

Domain Adaptation Neural Network を用いた広告クリック予測

Ad Click Prediction by using Domain Adaptation Neural Network

谷口和輝 安井翔太
Kazuki Taniguchi Shota Yasui

株式会社サイバーエージェント
CyberAgent, Inc.

Online display advertising is one of the largest businesses for Internet companies and growing each year. Predicting the probability of ad click is important for buyers to value bid requests in Real Time Bidding (RTB) setting. Most of previous research use ad impressions, which happened only when the buyer wins in the auction, as a training data for click prediction. Such click prediction models, however, predict the probability of click not only for impression but all bid requests in the real product. This gap suggests that the click prediction model trained with impression data is suffered from selection bias. In this paper, we propose a new click prediction model that uses domain adaptation neural network (DANN) to mitigate this problem. DANN can train both a label predictor and the invariant features between domains at once. Experimental result shows that our proposed method improves the accuracy of click prediction.

1. はじめに

オンライン広告はインターネット産業を支える大きなビジネスの一つである。日本の2017年時点でのインターネットにおける広告費は約1兆5000億円^{*1}にまで達しており、2018年以降も拡大している。オンライン広告の取引手法の一つであるReal Time Bidding (RTB)では、広告を配信するメディアが送るリクエスト毎にオークションが開催され、インターネット上に広告を出したい広告主と契約した買い手が入札額を決定し、入札を行うことで取引が行われる。RTBでは秒間で数万件の取引が行われるため、人間が入札額を決定するのではなく、アルゴリズムにより決定する。このことからRTBにおいて、入札アルゴリズムに関する研究が盛んに行われている。

入札アルゴリズムを開発する際に最も重要となる要素の一つがクリック予測である。買い手はオークションを開催するプラットフォームから広告表示を行う権利を買い付ける為にオークションに参加し、落札した場合にのみインプレッション（広告表示）を行う事ができる。そして、表示した広告がクリックされると広告主から報酬として予め決められた単価を受け取る。そのため、各リクエストにおいて広告を表示した場合に、広告がクリックされるかを予測する事は入札価格を適正に決定する上で重要である。広告クリック予測の研究はこれまでに多くの研究が行われている。[McMahan 13][Chapelle 14][Wang 17]しかし、これまでの多くの研究ではモデルを学習する際にオークションで落札した結果として得られたインプレッションのデータのみを利用しているが、実際に推論したいデータは学習期間において落札されたデータのみではなく全てのリクエストであるため、学習データと実際に推論するデータの分布が異なる。[Zhang 16]らはこの問題を解決するために、Importance Sampling[Shimodaira 00]を用いたクリック予測を提案している。Importance Samplingは広告に関する研究に広く用いられている手法であるが、両データの分布間の距離が大きくなると特定のサンプルにおいてImportanceが非常に大きくなるこ

連絡先: 谷口和輝, 株式会社サイバーエージェント, 〒150-0042 東京都渋谷区宇田川町40番1号, 050-5578-1290, taniguchi_kazuki@cyberagent.co.jp

*1 (株)電通「日本の広告費2017」より

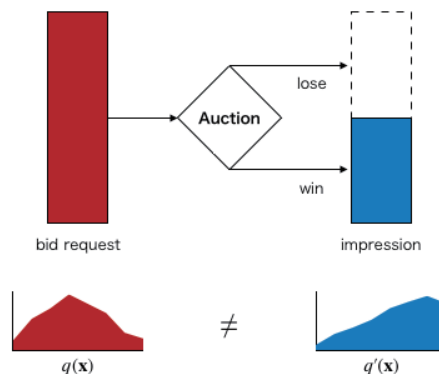


図1: 本研究の問題設定

とから損失関数の分散が大きくなるという問題が指摘されている。

本研究では、従来までのImportance Samplingを利用する方法ではなく、Domain Adaptationを応用した新しいモデルを提案する。提案手法に用いたDomain Adaptation Neural Network(DANN)[Ganin 15]はニューラルネットワークで特徴表現を行う際に損失にドメインに関する敵対的損失を加えることによってドメインに対して汎化した特徴表現を得ることを狙ったモデルである。本研究ではドメインとしてオークションの落札の結果を用いることで前述の問題設定へ応用する。最後に、人工的に生成したデータセットを用いた実験により提案手法の有用性を検証する。

