

# 協調フィルタリングにおけるメタラーニングの適用による疎なデータからの学習と不確実性の推論

## Meta Learning Approach to Collaborative Filtering for Tackling Learning from Sparse Data and Handling Uncertainty

福馬 智生  
Tomoki Fukuma

株式会社 TDAI Lab · 東京大学大学院工学系研究科  
TDAI Lab Co., Ltd. · Department of Systems Innovation, School of Engineering, The University of Tokyo  
fukuma@tdailab.com

鳥海 不二夫  
Fujio Toriumi

東京大学大学院工学系研究科  
Department of Systems Innovation, School of Engineering, The University of Tokyo  
tori@sys.t.u-tokyo.ac.jp

**keywords:** machine learning, recommendation system, meta-learning

### Summary

Latent factor models such as Matrix Factorization have become the default choice for recommender systems due to their performance and scalability. However, such algorithms have two disadvantages. First, these models suffer from data sparsity. Second, they fail to account for model uncertainty. In this paper, we exploit a meta learning strategy to address these problems. The key idea behind our method is to learn predictive distributions conditioned on context sets of arbitrary size of user/item interaction information. Our proposed framework has the advantages of being easy to implement and applicable to any existing latent factor models, providing uncertainty capabilities. We demonstrate the significant superior performance of our model over previous state-of-the-art methods, especially for sparse data in the top-N recommendation task.

## 1. 緒 言

近年情報過多に伴う負担を軽減するために、あらゆる方面での推薦システムの研究が広く行われている。中でも代表的なアプローチとして協調フィルタリング (Collaborative Filtering (CF)) が用いられている [Hu 17, Jiang 17, Wang 18]。協調フィルタリングは過去の履歴のみから学習を行い、推薦するアイテムのコンテンツ情報に非依存といった手軽な点において有用である。

協調フィルタリングの手法として最も広く用いられている手法としては Matrix Factorization (MF) [Koren 09] が挙げられる。MF はユーザーとアイテムをそれぞれ潜在的なベクトルで表現し同一空間上にマッピングを行い、内積といった類似度を図る指標に基づき、ユーザーのアイテムへの嗜好度をモデリングする手法である。その他にも近年提案されている MF の拡張手法として、類似度の計算に Deep Neural Network (DNN) を用いる研究も多数行われている [Deng 19, He 17, Xue 17]。

しかしこれらの手法には二つの欠点が大きく挙げられる。第一に、これら手法は過去の履歴のデータが豊富に利用できる場合には有効だが、高度に疎なデータの場合に性能が極端に減少する。最も疎なデータの事例としては、全く新しいアイテムや全くの新規ユーザーに対して

の推薦といったコールドスタートが挙げられる。そのような場合への対処としてはコンテンツ情報を用いることが一般的だが、それは協調フィルタリングの簡便性を損なう。第二の欠点としては、不確実性のモデリングが挙げられる。深層学習における不確実性のモデリングは近年注目を集めている。現実世界への応用を考える際、予測結果の出力のみではなく、その予測の確信度も含めモデリングすることは安全な自律システムを運用する上で重要である (e.g. 医療診断, 自動運転)。推薦システムにおける不確実性のモデリングには、能動学習への応用といったようなさらなる発展の可能性が挙げられる。能動的かつ適応的にユーザーのアイテムへの趣向を学習していく上で、不確実性のモデリングは探索と活用のバランスを取るといった応用先が考えられる。本研究の研究動機としては、上記二つの問題は互いに関連し合っているという仮説に基づく。推薦システムにおいてとりわけ新規に近いユーザーは識別情報の欠如により不確実性が生じることが知られており [Zhu 18]、そのためより正確な推薦を可能にするために不確実性のモデリングが重要である。

近年の発展としてメタラーニングの派生手法の一つである Neural Processes (NP) を用いて、より省データでの学習や不確実性のモデリングを行う研究が行われている

[Garnelo 18, Kim 19]. NP は確率過程に基づくデータから DNN を用いることで直接予測分布を学習する. 本研究では NP の発想に帰着を得ており, 深層学習を用いた協調フィルタリングの手法と組み合わせることで上記で取り上げた問題の解決を図る. 深層学習を用いた協調フィルタリングの手法の多くは, ネットワークの構造によりいかにユーザーとアイテムの embedding を合成させるかに焦点が置かれており, どのようにしてモデルを学習させるかという点における研究はあまり行われていない.

