

修士論文

時空間データの関係性を柔軟に捉えるための
RNN アテンションモデル

井上 嵩史

2019 年 2 月 22 日

奈良先端科学技術大学院大学
情報科学研究科 情報科学専攻

本論文は奈良先端科学技術大学院大学情報科学研究科に
修士（工学）授与の要件として提出した修士論文である。

井上 嵩史

審査委員：

池田 和司 教授	（主指導教員）
松本 裕治 教授	（副指導教員）
澤田 宏 客員教授	（副指導教員）
岩田 具治 客員准教授	（副指導教員）

時空間データの関係性を柔軟に捉えるための RNN アテンションモデル*

井上 嵩史

内容梗概

近年，都市化が進み世界中の都市部において混雑や遅延が問題となっている．混雑や遅延の問題の根本的な原因の一つとして挙げられるのは，人々の複雑な移動である．人々の移動を予測することが混雑や遅延の問題を克服する上で効果的であると考えられる．予測値に基づき誘導員を適切な場所に配置したり，適切なタイミングに人々を誘導するための放送を流す技術が現在検討されている．混雑や遅延を未然に防ぐためには，人々の移動を予測することが一つの解決策であり，予測精度を上げることが求められる．そこで，本研究では，予測精度の向上を目的とする．アテンション機構を適応した Recurrent Neural Network (RNN) を用いて，時空間データの関係性を捉えることにより予測精度を向上させる研究が提案されている．しかし，RNN による人々の分布を予測する上で，RNN における予測したい場所の現時刻の hidden layer の出力と異なる場所の過去の時刻の hidden layer の出力との関係性を捉えた手法は提案されていない．そこで，本研究ではアテンション機構を用いて時空間データの関係性を柔軟に捉える RNN アテンションモデルを提案する．提案法において，予測したい場所の時系列データとは異なる場所の時系列データを参照することが確認された．また，提案法により時空間データの関係性を柔軟に捉えることは予測精度を向上させる上で有効であることが確認された．

キーワード

時系列解析，時空間データ，人口予測，アテンション機構，RNN，ディープラーニング，データマイニング

*奈良先端科学技術大学院大学 情報科学研究科 情報科学専攻 修士論文, 2019 年 2 月 22 日.

RNN Attention Models to Capture Relations of Spatio-temporal Data*

Takashi Inoue

Abstract

In recent years, congestion and delay problems are happening in cities by increasing urbanization in the world. A basic reason of the problems is complicated movements of people. For that reason, predicting movements are an effective way to prevent from these problems. Based on the predicted values, technologies are developed now, for example setting guide appropriately and announcing at the right time. To prevent from these problems, predicting movements of people is a solution, but a high prediction accuracy is needed to limit the extent of damage. Using recurrent neural network (RNN) with attention mechanism, prediction methods that capture the relations of spatio-temporal data have been proposed. But the relations between the output of the hidden layer in the target area and the output of the hidden layer in other area are not considered. In my research, using attention mechanism, I propose RNN attention models that capture relations of spatio-temporal data. In practice, the proposed models predict future population data choosing population data in other area. As a result, proposed methods are effective to improve the prediction accuracy.

Keywords:

time series analysis, spatio-temporal data, population prediction, attention mechanism, rnn, deep learning, data mining

*Master's Thesis, Department of Information Science, Graduate School of Information Science, Nara Institute of Science and Technology, February 22, 2019.

目次

図目次	v
表目次	vi
第 1 章 序論	1
1.1 背景と目的	1
1.2 問題定義	2
1.3 論文構成	2
第 2 章 方法	3
2.1 従来法	3
2.1.1 RNN モデル	3
2.1.2 アテンションモデル	5
2.2 提案法	6
第 3 章 実験	9
3.1 データセット	9
3.2 提案法の条件設定	11
3.3 比較手法の条件設定	12
3.4 評価指標	12
3.5 実験結果	13
3.5.1 性能評価	13
3.5.2 Haven Area の評価	14
第 4 章 考察	15
4.1 周囲の地点の情報を使い分けている地点	15
4.2 ターゲットエリアのみを選択する地点	17
4.3 選択した地点が偏っていた地点	19
4.4 Haven Area を加えた場合による予測	20

第 5 章 結論	22
謝辞	23
参考文献	24
付録 A 長期予測	25

図目次

2.1	RNN モデル	3
2.2	アテンションモデル	5
2.3	提案法において用いる周囲のデータ	7
2.4	提案法	8
3.1	人口データの範囲（関東近郊）	9
3.2	人口データの範囲（関西近郊）	9
3.3	人口データの範囲（中部近郊）	9
3.4	人口データの範囲（北京近郊）	9
4.1	提案法による予測（田島駅周辺）	15
4.2	提案法による予測（篠塚駅周辺）	17
4.3	提案法による予測（用土駅周辺）	19
4.4	ベースラインと提案法による予測（原始村周辺）	20

