

# CVR 予測のためのノンパラメトリック Delayed Feedback モデル

吉川 友也 \*<sup>1</sup>      今井 優作 \*<sup>2</sup>  
Yuya Yoshikawa      Yusaku Imai

\*<sup>1</sup>千葉工業大学 人工知能・ソフトウェア技術研究センター  
STAIR Lab, Chiba Institute of Technology

\*<sup>2</sup>株式会社サイバーエージェント  
CyberAgent, Inc.

Predicting conversion rates (CVRs) in display advertising (e.g., predicting the proportion of users who purchase an item (i.e., a conversion) after its corresponding ad is clicked) is important when measuring the effects of ads shown to users and to understanding the interests of the users. There is generally a time delay (i.e., so-called *delayed feedback*) between the ad click and conversion. In this paper, we propose a nonparametric delayed feedback model for CVR prediction that represents the distribution of the time delay without assuming a parametric distribution, such as an exponential or Weibull distribution. Because the distribution of the time delay is modeled depending on the content of an ad and the features of a user, various shapes of the distribution can be represented potentially. In an experiment on Criteo dataset, we show that the proposed model outperforms the existing method that assumes an exponential distribution for the time delay in terms of conversion rate prediction.

## 1. はじめに

インターネット広告業界において、広告がユーザにクリックされた後、その広告に紐づく商品が購入される割合は、コンバージョン率 (CVR) と呼ばれる。CVR の予測は、表示する広告の効果測定やユーザの興味を理解する上で重要になるため、CVR 予測のためのモデルがここ数年よく研究されている [Lee 12, Ji 17].

コンバージョンのログは、図 1 のようなデータベースとして記録される。基本的に、広告のクリックとコンバージョンの間には、時間遅れ (これを *delayed feedback* と呼ぶ) が発生する。その結果、観測期間の終了までにコンバージョンが起きなかったサンプルのコンバージョン時刻は、'unobserved' とデータベース上に記録される。そして、コンバージョンの時間遅れは数時間から数日に及ぶため、そのようなサンプルの割合は比較的多いことが知られている [Chapelle 14b].

コンバージョン時刻が 'unobserved' と記録されたサンプルを全て負例として扱えば、ロジスティック回帰やニューラルネットワーク等を用いて CVR 予測モデルを学習できる。しかし、これらのサンプルの一部が最終的にコンバージョンする場合、その CVR 予測モデルは誤ったラベルを用いて学習されることになり、結果として精度の低い CVR 予測結果となり得る。したがって、*delayed feedback* を考慮して、'unobserved' となっているサンプルの正負を推定しながら CVR 予測モデルを構築することが不可欠である。

このような背景から、Chapelle は *delayed feedback* による時間遅れが指数分布に従うことを仮定した CVR 予測モデルを提案した [Chapelle 14a]. しかし、[Chapelle 14a] の図 5 で示される通り、時間遅れの実際の分布は指数分布ではなかったり周期的であったりし、サンプルによって分布の形は多様である。したがって、時間遅れに対しては、指数分布やワイブル分布のような決まった形の分布を仮定するのではなく、データに適切な分布を推定できるようにすることが望ましい。

そこで本論文では、時間遅れの分布に対してパラメトリック

ID	Click date	Conversion date	Ad feature 1	...	User feature 1	...
1	2018/01/04 10:12:15	2018/01/12 16:30:02	0.1	...	10.3	...
2	2018/01/05 08:42:33	unobserved	0.3	...	8.4	...
...	...	...	...	...	...	...
n	2018/03/30 22:50:11	unobserved	0.8	...	12.2	...

