

LSTMの枠組みによる交通量短期予測の検討： 鎌倉市中心部を事例として

小川 晃平¹・福田 大輔²

¹学生会員 東京工業大学修士課程 環境・社会理工学院（〒152-8552 東京都目黒区大岡山2-12-1）

E-mail: k.ogawa@plan.cv.titech.ac.jp

²正会員 東京工業大学准教授 環境・社会理工学院（〒152-8552 東京都目黒区大岡山2-12-1）

E-mail: fukuda@plan.cv.titech.ac.jp

近年、センシング技術の発展により膨大な交通情報を長期間でも容易に収集することが可能となった。蓄積されたビッグデータを基に将来予測を行うことはAIの典型的な活用事例であり、交通分野でも取り入れられ日々研究が進められている。

本研究では時系列データを処理することに適した深層学習モデルであるLSTMを活用し、鎌倉市中心部の交通量の短期予測を実施した。使用した交通量データは鎌倉市内に設置された感知器から得たものである。2017年の「中心部の断面交通量（60分単位）」、「中心部へ繋がる周辺部の断面交通量（60分刻み）」、「降水量」、「市内で開催されるイベントの有無」を入力データとして中心部の断面交通量を短期予測するモデルの学習を実施したところ、予測値と実測値の平均絶対パーセント誤差(MAPE)が6.85%、相関係数が0.96という結果が得られた。

Key Words : *deep learning, traffic volume prediction, long short-term memory*

1. はじめに

近年、センシング技術の発展により膨大な交通情報を長期間でも容易に収集することが可能となった。蓄積されたビッグデータを使用して将来予測を実施することはAIの典型的な活用事例であり、交通の分野でも日々研究が進められている。交通渋滞は交通需要がボトルネック交通量を超過することで生じる現象であり、その延伸や結合は時間・空間的に複雑となるため交通状態（渋滞）を予測することは容易ではない。そのため、交通状態が変化する予兆をいち早く検出する交通流動予測システムの確立が求められている。

本研究では、神奈川県鎌倉市中心部を対象として、交通渋滞緩和のための政策実施を想定した交通量短期予測に取り組む。交通量を予測する代表的手法である利用者均衡配分や交通シミュレーションなどでは、対象地の道路ネットワークデータやOD交通量など詳細な情報を準備する必要がある。道路ネットワークやOD表を構築すること自体は決して難しいものではないが、これらは時間的に不変のものではない。道路ネットワーク自体の変化は目まぐるしいものではないが、OD表等の交通インプット情報は曜日や季節の移り変わりと共に大きく

変化する。本研究の分析対象である鎌倉市を例に挙げると、市内に多く存在するあじさいの名所には開花時期の6月から7月上旬には例年多くの観光客が訪れる。鎌倉市に限らず一般に観光交通需要には大きな季節変動が存在するため、厳密に交通量を予測するためには曜日や季節ごとのOD表を多数構築する必要があるが、容易な作業ではない。

そこで本研究では分析手法として深層学習に着目する。本研究では、鎌倉市中心部における車両の時間的な集中度合いを短期で予測するための分析枠組みを構築する。経路・リンク交通量やエリア内の車両総旅行時間を短期予測するものではない。むしろ、観光交通需要の季節性、イベントの影響、降水量の影響等を考慮することで、短期の交通混雑予測の精度がどこまで向上しうるのかを明らかにすることを目的としている。深層学習は、入力されたデータを学習することでその特徴を包括的に考慮し、極めて詳細な予測を実施する。そのため上述の分析目的に適した手法だと考えられる。以上から、本研究では深層学習を用いて鎌倉市中心部の交通量の短期予測を行う枠組みを構築する。交通量などのデータは時間方向に強い依存性を持っていることから時系列データと呼ばれる。深層学習において時系列データの予測に適しているモデ

ルにはLong short-term memory (LSTM)¹⁾やGated recurrent unit (GRU)²⁾などがある。本研究ではこれらのモデルを活用し、鎌倉市中心部に位置する下馬の交通量、下馬に繋がる周辺部複数地点の交通量、降水量、市内で開催されるイベントの有無などを入力データとして、下馬の60分先の交通量を出力する。

