

多変量 LSTM とガウス過程回帰を融合した 時間帯別 OD 交通量生成

山下 聖太郎¹・柳沼 秀樹²・寺部 慎太郎³・海野 遥香⁴・鈴木 雄⁵

¹学生非会員 東京理科大学院修士課程 理工学研究科土木工学専攻 (〒 278-8510 千葉県野田市山崎 2641)

E-mail: 7622538@ed.tus.ac.jp

²正会員 東京理科大学准教授 理工学部土木工学科 (〒 278-8510 千葉県野田市山崎 2641)

E-mail: yaginuma@rs.tus.ac.jp

³正会員 東京理科大学教授 理工学部土木工学科 (〒 278-8510 千葉県野田市山崎 2641)

E-mail: terabe@rs.tus.ac.jp

⁴正会員 東京理科大学助教 理工学部土木工学科 (〒 278-8510 千葉県野田市山崎 2641)

E-mail: unoharuka@rs.tus.ac.jp

⁵正会員 東京理科大学助教 理工学部土木工学科 (〒 278-8510 千葉県野田市山崎 2641)

E-mail: suzuki@rs.tus.ac.jp

我が国の交通量観測の現状として、5年に1度の低頻度で人手によって行われる調査が主流であり、この調査結果は時・空間的に低分解能なデータとなっている。一方、日本の道路交通事情として、ロードプライシングなどの新たな交通政策やサービスの導入が進展してきている。このような新たな交通政策やサービスを検討するにあたり、時・空間的に高分解能な交通データの需要は高まっている。そこで、本研究では、リンク交通量から時間帯別 OD 交通量を出力する交通データ生成モデルを構築した。具体的には、リンク交通量の時系列予測として LSTM、リンク交通量から OD 交通量に拡大する際にガウス過程回帰を援用し構築した。構築したモデルに ETC2.0 プローブデータと道路交通センサデータを適用した結果、高精度な時間帯別 OD 交通量の生成に成功し、観測リンク交通量より時空間的に高分解能な交通データを生成可能であることが示された。

Key Words: OD traffic generation, LSTM, gaussian process, ETC2.0 probe, road traffic census

1. はじめに

(1) 背景と目的

我が国の交通量観測の現状は、国土交通省は全国道路・街路交通情勢調査(以下、道路交通センサス)として、全国のリンク交通量や起終点(以下、OD)交通量等を調査している。この調査は、5年に1度の低頻度かつ調査地点が限られた人手による調査、または調査票等に回答者が回答するアンケート調査となっており、調査結果は時・空間的に低分解能なデータとなっている。近年では、道路交通状況を把握するために、CCTVカメラやETC2.0プローブデータを活用した交通量観測が進展してきており、取得したデータにAI解析を加えた常時観測リンク交通量データの取得¹⁾も可能になりつつある。しかし、時々刻々と変化するOD交通量を常時観測することは困難であり、加えて過去・将来を含めた任意時刻のOD交通量データ生成手法は未発達である。

一方、日本の道路交通事情として、交通渋滞課題やMaaSの普及に加え、ロードプライシングなどの新たな交通政策やサービスの導入が進展してきている。国土交通省の調査(2012)によると、国内の交通渋滞による

総損失時間は年間約50億時間²⁾に及び、時間あたり平均賃金を用いると年間約10兆円の経済損失額と試算されているため、渋滞緩和に対する新しい取り組みは必須である。このような新たな交通政策やサービスを検討するにあたり、時空間的に高分解能な交通データの需要は高まってきている。

そこで、本研究は、観測リンク交通量を時空間方向に拡大した将来時間帯別OD交通量データ生成の手法を開発することを目的とする。将来時間帯別OD交通量データの生成が可能になることで、道路交通情報の常時更新に貢献し、先に述べた新たな交通政策やサービスの導入検討や道路交通マネジメント、店舗マーケティングの質的向上などに役立てられることが期待できる。

