

LSTM を用いた個人の移動モデルによる目的地予測の試作

Prototype Destination Prediction Using LSTM-based Personal Mobility Models

亀岡 賢太郎[†] 田中 悠[†] 笠松 大佑[†]Kentaro KAMEOKA[†] Haruka TANAKA[†] Daisuke KASAMATSU[†][†] 創価大学理工学部情報システム工学科[†] Faculty of Science and Engineering, SOKA University

1. はじめに

本研究の目的は、時系列データの学習や予測を可能とするリカレントニューラルネットワークを用いて個人の移動モデルによる目的地予測の試作に取り組むことである。

2. 課題

先行研究[1]では、群衆の移動先を交通手段ごとに分類し、交通手段によって異なる移動先の分布を考慮した目的地予測を行っている。しかしながら、群衆の移動傾向のみを用いて目的地予測を行うため、個人の移動傾向を考慮することができない。本研究の課題は、先行研究で用いた群衆の移動傾向から移動先を予測するデータマイニング手法に、個人の移動傾向から移動先を予測する個人の移動モデルを組み合わせることにより、目的地予測の精度を向上することである。

3. 提案手法

Long Short Term Memory (LSTM) は、時系列データを扱うことができるニューラルネットワークであり、時系列データの中で過去のデータを保持することができるという特長がある。本研究では、LSTM のアーキテクチャを用いる。入力ゲートには時系列データ 1 つを入力し、 X_t とする。次の時系列データは、 X_{t+1} となる。出力ゲートには、今までの時系列データから求められる次の時系列データを出力する必要があることから、 X_{t+1} までの時系列データを入力し、 h_{t+1} を出力する。これらのゲートを組み合わせたブロックを用いることで、過去の移動軌跡を学習することができる。

学習データを作成するにあたり、1 回分の移動軌跡データの終点を識別するために、移動軌跡データの最後に終端値データを追加する。移動系列を 1 つのデータ分だけスライドさせ、100 の時系列データを作成する。

予測手法を図 1 に示す。テストデータの移動系列を一部入力し、次の移動先を予測する。これを下記の 3 つの条件のいずれかに当てはまるまで予測処理を繰り返す。

- 予測した移動先が終端値データもしくはグリッドの範囲外である
- 予測した移動先が 100 回続けて同じグリッドである
- 予測した移動先が上記に当てはまらず、かつ予測処理が 100 秒以上経過した

上記の条件に当てはまった場合は、予測の処理を終了して、最後に予測したグリッドの 1 つ前に出力したグリッドを

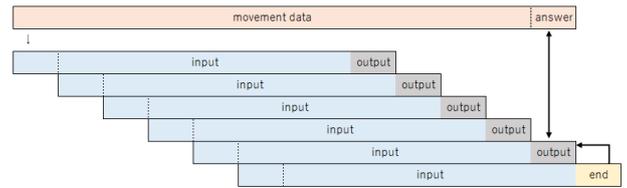


図 1 予測手法

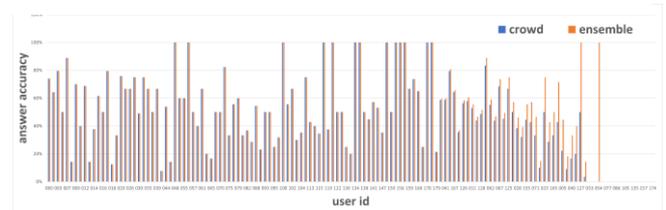


図 2 正解率の比較

目的地とする。

これは、学習元のデータにおいて、移動軌跡に終端値を追加しているため、予測先のグリッドが終端値である場合、予測先のグリッドの 1 つ前に出力したグリッドを目的地とすることで、終端値を除いた移動軌跡を出力するためである。

群衆の移動傾向予測のモデルでは、上位 5 つの目的地候補に、個人の移動傾向予測モデルの出力を追加し、最大 6 つの目的地候補を出力する。それら 6 つの目的地候補の中に、正解データが含まれていれば真とする。

4. 実験

各個人における正解率の比較を図 2 に示す。個人の移動傾向を考慮した場合、135 人中 33 人とおおよそ 25% のユーザーの正答率が向上した。個人の移動モデルを考慮しない場合における平均正答率は 53%、考慮する場合における正答率は 56% であった。

5. まとめ

本研究により、群衆の移動傾向に個人の移動モデルを組み合わせることで、目的地予測の精度を向上できることを確認した。

参考文献

- [1] Sachiko Yoshidomi, Hiroto Shiraikawa, and Daisuke Kasamatsu, "A Prediction Method of User Destination Using Historical Crowd Movement," GCCE, pp. 58-59, 2023.