図 1: コンバージョンログデータベースの一例。各行が 1 つのサンプルに対応し、クリック時刻 (click date)、コンバージョン時刻 (conversion date)、特徴量 (ad features, user features) から成る。もしコンバージョンがその時点までに起きていない場合は、そのサンプルのコンバージョン時刻は 'unobserved' と記録される。

クな分布を仮定しない CVR 予測のためのノンパラメトリック *delayed feedback* モデル (以下、NoDeF) を提案する。NoDeF は、時間遅れの分布を表現するために、カーネル密度推定のアイデアを一部参考としている。より具体的には、時間遅れの分布をコンバージョン時刻と時間軸上の疑似点のカーネルの重み付き和で表現する。ここで、重みはデータから学習されるものである。その上で、NoDeF は各サンプルが最終的にコンバージョンするかどうかを表す潜在変数を持ち、これがコンバージョン時刻が 'unobserved' となったサンプルの正負を推定する役割を果たす。NoDeF のパラメータ推定は EM アルゴリズムに基づいて行う。

実験では、Criteo データセットを用いて、NoDeF が未知のサンプルの CVR を正しく予測できることを示す。

### 1.1 関連研究

NoDeF は、[Chapelle 14a] で提案された *delayed feedback* モデルの拡張である。[Chapelle 14a] のモデルは、時間遅れの分布がサンプルの特徴量によって決定されるパラメータを持つ指数分布に従うと仮定する。その後、[Ji 17] は時間遅れの分布として混合ワイブル分布を用いたり、[Safari 17] はワイブル分布を時間遅れの分布とした場合の効率的なモデルの学習法を構築したりしている。我々が知る限り、本論文の研究は、CVR 予測モデルにおける時間遅れの分布をノンパラメトリックに表現する最初の研究である。

連絡先: 吉川 友也, 千葉工業大学 人工知能・ソフトウェア技術研究センター, yoshikawa@stair.center




図2: NoDeFにおけるハザード関数  $h$ , 重み関数  $\alpha_l$ , カーネル  $k$  の関係. 黄色の点線は各時刻  $t_l$  における  $\alpha_l(\mathbf{x}; \mathbf{V})$  を示し, 薄青色の実線は各時刻  $t_l$  における  $k(t_l, d)$  を示す. また, 紺青色の実線はハザード関数  $h(d; \mathbf{x}, \mathbf{V})$  の値を示す.

## 2. 事前準備: 生存時間分析

本節では, NoDeF を説明するために必要な生存時間分析を簡単に紹介する. 生存時間分析は本来, 生物の死や機械の故障といったイベントが起こるまでの時間を分析するために用いられている [Kleinbaum 12].

イベントが起こった時刻を表す確率変数  $T$  が与えられたとき,  $f(t) = Pr[T = t]$  は  $T$  の確率密度関数,  $F(t) = \int_0^t f(x)dx$  は  $f(t)$  の累積分布関数としてそれぞれ定義する. あるイベントが時刻  $t$  まで起こらない確率は, 生存時間関数  $s(t) = 1 - F(t)$  で与えられる. また, あるイベントが時刻  $t$  まで起こらず, 時刻  $t$  になったとき起きるイベント発生率は, ハザード関数  $h(t)$  として定義される.  $h(t), f(t), s(t)$  の関係は以下のとおりである.

$$h(t) = \frac{f(t)}{s(t)}. \quad (1)$$

さらに, 生存時間関数  $s(t)$  はハザード関数  $h(t)$  を用いて導出でき,

$$s(t) = \exp\left(-\int_0^t h(x)dx\right), \quad (2)$$

となる.

## 3. 提案法

本節では, NoDeF の定式化, パラメータ推定法, CVR の予測法について説明する.

観測データとして,  $n$  個の 4 つ組の集合  $\mathcal{D} = \{(\mathbf{x}_i, y_i, d_i, e_i)\}_{i=1}^n$  が与えられるとする. 具体的には,  $\mathbf{x}_i \in \mathbb{R}^M$  は  $i$  番目のサンプルを表す特徴ベクトル,  $y_i \in \{0, 1\}$  は  $i$  番目のサンプルがコンバージョンしたかどうかを表す二値変数,  $d_i \in [0, \infty]$  は  $i$  番目のサンプルにおけるクリックとコンバージョンの間の時間遅れを表す. ここで, コンバージョンが起きていない場合は,  $d_i = \infty$  となる.  $e_i \in [0, \infty)$  は,  $i$  番目のサンプルにおけるクリックからの経過時間を表す.

