

注意機構を用いた Graph Convolutional Networks による 短期的将来滞在人口数推定

久保田 祐輝^{1,†1,a)} 清水 哲夫¹ 大平 悠季¹

概要：近年位置測位技術の発達により、都市において多種多様なデータが観測・収集されており、それらの利活用に対する関心が高まっている。特に短期的な将来における滞在人口数の推定は、混雑緩和を始めとする様々な都市政策の施行において重要となる。都市空間で観測される時系列データには観測地点の位置情報が付与されるため、複雑な時空間構造が生じることで知られている。既存研究の多くは観測地域をグリッドに分割し、畳み込みニューラルネットワーク (CNN) を適用することで、空間的相関の把握を試みている。しかし、CNN は空間構造を幾何学的に処理しているに過ぎず、現実の都市に関連する情報を考慮できていない。そこで、本研究では都市に偏在する情報に基づき複数のグラフを作成し、Graph Convolutional Networks (GCNs) と注意機構を使用することで、都市特有の空間的相関を多面的に把握する予測手法 Attention based Contextual Multi-View Graph Convolutional Networks (ACMV-GCNs) を提案する。注意機構に基づき天候や時刻といった外的要因を考慮することで、従来手法よりも現実の状況に則した予測を行うことが可能となる。携帯端末より取得された人口統計データを使用し、将来滞在人口数の推定精度の検証を行うことで、提案手法が既存手法と比較して優れた推定精度を誇ることを示す。加えて、注意機構によって計算された重みを可視化することで、提案手法が予測時の祝祭日情報と時刻情報に基づき、各グラフを用いて計算された出力値を効果的に活用していることを示す。

1. 序論

近年位置測位技術の発達に伴い、都市で多種多様なデータが観測・収集されており、それらの利活用に対する関心が高まっている。その中の一例として、都市における滞在人口数の将来推定が着目されており、様々な研究で扱われている [2], [5]。将来滞在人口数を高い精度で推定することは、混雑解消を始めとした都市政策において多大な恩恵をもたらすことが期待される。

都市空間で観測された時系列データは、時系列相関に加えて観測地点同士の位置関係に依存する空間的相関も有している。これらの構造が相互に非線形の関係にあることにより、滞在人口数データは複雑な時空間構造を有することが明らかにされている [13]。

都市空間における時系列データの推定に関して、古典的には自己回帰和分移動平均 (ARIMA:Auto Regressive Integrated Moving Average) モデルやその発展形のモデル

など、時系列データを統計的な枠組みで扱う手法が用いられてきた [9]。しかしながら、これらの手法は時系列相関を把握することは可能だが、データに付与された位置情報を考慮し、空間的相関を予測に用いることは困難である [13]。

そこで、近年様々な分野で成功を収めている機械学習や深層学習のアルゴリズムを時空間データに対して適用する試みがなされた。都市空間で観測されたデータに対して、頻繁に用いられる深層学習の代表的なモデルには、長・短期記憶 (LSTM:Long Short-Term Memory) と畳み込みニューラルネットワーク (CNN:Convolutional Neural Network) の2つが存在する。LSTM はメモリセルと呼ばれる機構を設け、中間層の情報を伝播させることで時系列相関を考慮するモデルである。一方 CNN は従来画像を扱うモデルであるが、時空間データの解析においては主に空間的構造を把握する目的で用いられる。先行研究では、データの観測が行われた都市空間を矩形のグリッドに分割し、各グリッドを画像のピクセルとみなすことで CNN の適用を可能としている [7], [14]。

実際に都市で観測されたデータに対して LSTM や CNN を適用した先行研究では、ARIMA モデルなど古典的な統計モデルよりも予測精度が高いことが明らかにされている [6], [14], [16]。

¹ 東京都立大学 都市環境学部 観光科学科
Department of Tourism Science, Faculty of Urban Environmental Sciences, Tokyo Metropolitan University

^{†1} 現在、東京工業大学 情報理工学院 情報工学系
Presently with Department of Computer Science, School of Engineering, Tokyo Institute of Technology

^{a)} kubota.y.ao@m.titech.ac.jp

しかしながら、CNNは矩形形状のフィルタを用いた畳み込み演算に基づき、空間構造を幾何学的に処理しているに過ぎない。すなわち、CNNを用いる手法は空間的相関をユークリッド距離に基づいて把握していると解釈される。一方で、都市空間における空間的相関はユークリッド距離に限らず、公共交通機関の分布や、集客施設の立地環境など都市空間特有の関連性が存在すると考えられる。

そこで、本研究では都市構造に基づきグラフを作成し、GCNs (Graph Convolutional Networks) を適用することで、都市特有の空間的相関を多面的に考慮する予測手法を提案する。

グラフとしては距離グラフ、POIグラフ、交通ネットワークグラフの3つを作成する。また、これらのグラフによって計算された出力値の予測に対する重要度は、予測時の天候や時刻などの外的要因に依存すると考えられる。そこで、本研究ではLiuら[8]によって考案された外的要因を考慮する注意機構をモデルに加えることで、各グラフから得られた出力値に対する重要度を、モデルに学習させることを試みる。

注意機構には計算された重みに対する解釈が明瞭であるという利点が存在する。すなわち計算された重みを可視化することで、モデルが都市情報を如何にして予測に活用しているかを確認することが可能となる。この検証を行った研究は管見の限り見受けられない。

本研究の貢献としては以下の点が挙げられる。

- 都市構造に基づいたグラフを予測に用いることで、都市特有の空間的相関を考慮することが可能な予測手法を提案した。
- 提案手法の注意機構によって計算された重みを可視化することで、モデルが都市情報を如何にして予測に活用しているかの検証を行った。

