

時間・空間的相関を考慮した人流の時系列予測手法

挺屋 友幹^{1,a)} 青木 俊介² 米澤 拓郎¹ 河口 信夫^{1,2}

概要：人の流れをモデル化し、次の流れを予測する人流予測は渋滞予測や災害時の群衆誘導に活用されている。人流予測は過去時系列から次の値を予測しようとする時間的相関を考慮するタスクと、人流をカウントするセンサの位置関係などの空間的相関を考慮するタスクの両方を考える必要がある。それらのタスクで最適化するために、従来ではグラフ構造を再帰型ニューラルネットワークの入力に使用する GCN-RNN (Graph Convolutional Network - Recurrent Neural Network) ベースのモデルが提案されているが、パラメータ数の増加によるデータへの過剰適合を理由にノード固有の特徴を表すためのノード埋め込み次元を大きくすることができず、より正確な空間的相関を推論することができていない。本研究ではリッジ罰則に基づいてパラメータ空間を制限し、大きなノード埋め込み次元を持つことのできる予測モデルを提案する。また、人流は少なくとも一日単位での周期があるので、予測には予測時点の直前までのデータに加えて一日前のデータや一週間のデータを使って予測することができる。本研究では予測に大きく関わる局所的な時系列を過去系列から探索し、それを直接予測に用いる手法を用いることで、より複雑な時間的相関を捉える。その提案モデルを実世界の人流データセットに対して適応させ、既存手法と予測精度を比較することで評価を行い、検証した評価指標全てにおいて従来手法よりも高精度な予測が行えることが確認できた。

キーワード：人流予測, 深層学習, 時系列予測, 時空間相関, グラフ畳み込みネットワーク

1. はじめに

人の流れをモデル化し、次にどのように人が動くのかを予測する人流予測は、渋滞予測や災害時の群衆の誘導 [1] などに活用されており、コンピューター科学によって都市問題を解決するアーバンコンピューティングの問題の一つとして位置している。人流予測を行う際に使用する人流データは、BLE (Bluetooth Low Energy) ビーコンの検知イベント [2] や Wi-Fi アクセスポイントのログによる検知端末数、人感センサによる人数情報や電車の乗降者データ [3]、車両の GPS データ [4] などを使用して収集されているが、人感センサなどの固定されたセンサを使用するときは人流予測を、センサそれぞれの人数カウント情報の時系列を予測する多変量時系列予測として考えることができる。

人流予測での多変量時系列予測を考える際、次の二つのタスクについて考える必要がある。

(1) 変化する人流の時間的ダイナミクスをうまくとらえるタスク

(2) 複雑な交通網における空間依存性をとらえるタスク

1) の時間的相関を考慮するタスクに関しては、電車の到着などのイベントの有無や天候の影響などを受けて、非定常性を引き起こすことで長期予測を困難にしている。この時間的依存をとらえるために、ARIMA モデル (自己回帰和分移動平均モデル) やカルマンフィルター、ベクトル自己回帰 (VAR) を使用する方法がなされたが、単純な時系列モデルは通常、時系列に定常性があるものと仮定して行われるので、非定常な時間的変化のある人流などの交通予測には、これらの単純なモデルは有効でない。そのため従来では深層学習を用いた手法がとられている。しかしその深層学習の手法としては通常、再帰型ニューラルネットワーク [5], [6], [7], [8] (Long-Short Term や Gated Recurrent Unit など) や時間畳み込みモジュール [9], [10] を用いて時間依存性をモデル化している。しかしこれらは時間依存性をモデル化しているに過ぎず、空間的相関を考慮していないために、2) のタスクについて最適化することができない。

一方で2)の空間依存性をモデル化するために従来では、グラフ構造をニューラルネットワークの入力に使用する GCN ベースの手法 [9], [10], [11], [12], [13], [14], [15] が一般的に使用されている。中でもグラフ構造を再帰型ニューラルネットワークの入力に使用する GCN-RNN(Graph Convo-

¹ 名古屋大学大学院 工学研究科
Graduate School of Engineering, Nagoya University

² 名古屋大学未来社会創造機構
Institutes of Innovation for Future Society,
Nagoya University

a) choya@ucl.nuee.nagoya-u.ac.jp

lutional Network - Recurrent Neural Network) ベースのモデルにおいて、ノード固有のパラメータ空間を生成し、データからノード埋め込みを推論することでノードの隣接行列を学習によって得るモデルである AGCRN(Adaptive Graph Convolutional Recurrent Network)[16] は、他の GCN ベースのモデルと比べて良い予測精度を得ている。しかし、パラメータ数の増加によるデータへの過剰適合を理由にノード固有の特徴を表すためのノード埋め込み次元を大きくすることができず、より正確な空間的相関を推論することができていないという課題を持つ。

