

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

受付日 2020年3月31日, 採録日 2020年10月6日

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) がより高い広告クリエイティブを表示することが重要になる。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うえでの 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

Deep Time-decaying CTR Prediction of In-feed Advertising

TSUKASA DEMIZU^{1,2,a)} YUSUKE FUKAZAWA¹ HIROSHI MORITA²

Received: March 31, 2020, Accepted: October 6, 2020

Abstract: In-feed advertisement are characterized by high visibility to users, so it is important to display creatives with higher click-through rate (CTR). However, since in-feed advertisements are displayed to users frequently, the CTR has a rapid time-decay after the advertisement is delivered. In this study, we propose a CTR prediction method considering its time-decay for in-feed advertisements. First, we introduce a model can robustly predict CTR from multi-modal features such as image information, text information and audience setting information of advertising creatives. Next, we construct an RNN model considering the time series change of CTR. The effectiveness of our proposed model is demonstrated by offline verification of multi-period CTR prediction task using historical and contextual data on an ad network in Japan.

Keywords: deep learning, multi-modal learning, internet ads, CTR prediction

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。こうした特徴から、広告主およびユーザからの高い支持を受けて、インフィード広告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 (広告におけるバナー画像やテキスト) 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。たとえば、クリック課金型 (ユーザが広告をクリックした場合にのみ広告主があらかじ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

¹ 株式会社 NTT ドコモ
NTT DOCOMO, INC., Chiyoda, Tokyo 100-6150, Japan

² 大阪大学
Osaka University, Suita, Osaka 565-0871, Japan

a) tsukasa.demizu.sp@nttdocomo.com




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

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 予測の研究はさかに行われている。特に、広告クリエイティブに紐付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。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、ビジネスの観点からも求められている。しかし、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。たとえば、真の CTR が 5% の広告について、信頼度 85% で推定値が真値の 1% 以内に収まるようにするためには、約 1,000 回のインプレッション回数が必要である [5]. そのため、なるべく過学習を避けた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の特徴として、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あげられる。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。たとえば、ある広告について掲載初期の CTR は高いが、急峻な CTR 減衰が予測される場合は、掲載期間を短く設定するといった計画を事前に立てることができる。また、定められた予算と期間の中で、累積クリック数が最大となるような広告の買付け、および掲載期間を決定する最適化問題のパラメータとして活用することもできる。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うえでの CTR 予測手法を提案する。まず、広告クリエイティブの内容による

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。

- (1) 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 および 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。
- (2) 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。
- (3) 実データによる精度検証で、ベースライン (多期間の CTR を独立したものと見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、以下のとおりである。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 1 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 予測を行った。画像情報については、ImageNet [6] で事前学習された ResNet101 [7] を使い、テキスト情報については、Hashing Trick [8] 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 [9] 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 [10] による CTR 予測を提案した。ここでは、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 との関係性を解析していた。そのうえで、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 [11] は、こうした状況を是正するために Generative Adversarial Network (GAN) [12] 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 [13] により、すで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 2 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、 L 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。

Shi ら [14] は、検索連動型広告を対象として、CTR の指標だけでなく、1 クリックあたりの費用であるクリック単価 (Cost per click; CPC) も含めた予測を行った。用いた予測モデルとしては、Linear Regression, Random Forest そして Gradient Boosting をあげており、CTR 予測および

CPC 予測の精度と、各モデルでの重要特徴量の解析をしていた。本橋ら [15] 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とらえることができていた。

Chen ら [3] の Deep CTR Prediction にたいし、岩崎 [16] は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 [17] は、広告における CTR の数値が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。

Park ら [18] は、言語的な情報として、タイトルや説明内容だけでなく、広告クリエイティブの画像に埋め込まれたテキスト表現も用いて CTR の予測を行った。画像に埋め込まれたテキストの検出は OCR によってなされており、抽出後に BERT [19] によってベクトル化している。また、画像情報とテキスト情報との空間的な関係性を反映するための Attention 機構を取り入れた Multistep Modality Fusion Network (M2FN) を提案した。

