

深層学習による時間減衰を考慮したインフィード広告のCTR予測

出水宰^{1,2,a)} 深澤佑介¹ 森田浩²

概要：インフィード広告は、ユーザへの視認性が高いため、クリック率（CTR）の高い広告クリエイティブを表示することがより重要になる。しかし、インフィード広告はその高頻度な表示のために、配信以後のCTRの時間的な減衰が速いという特徴がある。そこで本研究では、この時間減衰を考慮した上でのCTR予測手法を提案する。まず、広告クリエイティブの画像情報やテキスト情報、配信設定情報といったマルチモーダルな特徴量からCTRをロバストに予測するモデルを構築する。次に、CTRの時系列変化を抽象的に表現可能なRNNモデルを構築する。アドネットワーク上の配信履歴データを用いたオフラインでの多期間のCTR予測検証を行い、提案手法の有効性を示す。

キーワード：深層学習、マルチモーダル学習、インターネット広告、クリック率予測

1. はじめに

インフィード広告とは、Webサイトやアプリにおけるフィード型コンテンツの間に、同様の体裁で表示される広告である。そのため、ユーザの目に止まりやすいという視認性の高さや、広告然とした雰囲気も薄いという特徴がある。インフィード広告需要は、広告主およびユーザからの高い支持を受けて、その市場は年々増加している。2017年時点の市場規模は1,903億円であったが、2023年では3,921億円になると推計されている[1]。

インフィード広告に限らず、インターネット広告において、広告クリエイティブの効果を測る指標として、インプレッション回数（広告が表示された回数）にたいするクリック回数の比率であるクリック率（Click through rate; CTR）が用いられる。このCTRを予測することは、ユーザおよび広告主の双方にとって重要である。例えば、クリック課金型（ユーザが広告をクリックした場合のみ広告主が予め入札していた金額を支払う形式）の設定では、広告を配信した場合の期待値は、広告主が設定した入札額とCTRによって決まる[2]。ある広告枠にたいし、複数の広告候補の中から配信すべき広告を買い付けて、収益の最大化を考えた際に、入札額は既知であるが、CTRは未知であるため予測を行う必要がある。この予測値が実際と乖離してしまうと、効果の低い広告を配信する可能性が高まり、収益の最大化は難しくなる。このように広告配信において、CTR予測は収益に直結する非常に重要な手段である[2]。

こうした背景から、広告配信におけるCTR予測の研究は盛んに行われている。特に、広告クリエイティブに紐づく画像情報やテキスト情報、そして配信設定情報といった、マルチモーダルな特徴量を用いたCTR予測が提案されている[3],[4]。これら多くの従来研究では、インプレッション単位でユーザにクリックされるかどうかを予測する問題設定として定義され、その下で予測手法が提案されている。

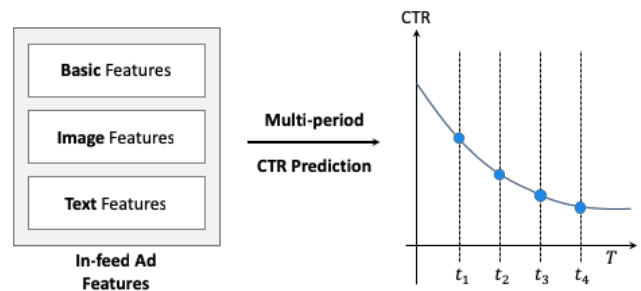


図1 インフィード広告における多期間のCTR予測
Figure 1 Multi-period CTR Prediction of in-feed Ads.

一方で、インプレッション単位ではなく、広告単位でCTRがどの程度になるかを事前に予測する問題設定は、ビジネス的にも求められている。特に、CTRは比率としての値であり、インプレッション回数が少ない場合にはばらつきが生じるため、よりロバストな予測手法が必要となる。

本研究で対象とするインフィード広告にみられる特徴として、その高頻度な表示のために、配信開始以後のCTRの時間的な減衰が速いということが挙げられる。その減衰速度は、広告クリエイティブ自体の内容や、対象ユーザー属性、掲載面といった配信設定に依存すると考えられる。このCTRの時間的な減衰まで含めて予測できれば、事前に適切な掲載期間の計画が可能となる。