(2) 既往研究と本研究の位置付け

交通量推定はこれまでも様々な手法が検討がされてきたテーマであり、近年では特に機械学習やニューラルネットワークを用いたテーマが盛んである。中でもOD交通量推定に着目すると、大谷ら³⁾はガウス過程回帰を用いてモデルを構築し、ETC2.0プローブデータから得られたサンプルデータのリンク交通量から日別

OD 交通量を従来の配分計算を行わずに逆推定した。誤差評価では二乗平均平方根誤差（以下、RMSE）は 406（台/day）となり、比較的少ない計算量で高精度の日別 OD 交通量推定に成功した。藤田ら⁴⁾は時間変動係数の観測リンク交通量から OD 交通量逆推定手法について検討した。特に観測リンク交通量からの時間変動係数の逆推定モデルを日 OD 交通量を与件として、時間均衡配分を併用することで残差最小化モデルとして構築し、その最適性条件と解法を示した。また、阿倉ら⁵⁾はリンク交通量とそれに対応する OD マトリックスのデータセットを予め作成し、与えられたリンク交通量に対し、それがどのクラスの OD マトリックスにより生成されたものかの判定を行う分類器を深層学習を用いて構築した。推定性能評価を行った結果、対象領域全体の 50%のリンク交通量が測定可能であれば、80%程度の精度を達成できることを確認した。

OD 交通量の他に、小川ら⁶⁾は鎌倉市の観光交通量を多変量 LSTM（Long short-term memory）を用いて、60 分先の横浜鎌倉線下馬の断面交通量短期予測を行った。多変量 LSTM の入力値として 15 分単位の交通量の他に、降水量や社会イベントを組み込んでおり、1 年以上の長期データを基に予測モデルの構築を行い、季節性による交通量の変動にも対応した。その結果、学習モデルは観光交通が持つ季節性を補足し、降雨や社会イベントの影響を予測に反映していることを確認した。Huseyin ら⁷⁾は空間的特徴を抽出する GCN（Graph Convolutional Network）と時間的特徴を抽出する LSTM を組み合わせて、数日先の長期交通流速度予測モデルを構築した。入力値には ETC2.0 速度、ETC2.0 サンプル数、降水量、曜日を用い、予測対象道路区間の他に上下流道路区間の情報を取得する道路ネットワークを準備した。時間帯別・対象道路区間別・曜日別の RMSE では、それぞれ 2.3~4.5（km/h）・2.2~3.9（km/h）・2.6~5.6（km/h）となった。特に曜日別の予測精度では平日の場合高いが、土日は少し低下し、祝日の場合は大きく低下することを確認した。加えて、従来の時系列予測に用いられてきた自己回帰和分移動平均モデル（ARIMA モデル）との精度比較を行って結果、LSTM や GCN などのディープラーニング手法が従来の時系列予測モデルよりも柔軟な予測が可能であることを示した。

以上から、観測リンク交通量より、将来リンク交通量や OD 交通量を推定する手法は様々存在するが、これらを組み合わせた時間帯別将来 OD 交通量の推定には至っていない。そこで、本研究では比較的柔軟な時系列予測が可能である LSTM と配分計算を行わずにリンク交通量から OD 交通量の推定が可能なガウス過程回帰を組み合わせることで、観測リンク交通量から時間帯別将来 OD 交通量を予測し生成する。

2. データ概要および基礎集計

(1) 交通量データ

a) ETC2.0 プローブデータ

主に走行時の日付や時刻、道路種別、速度、走行場所などの走行履歴情報や進行方位や前後加速度、左右加速度などの挙動履歴情報などが蓄積されており、全国約 1700 ヶ所（2011 年）に設置された ITS スポットから蓄積された情報を汲み取られる。記録の取り方は、基本的に前回記録地点から「200 メートル走行した時点」もしくは「走行方向が 45 度以上変化した時点」でデータが再記録される。なお、個人情報保護に基づく秘匿化処理により走行開始地点や走行終了地点は収集されない。利用状況は、2022 年 6 月時点で ETC 利用率 94.1% の内の 28.7% が ETC2.0 利用率となっており、約 238 万台/日が利用している。