そこで本研究では、リッジ罰則に基づいてパラメータ空間を制限し、大きなノード埋め込み次元を持つことのできる予測モデルを提案する。ノード埋め込み次元を大きくすることで、ノードの隣接行列を決定づける要素を増やし、より空間的相関を高い自由度で推論することができると考えられる。また、1) の課題の一つである長期予測人流は少なくとも一日単位での周期があるので、予測には予測時点の直前までのデータに加えて一日前のデータや一週間のデータを使って予測することができる。しかしモデルへの入力に過去の長い情報を使用してしまうと、計算時間の膨大な増加や、予測時点からは遠いが強く予測に関わってくるような情報が減衰してしまうといった問題が生じる。そこで我々は予測に大きく関わる局所的な時系列を過去系列から探索し、それを直接予測に用いる手法を提案する。この構造では計算時間や計算リソースの削減を可能にし、より複雑な時間的相関を捉える。その提案モデルを実世界の人流データセットに対して適応させ、従来の予測手法と予測精度を比較することで評価を行う。

2. 関連研究

本章では、人流の時系列予測手法に関する関連研究について述べる。

2.1 再帰的ニューラルネットワーク

相関性のある時系列予測、つまり多変量時系列予測は数十年前から研究されてきた。近年では、データから相関関係を自動で推論でき、非定常な時系列の予測も行えることから深層学習を用いる手法が多く提案されている。そのような研究では複雑な時間的ダイナミクスをモデル化するために LSTM や GRU といった再帰的ニューラルネットワークを用いており、時間的な相関は比較的うまくとらえられているものの、異なる時系列間の相互依存性のモデル化ができていない。

2.2 GCN

最近の研究ではセンサ間の空間的な相関をとらえるために、GCN(Graph Convolutional Network) ベースの研究が行われている。GCN ベースの時系列予測では、グラフの

ノードに各センサが割り当てられ、各ノードが任意の時間長の時系列を持っているとする。そのグラフが再帰的ニューラルネットワークの入力として使用され、出力として予測したい時間におけるグラフが出力される。DCRNNでは空間依存性を拡散過程として再定式化し、GCN を有向グラフに拡張した。Graph Wavenet では、GCN と因果畳み込みネットワークを組み合わせることで、長い時間入力を扱う際の計算時間を削減した。また、ASTGCN や STSGCN, GMAN ではより複雑なメカニズムを GCN に適用し、動的な空間依存性を捉えようとした。しかしこれらの GCN ベースのモデルはあらかじめ定義された隣接行列を使用しており、その隣接行列の定義にはセンサ間の距離などが使用されたが、実際にはセンサ間の関係性は距離だけでは表すことができず、逆に距離の情報がバイアスとしてはたらいってしまう。また、グラフ畳み込みを行う際のパラメータは全てのノードにおいて共通しており、個々のノードの特徴、つまり個々のセンサ特有の時間的な変化をとらえることができなかった。そこで AGCRN[16] が提案され、そのモデルではノード埋め込みベクトルを推論することでノード固有のパラメータ空間を作り出し、隣接行列も学習の過程で推論することを可能とした。しかし、通常の GCN に比べてパラメータが多くなり、データへ過剰適合しやすいという理由から、ノード埋め込み次元を大きくできず、結果としてより正確な空間的相関を推論することができていない。

3. 提案手法

本章では、本研究で提案する時系列予測手法について述べる。3.1 では GCN-RNN の定式化と高次のノード埋め込みを可能にするパラメータの制限手法について、3.2 では予測に直接利用可能な局所的時系列の抽出方法について述べる。

3.1 GCN-RNN

本節では、GCN ベースのモデルで最も高い予測精度を出している AGCRN[16] に基づいて問題の定式化を行う。

人流の予測には時系列の空間的な相関をとらえるために GCN を導入する。GCN で行われるグラフ畳み込み演算は、1 次のチェビシェフ多項式展開によって近似でき、高次元の GCN において次のように一般化される。

$$\mathbf{Z} = \left(\mathbf{I}_N + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \right) \mathbf{X} \Theta + \mathbf{b} \quad (1)$$

