

# ニューラルネットワークによる 滞在人口の短期間変動予測可能性に関する研究

高森 駿<sup>1</sup>・佐々木 邦明<sup>2</sup>

<sup>1</sup> 学生会員 早稲田大学 大学院創造理工学研究科 (〒169-8555 東京都新宿区大久保 3-4-1)  
E-mail:syun@fuji.waseda.jp

<sup>2</sup> 正会員 早稲田大学教授 創造理工学部社会環境工学科 (〒169-8555 東京都新宿区大久保 3-4-1)  
E-mail:sasaki.k@waseda.jp

災害時などの時間解像度の高い人口の移動予測の必要性は高い一方、その場合には従来の移動予測モデルは適していない。一方近年の IoT 化の進展に伴って、様々な観測データが利用できるようになった。そこで本研究では、COVID-19 の影響により人々の行動が大きく変化した期間を対象に、時間解像度の高い観測データの一つであるモバイル空間統計を用いて、ニューラルネットワークを活用した滞在人口の短期的な変動予測の実現可能性を検討した。また既往手法では考慮が難しいとされる動的な現象の影響について、ニューラルネットワークでは考慮できるのかを検討した。そしてその予測について、土地利用等に基づいた共通の特性を示した。この研究は、災害等の非定常時においてデータから直接的に人々の行動実態を予測する手法の一助となると考える。

**Key Words:** neural network, LSTM, mobile spatial statistics, gridded population, disaster

## 1. 研究の背景と目的

都市計画および交通計画において、人々の移動を把握し、予測を行うことが非常に重要であり、その手法としては、これまで四段階推定法や行動モデルが主として用いられてきた。四段階推定法とは、パーソントリップ調査（以下 PT 調査とする）などから得られた現在の人々の移動の実態をもとに、将来の人口や経済状況などを指標として、将来の人々の移動の総量やその手段別分量等を段階的に推定する手法である。四段階推定法は 1 日の中の時間帯による違いを考慮せず、平均的な状況の予測を行う、いわば静的な予測手法である。そのため、使用目的がインフラ整備やマスタープラン作成といった静的な内容であれば十分に利用できる手法とされてきた。しかし、時間帯別の移動の実態を予測することや、渋滞現象などの動的な現象をこの手法で考慮することは難しい。したがって、四段階推定法は中長期的な予測には有効であっても、リアルタイムに基づくような時間解像度の高い詳細な予測には適さないといえる。

一方で、近年は IoT 化の進展により膨大なビッグデータが収集・蓄積され、このデータを活用することで、社会課題の解決につながるような新しいサービスが生まれている。都市計画の分野においても、それまでは交通量調査に基づくデータや PT 調査データといった取得に手

間がかかるデータを中心に利用してきたが、この IoT 化の進展により新たに様々な観測データが利用できるようになってきている。その観測データの一つとして、モバイル空間統計<sup>1</sup>があげられる。これは、株式会社 NTT ドコモが自社の携帯電話通信ネットワークを活用して作成する人口統計情報である。モバイル空間統計は、他の人口統計手法と比較すると、一日を通じた時間帯別のデータ把握・高頻度でのデータ把握・データ取得可能なエリアの広域性・集計の速報性といった点が長所があるため、ダイナミックに変動する人口分布の実態を高い時間解像度で把握するための有力なツールとなり得る。

他方、近年は機械学習に関する研究が幅広い分野で行われている。この背景としては、分析対象となる膨大なデータが容易に入手可能となったことがあげられる。これは都市計画の分野においても例外ではなく、様々なデータが利用可能となり、これらのデータをもとに機械学習を利用した研究が見受けられる。

そこで、本研究ではモバイル空間統計で得られる 500m メッシュ単位での 1 時間ごとの滞在人口データから、ニューラルネットワーク（以降、NN とする）を用いた滞在人口変動予測の実現可能性を検討する。また既往手法では考慮が難しいとされる動的な現象の影響について、ニューラルネットワークでは考慮することができるのかを検討する。そしてその予測について、土地利用等

