓練用データ、2019-01-01~2019-12-31 を検証用データとした。

また、訓練用データから評価データを切り出した。評価データはニューラルネットワークの重みの計算には使用されず、学習中の性能評価や過学習の防止などを行うためのデータである。一般には訓練用データの末尾数%を充てることが多いが、本検証では渋滞時における予測性能を重視するため、評価データに一定数の渋滞時データが含まれるよう、訓練用データを渋滞時と非渋滞時に分割しそれぞれの末尾5%を評価データとした。

b) データクレンジング

入力および予測対象の時系列データ中に事故による渋滞や、機器の不具合によるデータ欠損が含まれるデータを除外した。突発的な事故の予知はまず不可能であり、それにより変化した交通状況は予測性能の評価に適切でないと考えられるためである。入力パターン毎のクレンジング前後のデータセット数を表-3、表-4に示す。ここでデータセットとは、入力時間長と予測時間長の合計時間分だけ連続した一連の時系列データを示す。

(4) 予測性能の評価方法

本研究の提案モデルは、現在から数時間先までの連続した時系列を予測する。ただし予測開始時点から時間が経過するにつれ予測は難しくなり、誤差は大きくなる傾向にある。直近の精度と6時間後の精度を同一に扱うことは適切ではないと考えられるた

表-5 需要予測モデルの経過時間毎の誤差評価値 (全体評価)

入力パターン	MAE [台/5分]			MAPE [%]		
	1時間後	3時間後	6時間後	1時間後	3時間後	6時間後
	①	11.30	13.15	-	15.76	17.85
②	11.43	12.99	14.00	16.17	17.79	18.65
③	11.78	13.45	-	16.18	18.00	-
④	11.56	13.06	14.05	16.12	17.60	18.60
⑤	12.30	13.93	-	16.72	18.49	-
⑥	12.17	13.69	14.53	17.36	18.89	20.14
⑦	11.50	13.77	-	15.66	18.50	-
⑧	11.36	12.85	13.69	15.54	16.91	17.56

表-6 需要予測モデルの経過時間毎の誤差評価値 (渋滞時評価)

入力パターン	MAE [台/5分]			MAPE [%]		
	1時間後	3時間後	6時間後	1時間後	3時間後	6時間後
	①	23.39	28.58	-	14.43	18.30
②	24.17	27.99	30.10	15.46	17.08	18.94
③	26.26	29.79	-	15.86	18.93	-
④	25.76	29.14	30.65	15.71	17.33	19.26
⑤	27.65	30.61	-	16.27	19.14	-
⑥	26.19	29.32	30.71	15.97	17.12	19.50
⑦	24.49	30.13	-	15.29	19.71	-
⑧	24.84	29.51	31.66	15.25	17.12	18.62

め、予測性能の評価は予測開始時点からの経過時間毎に行う。また、対象路線は週末に渋滞が頻発するものの総合的には非渋滞である時間が大半を占めるため、渋滞時の予測性能が希釈され見えづらい状態となる。したがって、結果は全体評価に加え、渋滞時を抽出したのもも確認する。

まず、予測開始から一定時間毎の誤差評価値を確認する。誤差評価値には、MAE (Mean Absolute Error) および MAPE (Mean Absolute Percentage Error) を使用した。\$y_i\$ は真値、\$\hat{y}_i\$ は予測値を表している。

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (4)$$

$$MAPE = \frac{100}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (5)$$

次に、恒常的に誤差が発生しているのか、特定のデータセットのみ大きい誤差が発生しているのかを確認するため、経過時間毎の誤差分布を確認する。最後に個別のデータセットについて真値と予測値の推移を時系列的に確認し、これらを総合的に勘案して評価を行う。

(5) 需要予測モデルの精度検証

予測開始から1, 3, 6時間後の全体・渋滞時それぞれの誤差評価値を表-5、表-6に示す。また、5分毎の誤差評価値のグラフを図-6~図-9に示す。結果を見ると、全体における経過3時間後の誤差は⑧(入力2時間 予測6時間 累積交通量あり)が最も少なく、MAEが12.85台、MAPEが16.91%となった。また、6時間後においても⑧でMAEが13.69台、MAPEが17.56%という精度で予測された。渋滞時における評価では全ての入力パターンでMAEが増加しているが、MAPEで比較すると全体と大きくは

