

災害時の人口集中エリア抽出による指定外避難所検出の検討

落合 桂一^{1,a)} 寺田 雅之¹ 花島 誠人² 佐野 浩彬² 白田 裕一郎²

概要: 2016年に発生した熊本地震では自治体により予め指定されている避難場所・避難所だけでなく、やむを得ず指定外の施設（以下、指定外避難所）に避難した住民も多かった。また、新型コロナウイルスの流行により、密を避けた避難を行うため避難所の収容人数が減少する可能性があり、より分散した避難となる可能性がある。指定外避難所では、発災初期に行政の支援が届かないという問題がある。そこで本稿では、携帯電話ネットワークの運用データから生成したリアルタイムな人口変動のデータを利用し、災害発生時に避難者が集まっている場所を抽出することにより、指定外避難所を検出することができるか検討を行う。具体的には、オートエンコーダを用いて災害発生後の人口推移の異常を検出することで指定外避難所の検出を試みる。熊本地震における避難所のデータを利用し、提案手法の有効性を評価する。

1. はじめに

日本では毎年のように自然災害が発生しており [1], 災害への備えが重要である。地震については東日本大震災以降も 2016 年の熊本地震, 2018 年の大阪府北部地震および北海道胆振東部地震などマグニチュード 6 を超える大きい地震は継続的に発生している。風水害については、大雨や短時間強雨の回数が増加していることが報告されていたり [1], 台風による被害も想定されるため今後も災害対応が必要である。2016 年に発生した熊本地震では自治体が予め指定した避難場所・避難所だけでなく、やむを得ず指定外の施設（以下、指定外避難所）に避難した住民も多かった [2]。また、新型コロナウイルスの流行により、密を避けた避難を行うため避難所の収容人数が減少する可能性があり、より分散した避難となる可能性がある。指定避難所の場合、場所は予めわかっているため避難者数がわかれば救援物資を配布するなど行政の支援を届けることができる。一方、指定外避難所の場合、場所が特定できないとそのような行政の支援を行うことができなくなるおそれがある。特に発災初期に迅速に指定外避難所を発見することが重要な課題である。

指定外避難所を検出するために、携帯電話の位置情報を利用して平常時の人口より混雑している場所を検出する取り組みが行われている [3], [4]。Yabe ら [3] の研究では、Yahoo Japan のアプリで収集した GPS データをメッシュ

単位に集計したメッシュ人口に対して、統計的な異常検知を適用することで指定外避難所（Yabe らの研究では隠れ避難所と呼んでいる）を検出している。この研究では指定外避難所の正解データでの評価は行われていない。舩越ら [4] は、Yabe らの手法を携帯電話ネットワークから推定された人口データ（モバイル空間統計）に適用し、熊本市から提供された指定外避難所のリストを正解として検出精度を評価している。精度評価の結果、検出できる避難所が半数に満たないことが報告されている。これらの手法では異常検知の対象として、深夜時間帯の人口（午前 4 時）のみを利用しているが、地震発生後は昼間の人口にも変動があったと想定される。

そこで本稿では、特定の時間帯のみではなく地震発生後の一定期間の人口を異常検知に用いることで検出精度を向上させる手法を提案する。具体的には、人口の時系列推移の波形が平常時と異なることを捉えるため、オートエンコーダ（Autoencoder, 以下 AE）を用いた異常検知を提案する。提案手法では地震発生前の各メッシュの人口データを時間区間 T ごとに分割し、その人口を復元するようにオートエンコーダを学習する。その後、地震後の人口データを同じ時間区間で区切り、学習済みの AE に入力し、入力した人口推移と復元した人口推移の誤差から異常を判定する。AE では 1 つのモデルで対象範囲全体の異常を判定するため、人口推移をそのまま学習に用いると、全体として平均的な推移を学習し、異常検知の精度が低下することが考えられる。そこで、人口推移をもとにメッシュをクラスタリングし、AE に人口推移に加えてクラスタの情報を入力することを提案する。提案手法の精度を指定および指定

¹ 株式会社 NTT ドコモ, NTT DOCOMO, INC.