2. 関連研究

都市空間の時系列データに対してグラフ構造の導入を試みた研究は幾つか存在する。概括的にはグラフ構造を構築する際の都合の良さから、交通センサーなど観測点が固定されているデータに対して用いられることが多い傾向にある。実際に交通センサーの位置に基づきグラフを作成し、GCNsを適用した研究が幾つか見受けられる[4], [15]。しかしながら、これらの研究ではグラフの接続関係をユークリッド距離や過去の時系列の推移パターンの類似度に基づき定めており、都市空間における情報を活用したグラフの作成は行っていない。

都市情報をグラフに反映させた研究としては、都市を道路区画に基づいて分割し、グラフを構築した研究や[11]、集客施設の分布を利用してグラフの重みを調整し、複数の出力値を注意機構によって混合している研究[8]などが存在する。一方、これらの研究では扱うグラフを一つに固定

しており、異なる期間の入力データを与えた際の出力値を融合している。すなわち、都市情報の観点に基づき複数の異なるグラフを構築しているわけではない。

他に、ライドヘイリングサービスにおける需要予測を試みた研究[3]では、集客施設の分布や交通網など幾つかの異なる観点からグラフを構築し、その出力値を融合している。この研究の着目点は本研究のものと類似しているが、この研究では天候や時刻情報などの外的要因を考慮しておらず、複数のグラフに基づく出力値を、算術平均を始めとする単純な集約関数によって融合したものを最終的な予測値としている。さらに、この研究では複数のグラフを用いた際の予測精度を検証しているに留まり、各グラフの出力値がどのような形で予測に寄与しているかは検証されていない。

本研究で提案する手法はこれらの課題を考慮し、複数の出力値を外的要因に基づく注意機構によって重み付けした和を取る。すなわち、本研究で提案する手法の方がより現実の状況に則した予測を行うことが可能となる。加えて、本研究では注意機構の重みを可視化することで、各グラフの出力値が最終的な予測値に対してどのように寄与しているかを検証する。

3. 手法

3.1 滞在人口数の定義

この節では滞在人口数の予測問題の定式化を行う。本研究では予測対象地を $I \times J$ サイズのグリッドで表現する。 I と J はそれぞれグリッドの行数と列数を表す。予測対象地における全てのグリッドの集合を V で与え、グリッドの総数を $I \times J = N$ と定義する。また、全グリッド集合内の任意のグリッドを $v_n \in V$ によって表現する。

時刻 t におけるグリッド v_n の滞在人口数を $x_t^n \in \mathbb{R}$ によって与え、時刻 $t = \{1, \dots, T\}$ における全グリッドの滞在人口数をテンソル $\mathbf{X}_t \in \mathbb{R}^{1 \times I \times J}$ によって定義する。

滞在人口数の予測問題は、過去の滞在人口数のデータ $\mathbf{X}_{t-l}, \dots, \mathbf{X}_t$ を入力として与えることで、一時間後の滞在人口数 \mathbf{X}_{t+1} の予測を行う問題として定式化される。ここで l はモデルが考慮する期間の長さを示している。

3.2 提案手法

本研究ではGCNsと注意機構を組み合わせた予測手法である、Attention based Contextual Multi-View Graph Convolutional Networks (ACMV-GCNs)を提案する。ACMV-GCNsにおける構造の概要は図1の通りである。

モデルには空間的相関を把握する構造と、天候などの外的要因を結合した上で時系列相関を把握する構造の組が並列に3つ設けられている。各構造で計算された3つの出力を外的要因に基づく注意機構で混合し、最終的な予測値を求める。なお、図1においてEmbedとFCは各々埋め込