2.3 本研究の位置付け

広告配信の事前に、その CTR の時間的な減衰を、広告クリエイティブの情報を用いて陽にモデル化するような CTR 予測手法は従来、提案されていない。広告配信ではなく、Web 上のニュース記事配信における CTR の時間的な減衰を、時系列モデルとして扱った既存研究は報告されている。Agarwal ら [20] は、自社のポータルサイト上に掲載されるニュース記事である Yahoo! Front Page Today Module^{*2}において、それらの掲載位置という空間的情報と掲載時刻からの時間的情報を元にした CTR 予測手法を提案した。ここでは、ニュース記事における CTR の減衰は、Wu ら [21] が提唱したように、ユーザへの繰り返しの表示による一種の疲弊から発生するものと仮定されている。また、ニュース記事における CTR 予測の時間スケールは 1 時間単位で扱われており、繰り返しの表示にともなう CTR の減衰だけでなく、1 日における時間帯ごとの傾向も考慮されている。こうした時間的情報を組み入れた Dynamic Gamma-Poisson モデルを提案し、シミュレーションを通じて良好な予測性能を示した。しかし、Agarwal らのモデ

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

^{*2} <https://webscope.sandbox.yahoo.com/catalog.php?datatype=r&did=49>

ルで、ニュース記事についてのマルチモーダルな情報（見出しにある画像やテキスト）は扱われていないため、記事自体の内容による影響は考慮されていない。また、CTRの予測を行うタイミングとしても、ニュース記事を配信した後に動的に予測することを想定しており、配信の事前に予測することは想定されていない。

そこで本研究では、新規広告を入稿する際に CTR を予測し、その広告を配信すべきか、また、CTR の時間減衰に応じてどの程度の掲載期間にすべきかの意思決定に役立てることを目標としている。そのため、インプレッション単位の CTR 予測ではなく、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ることにする。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している。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。さらに、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 [22]。図 2 に広告ごとの 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、週ごとの相対的な 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っている。たとえば図 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




図 2 CTR の時間減衰の例
Fig. 2 An example of time-decaying of CTR.

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。

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、さらなる収益向上が期待できる。たとえば、それぞれの広告について多期間にわたる CTR を予測し、ある程度の減衰が起きるところで、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り、長期的な意思決定に役立てることができる。また、予測された多期間の CTR をパラメータとして、定められた予算と期間の中で、累積クリック数が最大となるような広告の買付け、および掲載期間を決定する最適化問題に活用することも可能となる。

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とらえることを目指す。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み合わせが存在している。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。

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 (1,200 × 628 pixel)
Text	クリエイティブのテキスト情報

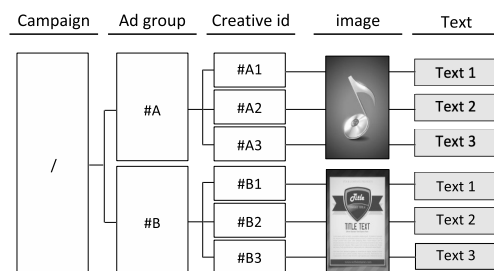


図 3 インフィード広告における構造
Fig. 3 In-feed ad campaign structure.

表 2 Basic 特徴量の例

Table 2 Examples of Basic features.

Features	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
掲載面	ページ上部からの掲載位置
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	曜日およ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

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 について, その配信日を基準とした週 t の CTR を以下で表す.

$$CTR_{l,t} = \frac{k_{l,t}}{n_{l,t}} \quad (4)$$

ここで, $k_{l,t}$ は, 広告クリエイティブ l についての配信日から週 t 初日までの累計クリック回数, $n_{l,t}$ は, 配信日から週 t 初日までの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 $CTR_{l,t}$ を予測する問題を考える.