2. 研究背景

2.1 問題設定

買い手に送られてくるリクエストを確率分布 $q(\mathbf{x})$ に独立に従う標本 \mathbf{x} 、および、オークションで落札し実際に配信したインプレッションを確率分布 $q'(\mathbf{x})$ に独立に従う標本 \mathbf{x}' とするとき、 $q'(\mathbf{x})$ は式(1)で表される。ここで、 $P(\text{win}|\mathbf{x})$ はリクエスト \mathbf{x} が送られてきた時にオークションで落札して広告が

表示される確率を表す。

$$q'(\mathbf{x}) = P(\text{win}|\mathbf{x})q(\mathbf{x}) \quad (1)$$

このとき、図 1 で示すように学習に利用するデータ (impression) と学習したモデルを利用して予測するデータ (bid request) の分布が異なるという問題が起こる。また、落札することが出来なかったリクエストに関してはラベルを得ることが出来ない点も考慮する必要がある。

2.2 先行研究

クリック予測の研究はこれまで多くの研究が行われているが、その基本的なアルゴリズムはロジスティック回帰をベースとしたものが多い。[McMahan 13][Chapelle 14] 深層学習を利用したモデルとして、特徴の交互作用をニューラルネットで表現する Deep & Cross Network[Wang 17] がある。これらのクリック予測に関する研究では、学習時に利用するデータは落札して実際に広告を配信したインプレッションのデータのみとなっている。しかし、実際には全てのリクエストに対して予測を行うため、学習時と推論時でデータの分布が異なる問題が起こる。

本研究の問題点となる学習データと推論時のデータ分布の違いを考慮した学習に関する先行研究について紹介する。[Shimodaira 00] は共変量シフト (Covariate Shift) の問題に対して Importance Sampling による手法を提案している。Importance Sampling は損失関数に対して重要度による重み付けを行うことによって、共変量シフト下で発生するバイアスの影響を打ち消すことが可能である。

本研究と同様の問題設定の先行研究として [Zhang 16] が挙げられる。Zhang らは前述の Importance Sampling を用いることでオークションの取引時に発生するバイアスの問題を解決する手法を提案しており、Importance Sampling に利用するための落札確率はオークションの入札価格を用いてモデリングしている。Importance Sampling は広告の分野でも幅広く使われてきているが、その欠点として分布間の距離が大ききときに損失の分散が大きくなる点が挙げられる。

本研究では Importance Sampling を用いたアプローチではなく、Domain Adaptation を用いた手法で前述の問題を解決する。

3. 提案手法

3.1 Domain Adaptation Neural Network

Domain Adaptation は転移学習の一種とされており、特に教師なし Domain Adaptation はあるドメインのラベル付きデータ (Source) と異なるドメイン (Target) のラベルなしデータの二種類を用いて、ラベルのない Target に対しても予測可能なモデルを学習する。Domain Adaptation Neural Network (DANN)[Ganin 15] は実際に予測したいラベル y の損失 L_y とは別にドメイン分類器を追加し、ドメイン分類器の損失 L_d を敵対的損失としてネットワーク全体の損失に追加し、誤差逆伝搬法によって学習を行う深層学習のモデルである。DANN で最小化したい損失 L は、入力されるデータ \mathbf{x} からドメイン d に対して不変な特徴ベクトル \mathbf{f} を学習するためのモデル $G_f(\mathbf{x})$ 、特徴ベクトル \mathbf{f} からラベル y の識別を行うモデル $G_y(\mathbf{f})$ 、同様にドメイン d の識別を行うモデル $G_d(\mathbf{f})$ を用いて式 (2) のように表される。

$$L(y, d, \mathbf{x}) = L_y(G_y(G_f(\mathbf{x})), y) - \lambda L_d(G_d(G_f(\mathbf{x})), d) \quad (2)$$

ここで、 λ はハイパーパラメータである。式 (2) を最小にするパラメータ θ_f , θ_y , θ_d は誤差逆伝搬法を用いて次の更新式によって学習する。

$$\theta_f \leftarrow \theta_f - \mu \left(\frac{\delta L_y}{\delta \theta_f} - \lambda \frac{\delta L_d}{\delta \theta_f} \right) \quad (3)$$

$$\theta_y \leftarrow \theta_y - \mu \left(\frac{\delta L_y}{\delta \theta_y} \right) \quad (4)$$

$$\theta_d \leftarrow \theta_d - \mu \left(\frac{\delta L_d}{\delta \theta_d} \right) \quad (5)$$