² 国立研究開発法人防災科学技術研究所, National Research Institute for Earth Science and Disaster Resilience

a) ochiaike@nttdocomo.com

外避難所のリストを用いて評価した。その結果、既存研究では Recall が 0.181 であったところ、提案手法では 0.578 と約 3.2 倍となることを確認した。また、実災害での活用を想定しモデル学習時間について評価を行った。熊本市と益城町の 2 市町 (500m メッシュで 2005 メッシュ) を対象とした場合、学習に用いるデータを地震発生前 2 週間とするとモデル学習に約 34.2 秒で処理が完了した。対象地域および学習期間を拡大し、県全域を対象に 2 ヶ月分の人口データで学習した場合は、モデル学習に約 10 分の時間を要した。これらの結果から、各地域に対するデータの前処理を事前に行っておくことで、発災時に住民が避難した後の人口データ生成後、概ね 10 分で推定が可能であることを確認した。

本研究の貢献は以下の通りである。

- 指定外避難所検出のタスクにおいて、特定時間帯の人口異常のみでなく人口推移の異常を捉えるために AE を利用することを提案した。
- 熊本地震を事例として評価を行い、AE を用いた提案手法が、特定時間帯の異常をもとに指定外避難所を検出する手法よりも検出できる避難所件数が多いことを確認した。
- 発災時に住民が避難した後の人口データ生成後、概ね 10 分で推定が可能であることを確認した。

2. 提案手法

提案手法は大きく 3 つのパートから構成される。

- (1) 平常時人口によるメッシュのクラスタリング (2.1 節)
- (2) 平常時人口による AE モデルの学習 (2.2 節)
- (3) 学習済み AE モデルを用いた異常判定 (2.3 節)

本章では提案手法の各パートの詳細を説明する。

2.1 平常時人口によるメッシュのクラスタリング

都市の中にはオフィス街、住宅街、繁華街などそれぞれの場所の機能が存在すると考えられる。本研究では、それらの各機能が人口推移に反映されるという想定のもと、各メッシュの人口推移を特徴量としてメッシュのクラスタリングを行うことで、類似した都市機能のメッシュをクラスタリングする。メッシュ m 、時刻 t の人口を $p_{m,t}$ とすると、期間 $T = [t_s, t_e]$ の人口推移は $pop_{m,T} = \{p_{m,t_s}, p_{m,t(s+1)}, \dots, p_{m,t_e}\}$ と表せる。各メッシュの人口推移 $pop_{m,T}$ に対して k-means クラスタリング [5] を適用することでメッシュをクラスタリングする。k-means クラスタリングでは、あらかじめクラスタ数を決めておき、各クラスタの中心と各データ点との距離を計算し最も近いクラスタにそのデータを所属させ、その後クラスタ中心を再計算するという処理をクラスタ中心が収束するまで繰り返すアルゴリズムである。

2.2 平常時人口によるオートエンコーダの学習

AE は入力データと出力データが同じようになるようニューラルネットワークを学習させることで入力データの次元圧縮を行う手法である [6]。AE では次元圧縮することで多量の特徴量から入力データの説明に有効な圧縮された特徴量の抽出が期待できる。AE の入力を $\mathbf{x} \in \mathbb{R}^d$ とし、圧縮された隠れ層ベクトルを $\mathbf{y} \in \mathbb{R}^{d'}$ 、エンコーダを $\mathbf{y} = f_{\theta}(\mathbf{x}) = \sigma(\mathbf{W}\mathbf{x} + \mathbf{b})$ 、エンコーダのパラメータを $\theta = \{\mathbf{W}, \mathbf{b}\}$ とする。 \mathbf{W} は $d \times d'$ の重み行列、 \mathbf{b} はバイアス項、 $\sigma(\cdot)$ は活性化関数を表すとする。また、 $\mathbf{z} \in \mathbb{R}^d$ を再構築されたベクトル、圧縮された隠れ層ベクトルから復元を行うデコーダを $\mathbf{z} = g_{\theta'}(\mathbf{y}) = \sigma(\mathbf{W}'\mathbf{y} + \mathbf{b}')$ 、デコーダのパラメータを $\theta' = \{\mathbf{W}', \mathbf{b}'\}$ とする。エンコーダとデコーダの重みには $\mathbf{W}' = \mathbf{W}^T$ の関係がある。訓練データ (災害発生前の人口推移) \mathbf{x}_i を隠れ層ベクトル \mathbf{y}_i に圧縮し、元の人口推移を復元したベクトルを \mathbf{z}_i とすると、AE は以下の目的関数を最小化することで重みを学習する。

$$\begin{aligned} \theta, \theta' &= \arg \min_{\theta, \theta'} \frac{1}{n} \sum_{i=1}^n L(\mathbf{x}_i, \mathbf{z}_i) \\ &= \arg \min_{\theta, \theta'} \frac{1}{n} \sum_{i=1}^n L(\mathbf{x}_i, g_{\theta'}(f_{\theta}(\mathbf{x}_i))) \end{aligned} \quad (1)$$