2. 既往研究と本研究の位置づけ

(1) 既往研究

過去数年に渡り、深層学習を利用した交通状態の予測に関する研究が数多く行われていた。Fu et al.(2016)³⁾はカリフォルニアの都市高速道路に設置された固定感知器から5分ごとの通過交通量を取得し、自己回帰和分移動平均モデル(ARIMA)と深層学習モデルLSTM、GRUそれぞれを用いて予測を実施し、その精度を比較した。予測精度比較の指標には平均絶対誤差(MAE)と平均二乗誤差(MSE)が用いられ、GRUはARIMAよりも約10%、LSTMよりも約5%MAEが低いことが確認された。

Zhao et al. (2017)⁴⁾では同じくLSTMによって北京内の主要道路3地点の交通量が予測された。1時間あたりの交通量が約2,000台に達する地点で平均パーセント誤差(MAPE)が約6.41%という結果が算出された。

先に挙げた例は過去の交通量データのみを入力データとして予測を行うモデルであったが、降水量や曜日、時間帯などの要因が交通量の変化に影響を与えることは容易に想像できる。複数の入力から交通現状値を出力した例としてはKe et al.(2017)⁵⁾やXu et al.(2018)⁶⁾などがある。前者はFusion convolutional long short-term memory network (FCN-Net)という畳み込みLSTM層、LSTM層、CNN層を組み合わせた複数層モデルを提案し、交通需要、平均旅行時間、時間帯・曜日、天気の入力から交通需要を出力した。後者はLSTMを交通需要、天気、大気環境データ、土地利用データを入力として、交通需要を出力するステーションフリー自転車シェアのための交通需要予測モデルを提案した。推定の結果より入力データが交通需要単独の予測よりも複数データの入力による予測の方がMAPEが低下することが明らかとなった。

(2) 本研究の位置づけ

既往研究のレビューより、交通量の短期予測にはLSTMやGRUに代表される時系列学習モデルが適していることが示唆された。また先に述べたように、交通量の変動が大きい観光地を対象とした予測には季節性や時間帯、天気など交通情報以外の要因を考慮することが重要となる。そこで本研究では、Ke et al.(2017)およびXu et al.(2018)に倣い、LSTM、GRUそれぞれのモデル構造のも

とで多変量型の交通量短期予測モデルを提案する。使用するデータの期間に関して、学習に用いられるデータが数か月の場合では季節性やイベントなどが交通量の変化に与える影響を十分に捕捉できない可能性があるため、今回は1年間のデータを基に予測モデルの構築を行った。

3. 深層学習モデルによる交通量短期予測の詳細

(1) 分析対象

本研究の分析対象地は神奈川県鎌倉市中心部である。鎌倉市は年間の入込観光客数が2,000万人を超える人気観光都市で、四方を海と山に囲まれる閉鎖的な地形から侵入口が限定されてしまい、深刻な交通混雑が発生している。混雑の緩和には計画的な道路規制や混雑課金等の政策実施が必要であり、本研究ではその前段階としての道路状況の分析として、市内中心部の交通量短期予測に取り組む。予測対象は鎌倉市を縦断する横浜鎌倉線下馬の下り車線交通量、上り車線交通量、両者を合計した交通量である。

なお予測精度の評価には式(3a)、(3b)に示す二乗平均平方根誤差(RMSE)と平均絶対パーセント誤差(MAPE)を用いることとした。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{obs,i} - y_{pred,i})^2} \quad (3a)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_{obs,i} - y_{pred,i}|}{y_{obs,i}} \quad (3b)$$

(2) データ概要

a) 交通量データ

日本道路情報センター(JARTIC)から図-1に示す12地点の交通量データを取得した。このエリアでは現在、路上カメラによる道路状況の撮影が行われており、将来的には映像解析による交通データが入手可能とされているが、今回の分析では固定感知器による交通量データを使用する。データ期間は2017年1月1日から12月31日である。交通量は5分刻みで記録されていたが、今回は60分間隔での分析を実施するため、交通量の時間間隔を60分に変更しデータセットを作成した。また当初は24時間分の交通量データを使用する予定であったが、1日の中で比較的交通量が少い深夜や早朝の時間帯を入力データとする必要がないと考え、0時から5時、23時から24時のデータを削除し、1日を17時間周期とする交通量データを学習に使用した。



