

アイテムの分散表現を用いた RNN の時系列データ推薦

Recommender Method with Item Embedding Using Recurrent Neural Network

シュレストアウツサブ¹
Utsav Shrestha

小林亜樹²
Aki Kobayashi

工学院大学大学院工学研究科¹
Graduate School of Engineering, Kogakuin University

工学院大学情報学部²
Faculty of Informatics, Kogakuin University

1 はじめに

情報推薦の分野で、時系列データを予測する枠組みとして Recurrent Neural Networks(RNN) が存在する。ユーザが評したアイテムの履歴やユーザの移動履歴といった一連のデータを時系列データとして扱うことで、RNN が順序情報を持つアイテムの予測に有効であることが示されている [1]。しかし、時系列データを用いた推薦では単純な RNN による推薦ではなく、アイテム間の類似性を考慮することでさらに推薦精度が向上するのではないかと考えられる。そこで、本稿では Word2Vec で構築したモデルから取得したアイテムの分散表現を用いることで、アイテムの類似性を考慮することが推薦精度にどのような影響を与えるか検証する。

2 RNN による情報推薦

2.1 データセット

データセットとして、ユーザのチェックインを集めた Foursquare データセットを用いる。ユーザ u が時刻 t に POI i にチェックインしたことを示し、ユーザごとに時刻情報をもとに時系列データとして扱う。チェックイン数が 10 以下のユーザとチェックインしてきたユーザが 10 以下の POI は含まれていない。ユーザ数は 24941、POI 数 28593、チェックイン数は 1196248、期間は 2012 年 04 月 3 日から 2013 年 9 月 16 日である。

2.2 ネットワークの概要

本研究では、ユーザ u が時刻 t にチェックインした POI i_t からその次の時刻 $t+1$ にチェックインする POI i_{t+1} を予測することを目的とするニューラルネットワークを構築した。このニューラルネットワークは、入力層、隠れ層、出力層の 3 つの層からなっている。まず、入力層の入力は、 i_t の one-hot ベクトルである。入力層の重みの行が POI の埋め込みベクトルを示す。隠れ層が RNN を示す。隠れ層の入力が、 i_t の埋め込みベクトルとなる。

出力層では、次元数が POI 数のベクトルが得られる。入力層の入力とするベクトルと出力層の計算結果として得られるベクトルの次元数は同じであり、それぞれの要素が 1 つの POI を示す。出力層の活性化関数として、Softmax 関数を用いており、出力ベクトルの要素をそれぞれの POI が出現する確率のようにみなしている。そのため、出力ベクトルで値がもっとも大きな要素の POI が、ユーザが次の時刻 $t+1$ にチェックインする POI i_{t+1} と予測した結果としている。

2.3 分散表現

Word2vec の考えをもとに、POI の分散表現を得る。Word2vec モデルは、Skip-gram を用いる。入力層と出力層の 2 層からニューラルネットワークである。それぞれのユーザが辿った POI の順番で、ある POI からその前後に訪れた POI を予測するモデルとする。この時の Word2vec モデルの入力層の重みを POI の分散表現とする。Word2vec モデルの入力層の重みを 2.2 章で説明したニューラルネットワークの入力層の重みとして用いる。

3 実験

RNN を用いた情報推薦で、POI 間の類似を考慮した場合と POI 間の類似を考慮していない場合で比較する。データセットをユーザ単位で全体の 10% をランダムに

評価用データ、次の 10% をランダムに検証用データ、残りを学習用データとする。この実験では、学習用データを用いて、学習を行い、検証用データでユーザの過去の系列データから次に訪れる POI を予測できるか評価する。評価用データは用いていない。

3.1 評価指標

評価指標として、Sequence Prediction Success at k (sps@ k) を扱う。推薦したアイテム k 件にユーザの次のアイテムが含まれた場合、sps@ k は 1 をとり、含まない場合は 0 をとる。最終的な sps@ k の値は全ユーザの平均である。実験では、ユーザの時系列データの時系列順で最後から 1 つ前までをニューラルネットワークの入力系列とし、そこから得られた推薦したアイテム k 件に、時系列順で最後のアイテムが含まれているかとしている。

3.2 実験条件

以下の 2 つで比較を行う。それぞれのニューラルネットワークの入力層の重みは epoch 数ごとに更新は行わないものとする。

- random : RNN の入力層の重みの値がランダム
- w2v : RNN の入力層が Word2vec モデルによって得た POI の分散表現

今回の実験では、Word2vec モデルはウィンドウサイズを 5 とし、ある POI からその前後 5 つの POI を予測するモデルとして epoch 数を 50 としている。RNN は、最適化手法が AdaGrad、学習率が 0.01、隠れ層のノード数が 100、バッチサイズが 10、epoch 数は 100 としている。評価の際の推薦アイテムの数 k は 10 としている。

3.3 結果および考察

表 1 に各実験の epoch 数が 100 での sps@10 を示す。

表 1 実験結果

	sps@10
random	0.02766
w2v	0.07377

表 1 から w2v が random に比べて、sps@10 の値が高く、推薦精度が高いことが示された。このことより、RNN を用いた情報推薦で、POI 間の類似を考慮したほうが、推薦精度が高くなることがわかった。

4 おわりに

本稿では、Word2Vec で構築したモデルから取得したアイテムの分散表現を用いることで、アイテムの類似性を考慮した場合での推薦精度について調査した。今後はアイテムの類似性を考慮するのに協調フィルタリングへの応用が必要である。

参考文献

- [1] Shuai Zhang, Lina Yao, Aixin Sun, Yi Tay “Deep Learning Based Recommender System: A Survey and New Perspectives”, ACM Computing Surveys, Vol. 52, No. 1, Article 5. Publication date: February 2019