そこで本研究では、図1に示すように、広告ごとの時間減衰を考慮した上でのCTR予測を提案する。まず、広告クリエイティブ自体の内容によるCTRの時間減衰への影響を表現する目的で、配信設定情報だけでなく画像情報やテキスト情報といったマルチモーダルな特徴量に入れ込むことを考える。次に、CTRの時系列的な変化を表現する目的で、Recurrent Neural Network (RNN)による予測モデルを構築する。本手法の効果を測るため、アドネットワーク上の配信履歴を用いたオフライン検証でCTR予測を実施する。

本研究の貢献ポイントは以下である。

- マルチモーダルな特徴量から広告単位のCTRをロバストに予測するため、従来研究[3]にDropout及びL2正則化を導入するネットワーク構造の改良を行い、実

1 株式会社NTTドコモ, NTT DOCOMO, INC.
2 大阪大学, Osaka University.
a) tsukasa.demizu.sp@nttdocomo.com

データによる精度検証で、マルチモーダルな特徴量による CTR 予測の精度向上を確認した

- CTR の時間減衰を推定するために、多期間にわたる CTR の時系列変化を抽象的に表現可能な RNN 型のネットワーク構造を提案した
- 実データによる精度検証で、ベースライン（多期間の CTR を独立したものとみなし同時に予測するモデル）との比較を行い、提案手法による精度向上を確認した

本稿の構成は、以下の通りである。2 章で関連する研究について述べ、3 章で本研究での問題設定について述べる。次に 4 章で提案手法について述べ、5 章でその有効性を確認するために行った評価実験について述べる。最後に 6 章で本研究のまとめと今後の課題について述べる。

2. 関連研究

本章では、広告配信における CTR 予測のアプローチを分類し、それぞれのアプローチに関連する研究について述べ、本研究の位置付けについて説明する。

2.1 インプレッション単位での CTR 予測

第一のアプローチは、あるユーザにたいする広告の 1 インプレッションあたりの結果 (click or non-click) から、二値の分類問題として学習するものである。広告表示の最小単位に着目し、対象とする広告とユーザの双方の情報を用いて CTR を予測する。すなわち、インプレッション時の d 次元の特徴量を $x \in \mathbb{R}^d$ としたとき、クリックされるかどうかを表す \hat{y} を次のようにして求める。

$$\hat{y} = \frac{1}{1 + \exp(-z)} \quad (1)$$

$$z = f(x) \quad (2)$$

訓練データとして、 N 回のインプレッションについて、それぞれの特徴量 $x_i \in \mathbb{R}^d$ とそのクリック結果 $y_i \in \{0, 1\}$ 、(0: not-click, 1: click) が与えられた場合、次に示す誤差関数 L の最小化によって関数 $f(\cdot)$ を得る。

$$L = \frac{1}{N} \sum_{i=1}^N (-y_i \log(\hat{y}_i) - (1 - y_i) \log(1 - \hat{y}_i)) \quad (3)$$

Chen ら[3]は、インプレッションにおける特徴量 x として、広告の配信設定 (ユーザの性別や掲載商品のカテゴリ、Web ページにおける広告の掲載位置) といった基本的な特徴量 (basic features) に加えて、広告クリエイティブの画像情報 (image features) を用い、End-to-End で CTR を学習する Deep CTR Prediction を提案した。

Aryafar ら[4]も、マルチモーダルな特徴量表現として、画像に加えて、広告に紐づくタグやタイトルといったテキスト情報を取り入れた CTR 予測を行なっている。画像情報

については、ImageNet[5]で事前学習された ResNet101[6]を使い、テキスト情報については、Hashing Trick[7]を使って、それぞれの分散表現を取得している。また、マルチモーダルな特徴量を単に結合するだけでなく、アンサンブルモデルとして学習することで、飛躍的な精度向上を達成した。

Zhang ら[8]は、ユーザの過去の広告クリック挙動との関係に注目し、RNN[9]による CTR 予測を提案した。ユーザが前回の広告クリックで訪問したページ上での滞在時間や、前回クリックからの経過時間といった情報と、CTR との関係を解析している。その上で、ユーザの過去の挙動を系列データとして入力の一部とした RNN モデルを構築し、同一データでの Logistic Regression モデルや Neural Network モデルからの精度向上を示した。