変わらない精度で予測できていることがわかる。渋滞時の MAE は各入力パターンで大きな違いはないものの、経過 3 時間後では②（入力 2 時間予測 6 時

- ①入力2時間 予測3時間
- ②入力2時間 予測6時間
- ③入力6時間 予測3時間
- ④入力6時間 予測6時間
- ⑤入力12時間 予測3時間
- ⑥入力12時間 予測6時間
- ⑦入力2時間 予測3時間 累積交通量あり
- ⑧入力2時間 予測6時間 累積交通量あり

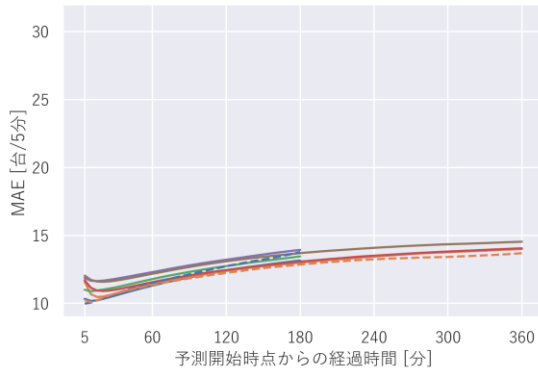


図-6 需要予測モデル MAE (全体)




図-7 需要予測モデル MAPE (全体)




図-8 需要予測モデル MAE (渋滞時)




図-9 需要予測モデル MAPE (渋滞時)

間) の 27.99 台が最も誤差の少ない結果となった。入力時間長で比較すると、12 時間とした⑤や⑥は全体評価で誤差が大きくなり、2 時間とした②や⑧の方が全体・渋滞時のいずれにおいても誤差指標値は良い結果となった。また予測時間長で比較すると、3 時間と長く設定した①③⑤⑦が必ずしも 6 時間と設定した②④⑥⑧より良い結果を示すとは限らず、渋滞時の経過 3 時間後の MAE が⑧の 29.51 台に対し⑦は 30.13 台と、悪化しているケースも見られた。

次に、経過時間毎の誤差分布を確認する。②および⑧の渋滞時の誤差分布を図-10、図-11に示す。これらの図では、経過時間毎に誤差の 1-99%ile を薄青、5-95%ile を青、25-75%ile を濃青、中央値を青の実線で示している。渋滞時で比較したところ、25-75%ile は時間経過に関わらず±10 台程度となり、




図-10 需要予測モデル 経過時間毎の誤差分布 (入力パターン② 渋滞時)

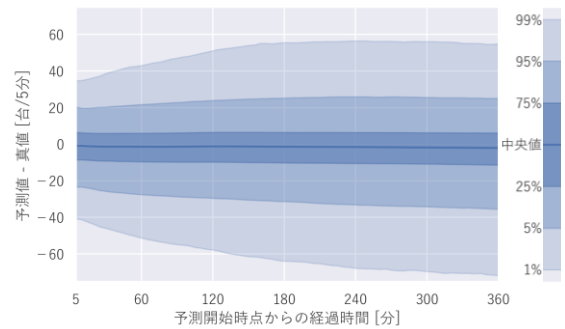


図-11 需要予測モデル 経過時間毎の誤差分布 (入力パターン⑧ 渋滞時)




図-12 需要予測モデル 推定結果の一例 (2019-09-29(日) 12:30)




図-13 需要予測モデル 推定結果の一例 (2019-08-11(日) 14:00)

表-7 交通状況予測モデル 経過時間毎の誤差評価値 (全体評価)

	MAE [分]			MAPE [%]		
	1時間後	3時間後	6時間後	1時間後	3時間後	6時間後
①	0.72	1.01	-	2.54	3.44	-
②	0.79	1.09	1.37	2.75	3.49	4.24