図-1 交通量データ取得地点

b) 降水量データ

鎌倉市の降水量データを気象庁より取得する予定であったがデータ取得地点に鎌倉市が含まれていなかったため、隣接する三浦市の降水量データを代替とした。データ期間は2017年1月1日から12月31日までで、1時間ごとの降水量が計測されている。

c) 鎌倉市イベントデータ

鎌倉市観光課に問い合わせたところ、表-1に示すイベントが来訪者が特に多いという回答を得たので、交通量に影響を及ぼすと判断し分析に取り入れることとした。

(3) 交通量短期予測のための代表的な深層学習モデル

交通量などの時系列データを分析することに適した深層学習モデルの代表例⁷⁾にはLSTMとGRUがある。

a) LSTM

LSTMはRecurrent neural network (RNN) が抱える勾配消失問題を解消した高次モデルであり、モデルの全体構造は図-2のようになる。隠れ層にはループ構造が備わっており、過去の情報を適切なタイミングまで保持して次の層へ伝播する仕組みである。ゆえにある時点 t の隠れ層 $h(t)$

は同時刻の入力層 $x(t)$ と一時刻前の隠れ層 $h(t-1)$ から信号を受け取ることとなる。なお保持する過去の情報量は自由に設定することができる。隠れ層内には図-3に示すLSTMブロックが設置されており、このブロックはメモリーセル、入力ゲート、出力ゲート、忘却ゲートで構成されている。式(3c)はメモリーセルの値、式(3d)は入力ゲートの値、式(3e)は出力ゲートの値、式(3f)は忘却ゲートの値、式(3g)は活性化された値、 U は入力層と隠れ層間の重み、 M は隠れ層間の重み、 N は隠れ層と出力層間の重み、 f, g は活性化関数、 b はバイアスペクトル、 \odot はアダマール積をそれぞれ表している。これらの装置には過去の信号をネットワーク内に保持する、保持した信号を必要なタイミングで次の層へ伝播させる、学習が完了し必要なくなった信号を消去するまでの役割が備わっている。これにより長期・短期の時系列データに対して効率よく学習を行うことが可能となった。

$$c(t) = i(t) \odot a(t) + f(t) \odot c(t-1) \quad (3c)$$

$$i(t) = \sigma(W_i x(t) + U_i h(t-1) + V_i c(t-1) + b_i) \quad (3d)$$

$$o(t) = \sigma(W_o x(t) + U_o h(t-1) + V_o c(t) + b_o) \quad (3e)$$

$$f(t) = \sigma(W_f x(t) + U_f h(t-1) + V_f c(t-1) + b_f) \quad (3f)$$

$$a(t) = f(W_a x(t) + U_a h(t-1) + b_a) \quad (3g)$$

表-1 人気イベントスケジュール(2017)

イベント名	開催期間
かまくらまつりパレード	4月9日～16日
大船祭り	5月21日
鎌倉花火大会	7月19日
あじさい祭り	6月中旬～7月上旬
大船 to 大船渡	9月24日