ここで、 \mathbf{A} はグラフの隣接行列であり $\mathbf{A} \in \mathbb{R}^{N \times N}$ である。 \mathbf{D} は次数行列、 $\mathbf{X} \in \mathbb{R}^{N \times C}$ および $\mathbf{Z} \in \mathbb{R}^{N \times F}$ は GCN 層への入力であり、 $\Theta \in \mathbb{R}^{C \times F}$ や $\mathbf{b} \in \mathbb{R}^F$ は重みをバイアスのパラメータであり、学習の過程で最適化される。しかし、本研究では AGCRN[16] に基づいて、グラフ畳み込み演算を次式で表す。

$$\mathbf{Z} = \left(\mathbf{I}_N + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \right) \mathbf{X} \mathbf{E}_G \mathbf{W}_G + \mathbf{E}_G \mathbf{b}_G \quad (2)$$

(1) 式と (2) 式では重みやバイアスのパラメータに $\mathbf{E}_G \in R^{N \times d}$ をかけているところが異なる。 d はノード埋め込み次元を表し、重みプールは $\mathbf{W}_G \in R^{d \times C \times F}$ として表され、 Θ は $\Theta = \mathbf{E}_G \cdot \mathbf{W}_G$ の演算を経て得られる。このように書き換えることによって、ノード固有の重みプールやバイアスプールが確保でき、ノード固有の特徴、つまり人流を計測したセンサ個々の時系列の特徴を学習できる。逆に言えば (2) 式のように変換せず (1) 式のまま扱ったと、重みプールやバイアスプールは全てのノードで共有されることとなり、個々の時系列の特徴を学習することなく、全ての時系列に共通する特徴のみ学習することとなる。

(2) では予め定義された隣接行列 \mathbf{A} が用いられているが、事前にグラフを定義すると空間依存性に関する全ての情報を含めさせることは難しく、逆に隣接行列に設定した値がバイアスとしてはたらいってしまうことが懸念される。そこで \mathbf{A} を生成して対称正規化ラプラシアン行列 $\mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}}$ を得るのではなく、ノード埋め込みベクトルを使用した低ランク近似を行い、対称正規化ラプラシアン行列を次のように求められる。

$$\mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} = \text{softmax}(\text{ReLU}(\mathbf{E} \cdot \mathbf{E}^T)) \quad (3)$$

(2)(3) 式より空間的相関を考慮する更新式が定式化されたので、次はそれらを再帰的ニューラルネットワークの構造に取り込んでいく。再帰的ニューラルネットワークのモデルには GRU を用い、その内部での演算は以下のように表される。

$$\tilde{\mathbf{A}} = \text{softmax}(\text{ReLU}(\mathbf{E} \cdot \mathbf{E}^T)) \quad (4)$$

$$\mathbf{z}_t = \sigma \left(\tilde{\mathbf{A}} [\mathbf{X}_{:,t}, \mathbf{h}_{t-1}] \mathbf{E} \mathbf{W}_z + \mathbf{E} \mathbf{b}_z \right) \quad (5)$$

$$\mathbf{r}_t = \sigma \left(\tilde{\mathbf{A}} [\mathbf{X}_{:,t}, \mathbf{h}_{t-1}] \mathbf{E} \mathbf{W}_r + \mathbf{E} \mathbf{b}_r \right) \quad (6)$$

$$\hat{\mathbf{h}}_t = \tanh \left(\tilde{\mathbf{A}} [\mathbf{X}_{:,t}, \mathbf{r} \odot \mathbf{h}_{t-1}] \mathbf{E} \mathbf{W}_h + \mathbf{E} \mathbf{b}_h \right) \quad (7)$$

$$\mathbf{h}_t = \mathbf{z}_t \odot \mathbf{h}_{t-1} + (1 - \mathbf{z}_t) \odot \hat{\mathbf{h}}_t \quad (8)$$

ここで、 $\mathbf{X}_{:,t}$ や \mathbf{h}_t は時間ステップ t における入出力を表し、 z や r は GRU におけるリセットゲートと更新ゲートを意味する。 $\mathbf{E}, \mathbf{W}_z, \mathbf{W}_r, \mathbf{W}_h, \mathbf{b}_z, \mathbf{b}_r, \mathbf{b}_h$ は更新可能なパラメータを表す。