に基づいた共通の特性を示す。この研究は、非定常時においてデータから直接的に人々の行動実態を予測する手法の一助となることを目的とする。

## 2. 既往研究と本研究の位置づけ

### (1) 既往研究の整理

本研究に関する既存研究を、モバイル空間統計に関する研究、滞在人口の時系列変動に関する研究の2つに分けて整理した。

#### a) モバイル空間統計に関する研究

清家ら<sup>29)</sup>は一連の研究において、新たな人口統計手法の一つとしてモバイル空間統計を挙げ、既往統計との比較により、モバイル空間統計の信頼性を評価した。人口分布の空間解像度はメッシュの人口密度に依存し、1kmメッシュの場合で人口が1000人程度以上であれば一定の信頼性があると結論づけている。また、いくつかのケーススタディを通して、モバイル空間統計を活用した地域評価モデルの検討を行った。結果としてモバイル空間統計は、昼間人口の集計が可能であること、広域性を持って柔軟にデータの取得ができることなどを活かして、既往統計にはない地域評価が可能であることを確認した。また、渋川ら<sup>4)</sup>はモバイル空間統計を用いた立地適正化計画の評価指標に関する研究を行った。宇都宮市を対象として、実際のモバイル空間統計による人口データを従来のデータと比較することでその精度の検証を行った。その結果、夜間人口や昼間人口についてモバイル空間統計が十分に地域の状況を捉えていることを確認したほか、昼間人口の集積状況も的確に捉えていることを確認した。

#### b) 滞在人口の時系列変動に関する研究

NNに関する研究は、様々な分野でその導入の検討を行うものが多い。佐藤ら<sup>3)</sup>は、イベント開催日を滞在含む3日間という短い期間における渋谷駅周辺の人口変動について、時系列モデルに基づく手法、時空間モデルに基づく手法、LSTM等のNN、時空間予測モデルと時系列予測モデルを組み合わせた提案手法などで予測を行い、その結果を比較した。通常時の予測については、どの手法も概ね高い精度で予測できており、中でも過去の変動をより直接的に活用する時系列予測モデルは最も高い精度を示した。また、LSTMは学習によって変動の周期を捉えることができている、高い精度を示した。一方で、学習データと変動傾向が大きく異なるイベント開催中のデータの予測については、時空間予測モデルと時系列予測モデルを組み合わせた提案手法が最も高い精度を示した。また、時系列モデル等に基づく予測と比較すると、LSTMによる予測のほうが良い結果を示した。

### (2) 本研究の位置づけ

既存研究より、モバイル空間統計は新たな人口統計手法として一定の信頼性があり、また時間解像度の高さや集計の容易さなどの様々な特性を活かして、都市の人口分布の実態を詳細かつ即時的に把握することが出来る有力なツールとして期待されている。また、近年ではNNを用いた研究が幅広い分野で行われており、人々の行動実態の把握についても同様に、複雑かつ大容量のデータをもとに高精度の予測を行うことが出来ることと期待される。

そこで本研究では、NNを用いてモバイル空間統計のメッシュ単位の滞在人口変動予測の可能性を検討する。また、既往手法では考慮することが難しいとされる動的な現象の影響について、NNで考慮できるのかを検討し、そしてその予測について土地利用等に基づいた共通の特性を示すことに特徴がある。

## 3. 基礎概念の整理

### (1) ニューラルネットワーク

NNとは、人間の脳内にある神経細胞と、そのつながりを数理的なモデルで表現したものである。NNの概念図を以下の図1に示す。NNは、入力層・中間層(隠れ層)・出力層の3つの層から構成されており、各層の間では重み付けが行われる。これは情報間のつながりに重要度をつけるような作業であり、NNでは出力と教師データが近づくように、この重み係数を学習によって調整していく。すなわちより多くのサンプルを用いて学習を行うほど、係数がより適切なものとなり、出力結果も正解に近いものとなる。一般にNNはその複雑な構造ゆえに高い表現力を持っているため、分類や予測において高い精度を有するとされている。

### (2) LSTM

LSTM (Long short-time memory) は、時系列データを学習できるNNであるRNNの一種である。まずRNNとは、他のNNとは異なり、ある時刻の中間層において同じ時