表-8 交通状況予測モデル 経過時間毎の誤差評価値 (渋滞時評価)

	MAE [分]			MAPE [%]		
	1時間後	3時間後	6時間後	1時間後	3時間後	6時間後
①	4.74	7.99	-	8.64	15.32	-
②	5.75	11.06	14.24	10.85	20.98	26.78

— ①予測3時間 渋滞時 - - - ①予測3時間 全体
— ②予測6時間 渋滞時 - - - ②予測6時間 全体




図-14 交通状況予測モデル MAE




図-15 交通状況予測モデル MAPE

入力パターンによって大きく変わらない結果となった。渋滞時の交通量は真値でも数十台の揺らぎが発生するため、これらに関しては概ね正しく予測できていると判断できる。5-95%ile では時間経過とともに誤差が増加し、3 時間後で±30 台程度となっている。最後に、需要予測モデルの推定結果の一例を図-12、図-13に示す。ここでは⑧の入力パターンで予測した結果を示している。図-12 では、対象路線における週末の午後からの交通量の増加をピーク時間帯、規模ともに精度良く一致させられている。一方図-13 は誤差の大きかった一例であるが、予測後の調べで 14:30 頃に対象区間より上流で事故が発生し車線規制が行われた結果、対象区間への流入が減少、その後規制解除に伴い増加していたことが明らかになった。このように突発的な事故に対しては予測が




図-16 交通状況予測モデル 経過時間毎の誤差分布 (入力パターン① 渋滞時)

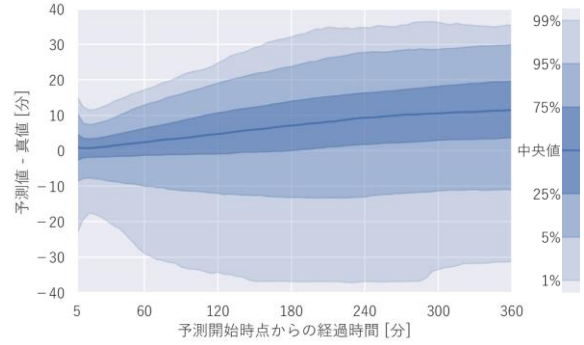


図-17 交通状況予測モデル 経過時間毎の誤差分布 (入力パターン② 渋滞時)

難しいことが示されたとともに、クレンジングの際には、区間の上流側や下流側の事故の影響の波及範囲を考慮して行う必要があることがわかる。

(6) 交通状況予測モデルの精度検証

交通状況予測モデルに関して旅行時間の予測性能を評価する。実際に運用するには需要予測モデルで予測された将来の上流側交通量を入力とするが、ここではモデル単体の予測性能を測るため真値を与えた上で結果を評価する。予測開始から 1, 3, 6 時間後の誤差評価値を表-7, 表-8 に示す。また、経過時間毎の誤差指標値を図-14 図-15 に示す。結果を見ると、全体評価では双方のパターンで 3 時間後の MAE が 1 分程度、MAPE も 5% 未満となっている。これは非渋滞時においては旅行時間がほぼ一定のため予測が当たりやすく、その非渋滞時が全体では大半を占めるためと考えられる。渋滞時では、① (予測 3 時間) が② (予測 6 時間) より良い結果となっており、より直近の予測に適合したモデルとなっていることがわかる。一方で②も 6 時間後の MAE が 14.24 分、MAPE が 26.78% となっており、6 時間先の予測としては十分な結果を示していると考えられる。次に、渋滞時における経過時間毎の旅行時間の誤差分布を図-16, 図-17 に示す。いずれも中央値が 0 より大きく、真値より旅行時間を過大評価した予測値が多かった。3 時間時点の精度を比較すると、①の 5-95%ile が±15 分の誤差に収まっているのに対し、②では+22- -15 分と相対的に大きい誤差となっている。一方で②も 6 時間経過後で 25-75%ile は 20 分以内、5-95%ile も 30 分以内に収まっているこ