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], [16] 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 予測へ拡張した 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 に与える影響をとらえることを考える. 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. また, 扱うデータ量にも差が生じやすく, 従来研究 [3] が扱うインプレッション単位の予測タスクは, 広告がユーザに表示される度にデータが蓄積され

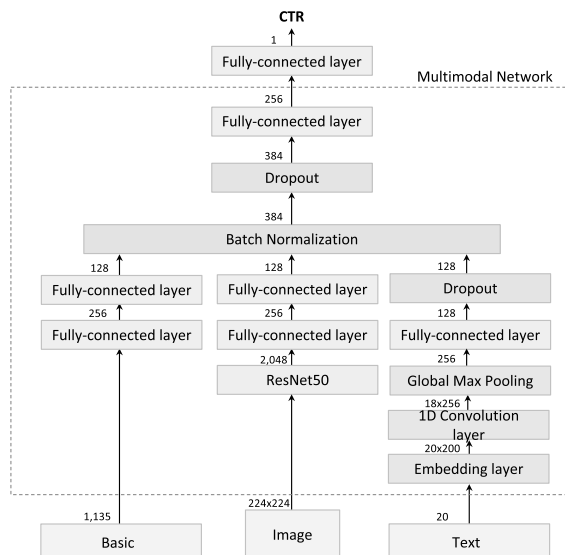


図 4 CTR 予測モデル

Fig. 4 CTR prediction model.

るが, 広告単位の予測タスクは, 広告ごとに 1 レコードの情報となるため, データ量は少なくなる傾向にある. そこで, 広告単位の CTR 予測タスクにおいて, 訓練データでの過学習を避けて, より安定的な学習を目指すため, 従来研究 [3], [16] のネットワーク構造へ新たに Dropout [23] および 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 を加えて過学習の回避を行っている. さらに, 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.

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, $1,200 \times 628$ pixel の画像を元としている. この画像をまず 224×224 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 [7] 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 シークエンスの単語リストへと分割する。また 20 シークエ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 [24] を用いて、分散表現 [25] 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。

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 を独立したものと見なし、それらを同時に予測していることになる。しかし、広告クリエイティブ l の週 t の CTR である $CTR_{l,t}$ は、 $CTR_{l,t-1}$ 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 がそれぞれ一時点の情報であり、出力が複数時点での CTR 情報であることから、Image Captioning [26] のような one-to-many 型ととらえることができる。

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の概要を表 3 に示す。これらは、株式会社 NTT ドコモが保有するアドネットワークに蓄積されたデータで、特定のメディア（広告枠）における広告情報と配信実績である。また、CTR 予測における従来研究 [5] と同様に、インプレッション回数が少なくとも 100 回以上の広告を選択している。インプレッション回数が 100 回に満たないような極端に少ない状態で算出した CTR は、真値と大きく異なる可能性があるという理由で、予測の対象外としている。また、表 3 に記載の期間（2018/10/01–2019/02/20）を通じて、インプレッション回数が 100 回未満の広告の割合はごく僅かであり、除外した場合の広告配信における実効的な影響もほぼないといえる。

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、広告クリエイティブごとの 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 $CTR_{l,t}$