インプレッション単位での CTR を予測する際に、CTR が極端に低い値の場合は、訓練データ $y_i \in \{0, 1\}$ について不均衡な分類問題となってしまう。Deng ら[10]は、こうした状況を是正するために Generative Adversarial Network (GAN)[11]から着想を得た Disguise Adversarial Network (DAN)を提案した。分類問題における不均衡データの是正方法として、SMOTE [12]により、既にある少数の正例データ (1: click) から線形な組合せで人工的にデータを生成する方法がある。これにたいして DAN では、大量の負例データ (0: not-click) を非線形な変換を経て、一部を "偽造された" 正例データとして増幅させる。ディスプレイ広告とモバイル広告の双方の CTR 予測タスクにおいて、DAN を利用することで SMOTE と比較して精度向上が確認された。

2.2 広告単位での CTR 予測

第二のアプローチは、広告単位で複数ユーザへのインプレッションを経た後の結果を用いて、CTR を直接予測するものである。ここでの訓練データとして、 N 個の広告の、それぞれの特徴量 $X_i \in \mathbb{R}^d$ とその CTR 結果である連続量 $Y_i \in (0, 1)$ を用いた学習を行う。

橋本ら[13]は、バナー広告の CTR にたいするトレンド効果や曜日効果、祝日効果といった影響に着目し、これらを考慮した状態空間モデルを構築した。また、実際の配信データを用いた実証分析では、提案モデルの有用性を示し、CTR の長期的な傾向の変化や曜日によって異なる振舞いを捉えることができていた。

岩崎[14]は、Chen ら[3]の Deep CTR Prediction に広告クリエイティブのテキスト情報を付与した予測モデルを提案し、インフィード広告である Facebook Ads^{*1}にたいしての実験を行った。実験では、CTR を求める回帰問題として定義し、広告の基本的な特徴量に加え、高次元な画像やテキスト特徴量を付与した場合の学習性能と配信影響について分析している。また、坂田ら[15]は、広告における CTR の数値が

*1 <https://www.facebook.com/business/ads>

閾値よりも高いかどうかの結果 (effective or ineffective) を分類する問題と定義し、画像特徴量の寄与について示していた。

2.3 本研究の位置付け

本研究では、2.2 節で述べた広告単位での CTR を回帰するアプローチを取り、広告配信の事前に CTR を予測するタスクを扱う。また、対象の広告は、近年その重要度が増しているインフィード広告とする。インフィード広告は、CTR の時間減衰が速いという性質を持つが、広告クリエイティブ自体の内容による CTR の時間減衰への影響を表現する目的で、配信設定情報だけでなく画像情報やテキスト情報を加えたマルチモーダルな特徴量を利用する。更に、CTR を 1 点ではなく、多期間にわたる減衰傾向までを考慮した系列データとしての拡張を行う。

3. 問題設定

3.1 CTR の時間減衰

インフィード広告は、ユーザの視認性が高いため、同じ広告クリエイティブを使い続けたときの CTR の減衰速度が、他のインターネット広告に比べ速いという特徴がある。図 2 に広告毎の CTR の時間的な減衰の様子を示す。5 つの広告のそれぞれについて、配信を開始した初週の CTR を基準値とし、週毎の相対的な CTR をプロットしている。どの広告も翌週には CTR が大きく低下し、初週から 25% 程度も低下する広告も存在する。このように、インフィード広告は CTR の時間減衰が速いという特徴を持つが、その速さは広告クリエイティブにより異なる。例えば図 2 中の広告クリエイティブ B は急激に CTR が減少しているが、広告クリエイティブ D の減少は比較的緩やかである。このように、CTR の時間減衰は、広告クリエイティブによってばらつきが存在する。これは、クリエイティブ自体の内容や、広告対象となるユーザ属性や掲載面といった配信設定に依存すると考えられる。




図 2 CTR の時間減衰の例

Figure 2 An example of time-decaying of CTR.