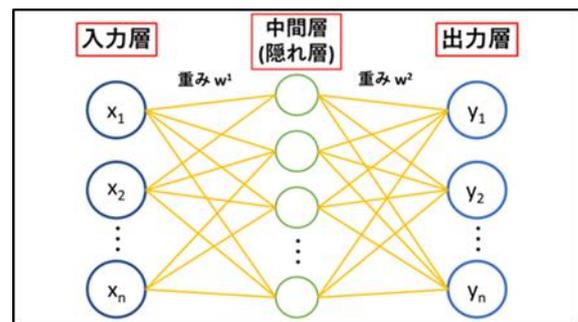


図1 ニューラルネットワークの概念図

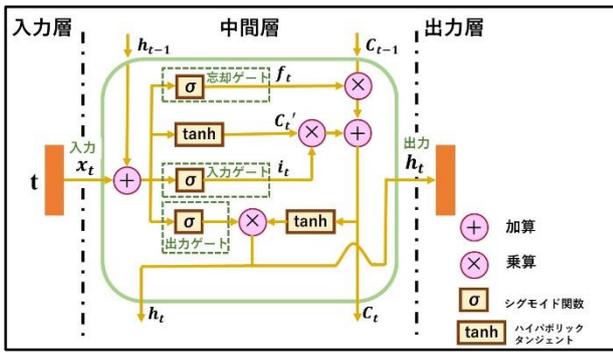


図2 LSTMの構造図

刻の入力層からの入力に加えて、前の時刻の中間層からの入力も受け取ることで、データのトレンドを学習することができる NN である。この RNN は、時間方向に展開した静的なネットワーク上で誤差逆伝播を用いて学習を行うが、系列が長くなると重みが掛けられる回数が多くなるため、時系列的に遠い過去のデータの影響が消失してしまう。これに対し、LSTM ではメモ

リセルを導入することで、遠い過去のデータの影響も考慮できるようになったため、長期依存を学習できなくなる問題を解消している。LSTM の構造を図 2 に示す。

#### 4. 研究の概要

##### (1) 使用するデータについて

使用するデータは、2020年1月以降の毎日1時間おきに500mメッシュ単位で得られるモバイル空間統計とする。この期間はCOVID-19の影響により、人々の行動が日々変化していたと考えられ、この変化をNNによって捉えることができるのかを検証する。また、COVID-19が滞在人口に与えた影響が大きかったことが予想される新宿区周辺から、各メッシュの用途地域に着目して、商業地域のメッシュとして6メッシュ、住宅地域のメッシュとして12メッシュを対象のメッシュとして選択した。これらの対象メッシュを図3、図4に示す。

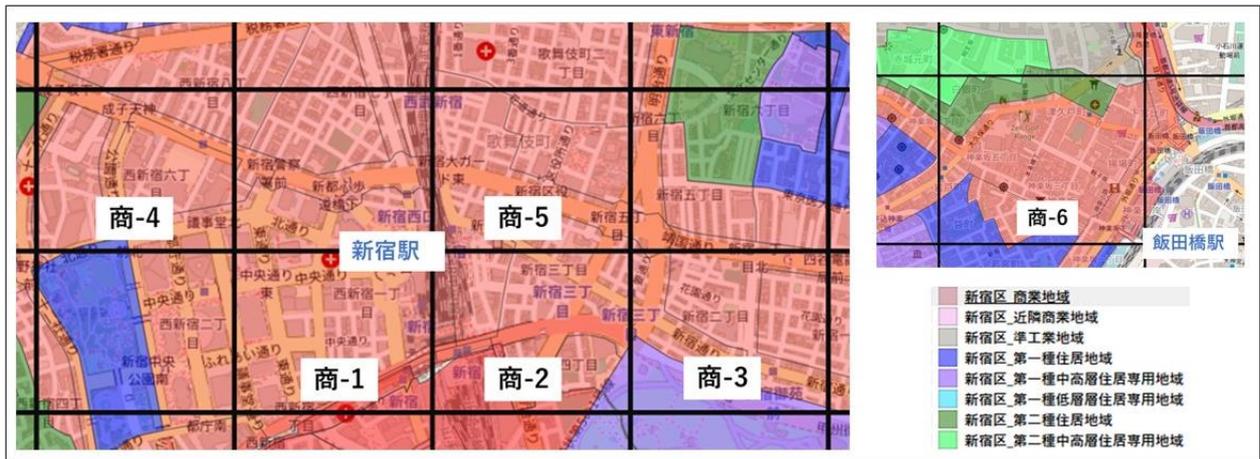


図3 商業地域のメッシュ (6メッシュ)