深層学習を行う際、現在どれくらいの誤差で学習が進んでいるかの指標となる損失関数を定義するが、時系列予測で一般的に用いられる絶対誤差の他に正則化項をペナルティとして加える。正則化項をペナルティとして付加することでパラメータの発散を制限し、モデルに過剰適合することを防ぐ。

$$\mathcal{L}(\mathbf{W}_\theta) = \sum_{i=t+1}^{i=t+\tau} |\mathbf{X}_{:,i} - \mathbf{X}'_{:,i}| + \lambda \sum_i |\Theta_i|^2 \quad (9)$$

正則化項には通常 L1 正則化や L2 正則化がよく用いられるが、本研究では L2 正則化を用いる。L1 正則化を用いた際、パラメータは 0 に収束することが多くなる。つまり特徴選択が行われ、不必要な特徴は 0 に近づく。0 が多くなると行列はより疎となり、計算が高速化される。その行列が疎になった場合を考えてみる。ノードの結びつきの強さを表す隣接行列 \mathbf{A} はノード埋め込み行列のによって計算された ((4) 式)。学習によってノード埋め込み行列が疎になった時には隣接行列も同時に疎になる。GCN ベースのモデルを使用する本来の目的は時系列間の複雑な空間依存性を考慮することであったが、隣接行列が疎になってはその複雑な空間依存性を読み取ることができなくなる。影響の強いエッジだけが残り、影響の弱いエッジが切り捨てられるとセンサ間の微量の人の移動を考慮できなくなるからだ。よってそのようなスパース性を持つ L1 性則化よりも、L2 性則化の方がパラメータ空間を制限しながらも、複雑な空間依存性を表現できると考え L2 正則化項をペナルティとして用いる。

3.2 過去時系列からの抽出

本節では、予測時点付近のデータだけでなく、広く過去の時系列を入力に使用する際に行う操作について述べる。

人は一日単位で行動するため、人流データには少なくとも 1 日の周期が存在する。そこで、入力時系列の長さは細かな周期がわからない限り 1 日分の長さが必要となる。また、1 日の周期があるので、予測時点付近の動きは 1 日前や 1 週間前にも似たような動きが見られ、その付近のデータは予測に有効であると考えられる。(図 1) 1 週間分のデータをそのまま深層学習モデルに入力しても予測はある程度行えるが、入力が非常に大きくなるため計算時間が大幅に増大し、非常に多くの計算リソースが必要となる。

そこで本研究では 1 日前や 1 週間前などの過去系列から、予測時点付近と似た動きをしている局所的な時系列を探索し、直接予測に用いる手法を提案する。

似た動きをする部分はちょうど 1 日前やちょうど 1 週間前を探せばそこに存在するわけではない。日によって多少の時間のズレが生じ、そのズレがどのようなレベルであっても探索できなくてはならない。そのための手順を次で述べる。

まず、予測付近の数時間分を比較する元になるものとして用意する。本研究では 3 時間分を使用した。この時間の長さは、短すぎても長すぎてもいけない。短すぎると探索をした時に似た局所的な時系列が多く存在し、どれが本当に予測に関係があるのか判断できなくなってしまう。そして長すぎると探索に必要な計算時間が増えてしまうので望ましくない。

次に 1 日前の時系列に対してその任意の時系列長をスライドしながら比較して、どれだけ似ているかを評価してい




図 1 時系列比較の例

Fig. 1 Example of time series comparison.




図 2 時系列探索の例

Fig. 2 Example of time series search.

く。(図 2) 全ての組み合わせについて評価を行った後、最も似ている局所的時系列の直後を予測値に近いものであると仮定して保持しておく。この保持しておくものは、統計的に導かれた予測値という意味合いを持つ。人が直感的に時系列予測を行う場合、過去の同じような動きをしているところを参考に予測を行うだろう。例えば、昨日と一昨日のこの時間に急激に値が増加したので、今日のこの時間もおそらく増加するだろうといった考え方である。この考え方と同じプロセスを予測に組み込めるように、似た時系列を探して、その直後の値を予測に使用する操作を行う。そしてこの操作を 2 日前 3 日前と行う。時系列がどれだけ似ているかの評価値 val はユークリッド距離とコサイン類似度を用いて次のように求める。

$$d(x, y) = \sqrt{\left(\frac{x_1 - y_1}{\sigma_1}\right)^2 + \dots + \left(\frac{x_n - y_n}{\sigma_n}\right)^2} \quad (10)$$

