

推薦論文

リアルタイム人口を用いた Stacked denoising Autoencoders によるタクシー将来需要予測

石黒 慎^{1,a)} 菊地 悠¹ 深澤 佑介¹

受付日 2018年4月11日, 採録日 2018年10月2日

概要: タクシーの効率的な運行には、乗車需要に関する情報を運転手に与えることが有効である。本稿では携帯電話ネットワークの仕組みを用いたリアルタイム人口データを利用したタクシー将来需要予測を行い、それに基づいた運行支援方法を提案する。提案法の予測には、Stacked denoising Autoencoders を利用し、入力データとして、タクシー運行データ、リアルタイム人口データ、および、天候データを用いた。オフラインの実験により、人口データを用いない場合の予測結果が二乗平均平方根誤差で 1.513 であるのに対し、人口データを利用することで誤差が 1.370 に低下することを示した。

キーワード: 需要予測, ニューラルネットワーク, 位置情報サービス

Taxi Demand Forecast with Stacked denoising Autoencoders Using Real-time Population Data

SHIN ISHIGURO^{1,a)} HARUKA KIKUCHI¹ YUSUKE FUKAZAWA¹

Received: April 11, 2018, Accepted: October 2, 2018

Abstract: For efficient operation of taxis, it is important to give drivers various information on passengers' demand. In this paper, we propose a taxi future demand prediction algorithm using cellular network based real-time population data with Stacked denoising Autoencoders. In the offline experiment, we will show that our proposal method is possible to predict with an error 0.877 by MAE when we use real-time population data compared to an error 1.042 when we do not use the data.

Keywords: Demand forecast, Neural Network, Location-based Service

1. はじめに

近年、タクシードライバの高齢化が進んでおり、将来の労働力を維持するために、若年のドライバの育成が急務となっている [1]。熟練ドライバは、どこでより多くの乗客候補を発見できるかの知見を暗黙的に持っており、より多くの収益を得ることができる。一方、新人のドライバはそのような知見が少なく、効率的に乗客を発見することができずに収益が低くとどまり、結果として離職などにつながる可能性がある。また、ベテランドライバであっても、不慣れた場所に乗客を送迎した際には、帰路で通過するエリア

の乗車需要に関する知見がなく、慣れたエリアに戻るまでの間、空車のまま運転してしまうことがある。このような知識量の違いによる運行収益の格差を埋めるため、従来では、マニュアルや講習などによってノウハウを伝承していた。しかしながら、すべてのノウハウを網羅的に共有することは難しく、また、乗車需要の知識は陳腐化するため必ずしも効率的ではない。この問題を解決するため、過去のタクシーの運行データから将来の乗車需要を予測する方法が研究されている [2], [3]。このような仕組みを使うことで新人ドライバは、乗車需要に関するノウハウがなくても将来需要の予測結果に基づいて、効率的な運行を行うことが

¹ 株式会社 NTT ドコモ
NTT DOCOMO, INC., Chiyoda, Tokyo 100-6150, Japan
^{a)} shin.ishiguro.tb@nttdocomo.com

本稿の内容は 2017 年 8 月の第 84 回 MBL 研究発表会にて報告され、同研究会主査により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である。

可能となる。また、タクシー利用客にとっても、乗りたいタイミングでタクシーが来ることで、より短時間で素早くタクシーに乗車できるメリットがある。

タクシー需要を予測するため、従来では、タクシーの乗車データおよび天候データを考慮した手法が提案されている [4]。一方、タクシーの乗車需要は、タクシーが運行しているエリアの人口の増減に大きく影響を受けると考えられる。たとえば、大きなイベントが終了する際は、タクシーの需要が高まることが想定される。このような場合においても、当該エリアの人口の変動を追うことによって、イベントをあらかじめ知らなくても、人々の移動が活発になっていることが分かるので、より早く需要の増加を発見することが可能となる。また、電車の遅延や事故などの際においても、上述の例と同様に、タクシーの需要が高まると考えられるが、リアルタイムに人口の変化を分析することで、タクシーの需要増加をより早く発見することができる。そこで、本研究では、過去のタクシーの乗降履歴、および天候データに加え、リアルタイムな人口データを用いることで、タクシーの需要を予測する手法を提案する。

ここで、タクシーの需要予測の精度を上げるため、タクシーの乗降実績、天候データおよびリアルタイムな人口データを組み合わせることで、乗車需要に強く関連する特徴量を設計することを考える。しかし、各データを単純に組み合わせただけの場合、膨大なパターンの組合せが考えられるため、人手により有用な組合せを獲得することは難しい。近年では機械学習手法の1つである深層学習が注目を浴びている。深層学習は今日までに画像認識、自然言語処理、音声認識など様々な分野で実績を上げている [5]。深層学習では、多層のニューラルネットワーク構造を用いてデータ間の構造・関係性を抽象的に表現することによって、データに含まれる重要な要素を抽出することができる。本研究では、深層学習を用いたタクシー将来需要予測手法を提案する。ここでは様々な研究で予測精度の効果が示されている Stacked denoising Autoencoders (SdA) モデル [6] を用いて個別に各層の学習を行う。

本研究の貢献は以下の2点である。

- 異種複数データ（過去のタクシーの乗降履歴データ、リアルタイム人口データ、天候データ）を統一的に抽象表現するため、深層学習によってモデル化した点。
- 従来手法（タクシーの乗降履歴データ+天候データ）に比べ、リアルタイム人口データを追加することでタクシー需要予測精度の向上を確認した点。

本稿の構成は以下のとおりである。2章では関連研究を述べる。3章では問題設定を行う。4章では人口データについて説明する。5章では提案手法について述べる。6章では実験を行う。7章でリアルタイム予測について議論を行い、8章で結論を述べる。

2. 関連研究

これまでのタクシーの将来需要予測に関する研究について述べる。

タクシーの需要予測では、推定対象とする需要をどのような空間粒度で定義するかによって、需要予測の方式が異なる。Leeら [7]、Yueら [8] は、タクシーの乗降履歴データのクラスタリングを行い、タクシー需要のホットスポットを推定し、ホットスポットごとに需要を推定する手法を提案した。Changら [9] は、タクシー乗降履歴データのクラスタリングを行い、クラスタ領域内の道路とクラスタを対応付けることで、道路ごとに将来需要を推定する手法を提案した。Liら [2]、Powellら [3] は、位置情報データを時刻ごとグリッドごとに分け、グリッドごとの需要を推定する手法を提案した。