表目次

3.1	提案法とベースラインの平均二乗誤差の比較	13
3.2	Haven Area のアテンションスコアが 0 より大きい地点における 提案法とベースラインの絶対誤差の比較	14

第 1 章 序論

1.1 背景と目的

近年，都市部に移り住む人々が増加したり，都市域ではなかった地域が都市になったりする都市化が顕著になっている [8]．都市化により起きる問題として混雑や遅延などが挙げられる．混雑や遅延は都市化が進んでいる地域において世界的にも問題となっており [3] 早急に手を打たねばならない課題である．

混雑や遅延の原因として，事故や災害などの異常事態が挙げられるが，根本的な原因の一つとして人々の複雑な移動が挙げられる．人々の複雑な移動が連鎖して混雑，遅延が生じるのは想像に難くない．

人々の移動を予測することが現状の問題点を克服するためには効果的であると考えられる．予測値に基づき誘導員を適切な場所に配置したり，適切なタイミングに人々を誘導するための放送を流す技術が現在検討されている [6]．混雑や遅延を未然に防ぐためには，人々の移動を予測することが一つの解決策であり，予測精度を上げることが求められる．そこで，本研究では，予測精度の向上を目的とする．

人々の移動を予測する先行研究は，主にシミュレーションを用いた予測手法 [2, 9] と機械学習を用いた予測手法 [1, 7] に分かれる．本研究では，機械学習を用いた予測モデルを提案する．機械学習は実データを扱うため，より実用性のある予測ができる．機械学習を用いて時空間データを予測する手法が Vemula らの論文 [10] にて提案されている．この論文では，Recurrent Neural Network (RNN) モデルにアテンション機構を応用し予測精度を向上させている．

先行研究 [10] では，人々の移動を予測するにあたって，予測したい場所における現時刻の hidden layer の出力と異なる場所における hidden layer の出力との関係性をアテンション機構を用いて捉えることにより予測精度を向上させている．しかし，時空間データを扱うにあたって現時刻の hidden layer の出力のみにアテンション機構を応用させることは時空間データを活かしきれていないといえない．そのため，時空間データを活かしきるには過去の hidden layer の出力も考慮に入れるべきである．

そこで，本研究にて先行研究において考慮されていなかった予測したい場所における現時刻の hidden layer の出力と異なる場所における過去の時刻の hidden layer

の出力との関係性を柔軟に捉える RNN アテンションモデルを提案する．先行研究においても活用されているアテンション機構を異なる場所まで拡張することにより時空間データの関係性をより広範囲に捉えられるため，予測精度の向上が見込まれる．また，本研究にて仮想的な時空間データをアテンションスコアを算出する際に加えた．予測したい場所と異なる場所の hidden layer の出力が関係性がない場合，仮想的な場所の hidden layer の出力を参照させることにより予測精度向上を図る．

1.2 問題定義

本研究では，複数エリアの人口を予測することにより提案法の有用性を検証する．全ての予測モデルにおいて，ある時刻の全ての地点それぞれの人口から次の時刻の全ての地点それぞれの人口を予測する．本研究では，30 分後の各地点の人口を予測する．

1.3 論文構成

本論文において以下のような構成をとる．第 2 章にて，まず提案法のベースとなる従来法の詳細について述べる．その後に提案法の詳細について述べる．第 3 章にて，本研究で扱う実データの詳細や提案法と従来法の予測結果を示す．第 4 章にて，提案法と従来法の予測結果の考察を述べる．また，仮想的な時空間データを加えた場合による予測の考察も述べる．第 5 章にて，結論を述べる．

第 2 章 方法

2.1 従来法

2.1.1 RNN モデル




図 2.1 RNN モデル

まず，本研究において扱う RNN モデルを説明する． L 地点ある時系列データの中の地点 ℓ の時系列データを用いた予測を図 2.1 に示す．input layer における入力データ x_t^ℓ に対するある時刻 t の hidden layer の k 番目のユニットの出力 h_{tk}^ℓ は，

$$h_{tk}^\ell = f_1(w_{1k}x_t^\ell + \mathbf{w}_{2k}^\top \mathbf{h}_{t-1}^\ell + b_{1k}) \quad (2.1.1)$$