### 3.1 Model

NoDeF は, 時間遅れモデルとコンバージョンモデルから構成される. 時間遅れモデルはクリックとコンバージョンの間の時間遅れを捉えるためのモデルであり, コンバージョンモデルは新しいサンプルが与えられたときに CVR を予測するためのモデルである.

NoDeF では, 時間遅れモデルを 2. 節で説明した生存時間分析の枠組みに基づいて定義する. 時間遅れの分布は, 表示される広告の内容やその広告を見るユーザーの特徴により変化すべ

きである. したがって, NoDeF の時間遅れモデルにおいては, 時間遅れの分布に対して指数分布やワイブル分布を仮定せず, また, 分布の形が広告やユーザーの特徴によって決定づけられるように定義する.

まず, NoDeF におけるハザード関数を説明する. ハザード関数を定義するために, NoDeF は  $L \in \mathbb{N}_+$  個の疑似点  $\{t_l \geq 0\}_{l=1}^L$  を時間軸上に等間隔に配置する. その上で, ハザード関数, すなわち,  $i$  番目のサンプルのコンバージョンが時間遅れ  $d_i$  まで起きず,  $d_i$  のその瞬間に起きる割合を, 以下のように定義する.

$$h(d_i; \mathbf{x}_i, \mathbf{V}) = \sum_{l=1}^L \alpha_l(\mathbf{x}_i; \mathbf{V}) k(t_l, d_i), \quad (3)$$

ここで,  $k$  はカーネル関数を表す. 直感的には, カーネル関数の値は時間軸上の 2 点の類似度を表現する. NoDeF で使用できるカーネル関数は,  $t_l, \tau, a \geq 0$  に対して,  $k(t_l, \tau), \int_0^a k(t_l, \tau)d\tau, \int_a^\infty k(t_l, \tau)d\tau$  が解析的に計算できる必要がある. 例えば, バンド幅  $h > 0$  のガウスカーネルは NoDeF で使用可能である. この場合は, 上記 3 つの値は以下の式で得られる.

$$k(t_l, \tau) = \exp\left(-\frac{(t_l - \tau)^2}{2h^2}\right), \quad (4)$$

$$\int_0^a k(t_l, \tau)d\tau = -h\sqrt{\frac{\pi}{2}} \left[ \operatorname{erf}\left(\frac{t_l - a}{\sqrt{2h}}\right) - \operatorname{erf}\left(\frac{t_l}{\sqrt{2h}}\right) \right] \quad (5)$$

$$\int_a^\infty k(t_l, \tau)d\tau = h\sqrt{\frac{\pi}{2}} \left[ 1 + \operatorname{erf}\left(\frac{t_l - a}{\sqrt{2h}}\right) \right]. \quad (6)$$

$\alpha_l$  はパラメータ  $\mathbf{V} \in \mathbb{R}^{L \times M}$  を持つ重み関数で, 時間軸上の  $l$  番目の疑似点  $t_l$  に対するカーネル関数の値を調整するものである. NoDeF では,  $\alpha_l$  を以下のように定義する.

$$\alpha_l(\mathbf{x}_i; \mathbf{V}) = \left(1 + \exp\left(-\mathbf{V}_l^\top \mathbf{x}_i\right)\right)^{-1}. \quad (7)$$

図 2 は, (3) におけるハザード関数  $h$ , 重み関数  $\alpha_l$ , カーネル関数  $k$  の関係を示す.