また、予測モデルについては下記の研究がされている。Luisら [10]、[11] はタクシースタンドごとの需要を予測するため、ストリーミングで取得されるタクシーデータをもとにオンラインで Time-Varying Poisson モデルと ARIMA モデルを組み合わせる手法を提案した。Kaiら [12] は、地域ブロックごとにエントロピーを計算することで需要の不確かさを求め、マルコフモデル、Lempel-Ziv-Welch モデル、ニューラルネットワークの3種の方式から、どの予測手法が理論的に最大の予測精度となるか識別し、予測に適用する手法を提案した。Yongxinら [4] は、タクシーの配車要求アプリから得られる過去の履歴情報を用いて、日時、場所、気象、料金ディスカウント情報などを組み合わせることで生成される多次元特徴量を複数の線形回帰モデルで予測する手法を提案した。Neemaら [13] は、タクシー需要の予測のために時系列データに対して、平均、線形回帰、Loess 回帰、TBATS、Holt Winters の需要予測を行う手法を評価した。

タクシー需要の定義の仕方について考察を行った研究もある。Dongxuら [14] は、空車のタクシーがどれくらい短時間で実車に変わるかで需要の定義を設計し、需要と供給のバランスを推定した。Afianら [15] はタクシー需要を乗せることができた顧客と需要はあるものの乗せることができていない顧客を分けることで、未遭遇の顧客からの需要を推定する手法を提案した。Yongxinら [4] は配車要求アプリの履歴を用いることで、流しの運行履歴では取得することができない、乗せることができなかった乗客からの潜在需要を考慮した需要予測手法を提案している。

このように、タクシーの将来需要予測は現在まで、様々な手法が研究されている。しかしながら、過去の研究では、リアルタイムな人口データおよび過去のタクシーデータの両方を用いた研究はなされていない。

3. 問題設定

本研究では、リアルタイム人口データ、天候データおよび過去のタクシー乗車数を入力とし、500m グリッド単位で30分先の需要（当該グリッドにおける乗車数の予測値）を出力するアルゴリズムを提案する。予測対象となる乗車需要は連続値となるため、回帰問題としてモデル化する。本稿では、東京無線協同組合の4,400台のタクシーを対象にタクシー需要の分析を行う。同社において運行が行われている主要エリアである東京23区、および、武蔵野市、三鷹市を含む2,723個の500mグリッドに区切られるエリアを対象として分析を行った。

3.1 共通モデル

従来研究 [2], [3] と同じく、本稿では、タクシーの需要予測をグリッド単位で行う。グリッド単位の予測では、グリッドごとに個別に、グリッド数と同じ数の予測モデルを構築する方法と、すべてのグリッドで共通の1つの予測モデルを構築する方法の2つの方針がある。ここで、グリッドごとのタクシーの乗車実績数を確認する。2016年9月1日～9月14日の14日間について、30分ウインドウ幅で、10分スライドごとにタクシーの乗車実績の回数を集計した。求められた各乗車実績数の出現回数の結果を図1に示す。図1に示すように、タクシー乗車が多く行われる高需要なグリッドが出現することは、比較的少なく、タクシーの乗車がほとんど行われない低需要のグリッドが多くなっている。このため、低需要なグリッドでは、タクシー乗車が行われることが稀であり、高精度に予測するために十分な学習データ量を担保することが難しいと考えられる。そこで、本研究では、モデルの汎化性能を高め、より多くのエリアと時間帯において高精度な予測を行うため、グリッドごとにモデルを構築するのではなく、全グリッドで共通




図1 タクシー乗車実績数と総出現回数（対数スケール）（2016年9月1日～9月14日）

Fig. 1 Taxi boarding number and total appearance frequency (logarithmic scale, Sep. 1st – Sep. 14th, 2016).

の単一モデルを生成することとした。

4. 人口データ

4.1 リアルタイム人口データの概要

人口データとして、携帯電話ネットワークの仕組みを利用することで、人口を推定したリアルタイム人口統計データを用いた*1。この技術では、500mごとの空間解像度、10分ごとの時間解像度で、モバイル端末の台数をエリア毎、時間ごとに推定を行う。同データにより日本全国にわたり、現在時刻から30分前までの人口推定結果を利用することが可能である。モバイル端末の位置登録情報を用いることで、モバイルネットワークの各基地局とモバイル端末の位置関係から、各端末の位置情報の推定をすることが可能となる。ただし、本稿で扱った人口データは、集計処理がNTTドコモの回線利用者に限定されているため、年齢や性別の分布に偏りが生じ得ること、少人数エリアのユーザの秘匿のためにデータ削除処理を行っていること、新幹線などの通過交通による人口が含まれること、などの理由により、データ中に様々な偏りが含まれている。そこで、データの偏りを低減するために、パーソントリップ調査データとの比較に基づいた拡大推計を行うことで、日本の各時刻各エリアにおける実人口を推定する処理を行っている。より詳細な人口データの作成方法については本稿の主眼ではないため、省略することとする。

4.2 リアルタイム人口とタクシー乗車数の関係

タクシーの乗車数と人口増減の関係を検証するため、これらの時系列遷移の比較を行った。平均乗車数の上位5%となるグリッドについて、タクシーの乗車数と人口の互いの相関関係を確認したところ、大きく2つの傾向が確認された。1つは、タクシーの乗車数が人口の増減と同期して遷移しているグリッド、もう1つは、人口の増減とずれてタクシーの乗車数が変化するグリッドである。これらの傾向が現れた1例として、新橋駅周辺と三軒茶屋駅周辺の500mグリッドについて、タクシー乗車数と人口の時系列グラフを図2、図3に図示する。図2では、実際にタクシー乗車数と人口の遷移が同期して推移していることが確認できる。一方、図3では、タクシー乗車数が人口の増加から5時間遅れて増加している。図2の新橋周辺は、オフィスエリアであり、オフィスが営業している日中の時間帯にタクシーの乗車が行われていることが想定される。一方で図3の三軒茶屋周辺は、繁華街であり、人の流れに合わせてタクシーの乗車需要が増加し、深夜になって電車の営業が終了した後に乗車需要のピークが表れていると考えられる。

*1 本実験で使用する人口統計は、エリア毎や属性ごとの集団の人数を示す情報であり、個人を特定できる情報をいっさい含まない。したがって、この人口統計により個人の行動が他人に知られることはない。なお、本実験で使用する人口統計は、モバイル空間統計ガイドラインを遵守している [25]。

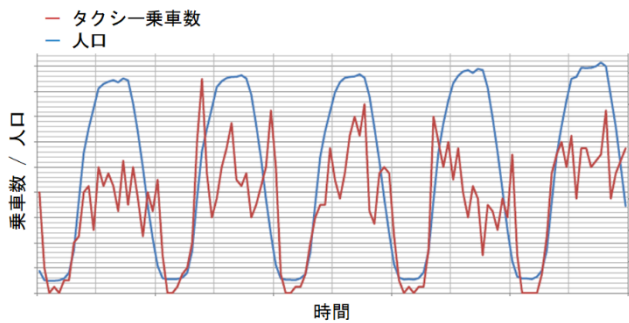


図 2 タクシー乗車数と人口の時系列グラフ (2016年9月1日~9月5日, 新橋駅周辺)

Fig. 2 Taxi boarding counts and population transition graph around Shinbashi station (Sep. 1st - Sep. 5th, 2016).