と表現できる． w_{1k} は，input layer と hidden layer 間のデータ x_t^ℓ における重みとする．式 (2.1.1) の添え字 k は hidden layer の k 番目のユニットを示す．そして， $\mathbf{w}_{2k}$ は要素数 K の重みベクトルとする． b_{1k} は，バイアスである． $\mathbf{h}_{t-1}^\ell$ は

要素数 K の一時刻前の hidden layer の出力ベクトルとする． $f_1(x)$ は非線形関数 $\text{ReLU}(x)$ である．

$$f_1(x) = \text{ReLU}(x) = \max(0, x) \quad (2.1.2)$$

要素数 K の hidden layer の出力ベクトルは， $\mathbf{h}_t^\ell = [h_{t1}^\ell, \dots, h_{tk}^\ell, \dots, h_{tK}^\ell]^\top$ である．そして，output layer における出力値 $\tilde{x}_{t+1}^\ell$ は，

$$\tilde{x}_{t+1}^\ell = f_2(\mathbf{w}_3^\top \mathbf{h}_t^\ell + b_2) \quad (2.1.3)$$

である．このとき， $\mathbf{w}_3$ は output layer における要素数 K の重みベクトル， b_2 はバイアスである． $f_2(x)$ は非線形関数である．そして，RNN モデルにおける目的関数 C は，以下のように表現する．

$$C = \frac{1}{L(T-1)} \sum_{\ell=1}^L \sum_{t=2}^T (x_t^\ell - \tilde{x}_t^\ell)^2 \quad (2.1.4)$$

T は出力層における予測値の最終時刻とする．

2.1.2 アテンションモデル




図 2.2 アテンションモデル

次に，RNN にアテンション機構を用いた場合の予測モデルを図 2.2 に示す．図 2.2 のように従来のアテンション機構 [5] では，過去の時刻の hidden layer の出力と現時刻の hidden layer の出力を用いて attention layer においてアテンションスコアを算出し，concatenation layer において現時刻の hidden layer の出力を連結させることによりアテンションが適応された hidden layer の出力を得る．attention layer における要素数 K の出力ベクトル $\mathbf{c}_t^\ell$ は，

$$\mathbf{c}_t^\ell = \sum_{i=1}^{t-1} a_{i,t}^\ell \mathbf{h}_i^\ell \quad (2.1.5)$$

である．ここで，attention layer におけるアテンションスコア $a_{i,t}^\ell$ は，softmax 関数によって算出される．

$$a_{i,t}^\ell = \text{softmax}(\mathbf{h}_i^{\ell\top} \mathbf{h}_t^\ell) = \frac{\exp(\mathbf{h}_i^{\ell\top} \mathbf{h}_t^\ell)}{\sum_{j=1}^{t-1} \exp(\mathbf{h}_j^{\ell\top} \mathbf{h}_t^\ell)} \quad (2.1.6)$$

そして、concatenation layer において attention layer にて算出された値と現時刻の hidden layer の出力を連結し、要素数 $2K$ の出力ベクトル $\tilde{\mathbf{h}}_t^\ell = [\mathbf{h}_t^\ell; \mathbf{c}_t^\ell]$ を算出する．concatenation layer において算出された値を用いて、output layer における出力値 $\tilde{x}_{t+1}^\ell$ を以下の式にて算出する．

$$\tilde{x}_{t+1}^\ell = f_2(\mathbf{w}_4^\top \tilde{\mathbf{h}}_t^\ell + b_2) \quad (2.1.7)$$

このとき、 $\mathbf{w}_4$ は output layer における要素数 $2K$ の重みベクトル、 b_2 はバイアスである． $f_2(x)$ は非線形関数である．また、アテンションモデルにおいても式 (2.1.4) に示す目的関数 C を最適化する．

2.2 提案法

本研究では、従来の予測モデル [10] において考慮されていなかった時空間データの関係性を捉えるための予測モデルを提案する．提案法は、RNN モデルにおいてアテンション機構を応用させた予測モデルである．従来法は、予測したい場所における現時刻の hidden layer の出力と異なる場所における過去の時刻の hidden layer の出力との関係性を捉えていない．そこで、アテンションスコアを用いてそれらの関係性を捉え予測精度の向上を図る．提案法では、予測したい場所の周囲の時系列データを活用した．先行研究においても予測したい場所の周囲の時系列データがより影響が大きいため、予測したい場所から離れた時系列データは無視していた [4]．具体的には、図 2.3 に示すように予測したい場所の周囲の時系列データを活用した．各時系列データに 0~7 の番号を本研究では振った．提案法のアテンション機構では、図 2.4 に示すように予測したい場所の時系列データのみではなく異なる場所の時系列データも参照する．提案法では、式 (2.1.5) と同様の計算を行うが、以下の