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、訓練データ中にいっさい含まれ

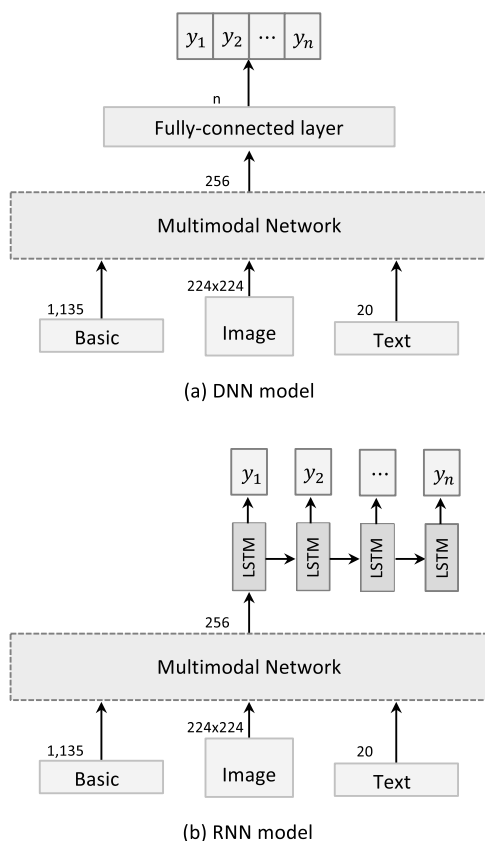


図 5 多期間 CTR 予測モデル

Fig. 5 Multi-period CTR prediction model.

表 3 配信データの概要

Table 3 Dataset summary.

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 ($\times 10^{-5}$)	% Improve
Avg. CTR (Baseline)	3.07	—
Basic	2.29	25.4%
Basic + Image	1.97	35.8%
Basic + Image + Text	1.82	40.7%

ない。また、予測モデルの学習中の評価を行うために、訓練データからランダムに分割してバリデーションデータを作成した。各データセットの量に関して、訓練データ、バリデーションデータ、テストデータの比率はそれぞれ 70%、15%、15%としている。

5.2 CTR 予測の精度評価

5.2.1 マルチモーダル特徴量による効果

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 は、次のように算出している。まず、訓練データ中のすべての広告クリエイティブ l における、全期間 T での CTR の平均値 $\bar{y} = \frac{\sum_l k_l}{\sum_l n_l}$ を算出する。ここで、 k_l および n_l はそれぞれ、広告クリエイティブ l の全期間 T におけるクリック回数とインプレッション回数を示す。次に、この算出された 1 点の値である \bar{y} を、テストデータにおける個々の広告クリエイティブの CTR の予測値として用いる。この Baseline にたいし、特徴量として 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、すべ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 予測を行ううえで、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 [27] を用いて重要度を算出し、上位 50 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、上位 50 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、すべ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の重要度が減少し、代わりに Image 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 といった広告クリエイティブ自体の特徴を反映していることが分かる。

表 5 上位 50 の重要特徴量
Table 5 Top 50 Important features.

Model	主な重要特徴量
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)

表 6 新規広告主の場合の CTR 予測における精度比較
Table 6 Comparison of model accuracy for new clients.

Model	MSE ($\times 10^{-5}$)
Basic	2.69
Basic + Image + Text	2.43

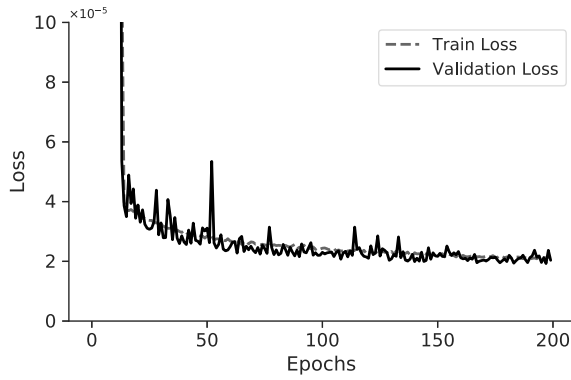
表 7 Dropout および L2 正則化の有無による精度比較
Table 7 Comparison with and without Dropout and L2 normalization.

Model	MSE ($\times 10^{-5}$)
w/ dropout+L2 normalization	1.82
w/o dropout+L2 normalization	3.01