生存時間関数 (2) の定義と (3) に基づくと, NoDeF における生存時間関数は以下ようになる.

$$s(d_i; \mathbf{x}_i, \mathbf{V}) = \exp\left(-\sum_{l=1}^L \alpha_l(\mathbf{x}_i; \mathbf{V}) \int_0^{d_i} k(t_l, \tau)d\tau\right). \quad (8)$$

次に, [Chapelle 14a] と同様に, コンバージョンまでの経過時間によらず  $i$  番目のサンプルがコンバージョンするかどうかを表す潜在変数  $c_i \in \{0, 1\}$  を考える. もし,  $y_i = 1$ , すなわち,  $i$  番目のサンプルがコンバージョンしたと記録されていれば, 明らかに  $c_i = 1$  となる. その一方で,  $y_i = 0$ , すなわち,  $i$  番目のサンプルが経過時間  $e_i$  までにコンバージョンしなかった場合,  $c_i$  は決定することができない. したがって,  $y_i = 0$  となるサンプルに対しては,  $c_i$  の割り当てを推定する必要がある.

$i$  番目のサンプルにおいて時間遅れ  $d_i$  でコンバージョンが起こる確率を定義する. ハザード関数 (3) と生存時間関数 (8) に基づくと, 上記の確率は以下のように計算できる.

$$p(d_i | \mathbf{x}_i, c_i = 1) = s(d_i; \mathbf{x}_i, \mathbf{V}) h(d_i; \mathbf{x}_i, \mathbf{V}). \quad (9)$$

コンバージョンモデルに関しては, 尤度が微分可能な二値分類器 (例えば, ロジスティック回帰や多層パーセプトロン) を用いることが可能である. 本論文では, 簡単のため, 以下のロジスティック回帰を用いる.

$$p(c_i = 1 | \mathbf{x}_i; \mathbf{w}) = \left(1 + \exp(-\mathbf{w}^\top \mathbf{x}_i)\right)^{-1}, \quad (10)$$

$$p(c_i = 0 | \mathbf{x}_i; \mathbf{w}) = 1 - p(c_i = 1 | \mathbf{x}_i), \quad (11)$$

ここで、 $\mathbf{w} \in \mathbb{R}^M$  はコンバージョン分類器の重みベクトルである。

次に、NoDeF の尤度を定義する。簡便のため、以下の2つの集合を定義する。

$$\mathcal{I}_1 = \{i | y_i = 1, i = 1, 2, \dots, n\}, \quad \mathcal{I}_0 = \{i | y_i = 0, i = 1, 2, \dots, n\}.$$

パラメータ  $\Theta = \{\mathbf{V}, \mathbf{w}\}$  が与えられたとき、観測データ  $\mathcal{D} = \{(\mathbf{x}_i, y_i, d_i, e_i)\}_{i=1}^n$  の尤度は以下のように分解できる。

$$p(\mathcal{D}; \Theta) = \prod_{i=1}^n \sum_{c_i \in \{0,1\}} p(y_i | \mathbf{x}_i, c_i, e_i) p(c_i | \mathbf{x}_i) p(d_i | \mathbf{x}_i, c_i = 1), \quad (12)$$

ここで、 $c_i = 0$  の場合は必ず  $y_i = 0$  となるため、以下の等式は常に成り立つことが分かる。

$$p(y_i = 0 | \mathbf{x}_i, c_i = 0, e_i) = 1, \quad (13)$$

$$p(y_i = 1 | \mathbf{x}_i, c_i = 0, e_i) = 0. \quad (14)$$

したがって、(13) と (14) を尤度 (12) に代入し、サンプル集合を  $\mathcal{I}_1$  と  $\mathcal{I}_0$  に分割することにより、尤度は以下のように変形できる。

$$p(\mathcal{D}; \Theta) = \prod_{i \in \mathcal{I}_1} p(c_i = 1 | \mathbf{x}_i) p(d_i | y_i = 1, \mathbf{x}_i) \quad (15)$$

$$\times \prod_{i \in \mathcal{I}_0} \sum_{c_i \in \{0,1\}} p(y_i = 0 | \mathbf{x}_i, c_i, e_i) p(c_i | \mathbf{x}_i).$$