交通調査基本区間番号を基にリンク交通量を集計した。東京都内の高速自動車国道、都市高速道路、一般国道を対象とし、2016 年 6 月から 12 月の平日を対象期間と設定した。以上より、ETC2.0 プローブデータから得られるリンク交通量（以下、ETC2.0 リンク交通量）は常時観測可能なサンプルデータという位置付けになる。

b) 道路交通センサデータ

5 年に一度、国土交通省の管轄で行われている調査より得られた全国の道路交通状況に関するデータである。なお、この調査には断面交通量及び旅行速度を調査する「一般交通量調査」や自動車の運行状況などを調査する「自動車起終点調査」の 2 つに大別される。

本研究では自動車起終点調査より、オーナーインタビュー調査のうち自家用車の簡易調査票・詳細調査票、営業用車に共通する全ての調査結果を集計したオーナーマスターデータと NEXCO が実施した高速 OD 調査結果を集計した高速マスターデータを組み合わせた、OD 集計用マスターデータより OD 交通量を集計し、午前 6 時から午後 21 時台の 1 時間単位に再集計した。東京都内に OD ペアを持つものを対象とし、2015 年度のデータを使用する。以上より、道路交通センサデータから得られる OD 交通量（以下、センサ OD 交通量）は常時観測不可能な母集団データという位置付けになる。なお、センサ OD 交通量は 1 日分のデータとして再集計した。

(2) 降水量データ

気象庁より東京都内の観測地点として、世田谷、羽田、江戸川臨海、練馬、青梅、八王子、小沢、府中、小河内、八丈島、大島を選定し、1 時間単位の降水量データを取得した。本研究では観測地点の緯度経度とリンクの緯度経度を比較し、最も近い観測地点とリンクを

表-1: 基礎集計 (ETC2.0 リンク交通量)

リンク数 (本)	平均 (台)	最大値 (台)	最小値 (台)
1269	15.70	273.0	0

表-2: 基礎集計 (センサス OD 交通量)

OD ペア数 (本)	平均 (台)	最大値 (台)	最小値 (台)
9488	24.58	5437	0

表-3: 基礎集計 (降水量)

リンク数 (本)	平均 (mm)	最大値 (mm)	最小値 (mm)
1269	0.288	46.50	0



図-1: モデル構造

結ぶことで、リンクごとの降水量（以下、リンク降水量）を集計した。

(3) 基礎集計

本研究で使用するデータの基礎集計結果は表-1 から表-3 に示す。ここで、道路交通センサスデータから得られる OD 交通量は常時観測が不可能であるため、本研究では ETC2.0 リンク交通量とリンク降水量より、将来時間帯別センサス OD 交通量を予測するモデルを構築する。

3. 時間帯別将来 OD 交通量生成モデルの構築

(1) モデル構造

本研究におけるモデル構造は図-1 より、LSTM とガウス過程回帰の 2 手法を組み合わせた構造である。LSTM 層よりリンク交通量の将来時系列予測を行い、ガウス過程回帰層よりリンク交通量から OD 交通量への拡大を行う。モデル全体の入力値は観測リンク交通量、出力値は将来時間帯別 OD 交通量である。

(2) 多変量 LSTM

LSTM⁸⁾ とは時系列データの扱いに長けた再帰型ニューラルネットワークであり、同じく再帰型ニューラルネットワークの RNN(Recurrent Neural Network) の課題

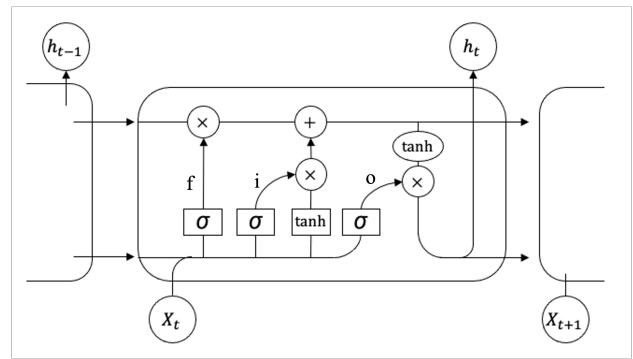


図-2: LSTM の構造

点であったデータの長期依存関係を克服し、学習可能としたものである。LSTM の特徴は、「ゲート」という仕組みと「記憶セル」という経路が存在することである。ゲートとはデータの流れを制御する箇所であり、データからゲートの開き具合、すなわちどの程度データを通すかを学び、情報の取捨選択を行う。記憶セルとは LSTM レイヤ内のみでデータの受け渡しを行い、LSTM の記憶部分に相当する。これらのゲートと記憶セルによって、時系列データの長期依存関係を学習することが可能となる。