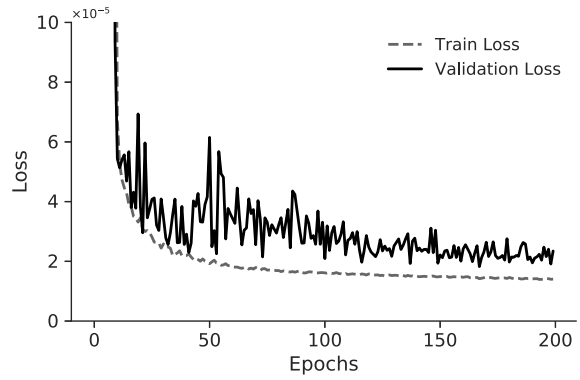
これによる効果として、新規の広告主にたいする CTR 予測精度の向上が考えられる。そこで、表 4 のテストデータのうち、訓練データ中に含まれていない新規の広告主のみに限定した場合で、同様に CTR 予測の精度比較を行った。その結果を表 6 に示す。新規広告主の場合においても、Basic のみのモデルに比べて、すべての特徴量を用いたモデル (Basic + Image + Text) により予測精度が向上できている。なお、新規広告主の場合では、Basic における広告主に関する特徴量は欠損値となっている。また、テストデータにおける新規広告主の割合は、22% 程度を占めている。これらの結果から、新規の広告主にたいしても Image や Text といった広告クリエイティブ自体の特徴を、予測に用いることは有効であるといえる。

5.2.2 ネットワーク構造の改良による効果

4.1 節で述べた Dropout と L2 正則化の追加といったネットワーク構造の改良による CTR 予測の精度評価を表 7 に示す。ここではすべての特徴量 (Basic + Image + Text) を用いており、図 4 で示した提案手法の場合 (w/ dropout+L2 normalization) と、従来手法の場合 (w/o dropout+L2 normalization) との精度比較を行っている。表 7 に示すように、Dropout と L2 正則化の追加といったネットワーク構造の改良によって、CTR 予測の精度が大きく向上していることが分かる。また、それぞれの場合の学習曲線を図 6 に示す。図 6(a) は提案手法の場合、図 6(b) は従来手法の場合の学習曲線であり、横軸は学習のエポック数、縦軸は誤差 (MSE) を表す。また、破線と実線は、それぞれ訓練データとバリデーションデータにおける結果を示している。学習における最適化アルゴリズムは Adam [28] を用い



(a) w/ dropout + L2 normalization



(b) w/o dropout + L2 normalization

図 6 学習曲線

Fig. 6 Learning curves.

表 8 多期間 CTR 予測モデルの精度比較

Table 8 Comparison of model accuracy in multi-period CTR prediction task.

Model	MSE ($\times 10^{-5}$)			
	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 9 Avg. CTR からの MSE 改善率比較

Table 9 Comparison of MSE improvement from Baseline in multi-period CTR prediction task.

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%

ており、学習率は 10^{-5} とした。従来手法では、バリデーションデータと訓練データでの誤差に乖離があり、ハイバリアンスな状態となっているが、提案手法では、バリデーションデータの誤差も順調に減少していることが分かる。このことから、提案手法であるマルチモーダルな特徴量を用いた CTR 予測モデルへの Dropout と L2 正則化の追加によって、過学習を防ぎ、CTR 予測のロバスト性を向上できたといえる。

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 予測を行った。対象とする広告は、累計インプレッション回数が 1,000 回以上のもので選択している。これは、初週における CTR のばらつきを軽減し、CTR の時間的な減衰をより精緻に見るためである。また、1 章の例で述べたように、インプレッション回数が 1,000 回あれば、CTR の真値が 5% の広告について、信頼度 85% で推定値がその 1% 以内に収まっているといえる。

モデル比較のため、訓練データにおける全広告で算出した各期間の平均 CTR を予測値とするモデル (Avg. CTR) の精度も求めた。表 8 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 9 に Avg. CTR モデルからの MSE 改善率を示す。表 8 から、提案手法である