ここで、 μ は学習率である。 θ_f は敵対的損失を持っているため、Gradient Reversal Layer(GRL) を用いて誤差逆伝搬を行う。GRL の定義は式 (6) で示す。

$$R_\lambda(\mathbf{x}) = \mathbf{x} \quad (6)$$

$$\frac{\delta R_\lambda}{\delta \mathbf{x}} = -\lambda \mathbf{I} \quad (7)$$

3.2 提案手法

提案手法では DANN を利用した落札していないリクエストデータに対しても性能の高いモデルを提案する。図 2 に提案手法のモデルを図示した。

提案手法では、ドメインはオークションで落札したかどうかの二値を利用する。また、一般的な広告インプレッションは高次元でスパースなカテゴリ変数を扱うため、提案手法ではカテゴリ変数に対して Embedding レイヤーを用いて低次元で密なベクトルを学習する。[Cheng 16] [Wang 17] カテゴリ変数から計算した Embedding と連続変数の特徴を連結し、全結合層を重ねたネットワーク ($G_f(\mathbf{x})$) から特徴 \mathbf{f} を計算する。 \mathbf{f} からラベル予測するモデル ($G_y(\mathbf{f})$) とドメインを識別するモデル ($G_d(\mathbf{f})$) に分岐し、最終的に求めたいラベルの予測値を得る。

4. 実験

4.1 データセット

本実験では Display Advertising Challenge*2 で公開されたデータを利用する。データセットには 13 個の連続変数と 26 個のカテゴリ変数が含まれており、学習データのみで約 4500 万行のデータが含まれている。本研究では Source と Target の二つのデータセットが必要であり、モデルの性能を比較するためには両データセットにラベルが付与されている必要がある。そのため、本実験では利用するデータセットの中の学習データのみを利用し、学習データを Source と Target のデータセットに分類する。分類には式 (8) を用いて行う。ここで、 \mathbf{x} は特徴ベクトル、 \mathbf{w}' は重み係数でランダムで決定したものである。

$$d \sim \text{Bernoulli}\left(\frac{1}{1 + \exp(-\mathbf{w}'\mathbf{x})}\right) \quad (8)$$

4.2 実験設定

本実験では提案手法の有用性を検証するために、従来手法との比較を行った。比較に用いる評価指標には、クリック予測で広く利用されている logloss を利用する。一般的に logloss が低いほど、予測性能が高いと言われている。また、本研究では Source と Target の両者の予測性能を検証する必要があるため、評価指標は Source と Target の各々で計算した。比較手法とし