$p(y_i = 0 | \mathbf{x}_i, c_i = 1, e_i)$  は、 $i$  番目のサンプルが経過時間  $e_i$  までにコンバージョンが起きず、その後コンバージョンが起きる確率であり、この確率は以下のように計算できる。

$$p(y_i = 0 | \mathbf{x}_i, c_i = 1, e_i) \quad (16)$$

$$= p(d_i > e_i | \mathbf{x}_i, c_i = 1, e_i) \quad (17)$$

$$= 1 - \int_0^{e_i} p(d_i = \tau | c_i = 1, \mathbf{x}_i) d\tau \quad (18)$$

$$= s(e_i; \mathbf{x}_i, \mathbf{V}), \quad (19)$$

ここで、(18) から (19) への式変形は、2. 節で説明した  $s(t) = 1 - F(t)$  という関係式を適用することで得られる。

### 3.2 パラメータ推定法

本節では、EM アルゴリズムに基づく NoDeF のパラメータ学習法を説明する。

まず、EM アルゴリズムにおける標準的なやり方で目的関数を定義する。イエンセンの不等式より、対数尤度の下限  $Q(\Theta; \bar{\Theta})$  は以下のように導出できる。

$$\log p(\mathcal{D}; \Theta) \geq Q(\Theta; \bar{\Theta}) \quad (20)$$

$$= \sum_{i \in \mathcal{I}_1} \log [p(c_i = 1 | \mathbf{x}_i) p(d_i | \mathbf{x}_i, c_i = 1)]$$

$$+ \sum_{i \in \mathcal{I}_0} \sum_{c_i \in \{0,1\}} \bar{q}_{ic_i} \log [p(y_i | \mathbf{x}_i, c_i, e_i) p(c_i | \mathbf{x}_i)],$$

ここで、 $\bar{q}_{ic_i}$  は  $c_i$  の事後分布で、以下のように定義される。

$$\bar{q}_{ic} \propto p(y_i = 0 | \mathbf{x}_i, c_i = c, e_i) p(c_i = c | \mathbf{x}_i). \quad (21)$$

もし  $c = 0$  ならば、 $p(y_i = 0 | \mathbf{x}_i, c_i = c, e_i)$  は必ず 1 となる。したがって、

$$\bar{q}_{i0} = p(c_i = 0 | \mathbf{x}_i, y_i = 0, d_i, e_i) \propto p(c_i = 0 | \mathbf{x}_i), \quad (22)$$

となり、これは、(11) を用いて計算可能である。その一方で、 $c = 1$  の場合は、 $c_i$  の事後分布は以下のように計算できる。

$$\bar{q}_{i1} \propto p(c_i = 1 | \mathbf{x}_i) p(y_i = 0 | \mathbf{x}_i, c_i = 1, e_i), \quad (23)$$

ここで、 $p(c_i = 1 | \mathbf{x}_i)$  と  $p(y_i = 0 | \mathbf{x}_i, c_i = 1, e_i)$  は、それぞれ (10) と (16) を用いて計算できる。ここで、(22) と (23) により得られた  $\bar{q}_{ic}$  は、 $\bar{q}_{ic} = \bar{q}_{ic} / (\bar{q}_{i0} + \bar{q}_{i1})$  と正規化する必要があることに注意する。E ステップは、パラメータ  $\Theta$  の現在の推定値の下で、 $c_i$  の事後分布を更新することである。