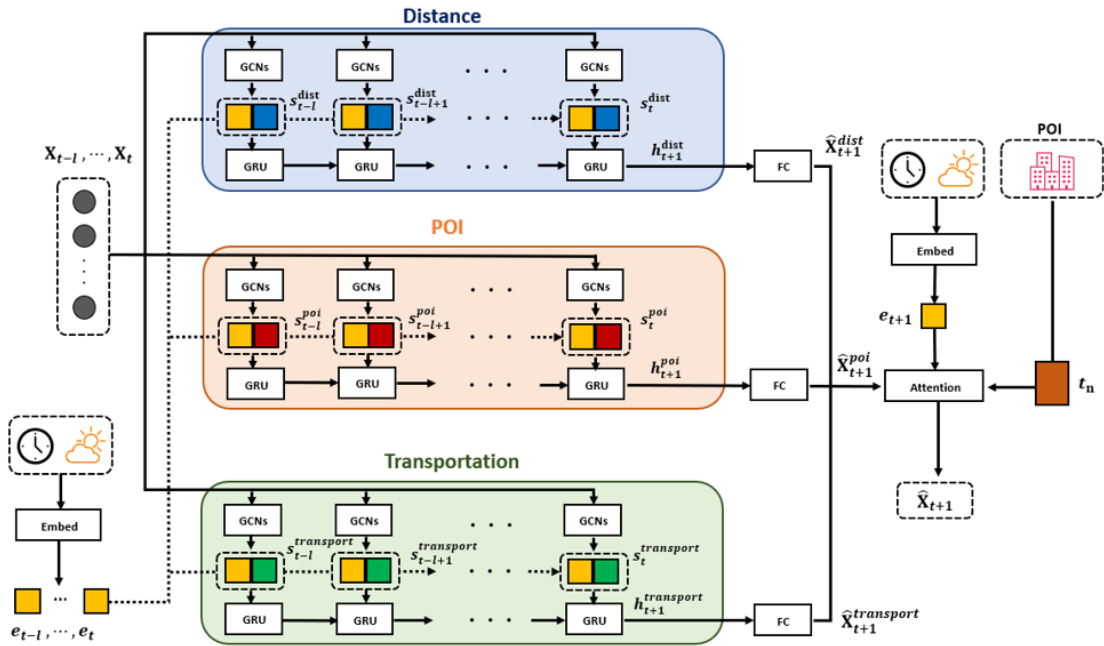


図 1 ACMV-GCNs の模式図

み層と全結合層を表している。

3.3 都市情報に基づいたグラフの作成

本節では都市情報に基づきグラフを構築する方法を述べる。なお、本研究で用いるグラフは全て無向グラフであるとする。

3.3.1 距離グラフ

都市における空間的相関の一つとしてユークリッド距離を考慮する。ここでは距離グラフ G_{dist} を全グリッドの集合 V とグラフの隣接行列 \mathbf{A}_{dist} の組によって定義する。すなわち $G_{dist} = (V, \mathbf{A}_{dist})$ である。ここで隣接行列の各要素の値は、閾値を設けたガウスカネル [10] を用いて、

$$\mathbf{A}_{dist, nm} = \begin{cases} \exp\left(-\frac{[dis(n, m)]^2}{2\theta^2}\right) & (dis(n, m) \leq \kappa) \\ 0 & (otherwise) \end{cases} \quad (1)$$

によって定義する。ただし $dis(n, m)$ はグリッド v_n, v_m 間のユークリッド距離を表す。 θ と κ はガウスカネルにおけるパラメータである。

3.3.2 POI グラフ

POI とは Point of Interest の略称であり、人々の興味・関心を集め、行動目的となるような施設のことを指す。すなわち各グリッドにおける POI の分布を考慮することで、該当グリッドの地域特性を把握することが可能となる。地域特性が類似した地点同士は、滞在人口数の推移傾向も類似すると考えられるため、POI 分布に基づいて空間的相関を考慮できる可能性が高い。

まず、各グリッド v_n における POI の分布をベクトル化するために、自然言語処理などの分野で用いられる TF-IDF

を適用する。POI のカテゴリの集合を C 、グリッド v_n におけるカテゴリ $c \in C$ の POI の数を ω_n^c と定義すれば、グリッド v_n におけるカテゴリ c に属する POI の TF-IDF 値 t_n^c は、

$$t_n^c = \frac{\omega_n^c}{\sum_{c \in C} \omega_n^c} \times \log \frac{N}{|\{v_n \in V | \omega_n^c \neq 0\}|} \quad (2)$$

によって与えられる。ここで $|\cdot|$ は集合の要素数を意味する。これを全ての POI カテゴリ C に関して求めたものを $\mathbf{t}_n \in \mathbb{R}^{|C|}$ とすれば、 \mathbf{t}_n はグリッド v_n における POI の分布をベクトル化したものとなる。POI グラフの隣接行列 \mathbf{A}_{poi} をこれらのベクトル間の \cos 類似度、

$$\mathbf{A}_{poi, nm} = \begin{cases} \cos(\mathbf{t}_n, \mathbf{t}_m) & (\cos(\mathbf{t}_n, \mathbf{t}_m) \geq \gamma) \\ 0 & (otherwise) \end{cases} \quad (3)$$

によって定義する。そしてこの隣接行列を用いて、POI グラフを $G_{poi} = (V, \mathbf{A}_{poi})$ によって与える。また、 γ は隣接行列の要素に対する閾値として設けた。

3.3.3 交通ネットワークグラフ

現実の都市において人々は公共交通機関を利用して頻繁に移動するため、交通網に基づき地点間に空間的相関が発生すると考えられる。本研究では交通網として鉄道網と高速道路網の2つを考慮する。特に鉄道網において、滞在人口は駅に集中する傾向にあるため、同じ鉄道路線の駅が位置するグリッド間は、接続関係にあるとして隣接行列を定める。また、高速道路に関しては同じ高速道路に重なっているグリッドの組は全て接続関係にあるとする。

ここで、考慮すべき全鉄道と全高速道路の合計数を M で与える。なお、ここでいう鉄道とは山手線、中央線といっ

たように路線の名称ごとに分類されており、高速道路に関しても同様である。各グリッド v_n に対して交通網の分布状況を表現した M 次元ベクトル $\mathbf{g}_n \in \mathbb{R}^M$ を考える。ベクトル \mathbf{g}_n の各要素には、考慮した M 個の鉄道・高速道路のうち、該当する鉄道の駅、もしくは高速道路とグリッド v_n が重なっている場合にのみ 1 を与え、それ以外の場合は 0 を与える。ここで道路ネットワークの隣接行列を、

$$\mathbf{A}_{transport, nm} = \mathbf{g}_n^T \mathbf{g}_m \quad (4)$$

によって定義する。すなわち、同じ路線の鉄道駅、または同じ高速道路と重なっているグリッド間には接続関係が生じる。また、あるグリッドの組が同じ路線の鉄道駅や同じ高速道路を複数共有している場合、より大きな重みが与えられる。最後に、この隣接行列を用いて $G_{transport} = (V, \mathbf{A}_{transport})$ を定義する。

3.4 Graph Convolutional Networks

グラフ構造に対する深層学習は大きくユークリッド空間において畳み込み演算を行う手法と、スペクトル領域において畳み込み演算を行う手法に分類される [12]。本研究ではスペクトル領域に基づく GCNs を採用する。