ここで L は損失関数であり、具体的には Mean Squared Error (MSE): $L(\mathbf{x}_i, \mathbf{z}_i) = \|\mathbf{x}_i - \mathbf{z}_i\|^2$ を利用する。

一般的に AE のモデルには全結合のニューラルネットが用いられる [7]。本研究ではモデルを学習しやすくするためモデルのパラメータがより少ない畳み込みを用いたオートエンコーダ (Convolutional Autoencoder, CAE) [8] を用いる。 k 番目の特徴マップを \mathbf{y}^k 、 $*$ を畳み込みの演算とすると、CAE による特徴抽出 (エンコーダ) は以下の式となる。

$$\mathbf{y}^k = \sigma(\mathbf{W}^k * \mathbf{x} + \mathbf{b}^k) \quad (2)$$

また、 H を畳み込みのフィルタサイズとするとデコーダは以下の式となる。

$$\mathbf{z} = \sigma\left(\sum_{k \in H} \mathbf{W}'^k * \mathbf{y}^k + \mathbf{b}'^k\right) \quad (3)$$

CAE の損失関数 L_{CAE} には二乗誤差 (MSE) を用いる。入力する人口推移ベクトルを \mathbf{x} 、復元された人口推移ベクトルを \mathbf{z} とした時、損失関数 L_{CAE} は式 (4) で定義される。

$$L_{CAE}(\theta) = \frac{1}{2n} \sum_{i=1}^n (\mathbf{x}_i - \mathbf{z}_i)^2 \quad (4)$$

式 (4) は誤差逆伝播法 [9] により最適化される。

本研究では、各メッシュごとの特定の期間の人口推移を 1 つの入力ベクトルとして AE を学習する。例えば、メッシュごとに 1 時間ごとの人口 24 時間分を 1 つのベクトルとし (この場合は 24 次元のベクトル)、その人口推移ベクトルに、そのメッシュのクラスタを示す One-hot ベクトルを連結させたベクトルを入力とする。

2.3 学習済み AE モデルを用いた異常判定

異常検知を行う際は、正常データで学習済みの AE モデルに新たなデータを入力し復元した値と入力との誤差を計算し、誤差が一定の閾値を超える場合に異常と判定する。前節と同様に、入力する人口推移ベクトル（クラスタを示す One-hot ベクトルを含む）を \mathbf{x} 、復元された人口推移ベクトルを \mathbf{z} とした時、各サンプル i について復元誤差 R_i を以下の式で計算する。

$$R_i = L(\mathbf{x}_i - \mathbf{z}_i) \quad (5)$$

ここで L は MSE や Mean Absolute Error (MAE) が利用できる。そして、 R_i が所定の閾値 th を超える場合に異常と判定する。

3. 評価

3.1 データ

人口データ：人口データには、NTT ドコモの国内人口分布統計（リアルタイム版）を利用した。国内人口分布統計（リアルタイム版）は NTT ドコモの携帯電話の在圏情報をもとにメッシュごとの人口を推定したモバイル空間統計と呼ばれる人口データである。500m メッシュごとに 10 分間隔に 1 時間前までの人口を推定している。詳細は文献 [10] を参照されたい。検証に利用したデータは 2016 年 4 月 1 日から 4 月 18 日までの熊本市と益城町の人口データであり、2016 年 4 月 1 日から 4 月 14 日 0 時までの期間の 1 時間ごとの人口を平常時のデータとしてオートエンコーダの学習に利用した。異常検知に用いたデータは熊本地震の本震発生後の期間として、2016 年 4 月 16 日 0 時から 2016 年 4 月 17 日 23 時までの 48 時間の人口推移を利用した。異常検知に 48 時間分の人口を入力するため、平常時の人口も 1 時間ごとに 48 時間分の人口推移を 1 つのベクトルとして学習を行なった。

避難所データ：指定避難所および指定外避難所のデータには、国土交通省の国土数値情報に掲載されている避難施設データ*1（国土数値情報データ）と、防災科学技術研究所が保有する熊本地震の際の開設避難所のデータ（防災科研データ）を利用した。国土数値情報データでは指定避難所のみが掲載されている、一方、防災科研データには指定避難所と指定外避難所の両方が含まれていたため、国土数値情報データと防災科研データで避難所を突合し、突合できた避難所を指定避難所（191 件）、突合できなかった避難所を指定外避難所（200 件）とした。