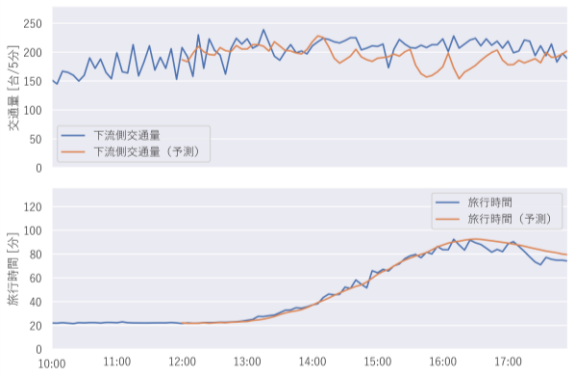


図-18 交通状況予測モデル推定結果の一例
(2019-06-09(日) 13:00)

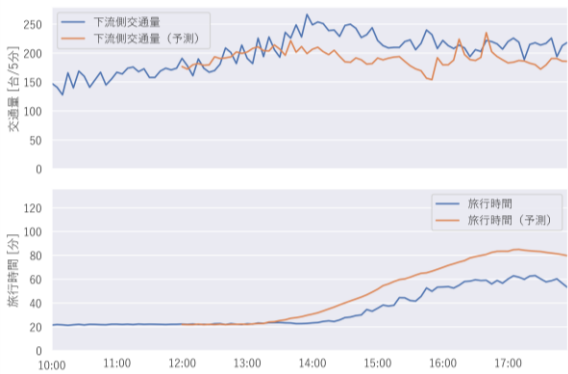


図-19 交通状況予測モデル推定結果の一例
(2019-07-07(日) 12:00)

とがわかる。最後に、個別の予測事例を確認する。
 図-18 の予測は夕方にかけて旅行時間が増加する時刻、規模ともに良好に予測できている。一方で図-19 のように、渋滞が起き始める時間を早く、渋滞規模を大きく予測してしまっている例も存在した。これは下流側交通量を過小に予測していることが原因の1つとして考えられる。

6. 結合モデルの予測性能

前章の2つのモデルにつき、単独の予測結果が良好であったパターンを組み合わせることで結合モデルを構築する。需要予測モデルは、短時間の入力でも長時間を予測できるという有用性も勘案し、⑧（入力2時間 予測6時間 累積交通量あり）を採用した。一方で交通状況予測モデルは予測時間長と予測性能がトレードオフの関係にあり、こちらは両パターンを用いて提案モデルでも試行し、結果を比較することとした（表-9）。

旅行時間予測結果の誤差指標値を表-10、表-11に、経過時間毎の誤差指標値を図-20、図-21に、誤差分布を図-22に示す。全体評価では、誤差が経過6時間後でも2分以内という結果となった。また、渋滞時評価では①と②の経過3時間後のMAEはそれぞれ13.48分、15.83分となった。その差は2.35であり、交通状況予測モデルではMAEがそれぞれ7.99分、11.06分でその差が3.07であったことから、予

表-9 結合モデルの入力パターン

種類	内容	入力パターン	
		①	②
入力時間長	2時間	○	○
予測時間長	3時間	○	○
	6時間		○

表-10 結合モデル 経過時間毎の誤差評価値
(全体評価)

	MAE [分]			MAPE [%]		
	1時間後	3時間後	6時間後	1時間後	3時間後	6時間後
①	0.75	1.32	-	2.59	4.16	-
②	0.83	1.41	1.94	2.83	4.27	5.86

表-11 結合モデル 経過時間毎の誤差評価値
(渋滞時評価)

	MAE [分]			MAPE [%]		
	1時間後	3時間後	6時間後	1時間後	3時間後	6時間後
①	5.58	13.48	-	10.24	24.82	-
②	6.24	15.83	21.02	11.61	28.85	38.84

— ①予測3時間 渋滞時 - - - ①予測3時間 全体
 — ②予測6時間 渋滞時 - - - ②予測6時間 全体




図-20 結合モデル MAE




図-21 結合モデル MAPE




図-22 結合モデル 経過時間毎の誤差分布
(入力パターン② 渋滞時)