こうしたインフィード広告の CTR において、時間減衰まで含めて予測できれば、収益最大化のための広告買い付けだけでなく、配信の事前に最適な配信スケジュールの計画が可能となり、更なる収益向上が期待できる。すなわち、それぞれの広告について時間毎の CTR を予測し、ある程度の減衰が起きたところで、別の広告配信に切り替える、というオペレーションが事前に計画可能となる。

3.2 利用する特徴量

本研究では、インフィード広告の時間減衰まで含めた CTR 予測を目的とする。CTR 予測モデルの入力として用いられる特徴量は、2 章で述べたようにさまざまなものが提案されている。本研究で用いる特徴量を表 1 に示す。CTR 予測モデルの入力として、画像情報やテキスト情報といった高次元な特徴量を用い、クリエイティブ自体が与える影響を捉えることを目指す。また、広告クリエイティブにおける関係図を図 3 に示す。広告クリエイティブごとに、その上位階層として、広告グループ、キャンペーンが存在する。また、広告クリエイティブごとに画像とテキストの組合せが存在している。広告の配信設定に関する情報 (Basic) の一部を表 2 に示す。ここで示すように、広告自体の情報や、配信されるユーザ属性などの幅広い設定情報を用いる。

3.3 問題設定

広告クリエイティブ l の特徴量 X_l は、表 1 で示したものから、 $X_l = [B_l, I_l, T_l]$ と表す。ここで B_l, I_l, T_l は、それぞれ Basic, Image, Text の特徴量であり、ベクトルとして表現できる。次に、予測対象とする多期間の CTR を定義する。広告クリエイティブ l の配信日を基準とし、週 t の CTR を以下で表す。

$$CTR_t = \text{Clicks}_{<0,t>} / \text{Impressions}_{<0,t>} \quad (4)$$

ここで、 $\text{Clicks}_{<0,t>}$ は配信日から週 t 初日まで累計クリック回数、 $\text{Impressions}_{<0,t>}$ は、配信日から週 t 初日まで累計インプレッション回数とする。本研究では $X_l = [B_l, I_l, T_l]$ から多期間 $t = 1, \dots, T$ における CTR_t を予測する問題を考える。

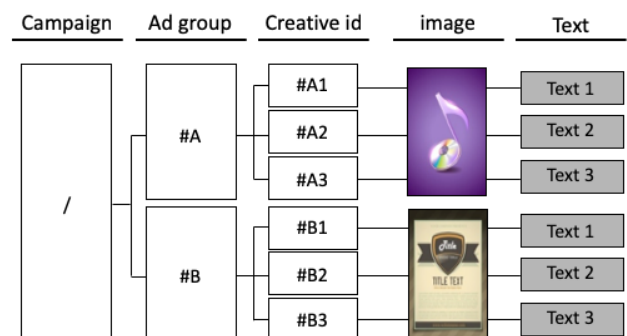


図 3 インフィード広告における構造

Figure 3 In-feed ad campaign structure.

表 1 特徴量の種類
 Table 1 Type of features.

Features	Details
Basic	広告の配信設定に関する情報
Image	クリエイティブの画像情報 (1200x628 pixel)
Text	クリエイティブのテキスト情報

表 2 Basic 特徴量の例
 Table 2 examples of Basic features.

Feature	Details
広告主	広告主の ID
広告種別	ターゲティング型, リターゲティング型といった広告の種類
対象ユーザ属性	対象とするユーザの性別, 年齢, 居住地に関する設定情報
配信可能時間帯	曜日及び時間帯の配信可否情報
CPC 上限値	1 クリックあたりに支払うコスト (Cost Per Click; CPC) の上限額
日予算	1 日あたりの設定予算額

4. 提案手法

本章では, 3.2 節で述べた Basic, Image や Text といった広告クリエイティブに紐づく特徴量から CTR を予測する提案モデルを説明する. 4.1 節で従来研究[3]のネットワーク構造に改良を加えた予測モデルを述べる. 4.2 節でそれを多期間の CTR 予測に拡張した RNN モデルについて述べる.

4.1 CTR 予測モデル

広告クリエイティブの Basic, Image そして Text を特徴量として, クリエイティブ自体が CTR に与える影響を捉えることを考える. 従来研究[3]は, 2.1 節で述べたようにインプレッション単位の CTR 予測タスクにおいて, マルチモーダルな特徴量を End-to-End に学習する手法を提案した. しかし, 広告単位の CTR 予測タスクにおいては, インプレッション回数が少ないような場合, 1 クリックが与える影響に左右されて CTR がばらつくため, よりロバストな予測が求められる. そこで, より安定的な学習を目指すため, [3]のネットワーク構造へ新たに Dropout 及び L2 正則化を追加した. 改良したモデルを図 4 に示す. Basic, Image そして Text からのスケールを吸収するために Batch Normalization をかけた結合の後に, Dropout[20]を加えて過学習の回避を行なっている. 更に, その後の全結合層に L2 正則化を取り入れた. 最終的全結合層で sigmoid 関数による活性化を経た後, 数値として CTR を出力する. 次にそれぞれの特徴量の加工, およびネットワーク構造について述べる.