RNN モデルがすべての期間で、最も良い精度であることが分かる。また表 9 から、短期先の予測 (week 1) では、DNN モデルと RNN モデルの改善率の差は 0.6% と限定的であるが、より長期先の予測 (week 4) では、改善率の差が 1.6% になり提案手法による効果が現れ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 モデルでは多期間の CTR を系列データとして学習させているため、CTR の時間変化を効果的にとらえられたためだと考えられる。これより、評価実験で示した 4 週間先、またはそれ以上といった、長期的な広告掲載が見込まれる場合において、どの程度の CTR 減衰が起きるかを、掲載事前に精度良く予測できるという点で、DNN モデルに比べ提案手法に優位性があるといえる。より正確な CTR 予測ができることで、クリックされやすい広告を効果的に選択することが可能になり、クリック数の増加につながるという利点がある。今回、提案手法による 4 週間先の CTR 予測の DNN モデルにたいする精度改善が 1.6% であり、大規模なアドネットワークでよりインプレッション数が多い場面ほど、広告クリックによる送客数は増えていくといえる。

今回の評価実験で使用した広告配信の実績データは、特定のメディア上で掲載された広告であり、また、掲載期間も表 3 に示した特定の期間 (2018/10/01-2019/02/20) であるため、データの選択バイアスを含む可能性がある。しかしながら、広告の内容は他メディアでも掲載されている

一般的なものであり、メディアや季節に依存する広告が占める割合は少なく、その影響は軽微であると考えている。今後、さらに汎用性を高めるためには、複数メディアでの長期間のデータセットを用い、広告の掲載先に関する空間的な特徴量や、季節性・イベントに関する時間的な特徴量を組み入れるといった工夫が考えられる。

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。提案手法の効果を測るために、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 の減衰をとらえることで、意思決定により反映されやすい予測にすることも考えられる。また、CTR の時間減衰を推定したうえで、最適な配信計画を分散最適化問題として求解した場合の効果を明らかにすることが課題としてあげられる。さらに、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 [27] を用いた解析を行い、クリエイティブ自体の改善につなげていくことも考えられる。

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, 株式会社サイバーエージェント (オンライン), 入手先 (<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, *Proc. 24th ACM International Conference on Multimedia*, 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, *Proc. ADKDD'17*, pp.1–6 (2017).
- [5] Richardson, M., Dominowska, E. and Ragno, R.: Predicting clicks: estimating the click-through rate for new ads, *Proc. 16th International Conference on World Wide Web*, pp.521–530 (2007).
- [6] Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K. and Fei-Fei, L.: Imagenet: A large-scale hierarchical image database, *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pp.248–255, IEEE (2009).
- [7] He, K., Zhang, X., Ren, S. and Sun, J.: Deep residual learning for image recognition, *Proc. IEEE Conference on Computer Vision and Pattern Recognition*, pp.770–778 (2016).
- [8] Weinberger, K., Dasgupta, A., Langford, J., Smola, A. and Attenberg, J.: Feature hashing for large scale multi-task learning, *Proc. 26th Annual International Conference on Machine Learning*, pp.1113–1120 (2009).
- [9] Zhang, Y., Dai, H., Xu, C., Feng, J., Wang, T., Bian, J., Wang, B. and Liu, T.-Y.: Sequential click prediction for sponsored search with recurrent neural networks, *28th AAAI Conference on Artificial Intelligence* (2014).
- [10] Mikolov, T., Karafiát, M., Burget, L., Černocký, J. and Khudanpur, S.: Recurrent neural network based language model, *11th Annual Conference of the International Speech Communication Association* (2010).
- [11] Deng, Y., Shen, Y., Jin, H., et al.: Disguise Adversarial Networks for Click-through Rate Prediction, *IJCAI*, pp.1589–1595 (2017).
- [12] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y.: Generative adversarial nets, *Advances in Neural Information Processing Systems*, pp.2672–2680 (2014).
- [13] Chawla, N.V., Bowyer, K.W., Hall, L.O. and Kegelmeyer, W.P.: SMOTE: Synthetic minority over-sampling technique, *Journal of Artificial Intelligence Research*, Vol.16, pp.321–357 (2002).
- [14] Shi, L. and Li, B.: Predict the click-through rate and average cost per click for keywords using machine learning methodologies, *Proc. International Conference on Industrial Engineering and Operations Management Detroit* (2016).
- [15] 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, pp.574–583 (2012).
- [16] 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, 一般社団法人人工知能学会 (2018).
- [17] 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, 一般社団法人人工知能学会 (2018).
- [18] Park, K.-W., Lee, J., Kwon, S., Ha, J.-W., Kim, K.-M. and Zhang, B.-T.: Which Ads to Show? Advertisement Image Assessment with Auxiliary Information via Multi-step Modality Fusion, arXiv preprint arXiv:1910.02358 (2019).
- [19] Devlin, J., Chang, M.-W., Lee, K. and Toutanova, K.: Bert: Pre-training of deep bidirectional transformers for language understanding, arXiv preprint arXiv:1810.04805 (2018).
- [20] Agarwal, D., Chen, B.-C. and Elango, P.: Spatio-temporal models for estimating click-through rate, *Proc. 18th International Conference on World Wide Web*, pp.21–30 (2009).
- [21] Wu, F. and Huberman, B.A.: Novelty and collective attention, *Proc. National Academy of Sciences*, Vol.104, No.45, pp.17599–17601 (2007).
- [22] 株式会社サイバーエージェント: 大量のクリエイティブを自動精査し, インフィード広告の効果最大化に貢献, 株式会社サイバーエージェント (オンライン), 入手先 (<https://www.cyberagent.co.jp/news/detail/id=12643>) (参照 2016-10-04).
- [23] 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, pp.1929–1958 (2014).
- [24] Suzuki, M., Matsuda, K., Sekine, S., Okazaki, N. and