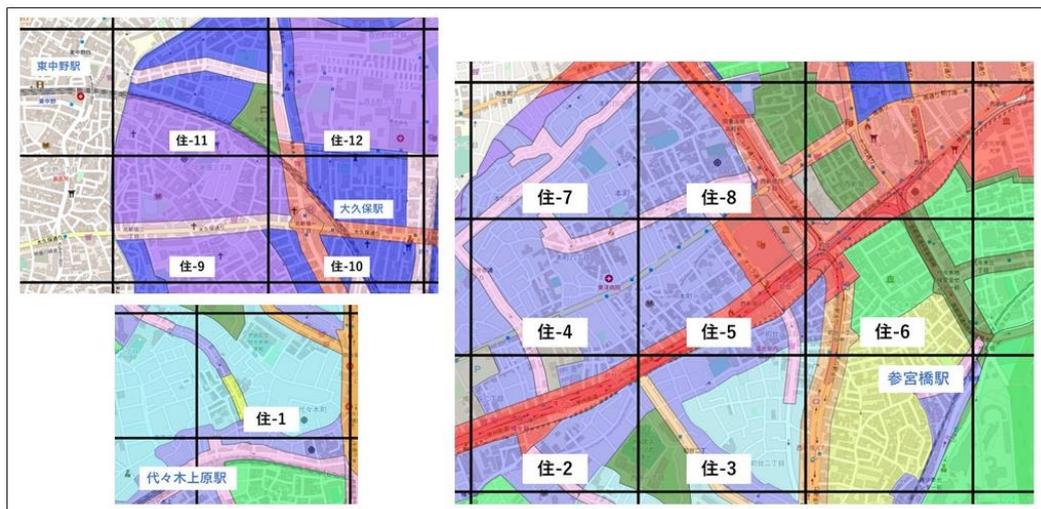


図4 住宅地域のメッシュ (12メッシュ)

## (2) 使用するNNについて

滞在人口は、その場所に来る、あるいはそこから別の場所へ行くというような、一人一人の行動によって決まる。人々の行動は、通勤通学に代表されるような固定的でパターン化したものがある。このように曜日や時間帯などによって決まる変動のパターンがあるため、滞在人口については時系列予測が適していると考えられる。時系列データを分析する際に重要となるのは、そのデータがどのようなトレンドをもち、どのように変化するかという点である。そこで本研究では、時系列データを扱うことができる RNN の中でも記憶期間の長さの考え方を導入することにより、直近の出力だけでなく、遠い過去の出力の影響も保持することが可能な NN である LSTM を用いる。

## 5. LSTMによる滞在人口の変動予測

### (1) LSTMの実装について

LSTM による学習・予測を行うプログラムの作成に関しては、プログラミング言語 Python を用いた。また、Python で利用可能な深層学習のオープンソースライブラリである keras, 及び google によって開発された高速数値解析用のライブラリである TensorFlow を活用することで LSTM を実装した。

### (2) データについて

使用するデータに関しては、東京 23 区 500m メッシュにおける 2020 年 1 月以降 1 時間ごとに得られるモバイル空間統計とする。また、入力データとしては、過去 1 週間分のデータ、すなわちウィンドウサイズを 168 個 (24 時間×7 日間) とし、その 168 時点分の入力データから次の 1 時点の値を出力および予測するモデルとする。

### (3) 学習結果

NN では、膨大な量の入力データと教師データのセットから、推論のために最適な重み係数やバイアスを決定する学習と呼ばれる処理を行う。このとき、それらのパラメータが最適なものへ近づくための指標となるのが損失関数である。これは、正解の値と NN による出力値の誤差を表すものであり、具体的に使われる関数としてはいくつか種類がある。NN の学習においては、この損失関数の値が小さくなるように内部の係数やバイアスを更新していき、最終的にはその値が最小となるように調整を行う。本研究の LSTM では、学習時の損失関数として平均二乗誤差 (MSE) を用いる。これは、機械学習の回帰分析において、そのシンプルさから損失関数として頻繁に用いられるものである。その計算としては正解の値と予測値の差を二乗し、データセット全体で平均をとったものである。

### (4) 予測結果

まず、学習に用いるデータと予測を行う期間との間に滞在人口の変動パターンに特殊な変化等がない場合において、LSTM で滞在人口を予測することが出来るのかを確かめた。ここでは、2020 年 1 月 1 日 0 時から 2020 年 4 月 30 日 23 時までのデータで学習を行い、2020 年 5 月の滞在人口変動を予測した。ここでは一例として、商-1 メッシュにおける予測結果を図 5 に示す。実測値と予測値を示す線はほとんど重なっており、誤差が非常に小さいことがわかる。このほかのメッシュでも、同様であった。したがって、滞在人口の変動パターンに特殊な変化等がない場合、LSTM を用いることで滞在人口変動を非常に高い精度で予測することができるといえる。