*2 <https://www.kaggle.com/c/criteo-display-ad-challenge>

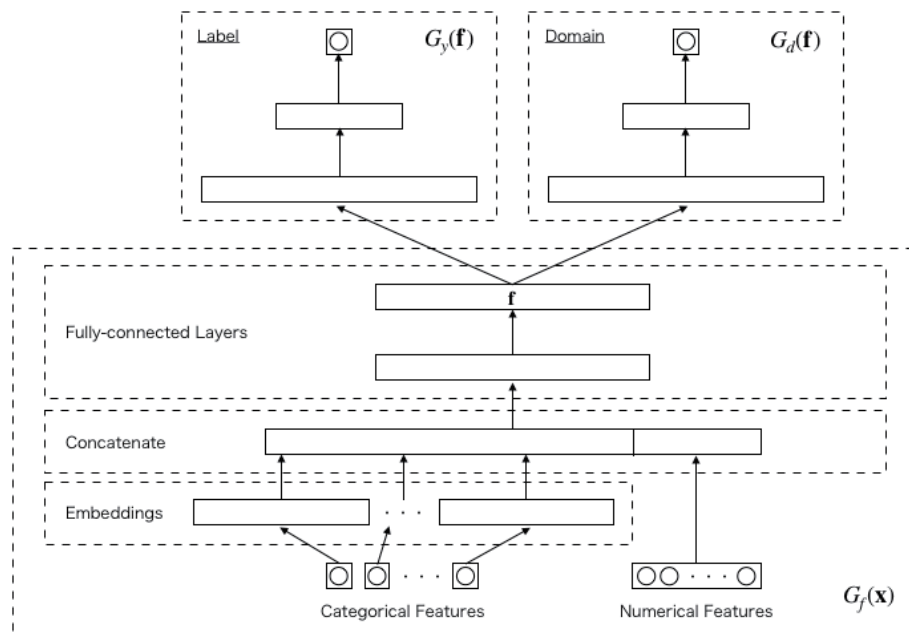


図 2: 提案手法のモデル

表 1: 提案手法の比較実験の結果

手法	テストデータ	logloss
Baseline	Source	0.4481
Importance Sampling	Source	0.4476
提案手法	Source	0.4452
Baseline	Target	0.4768
Importance Sampling	Target	0.4736
提案手法	Target	0.4725

て、Deep Neural Network(DNN) を用いたモデル (Baseline) と、Baseline に対して Importance Sampling を用いたモデルを利用した。Importance Sampling については、 $P(win|x)$ を単純なロジスティック回帰を用いて予測した予測値を利用した。

4.3 結果

実験の結果を表 1 に示す。表から見ても分かる通り、が従来手法に比べて高い精度を示した。提案手法は学習時にラベルのある Source に対する精度だけでなく、学習時にラベルのない Target に対する精度も向上していることが確認できる。logloss の値の向上幅が小さく見えるが、広告のクリック予測の問題においては、オンライン広告の膨大な取引量があるため 0.001 の向上は非常に重要とされている。[Wang 17]

5. おわりに

本研究では RTB における広告のクリック予測問題に対して、従来までのインプレッションしたデータだけを学習するモデルではなく、落札が出来なかったデータに対しても汎化する新しいモデルを提案した。実験では公開データセットのラベルがあるデータから人工的にデータセットを作成し、定量評価を行い、本研究の有用性を確かめた。

今後の展望として、実際の配信データを利用した先行研究との比較、データセットの作成方法の妥当性の検証が挙げら

れる。

参考文献

- [Chapelle 14] Chapelle, O., Manavoglu, E., and Rosales, R.: Simple and Scalable Response Prediction for Display Advertising, *ACM Trans. Intell. Syst. Technol.*, Vol. 5, No. 4, pp. 61:1–61:34 (2014)
- [Cheng 16] Cheng, H.-T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., Anderson, G., Corrado, G., Chai, W., Ispir, M., Anil, R., Haque, Z., Hong, L., Jain, V., Liu, X., and Shah, H.: Wide & Deep Learning for Recommender Systems, in *Proceedings of the 1st Workshop on Deep Learning for Recommender Systems, DLRS 2016*, pp. 7–10, New York, NY, USA (2016), ACM
- [Ganin 15] Ganin, Y. and Lempitsky, V.: Unsupervised Domain Adaptation by Backpropagation, in *Proceedings of the 32nd International Conference on International Conference on Machine Learning - Volume 37, ICML'15*, pp. 1180–1189, JMLR.org (2015)
- [McMahan 13] McMahan, H. B., Holt, G., Sculley, D., Young, M., Ebner, D., Grady, J., Nie, L., Phillips, T., Davydov, E., Golovin, D., Chikkerur, S., Liu, D., Wattenberg, M., Hrafnkelsson, A. M., Boulos, T., and Kubica, J.: Ad Click Prediction: A View from the Trenches, in *Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '13*, pp. 1222–1230, New York, NY, USA (2013), ACM
- [Shimodaira 00] Shimodaira, H.: Improving predictive inference under covariate shift by weighting the log-

likelihood function, *Journal of Statistical Planning and Inference*, Vol. 90, No. 2, pp. 227 – 244 (2000)

[Wang 17] Wang, R., Fu, B., Fu, G., and Wang, M.: Deep & Cross Network for Ad Click Predictions, in *Proceedings of the ADKDD'17*, ADKDD'17, pp. 12:1–12:7, New York, NY, USA (2017), ACM

[Zhang 16] Zhang, W., Zhou, T., Wang, J., and Xu, J.: Bid-aware Gradient Descent for Unbiased Learning with Censored Data in Display Advertising, in *Proceedings of the 22Nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '16, pp. 665–674, New York, NY, USA (2016), ACM