

ユーザーのページビュー系列からのコンバージョン予測 2B1-2

Conversion prediction from users' pageview series

金子 貴輝 *1
Taka-ki Kaneko

青井 順一 *2
Junich Aoi

上野山 勝也 *3
Katsuya Uenoyama

松尾 豊 *4
Yutaka Matsuo

*1 東京大学 技術経営戦略学専攻
Technology Management for Innovation, The University of Tokyo

*2 株式会社 MicroAd
MICROAD, INC.

*3 東京大学 工学系研究科
Graduate School of Engineering, The University of Tokyo

*4 東京大学 工学系研究科
Graduate School of Engineering, The University of Tokyo

Web 広告ではユーザーのページビュー履歴からコンバージョンを予測することは重要な問題である。Web 広告には複数の業種があるので、予測タスク間で情報を共有することができる。本研究ではまず、RNN を用いた時系列モデルを使ってコンバージョンを予測することで時系列を使わない SVM モデルより精度を若干向上させられることを示す。次にアテンションモデルを加えることで複数のタスクの情報を共有し、精度向上を目指す。

1. はじめに

Web 広告ではユーザーのページビュー履歴からコンバージョンを予測することは重要な問題である。Web 広告には複数の業種があるので、マルチタスクの問題として設定することで、タスク間で共有される知識が学習サンプルの少ないタスクの精度向上に役立つと期待できる。そこで本研究では、マルチタスクなコンバージョン予測のために共通の RNN を使用することと、アテンションモデルを用いることを提案する。

実験において、RNN を用いた時系列モデルは時系列を使わない SVM モデルより若干の精度向上が見られた。またアテンションモデルを加えることで複数の業種の情報を共有することができるが、特定の実験設定では精度向上は見られなかった。

2. 章で基礎となる研究について説明し、3. 章で提案手法について説明する。4. 章で SVM と RNN とアテンションモデルの比較実験について説明し、5. 章で結論をまとめる。

2. 既存研究

2.1 コンバージョン予測

Web ページにおけるユーザーの購買行動を予測するために、RNN を用いる研究がなされてきている [1]。

本研究では時系列データに含まれる階層的な特徴を獲得することを期待して Long Short-Term Memory RNN(LSTM) を使用し、またコンバージョン予測に用いる情報を業種ごとに大きく変化させられるよう、アテンションモデルを用いる。

2.2 LSTM

LSTM [2] は、次の式で順伝播が定義される RNN モデルである。誤差逆伝播法を用いて学習できる。

$$h_{t+1} = o_t \odot \tanh(c_{t+1}) \quad (1)$$

$$c_{t+1} = c_t \odot f_t + z_t \odot i_t \quad (2)$$

$$i_t = \sigma(W_i x_t + U_i h_t + b_i) \quad (3)$$

$$o_t = \sigma(W_o x_t + U_o h_t + b_o) \quad (4)$$

$$f_t = \sigma(W_f x_t + U_f h_t + b_f) \quad (5)$$

$$z_t = \tanh(W_z x_t + U_z h_t + b_z) \quad (6)$$

Elman 型のシンプルな RNN よりも長期依存について誤差逆伝播で学習しやすい特徴を持っており、様々なタスクで使用されている。本研究でも、ページビュー履歴が持つコンバージョン予測に係る特徴が短期的なものから長期的なものまで含まれると考えられるため、このモデルを使用する。

2.3 アテンションモデル

可変長の系列に対して内積で重みを算出し、足し合わせることで一部から情報を取り出す Soft Attention を使用する。式は次の通り。

$$h_{att} = \sum_t a_t h_t \quad (7)$$

$$a_t = \frac{\exp(\text{score}(w, h_t))}{\sum_\tau \exp(\text{score}(w, h_\tau))} \quad (8)$$

アテンションを指定する w を用いて各時刻の特徴量 h_t への重みを決定する。これにより w の値で出力に強く影響する時刻を変化させることが用意になると考えられる。

Zhai らは、検索クエリに対する広告の適切さの予測に Attention Pooling をもちいて Last Pooling に対する有効性を主張した [3]。しかしアテンションの効果はマルチタスクでも有効だと考え、本研究では実験を行った。マルチタスクに対応するため、アテンションを決定する部分には業種ごとの特徴量を入力した。

3. 提案手法

時系列から特徴量を作成するために RNN モデルにもアテンションモデルにも LSTM RNN を使用した。予測モデルとして、sigmoid レイヤから確率値を出力させた。RNN モデルはマルチタスクに対応させるため、最終時間の隠れ層の表現にタスク指定に関する特徴量を結合させ、予測を担う多層ニューラルネットに入力した。

3.1 マルチタスクのためのアテンションモデル

マルチタスクでモデルを共用する場合、必要になる情報をタスクごとに切り替える必要が予想されるため、アテンションモデルを適用した。アテンションベクトルは予測する業種の特徴量を用いて作成した。アテンションベクトルを適用して抽出した特徴量は最終時間の特徴量と結合して予測モデルに入力した。

連絡先:

- 入力: CVユーザーの日別トピックPV数 + 業種ごとの特徴量
- 出力: CVユーザーの11月のCV予測




図 1: CV 予測に用いた LSTM モデルの概念図. 日別の特徴量を LSTM でユーザーの特徴量に変換したのち、業種ごとの特徴量と結合し、CV 予測に用いる。

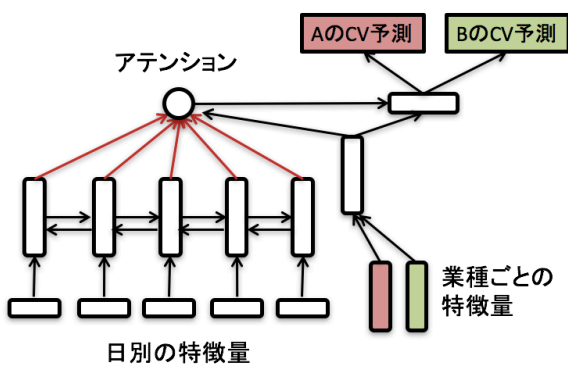


図 2: マルチタスクのためのアテンションを用いた RNN モデルの概念図.