3.2 比較手法

本研究と同様に指定外避難所を検出する既存研究である Yabe ら [3] の手法（以下、比較手法）と提案手法を比較し

*1 <https://nlftp.mlit.go.jp/ksj/gml/datalist/KsjTmplt-P20.html>




図 1 クラスタ数を変化させたときのクラスタ内誤差の変化

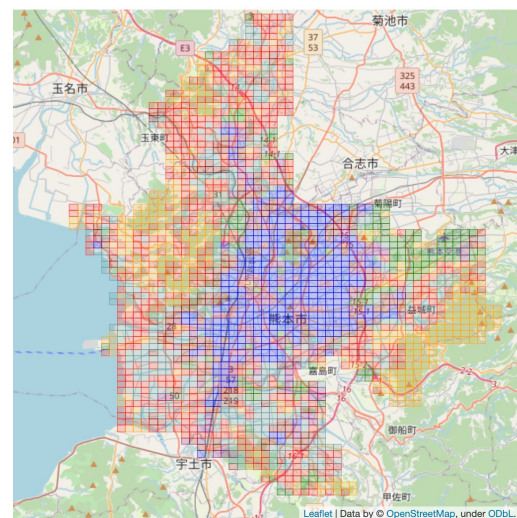


図 2 クラスタリング結果

た。Yabe らの手法では以下の式で人口の異常度スコアを計算し、異常度スコアが 3 を超える場合に異常と判定する。

$$K_{i,j} = \frac{M_{i,j} - \mu_i}{\sigma_i} \quad (6)$$

ここで $M_{i,j}$ はメッシュ i 、時刻 j の人口、 μ_i はメッシュ i の平均人口、 σ_i はメッシュ i の人口の標準偏差を示す。この表記は文献 [3] に従う。Yabe らの手法では深夜 4 時の人口に対して式 (6) を計算し異常度スコアを計算していたため、同様に 4 時の人口で計算した。平均人口 μ_i 、標準偏差 σ_i は、提案手法で学習データとして利用した期間で計算した。

3.3 平常時人口によるメッシュのクラスタリング

2.1 節で述べたクラスタリングについて、k-means クラスタリングのクラスタ数を 3 から 20 まで変化させたときのクラスタ内誤差をプロットした結果を図 1 に示す。エルボー法 [11] によりクラスタ数を 7 とした。クラスタ数 7 で熊本市と益城町を対象にクラスタリングを行なった結果を図 2 に示す。図中の同じ色が同じクラスタであることを示す。図の中心部が熊本市の中心部で同じクラスタになって




図 3 入力した人口推移と AE で復元した人口推移の例




図 4 入力した人口推移と AE で復元した人口推移の例

いたり (青色のメッシュ), 図の右側には山間部が同一クラスにまとまっている (黄色のメッシュ) ことがわかる。

3.4 AE による人口推移の復元

平常時データで学習した AE で人口推移が復元できるか検証を行なった。学習データで人口を復元したときの誤差の分布を図 3 に示す。誤差の最大値は 0.0975, 中央値は 0.0416 であった。図 4 に実際の入力データと復元したデータを示す。概ね入力の人口推移の波形を復元できていることがわかる。

3.5 避難所検出の精度評価と考察

評価指標: 本研究では 3 つの指標で性能を評価する。1 つめは, 避難所を漏れなく検出できているかという観点で評価するため Recall を用いる。Recall は, 避難所があるメッシュのうちどの程度の割合のメッシュを抽出できたかを示す。2 つめは, 正しく避難所を検出できているかという観点で評価するため Precision を用いる。Precision は, 抽出したメッシュのうち実際に避難所が存在するメッシュの割合を示す。3 つめは, Recall と Precision は一般にトレードオフの関係にあるため, 総合的な精度をみるために F 値を用いる。F 値は Recall と Precision の調和平均で計算される。