M ステップでは、 $c_i$  の事後分布を固定して、パラメータ  $\Theta$  を勾配に基づく最適化手法を用いて更新する。本論文では、準ニュートン法における効率的な手法である L-BFGS を使用する。ここで、目的関数 (20) に  $\mathbf{w}$  と  $\mathbf{V}$  に対する  $\ell_2$  正則化項を追加する。正則化の強さは、 $\lambda_{\mathbf{w}}, \lambda_{\mathbf{V}} \geq 0$  の値の大きさを調節する。この正則化は、平均 0、精度  $\lambda_{\mathbf{w}}, \lambda_{\mathbf{V}}$  のガウス事前分布をパラメータに対して置くことと等価である。

まず、 $\mathbf{w}$  の勾配は、以下のように計算できる。

$$\frac{\partial Q(\Theta; \bar{\Theta})}{\partial \mathbf{w}} = \sum_{i \in \mathcal{I}_1} \frac{\partial}{\partial \mathbf{w}} \log p(c_i = 1 | \mathbf{x}_i) \quad (24)$$

$$+ \sum_{i \in \mathcal{I}_0} \sum_{c_i \in \{0,1\}} \bar{q}_{ic} \frac{\partial}{\partial \mathbf{w}} \log p(c_i | \mathbf{x}_i) - \lambda_{\mathbf{w}} \mathbf{w},$$

ここで、

$$\frac{\partial}{\partial \mathbf{w}} \log p(c_i = 1 | \mathbf{x}_i) = \mathbf{x}_i (1 - p(c_i = 1 | \mathbf{x}_i)), \quad (25)$$

$$\frac{\partial}{\partial \mathbf{w}} \log p(c_i = 0 | \mathbf{x}_i) = -\mathbf{x}_i p(c_i = 1 | \mathbf{x}_i), \quad (26)$$

である。次に、 $\mathbf{V}_l$  の勾配は以下のように計算できる。

$$\frac{\partial Q(\Theta; \bar{\Theta})}{\partial \mathbf{V}_l} = \sum_{i \in \mathcal{I}_1} \frac{\partial}{\partial \mathbf{V}_l} \log p(d_i | \mathbf{x}_i, c_i = 1) \quad (27)$$

$$+ \sum_{i \in \mathcal{I}_0} \sum_{c_i \in \{0,1\}} \bar{q}_{ic} \frac{\partial}{\partial \mathbf{V}_l} \log p(y_i = 0 | \mathbf{x}_i, c_i, e_i) - \lambda_{\mathbf{V}} \mathbf{V}_l,$$

ここで、

$$\frac{\partial}{\partial \mathbf{V}_l} \log p(d_i | \mathbf{x}_i, c_i = 1) = \frac{\partial}{\partial \mathbf{V}_l} \log s(d_i; \mathbf{x}_i, \mathbf{V}) + \frac{\partial}{\partial \mathbf{V}_l} \log h(d_i; \mathbf{x}_i, \mathbf{V}), \quad (28)$$

$$\frac{\partial}{\partial \mathbf{V}_l} \log p(y_i = 0 | \mathbf{x}_i, c_i = 1, e_i) = \frac{\partial}{\partial \mathbf{V}_l} \log s(e_i; \mathbf{x}_i, \mathbf{V}), \quad (29)$$

$$\frac{\partial}{\partial \mathbf{V}_l} \log s(d_i; \mathbf{x}_i, \mathbf{V}) = -\mathbf{x}_i \alpha_l(\mathbf{x}; \mathbf{V}) (1 - \alpha_l(\mathbf{x}; \mathbf{V})) \int_0^{d_i} k(t_l, \tau) d\tau, \quad (30)$$

$$\frac{\partial}{\partial \mathbf{V}_l} \log h(d_i; \mathbf{x}_i, \mathbf{V}) = \frac{\mathbf{x}_i \alpha_l(\mathbf{x}; \mathbf{V}) (1 - \alpha_l(\mathbf{x}; \mathbf{V})) k(t_l, d_i)}{h(d_i; \mathbf{x}_i, \mathbf{V})}, \quad (31)$$