4. 実験

4.1 データセット

9つの業種について、業種ごとに得られる特徴量と、一般的な広告を掲載しているページについて1日のうちにユーザーがページビューした回数についての情報を利用した。9つの業種は図3に使用した全体のユーザー数とともに示した。

4.2 共通設定

勾配法には Adam を使用した。Keras を用いて実装した。訓練は早期終了を用いて行った。

4.3 実験 1

訓練とテスト両方で、2016/7/1 から 2016/10/31 までを特徴量に使用し、2016/11/1 から 2016/11/30 までのコンバージョンを予測した。訓練とテストはそれぞれ別のユーザーについて行った。

RNN モデルに入力するデータには次の前処理を行った。ページビューした特定の Web ページを 640 種類のトピックに分類し、1日のうちに各トピックにページビューがあったか無かったかを 0, 1 とした特徴量と、業種ごとの特徴量を結合して日別の特徴量とした。

RNN からの特徴量から CV 予測を行う多層ニューラルネットワークの活性化関数は Tanh を使用し、Dropout には GaussianDropout を使用した。

比較対象の SVM では、時系列データを扱えないので、2016/7/1 から 2016/10/31 までの内に一度でもページビューがあったかで 0, 1 とした特徴量をモデルに入力した。トピッ

クの特徴量を用いると精度が落ちたため、業種ごとの特徴量のみを用いた。

SVM モデルから確率値を出力するため、Platt スケーリングを使用した。

4.4 実験 2

実験 1 と同様の訓練とテストデータを用意し、マルチタスク課題となるよう、1つのモデルに複数の業種の課題を与えた。ただし、アテンションモデルでの訓練・テストでは、実装上の都合から一部の外れ値を取り除いた。テスト時はすべてのユーザーについて各タスクごとに予測させスコアを計算した。

特徴量も実験 1 と同様に作成した。ただしマルチタスクな問題設定に合わせて、日別の特徴量に結合されている業種の特徴量は 9 種すべてを結合した。

LSTM を bi-directional にして利用している。

アテンションモデルでは複数の業種についての予測タスクをランダムに選択し訓練に用いた。テスト時には、それぞれの業種ごとに AUC スコアを評価した。

業種	SVM	LSTM	Attention
アルバイト(n=29,771)	0.914	0.917	> 0.833
美容(n=16744)	0.946	0.942	> 0.818
旅行(n=27322)	0.860	0.865	> 0.791
不動産(n=15237)	0.824	0.831	> 0.768
ファッション(n=563)	0.913	0.631	< 0.687
結婚式場(n=2360)	0.861	0.717	< 0.792
スポーツ(n=2085)	0.867	0.741	> 0.699
転職(n=822)	0.874	0.596	< 0.688
保険(n=858)	0.779	0.630	< 0.681

図 3: 3つのモデル間での AUC スコアの比較。SVM と LSTM はそれぞれの業種ごとにモデルを作成している。

4.5 結果

SVM と RNN を比較してサンプル数の多いタスクではかろうじて精度が向上しているものの、サンプル数の少ないタスクでは精度が低く、タスクごとに学習できる SVM の表現力の方が高いことが予想される。

また、アテンションを適用するとサンプル数の少ないタスクで精度向上が見られる一方で、サンプル数の多いタスクでは精度が下がってしまった。これは、揃えることのできなかったユニットサイズの違いから、マルチタスクに十分な表現をアテンションモデルで獲得できなかったことから来していると考えられる。

5. 結論

RNN を用いた時系列モデルを使ってコンバージョンを予測することで時系列を使わない SVM モデルより若干の精度向上が見られた。またアテンションモデルを加えることで複数の業種の情報を共有することができるが、特定の実験設定では精度向上は見られなかった。精度向上を目指すため、マルチタスク性が十分に生きるほどタスク数を増やす実験は今後の課題としたい。

謝辞

本研究は JSPS 科研費 JP25700032, JP15H05327, JP16H06562 の助成と国立研究開発法人新エネルギー・産業技術総合開発機構 (NEDO) の平成 28 年度「データサイエンティスト育成」「Deep Learning 講座」の助成を受けたものです。

参考文献

- [1] Chen, Q. H., Yu, S. M., Guo, Z. X., & Jia, Y. B. (2016). Estimating Ads ' Click through Rate with Recurrent Neural Network. In ITM Web of Conferences (Vol. 7, p. 04001). EDP Sciences.
- [2] Graves, A. Supervised sequence labelling with recurrent neural networks. Vol. 385. Springer, 2012.
- [3] Zhai, S., Chang, K. H., Zhang, R., & Zhang, Z. (2016, April). Attention based recurrent neural networks for online advertising. In Proceedings of the 25th International Conference Companion on World Wide Web (pp. 141-142). International World Wide Web Conferences Steering Committee.