図 3 タクシー乗車数と人口の時系列グラフ (2016年9月1日~9月5日, 三軒茶屋駅周辺)

Fig. 3 Taxi boarding counts and population transition graph around Sangenjaya station (Sep. 1st - Sep. 5th, 2016).

これらの例が示すように、タクシー乗車数と人口の推移は互いに密接に関係している可能性がある。ただし、その相関関係はすべてのエリアで均一ではなく、エリアごとに異なるため、需要予測モデルでは、単純な比例関係ではなくグリッドごとの特性の違いを学習する必要があると考えられる。そこで我々は、このようなグリッドによって異なるタクシー乗車需要と人口との関係を上手く扱うため、高度な抽象表現を生成できる深層学習の手法によって、需要予測を行うこととした。

5. 提案手法

5.1 特徴量の設計

本稿では入力データとして、タクシーデータ、人口データ、天候データ、時刻データの4種類のデータを用いる。タクシーデータは、個々のタクシーに設置されたGPSデバイスより5~10秒に1回の周期で、緯度、経度、客車状態(0,1)が記録される。この情報から、タクシーの乗車、または、降車がなされた緯度経度と該当時刻の抽出を行った。人口データには、4章で説明したリアルタイム人口データを用いる。天候データは、特にタクシー需要に大きく影響を与えられと考えられる雨量のデータを用いる。利用した天候データは、5分ごと1kmメッシュ全国合成レーダGPVデータである。このデータでは、各時刻における該当1km

表 1 データの詳細について

Table 1 Data Details.

対象地域	東京 23 区, 武蔵野市, 三鷹市	
期間	2015 年 4 月 1 日 ~ 2016 年 9 月 14 日	
タクシーデータ	台数 取得頻度	4400 台 5~10 秒毎
人口データ	解像度 取得頻度	500m 10 分毎
天候データ	解像度 取得頻度	1000m 5 分毎
時刻データ	記録情報	10 分毎の時刻 平日休日フラグ

メッシュの降水量が記録されている。また、時刻データとして、10分ごとの時刻情報と平日と休日について(0,1)で表現した平日休日フラグ情報を用いる。各データの詳細は表1のとおりである。

5.1.1 空間解像度/時間解像度の変換

各データで異なる空間解像度、時間解像度をあわせるため、データの集約を行った。タクシーデータについては、過去の乗車数だけでなく、降車数も将来の乗車数に影響を及ぼすと考えた。そこで目的変数としては将来30分間の乗車数を、説明変数としては過去の乗車数および降車数の双方をそれぞれ利用した。また、グリッド単位で扱えるようにするため、500m/10分ごとに、将来30分間ウィンドウ幅の乗客の乗車数の総和、および、乗客の降車数の総和を計算した。人口データは、500m/10分ごとの人口データを利用している。人口データは10分ごとに各500mグリッドのその瞬間の人数を推定したデータである。天候データとして用いた雨量データは1,000m、5分ごとの降水量データとして記録されている。同データを1,000mごとから500mごとのデータとするため、4で割ることで空間方向に4分割し、5分ごとから10分ごとのデータへと時間方向に和を求めることで、500mごと10分ごとのデータへと変換を行った。

5.1.2 時系列特徴量/統計特徴量

タクシーの乗車数は季節、曜日(平日・休日・休前日)、および時刻によって変化する。このような時系列による変化を予測するには、現在の時刻情報、短期間の時系列トレンド、長期間の時系列トレンドの情報をそれぞれ考慮することが有効であると考えた。現在の時刻情報として、平日休日フラグおよび時刻を用いる。平日休日フラグは当日の平日・休日判定、翌日の平日・休日判定に基づいた2bitの1-of-kのデータで表現した。時刻情報は0~24時の形で用いると0と24が同時刻であるにもかかわらず大きな差を生じてしまう。したがって本稿では、式(1)に基づいて時

刻を (α, β) による 2 次元で表現した. また, 短期間のトレンドとして, タクシーデータ, 人口データ, 天候データのそれぞれについて, 予測対象時刻から 30 分前, 60 分前, ..., 6 時間前と順に 30 分ずつ遡った計 13 期分の過去のデータを用いる. 長期間のトレンドとして, 過去 1 年間のタクシー乗車数, 降車数, 人口について各 500 m グリッド, 曜日ごと, 時刻ごとに平均を計算し, 予測対象時刻に該当する統計量を利用する.

$$\alpha = \sin \frac{\pi}{12} t, \quad \beta = \cos \frac{\pi}{12} t, \quad \{0 \leq t < 24\} \quad (1)$$

5.1.3 データの正規化

ニューラルネットワークの活性化関数は, 入力データが 0 付近にあるときに機能する. 上記手順で作成された各データについて, 式 (2) の計算を行うことで, $-1 \leq x_i \leq 1$ を満たすようにデータの正規化を行った.

$$\hat{x}_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \times 2 - 1 \quad (2)$$

5.2 深層学習による需要予測モデル

Stacked denoising Autoencoders を用いたディープラーニングによるタクシー将来需要予測手法について説明する. Stacked Autoencoders [17] は Autoencoder [18] を積層したニューラルネットワークにより, 学習を行うモデルである.

5.2.1 Autoencoder による特徴抽出 (pre-training)

Autoencoder は入力データの復元を試みるニューラルネットワークの手法である. 図 4 に Autoencoder の模式図を示す, この図では, 入力層, 隠れ層, 出力層を 1 つずつ持つニューラルネットワークが表現される.

ここで, タクシーデータを x_a , 人口データを x_b , 天候データを x_c , 時刻データを x_d とするとき, 入力ベクトル $x = \{x_a^1, x_a^2, \dots, x_a^{N_a}, x_b^1, x_b^2, \dots, x_b^{N_b}, x_c^1, x_c^2, \dots, x_c^{N_c}, x_d^1, x_d^2, \dots, x_d^{N_d}\}$, $x_a^i, x_b^j, x_c^k, x_d^l \in R$ が与えられるとき, Autoencoder は, まず式 (3) のエンコーダ $y = f_\theta(x)$ を用いて入力ベクトル x を変換した出力 y を求める. 次に式 (4) のデコーダ $z = g_{\theta'}(y)$ を用いて, 隠れ層の出力 y を入力として, \hat{x} を出力する. Autoencoder では, ニューラルネットワークの説明変数, 目的変数にそれぞれ同じ値を入力した




図 4 Autoencoder の模式図

Fig. 4 Schematic diagram of Autoencoder.