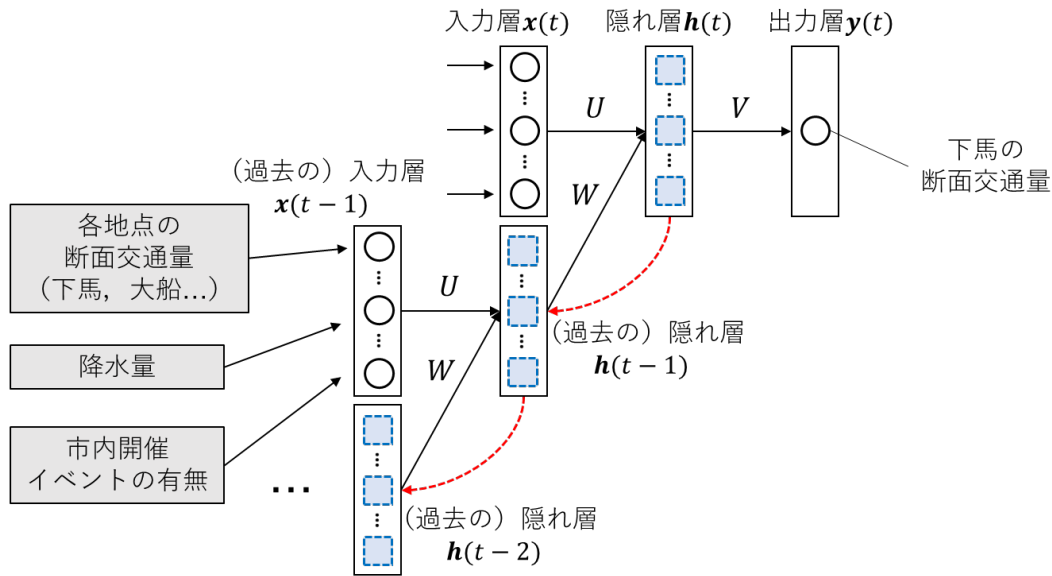


図-2 交通量短期予測モデル概略図




図-3 LSTMブロック




図-4 GRUブロック

b) GRU

GRUは時系列データの分析においてLSTMに劣らない性能を持ち、かつ計算時間を抑えたモデルである。LSTMとGRUの構造的差異は隠れ層内にあるブロックのみであり、LSTMブロックはメモリーセル、入力ゲート、出力ゲート、忘却ゲートで構成されていたが、GRUブロック（図-4）はリセットゲートと更新ゲートのみで構成されている。ブロックの構造がLSTMよりもシンプルであるため、計算時間が短いとされている。式(3h)はリ

セットゲートの値、式(3i)は更新ゲートの値、式(3j)は活性化された値をそれぞれ表している。

$$r(t) = \sigma(W_r x(t) + U_r h(t-1) + b_r) \quad (3h)$$

$$z(t) = \sigma(W_z x(t) + U_z h(t-1) + b_z) \quad (3i)$$

$$\tilde{h}(t) = f(W_h x(t) + U_h (r(t) \odot h(t-1)) + b_h) \quad (3j)$$

(4) 本研究で扱うモデルの設定

先に述べたデータを入力項目として下馬の交通量を入力するモデルを構築する。図-2から分かるように、入力層には出力対象である下馬を含む各地点の交通量、降水量が60分刻みで挿入され、イベントの有無は該当する場合には1、そうでない場合は0が入る仕様とした。

a) 保持する過去の情報量

交通量は日単位あるいは週単位で規則的に変化することが予想されるため、保持する情報量をそれらの周期に合わせることで交通量の変動を効率的に学習できると考えられる。そこで保持する情報量を1時間、半日、1日、1週間、2週間と変更して推定を行い、予測精度を比較した。その結果を表-2に示す。これを見ると、保持する過去の情報量を1週間と設定したときにMAPEが最小となることが分かる。これは今回使用した交通量データが1週間周期の特徴的な変動を有しており、それを学習で捕捉することができたためだと考えられる。以上のことから保持する情報量は1週間分とした。

表-2 情報保持時間別MAPE[%]

情報保持時間	MAPE[%]
1時間	44.39
半日	19.00
1日	11.54
1週間	8.60
2週間	9.58

b) ハイパーパラメータ

深層学習での予測において、隠れ層の数とブロック数は精度の良し悪しに関わるハイパーパラメータである。今回の分析では隠れ層を1層から5層、隠れ層内に設置するブロックを4個、8個、16個、32個、64個、128個の6種類を用意し、予測精度が最良となる組み合わせを調査する。

c) 損失関数

交通量に限らず何らかの数値を予測する際は、真値に近い予測値を目指すことが当然だとされる。しかし仮に予測が外れる場合は楽観的な評価を避けることが一般的だと思われる。例えばある商品の明日の売れ行きを予測する際、店側は在庫切れを避けるために販売数を多めに見積もり、商品の予備を確保するだろう。これは交通量の予測でも同様であり、予測した交通量よりも実際の交通量の方が多い場合が継続すると、混雑発生を検知するタイミングが遅れてしまう恐れがある。この問題に対処すべく本分析では損失関数に着目する。回帰問題において一般的に扱われる損失関数は式(3k)で表される平均二乗誤差 (Mean Squared Error / MSE) である。これは線形回帰モデルやニューラルネットワークなど様々なモデルで用いられている。これに対して式(3l)で表される平均二乗対数誤差 (Mean Square Logarithmic Error / MSLE) は予測値が実測値を超過しやすいという特徴を持っている。ゆえに予測値の過小問題を回避することが期待され、両損失関数による予測に対して過小評価割合の比較を行い、MSLEの性能を検証する。

$$MSE(y_{obs,i}, y_{pred,i}) = \frac{1}{n} \sum_{i=1}^n (y_{obs,i} - y_{pred,i})^2 \quad (3k)$$

$$MSLE(y_{obs,i}, y_{pred,i}) = \frac{1}{n} \sum_{i=1}^n \left\{ \log(1 + y_{obs,i}) - \log(1 + y_{pred,i}) \right\}^2 \quad (3l)$$

d) LSTMとGRU

前節でLSTMとGRUのモデル構造について触れたが、今回の交通量短期予測に対する両者の性能について調査する必要がある。そこで下馬下り車線の交通量データに

表-3 エポックごとのMAPE[%]