0	1	2
3	Target Area	4
5	6	7

図 2.3 提案法において用いる周囲のデータ

ように拡張された要素数 K の出力ベクトル $\tilde{\mathbf{c}}_t^\ell$ を算出する.

$$\tilde{\mathbf{c}}_t^\ell = \sum_{i=1}^{t-1} a_{i,t}^\ell \mathbf{h}_i^\ell + \sum_{m=0}^{M-1} \sum_{j=t-\text{LAG}}^{t-1} a_{j,t}^{m\ell} \mathbf{h}_j^{m\ell} + a_t^{M\ell} \mathbf{h}^M \quad (2.2.1)$$

提案法では, 図 2.4 に示すように周囲の時系列データの過去の時刻数を LAG とした. LAG とすることにより, 周囲の情報をヒューリスティックに調整することが可能である. そして, M は周囲の場所の数を表す. 式 (2.2.1) における m は図 2.3 における番号を示す. 提案法では $M = 8$ とした. このとき, $m = M = 8$ として仮想的な Haven Area を本研究では加えた. 予測したい地点 (Target Area) の人口が周囲の地点の人口と関係性が無い場合, Haven Area の情報と関係性を持たせることによって, 予測精度の低下を防ぐ. 式 (2.2.1) の第三項 (Haven Area) において $\mathbf{h}^M$ は要素数 K のゼロベクトルとする. 同様に式 (2.1.6) のアテンションスコアも提案法では以下のように算出する.

$$a_{i,t}^\ell = \text{softmax}(\mathbf{h}_i^{\ell\top} \mathbf{h}_t^\ell) \quad (2.2.2)$$




図 2.4 提案法

$$a_{j,t}^{m\ell} = \text{softmax}(\mathbf{h}_j^{m\ell\top} \mathbf{h}_t^\ell) \quad (2.2.3)$$

$$a_t^{M\ell} = \text{softmax}(\mathbf{h}^{M\top} \mathbf{h}_t^\ell) \quad (2.2.4)$$

そして, concatenation layer においても従来法のアテンションモデルと同様に結合し要素数 $2K$ の出力ベクトル $\tilde{\mathbf{h}}_t^\ell = [\mathbf{h}_t^\ell; \tilde{\mathbf{c}}_t^\ell]$ を算出する. concatenation layer において算出された値を用いて, output layer における出力値 $\tilde{x}_{t+1}^\ell$ を以下の式にて算出する.

$$\tilde{x}_{t+1}^\ell = f_1(\mathbf{w}_4^\top \tilde{\mathbf{h}}_t^\ell + b_2) \quad (2.2.5)$$

このとき, $\mathbf{w}_4$ は output layer における要素数 $2K$ の重みベクトル, b_2 はバイアスである. また, 提案法においても式 (2.1.4) に示す目的関数 C を最適化する.

第 3 章 実験

3.1 データセット




図 3.1 人口データの範囲（関東近郊）




図 3.2 人口データの範囲（関西近郊）



図 3.3 人口データの範囲（中部近郊）



図 3.4 人口データの範囲（北京近郊）

本研究では、提案法を評価するために人口データを用いて実験した。人口データは、関東近郊と関西近郊と中部近郊と北京近郊の人口データを扱った。人口データは各地点 30 分ごとに一日分が集計されている。例えば、地点 ℓ では人口データ $\mathbf{x}^\ell = [x_1^\ell, \dots, x_t^\ell, \dots, x_{48}^\ell]^\top$ が一日分集計されている。 x_t^ℓ は、地点 ℓ 周りの 5km 四方の範囲の時刻 t における人口を表している。ただし、北京近郊の人口データのみ 1km 四方の範囲内が計測されている。本研究では、図 3.1¹⁾、図 3.2¹⁾、図 3.3¹⁾、図 3.4¹⁾の赤枠内の地点の人口を予測するが、提案法では赤枠に隣接した地点も考慮するためその地点においては人口データ $\mathbf{x}^\ell$ がゼロベクトルとなるように初期化した。また、本研究では、時系列を考慮し各エリアの人口データをトレーニングデータ、バリデーションデータ、テストデータに分割した。

関東近郊の人口データ トレーニングデータを 2013 年 7 月 1 日 (月)、2013 年 7 月 7 日 (日)、2013 年 10 月 7 日 (月)、2013 年 10 月 13 日 (日) の 4 日間、バリデーションデータを 2013 年 12 月 16 日 (月) の 1 日間、テストデータを 2013 年 12 月 22 日 (日) の 1 日間とした。