教師なし学習による事前学習を行うことで, エンコーダとデコーダに変換と復元の機能を実現する.

$$y = f_\theta(x) = s(\mathbf{W}x + b) \quad (3)$$

$$z = g_{\theta'}(y) = s(\mathbf{W}'y + b') \quad (4)$$

式 (3) のパラメータは $\theta = \{\mathbf{W}, b\}$, 式 (4) のパラメータは $\theta' = \{\mathbf{W}', b'\}$ で表現される. ここで, \mathbf{W} は重み行列, b はバイアスベクトル, \mathbf{W}' は逆変換の重み行列, b' は逆変換のバイアスベクトルとなる. $s(x)$ には非線形の活性化関数を用いる. 本研究では, ReLU 関数 $s(x) = \max(0, x)$ を利用する.

復元誤差 $L(x, \hat{x})$ を最小化するため, 下記の目的関数を用いて, モデルのパラメータ θ, θ' を最適化する.

$$\begin{aligned} \theta, \theta' &= \operatorname{argmin}_{\theta, \theta'} L(x, z) \\ &= \operatorname{argmin}_{\theta, \theta'} \frac{1}{M} \sum_{i=1}^M (x_i - g(f(x_i)))^2 \end{aligned} \quad (5)$$

このようにして獲得されるエンコーダの出力 y により, 入力 x を復元するための情報を保持したまま, 隠れ層のノード数の増減が可能となる. したがって, Autoencoder は元の入力から役立つ情報を抽出することを実現する機能を有する.

5.2.2 Autoencoder の積層によるモデル作成 (fine tuning)

Stacked Autoencoders のモデルでは, 下層の Autoencoder の出力結果を入力として用いることで, Autoencoder の層を積層し, 深いネットワーク構造を表現する. ここで, 層数が l である Stacked Autoencoders について考える. Stacked Autoencoders の初めの層では, 入力データを用いた Autoencoder を学習する. 初めの層の学習結果を獲得した後は, k 番目の隠れ層の出力を, $k+1$ 番目の隠れ層の入力として用いる. このようにして, 複数の Autoencoder を積層が実現される.

本稿のタクシー需要予測では, 将来の乗車需要を回帰問題として解くアプローチをとる. このため, 作成された Stacked Autoencoders モデルの最終層に回帰の予測器を加える. 目的変数として, 当該グリッドの 30 分先の乗車需要を示すタクシーの乗車数データを入力することで, 教師あり学習を行う. この設定で, ネットワークの再学習 (ファインチューニング) を実施することで, ネットワーク全体で, タクシーの乗車需要の予測値を出力するアーキテクチャを実現する. 図 5 に Stacked Autoencoders の予測器の模式図を示す.

5.2.3 Sparse Autoencoder

Autoencoder で表現されるエンコーダの出力結果 y は, 入力 x の情報を保存するが, それだけでは, 有用な情報が抽出されることは保証されない. なぜなら, 隠れ層のノ

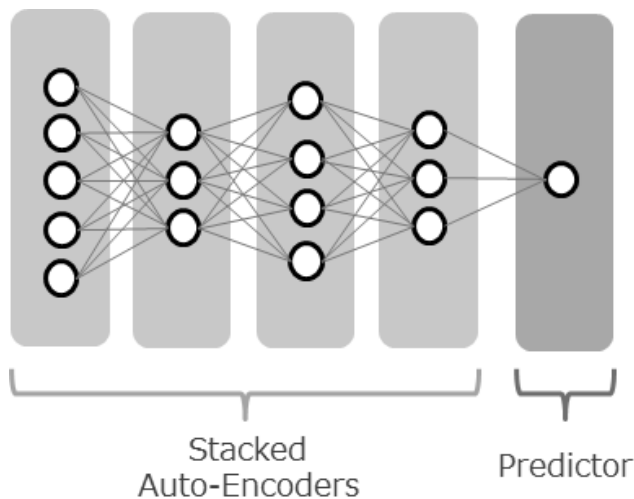


図 5 Stacked Autoencoders による予測器

Fig. 5 Schematic diagram of Stacked Autoencoders.

ド数が入力層と等しい Autoencoder の最適化では、恒等関数が学習される可能性があるからである [18]. したがって、入力データのノイズから有用な情報を分離するには、更なる制約が必要である.

入力層の次元数を d , 隠れ層の次元数を d' とした際、 $d' < d$ とする変換を行う場合を考える. この場合、エンコーダの出力 y は、入力 x よりも少ない次元数で x の復元を実現するため、次元圧縮と呼ばれる. しかしながら、低次元の y からの復元 x は、復元誤差が大きくなり、元の x よりも情報量が失われる可能性がある.

これに対し、 $d' > d$ とする変換を行う場合を考える. この場合、エンコーダの出力 y は、入力 x よりも次元数の多いスパース表現によって学習される. スパース表現では、次元圧縮より正確に元の情報を保持できる場合があり、代替として注目を浴びてきた [19]. 明示的に次元数を落とす場合とは異なり、スパース表現では多くの 0 値を含むことで、隠れ層ノードで内的に次元削減が表現される. このようなデータがスパースに表現される Autoencoder を Sparse Autoencoder という [19].

スパース表現の獲得を促進するため、目的関数に制約を付加する. 制約条件は重み \mathbf{W} の平均を正則化項として加算することで与える. ノード i の重みを \mathbf{W}_i , 隠れ層 j のノード数を N_j , 隠れ層の総数を D , 正則化係数を ρ とすると、制約を加味した目的関数 L' は式 (6) のようになる. ここで、正則化係数 ρ は 0 に近い小さな値を用いることとする.

$$L'(x, z) = L(x, z) + \rho \sum_{j=1}^D \left(\frac{1}{N_j} \sum_{i=1}^{N_j} |\mathbf{W}_{ji}| \right) \quad (6)$$

5.2.4 Denoising Autoencoder

次元圧縮, Sparse Autoencoder とは異なるアプローチとして、入力データにノイズを加えたうえで、変換・復元を行う Denoising Autoencoder の手法がある [2]. Denoising

Autoencoder では、欠損が加わったデータから元データを復元する処理を行うことで、入力データが元々持つノイズや欠損に対してロバストになること、および、元データの復元において重要な情報が優先的に抽出されることを期待できる.