である。

EM アルゴリズムでは、目的関数 (20) の値が収束するまで、E ステップと M ステップを交互に繰り返しながらパラメータ  $\Theta$  を推定する。

超パラメータの設定。NoDeF では、疑似点の数  $L$ 、ガウスカネルのバンド幅  $h$ 、精度パラメータ  $\lambda_{\mathbf{w}}, \lambda_{\mathbf{V}}$  が超パラメータである。これらの超パラメータは交差検定法や開発用セットを用いて決定することができる。  $h$  を決定する別の方法として、等間隔に配置された隣接する二つの疑似点の間の長さを利用する方法がある。時間遅れの分布を滑らかな関数として推定するためには、 $h = (t_{i+1} - t_i) / 2$  として  $h$  を決定することを推奨する。この方法は、4. 節の実験で一貫して用いる。

### 3.3 CVR の予測

NoDeF では、新たなサンプルが指定した時刻までにコンバージョンするかどうかの予測が可能である。これは、以下の式を用いて、サンプル  $\mathbf{x}$  が時刻  $E \geq 0$  までにコンバージョンする

表 1: Criteo データセットにおける直近キャンペーンに対する予測性能. 太字は各指標において最も良いスコアを示す.

	Log loss	Accuracy	AUC
NAIVE	0.2818 ± 0.021	0.9124 ± 0.013	0.7187 ± 0.019
DFM	0.3689 ± 0.051	0.9151 ± 0.012	0.7213 ± 0.022
NoDeF	<b>0.2575 ± 0.020</b>	<b>0.9157 ± 0.012</b>	<b>0.7242 ± 0.025</b>

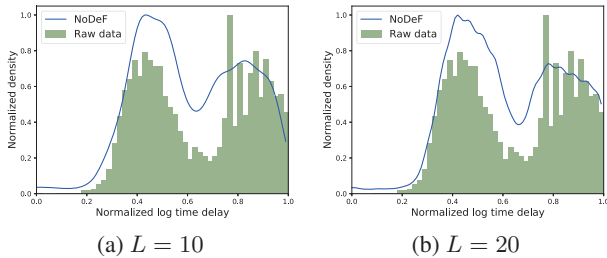


図 3: 異なる  $L$  を設定した NoDeF における推定された時間遅れの分布. その他の超パラメータは,  $\lambda_w = 0.1$ ,  $\lambda_V = 0.1$  と設定した.

確率を求めることで可能である.

$$\begin{aligned}
 p(y = 1 | \mathbf{x}, c = 1, E) &= p(c = 1 | \mathbf{x}) p(d < E | c = 1, \mathbf{x}) \\
 &= p(c = 1 | \mathbf{x}) \int_0^E p(t | c = 1, \mathbf{x}) dt \\
 &= p(c = 1 | \mathbf{x}) (1 - s(E; \mathbf{x}, \mathbf{V})) \quad (32)
 \end{aligned}$$

## 4. 実験

この節では, [Chapelle 14a] で使用されているコンバージョンログデータセットの Criteo データセットを用いて, NoDeF の予測性能を示す.

実験では, [Chapelle 14a] と同様に, 直近のキャンペーンに関するコンバージョンログのみから構成されるデータセットを用いる. まず, このデータセットから, 6つの期間のコンバージョンログを抽出する. その上で, 各期間において, サンプル集合を訓練用, 開発用, テスト用に分割する. 訓練用セットはその期間の最初の3日間にクリックされた 50,000 サンプルであり, その3日間を超えてコンバージョンが起こったサンプルのコンバージョン時刻は 'unobserved' とする. 開発用セットは, その期間の4日目から5日目にクリックされた 10,000 サンプルから構成され, それ以降にコンバージョンが起きたサンプルは負例として扱う. テスト用セットは, その期間の5日目から6日目にクリックされた 10,000 サンプルから構成され, それ以降にコンバージョンが起きたサンプルは負例として扱う.