関西近郊の人口データ トレーニングデータを 2013 年 8 月 8 日 (木)、2013 年 8 月 11 日 (日)、2013 年 9 月 16 日 (月)、2013 年 9 月 22 日 (日) の 4 日間、バリデーションデータを 2013 年 12 月 24 日 (火) の 1 日間、テストデータを 2013 年 12 月 29 日 (日) の 1 日間とした。

中部近郊の人口データ トレーニングデータを 2013 年 7 月 22 日 (月)、2013 年 7 月 28 日 (日)、2013 年 9 月 16 日 (月)、2013 年 9 月 22 日 (日) の 4 日間、バリデーションデータを 2013 年 12 月 24 日 (火) の 1 日間、テストデータを 2013 年 12 月 29 日 (日) の 1 日間とした。

北京近郊の人口データ トレーニングデータを 2008 年 2 月 2 日 (土)、2008 年 2 月 3 日 (日)、2008 年 2 月 4 日 (月)、2008 年 2 月 5 日 (火) の 4 日間、バリデーションデータを 2008 年 2 月 6 日 (水) の 1 日間、テストデータを 2008 年 2 月 7 日 (木) の 1 日間とした。

関東近郊、関西近郊、中部近郊、北京近郊の人口データのそれぞれの日は、489 地点分、944 地点分、711 地点分、1209 地点分の 48 時刻分含まれている。

¹⁾<https://openstreetmap.jp/>

3.2 提案法の条件設定

本研究では，従来法と比較するため複数の提案法を検討した．以下の 8 種類の提案法を考えた．

提案法 (LAG = 1) (proposed(LAG = 1)) 提案法における LAG = 1 のときの予測モデルである．ただし，Haven Area は加わっていないものとする．

提案法 (LAG = 2) (proposed(LAG = 2)) 提案法における LAG = 2 のときの予測モデルである．ただし，Haven Area は加わっていないものとする．

提案法 (LAG = 3) (proposed(LAG = 3)) 提案法における LAG = 3 のときの予測モデルである．ただし，Haven Area は加わっていないものとする．

提案法 (LAG = ALL) (proposed(LAG = ALL)) 提案法における LAG = ALL のときの予測モデルである．周囲の場所の過去の情報全てを含めるものとする．ただし，Haven Area は加わっていないものとする．

提案法 (LAG = 1, haven) (proposed(LAG = 1, haven)) 提案法における LAG = 1 のときの Haven Area が加えられた予測モデルである．

提案法 (LAG = 2, haven) (proposed(LAG = 2, haven)) 提案法における LAG = 2 のときの Haven Area が加えられた予測モデルである．

提案法 (LAG = 3, haven) (proposed(LAG = 3, haven)) 提案法における LAG = 3 のときの Haven Area が加えられた予測モデルである．

提案法 (LAG = ALL, haven) (proposed(LAG = ALL, haven)) 提案法における LAG = ALL のときの Haven Area が加えられた予測モデルである．周囲の場所の過去の情報全てを含めるものとする．

RNN の各 hidden layer のユニット数をエリアごとに選択した．バリデーションデータにおける目的関数の値が一番小さかったときの hidden layer のユニット数を選択した．学習係数 0.001 の Adam を用いて提案法を最適化した．本研究においてはミニバッチ学習を行った．ミニバッチサイズは関東近郊の人口データでは 489，関西近郊の人口データでは 944，中部近郊の人口データでは 711，北京近郊の人口データでは 1209 と各エリアの地点数とした．

3.3 比較手法の条件設定

提案法の有用性を確認するために複数の従来手法を用意した。

コピーモデル (Copy) 一時刻前のデータを予測値とするモデルである。

平均モデル (Avg.) トレーニングデータ 4 日間の各地点各時刻の平均値を予測値とするモデルである。

自己回帰モデル (AutoRegressive: AR) 一時刻前のデータを参照する自己回帰モデルである。

ニューラルネットワークモデル (Neural Network: NN) input layer, hidden layer と output layer の三層から成るニューラルネットワークモデルである。hidden layer の非線形関数は ReLU 関数とした。また, output layer では線形回帰を行い予測値を算出した。

リカレントニューラルネットワークモデル (Recurrent Neural Network: RNN)

提案法においても用いられる RNN とし, output layer では線形回帰を行い予測値を算出した。

アテンションモデル (conventional Attention) ターゲットエリアの過去の hidden layer の出力のみを参照するアテンションモデルである。リカレントニューラルネットワークモデル同様 output layer では線形回帰を行い予測値を算出した。