Denoising Autoencoder のアルゴリズムでは、入力データに欠損を加えたうえで、欠損が加わる前の元データの復元を行う. x に欠損を加えた \hat{x} を取得する. \hat{x} に対して Autoencoder の演算を行うことで、復元値 z を算出する.

$$y = f_{\theta}(\hat{x}) = s(\mathbf{W}\hat{x} + b) \quad (7)$$

$$z = g_{\theta'}(y) = s(\mathbf{W}'y + b') \quad (8)$$

復元された z について、欠損が加わる前の x との平均誤差の最小化を実施する. これによって、欠損のない入力 x を用いる場合よりも有用な情報の抽出が実現される.

$$\theta, \theta' = \underset{\theta, \theta'}{\operatorname{argmin}} L(x, z) \quad (9)$$

5.2.5 データのミニバッチ化

ネットワークの汎化性能を上げる手法としてミニバッチ化という手法が知られている [21]. 本手法でもミニバッチを採用する. これまでの手順で作成された各データを 1 つのデータセットとしてまとめ、500 m/10 分ごとにデータセットからランダムに取得したミニバッチを取得する.

またバッチごとのデータの分布の違いを考慮するため、活性化関数の前段で Batch Normalization [22] を用いることで、データの正規化を実施した.

6. 実験

提案法のディープラーニングを用いて、タクシーの将来需要予測の実験を行う.

6.1 データセット

実験で用いるデータは、5.1 節で作成したタクシーデータ、人口データ、気象データ、および時刻データである. ここでは、東京 23 区および武蔵野市、三鷹市を含むエリアを対象とし、2015 年 4 月 1 日～2016 年 8 月 31 日を学習用データ、2016 年 9 月 1 日～2016 年 9 月 14 日を評価用データとして利用する.

6.2 評価方法

実験の評価では、10 分ごと、各 500 m グリッドに関して、ある対象の時刻から将来 30 分間に同エリアで、何台のタクシーが乗客を乗せることができたかを計算する.

提案法の有用性を評価するため、二乗平均平方根誤差 (RMSE) の指標を用いて評価を行う. 定義を以下に示す. ここで、 t_i は、タクシーの実際の乗車数、 \hat{t}_i は予測したタクシーの乗車数である.

$$RMSE = \left(\frac{1}{n} \sum_{i=1}^n (t_i - \hat{t}_i)^2 \right)^{\frac{1}{2}} \quad (10)$$

6.3 Stacked denoising Autoencoders のパラメータ探索

Denoising Autoencoder の深層ネットワークの予測性能はネットワーク構造を規定する各ハイパーパラメータの設定に依存する。ハイパーパラメータは各層ごとに多数あり、ハイパーパラメータどうしも互いに関係しているため、組合せが多岐にわたる。探索方法としてよく知られているグリッドサーチによる全探索は、離散的に設定されたパラメータ群から探索を行う物であるが、探索範囲が限られるため、十分に探索が実施された場合、ランダムサーチの精度に劣ることが知られている [23]。そこで本稿では Python の hyperopt モジュールを利用し、ランダムサーチによるハイパーパラメータ探索を実施した [24]。

探索対象としたハイパーパラメータは、5.2.3 項で説明した d に相当する各層の隠れ層のノード数、denoising Autoencoder のノイズ係数、Sparse Autoencoder の正則化係数、Dropout の割合、バッチサイズである。それぞれのパラメータについて表 2 の範囲で探索を実施した。

6.4 実験結果

実験の深層学習では、最適化関数として Adam を用いた学習を実施した。3 層、4 層、5 層の隠れ層を持った SdA について 1,000 モデルずつパラメータ探索および学習を行うことで、精度評価を行った。表 3 および図 6 に評価結果を示す。表 3 は、評価期間中の全データに関する平均二乗絶対誤差の結果である。表 3 からは 3 層の精度が最も高いことが分かる。しかしながら、図 1 に示したとおり、各乗車実績数には出現回数に大きな偏りがあり、乗車実績数 0 の際の予測誤差が、平均精度に対して支配的な影響を及ぼしていると考えられる。このため、表 3 による評価だけでは、必ずしも公平な評価をすることはできない。そこで、図 6 では乗車実績数ごとの予測精度を示している。結果から、乗車実績数 0 では、3 層の SdA による予測結果が最も精度が高いことが分かるが、乗車実績数 1 では、4 層のネットワークによる予測精度が高く、乗車実績数 2 から 5- では、それぞれのモデルについて、ほぼ同等の精度であり、10- から 30- では、わずかに 3 層の SdA の精度が高いことを確認できる。乗車数 40 以上では、4 層のネットワークの乗車実績数の精度が最も高くなっている。このことから、比較的、乗車実績数の小さい場合は、モデルが単純な方が予測をしやすと考えられ、少ない層数のモデルが僅かに高精度となるものの、どの層数の SdA でも近い精度で予測ができると考えられる。一方で、乗車実績数の大きい領域では、4 層の SdA の精度が最も高く表れている。

表 2 ハイパーパラメータの探索範囲
Table 2 Hyper parameters search space.

ハイパーパラメータ	探索範囲
Denoising Autoencoder のノイズ係数	$0 \leq q_d \leq 0.2$
Sparse Autoencoder の正則化係数	$0 \leq \rho \leq 0.02$
Dropout の割合	$0.3 \leq \epsilon \leq 0.7$
バッチサイズ	$50 \leq BS \leq 200$
隠れ層のノード数	$10 \leq N \leq 1000$

表 3 層数ごとのモデル評価結果

Table 3 Model evaluation results for each number of layers.

手法	RMSE
3 層	1.295
4 層	1.378
5 層	1.399




図 6 各総数の SdA による乗車実績値ごとの予測精度
Fig. 6 Predictive accuracy for each boarding value by SdA of each layer number.


これは、よりモデルの表現力が低い 3 層では、需要を予測するために必要な情報を十分抽出することができなかったこと。また、モデルの表現力が高い 5 層では、モデルが複雑化し、ハイパーパラメータの探索範囲が広がりすぎた結果、同じ学習時間内では十分な予測性能を得ることができなかったか、あるいは、モデルが過剰な表現力を持ったことから、過学習が行われてしまった可能性があると考えられる。

次に、タクシー乗車需要の予測に関して、各種データがどのように影響しているかを確認するため、入力するデータ種別を変更する実験を行った。ここでは、タクシーデータのみでのモデル、タクシーデータと人口データによるモデル、タクシーデータと気象データによるモデル、3 種すべてのデータによるモデルの計 4 パターンについて、4 層の SdA に関して、パラメータ探索および学習を 1,000 モデルずつ行った。なお、時刻データについては、すべてのパ

表 4 異なる入力データによるモデル評価結果

Table 4 Model evaluation results for different input data.