スペクトル領域に基づく GCNs では、グラフフーリエ変換によりノード上の信号をスペクトル領域へ変換した後に畳み込み演算を行う。 $\theta \in \mathbb{R}^N$ をパラメータを持つ $g_\theta = \text{diag}(\theta)$ を畳み込み演算のフィルタとして定義すれば、グラフ信号 $\mathbf{x} \in \mathbb{R}^N$ に対する畳み込み演算は、

$$g_\theta *_{\mathcal{G}} \mathbf{x} = g_\theta(\mathbf{L})\mathbf{x} = g_\theta(\mathbf{U}\mathbf{\Lambda}\mathbf{U}^T)\mathbf{x} = \mathbf{U}g_\theta(\mathbf{\Lambda})\mathbf{U}^T\mathbf{x} \quad (5)$$

と定義される。ここで、 $*_{\mathcal{G}}$ はグラフ畳み込みにおける演算子で、 $\mathbf{U} = [\mathbf{u}_0, \mathbf{u}_1, \dots, \mathbf{u}_{N-1}] \in \mathbb{R}^{N \times N}$ と $\mathbf{\Lambda} = \text{diag}(\lambda_0, \lambda_1, \dots, \lambda_{N-1}) \in \mathbb{R}^{N \times N}$ は各々正規化ラプラシアン行列 $\mathbf{L} = \mathbf{I}_N - \mathbf{D}^{-\frac{1}{2}}\mathbf{A}\mathbf{D}^{-\frac{1}{2}} \in \mathbb{R}^{N \times N}$ の固有ベクトルを並べた行列、固有値を要素に持つ対角行列である。なお、 $\mathbf{I}_N \in \mathbb{R}^{N \times N}$ は単位行列、 $\mathbf{A} \in \mathbb{R}^{N \times N}$ はグラフの隣接行列、 $\mathbf{D} \in \mathbb{R}^{N \times N}$ は次数行列 $D_{ii} = \sum_j \mathbf{A}_{ij}$ である。

しかし、実際には正規化ラプラシアン行列の固有値分解を直接行うのは膨大な計算量を必要とし、特に大規模なグラフの場合においては困難になる。この問題に対処するために Defferrand ら [1] は ChebNet を考案した。ChebNet はフィルタ g_θ を、チェビシェフ多項式を適用した結果で近似することで、固有値計算を明示的に行うことを避けた手法である。ChebNet によるグラフの畳み込み演算は、

$$g_\theta *_{\mathcal{G}} \mathbf{x} = g_\theta(\mathbf{L})\mathbf{x} = \sum_{k=0}^{K-1} \theta_k T_k(\tilde{\mathbf{L}})\mathbf{x} \quad (6)$$

によって与えられる。ここで、 $\tilde{\mathbf{L}} = 2\mathbf{L}/\lambda_{max} - \mathbf{I}_N$ である。チェビシェフ多項式は、 $T_k(x) = 2xT_{k-1}(x) - T_{k-2}(x)$ 、 $T_1(x) = x$ 、 $T_0(x) = 1$ と再帰的に定義され、このフィルタ

によって K 次のチェビシェフ多項式近似を求めることは、各ノードから見て K 番目までに隣接しているノードの情報を考慮した畳み込み演算を行っていることに等しい [1]。

3.5 モデルによる演算

本節では ACMV-GCNs が実際に行う演算の詳細を記す。図 1 の模式図にあるように、提案手法は距離グラフ、POI グラフ、交通ネットワークの 3 つのグラフに対してそれぞれ同じ演算を並列に行うように設計されており、最終的な予測値は各出力値に対し、注意機構を適用して混合した結果で与えられる。

3.5.1 時空間構造の把握

$G_{dist}, G_{poi}, G_{transport}$ の 3 つのグラフに対して式 (6) で定義される畳み込み演算を適用することで、それぞれ異なる観点に基づいた空間構造の把握を試みる。また、後述する GRU の入力へ接続するために、同じ構造をもつ GCNs を入力期間 l と同じ数だけ並列に設ける。3.4 節の議論に基づけば、ACMV-GCNs における畳み込み演算は、

$$\mathbf{H}_t^{(z+1)} = f\left(\sum_{k=0}^{K-1} \theta_k T_k(\tilde{\mathbf{L}})\mathbf{H}_t^{(z)}\right) \quad (7)$$

によって与えられる。ただし、 $\mathbf{H}_t^{(z+1)} \in \mathbb{R}^{N \times F_{z+1}}$ と $\mathbf{H}_t^{(z)} \in \mathbb{R}^{N \times F_z}$ は各々時刻 t でのモデルの第 z 層における出力と入力に相当する。また、 $f(\cdot)$ は活性化関数である。

Z 回の畳み込み演算による最終的な出力は $\mathbf{H}_t^{(Z+1)} \in \mathbb{R}^{N \times F_{Z+1}}$ で与えられるが、後続の GRU で扱えるように $\mathbf{s}_t^a \in \mathbb{R}^{N \times F_{Z+1}}$ とベクトルに変形する。ここで $a \in \{dist, poi, transport\}$ であり、それぞれ距離グラフ、POI グラフ、交通ネットワークグラフのうち、どのグラフに基づいて計算されたか結果であることを表す。従って、入力期間分並列に設置した GCNs による最終的な出力として $\mathbf{s}_{t-l}^a, \dots, \mathbf{s}_t^a$ を得る。

続いて、時空間構造以外の外的要因として、観測が行われた時点の時刻・天候・祝祭日に関する情報を考慮する。時刻情報は 0 時から 23 時までの値、天候情報は晴れ・曇り・雨の 3 つの値、曜日情報は平日か休日であるかの 2 つの値を取る。これらはカテゴリ型のデータとして扱い、ニューラルネットワークにおける埋め込み層を適用することで、密なベクトルに変換する。