精度評価結果: 指定避難所と指定外避難所を区別せずにい

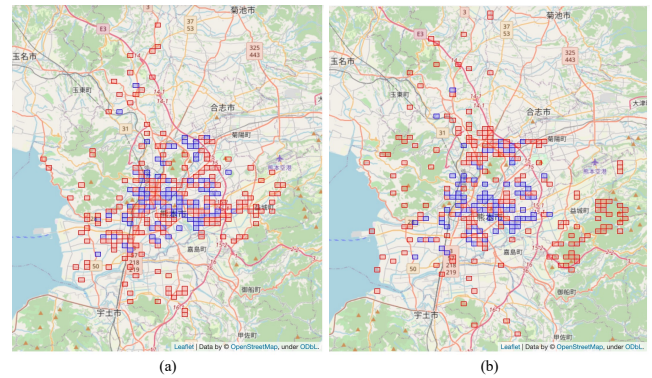


図 5 Recall (a) および Precision (b) の地図上での可視化結果

ずれかの種類の避難所を検出できたことを正解として評価した結果を表 1 に示す。人口推移のみを利用した場合, Recall および F 値において提案手法の方が精度が高かったが, Precision は比較手法がよかった。人口推移に加えクラスタ情報を利用した場合, すべての指標で比較手法より精度が高かった。指定外避難所のみを正解として評価した結果を表 2 に示す。この場合も同様の傾向であった。

図 5 に提案手法の結果を地図上に可視化した図を示す。図 5 (a) は Recall を示しており, 青いメッシュが避難所があるメッシュを検出できた場所, 赤いメッシュが避難所があるにもかかわらず検出できなかったメッシュを示す。図 5 (b) は Precision を示しており, 異常として検出したメッシュで実際に避難所があるメッシュを青いメッシュで示し, 異常として検出したが避難所がないメッシュを赤いメッシュで示す。Recall の観点では熊本市の中心地で検出できなかったメッシュがあることがわかる。一方, Precision の観点では山間部で誤検出していることがわかる。

図 5 (b) の結果から, 人口が少ないと考えられる山間部で誤検出が多いことがわかった。そこで, 平常時からある程度人口がある程度存在するエリアに絞って評価を行なった。そのために, 比較手法および提案手法で異常検知を行なった後に, 学習期間の深夜人口が 500 人以上という条件でメッシュを絞って評価を行なった。この条件で, 指定避難所と指定外避難所を区別せずにいずれかの種類の避難所を検出できたことを正解として評価した結果を表 3 に, 指定避難所のみを正解として評価した結果を表 4 に示す。これらの結果から, 平常時から 500 人以上の人口が存在するエリアでは Precision が向上したことがわかる。つまり, 平常時から人がいるという事前情報を活用することで誤検出を低減させることができたと言える。特に比較手法において Precision の向上が大きかった。

総合的な検出を示す F 値では, 提案手法がいずれの条件でも高精度であったが, Recall および Precision 別で見ると提案手法では Recall が高く, 比較手法では Precision が高いという特性が明らかになった。また表 3 および表 4 の結果から事前情報を活用することで Precision を向上させ

表 1 避難所検出精度 (指定・指定外避難所の両方を正解とした場合)

手法	Recall	Precision	F1
Yabe らの手法 [3]	0.181 (52/287)	0.371 (52/140)	0.244
提案手法 (人口推移のみ)	0.317 (91/287)	0.320 (91/284)	0.319
提案手法 (人口推移+クラスタ)	0.578 (166/287)	0.455 (166/365)	0.509

表 2 避難所検出精度 (指定外避難所のみを正解とした場合)

手法	Recall	Precision	F1
Yabe らの手法 [3]	0.166 (26/157)	0.186 (26/140)	0.175
提案手法 (人口推移のみ)	0.287 (45/157)	0.159 (45/284)	0.204
提案手法 (人口推移+クラスタ)	0.592 (93/157)	0.255 (93/365)	0.255

表 3 避難所検出精度 (指定・指定外避難所の両方を正解とした場合で各メッシュの人口でフィルタした場合)

手法	Recall	Precision	F1
Yabe らの手法 [3]	0.164 (47/287)	0.681 (47/69)	0.264
提案手法 (人口推移)	0.307 (88/287)	0.503 (88/175)	0.384
提案手法 (人口推移+クラスタ)	0.544 (156/287)	0.515 (156/303)	0.529

表 4 避難所検出精度 (指定外避難所のみを正解とした場合で各メッシュの人口でフィルタした場合)

手法	Recall	Precision	F1
Yabe らの手法 [3]	0.147 (23/157)	0.349 (23/69)	0.206
提案手法 (人口推移)	0.280 (44/157)	0.251 (44/175)	0.265
提案手法 (人口推移+クラスタ)	0.561 (88/157)	0.290 (88/303)	0.383