図-2 より、 x_t は時刻 t での入力、 h_t は時刻 t での隠れ層の値、 f, i, o はそれぞれ、forget ゲート、input ゲート、output ゲート、 σ はシグモイド関数を表す。それぞれのゲート及び隠れ層の値は以下で表される。

$$f = \sigma(x_t W_x^f + h_{t-1} W_h^f + b^f) \quad (1)$$

$$i = \sigma(x_t W_x^i + h_{t-1} W_h^i + b^i) \quad (2)$$

$$o = \sigma(x_t W_x^o + h_{t-1} W_h^o + b^o) \quad (3)$$

$$h_t = o \bullet \tanh(c_t) \quad (4)$$

ここで、

- $W_x^{()}$: 各ゲートにおける入力 x_t に対する重み
- $b^{()}$: 各ゲートにおけるバイアス
- c_t : 記憶セル

である。なお \bullet はアダマール積を表す。

本研究におけるハイパーパラメータは表-4。なお検出限界値には 3 シグマ法を用い、平均値で補完した。

(3) ガウス過程回帰

ガウス過程回帰⁹⁾ とは、ガウス過程により入力変数 x から出力変数 y に対応する関数 $y = f(x)$ の推定を指す。関数の推定にはベイズ推定を用いており、関数の分布として推定されるため、推定値の信頼度を表現することが可能である。ガウス過程の定義は、出力 $y = (y_1, y_2, \dots, y_N)$ の同時分布が多変量ガウス分布に従う時、入力 x_1, x_2, \dots, x_N と出力 y の関係、すなわち関数 f はガウス過程に従うという。

表-4: LSTM 層ハイパーパラメータ

パラメータ	値
エポック数	500
損失関数	平均二乗誤差 (MSE)
オプティマイザ	RAAdam
隠れ層のユニット数	48
隠れ層数	4
シーケンシャルサイズ	5

ここで、入力 $\mathbf{x} = (x_1, x_2, \dots, x_N)$ と各特徴の重み $\mathbf{w} = (w_0, w_1, \dots, w_H)$ による線形回帰モデルを計画行列 Φ を使って以下のように表す。

$$\mathbf{y} = \Phi \mathbf{w} \quad (5)$$

重み \mathbf{w} は、ガウス分布

$$\mathbf{w} \sim \mathcal{N}(0, \lambda^2 \mathbf{I}) \quad (6)$$

から生成されるとすると、式 (5) もガウス分布となる。ここで、 λ^2 は \mathbf{w} の分散、 \mathbf{I} は単位行列である。すなわち、式 (5) の期待値 \mathbf{E} と共分散行列は Σ それぞれ、

$$\mathbf{E}[\mathbf{y}] = \mathbf{E}[\Phi \mathbf{w}] = \mathbf{0} \quad (7)$$

$$\begin{aligned} \Sigma &= \mathbf{E}[\mathbf{y}\mathbf{y}^T] - \mathbf{E}[\mathbf{y}]\mathbf{E}[\mathbf{y}]^T = \Phi \mathbf{E}[\mathbf{w}\mathbf{w}^T] \Phi^T \\ &= \lambda^2 \Phi \Phi^T \end{aligned} \quad (8)$$