時刻 t における外的要因の情報を埋め込み層を適用してベクトル化したものを $\mathbf{e}_t \in \mathbb{R}^m$ で与える。GCNs で得られた出力値 \mathbf{s}_t^a とこれを結合して、

$$\mathbf{p}_t^a = \mathbf{s}_t^a \oplus \mathbf{e}_t \quad (8)$$

を与える。すなわち、この結合演算によって得たベクトル $\mathbf{p}_{t-l}^a, \dots, \mathbf{p}_t^a$ は、空間的相関を把握したベクトルに対して、各時刻における外的要因の情報を付与したものである。

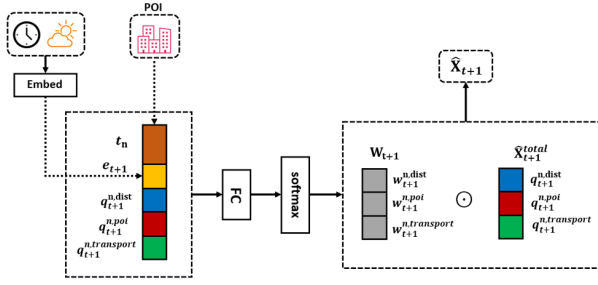


図 2 ACMV-GCNs で使用する注意機構の模式図

次に、時系列相関を考慮するためのモデルとして GRU を用いる。GRU は LSTM の派生モデルであり、LSTM の忘却ゲートと入力ゲートを一つの更新ゲートに統合した構造を持つ。GRU は入力として \mathbf{p}_t^a を受け取るので、各 $a \in \{dist, poi, transport\}$ について時刻 t における更新式は、

$$\mathbf{z}_t^a = \sigma(\mathbf{W}_z^a \mathbf{p}_t^a + \mathbf{U}_z^a \mathbf{h}_{t-1}^a + \mathbf{b}_z^a) \quad (9)$$

$$\mathbf{r}_t^a = \sigma(\mathbf{W}_r^a \mathbf{p}_t^a + \mathbf{U}_r^a \mathbf{h}_{t-1}^a + \mathbf{b}_r^a) \quad (10)$$

$$\tilde{\mathbf{h}}_t^a = \phi(\mathbf{W}_h^a \mathbf{p}_t^a + \mathbf{r}_t^a \odot \mathbf{U}_h^a \mathbf{h}_{t-1}^a + \mathbf{b}_h^a) \quad (11)$$

$$\mathbf{h}_t^a = (\mathbf{1} - \mathbf{z}_t^a) \odot \mathbf{h}_{t-1}^a + \mathbf{z}_t^a \odot \tilde{\mathbf{h}}_t^a \quad (12)$$

で与えられる。

ここで $\mathbf{W}_\beta^a, \mathbf{U}_\beta^a, \mathbf{b}_\beta^a$ ($\beta \in \{z, r, h\}$) はモデルによって学習される重みパラメータである。時系列相関を考慮した GRU の最終的な出力は \mathbf{h}_{t+1}^a によって与えられ、これは各グラフに基づいて空間的相関、外的要因、時系列相関を考慮した上での出力値となる。

3.5.2 注意機構による予測値の融合

3.5.1 節で定義した出力値 \mathbf{h}_{t+1}^a に対して一層の全結合層を加え、その出力値を変形すればテンソル $\hat{\mathbf{X}}_{t+1}^a \in \mathbb{R}^{1 \times I \times J}$ ($a \in \{dist, poi, transport\}$) が得られる。グラフ $G_{dist}, G_{poi}, G_{transport}$ に対応して 3 つの予測値が得られるので、これらの値を一つに統合する必要がある。現実的には、距離、POI、交通ネットワークのうち、どの観点により重視するかは時刻や天候に依存し、各地域ごとに異なることが想定される。そこで、本研究では外的要因に基づく注意機構 [8] を用いることでこの問題に対処する。

図 2 は本研究で用いる注意機構の模式図を示している。まず、予測対象時刻における外的要因に関する情報を、3.5.1 節で述べた手法と同様に埋め込み層でベクトル化し、 $\mathbf{e}_{t+1} \in \mathbb{R}^m$ を得る。次に、グリッド v_n においてグラフ G_a に基づいて計算された予測値を $q_{t+1}^{n,a} \in \mathbb{R}$ とおく。各グリッドについてこれら 3 つの予測値 $q_{t+1}^{n,dist}, q_{t+1}^{n,poi}, q_{t+1}^{n,transport}$ に加え、ベクトル化した \mathbf{e}_{t+1} と、3.3.3 節で定義した POI 分布ベクトル $\mathbf{t}_n \in \mathbb{R}^{|C|}$ を結合する。すなわち、各グリッドにおいて $3 + m + |C|$ 次元のベクトルが与えられることになる。このベクトルを出力次元が 3 次元の全結合層に入力として与え、続いてソフトマックス関数を適用する。

この結果を、全グリッドに関してまとめたものをテンソル $\mathbf{W}_{t+1} \in \mathbb{R}^{3 \times I \times J}$ とおく。すなわち、 \mathbf{W}_{t+1} は外的要因を考慮した上で、3 つのグラフからの出力値に対して配分した重みを、全てのグリッドについてまとめたものであると解釈できる。

次に、 $\hat{\mathbf{X}}_{t+1}^{dist}, \hat{\mathbf{X}}_{t+1}^{poi}, \hat{\mathbf{X}}_{t+1}^{transport}$ を結合したものを $\hat{\mathbf{X}}_{t+1}^{total} \in \mathbb{R}^{3 \times I \times J}$ とすれば、 \mathbf{W}_{t+1} と $\hat{\mathbf{X}}_{t+1}^{total}$ は同じ形状を持つ。これらを要素ごとに掛け合わせその和を取れば、注意機構で計算された重みに基づき 3 つの出力値を混合した $\hat{\mathbf{X}}_{t+1} \in \mathbb{R}^{1 \times I \times J}$ が求まる。これはすなわち、各グリッド v_n に対して予測値の重み付き和

$$\begin{aligned} x_{t+1}^n = & q_{t+1}^{n,dist} w_{t+1}^{n,dist} + q_{t+1}^{n,poi} w_{t+1}^{n,poi} \\ & + q_{t+1}^{n,transport} w_{t+1}^{n,transport} \end{aligned} \quad (13)$$