そして, 提案法と同様の条件下で比較手法を最適化した。

3.4 評価指標

本研究では, 一時刻先 (30 分後) の人口データを予測し提案法の有用性を評価した。ただし, このとき参照する過去の情報は予測モデルごとに異なる。また, 本研究では原則としてある地点のある時刻の人口データを入力し, その地点の 30 分後の人口データを予測した。入力に人口以外のデータを含めないものとした。予測モデルの評価指標として, 式 (2.1.4) を用いて評価した。

表 3.1 提案法とベースラインの平均二乗誤差の比較

Model	Kanto	Kansai	Chubu	Beijing
Copy	21.376	2.081	1.180	3.776
Avg.	335.434	12.635	6.331	51.039
AR	21.372	2.081	1.178	3.728
NN	21.304	2.046	1.167	3.709
RNN	9.743	1.906	1.036	3.048
conventional Attention	9.691	1.856	1.014	3.042
proposed(LAG = 1)	9.806	1.819	1.035	3.009
proposed(LAG = 2)	9.721	1.856	1.028	3.009
proposed(LAG = 3)	9.850	1.838	1.027	3.011
proposed(LAG = ALL)	11.937	1.823	1.054	3.342
proposed(LAG = 1, haven)	9.637	1.849	1.010	3.013
proposed(LAG = 2, haven)	9.738	1.840	1.007	3.014
proposed(LAG = 3, haven)	9.658	1.815	1.028	3.009
proposed(LAG = ALL, haven)	13.730	1.838	1.031	3.343

3.5 実験結果

3.5.1 性能評価

表 3.1 に示すように，どのエリアにおいても Haven Area を加えた提案法が最高精度を記録した．伝統的な時系列予測手法である AR モデルなどと比較して提案法はかなり精度が高くなった．また，提案法のように周囲の人口データを考慮に入れることにより，従来のニューラルネットワークモデルよりも予測精度が向上することが確認できた．そして，アテンション機構が人口データに対して応用可能であることが表 3.1 から確認できた．また，本研究において扱っている人口データは過去の人口データの平均値を予測値とするよりも一時刻前の人口データを予測値とする方が正解値との誤差が小さくなる傾向があった．

3.5.2 Haven Area の評価

表 3.2 Haven Area のアテンションスコアが 0 より大きい地点における
提案法とベースラインの絶対誤差の比較

Model	Kanto
conventional Attention	0.036
proposed(LAG = 1)	0.025
proposed(LAG = 1, haven)	0.017

表 3.2 の予測誤差の平均は，次式にて表される．

$$D = \frac{1}{N(T-1)} \sum_{t=2}^T \sum_{n=1}^N |x_{t,n} - \tilde{x}_{t,n}| \quad (3.5.1)$$

式 (3.5.1) はテストデータ中の Haven Area においてアテンションスコアが 0 よりも大きかった $N = 12$ 地点を対象とした．表 3.2 においてよりモデルごとの差が現れる絶対誤差を採用した．表 3.2 より提案法がベースラインと比較して一日に観測された人口が 0 人の地点の予測においては有効であることがわかった．

第 4 章 考察

4.1 周囲の地点の情報を使い分けている地点




図 4.1 提案法による予測（田島駅周辺）

図 4.1 に示すように, `proposed(LAG = 1, haven)` においては, 田島駅周辺の人口データを予測するときに周囲の地点の情報を選択していることがわかる. また, $t = 35$ のときの田島駅周辺の人口を予測するときは, $t = 34$ のときの佐野市運動公園周辺の情報と $t = 3$ のときの田島駅周辺の情報との関係性を捉え予測していたことがわかった. このことから, 時刻ごとに関係性のある地点の情報を用いて柔軟に予測していることがわかった. そして, アテンションスコアの印象として全体にばらけるのではなく, ある時刻はある地点を選択するという傾向があった. このことから, ターゲットエリアの過去の情報を用いるよりも他の地点の情報を用いた方が予測しやすいのではないかと考えられる.