式 (7) と式 (8) より、 \mathbf{y} の分布は、

$$\mathbf{y} \sim \mathcal{N}(0, \lambda^2 \Phi \Phi^T) \quad (9)$$

式 (9) となる。以上より、入力 \mathbf{x} から出力 \mathbf{y} の分布が得られた。なお、式 (5) に存在する重み \mathbf{w} はここまでの過程で削除されるため、線形モデルの入力変数 \mathbf{x} が高次元時に発生する次元の呪いを回避可能となり、 \mathbf{y} の分布は共分散行列 $\lambda^2 \Phi \Phi^T$ に依存する。共分散行列 $\lambda^2 \Phi \Phi^T$ は動径基底関数 (RBF) などのカーネル関数を用いて、決定する。

本研究におけるカーネル関数は式 (10)、式 (11) で表される、線形カーネルと MLP カーネルを乗じたものを用いた。

$$k(x, x') = x^T x' \times \sigma^2 \frac{2}{\pi} \arcsin A \quad (10)$$




図-3: クロスバリデーション

ただし、

$$A = \left(\frac{\sigma_w^2 x^T y + \sigma_b^2}{\sqrt{\sigma_w^2 x^T x + \sigma_b^2 + 1} \sqrt{\sigma_w^2 y^T y + \sigma_b^2 + 1}} \right) \quad (11)$$

LSTM 層の出力値、すなわち将来時間帯別リンク交通量を 0 時台～23 時台の 1 時間ごとの和をとり、集計値を入力値として、将来時間帯別 OD 交通量を出力する。なお検出限界値には 3 シグマ法を用い、平均値で補完した。

4. 予測精度の検証と考察

(1) データの適用

モデル全体の入力値には ETC2.0 リンク交通量とリンク降水量、出力値にはセンサ OD 交通量を用いた。第一に LSTM 層の入力値には ETC2.0 リンク交通量とリンク降水量の 2 つの特徴量を生成し、学習データを 2016 年 6 月 1 日から同年 10 月 31 日、テストデータを 2016 年 11 月 1 日から同年 12 月 31 日の期間に分割した。すなわち $2496 \times 1269 \times 2$ テンソルを学習データ、 $984 \times 1269 \times 2$ テンソルをテストデータと分割した上で、正規化を施した。ゆえに、LSTM 層の出力値は 984×1269 行列である。

次に、LSTM 層の出力値である将来時間帯別リンク交通量を 24×1269 行列に再集計し、ガウス過程回帰層の入力値とした。ガウス過程回帰層の出力値は 24×9488 行列で表される将来時間帯別 OD 交通量となる。この出力結果をセンサ OD 交通量との予測精度評価に用いる。

(2) 予測結果

本研究における予測精度評価には、RMSE(台/h) と平均絶対誤差 (MAE, 台/h) を用いた。

それぞれ、0 に近似するほど高い予測精度を有し、RMSE の場合は誤差関数に二乗誤差を用いているため外れ値の影響を受けやすい。対して、MAE の場合は誤

表-5: 予測精度評価

	RMSE[台/h]	MAE[台/h]
時間帯別 OD 交通量予測モデル	48.82	12.93




図-4: 時間帯別 OD 交通量予測モデルの
Observed-Predicted Plot

差関数に絶対誤差を用いているため RMSE より比較的
に外れ値に対してロバストである。予測誤差評価に加
えて、Observed-Predicted Plot を用いた予測精度評価も
行った。横軸に Observed(観測値)，縦軸に Predicted(予
測値)を設定し， $y = x$ 上にプロットが近似するほど高
い予測精度を有する。

本モデルを用いた時間帯別 OD 交通量の予測精度評
価を表-5，および Observed-Predicted Plot を図-4 に表
す。なお，時間帯別 OD 交通量予測モデルの Observed-
Predicted Plot の決定係数は 0.863 である。表-5 より，
RMSE の値が MAE の値より大きく上回っており，デー
タセットに外れ値が多く混在していた可能性が高い。し
かし，データセットに関しては 3 シグマ法にて外れ値
を検知した上で，平均値を用いて補完した後，正規化を
行った。これより，データセットが正規分布ではなく，
歪みを有した分布になっていた可能性が高い。図-4 より，
確かに過小評価されている点が多く見える。また
図-4 より，観測値が大きい値を取るほど，予測値との
誤差が大きくなることが確認できる。これはガウス過
程回帰の性質より，異なる入力値同士が近い値を取
るほど，それに対応する出力値同士も近い値を取る。
これより，本研究のガウス過程回帰層では入力値のみ
正規化したため，このような結果になったと考える。