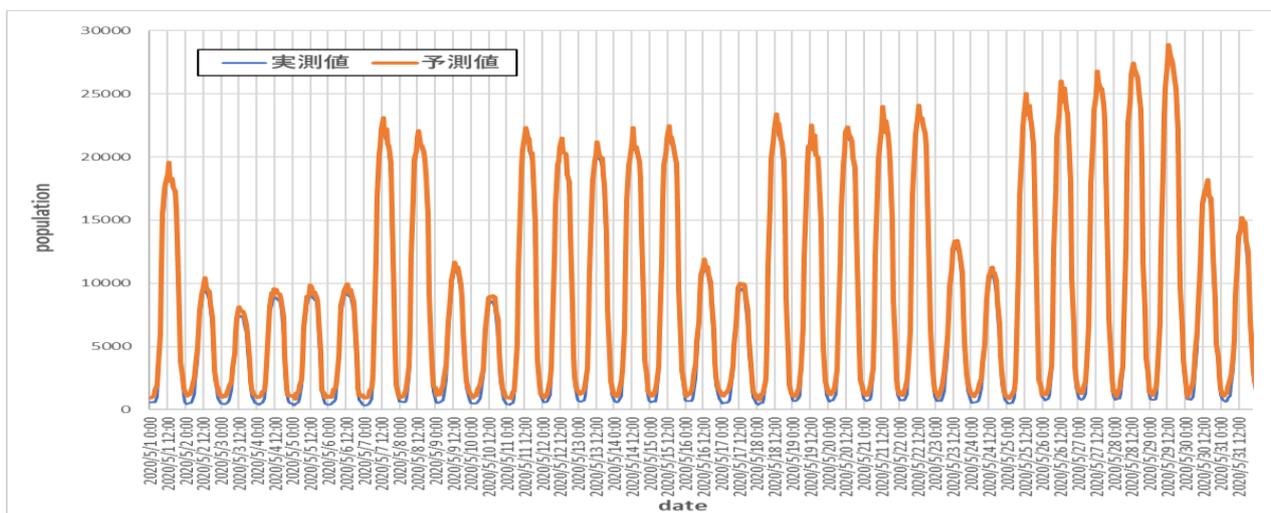


図 5 2020 年 5 月の滞在人口変動の実測値と予測値 (商-1 メッシュ)

## 6. 急激な変動がある場合の LSTM による予測

### (1) 学習データの期間の変更による予測精度の比較

機械学習では、学習データから捉えた特徴をもとに予測を行う。今回使用している LSTM の場合、学習に用いたデータから時系列的な特徴（例えば、オフィス街は平日の朝から夕方にかけて滞在人口が極端に多くなるというような変動パターン）を学び、それをもとに予測を行う。そのため原則として、変動パターンが急激に変化した場合、変化前のデータで学習しただけでは上手く予測できないと考えられる。そこで、変動パターンの急激な変化を境に、それ以後学習に用いるデータの期間を少しずつ変えることで、急激な変化があった場合にそこからどれくらいの期間を学習する必要があるのかを検証した。具体的には東京都の外出自粛要請が適用された 2020 年 3 月 28 日に変動パターンが急激に変化したと考え、学習データの期間は開始日が 2020 年 1 月 1 日で固定であり、終了日を ①3 月 27 日(パターンの変化前) ②4 月 3 日 ③4 月 10 日 ④4 月 17 日 ⑤4 月 24 日 ⑥5 月 1 日 と 1 週間単位で変更し、またいずれにおいても 5 月 2 日~5 月 8 日までの一週間の滞在人口を 1 時間単位で予測した。結果をそれぞれ図 6-1, 図 6-2, 図 7 に示す。なお、図 6-2 は、図 6-1 の中で誤差が大きい 2 メッシュ (商-1, 商-2 メッシュ) を除いたものを示している。また、予測精度の評価指標としては RMSE (二乗平均平方根誤差) が一般的に用いられるが、RMSE は各メッシュに依存する値である

ため、今回はメッシュ同士を比較するために RMSPE (平均平方二乗誤差率) を用いた。RMSPE は、実測値を  $y_i$ 、予測値を  $f_i$  として以下の式で表される。

$$RMSPE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{f_i - y_i}{y_i} \right)^2} \quad (1)$$

まず、商業地域について、今回は主に新宿駅周辺のメッシュを対象としており、東京都の外出自粛要請の影響により滞在人口が著しく減少したエリアである。すなわち、3 月 28 日頃に変動パターンに大きな変化があり、そのため変化前までのデータで学習すると大きな誤差が生じた。また、変化後のデータを学習データに追加したところ、1, 2 週間分追加しても誤差はあまり変わらず、3, 4 週間分追加してようやく誤差の減少が見られた。したがって、商業地域のメッシュについて今回のモデルで滞在人口の変動予測を行う場合、変動パターンが急激に変化した後、概ね予測可能となるためには約 3 週間分のデータを学習する必要がある。

一方、住宅地域のメッシュについても、外出が減ること通常よりも滞在人口が増えるというような変動パターンの変化があった。しかし、商業地域のパターン変化に比べるとその度合いが小さいということもあり、パターンが急激に変化したと考えた 3 月 28 日以前のデータのみで学習していても十分対応した予測できている。