	LSTM	GRU
30 epoch	8.60	9.46
50 epoch	9.41	9.32
100 epoch	8.51	11.59
200 epoch	9.67	10.39
300 epoch	10.05	10.23

対してエポック数を変更させて複数回推定を実施した。なお使用した損失関数はMSEである。結果を表-3に示す。MAPEが最良となるエポック数はLSTMが100 epoch、GRUが50 epochであった。200、300 epochの結果を比較しても、LSTMの方が長期的な学習に適していると考えられる。推定に要する時間が膨大となるのであればGRUを採用すべきであるが、本分析に要した時間は最長でも10分ほどであったため、より高い精度を出力したLSTMをメインツールとして予測を実施こととする。

e) 訓練データとテストデータ

深層学習で扱われるデータは一般的に学習に用いられる訓練データと検証に用いられるテストデータに分割される。本分析では2017年1月1日から12月31日までの交通量データ、降水量データ、イベントデータをデータセットとして予測を実施し、そのうち1月1日から10月20日までのデータを訓練データ、10月21日から12月31日までのデータをとした。これは紅葉シーズンを含む期間をテストデータとすることで、混雑時期にどの程度予測値の当てはまりが良いのか検証を行うためである。

4. 統計的学習の結果と考察

(1) 予測性能の評価

LSTMモデルを用いて鎌倉市中心部下馬における下り車線、上り車線、両者の合計、それぞれの交通量を予測した結果を表-4に示す。表中のHL2とは隠れ層数が2であることを、B4とはブロック数が4であることを意味している。各予測における隠れ層数とブロック数の最適な組み合わせは、下馬（下り）が3層・64ブロック、下馬（上り）が4層・64ブロック、下馬（合計）が5層・64ブロックであった。また2層・4ブロックでの予測結果と比較すると、RMSEは5台ほど低下、MAPEは1.2%から2.5%低下、相関係数は約0.1増加していることが分かる。このうちMAPEに着目すると、下馬（下り）、下馬（合計）は6.85%、7.00%となっている。無論、使用されたデータやモデルが既往研究とは同一ではないため、単純比較することはできないが、LSTMによる交通量短期予測を実施したいくつかの既往研究の結果ではMAPEはおお

表4 LSTMによる予測性能

	下馬 (下り)		下馬 (上り)		下馬 (合計)	
	HL2×B4	HL3×B64	HL2×B4	HL4×B64	HL2×B4	HL5×B64
平均交通量 [台/60分]	334		348		682	
RMSE [台/60分]	31.06	26.11	50.08	46.69	63.25	57.42
MAPE [%]	8.99	6.85	14.66	12.10	8.20	7.00
相関係数	0.96	0.96	0.90	0.92	0.95	0.96

むね5%から10%が最良値であったため、良好な結果を示すことができたと考える。

緩和を目的とした交通政策の立案に対する本手法の適用可能性の高さを示唆する結果であると考えられる。

(2) 時間帯別誤差率

推定された予測値に対して、時間帯別の適合度を確認するため、予測値のプロットと時間帯毎の観測値に対する予測値の誤差率を図-5に示す。左側の軸が下馬下り車線の断面交通量[台/60分]を右側の軸が誤差率[%]を表す。誤差率は式(4a)のように定義される。プロットの期間は2017年11月27日から12月3日までの紅葉シーズンの1週間である。黒破線は下馬下り車線の交通量の実測値、青実線はその予測値である。横軸の時間は6時から22時までの17時間周期となっている。両者の重なりを確認すると朝と夜の当てはまりが良く、交通量が増加し変化が大きい日中の予測精度は悪いと感じられるが、赤線棒グラフで示される誤差率を見ると日中の方が予測値の当てはまりが良いことが分かる。車両の流入量大きい時間帯に対して精度の高い予測値が算出されたことは、特に混雑