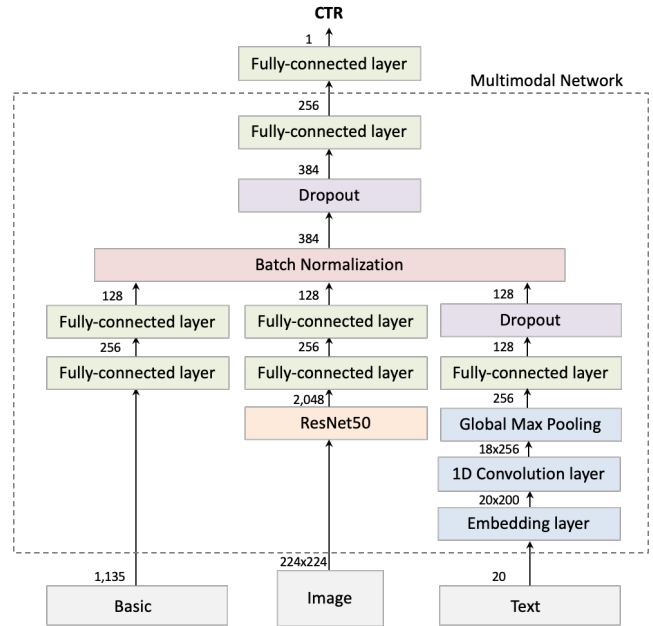


図 4 CTR 予測モデル
 Figure 4 CTR prediction model.

4.1.1 Basic 特徴量

広告の配信設定に関する情報の Basic は, 大部分がカテゴリカルデータである. こうしたカテゴリカルな変数は one-hot encoding によりバイナリー変数として表現している. また CPC 上限値や日予算額といった計量値は, 標準化 (Standardization) によって平均 0, 分散 1 の特徴量に変換をしている. このようにして得られた約 1,000 次元の Basic 特徴量から, 2 層の全結合層を経て 128 次元の特徴量を取り出す.

4.1.2 Image 特徴量

対象とするインフィード広告の Image 特徴量は, 3.2 節で述べたように, 1200x628 pixel の画像を元としている. この画像をまず 224x224 pixel にリサイズする. 次に, ImageNet で事前学習した重みを使った ResNet50 モデル[6]から 128 次元の特徴量を取り出す. ここで, ResNet50 モデルの最後の畳み込み層の出力では, Global max pooling を適用している.

4.1.3 Text 特徴量

Text 特徴量は, まず形態素解析で最大 20 シーケンスの単語リストへと分割する. また 20 シーケンスに満たない場合はゼロパディングによって先頭部分を穴埋めする. 次に, 日本語版 Wikipedia の本文全文から学習したエンティティベクトル[16]を用いて, 分散表現[19]を得る. その後, 1 次元方向の畳み込み層と Global max pooling 層, 全結合層を経た後に, Dropout をかけて 128 次元の特徴量を取り出す.