表-6: ETC2.0 リンク交通量時系列予測精度評価

	RMSE[台/h]	MAE[台/h]
ETC2.0 リンク交通量時系列予測	5.474	2.840

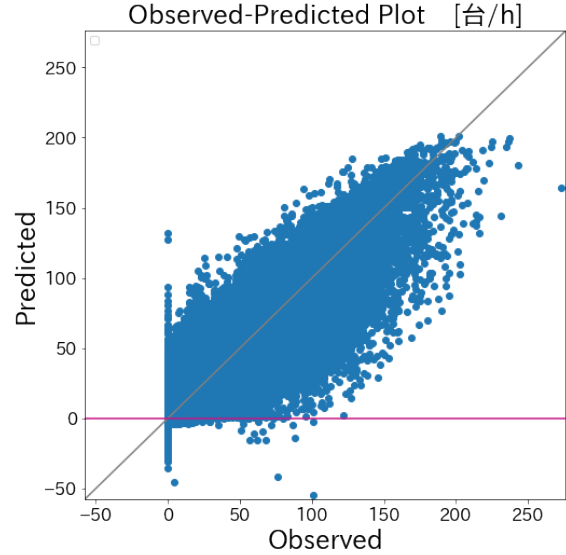


図-5: ETC2.0 リンク交通量時系列予測の
Observed-Predicted Plot

大谷ら³⁾が構築した OD 交通量生成モデルでは観測リ
ンク交通量より 1 日の OD 交通量を予測し，RMSE は
406(台/day)であり，Observed Predicted Plot の決定係
数は 0.937 であった。また，小川ら⁶⁾が構築した短期交通
量予測モデルではリンク交通量より 15 分単位の将来リ
ンク交通量を予測し，RMSE は 17.71(台/15min)であ
った。これらの既往モデルとは対象地域やモデル構造，ス
ケールなどが同一ではないため一概に比較することは
できないが，図-4 の Observed Predicted Plot より，比
較的良好な精度を有した時間帯別 OD 交通量生成モデル
を構築できたことを確認した。

ここで，LSTM 層のみ，すなわち ETC2.0 リンク交通
量時系列予測の結果を表-6，図-5 に表す。なお，本予
測における Observed-Predicted Plot 決定係数は 0.940 で
ある。図-5 の Observed Predicted Plot より，良好な予測
精度は得られた。しかし，出力値に負数が発生してお
り，誤差精度には現れない課題点がある。データセット
に負数は存在しないのでうまく学習できていない可能
性が高く，損失関数やシーケンシャルサイズの変更を
施すことで予測結果に負数が発生することへの抑制や
精度向上に繋がると期待される。逆に LSTM 層の出力
値に負数が含まれていてもガウス過程回帰層を通すと，
修正された OD 交通量が生成された。

5. おわりに

(1) 結論

本研究では、多変量 LSTM とガウス過程回帰を組み合わせて、観測リンク交通量から将来時間帯別 OD 交通量の生成モデルを構築した。そして、ETC2.0 プローブデータや道路交通センサデータ、気象庁の降水量データをデータに適用し、予測精度評価を行った。その結果、RMSE は 48.82(台/h)、MAE は 12.93(台/h) という予測精度となり、高精度な時間帯別 OD 交通量の生成に成功した。また、本モデルの LSTM 層を利用し、リンク交通量予測の精度評価も行った。その結果、RMSE は 5.474(台/h)、MAE は 2.840(台/h) という予測精度となった。これらの結果より、観測リンク交通量から時空間的に高分解能な交通データを生成可能であることが示され、新たな交通調査に貢献されることが期待される。