4.2 ターゲットエリアのみを選択する地点




図 4.2 提案法による予測（篠塚駅周辺）

図 4.2 に示すように，篠塚駅周辺のように他の地点に比べて人口が多い地点において，`proposed(LAG = 1, haven)` は，ターゲットエリアの情報のみを参照していたことがわかった．人口が他の地点と比べて多く全体的に変動が少ないときに提案法は `conventional Attention` モデルのようにターゲットエリアの過去の情報のみを参照していたことがわかった．このことから，提案法は状況に応じてモデルを使い分けて予測していると考えられる．

4.3 選択した地点が偏っていた地点




図 4.3 提案法による予測（用土駅周辺）

図 4.3 に示すように, $\text{proposed}(\text{LAG} = 1, \text{haven})$ においては, 用土駅周辺の人口データを予測するときに周囲の特定の地点の情報のみを参照していたことがわかった. 図 4.3 の特徴として挙げられるのは, 前述のような他地点の使用法ではなく, 用土駅周辺を予測する場合は全ての時刻において栗田鉄金周辺の情報のみを選択していたことである. 図 4.3 のように変動が激しい場合は, 提案法は予測しやすい情報を柔軟に選択していたと考えられる.

4.4 Haven Area を加えた場合による予測




図 4.4 ベースラインと提案法による予測 (原始村周辺)

Haven Area を提案法にて採用しているが，Haven Area がアテンション機構において活用されているときは一日に観測された人口が 0 人の地点である．従来法と Haven Area を加えていない提案法においては，図 4.4 のように 0 人というのは予測しにくい，Haven Area を加えた提案法においては，予測しやすいことがわかる．このことより，周囲に予測したい人口と似たような情報があると予測しやすいと考えられる．

第 5 章 結論

本研究にて，時空間データの関係性を柔軟に捉えるための RNN アテンションモデルを提案した．アテンション機構を活用し，異なる場所の時系列データとの関係性を柔軟に捉えることにより，予測精度が向上することを確認できた．今後の課題として，提案法は予測したい場所の周囲 8 地点の人口データを活用したが，さらに広い範囲を考慮に入れた場合，一定の予測精度が保たれるか検証する必要がある．そして，本研究において扱った人口データよりも多次元なデータにおいて提案法が利用されることを期待したい．

謝辞

本研究を遂行するにあたって，多くの方々からご指導いただきました．主指導教員の池田和司教授には，研究発表の際貴重なご意見ならびにご助言をいただき感謝申し上げます．副指導教員の松本裕治教授には，研究発表の際有益なご助言をいただき感謝申し上げます．副指導教員の澤田宏客員教授には，本研究に関して終始ご指導ご鞭撻いただき深く感謝申し上げます．副指導教員の岩田具治客員准教授には，本研究に関するご指導ならびにコーディングのご指導をいただき深く感謝申し上げます．最後に，お世話になった奈良先端科学技術大学院大学数理情報学研究室，コミュニケーション学研究室の皆さんに感謝の意を申し上げます．

参考文献

- [1] Yasunori Akagi et al. 2018. A Fast and Accurate Method for Estimating People Flow from Spatiotemporal Population Data. IJCAI.
- [2] 今井武晃, 山中章裕. 2017. 人流シミュレーションのパラメータ推定手法. DEIM Forum 2017, P5-4.
- [3] 石田哲也. 2018. 世界で進行する都市化の傾向と都市開発戦略(その1). 国土交通政策研究所報第68号.
- [4] Tomoharu Iwata et al. 2017. Estimating People Flow from Spatio-temporal Population Data via Collective Graphical Mixture Models. ACM.
- [5] Giancarlo D. Salton, Robert J. Ross and John D. Kelleher. 2017. Attention Language Models. AFNLP.
- [6] 佐藤大祐ほか. 2018. 群集誘導のための人流予測技術. NTT 技術ジャーナル, pp.38-41.
- [7] Chaoming Song et al. 2010. Limits of Predictability in Human Mobility. SCIENCE, VOL327.
- [8] 土屋宰貴. 2009. わが国の「都市化率」に関する事実整理と考察ー地域経済の視点からー.
- [9] 上田修功. 2018. 時空間データ解析技術とその集団最適誘導への応用. 通信ソサイエティマガジン, No.45, 夏号 2018.
- [10] Anirudh Vemula, Katharina Muelling and Jean Oh. 2018. Social Attention: Modeling Attention in Human Crowds.