$$E^* = \frac{|y_{obs,i} - y_{pred,i}|}{y_{obs,i}} \times 100(\%) \quad (4a)$$

(3) 過小予測割合

損失関数をMSEからMSLEに変更して再度、下馬下り車線交通量の予測を実施した。予測結果を表-5に示す。損失関数をMSLEに変更することで、RMSE、MAPEがともに増加していることから予測精度がやや悪化していることが分かる。しかし表-6に示す過小予測割合をみると、予測値総数1224に対して、MSEを損失関数とした場合は43%、MSLEを損失関数とした場合は34%であるため、過小予測割合が低下している。ゆえにMSLEが損失関数として正常に機能したことが確認された。

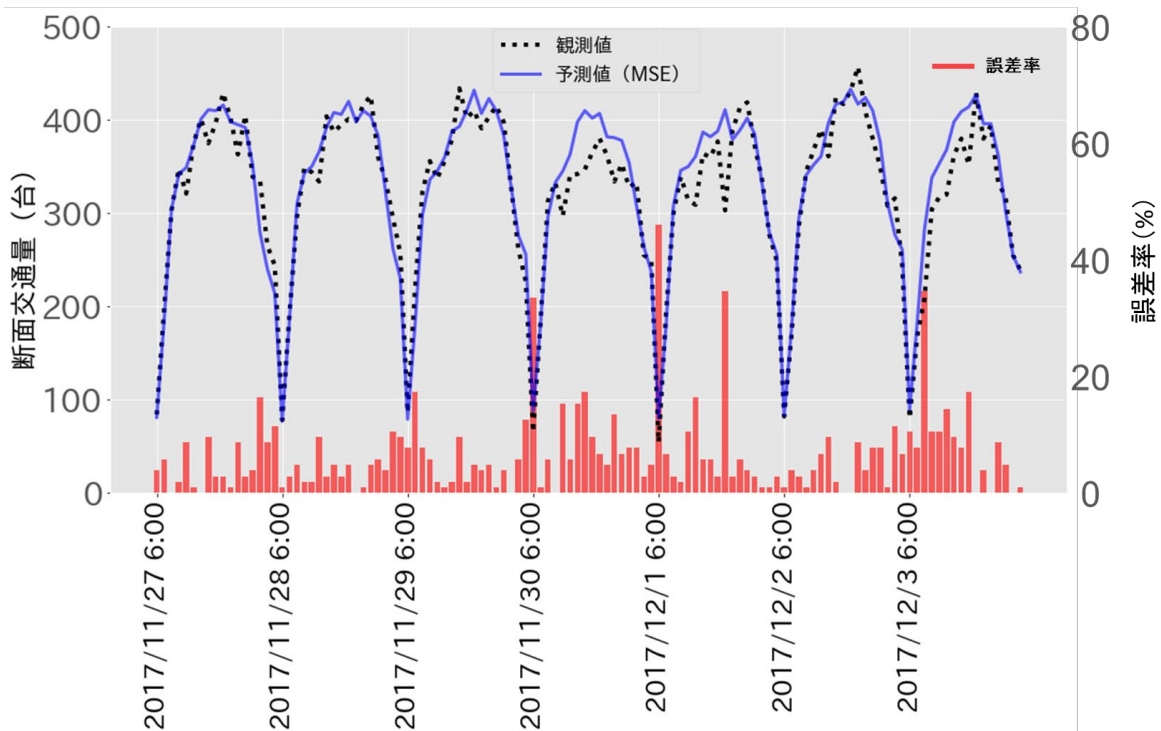


図-5 下馬下り車線交通量の予測値と誤差率

表-5 損失関数別下馬（下り）予測性能

損失関数	MSE	MSLE
平均交通量 [台/60分]	334	
RMSE [台/60分]	26.11	26.50
MAPE [%]	6.85	7.57
相関係数	0.96	0.96

表-6 過小予測割合 [%]