$$c(x, y) = 1 - \frac{x_1 y_1 + \dots + x_n y_n}{\sqrt{x_1^2 + \dots + x_n^2} \sqrt{y_1^2 + \dots + y_n^2}} \quad (11)$$

$$val = d(x, y) * c(x, y) \quad (12)$$

ここで x_1, x_2, \dots, x_n は系列 X の要素で、 y_1, y_2, \dots, y_n は系列 Y の要素である。その系列 X, Y に関する評価値を計算している。(10) 式のユークリッド距離は時系列の各点の距離をみることで時系列間の距離を算出している。各点の

距離を計算していることから、ユークリッド距離だけでは時系列の上下する動きを比較評価することができない。そこでコサイン類似度を用いて時系列の動きの比較評価を行う。(11) 式) このように求められた val は、値が 0 に近ければ近いほど比較した時系列が似たものであると言える。

数日分の探索を行って求められた、予測値に関与する値を最後に再帰的ニューラルネットワークによって求められた予測値と共に畳み込みの操作を行って最終的な予測値を計算する。

4. 評価

4.1 データセット

本節ではモデルの評価に用いるデータセットについて述べる。評価には二つのデータセットを用いる。

一つ目は永田らによって行われた人流推定の研究 [17] で設置された、3 D 人感センサから収集された人の通過データを、15 分の時間粒度で通過人数をカウントしたものである。人感センサはある屋内の閉空間の出入り口に計 21 個設置され、それぞれのセンサが閉空間に入った情報と、出ていった情報を計測できるため、合計で 42 個の時系列がある。2020 年 6 月 1 日～2020 年 11 月 18 日の期間の平日のデータを使用し、データが収集されなかった部分は事前に取り除いた。このデータセットを用いて提案手法と従来法の精度比較を行う。

二つ目は従来法の AGCRN でも使用されていたデータセットである PeMSD4 である。PeMSD4 はアメリカ合衆国、サンフランシスコにおける交通流データセットであり、Caltrans Performance Measurement System (PeMS) によって 30 秒ごとにリアルタイムで収集されている。期間は 2018 年 1 月 1 日～2018 年 2 月 28 日である。307 個の交通量検出器で計測されており、データには総流量、平均速度、平均占有率の 3 つの特徴量が記録されている。一つ目のデータセットに比べて空間的に大規模なデータセットになっている。このデータセットを用いて、ノード埋め込み次元の大きさに対するモデルの予測精度の評価を行う。

4.2 評価指標

予測精度の評価には MAE (Mean Absolute Error, 平均絶対誤差), RMSE (Root Mean Square Error, 平均平方二乗誤差) MAPE (Mean Absolute Percentage Error, 平均絶対誤差率) を用いる。データ数を n , 真の値を y_1, \dots, y_n , 予測値を f_1, \dots, f_n とすると、各評価指標は次のように表される。

$$MAE = \frac{1}{n} \sum_{k=1}^n |f_i - y_i| \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (f_i - y_i)^2} \quad (14)$$

$$\text{MAPE} = \frac{100}{n} \sum_{k=1}^n \left| \frac{f_i - y_i}{y_i} \right| \quad (15)$$

これら全ての評価指標において、値が小さい方が予測精度が優れている評価になる。

4.3 比較

検証1 検証1では4.1の前半で述べた、人感センサから得られたデータセットを用いて、提案手法と従来手法の予測精度比較を行う。検証1で比較するにあたって提案手法とは、損失関数にペナルティを課し、過去系列から予測に必要な部分を探索して直接予測に使用したモデルを指す。この提案手法と、従来法である AGCRN、そして提案手法の内で損失関数にペナルティを課す構造のみ用いた AGCRN+regulation で比較して評価を行う。

検証2 検証2では4.1の後半で述べた PeMSD4 データセットを用いて、ノード埋め込み次元を大きくした場合の予測精度への影響を調べる。検証2においては、提案手法で正則化項をペナルティとして損失関数に付加したモデルと、付加しないモデルで比較を行い、ノード埋め込み次元の大きさとペナルティ項の有無の関係を調べる。