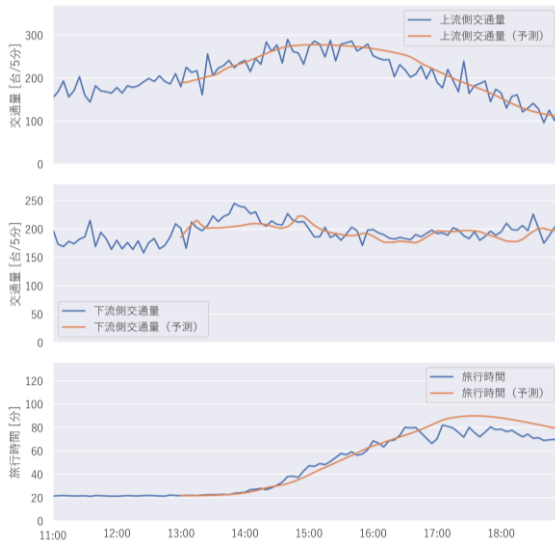


図-23 結合モデル推定結果の一例
(2019-03-24(日) 13:00)

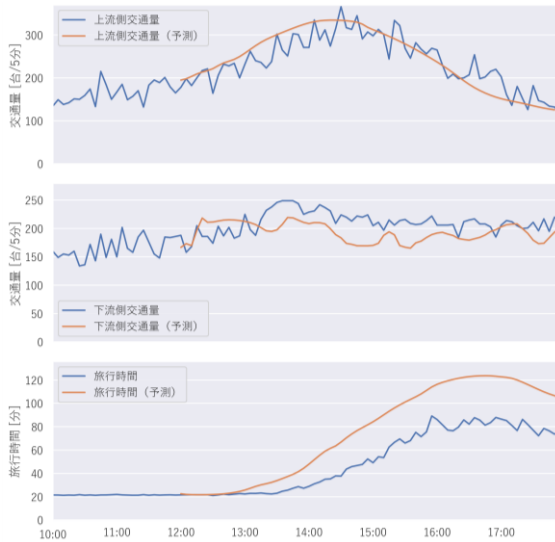


図-24 結合モデル推定結果の一例
(2019-06-02(日) 12:00)

測時間長を短くした①が②より良い結果を示す傾向は依然として存在するものの、その差は交通状況予測モデル単独より小さくなる結果となった。②の経過 6 時間後における MAE は 21.02 分、MAPE は 38.34% となり、やや誤差の大きい結果となっている。誤差分布では、②のモデルの 3 時間後の 25-75%ile が ±20 分に収まる結果となった。最後に予測結果の一例を図-23、図-24 に示す。いずれも②の入力パターンにより予測した例だが、図-23 では上流側交通量および下流側交通量の推移が精度良く予測され、それに伴い旅行時間も渋滞の立ち上がりおよびピークを概ね予測できた結果となった。一方、図-24 のように、渋滞規模がピーク時で約 40 分過大に予測されるような事例も存在した。上流側交通量は大幅に外していないものの絶対数が多い日であり、下流側交通量が若干過小に評価された結果と考えられるが、今後、このようなケースについても原因を究明し、改善を行っていく必要がある。

7. おわりに

(1) まとめ

本研究では、車両感知器や天候データから旅行時間を予測する手法を構築した。本手法の特長としては、交通量と旅行時間の関係性を考慮したモデル構造を元としているため結果の解釈や改良などがしやすい点、深層学習を用いることでデータドリブンなモデルとなりシミュレーションモデルなどと比較して外生的に与えるパラメータが少ない点、3-6 時間先までの連続した旅行時間を予測できる点が挙げられる。

このモデルを用いて小仏トンネルを含む中央自動車道上り大月 IC~八王子 JCT の約 35km の区間のデータを用いて検証を行った結果、渋滞時においても予測開始時点から 3 時間後の MAE が 13-16 分、6 時間後が 21 分となり、高い精度で予測できていることが示された。一方で、個別に見ると事故などのイレギュラーが発生した際の予測については大きく外している他、事故でない日でも一部で 40 分の誤差が発生していた。