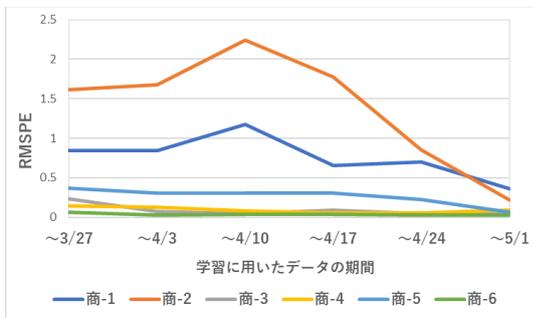


図 6-1 学習に用いるデータの期間が異なる場合の予測精度の比較 (商業地域)

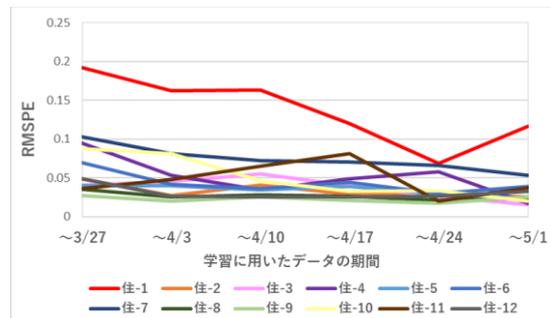


図 7 学習に用いるデータの期間が異なる場合の予測精度の比較 (住宅地域)

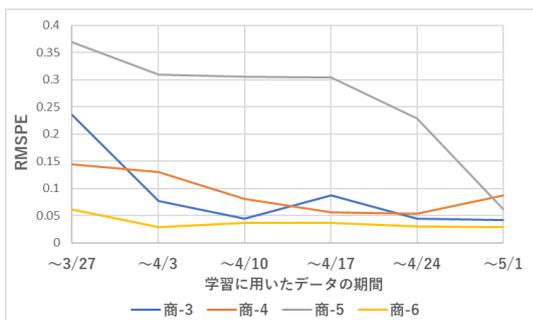


図 6-2 学習に用いるデータの期間が異なる場合の予測精度の比較 (商業地域, 2 メッシュ除去)

(2) 実用的な利用に向けて

LSTM は膨大なデータから時系列的な特徴を学習することを得意とする NN である。それゆえに、前節までに述べた通り、時系列的な特徴、すなわちパターン等が変化すると精度の高い予測は困難となる。本節では、パターン等が変化した場合における LSTM を用いた滞在人口変動予測の実現手法について検討する。図 8-1、図 8-2、図 8-3、図 8-4 は、横軸の日付の 1 時間ごとの滞在人口を LSTM で予測したときの RMSPE の値を示したものである。その際、2020 年 1 月 1 日からそれぞれ予測を行う日の前日 23 時までのデータを学習データとして用いている。これらの図から、急激な変動があった 3 月 28 日から 3 月 30 日頃の間で RMSPE の値が増加し、その後は RMSPE が大きな値を示し続けている。すなわち、RMSPE や RMSE 等の誤差の指標となる値に注目し、そ

の閾値を適切に設定することで、パターンの変化を検知することができるのではないかと考えられる。

また、パターンの変化を検知した際、学習に用いるデータの期間や LSTM 内部の各種パラメータを変更して、学習および予測を行うことで、精度の高い予測の実現可能性を検討する。一例として、3 月 28~30 日と RMSPE の値が大きくなっており、ここでパターンの変化を検知したとする。このとき、それ以降で RMSPE の値が大きくなっている 4 月 1-3 日について、学習方法を変更して予測を行った。具体的には、予測対象日の直前 1 日から 3 日間分の短期間のデータを学習に用いた。また、これまでは直前 1 週間(168 時点)分のデータから予測を行っていたが、今回は学習に用いるデータ数が少ないため、直前 6 時間のデータから予測を行った。結果を表 1-1、表 1-2、表 1-3、表 1-4 に示す。

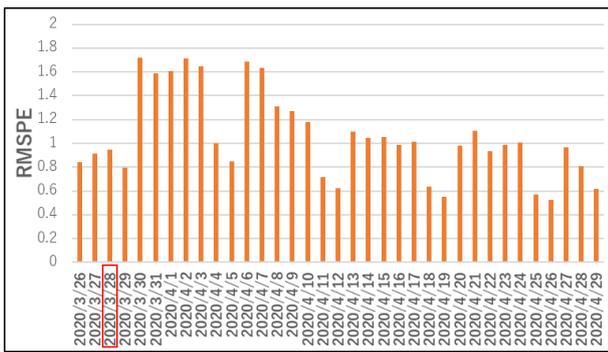


図 8-1 1 日ごとの RMSPE (商-1 メッシュ)