データ		RMSE
A	タクシー	1.513
B	タクシー + 人口	1.370
C	タクシー + 天候	1.351
D	全データ	1.378



A: タクシーデータ, B: タクシーおよび人口データ, C: タクシーおよび天候データ, D: 全データ

図 7 異なる入力データによる SdA の乗車実績値ごとの予測精度

Fig. 7 Predictive accuracy for each boarding value of SdA with different input data.

ターンにおいて入力として用いることとした。これらの異なる入力データによる学習済みモデルから、それぞれ最も高い予測精度を示したモデルに関して、乗車実績数ごとの予測精度を表 4 および図 7 に示す。表 4 は、評価期間中の全実績値について平均二乗絶対誤差を計算した結果である。表 4 の結果から、タクシーデータのみによる学習に比べ、タクシーデータに人口データや天候データを加えた場合に、予測精度が高まることを確認できる。しかしながら、表 3 の実験と同様に、表 4 では、出現頻度が最も高い乗車実績数 0 の誤差が大きく影響している。そこで、図 7 に示すように乗車実績数ごとの精度についても確認を行う。

図 7 から、乗車実績数 0 から 4- においては、予測精度の差は軽微であることが確認できる。また、乗車実績数 5- 以上では、タクシーデータのみで作成されるモデルよりも、人口データや天候データ、または全データを加えて学習を行ったモデルの予測精度が高いことを確認できる。また、乗車実績数 5- から 40- においては、タクシーデータに天候データを加えたモデルの予測精度が最も高い。一方、乗車実績数 50- 以上においては、全データによるモデルの予測精度が最も高くなることを確認することができる。この結果から、人口データの精度に対する寄与は、より乗車実績数が多い、需要の高いグリッドにおいて影響が大きくなる傾向にあるということ。また、需要の高いグリッドでは、天候データの寄与する割合が大きくなるが、一定以上の需

要を超えるエリアでは、天候変化だけでは十分説明することのできない需要の変化があり、このような変化について、人口データを用いることによって予測精度を向上されたのではないかと考えられる。

また、乗車実績数の値が 70- をピークとして、それ以上の乗車実績数が観測されるエリア・時間帯においては、需要予測の誤差が低下し、精度が改善している傾向がある。乗車実績数 80 以上となる乗車需要は、図 1 に見られるように、全域・全時間帯において最も高い需要であり、頻度がきわめて少ない。このような高需要は、たとえば、大きな駅で周期的に表れる需要のピークのような類似したパターンの中で表れるものである。これに対して、70- までの乗車実績数は様々なエリア・時間帯において出現するものであり、かつ、周期的な需要のピークだけでなく、異常値ととれるピーク需要も含まれている。このような需要には様々な要因が関係していると考えられ、80- 以上となる場合に比べ、高精度に需要予測を行うことがより難しい。

さらに、図 8 に東京のいくつかの特定地点における予測値と実測値の時系列グラフの例を示す。ここでは、乗車実績数を基準として、乗車実績数の最も大きい部類のエリアである (a)、乗車実績数の標準的な部類のエリアである (b), (c), (d), (e)、乗車実績数が低いものの 0 ではないエリアとして (f) を選択することで、高需要から低需要までの代表的なエリアにおける需要予測結果の遷移を示した。また、乗車実績数の標準的なエリアとしては、曜日ごとに大きく需要が変化するエリアである (c), (d) と、曜日にかかわらず周期的に需要が変化するエリアである (b), (e) の例を示す。

(a) のように需要が 80 付近を示すような高需要エリアは、今回学習・予測に用いたエリア中では最も需要の高いエリアの 1 つである。グラフから、ピーク以外の時間帯では、小さい誤差で予測できていることが分かる。一方で、ピーク時においては予測結果が下振れしてしまうことが見られた。(b), (c), (d), (e) のエリアは、平均乗車回数が上位 10% となる需要の高いエリアである。このようなエリアでは、全域ではおおむね需要変化に追従することができている。また、ピーク時の下振れは発生しているものの、(a) の場合と比較するとその比率が緩和されている様子が確認できる。(c) の 9 月 13 日や、(e) の 9 月 11 日において、周期的な需要から外れる突発的な高需要が生じているケースでは、周期的な需要から外れているため、予測が外れてしまっている。また、(c), (d) について、曜日によって需要が異なるような場合においては、需要の変化を追従し、正しく予測できていることを確認できる。低需要エリアである (f) では、稀に 3~4 程度の乗車が生じる。このような乗車需要は、日中に生じるなどの大まかな周期傾向はあるものの、周期性がある訳ではなく突発的な需要として現れる。このケースでは、需要の高まる日中に 1~2 程度として乗