付録 A 長期予測

提案法が長期予測において機能するか検証した．全ての予測手法において， $t = 1$ のときの人口が既知の場合，それ以降の人口を予測値のみから算出し長期予測を行った．提案法にて用いている RNN モデルにおいて，時刻 1 のときは，式 (2.1.1) と同様に中間層の出力を算出する．時刻 2 以降は以下の式にて中間層の出力を算出する．

$$h_{tk}^{\ell} = f_1(w_{1k}\tilde{x}_t^{\ell} + \mathbf{w}_{2k}^{\top} \mathbf{h}_{t-1}^{\ell} + b_{1k}) \quad (\text{A.1})$$

このとき， $f_1(x)$ は式 (2.1.2) と等しいとする．そして，最終的な予測値 $\hat{x}_{t+1}^{\ell}$ は，各予測モデル，式 (2.1.3)，式 (2.1.7)，式 (2.2.5) を用いて算出する．また，長期予測においても式 (2.1.4) に示す目的関数 C を最適化する．それぞれの予測モデルは本論と同様に条件設定を行った．

表 A.1 提案法とベースラインの平均二乗誤差の比較

Model	Kanto	Kansai	Chubu	Beijing
AR	1079.3	41.1	15.91	15.00
NN	833.6	32.6	10.43	14.11
RNN	484.9	32.3	7.89	13.56
conventional Attention	725.3	32.5	10.52	13.78
proposed(LAG = 1)	608.9	21.6	9.21	13.71
proposed(LAG = 2)	513.7	23.3	6.46	13.45
proposed(LAG = 3)	557.4	22.5	6.96	13.44
proposed(LAG = ALL)	571.5	22.1	9.29	13.20
proposed(LAG = 1, haven)	622.8	21.8	9.01	13.47
proposed(LAG = 2, haven)	553.2	22.1	6.54	13.19
proposed(LAG = 3, haven)	576.1	22.7	8.57	13.42
proposed(LAG = ALL, haven)	618.9	19.4	8.92	13.49

表 A.1 は長期予測における各予測モデルの結果を示す．関東近郊以外において提案法が従来法と比較して予測精度が高いという結果となった．また，表 3.1 と比較

して、長期予測における平均二乗誤差は大きい値となった。

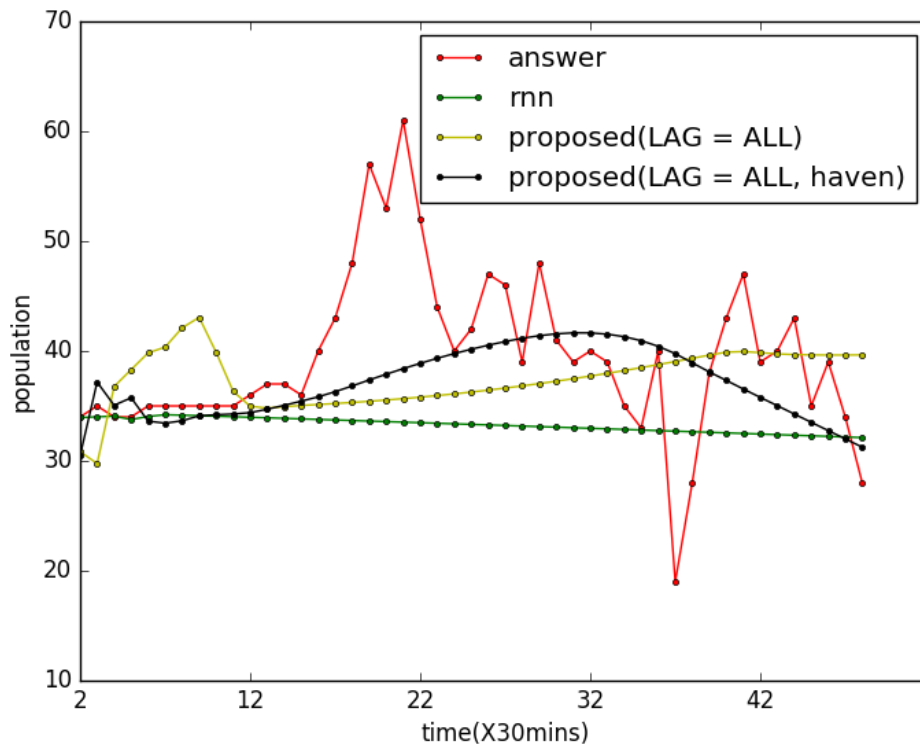


図 A.1 ベースラインと提案法による予測（西山公園周辺）

図 A.1 は長期予測における西山公園周辺の予測である．人口の予測値を元に予測する場合，人口の正解値を元に予測する場合と比べてかなり精度が悪いことがわかる．また，図 A.1 において $t = 15$ から急激に人口が増加するが，このように変動が激しい場合は，長期予測において予測することは難しいことがわかった．しかし，提案法は他の従来法と比べて大まかな流れは予測できていることが図 A.1 から確認できる．このことから，時空間データの関係性を柔軟に捉えることは，時空間データを予測する上で有効であることがわかる．