我々は NP の学習の枠組みを協調フィルタリングに応用した MetaCF という学習方法を提案し, 疎なデータにおける学習の難しさとモデルの出力における不確実性のモデリングを可能にした. 本研究は学習のさせ方に焦点を置いており, その点あらゆる既存の深層学習ベースの手法へ, モデルの機構に実質手を加えることなく応用が可能である. MetaCF は実験的に疎なデータセットにおいて, 推薦システムのタスクの一つである暗黙的フィードバックを用いた Top-N 推薦タスクにおいて, 既存の state-of-the-art の手法に対し大きく上回る有効性を示した. また MetaCF はとりわけ過去履歴の少ないユーザー, もしくはアイテムに対し, 高い不確実性を示し, またそれらが最終的な推薦タスクのスコアに貢献していることを示した.

本研究のまとめとして, 主な貢献は以下である.

- NP の学習の枠組みを推薦システムに拡張し, 疎なデータでも効率的にまた不確実性を持って学習を行う MetaCF という学習方法を提案した.
- 近年提案された CFNet[Deng 19] に MetaCF を適応した MetaCFNet というネットワークを提案した. top-N 推薦のタスクにおいて, 4 つのデータセットにおいて優れた結果を出し, とりわけ疎なデータセットにおいては極めて大きな性能の向上を示した.
- 実験的に過去履歴の少ないユーザーやアイテムに対する推論には高い不確実性を持って出力を示していることを確認し, またそれらが最終的なベンチマークにおけるスコアの向上に貢献していることを確認した.

以下の構成は, まず関連研究について述べる. 続いて表記や背景知識について, その後提案手法である MetaCF について述べる. 最後にデータセットを用いた実験の結果について述べ, 考察を行う.

## 2. 関連研究

### 2.1 推薦システムにおける手法と課題設定

協調フィルタリングはあらゆる推薦システムにおいて広く適用されている. 中でも MF は基本的ではあるものの効果的な手法である. 近年の研究では DNN を用いることで従来のモデルの性能が向上することが知られている. 例えば [Sedhain 15] では AutoEncoder を協調フィ

ルタリングに応用している. また DeepMF[Xue 17] は MF に DNN を適応させており, 加えて NCF[He 17] は generalized matrix factorization model (GMF) と多層パーセプトロン (MLP) の二つの機構を組み合わせた機構を持っている. CFNet[Deng 19] はユーザーとアイテムの embedding のマッチングを複雑な非線形性を考慮した部分と, 低ランクのマッチングを行う部分とに明示的にネットワークを分けて学習を行っている.

しかしながらこれらモデルは明示的に不確実性を考慮しているモデルではない. GeRec[Jiang 19] は Gaussian Embedding[Dos Santos 17] を用いてユーザーとアイテムの embedding を固定のベクトルではなく, 密度で表現することで不確実性をモデリングしている. しかし同手法は出力に不確実性を持たせる場合には embedding からのサンプリングを行う必要があり, すなわちモデルの出力に直接不確実性を持たせている手法ではない.

Netflix Prize[Bennett 07] に端を発し, 協調フィルタリングの初期の研究はユーザーの付与した星の数といった明示的なフィードバックに着目し, 回帰タスク (rating prediction) として定式化されていた. しかし近年の研究により, 同タスクで高性能なモデルであっても, ユーザーの趣向の高さ順にアイテムを並び替えて推薦する Top-N 推薦タスクでは必ずしも良い性能を示さないということが明らかになり [Cremonesi 10], よりランキングタスクでの評価を呼びかける機運が高まっている. また [Rendle 19] によると, 単純な Bayesian MF[Salakhutdinov 08] などのベースラインモデルを注意深くチューニングした結果, 近年提案されたモデルのいずれもそのスコアを超えることができなかったと報告され, rating prediction における評価の難しさが近年挙げられている. 本研究ではこれらの流れを踏まえ, Top-N 推薦タスクでの評価を用いた有効性の検証を行った.

### 2.2 メタラーニングと Neural Processes

大規模なデータセットにおける機械学習の性能の向上の傍ら, より少ないデータからの効率的な学習の需要が高まっている. メタラーニングは近年提唱された, いかにして新しいタスクに省データですぐに対応できるかを解くための複数タスクでの学習を行う枠組みである. 代表的な手法である MAML[Finn 17] は数回の勾配降下ステップによって新しいタスクに適応するような初期パラメータを複数データセットより学習する.

メタラーニングを推薦システムに応用した研究は過去にも存在し, [Vartak 17] では Twitter や Facebook における新規投稿をコールドスタート問題として捉えメタラーニングの枠組みを適応している. また [Chen 18] はメタ連合学習 (federated meta learning) の枠組みを用いて分散学習とプライバシー保護の観点から提案を行っている.