	MSE_予測	MSLE_予測
予測値の総数	1224	1224
過小予測値の出現数	527	421
過小予測割合	43%	34%

5. おわりに

本研究では鎌倉市中心部の混雑を緩和するための交通政策実施を想定して、深層学習ベースの交通量短期予測の枠組みを構築した。時系列データ予測の代表的な深層学習モデルであるLSTMを用いたところ、実測値と予測値の絶対パーセント誤差(MAPE)が6.85%、相関係数0.96という結果を得た。また、予測値の適合度を時間帯ごとに確認すると、交通量の増減が大きい日中の誤差率が低いことが明らかとなった。これは交通量の変化を本研究で提案したモデルによって十分に捕捉できたためだと考えられる。さらに、損失関数を平均二乗誤差(MSE)から平均二乗対数誤差(MSLE)に変更することで、予測値が実測値を超過する割合が増加することも確認された。予測値よりも多くの交通量の流入が続いた場合、混雑の発生をいち早くかつ正確に検知することができない可能性がある。したがって予測値の過小評価を回避することでより混雑緩和の観点により即した交通量短期予測の枠組みを構築することができたと考えられる。

しかし逆に予測値の過大評価が過ぎると、交通容量に余裕がある段階で流入が規制される、実際の交通量には見合わない課金額が設定されるなど、交通政策が本来持つ効果を発揮できないことが予想される。そのため実施を想定する交通政策の特性を考慮したうえで予測モデルの設定を決定することが重要である。

また、今回の分析では交通量データのみを使用しているため、その情報だけでは渋滞の発生の有無を判断することができず詳細な交通状態を把握するまでには至っていない。そこで今後は車両の走行速度や道路占有率などのデータも統合的に活用して、混雑状況をより適切に分析できる交通量短期予測の枠組みへと精緻化する予定である。

謝辞：本研究は、国土交通省・道路政策の質の向上に資する技術研究開発「学習型モニタリング・交通流動予測に基づく観光渋滞マネジメントについての研究開発」（代表：布施孝志）の一環として行われた。ここに記して感謝の意を表します。

参考文献

- 1) S. Hochreiter, and J. Schmidhuber. : Long short-term memory, *Neural Computation*, 9(8), pp1735-1780, 1997.
- 2) K. Cho, B. Merriënboer, C. Gulcehre, F. Bougares, H. Schwenk, and Y. Bengio. : Learning phrase representations using rnn encoder-decoder for statistical machine translation, *Proceedings of the Empirical Methods in Natural Language Processing (EMNLP 2014)*, 2014.
- 3) Fu R., Zhang, Z. and Li, L. : Using LSTM and GRU Neural Network Methods for Traffic Flow Prediction, *The 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*, Wuhan, pp. 324-328, 2016.
- 4) Zhao, Z, Chen, W., Wu, X., Chen, P.C.Y. and Liu, J. : LSTM network: A deep learning approach for short-term traffic forecast, *IET Intelligent Transport Systems*, Vol. 11, No. 2, pp. 68-75, 2017.
- 5) Ke, J., Zheng, J., Yang, H. and Chen, X.(M). : Short-term forecasting of passenger demand under on-demand ride services: A spatio-temporal deep learning approach, *Transportation Research Part C*, Vol. 85 pp591-608,2017.
- 6) Xu, C., Ji, J. and Liu, P. : The station-free sharing bike demand forecasting with a deep learning approach and large-scale datasets, *Transportation Research Part C*, Vol. 95, pp. 47-60,2018.
- 7) 巢籠悠輔：詳解ディープラーニング TensorFlow・Keras による時系列データ処理，マイナビ，2017.

(? 受付)

SHORT-TERM PREDICTION OF TRAFFIC STATES USING THE FRAMEWORK OF LSTM : A CASE STUDY IN KAMAKURA

Kohei OGAWA, Daisuke FUKUDA

It is one of the typical applications of artificial intelligence which learns and predicts using the accumulated big data and the accumulation of research has been advancing in the transportation field as well. However, traffic congestion is a complex phenomenon that is mainly caused by traffic demand exceeding the traffic capacities, it is not easy to predict the traffic states. In this paper, we develop a short-term traffic condition estimation method in the framework of long short-term memory (LSTM) which is suitable for processing time series traffic data. The analysis target is the central area of Kamakura City, which is one of the most popular tourist cities in Japan. The learning model aims to predict traffic condition (e.g. congestion) in the city center after 60 minutes by using the information such as the past traffic congestion in the city center, section traffic volume in the surrounding roads to the central area, amount of rain fall and presence or absence of public events as input variables. The results of model learning implied that the mean absolute percentage error between the predicted value and the observation value is about 6.43% and that the correlation coefficient is 0.96.