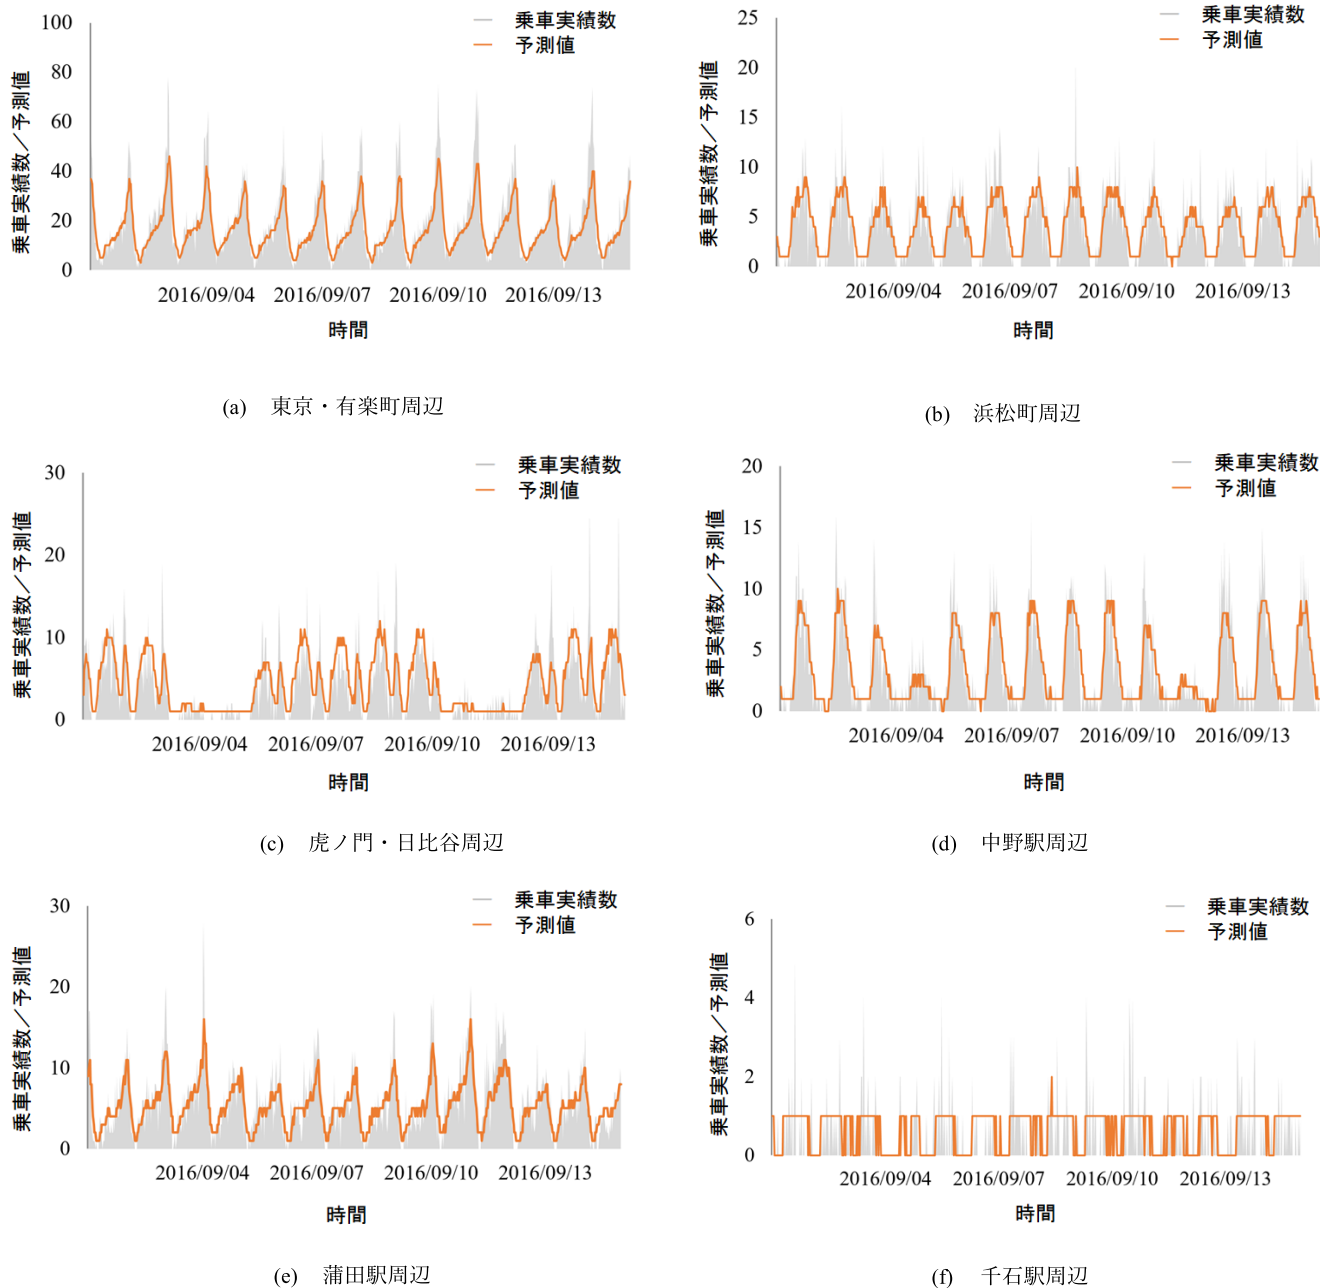


図 8 ある地点におけるタクシー需要の予測値・実測値の比較グラフ (横軸: 時刻, 縦軸: 乗車数)

Fig. 8 Comparison of predicted and actual taxi boarding counts at a certain location (X-axis: time, Y-axis: number of boarding).

車需要を予測しており下振れる傾向があった。(a)~(f)に見られる周期的ではない乗車の需要は、どのようなグリッドにおいても生じる可能性のあるものである。このような需要について予測精度を高めるには、周期性の考慮だけではなく、異常検知に基づいた需要予測手法の導入や、イベントなどに関する、さらなる外部データの追加を行うことが必要となると考える。

7. リアルタイム予測についての議論

提案法のタクシー乗車需要予測をリアルタイムに行うには、各種データをリアルタイムに取得する必要がある。本

稿で扱ったタクシーデータ、人口データ、気象データ、時刻データは、直前 30 分前を含めて、それより以前のデータであれば作成可能である。したがって、提案法では、5.1.2 項で示したように直前 30 分前、および、それ以前の過去データを入力データとして扱う設計とした。このため提案法を用いることで、実際に需要予測をリアルタイム化した場合にも、同等の精度で予測することが可能だと考えられる。

より高精度に需要予測を行うためには、データの取得遅延をさらに短期間にするすることで、より直近のデータを取得する方法が考えられる。提案法で用いたデータでは、人口データが最もデータ量が多く、作成時の計算負荷が高いた

め遅延が生じるものである。したがって、計算機を増強することや、人口統計データの集計方法に簡略化し、簡略化された人口統計データを工夫して前処理することで、元データと同等の精度で予測を行うことなどによって、人口データの取得遅延をより短時間にしつつ、さらに高精度な需要予測を行う方法も考えられるだろう。

また提案法では、30分先までの将来の乗車需要の予測を行った。より将来の需要予測を行う場合では、取得される各種データと予測対象時刻との乖離が広がることとなるため、データ間の相関性が失われ、需要予測の精度が下がると考えられる。たとえば、お祭りなど、特殊な乗車需要が発生する場合、通常の周期的な需要とは異なることとなり、過去から直近までのタクシー、人口、雨量の変化だけでは予測することが難しいと考えられる。このような場合では、たとえばSNSから取得される未来のイベント情報を用いることや、該当エリア以外も含めたより広い範囲かつ、詳細な粒度で、人流のモデル化を行うことで、より先の将来需要をモデル化するための工夫を加える方法が考えられる。

8. まとめ

本稿では、Stacked denoising Autoencodersを用いたタクシー需要予測手法について提案した。実験では、タクシー乗降履歴、人口、天候、時刻情報を組み合わせた位置情報データを用いた学習を行った。実験では特に乗車数の多い需要の高いエリア・時間帯において、人口データが精度向上に寄与することを示した。

今後の課題は、すべてのドライバーに同じ情報を見せるとタクシーの向かう場所が不均衡になり、客車効率が下がる可能性がある点である。このため、個々のドライバーの効率的な配車制御が必要となる。