を求めていることに等しい。ここで、 $w_{t+1}^{n,a}$ はグリッド v_n のグラフ G_a の出力値に対して配分された重みであり、ソフトマックス関数を通じて求めているので、 $\sum_a w_{t+1}^{n,a} = 1$ が成り立つ。

4. 実験

4.1 使用データの詳細

本研究では滞在人口数のデータとして株式会社ドコモ・インサイトマーケティングより提供されたモバイル空間統計*1を使用する。提供データでは日本全国が 500m 四方のグリッドに分割されており、各グリッドに滞在している推定人口数が 1 時間ごと与えられている。さらに、個人情報特定されないよう匿名化されたうえで、滞在人口の「年齢・性別」、「居住都道府県」、「居住市区町村」のいずれかの観点に基づいた集計値も存在する。データは 2020 年 1 月 1 日から 2020 年 5 月 31 日までの期間が存在する。本研究では各グリッドが位置する市区町村に対し、居住市区町村が異なる滞在者、すなわち外部市区町村より来訪している人口のみを滞在人口と定義し、予測対象として扱う。

また、POI と交通網のデータは国土数値情報*2より、シェープファイル形式で提供されているものを使用する。POI は 9 つのカテゴリーに分類し、交通網としては鉄道網・鉄道駅・高速道路網のデータを使用する。天候情報に関しては気象庁*3が公開しているオープンデータを使用する。

4.2 実験設定

本研究では予測対象地として東京都心部を選定し、全国分のグリッドデータから 32×40 の大きさのエリアを抽出した (図 3 参照)。

滞在人口数データは新型コロナウイルス感染症拡大の影響を考慮して 2020 年 1 月 1 日から 2020 年 3 月 24 までの

*1 <https://mobaku.jp/>

*2 <https://nlftp.mlit.go.jp/ksj/>

*3 <https://www.jma.go.jp/jma/index.html>

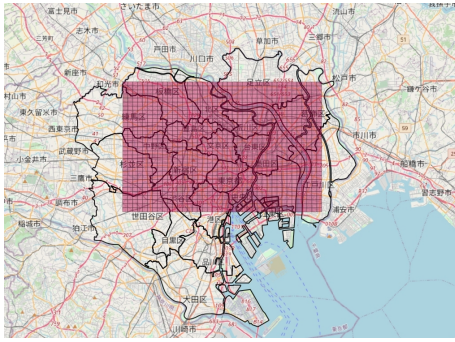


図 3 本研究で扱う予測対象地域

データを用いることとし、その中でも1月1日から3月10までのデータを訓練データ、3月11日から3月17日までのデータを検証用データ、3月18日から3月24日までのデータをテストデータに分割して使用する。

また、ニューラルネットワークの学習を円滑に進めるためには入力データの尺度を揃えるスケールリングが有効である。本研究では、極端に大きな値にスケールリングの結果が影響される可能性を考慮し、以下の式に基づく変換を行う。

$$\hat{x}_i = \frac{x_i - Q_1}{Q_3 - Q_1} \quad (14)$$

ここで、 Q_1, Q_3 は各々入力用訓練データにおける第1四分位数、第3四分位数である。なお、予測誤差はモデルの予測値を逆変換して、もとの尺度に戻した値に基づき計算する。

また、ハイパーパラメータのチューニングには optuna ライブラリ^{*4}を使用した。探索対象としたハイパーパラメータは、モデルの層数、各層のユニット数、活性化関数、最適化アルゴリズムにおける学習率である。

最適化アルゴリズムには Adam を使用し、バッチサイズは 32、学習エポック数は 200 に設定し、GCNs のフィルタの次数は $K = 3$ に設定した。

また、予測モデルへのデータ入力期間は、先行研究において予測時刻の8時間前までが選択されることが多く、本研究もその慣例に習い8時間に設定した。

4.3 評価指標

考案したモデルの有用性を検証するための評価指標として、絶対平均誤差 (MAE)、二乗平均平方根誤差 (RMSE)、加重絶対パーセント誤差 (WAPE) を用いる。各評価指標は次式で定義される。

$$\text{MAE} = \frac{1}{NT} \sum_{n=1}^N \sum_{t=1}^T |y_t^n - \hat{y}_t^n| \quad (15)$$

$$\text{RMSE} = \sqrt{\frac{1}{NT} \sum_{n=1}^N \sum_{t=1}^T (y_t^n - \hat{y}_t^n)^2} \quad (16)$$

$$\text{WAPE} = 100 \times \frac{1}{NT} \frac{\sum_{n=1}^N \sum_{t=1}^T |y_t^n - \hat{y}_t^n|}{\sum_{n=1}^N \sum_{t=1}^T |y_t^n|} \quad (17)$$

ここで、 y_t^n はグリッド v_n の時刻 t における真の滞在人口数、 \hat{y}_t^n はモデルによって計算された対応する予測値を意味する。また、各モデルにおいて訓練と予測を10回ずつ独立に行い、全試行における誤差の値を平均したもので精度の評価を行う。

4.4 比較手法

本研究で提案する手法に加えて、下記のモデルを用いて予測を行い、その精度を比較する。また、これらのモデルにおいても4.2節で述べたハイパーパラメータの調整を同様に施し、予測時の条件は等しくする。