近年のメタラーニング研究は学習アルゴリズムの最適化に焦点が当てられている中, NP は階層ベイズと確率

過程の観点からメタラーニングを捉え直した手法である [Garnelo 18]. 通常のノンパラメトリックなベイジアン手法では単純な事前確率を仮定し、事後分布の追跡を行うが、NP は代わりにニューラルネットを用いることで直接確率過程に基づくデータから予測分布の学習を行う。この手法によってデータから複数の関数の生成や出力における分散のモデリングが可能になる。NP は few-shot 分類・回帰や画像補完などへの適用が行われている [Garnelo 18, Kim 19]. 本研究は省データからの学習のみならず不確実性の考慮という点において、メタラーニングを推薦システムに応用した先行研究とは一線を画す。

### 3. Top-N 推 薦

最初に暗黙的フィードバックにおける Top-N 推薦の定式化を行う。次に本研究への関連性を明確にするために NP の要点を説明する。

#### 3.1 背 景 知 識

先行研究 [He 17] の設定に基づき、M 人のユーザーと N 個のアイテムからインタラクション行列  $\mathbf{Y} \in \mathbb{R}^{M \times N}$  をユーザーの暗黙的フィードバック、例えばクリックや視聴、収集、購買の履歴から構築する。

$$y_{ui} = \begin{cases} 1, & \text{フィードバックが観測された場合} \\ 0, & \text{それ以外} \end{cases} \quad (1)$$

$y_{ui} = 1$  は、ユーザーからアイテムへの暗黙的フィードバックが観測されたことを意味する。暗黙的フィードバックを用いた推薦は、 $\mathbf{Y}$  における未観測の要素の値を推定し、アイテムのランキングに用いることで定式化される。

上記の問題設定は One-Class Collaborative Filtering (OCCF) 問題として知られており、本研究では [Hu 08, Pan 08] らのアプローチに則る。すなわち観測されていないユーザーアイテムの組み合わせの一部をサンプリング (negative sampling) し、二値分類として定式化する。しかしただ分類問題を解くだけではランキング化が行えず、各  $y_{ui}$  にベルヌーイ分布を仮定し、確率的にモデリングすることでその尤度を元にランキングを構築する。

$$P(y_{ui} = k | p_{ui}) = \begin{cases} 1 - p_{ui}, & k = 0 \\ p_{ui}, & k = 1 \end{cases} \quad (2)$$

$$= p_{ui}^k (1 - p_{ui})^{1-k}$$

$p_{ui}$  は  $y_{ui} = 1$  となる確率を意味する。そのため  $p_{ui}$  は同時にどれだけ  $u$  が  $i$  とマッチするかの確信度としても解釈することができる。言い換えると  $p_{ui}$  が 1 に近いということは完璧に  $u$  が  $i$  を高い確信度でマッチすると予測しており、また 0.5 は最もモデルの推論として確信を持っていないと解釈できる。

#### 3.2 Neural Processes

NP は few-shot 学習などを行うメタラーニングの手法の一つである。通常の教師あり学習との相違点として、Gaussian Processes [Rasmussen 06] と類似するように確信度に基づく分布を出力に持つ。データ数を  $N$  とした際、Gaussian Process は計算時間はオーダー  $\mathcal{O}(N^3)$  であるのに対し、NP は  $\mathcal{O}(N)$  という点で大規模データに対してスケーラブルな点で優れた手法と言える。

未知の確率過程  $f: \mathcal{X} \rightarrow \mathcal{Y}$  由来のいくつかの観測が与えられた際、NP は条件付き表現  $\mathbf{r}$  に基づき  $f$  の未観測の値を推論するように学習を行う。定式化すると  $\mathbf{x}_i \in \mathcal{X}$ ,  $\mathbf{y}_i \in \mathcal{Y}$  における  $(\mathbf{x}_i, \mathbf{y}_i)$  を  $f$  のそれぞれの関数に対して二つの集合に分割する、つまり  $n$  個データが観測された際、 $m$  個の文脈データ  $C = (\mathbf{x}_i, \mathbf{y}_i)_{i=1}^m$  と  $n - m$  個の目標データ  $T = (\mathbf{x}_j, \mathbf{y}_j)_{j=m+1}^n$  に分けられる。これらデータは以下のように処理される。

$$\mathbf{r}_i = h_\theta(\mathbf{x}_i, \mathbf{y}_i), \quad \forall (\mathbf{x}_i, \mathbf{y}_i) \in C \quad (3)$$

$$\mathbf{r} = \mathbf{r}_1 \oplus \mathbf{r}_2 \oplus \dots \oplus \mathbf{r}_{m-1} \oplus \mathbf{r}_m \quad (4)$$

$$\phi_j = g_\theta(\mathbf{x}_j, \mathbf{r}), \quad \forall (\mathbf{x}_j) \in T \quad (5)$$