4.4 モデルの学習

検証1ではモデルのパラメータを表1で示すように設定し、学習を行った。その訓練と検証での損失の推移は図3に示し、モデルの評価比較を表2に示す。その図3は縦軸が損失で横軸がエポック数、つまりデータを何周学習したのかを表す。青色の線が訓練の損失の推移、オレンジ色の線が検証の損失の推移を表し、検証の損失が収束しきって検証時の損失が一番低いところのモデルを保存している。

検証2ではノード数を307、ノード埋め込み次元を可変として、それ以外は表1で示すように学習を行った。その評価比較を表3に示す。

また、深層学習ライブラリはPytorchを用いて実装され、バージョンは1.1.0である。実行は一枚の NVIDIA QUADRO RTX 8000 で行われた。

4.5 考察

検証1の結果である表2より、提案手法が全ての評価使用において従来手法の AGCRN よりも精度が高いことがわかる。MAPE においては AGCRN+regulation が最も良い精度を出しているが、その他の2つの指標においては AGCRN よりも精度に欠いている。このことから予測を行うにあたって、過去時系列から予測に関与しそうな部分を探索し、その次の時間ステップを直接予測に使用する構造が予測に有効であると言える。また、MAPE がどれも70%に近い値を記録し、モデルの予測精度が悪いように思われるが、これはデータセットに原因があると考えられる。MAPE の定義である (15) 式を見てわかるように、分

表1 深層学習モデルのパラメータ

Table 1 Deep learning model parameters.

パラメータ	値
入力時系列の長さ	100
ノード数	42
GRU のユニット数	64
GRU の層数	2
バッチサイズ	256
ノード埋め込み次元	30
最適化法	Adam
損失関数	MAE
チェビシェフ次数	2
データの正規化	std
ペナルティ項の係数	5e-4




図3 訓練と検証での損失の推移

Fig. 3 Loss in training and validation.

表2 検証1 モデルの評価比較

Table 2 Model evaluation comparison.

	評価指標		
	MAE	RMSE	MAPE
AGCRN	5.86	16.82	76.5426%
AGCRN+regulation	5.99	18.46	68.4778%
提案手法	5.50	15.60	70.4491%

表3 検証2 ノード埋め込み次元と精度の関係

Table 3 Relationship between node embedding dimension and accuracy.

	次元	評価指標		
		MAE	RMSE	MAPE
正則化項なし	10	24.98	45.14	14.2026%
	50	129.35	164.33	185.4857%
	100	129.35	164.32	185.5433%
正則化項あり	10	24.92	45.23	14.1721%
	50	25.34	45.96	14.4379%
	100	25.41	46.50	14.2135%

母に真の値 y があるが、真の値が0もしくは0に近い時、MAPE の値は非常に大きくなる。実際にデータセットに

は夜中から早朝にかけての一通りの少ない時間は、0を計測している。よってMAPEの値が大きくなってしまったと考えられる。

検証2の結果である表3より、ノード埋め込み次元が大きければ大きいほど正則化が有効であることがわかる。ノード埋め込み次元が50, 100の時には正則化項なしでは予測誤差が極めて大きくなってしまっている一方、正則化項ありではノード埋め込み次元が100であっても予測が発散することなく低い予測誤差を得ることができた。このことより、空間的に大規模な人流予測を行う場合には、より複雑な空間依存性を考慮するためにより正確なノードの隣接行列を推論する必要があるが、そのために正則化項を付加してパラメータ空間を制限することで発散を抑え、高いノード埋め込み次元で自由度の大きい隣接行列の推論を行うべきであると言える。

以上より提案手法は時間的な相関と空間的な相関の両方に対して考慮しながら学習できるモデルと言える。

5. まとめ

本論文ではグラフ構造を再帰型ニューラルネットワークの入力に使用するGCN-RNN (Graph Convolutional Network - Recurrent Neural Network) ベースのモデルにおいて、パラメータ数の増加によるデータへの過剰適合を理由にノード固有の特徴を表すためのノード埋め込み次元を大きくすることができず、より正確な空間的相関を推論することができていないという問題に対し、リッジ罰則に基づいてパラメータ空間を制限し、大きなノード埋め込み次元を持つことのできる予測モデルを提案した。また、人流は少なくとも一日単位での周期があることから、予測には予測時点の直前までのデータに加えて一日前のデータや一週間のデータを使って予測することを行った。その時系列に対して予測に大きく関わる局所的な時系列を過去系列から探索し、それを直接予測に用いる手法を用いることで、より複雑な時間的相関を直感的に捉える構造を提案した。その提案モデルを実世界の人流データセットに対して適応させ、従来の予測手法と予測精度を比較することで評価を行い、提案手法は時間的な相関と空間的な相関の両方を考慮して予測を行えることがわかった。