- **Historical Average**

特定の時刻における滞在人口数を、過去の同じ曜日、同じ時刻における滞在人口数の平均値によって予測する。

- **ベクトル自己回帰モデル (VAR モデル)**

時系列に沿って変化する複数の変数をベクトルとしてまとめて扱うモデル。ラグの次数は8を選択した。

- **畳み込みニューラルネットワーク (CNN)**

CNN 単体のモデルであるため、時系列相関を無視した上で空間構造のみに基づいた予測を行う。

- **長・短期記憶 (LSTM)**

CNN とは対照的に時系列相関のみに基づいた予測を行う。

- **Convolutional LSTM (ConvLSTM)**

LSTM を拡張したモデルであり、LSTM と同じ構造を持つがモデルの内部で畳み込み演算を行う。すなわち時系列相関と空間的相関を同時に考慮した予測を行う。

- **ACMV-GCNs**

本研究で提案する手法であり、グラフ構造を扱う GCNs に基づいて空間的相関を把握した後に、GRU を適用することで時系列相関も同時に考慮する。さらに、外的要因に基づいた注意機構によって各出力値に対する重みを動的に変更し、最終的な予測値を出力する。

4.5 結果

各モデルによって予測検証を行った結果を表1に示す。また、注意機構による重み付けの有用性を確認するために、算術平均によって出力値の融合を行った予測モデルとの比較を表2に示す。

*4 <https://optuna.org/>

続いて、注意機構によって計算された重みと都市構造との関連性を視覚的に把握するために、ある平日午前10時の予測における注意機構で求められた重みを図4で地図上に示した。図1の模式図との整合性を保つため、距離グラフの出力値に対する重みを青色の画素に変換しており、POIグラフ、交通ネットワークグラフに関しても同様に赤色、緑色の画素に変換した上で画像で表現している。なお、10回の学習のうち、MAEとWAPEにおいて最も優れた性能を示したモデルにおいて計算された重みを用いている。

表1 各モデルによる予測誤差

モデル	MAE	RMSE	WAPE
Historical Average	205.64	980.68	19.20%
VAR	91.30	165.93	18.94%
CNN	65.27	121.25	17.45%
LSTM	71.80	128.17	23.60%
ConvLSTM	59.85	111.55	15.27%
ACMV-GCNs	57.00	108.73	14.11%

表2 注意機構の有無による予測誤差

出力値の融合方法	MAE	RMSE	WAPE
算術平均	61.03	109.25	18.88%
注意機構	57.00	108.73	14.11%

また、注意機構によって計算された重みが時刻や天候などの外的要因によってどのように変化するかを確認するため、計算された重みの推移を画像として可視化したものを図5, 6に示す。図5は平日晴天時における注意機構で計算された重みを示しており、図6は休日晴天時における重みを示している。

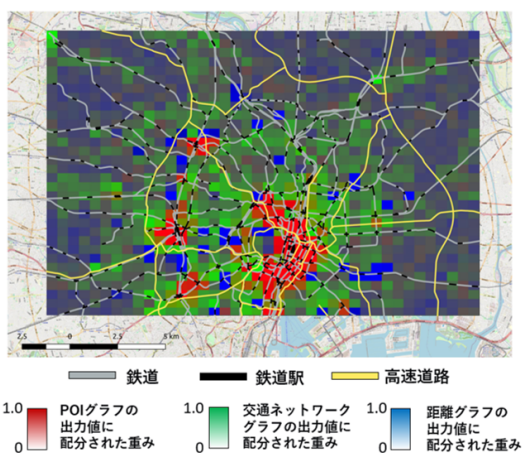


図4 地図上で描画した注意機構によって計算された重み




図5 平日晴天時において注意機構で計算された重み




図6 休日晴天時において注意機構で計算された重み

4.6 考察

表1に示されている結果では、全ての評価指標において本研究で提案したモデルが最も優れた成果を達成しており、都市構造や外的要因を予測に反映させることの有用性が示された。

また、単純な Historical Average や線形モデルの VAR と比較すると、CNN や LSTM などの深層学習に基づいたモデルの方が優れた性能を示す傾向にある。この結果は数多くの先行研究で既に得られており、複雑な非線形関係に基づいた予測を行うことが可能な深層学習モデルの表現力の高さが示唆される。加えて、ConvLSTM が CNN や LSTM 単体のモデルよりも優れた予測性能を示していることから、時系列相関と空間的相関を同時にモデルリングすることの有用性が確認できる。

また、表2の結果からは注意機構の代替として、単純な算術平均値に基づいて予測値を融合した場合、最終的な予測精度が悪化していることが確認できる。すなわち、注意機構は予測精度の向上に貢献していると判断でき、外的要因に基づいて各出力値に対する重みを適切に変更することの重要性が示された。

図4からは鉄道網が密集する中心部において緑色や赤色の画素が大きな割合を占めていることが確認できる。画像左側で赤色の画素が強く表れている地域は、各々池袋駅・新宿駅・渋谷駅に重なっていることが確認でき、3大副都心において POI グラフの予測に対する貢献が大きくなっていることが確認できる。これは副都心の集客力を考慮すれば非常に妥当な結果であり、画像中央部の東京駅周辺において、同様に赤色の画素が大きな割合を占めていること

も納得の行く結果である。また、図からは交通ネットワークグラフへの重みに対応する緑色の画素が、概ね交通網の分布に沿って放射状に拡散していることも確認できる。これらの事実から、注意機構で計算された重みが現実空間における環境をある程度忠実に反映していると判断できる。