(2) 今後の課題

今回の検証では各モデルの入力時間長などを中心に行い、LSTM モデルのハイパーパラメータチューニングを行っていないが、隠れ層数やブロック数などを調整することで精度が向上する可能性がある。また訓練データの期間や特徴量の選択などについても検討の余地を残している。

本手法をリアルタイムに運用する際の課題として、予測を行う時点では最新の downstream 交通量および旅行時間が確定していないため、モデルとして予測を開始できる時点は現在時刻より少し前となる点がある。この時刻の隔たりは旅行時間に依存するため、渋滞時には 1 時間以上前からの予測となることもあり、精度の低下が懸念される。これに対しては同時刻和旅行時間などの最新の交通状況を示す特徴量をモデルに与えることで精度向上できる可能性があり、今後、より実用性の向上に向けて研究を進める必要がある。

謝辞：本研究で用いられている予測手法は、東京大学の日下部氏、中日本ハイウェイ・エンジニアリング東京(株)の山下氏、山田氏、細江氏により、特許を取得しています。(特許第 7065246 号)

参考文献

- 1) 小倉大輝, 安田昌平, 井料隆雅, 向井梨紗: 時空間交通状態のパターンマッチングによる速度コンター図と旅行時間の短期予測, 交通工学論文集, 第 6 巻, 第 4 号 (特集号 A), pp.A_48-A_57, 2020.
- 2) Sepp Hochreiter, Jürgen Schmidhuber: Long Short-Term Memory, *Neural Computation*, Vol.9(8), pp.1735-1780, 1997.

- 3) 小川晃平, 福田大輔: 多変量 LSTM による短期交通量予測: 鎌倉市の観光交通を対象として, 土木計画学研究発表会講演集, Vol.61, CD-ROM, 2020.
- 4) 寺前智文, 向井梨紗, 鈴木健太郎, 小島悠紀子, 阿部敦: 機械学習を用いた阪神高速道路における交通渋滞予測精度向上に関する研究, 土木計画学研究発表会講演集, Vol.62, CD-ROM, 2020.
- 5) 寺田雅之, 赤塚裕人, 永田智大, 仲西哲志: 東京湾アクアラインの渋滞を「AI 渋滞予知」で回避する——携帯電話ネットワークの運用データの統計処理に基づく未来予測の試み——, NTT DOCOMO テクニカル・ジャーナル, Vol.27 No.2, pp.26–33, 2019.
- 6) 日下部貴彦, Qianjun CHEN, 柴崎亮介, 中川浩, 後藤誠: ランダムフォレストによるプローブカーデータからの旅行時間短期予測手法, 交通工学研究発表会論文集, Vol.40, pp.271–277, 2020.
- 7) Wei, C., Iryo, T., Asakura, Y.: Implementation of Short-Term Travel Time Prediction Model on Urban Expressway, International Journal of ITS Research, Vol.7 No.2, pp.101–108, 2009.

Travel Time Prediction using a LSTM Model Reflecting Traffic State Transition in Interurban Expressway

Yusuke TAGO, Masakazu NAKANISHI, Yoshiki SUGA, Tadashi NISHINO,
Kazuhiko YAMASHITA, Takahiko KUSAKABE

In this study, we propose a method to predict travel times after several minutes or hours by traffic volume, speed, and other data measured by traffic counters. The features of the model are basing on the traffic flow model that considers the relationship between sectional inflow/outflow traffic volume and travel time variation, and incorporating LSTM, a deep learning method, into the model. To learn impacts of relaxing assumptions of the traffic flow model by deep learning, and to be a data-driven model, will enable both assurance of prediction accuracy and easy and flexible model construction. We tested this method on a 35-km section of the Chuo Expressway, where bottlenecks such as the Kobotoke Tunnel exist and traffic congestion on holidays can take more than 100 minutes. As a result, it was confirmed that the method can predict travel times with good accuracy, with MAE (Mean Absolute Error) of approximately 15-20 minutes at 4 hours after the start of the prediction, even when traffic congestion causes large fluctuations in travel time.