謝辞 本研究を実施するにあたり、タクシーデータの提供や様々な相談をさせていただいた東京無線協同組合の皆様に謹んで感謝の意を表す。

参考文献

- [1] 東京のタクシー 2017: 東京ハイヤー・タクシー協会, 入手先 (<http://www.taxi-tokyo.or.jp/datalibrary/pdf/hakusyo2017all.pdf>) (参照 2018-04-10).
- [2] Li, B. et al.: Hunting or waiting? Discovering passenger-finding strategies from a large-scale real-world taxi dataset, *International Conference on Pervasive Computing and Communications Workshops*, pp.63–68, IEEE (2011).
- [3] Powell, J.W. et al.: Towards reducing taxicab cruising time using spatio-temporal profitability maps, *International Symposium on Spatial and Temporal Databases*, pp.242–260, Springer (2011).
- [4] Tong, Y. et al.: The simpler the better: A unified approach to predicting original taxi demands based on large-scale online platforms, *International Conference on Knowledge Discovery and Data Mining*, pp.1653–

- 1662, ACM (2017).
- [5] LeCun, Y., Bengio, Y. and Hinton, G.: Deep learning, *Nature*, Vol.521, No.7553, p.436 (2015).
- [6] Vincent, P. et al.: Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion, *Journal of Machine Learning Research*, Vol.11, pp.3371–3408 (2010).
- [7] Lee, J., Shin, I. and Park, G.-L.: Analysis of the passenger pick-up pattern for taxi location recommendation, *International Conference on Networked Computing and Advanced Information Management*, pp.199–204, IEEE (2008).
- [8] Yue, Y. et al.: Mining time-dependent attractive areas and movement patterns from taxi trajectory data, *International Conference on Geoinformatics*, pp.1–6, IEEE (2009).
- [9] Chang, H.-W., Tai, Y.-C. and Hsu, J.Y.-J.: Context-aware taxi demand hotspots prediction, *International Journal of Business Intelligence and Data Mining*, Vol.5, No.1, pp.3–18 (2009).
- [10] Moreira-Matias, L. et al.: Predicting taxi-passenger demand using streaming data, *Transactions on Intelligent Transportation Systems*, Vol.14, No.3, pp.1393–1402, IEEE (2013).
- [11] Moreira-Matias, L. et al.: On predicting the taxi-passenger demand: A real-time approach. Portuguese Conference on Artificial Intelligence, pp.54–65, Springer (2013).
- [12] Zhao, K. et al.: Predicting taxi demand at high spatial resolution: Approaching the limit of predictability, *International Conference on Big Data*, pp.833–842, IEEE (2016).
- [13] Davis, N., Raina, G. and Jagannathan, K.: A multi-level clustering approach for forecasting taxi travel demand, *International Conference on Intelligent Transportation Systems*, pp.223–228, IEEE (2016).
- [14] Shao, D. et al.: Estimating taxi demand-supply level using taxi trajectory data stream, *International Conference on Data Mining Workshop*, pp.407–413, IEEE (2015).
- [15] Afian, A., Odoni, A. and Rus, D.: Inferring unmet demand from taxi probe data, *International Conference on Intelligent Transportation Systems*, pp.861–868, IEEE (2015).
- [16] Li, X. et al.: Prediction of urban human mobility using large-scale taxi traces and its applications, *Frontiers of Computer Science*, Vol.6, No.1, pp.111–121 (2012).
- [17] Lv, Y. et al.: Traffic flow prediction with big data: A deep learning approach, *Transactions on Intelligent Transportation Systems*, Vol.16, No.2, pp.865–873, IEEE (2015).
- [18] Hinton, G.E. and Salakhutdinov, R.R.: Reducing the dimensionality of data with neural networks, *Science*, Vol.313, No.5786, pp.504–507 (2006).
- [19] Andrew, N.: Sparse autoencoder, CS294A Lecture notes, p.72 (2011).
- [20] Vincent, P. et al.: Extracting and composing robust features with denoising autoencoders, *International Conference on Machine Learning*, pp.1096–1103, ACM (2008).
- [21] Li, M. et al.: Efficient mini-batch training for stochastic optimization, *International Conference on Knowledge Discovery and Data Mining*, pp.661–670, ACM (2014).
- [22] Ioffe, S. and Szegedy, C.: Batch normalization: Accelerating deep network training by reducing internal covari-

ate shift, *International Conference on Machine Learning*, pp.448–456, ACM (2015).

- [23] Bergstra, J. and Yoshua, B.: Random search for hyperparameter optimization, *Journal of Machine Learning Research*, Vol.13, pp.281–305 (2012).
- [24] Bergstra, J., Yamins, D. and Cox, D.D.: Hyperopt: A python library for optimizing the hyperparameters of machine learning algorithms, *Python in Science Conference*, pp.13–20 (2013).
- [25] モバイル空間統計ガイドライン, 入手先 (<https://www.nttdocomo.co.jp/corporate/disclosure/mobile.spatial-statistics/guideline/index.html>) (参照 2018-04-10).

推薦文

本稿では、タクシーの将来需要の予測とそれに基づく運行支援手法が提案されている。タクシー運行データ、リアルタイム人口統計データ、雨量データを併用し、26.77%の誤差での予測を達成している。予測手法として Stacked denoising Autoencoder という時空間特徴量の考慮される深層学習の一種を用いている。様々なモバイル端末が自由に移動するような環境を各種統計データの併用により予測するための筋道がたてられており、モバイルコンピューティング分野の発展に寄与すると考え、情報処理学会論文誌へ推薦する。

(モバイルコンピューティングとパーベイシブシステム
研究会主査 河口信夫)



深澤 佑介 (正会員)

株式会社 NTT ドコモ。2002 年東京大学工学部卒業。2004 年東京大学大学院工学系研究科システム創成学科修士課程修了。同年株式会社 NTT ドコモ入社。2011 年東京大学大学院工学系研究科博士後期課程修了。同年 10 月より東京大学人工物工学研究センターにて協力研究員兼任。2017 年より客員研究員兼任。現在に至る。Web マイニング、パーソナライゼーション、確率モデルに関する研究開発を行っている。IEEE, 人工知能学会各会員。博士(工学)。



石黒 慎 (正会員)

株式会社 NTT ドコモ。2014 年東京大学大学院学際情報学府修士課程修了。同年株式会社 NTT ドコモ入社。2018 年 10 月より東京大学大学院工学系研究科博士後期課程入学。人流データ分析に基づいた位置情報サービスに関する研究開発に従事。

る研究開発に従事。



菊地 悠 (正会員)

株式会社 NTT ドコモ。2000 年東京大学精密機械工学科卒業。2002 年同大学院博士前期課程修了。同年株式会社 NTT ドコモ入社。SNS および位置情報解析の研究開発に従事。