ることができることがわかった。しかしながら、Recall の観点では提案手法 (人口推移+クラスタ) 以外では 0.5 に到達していないことから半数以上の避難所を見逃している状態である。これらを踏まえ、さらに精度を改善するために既存研究で算出している異常スコアと提案手法の異常スコアを統合することで、両者の特性を活かした高精度な検出手法を構築するということが考えられる。

計算時間評価: 指定外避難所の検出は発災後早期に実施する必要があるため、モデルの学習や推論に要する時間を評価する。実測の結果、学習済みモデルを利用して推論に要する時間は短く、モデル学習に要する時間が大半であったため、発災後に AE モデルを学習することを想定し学習に必要な計算時間を計測した。計算に利用したハードウェアのスペックは、Intel(R) Xeon(R) Platinum 8260 CPU @ 2.40GHz の CPU96 コア、メモリ 756GB である。熊本市および益城町を対象とした処理では、モデル学習に約 34.2 秒で処理が完了した。対象地域および学習期間を拡大し、県全域を対象に 2 ヶ月分の人口データで学習した場合は、モデル学習に約 10 分の時間を要した。これらの結果から、各地域に対するデータの事前処理を事前に行っておくことで、発災時に住民が避難した後の人口データ生成後、概ね 10 分で推定が可能であることを確認した。

4. おわりに

本稿ではオートエンコーダを用いて人口変動の異常を判定することで避難所を検出する手法を提案した。熊本地震における避難所データを正解データとし、モバイル空間統

計に対して提案手法を適用することで避難所を検出できるか検証を行った。メッシュの平均人口および標準偏差から異常判定を行う比較手法より、オートエンコーダとメッシュのクラスタリングを用いた提案手法が高精度に避難所を検出できることを確認した。なお、本稿で検討した手法では、大規模な災害時には基地局にも被害が発生する可能性があり、その場合人口データが正確に推定できない可能性があるという制約がある。

今後は、提案手法でも見逃している避難所があるため、さらなる精度向上を図るとともに、熊本地震以外の災害における評価を行い、提案手法の一般性を評価したい。

参考文献

- [1] 国土交通省: 国土交通白書 2020 令和 2 年版, 日経印刷 (2020).
- [2] 井上学: 熊本地震の行政対応: 失敗から学んだこと (要約)(特集 研修紹介)-(研修第 2 回トップマネジメントセミナー: 災害対応力の強化に向けて), 国際文化研修, Vol. 26, No. 1, pp. 22-29 (2018).
- [3] Yabe, T., Tsubouchi, K., Sudo, A. and Sekimoto, Y.: A framework for evacuation hotspot detection after large scale disasters using location data from smartphones: case study of kumamoto earthquake, *Proceedings of the 24th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, pp. 1-10 (2016).
- [4] 船越康希, 畑山満則ほか: 熊本地震を事例とした避難所の同定及び市町村をまたぐ広域避難に関する研究, 情報処理学会研究報告情報システムと社会環境 (IS), Vol. 2016, No. 14, pp. 1-8 (2016).
- [5] MacQueen, J. et al.: Some methods for classification and analysis of multivariate observations, *Proceedings of*

the fifth Berkeley symposium on mathematical statistics and probability, Vol. 1, No. 14, Oakland, CA, USA, pp. 281–297 (1967).

- [6] Hinton, G. E. and Salakhutdinov, R. R.: Reducing the dimensionality of data with neural networks, *science*, Vol. 313, No. 5786, pp. 504–507 (2006).
- [7] 岡谷貴之: 深層学習, 講談社 (2015).
- [8] Masci, J., Meier, U., Cireşan, D. and Schmidhuber, J.: Stacked convolutional auto-encoders for hierarchical feature extraction, *Artificial Neural Networks and Machine Learning–ICANN 2011*, pp. 52–59 (2011).
- [9] Rumelhart, D. E., Hinton, G. E. and Williams, R. J.: Learning representations by back-propagating errors, *nature*, Vol. 323, No. 6088, pp. 533–536 (1986).
- [10] Terada, M., Nagata, T. and Kobayashi, M.: Population estimation technology for mobile spatial statistics, *NTT DOCOMO Technical Journal*, Vol. 14, No. 3 (2013).
- [11] Kodinariya, T. M. and Makwana, P. R.: Review on determining number of Cluster in K-Means Clustering, *International Journal*, Vol. 1, No. 6, pp. 90–95 (2013).