謝辞 本研究の一部はNICT委託研究により支援していただいております。

参考文献

- [1] 佐藤 大祐, 塩原 寿子, 宮本 勝, 上田 修功, 群集誘導のための人流予測技術.2018
- [2] 佐藤 大祐, 美原 義行, 佐藤 吉秀, 田中 悠介, 宮本 勝, 佐久間 聡, BLE ビーコンを利用した混雑度可視化サービス, 情報処理学会論誌 2018.
- [3] Desheng Zhang, Tian He, Fan Zhang, Real-Time Human Mobility Modeling with Multi-View Learning, 2017.
- [4] Shunsuke Aoki, Kaoru Sezaki, Nicholas Jing Yuan, Xing Xie, An Early Event Detection Technique with Bus GPS Data, 2017.
- [5] Lei Bai, Lina Yao, Salil S Kanhere, Zheng Yang, Jing Chu, and Xianzhi Wang. Passenger demand forecasting with multi-task convolutional recurrent neural networks. In Pacific-Asia Conference on Knowledge Discovery and Data Mining, pages 29–42. Springer, 2019.
- [6] Xianfeng Tang, Huaxiu Yao, Yiwei Sun, Charu Aggarwal, Prasenjit Mitra, and Suhang Wang. Joint modeling of local and global temporal dynamics for multivariate time series forecasting with missing values. arXiv preprint arXiv:1911.10273, 2019.
- [7] Huaxiu Yao, Fei Wu, Jintao Ke, Xianfeng Tang, Yitian Jia, Siyu Lu, Pinghua Gong, Jieping Ye, and Zhenhui Li. Deep multi-view spatial-temporal network for taxi demand prediction. In Thirty-Second AAAI Conference on Artificial Intelligence, 2018.
- [8] David Salinas, Valentin Flunkert, Jan Gasthaus, and Tim Januschowski. Deepar: Probabilistic forecasting with autoregressive recurrent networks. International Journal of Forecasting, 2019.
- [9] Lei Bai, Lina Yao, Salil S Kanhere, Xianzhi Wang, and Quan Z Sheng. Stg2seq: spatial-temporal graph to sequence model for multi-step passenger demand forecasting. In Proceedings of the 28th International Joint Conference on Artificial Intelligence, pages 1981–1987. AAAI Press, 2019.
- [10] Bing Yu, Haoteng Yin, and Zhanxing Zhu. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting. In Proceedings of the 27th International Joint Conference on Artificial Intelligence, pages 3634–3640, 2018.
- [11] Yaguang Li, Rose Yu, Cyrus Shahabi, and Yan Liu. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting. In the Sixth International Conference on Learning Representations (ICLR), 2018.
- [12] Zonghan Wu, Shirui Pan, Guodong Long, Jing Jiang, and Chengqi Zhang. Graph wavenet for deep spatial-temporal graph modeling. In Proceedings of the 28th International Joint Conference on Artificial Intelligence, pages 1907–1913. AAAI Press, 2019.
- [13] Shengnan Guo, Youfang Lin, Ning Feng, Chao Song, and Huaiyu Wan. Attention based spatialtemporal graph convolutional networks for traffic flow forecasting. In Proceedings of the AAAI Conference on Artificial Intelligence, volume 33, pages 922–929, 2019.
- [14] Chao Song, Youfang Lin, Shengnan Guo, and Huaiyu Wan. Spatial-temporal synchronous graph convolutional networks: A new framework for spatial-temporal network data forecasting. In Proceedings of the AAAI Conference on Artificial Intelligence, 2020.
- [15] Chuanpan Zheng, Xiaoliang Fan, Cheng Wang, and Jianzhong Qi. Gman: A graph multiattention network for traffic prediction. arXiv preprint arXiv:1911.08415, 2019.
- [16] Lei Bai, Lina Yao, Can Li, Xianzhi Wang, Can Wang, Adaptive Graph Convolutional Recurrent Network for Traffic Forecasting, arXiv preprint arXiv:2007.02842, 2020.
- [17] 永田 吉輝, 廣井 慧, 米澤 拓郎, 河口 信夫, 複数の3D通過センサによるプライバシーを考慮した人流推定手法, 2020.