最初にエンコーダー  $h_\theta$  を用いてすべての文脈データ  $(\mathbf{x}_i, \mathbf{y}_i)$  の集合を条件付き表現  $\mathbf{r}_i$  に変換を行う ( $h_\theta: \mathcal{X} \times \mathcal{Y} \rightarrow \mathbb{R}^d$ )。続いて  $\mathbf{r}_i$  を順列非依存な集約計算 (平均や和) などを用いて固定長な表現である  $\mathbf{r}$  へ集約を行う。最終的にデコーダー  $g_\theta$  を用いて予測分布の推論を目標点  $\mathbf{x}_i \in T$  に対して行う ( $g_\theta: \mathcal{X} \times \mathbb{R}^d \rightarrow \mathbb{R}^e$ )。回帰タスクにおいては  $\phi_i$  は正規分布  $\mathcal{N}(\mu_i, \sigma_i^2)$  における平均と分散  $\phi_i = (\mu_i, \sigma_i^2)$  をモデリングし、また分類タスクにおいて  $\phi_i$  はカテゴリカル分布におけるクラス  $c$  における生起確率  $p_c$  をモデリングする。目的関数としては条件付き対数尤度の最大化を行う。

### 4. 提 案 手 法

本章ではまず全体的な提案手法の枠組みについて、続いて提案手法を適応させるネットワークの機構について説明を行う。

#### 4.1 全 体 の 流 れ

ユーザーとアイテムのインタラクション行列は確率過程に基づいた一部の観測結果とみなすことができる。なぜならインタラクション行列  $\mathbf{Y}$  における  $y_{ui} = 0$  は必ずしも  $u$  が  $i$  のことを好んでいないだけでなく、ただ気づいていないだけかもしれないという、真の状態の一部のみを確率的に観測したデータであるためである。NP に則り、提案手法の主なアイデアは観測された点のうち確率的にサンプリングした任意の数の点を用い、予測分布を学習させることにある。

行列における未観測の要素の予測というタスクは先行研究の NP を画像補完タスクに応用した事例に近い部分がある [Kim 19]. 同研究では文脈データの候補として任意の要素を用いていたが、本研究では推論を行う目的の点  $y_{ui}$  に対して、対応する同行・同列における観測されている点のみを文脈データの候補として用いる点において異なる。これは目的の点における出力をモデリングする際、行も列も異なる点の情報よりも同一行・列内の情報との依存性が他の任意の点に比べ大きいと考えたためであり、この考え方は MF といった一般的な協調フィルタリングの手法とも考え方が共通している。

定式化すると以下  $\mathbf{y}_{u*}$  を  $\mathbf{Y}$  におけるユーザー  $u$  と対応する行ベクトルとし、 $\mathbf{y}_{*i}$  をアイテム  $i$  と対応する列ベクトルとする。続いて各学習のイテレーションごとにランダムに目的とする  $y_{ui}$  に対し、 $\mathbf{y}_{u*}$  と  $\mathbf{y}_{*i}$  のうち観測された点を確率的に任意の数サンプリングし、文脈点として用いる。本研究ではこの過程のことを MetaCF サンプリングと呼ぶこととする。これは NP におけるランダムに文脈点を選ぶ過程と動機を共有する。直感的には同ユーザーは過去の履歴のうち一部が欠けていたとしても同様のフィードバックを行っていたであろうとみなすことができる。MetaCF サンプリングは以下のように記述される：

$$p_u \sim \text{Uniform}(0, 1) \quad (6)$$

$$\mathbf{m}_{u*} \sim \text{Bernoulli}(p_u) \quad (7)$$

$$\mathbf{y}'_{u*} = \mathbf{m}_{u*} \odot \mathbf{y}_{u*} \quad (8)$$

ここでの  $\odot$  は要素積を意味する。 $\mathbf{m}_{u*}$  はそれぞれ独立なベルヌーイ分布からサンプリングされた 0 か 1 を持つマスキングのためのベクトルであり、同ベルヌーイ分布のパラメータ  $p_u$  は  $[0, 1]$  の一様分布からサンプリングされる。 $\mathbf{m}_{u*}$  は対応する行  $\mathbf{y}_{u*}$  との要素積を行い、 $\mathbf{y}'_{u*}$  を計算する。本過程は各学習ステップごとに行われ、アイテム  $i$  の列についても対応する列  $\mathbf{y}_{*i}$  と同様の計算を行い、MetaCF サンプリング後の列  $\mathbf{y}'_{*i}$  を計算する。本提案手法は Dropout [Srivastava 14] と類似しているが、Dropout は学習時の  $p_u$  などと対応するノードを落とす割合が事前に固定であり、出力に同割合の逆数でスケールアップさせるのに対し、本手法ではノードの落とす割合も変動し、スケールアップも行わない点において異なる。