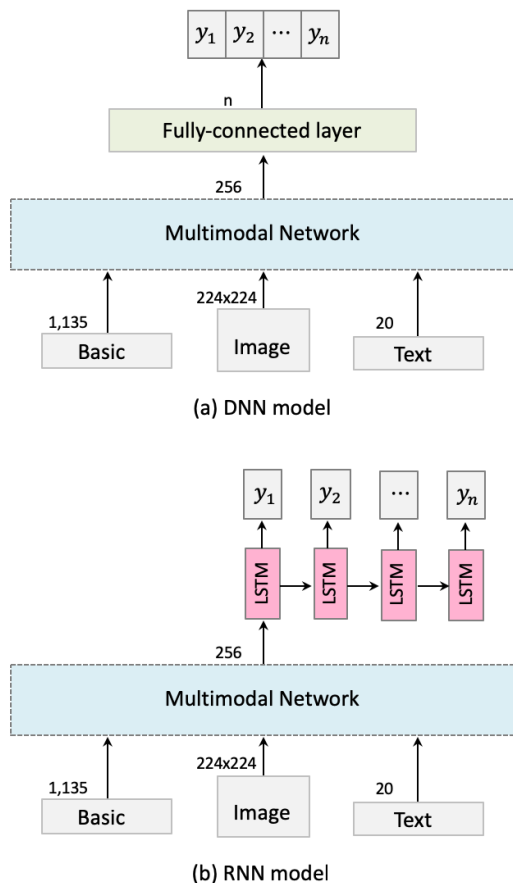


図 5 多期間 CTR 予測モデル

Figure 5 Multi-period CTR prediction model.

4.2 多期間 CTR 予測への拡張

本節では、インフィード広告で顕著に現れる CTR の時間減衰を推定する目的で、多期間の CTR 予測への拡張を考える。まず自然な拡張として図 5 (a)のように、4.1 節で示した CTR 予測モデルの最終層の出力の次元を、1次元から多次元にした Deep Neural Network(DNN)モデルが考えられる。このモデルは、多期間の CTR を独立したものとみなし、それらを同時に予測していることになる。しかし、週 t の CTR である CTR_t は、 CTR_{t-1} の影響を受けるため、このように独立して扱うことは現実に即していないと考えられる。

これにたいして、多期間にわたる CTR の時系列変化を、マルチモーダルな特徴量から抽象的に表現することを目指した提案モデルを図 5 (b)に示す。これは、4.1 節の CTR 予測モデルの最終層を Long short-term memory (LSTM) を使って繰り返すことにより、多次元の出力を系列データとして取り出す RNN モデルである。この提案モデルは、入力としての Basic, Image そして Text がそれぞれ 1 時点の情報であり、出力が複数時点での CTR 情報であることから、Image Captioning[17]のような one-to-many 型と捉えることができる。

表 3 配信データの概要

Table 3 About datasets.

Period	# Total impressions	# Ads
2018/10/01~2019/02/20	1,814,634,077	28,470

表 4 CTR 予測における精度比較

Table 4 Comparison of model accuracy.

Model	MSE (x 1e-5)	% Improve
Avg. CTR (Baseline)	3.07	-
Basic	2.29	25.4%
Basic + Image	1.97	35.8%
Basic + Image + Text	1.82	40.7%

表 5 重要特徴量

Table 5 Top 50 Important features.

Model	主な重要特徴量 (Top50)
Basic	広告主に関する特徴量 (29 個)
Basic + Image + Text	広告主に関する特徴量 (6 個), Image 由来の特徴量 (15 個), Text 由来の特徴量 (12 個)

5. 評価実験

本章では、提案手法である多期間 CTR 予測モデルを評価するために、実データを用いた実験について説明する。評価実験の目的は、1) CTR 予測モデルの精度評価、2) 多期間 CTR 予測における提案モデルの精度評価の 2 点である。

5.1 データセット

評価実験で用いたインフィード広告の配信データは、NTT ドコモが保有する広告アドネットワークに蓄積された広告情報と配信実績を利用した。利用した配信データを表 3 に示す。尚、対象とする広告は、インプレッションの回数が少なくとも 100 回以上のもを選択している。

配信実績は、広告クリエイティブの 1 インプレッション単位の結果 (click or not-click) が保持されており、広告の配信開始以降の任意の期間での CTR 算出が可能である。今回の評価実験のうち、CTR は以下のように算出している。

1) CTR 予測の精度比較の場合：広告の配信日から終了までの全期間における CTR

2) 多期間 CTR 予測の精度比較の場合：式(4)で示した、配信日から週 t 初日までの CTR_t

予測モデルの精度は、実際の運用を想定し、新規の広告クリエイティブの場合で検証した。すなわち、訓練データとテストデータは、広告の配信日で分割し、テストデータの広告クリエイティブは、訓練データ中に一切含まれない。