各サンプルには, 8種類の整数値特徴と9種類のカテゴリカル特徴がある. カテゴリカル特徴量については, one-hot 表現に変換し, 整数値特徴と連結して使用する. この処理により作成される特徴ベクトルは 2,594 次元であるが, 主成分分析を用いて 100 次元に次元圧縮して実験で用いる.

NoDeF では, 各サンプルの遅れ時間や経過時間は, 対数変換した後で正規化して用いる. NoDeF の超パラメータは,  $L \in \{10, 20, 30\}$ ,  $\lambda_w \in \{1.0, 0.1, 0.01\}$ ,  $\lambda_V \in \{1.0, 0.1, 0.01\}$  の範囲でグリッドサーチを行い, 開発用セットで最適な組み合わせを求める. また, ガウスカーネルのバンド幅  $h$  は, 3.2 節の最後に説明した方法を用いて決定する.

比較のために, [Chapelle 14a] で用いられている DFM と NAIVE を用いる. DFM は [Chapelle 14a] の提案手法で, 時間遅れに対して指数分布を仮定して delayed feedback を考慮す

るモデルである. NAIVE はベースライン手法で, コンバージョン時刻が 'unobserved' となっているサンプルを全て負例として扱って学習したロジスティック回帰モデル<sup>\*1</sup>である. DFM と NAIVE の超パラメータは, 開発用セットを用いて決定する. DFM については, 遅れ時間と経過時間を訓練用セットで観測した遅れ時間の最大値で正規化して用いる.

表 1 は, 上記の Criteo データセットにおける予測性能を示す. この表から, 全ての指標において, NoDeF は NAIVE と DFM よりも優れた性能を示すことが分かる.

図 3 は, 異なる  $L$  を設定した NoDeF で推定された時間遅れの分布である. 図を見ると, NoDeF は分布に関する事前知識無しで, 実際のデータに現れる 2つのピークを捉えられていることが分かる. その上で, 異なる  $L$  を設定した場合でも, 推定された分布は滑らかであることが見て取れるため,  $h$  の自動決定が有効であることが示唆される.

## 5. おわりに

本論文では, インターネット広告におけるコンバージョン率 (CVR) 予測のために, ノンパラメトリック delayed feedback モデル (NoDeF) を提案した. 既存の delayed feedback モデルとは異なり, NoDeF は広告クリックからコンバージョンまでの時間遅れの分布をノンパラメトリックに推定可能である. 実験では, Criteo データセットを用いて, NoDeF が既存手法と比較して優れた CVR 予測が可能であることを示した.

## 参考文献

- [Chapelle 14a] Chapelle, O.: Modeling Delayed Feedback in Display Advertising, *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 1097–1105 (2014)
- [Chapelle 14b] Chapelle, O., Manavoglu, E., and Rosales, R.: Simple and Scalable Response Prediction for Display Advertising, *ACM Transactions on Intelligent Systems and Technology*, Vol. 5, No. 4, p. Article 61 (2014)
- [Ji 17] Ji, W., Wang, X., and Zhu, F.: Time-Aware Conversion Prediction, *Frontiers of Computer Science*, Vol. 11, No. 4, pp. 702–716 (2017)
- [Kleinbaum 12] Kleinbaum, D. G. and Klein, M.: *Survival Analysis*, Statistics for Biology and Health, Springer New York, New York, NY (2012)
- [Lee 12] Lee, K.-c., Orten, B., Dasdan, A., and Li, W.: Estimating Conversion Rate in Display Advertising from Past Performance Data, in *Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, p. 768, New York, New York, USA (2012), ACM Press
- [Safari 17] Safari, A., Altman, R. M., and Loughin, T. M.: Display Advertising: Estimating Conversion Probability Efficiently, *arXiv preprint* (2017)

\*1 ロジスティック回帰の実装は Scikit-learn 0.19.0 を用いた.