これら  $\mathbf{y}'_{u*}$  と  $\mathbf{y}'_{*i}$  はニューラルネットワークを用いて以下のように処理される：

$$\mathbf{r}_u = h_\theta^U(\mathbf{y}'_{u*}) \quad (9)$$

$$\mathbf{r}_i = h_\theta^I(\mathbf{y}'_{*i}) \quad (10)$$

$$\phi_{ui} = g_\theta(\mathbf{r}_u, \mathbf{r}_i) \quad (11)$$

最初にエンコーダー  $h_\theta^U$  を用いて  $\mathbf{y}_{u*}$  を変換しユーザーの潜在表現  $\mathbf{r}_u$  を得る。そしてエンコーダー  $h_\theta^I$  を用いて

$\mathbf{y}_{*i}$  を変換しアイテムの潜在表現  $\mathbf{r}_i$  を得る。この過程は文脈データを潜在変数としてベクトル空間に埋め込み、固定次元への圧縮を行っている。すなわち NP における条件付きの潜在表現を得る式 (3) と固定次元への集約を同時に行っている点において式 (4) と対応している。その後デコーダー  $g_\theta$  は  $\mathbf{r}_u$  と  $\mathbf{r}_i$  を入力とし式 (2) に示す出力を行う。本研究の問題設定ではベルヌーイ分布のパラメータを出力し、対数尤度の最大化を目的関数に学習を行う。このようにして MetaCF の学習の枠組みで学習するモデルは NP の枠組みに基づき出力に予測の分布を仮定した形で学習を行うことができる。

ネットワークの出力  $\phi$  はタスクに基づいて選択される。本研究では Top-N 推薦タスクのため  $\phi_{ui}$  は式 (2) における  $p_{ui}$  を出力する。また rating prediction を解く場合は  $\phi_{ui}$  は正規分布  $\mathcal{N}(\mu_{ui}, \sigma_{ui}^2)$  の平均と分散  $\phi_{ui} = (\mu_{ui}, \sigma_{ui}^2)$  を出力する。もしくは多腕バンディット問題のように多クラス分類を扱う場合  $\phi_{ui}$  はカテゴリカル分布の各クラス  $c$  の生起確率  $p_c$  と対応する。以上これら MetaCF サンプリングと出力のモデリングを合わせて、提案手法を MetaCF と呼称する。MetaCF は Keras [Chollet 15] を用いて数行での実装が行える点と従来の深層学習ベースの協調フィルタリングモデルのうちネットワーク機構を変えることなく実装できるという点において利便性が高い。

## 4.2 ネットワーク機構

本研究での提案手法である MetaCF はネットワークの構造に依存しないため、ここではその有効性の検証として従来手法の CFNet に適応させることで有効性を確認する。従来の深層学習を用いた協調フィルタリングの手法は大きく 2 種類の大別される。一つ目は表現学習 (representation learning) に重きを置いたもの、二つ目はマッチング学習 (matching learning) に重きを置いたものである。CFNet はその両方の機構を採用した形をしており、複雑なユーザーとアイテムの合成を行う関数や低ランクな関係をモデリングする。本章では本研究で用いた実装について述べる。また CFNet を MetaCF の枠組みで学習させたネットワークを MetaCFNet と呼ぶこととし、全体の構造について図 1 に示す。

### §1 表現学習 (Representation Learning)

表現学習は DNN を用いて複雑な関数を近似しユーザーとアイテムの embedding を同一空間に写像し、直接同空間内での類似度を図ることで推論を行うことを目的とする。本研究では多層パーセプトロン (MLP) を用いてユーザーアイテムそれぞれの表現を学習する。同学習手法は以下のように定義される：