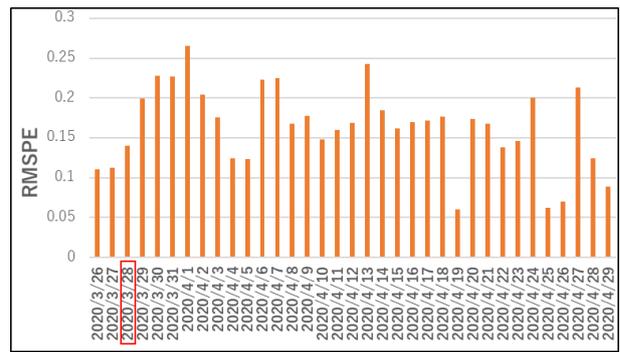


図 8-2 1 日ごとの RMSPE (商-3 メッシュ)

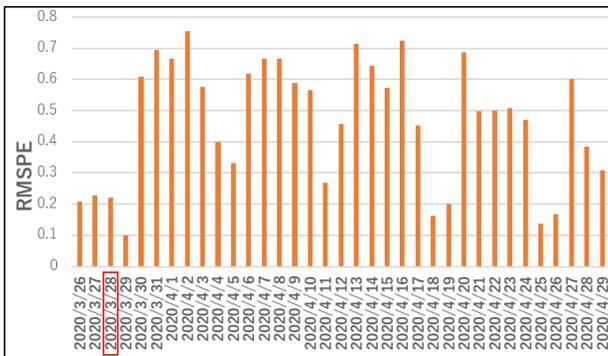


図 8-3 1 日ごとの RMSPE (商-5 メッシュ)

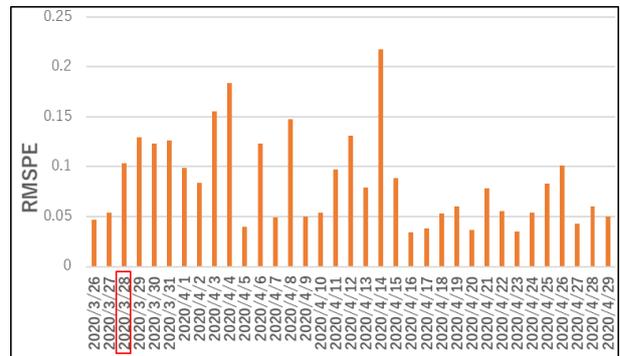


図 8-4 1 日ごとの RMSPE (商-6 メッシュ)

表 1-1 短期間学習での RMSPE (商-1 メッシュ)

		予測対象日		
		4月1日	4月2日	4月3日
学 習 期 間	直前1日分	6.7511	7.2467	7.9057
	直前2日分	1.5610	1.7349	1.4539
	直前3日分	0.8757	1.6173	1.1474
	通常	0.5671	0.5654	0.3383

表 1-2 短期間学習での RMSPE (商-3 メッシュ)

		予測対象日		
		4月1日	4月2日	4月3日
学 習 期 間	直前1日分	0.7934	0.9539	0.8248
	直前2日分	0.7257	0.4659	0.5337
	直前3日分	0.2919	0.2289	0.5289
	通常	0.0595	0.0709	0.0574

表 1-3 短期間学習での RMSPE (商-5 メッシュ)

		予測対象日		
		4月1日	4月2日	4月3日
学 習 期 間	直前1日分	1.6150	1.5741	1.4442
	直前2日分	0.4960	0.7132	0.5344
	直前3日分	0.1931	0.3305	0.4770
	通常	0.1164	0.1064	0.1119

表 1-4 短期間学習での RMSPE (商-6 メッシュ)

		予測対象日		
		4月1日	4月2日	4月3日
学 習 期 間	直前1日分	0.6117	0.5399	0.5661
	直前2日分	0.5492	0.3982	0.3042
	直前3日分	0.3353	0.2074	0.4159
	通常	0.0492	0.0620	0.0874

縦の日数が学習に用いた日数、横の日付が予測対象日である。また、短期間学習ではなく、パターン変化の前からのデータを学習したものを通常とした。結果として、パターンの変化の検知後、短期間のデータで学習を行うと、予測精度は更に低くなってしまった。この理由として、本来 LSTM をはじめとする NN は、膨大なデータからそれぞれの特徴等を学習しそれにもとづいて予測を行うため、このように短期間のデータで学習を行った場合は学習不足となり、そのような特徴を十分に捉えることができないからであると考えられる。