5.2 CTR 予測の精度評価

4.1 節で述べた Basic, Image そして Text といった広告クリエイティブに基づく特徴量を用いた CTR 予測モデルの精度評価を表 4 に示す。精度評価の Baseline として、訓練データ中の広告クリエイティブの CTR の平均値のみで予測したものをおいている。この Baseline にたいして Basic のみのモデル、Basic に Image を追加したモデル、Basic に Image と Text の双方を追加したモデルで、平均二乗誤差 (Mean Squared Error; MSE) とその改善率を求めた。表 4 に示すように、広告クリエイティブに関する特徴量である Basic, Image そして Text を追加していくことで、Baseline から誤差を段階的に改善できていることが分かる。特に、全ての特徴量を用いたモデル (Basic + Image + Text) の場合、Baseline から誤差を 40%以上も改善できている。このことから、広告クリエイティブの CTR 予測を行う上で、画像情報やテキスト情報が有用であること示した。

次に、CTR 予測をする際に寄与した特徴量を調べるために、SHAP value[18]を用いて重要度を算出し、Top50 の特徴量を抽出した。モデルごとの主な特徴量を表 5 に示す。Basic のみのモデルは、Top50 の重要特徴量うち大部分が、広告主に関する特徴量である。一方で、全ての特徴量を用いたモデル (Basic + Image + Text) では、広告主に関する特徴量は重要度が減少し、代わりに Image 由来の特徴量や Text 由来の特徴量の重要度が増している。このことから、広告主といった過去の配信結果を基にした特徴量に依存せず、Image や Text といった新規の広告クリエイティブにたいしても有効であることが分かる。

5.3 多期間 CTR 予測における提案モデルの評価

4.2 節で述べた、CTR 予測を多期間に拡張した DNN モデル、および提案モデルである RNN モデルにて、新規広告の配信開始から4週目までの CTR 予測を行なった。ここで、初週における CTR のばらつきを軽減し、CTR の時間的な減衰を精緻に見るため、対象とする広告は、累計インプレッション回数が 1,000 回以上のものを選択している。

モデル比較のため、訓練データにおける各広告の週毎で計算した CTR の平均値をそのまま予測値とするモデル (Avg. CTR) でも精度を検証した。表 6 に各モデルの多期間 ($t = 1,2,3,4$) の CTR にたいする誤差 (MSE)、表 7 に Avg. CTR モデルからの MSE 改善率を示す。表 6 から、提案手法である RNN モデルが全ての期間で、最も良い精度であることが分かる。また表 7 から RNN モデルでは、より長期先の予測ほど DNN モデルから改善効果が高まっていることが分かる。これは DNN モデルにおける多出力の CTR は独立した予測値になっているが、RNN モデルでは系列データとして学習させているため、より効果的に学習できたためだと考えられる。

表 6 多期間 CTR 予測モデルの精度比較

Table 6 Comparison of model accuracy in multi-period CTR prediction task

Model	MSE (x 1e-5)			
	week 1	week 2	week 3	week 4
Avg. CTR	2.28	1.71	1.60	1.57
DNN	1.36	0.99	0.91	0.89
RNN	1.35	0.98	0.90	0.86

表 7 Avg. CTR からの MSE 改善率比較

Table 7 Comparison of MSE improvement rate from Baseline

Model	% Improve			
	week 1	week 2	week 3	week 4
Avg. CTR	-	-	-	-
DNN	40.2%	42.4%	42.9%	43.5%
RNN	40.8%	42.6%	43.6%	45.1%

6. おわりに

本研究では、インフィード広告における CTR の時間減衰を考慮した多期間の CTR 予測手法を提案した。まず、マルチモーダルな特徴量から広告単位の CTR をロバストに予測するための CTR 予測モデルを構築した。次に、多期間にわたる CTR の時系列変化を抽象的に表現可能な RNN 型のネットワーク構造を提案した。提案手法の効果を知るために、アドネットワーク上の配信履歴を用いたオフライン検証で多期間 CTR 予測を実施し、提案手法の有効性を示した。

今後の課題は、週次といった時間単位だけでなく、インプレッション回数に応じた CTR の減衰を捉えることで、よりオペレーションに落とし込みやすい予測にする必要がある。今後は、CTR の時間減衰を推定した上で、最適な配信計画を離散最適化問題として求解した場合の効果も明らかにしていきたい。また、多期間 CTR 予測において各期間の重要特徴量がどのように変化していくかを SHAP value を用いた解析を行ない、クリエイティブ自体の改善にもつなげていきたい。