$$\mathbf{p}_u = \mathbf{P}^T \mathbf{y}'_{u*} \quad (12)$$

$$\mathbf{q}_i = \mathbf{Q}^T \mathbf{y}'_{*i} \quad (13)$$

$$\mathbf{r}_u = \text{MLP}_u(\mathbf{p}_u) \quad (14)$$

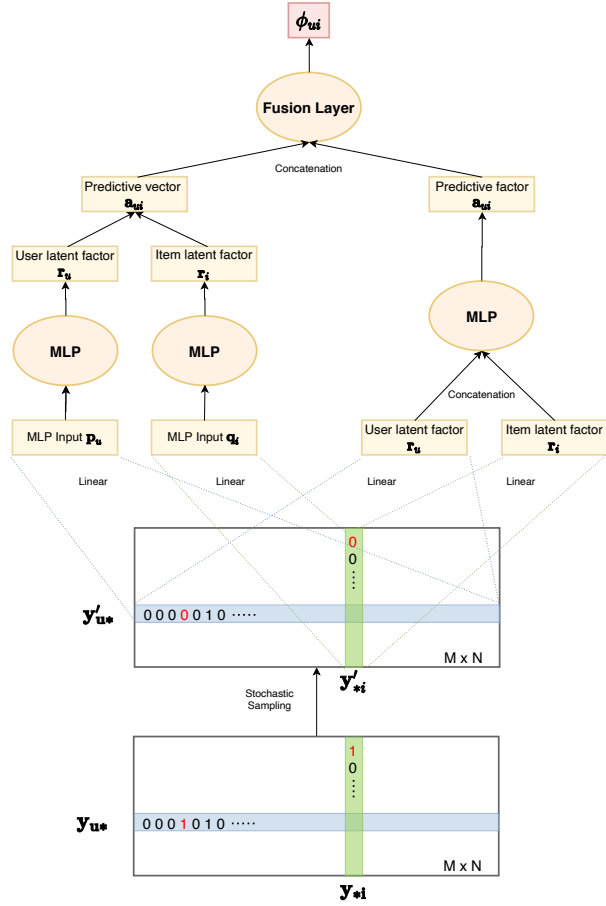


図1: MetaCFNet の構造

$$\mathbf{r}_i = \text{MLP}_i(\mathbf{q}_i) \quad (15)$$

$$\mathbf{a}_{ui} = \mathbf{r}_u \odot \mathbf{r}_i \quad (16)$$

$$\phi_{ui} = \sigma(\mathbf{W}_{out}^T \mathbf{a}_{ui}) \quad (17)$$

$\mathbf{P}$  と  $\mathbf{Q}$  はインタラクション行列の行・列から embedding を得るための線形変換のパラメータを表す ( $\mathbf{P}: \mathbb{R}^M \rightarrow \mathbb{R}^{M'}, \mathbf{Q}: \mathbb{R}^N \rightarrow \mathbb{R}^{N'}$ ).  $\text{MLP}_u(*)$  と  $\text{MLP}_i(*)$  は MLP を用いた写像を意味する ( $\text{MLP}_u: \mathbb{R}^{M'} \rightarrow \mathbb{R}^d, \text{MLP}_i: \mathbb{R}^{N'} \rightarrow \mathbb{R}^d$ ).  $\text{MLP}_u(*)$  と  $\text{MLP}_i(*)$ . 類似度計算にノンパラメトリックな内積を用いることでモデルは低ランクな関係を学習する. 本研究で提案手法 MetaCF と組み合わせた表現学習のネットワークを MetaCF-rl と以下では呼称する.

## §2 マッチング学習 (Matching Learning)

マッチング学習では DNN の非線形性を活用し、ユーザーとアイテムの表現の合成を複雑な関数で近似することで推論を行う. 本研究では MLP を用いて関数の近似を行い、以下のように定式化される:

$$\mathbf{r}_u = \mathbf{P}^T \mathbf{y}'_{u*} \quad (18)$$

$$\mathbf{r}_i = \mathbf{Q}^T \mathbf{y}'_{*i} \quad (19)$$

$$\mathbf{a}_{ui} = \text{MLP}\left(\begin{bmatrix} \mathbf{r}_u \\ \mathbf{r}_i \end{bmatrix}\right) \quad (20)$$

$$\phi_{ui} = \sigma(\mathbf{W}_{out}^T \mathbf{a}_{ui}) \quad (21)$$

潜在表現  $\mathbf{r}_u$  と  $\mathbf{r}_i$  は連結させることで集約を行い, MLP を用いて推論を行う. 本研究で提案手法 MetaCF と組み合わせたマッチング学習のネットワークを MetaCF-ml と以下では呼称する.

## §3 フュージョンレイヤー

先二つで提唱したモデルによって得られた表現  $\mathbf{a}_{ui}$  を組み合わせることで両者の利点を生かした表現が学習される. 二つの表現を連結させ全結合層へと入力することで最終的な予測を行う.  $\mathbf{a}_Y^{rl}$  と  $\mathbf{a}_Y^{ml}$  をそれぞれ表現学習由来の表現とマッチング学習由来の表現とみなした場合, 以下のように定式化される:

$$\phi_{ui} = \sigma\left(\mathbf{W}_{out}^T \begin{bmatrix} \mathbf{a}_{ui}^{rl} \\ \mathbf{a}_{ui}^{ml} \end{bmatrix}\right) \quad (22)$$

式 (22) を用いることで, MetaCF-rl と MetaCF-ml を組み合わせ最終的な提案ネットワーク機構 MetaCFNet となる.

## 5. 実験

本章では下記のリサーチクエスション (RQ) に答える形で実験を行う:

### §1 RQ1.

ネットワークの様々な学習設定のうち重要なのはどこか?