Inui, K.: Neural joint learning for classifying Wikipedia articles into fine-grained named entity types, *Proc. 30th Pacific Asia Conference on Language, Information and Computation: Posters*, pp.535–544 (2016).

- [25] Hinton, G.E.: Distributed representations (1984).
- [26] Vinyals, O., Toshev, A., Bengio, S. and Erhan, D.: Show and tell: A neural image caption generator, *Proc. IEEE Conference on Computer Vision and Pattern Recognition*, pp.3156–3164 (2015).
- [27] Lundberg, S.M. and Lee, S.-I.: A unified approach to interpreting model predictions, *Advances in Neural Information Processing Systems*, pp.4765–4774 (2017).
- [28] Kingma, D.P. and Ba, J.: Adam: A method for stochastic optimization, arXiv preprint arXiv:1412.6980 (2014).



森田 浩

1983年大阪大学工学部卒業。1988年大阪大学大学院工学研究科博士後期課程単位取得退学。大阪府立大学、大阪市立大学、神戸大学を経て、2001年大阪大学。2005年同大学院情報科学研究科教授。現在に至る。オペレーションズ・リサーチ、データ科学等に関する教育研究を行っている。日本オペレーションズ・リサーチ学会、スケジューリング学会、日本品質管理学会、INFORMS等の会員。博士（工学）



出水 宰（正会員）

2011年大阪大学工学部卒業。2013年大阪大学大学院情報科学研究科博士前期課程修了。同年株式会社NTTドコモ入社。2018年10月より大阪大学大学院情報科学研究科博士後期課程に進学。マーケティングにおける予測モデル、数値最適化、深層強化学習に関する研究開発を行っている。日本オペレーションズ・リサーチ学会会員。



深澤 佑介（正会員）

2004年東京大学大学院工学系研究科システム創成学科修士課程修了。同年株式会社NTTドコモ入社。2011年東京大学大学院工学系研究科博士後期課程修了。東京大学人工物工学研究センターにて協力研究員（2011～2016年）および客員研究員（2016～2019年）を兼任。2019年より早稲田大学イノベーション研究所招聘研究員を兼任。現在に至る。Webマイニング、パーソナライゼーション、確率モデルに関する研究開発を行っている。2019年度情報処理学会業績賞受賞。IEEE、人工知能学会各会員。博士（工学）。