## 7. 今後の課題と予定

本研究では、LSTM をモバイル空間統計 1 メッシュに適用し、COVID-19 の影響下での滞在人口の変動を 500m メッシュ単位で予測を行った。その結果、まず変動パターンの変化がない場合は、LSTM により滞在人口変動を高い精度で予測することができた。また、パターンが急激に変化した場合でも、住宅地域のメッシュでは、今回データとして用いた COVID-19 による滞在人口の急激な変動に対して、大きな誤差を生じることなく、おおむね良く予測ができていた。COVID-19 と自然災害を比較すると、その影響が及ぶ期間は異なるが、人々の行動に与える影響そのものは似ている（例えば、台風の際は家にとどまる人が増えて住宅地域の滞在人口が増加する等）。したがって住宅地域については、災害などの非定常時においても LSTM を用いて十分な予測が行えると考えら

れる。一方、商業地域のメッシュではパターン変化の度合いが著しく大きいため、滞在人口のみを入力とする LSTM で予測を行うのは難しいと考えられる。ただし、あくまでも滞在人口は時系列な特徴を強く持つため、滞在人口のみならずその他の時系列の変数等を併せて入力する LSTM を構築したり、あるいは他のニューラルネットワークを組み合わせることで再現性の向上が期待できる。また、パターン変化によって予測が困難であった商業地域の一部のメッシュでは、逆に予測精度の変動からパターン変化を検知することが可能であるという結果が得られた。このパターン変化の検知が可能であることで、例えば災害時などにどこで人々の行動に直接的な影響を与えるようなことが起こっているのかを、モバイル空間統計をはじめとした観測データから導き出すことができると考えられる。今後は、パターン変化の自動検知、それに応じた学習期間の最適化等を検証し、また土地利用についてもより詳細な分類や施設立地などを考慮したモデルを構築することで、適切な予測が行えるような手法を検討したい。

**謝辞：**本研究を行うにあたり、モバイル空間統計の貴重なデータを提供していただいた株式会社ドコモ・インサイトマーケティングに、この場を借りて深く御礼申し上げます。

## 参考文献

- 1) 株式会社ドコモ・インサイトマーケティング, 「モバイル空間統計」, <https://mobaku.jp/> 最終閲覧 2021/9/30
- 2) 清家剛, 三牧浩也, 原裕介, 小田原亭, 永田智大, 寺田雅之, 「まちづくり分野におけるモバイル空間統計の活用可能性に係る研究」, 都市計画学会 都市計画論文集, Vol. 46, No. 3, pp451-456, 2011
- 3) 清家剛, 三牧浩也, 森田祥子, 「柏市および横浜市を対象としたモバイル空間統計による地域評価モデルに関する研究」, 建築学会 技術報告書, 第 21 巻, 第 48 号, pp821-826, 2015
- 4) 渋川剛史, 浅野周平, 十河孝介, 森本章倫, 「携帯電話基地局データを用いた立地適正化計画の評価指標に関する研究 - 宇都宮市をケーススタディとして」, 都市計画論文集, 第 53 巻, 第 3 号, pp408-415, 2008
- 5) 佐藤大祐, 松林達史, 福田匡人, 堤田恭太, 中山彰, 戸田浩之, 「残差回帰による複合時空間予測手法」, IDIM2020(第 12 回データ工学と情報マネジメントに関するフォーラム) , I6-4, day2 p74  
<https://db-event.jpn.org/dcim2020/post/proceedings/papers/I6-4.pdf> 最終閲覧 2021/9/30
- 6) 斎藤康毅(2016), 「ゼロから作る Deep Learning - Python で学ぶディープラーニングの理論と実装」, 株式会社オライリー・ジャパン

?

## STUDY ON THE PREDICTABILITY OF SHORT- TERM FLUCTUATIONS IN THE GRIDDED POPULATION BY USING NEURAL NETWORK

Suguru TAKAMORI and Kuniaki SASAKI

There is a strong need for predicting population movements with high temporal resolution during disasters. On the other hand, conventional behavioral models are not suitable for such a case. In addition, with the recent development of the IoT, various observation data have become available. In this study, we examined the feasibility of using neural networks to predict short-term fluctuations in the gridded population using mobile spatial statistics data, which is one of the observation data with high temporal resolution, for the period when people's behavior changed significantly due to COVID-19. And, we examined whether neural networks can take into account the effects of dynamic phenomena, which are considered difficult to be taken into account by existing methods. In addition, common characteristics of the prediction based on land use and other factors are presented. We believe that this research will contribute to a method for predicting the actual behavior of people directly from data in non-stationary situations such as disasters.