参考文献

- [1] 株式会社サイバーエージェント:インフィード広告市場調査、<<https://www.cyberagent.co.jp/news/detail/id=21333>> (参照 2018-02-14)
- [2] 田頭 幸浩, 山本 浩司, 小野 真吾, 塚本 浩司, 田島 玲, オンライン広告における CTR 予測モデルの素性評価, 第 5 回データ工学と情報マネジメントに関するフォーラム (DEIM2013) (2013).
- [3] Chen, J., Sun, B., Li, H., Lu, H. and Hua, X. S.: Deep ctr prediction in display advertising, *In Proceedings of the 24th ACM international conference on Multimedia*, ACM, pp. 811-820 (2016).
- [4] Aryafar, K., Guillory, D. and Hong, L.: An Ensemble-based Approach to Click-Through Rate Prediction for Promoted Listings

- at Etsy, *In Proceedings of the ADKDD'17*, ACM, p. 10 (2017).
- [5] Deng, J., Dong, W., Socher, R., Li, L. J., Li, K. and Fei-Fei, L.: Imagenet: A large-scale hierarchical image database, *In 2009 IEEE conference on computer vision and pattern recognition*, IEEE, pp. 248-255 (2009).
- [6] He, K., Zhang, X., Ren, S. and Sun, J.: Deep residual learning for image recognition, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, IEEE, pp. 770-778 (2016).
- [7] Weinberger, K., Dasgupta, A., Attenberg, J., Langford, J. and Smola, A.: Feature Hashing for Large Scale Multitask Learning, *In Proceeding of the 26th International Conference on Machine Learning, ICML'09*, pp.1113-1120 (2009).
- [8] Zhang, Y., Dai, H., Xu, C., Feng, J., Wang, T., Bian, J. and Liu, T. Y.: Sequential click prediction for sponsored search with recurrent neural networks, *In Twenty-Eighth AAAI Conference on Artificial Intelligence* (2014).
- [9] Mikolov, T., Karafiát, M., Burget, L., Černocký, J. and Khudanpur, S.: Recurrent neural network based language model, *In Eleventh annual conference of the international speech communication association* (2010).
- [10] Deng, Y., Shen, Y. and Jin, H.: Disguise Adversarial Networks for Click-through Rate Prediction, *In IJCAI*, pp. 1589-1595 (2017).
- [11] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S. and Bengio, Y.: Generative adversarial nets, *In Advances in neural information processing systems*, pp. 2672-2680 (2014).
- [12] Chawla, N. V., Bowyer, K. W., Hall, L. O. and Kegelmeyer, W. P.: SMOTE: synthetic minority over-sampling technique, *Journal of artificial intelligence research*, 16, pp. 321-357 (2002).
- [13] 本橋永至, 磯崎直樹, 長尾大道, 樋口知之: 状態空間モデルによるインターネット広告のクリック率予測, オペレーションズ・リサーチ: 経営の科学, Vol.57, No.10, 574-583. (2012).
- [14] 岩崎祐貴: 深層学習による Facebook 広告の CTR 予測, 人工知能学会全国大会論文集 第 32 回全国大会 (2018).
- [15] 坂田隼人, 栗田啓大, 山崎俊彦. Convolution Neural Network による広告画像効果の推定, 人工知能学会全国大会論文集 第 32 回全国大会 (2018).
- [16] Suzuki, M., Matsuda, K., Sekine, S., Okazaki, N. and Inui, K.: Neural joint learning for classifying Wikipedia articles into fine-grained named entity types, *In Proceedings of the 30th Pacific Asia Conference on Language, Information and Computation: Posters*, pp. 535-544 (2016).
- [17] Vinyals, O., Toshev, A., Bengio, S. and Erhan, D.: Show and tell: A neural image caption generator, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, IEEE, pp. 3156-3164 (2015).
- [18] Lundberg, S. M. and Lee, S. I.: A unified approach to interpreting model predictions, *In Advances in Neural Information Processing Systems*, pp. 4765-4774 (2017).
- [19] Hinton, G., McClelland, J. and Rumelhart, D.: Distributed representations, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Cambridge, MA, MIT Press, Vol. I, chapter 3, pp. 77-109, (1986).
- [20] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R.: Dropout: a simple way to prevent neural networks from overfitting, *The Journal of Machine Learning Research*, Vol.15, No.1, 1929-1958 (2014).