### §2 RQ2.

提案手法は暗黙的フィードバックにおける Top-N 推薦において既存の state-of-the-art の手法を上回るか?

### §3 RQ3.

提案手法は不確実性を扱っており, 推薦の性能の向上に寄与できているか?

## 5.1 実験設定

### §1 データセット

検証には一般公開されている 4 つのデータセットを用いる: MovieLens 1M (ml-1m)\*<sup>1</sup>, LastFM (lastfm)\*<sup>2</sup>, Amazon music (AMusic)\*<sup>3</sup>, and Amazon toys (AToy)\*<sup>3</sup>. ml-1m と lastfm は 1 ユーザーあたり最低 20 個の履歴があるユーザーのみが含まれるように事前に加工され公開されている. 一方 AMusic では 59% のユーザーが, AToy では 49% のユーザーが 20 より少ない履歴しかもっていない. そのような点で後者二つはより疎なデータセットであるといえる. それぞれの統計情報について表 1 に載せる.

\*1 <https://grouplens.org/datasets/movielens/>

\*2 <http://www.dtic.upf.edu/~ocelma/MusicRecommendationDataset/>

\*3 <http://jmcauley.ucsd.edu/data/amazon/>

表 1: データセットの統計情報

統計量	ml-1m	lastfm	AMusic	AToy
ユーザー数	6040	1741	1776	3137
アイテム数	3706	2665	12929	33953
評価数	1000209	69149	46087	84642
スパース度	0.9553	0.9851	0.9980	0.9992

## §2 評価

先行研究 [Deng 19, He 17] に則り, leave-one-out 評価を行う; 全部のアイテムでのランキング評価は時間的コストがとて大きいので, ユーザーごとに最新のインタラクションしたアイテム  $r_{\text{test}}(u, i)$  とランダムに選択した観測されていないアイテム 100 件を用いランキングを構築する.

ランキングの評価には二つの代表的な指標 Hit Ratio (HR) と Normalized Discounted Cumulative Gain (NDCG) [Järvelin 02] を用いる.

$$HR@k = \begin{cases} 1, & \text{if } r_{\text{test}}(u, i) \in R_k \\ 0, & \text{otherwise} \end{cases} \quad (23)$$

$$NDCG@k = \frac{DCG@k}{IDCG@k} = \sum_{j=1}^k \frac{2^{r(u,j)} - 1}{\log(i+1)} \quad (24)$$

$R_k$  は確信度に基づく上位  $k$  件のリストである. また  $r(u, j)$  は  $j$  番目の推薦アイテムが  $r_{\text{test}}(u, i)$  と一致する場合 1, それ以外は 0 を表す.

直感的に HR は上位  $k$  番目までにインタラクションしたアイテムが存在するか, NDCG はどれだけその中でも上位にあるかを示した指標である. 先行研究 [Deng 19] に則り, 両指標における評価は上位 10 件で評価を行う.

## §3 学習

モデルの最適化には Adam [Kingma 14] を用いたミニバッチ学習で行う. バッチサイズは 256 に, 学習率は 0.001 に固定した. モデルのパラメータは平均 0, 分散 0.01 の正規分布からのサンプリングで初期化を行った. negative sampling の数は 4 とし, 毎エポックごとに更新する. 検証用データにはユーザー毎にランダムに 1 件のインタラクションを用い, エポック数のハイパーパラメータチューニングを行った.

## 5.2 事前学習

先行研究より学習済みのモデルの重みを用いて初期化を行うことで最終的なスコアの向上と収束が早くなることが知られている [Deng 19, He 17]. 本研究では事前学習した MetaCF-rl と MetaCF-ml を用いて MetaCFNet の重みの初期化を行った. MetaCF-rl と MetaCF-ml は Adam を用いて未学習の状態から学習を行い, MetaCFNet は確率的勾配降下法 (SGD) を用いて最適化を行った. Adam

表 2: 事前学習の有無に伴う MetaCFNet の性能比較.

Datasets	Without pre-training		With pre-training	
	HR	NDCG	HR	NDCG
ml-1m	0.6033	0.3474	0.7280	0.4353
lastfm	0.7025	0.4306	0.8949	0.6074
AMusic	0.2302	0.1193	0.5557	0.3083
AToy	0.3009	0.1614	0.6063	0.3405

は以前のモメンタムといった情報が必要になってしまうため事前学習後には用いなかった.

## 5.3 比較手法

比較手法は以下である.