(2) 今後の展望

本研究の主な課題点として、以下の 2 点が挙げられる。1 点目は、予測精度向上である。良好な予測精度を有したモデル構築に成功したが、LSTM 層における負数発生など課題点が多いにある。その原因の一つとして、道路ネットワーク構造を考慮していない点が挙げられる。本研究は道路ネットワーク構造は考慮せずモデル構築を行ったため、交通量の流入出を加味できていない。そこで、DRM 情報等よりネットワーク構造を加味したモデル構築を行うことで精度向上が期待される。次に最適な入力値の選定を行う必要がある。小川らの既往モデルでは交通量の他に社会イベントを特徴量として入力値に選定している。また、交通量は曜日等に影響を受けやすいので、曜日ダミー等を特徴量として入力値に選定することで精度向上を期待される。最後に安定した学習を行うために、LSTM 層やガウス過程回帰層におけるハイパーパラメータの最適化も同時並行で行う必要がある。2 点目は、LSTM 層の膨大な推定時間である。本研究では東京都内の高速自動車国道、都市高速道路、一般国道を対象とし分析を行い、推定時間は 10 時間を超えた。この先、対象地域・道路種別拡大を行うと推定時間は一層増大すると考えられる。少ないデータセット数で安定した学習を行えるようなモデル構築が重要であると考え。今後はこれらの課題点の解決に向けて、さらなるモデル構築を目指していく。

参考文献

- 1) 国土交通省: CCTV カメラ (AI 解析) の精度に関する報告, 2021.
- 2) 国土交通省: 高速道路を中心とした「道路を賢く使う取組の基本方針, 2015.
- 3) 大谷貴俊, 柳沼秀樹, 寺部慎太郎, AND 田中皓介: 大規模プローブデータとエミュレーション技術を活用した OD 交通量逆推定, 第 64 回土木計画学研究発表会・講演集, 2021.
- 4) 藤田素弘, 渡邊健, AND 山田真士: 観測交通量からの時間変動係数に基づく時間帯別 OD 交通量の逆推定手法の開発, 交通工学論文集, VOL.2, NO.1, PP.11–20, 2016.
- 5) 阿倉佑樹, 天野辰哉, 山口弘純, 廣森聡仁, 東野輝夫, 西村友佑, 諏訪晃, 長村吉富, 竹嶋進, AND 高井峰生: 深層学習によるリンク交通量から OD 交通量の推定手法, 研究報告高度交通システムとスマートコミュニティ (ITS), VOL.2020, NO.5, PP.1–7, 2020.
- 6) 小川晃平 AND 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, 土木学会論文集 D3 (土木計画学), VOL.76, NO.5, PP.1389–1398, 2021.
- 7) HUSEYINTIRTOM, 森田格, 辻大樹, 村戸伸行, AND 力石真: グラフ畳み込みニューラルネットワークを用いた観光地における旅行速度予測, 第 64 回土木計画学研究発表会・講演集, 2021.
- 8) 斉藤康毅: ゼロから作る DEEP LEARNING2, 株式会社オライリー・ジャパン, 2018.
- 9) 持橋大地 AND 大羽成征: ガウス過程と機械学習, 株式会社講談社, 2019.

(2022. 9. 30 受付)

COMBINING MULTIVARIATE LSTM AND GAUSSIAN PROCESS REGRESSION OD TRAFFIC GENERATION BY TIME OF DAY

Shotaro YAMASHITA, Hideki YAGINUMA, Shintaro TERABE, Haruka UNO and Yu
SUZUKI

The current state of traffic volume observation in Japan is dominated by surveys conducted manually at a low frequency of once every five years, and the results of these surveys are low-resolution data in time and space. On the other hand, new transportation policies and services, such as road pricing, have been introduced in Japan. In order to consider such new traffic policies and services, there is a growing demand for traffic data with high time and space resolution. In this study, we developed a traffic data generation model that outputs OD traffic volumes by time period from link traffic volumes. Specifically, LSTM was used for time-series prediction of link traffic volume, and Gaussian process regression was used to expand from link traffic volume to OD traffic volume. By applying the ETC2.0 probe data and road traffic census data to the model, we succeeded in generating highly accurate OD traffic volumes by time period, and showed that the model can generate traffic data with higher time and space resolution than observed link traffic volumes.