図5からは深夜や早朝時刻と比較して、人々が活動する昼間時刻において緑色と赤色の画素の占める割合が増加していることが分かる。すなわち、予測対象の時刻に基づいて、モデルが各グラフで計算された出力値に配分する重みを調整している様子が確認できる。また、この重みの変化は公共交通機関の運行時刻や集客施設の営業時間を考慮すれば妥当な結果であり、注意機構による重み付けが機能していることが確認できる。

図6には休日晴天時における注意機構によって計算された重みを示しており、平日の結果と比較した場合、全体的に交通ネットワークグラフとPOIグラフに対する重みが小さくなっていることが確認できる。特に画像の中央部においてその特徴が顕著であり、昼間時刻においても緑色と赤色の画素の占める割合が小さく留まっている。これは、休日のため会社への通勤が起こり得ないことにより、平日と比較して公共交通機関の予測に対する重要度が減少したことが要因として考えられる。

5. 結論

本研究では都市構造に基づき複数のグラフを作成し、提案した手法であるACMV-GCNsを使用することで、都市特有の空間的相関を多面的に捉えることに成功した。さらに、外的要因に基づく注意機構を設けることにより、モデルが複数の出力値に対して動的に重みを変更することを可能とした。注意機構で計算された重みの検証からは、提案手法が時刻と休日に関する情報を有効的に活用しており、現実の環境と照らし合わせても、非常に納得の行く重みの配分を行っていることが確認された。

本研究ではGCNsの計算上の特性から、扱うグラフは全て無向グラフであることを仮定したが、有向グラフも扱えるようにモデルを拡張することで更なる表現力の向上が期待される。

参考文献

- [1] Defferrard, M., Bresson, X. and Vandergheynst, P.: Convolutional Neural Networks on Graphs with Fast Localized Spectral Filtering, *Proceedings of the International Conference on Neural Information Processing Systems*, pp. 3837–3845 (2016).
- [2] Feng, J., Lin, Z., Xia, T., Sun, F., Guo, D. and Li, Y.: A Sequential Convolution Network for Population Flow Prediction with Explicitly Correlation Modelling, *Proceedings of the International Joint Conference on Artificial Intelligence*, pp. 1331–1337 (2020).
- [3] Geng, X., Li, Y., Wang, L., Zhang, L., Yang, Q., Ye, J. and Liu, Y.: Spatiotemporal Multi-Graph Convolution Network for Ride-Hailing Demand Forecasting, *Proceedings of the AAAI Conference on Artificial Intelligence*, pp. 3656–3663 (2019).
- [4] Guo, S., Lin, Y., Feng, N., Song, C. and Wan, H.: Attention Based Spatial-Temporal Graph Convolutional Networks for Traffic Flow Forecasting, *Proceedings of the AAAI Conference on Artificial Intelligence*, pp. 922–929 (2019).
- [5] Junbo, Z., Yu, Z. and Dekang, Q.: Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows Prediction, *Proceedings of the AAAI Conference on Artificial Intelligence*, pp. 1655–1661 (2017).
- [6] Junbo, Z., Yu, Z., Junkai, S. and Dekang, Q.: Flow Prediction in Spatio-Temporal Networks Based on Multitask Deep Learning, *IEEE Transactions on Knowledge and Data Engineering*, pp. 468–478 (2019).
- [7] Ke, J., Zheng, H., Yang, H. and Chen, X.: Short-term forecasting of passenger demand under on-demand ride services: A spatio-temporal deep learning approach, *Transportation Research Part C: Emerging Technologies*, Vol. 85, pp. 591–608 (2017).
- [8] Liu, T., Wu, W., Zhu, Y. and Tong, W.: Predicting taxi demands via an attention-based convolutional recurrent neural network, *Knowledge-Based Systems*, p. 106294 (2020).
- [9] Shekhar, S. and Williams, B. M.: Adaptive Seasonal Time Series Models for Forecasting Short-Term Traffic Flow, *Transportation Research Record*, pp. 116–125 (2007).
- [10] Shuman, D., Narang, S. K., Frossard, P., Ortega, A. and Vandergheynst, P.: The Emerging Field of Signal Processing on Graphs: Extending High-Dimensional Data Analysis to Networks and Other Irregular Domains, *IEEE Signal Processing Magazine*, pp. 83–98 (2012).
- [11] Sun, J., Zhang, J., Li, Q., Yi, X. and Zheng, Y.: Predicting Citywide Crowd Flows in Irregular Regions Using Multi-View Graph Convolutional Networks, *arXiv preprint arXiv:1903.07789* (2019).
- [12] Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C. and Yu, P. S.: A Comprehensive Survey on Graph Neural Networks, *IEEE transactions on neural networks and learning systems*, pp. 4–24 (2021).
- [13] Xie, P., Li, T., Liu, J., Du, S., Yang, X. and Zhang, J.: Urban flow prediction from spatiotemporal data using machine learning: A survey, *Information Fusion*, pp. 1–12 (2020).
- [14] Yao, H., Wu, F., Ke, J., Tang, X., Jia, Y., Lu, S., Gong, P., Ye, J. and Li, Z.: Deep Multi-View Spatial-Temporal Network for Taxi Demand Prediction, *Proceedings of the AAAI Conference on Artificial Intelligence*, pp. 2588–2595 (2018).
- [15] Yu, B., Yin, H. and Zhu, Z.: Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting, *Proceedings of the International Joint Conference on Artificial Intelligence*, pp. 3634–3640 (2018).
- [16] Zhang, J., Zheng, Y., Qi, D., Li, R. and Yi, X.: DNN-Based Prediction Model for Spatio-Temporal Data, *Proceedings of the ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, pp. 92:1–92:4 (2016).