- **CFNet-rl** [Deng 19] は表現学習の機構を用いた手法である. MetaCF-rl とネットワークの機構は同じであり, 唯一の違いは MetaCF の枠組みの下で学習させたか否かである.
- **CFNet-ml** [Deng 19] はマッチング学習の機構を用いた手法である. MetaCF-ml とネットワークの機構は同じであり, 唯一の違いは MetaCF の枠組みの下で学習させたか否かである.
- **CFNet** [Deng 19] は CFNet-rl と CFNet-ml の機構を組み合わせた state-of-the-art の手法である. MetaCFNet とネットワークの機構は同じであり, 唯一の違いは MetaCF の枠組みの下で学習させたか否かである.

## 5.4 実験結果

### §1 学習機構による感度性

まず最初に RQ1 に答える形で以下 3 つの設定に対する性能の変化を確認する. 第一に事前学習の有無, 第二に MetaCF サンプリングをユーザーのみアイテムのみもしくは両方から行った場合, 第三に表現学習とマッチング学習の比較について行う.

最初に MetaCFNet における事前学習の有無を比較した結果を表 2 に載せる. 事前学習を行った MetaCFNet はしなかった場合に比べて大きな性能の向上を果たした. しかし事前学習を行わなかった MetaCFNet は後述の MetaCF-rl と MetaCF-ml よりも結果が悪くなった. このことより事前学習が有効であるということだけでなく, ネットワークの機構によっては MetaCF サンプリングの効果にばらつきがあることが確認された. 考察としては MetaCFNet は二股構造をしており, より明示的に条件付き表現  $\mathbf{r}$  を学習させる機構の方が望ましかった可能性がある.

第二に MetaCF サンプリングをユーザーのみから行った場合, アイテムのみから行った場合, 両方から行った場合を比較してどれが最終的な結果に貢献したかを確認する. 結果を表 3 に載せる. 結果として両方から行った場合が最も結果が良くなりやすく, ユーザーからのみ行っ

表 3: 学習機構と MetaCF サンプルングに基づく HR@10 の結果. 各行ごとに最大性能を太字で表す.

Datasets	Models	MetaCF Sampling		
		Users	Items	Both
ml-1m	MetaCF-rl	<b>0.5692</b>	0.5510	0.5374
	MetaCF-ml	<b>0.7179</b>	0.6995	0.7142
	MetaCFNet	0.7206	0.7005	<b>0.7280</b>
lastfm	MetaCF-rl	<b>0.8569</b>	0.8530	0.8507
	MetaCF-ml	0.8845	0.8736	<b>0.8926</b>
	MetaCFNet	0.8943	0.8845	<b>0.8949</b>
AMusic	MetaCF-rl	0.4865	0.3778	<b>0.5051</b>
	MetaCF-ml	0.5462	0.4144	<b>0.5456</b>
	MetaCFNet	0.5546	0.4245	<b>0.5557</b>
AToy	MetaCF-rl	0.5202	0.3522	<b>0.5413</b>
	MetaCF-ml	0.5757	0.3828	<b>0.6025</b>
	MetaCFNet	0.5990	0.3848	<b>0.6063</b>

表 4: 学習機構と MetaCF サンプルングに基づく NDCG@10 の結果. 各行ごとに最大性能を太字で表す.

Datasets	Models	MetaCF Sampling		
		Users	Items	Both
ml-1m	MetaCF-rl	<b>0.3155</b>	0.3062	0.2967
	MetaCF-ml	<b>0.4340</b>	0.4260	0.4311
	MetaCFNet	<b>0.4390</b>	0.4190	0.4353
lastfm	MetaCF-rl	0.5579	<b>0.5667</b>	0.5629
	MetaCF-ml	0.5994	0.5827	<b>0.6047</b>
	MetaCFNet	0.5996	0.5952	<b>0.6074</b>
AMusic	MetaCF-rl	0.2691	0.2310	<b>0.2753</b>
	MetaCF-ml	0.3022	0.2561	<b>0.3027</b>
	MetaCFNet	0.3049	0.2673	<b>0.3083</b>
AToy	MetaCF-rl	0.2885	0.2063	<b>0.2988</b>
	MetaCF-ml	0.3182	0.2343	<b>0.3346</b>
	MetaCFNet	0.3343	0.2482	<b>0.3405</b>

た場合がアイテムからのみ行うよりも効果的であることが確認された. それは AMusic や AToy データセットといったコールドなユーザーを多く含んでいる場合で顕著であった.

第三に表 3 と表 4 に表現学習とマッチング学習との比較を行った結果を載せる. すべての場合においてマッチング学習が上回る結果となった. しかし両者を事前学習して組み合わせることで性能は向上することも確認された. これらのことより条件付き表現を得る上で early ステージでのフュージョンが late ステージでのフュージョンよりも効果的であることが確認された.

## 5.5 総 合 評 価

RQ2 に答えるため, MetaCFNet をベースライン手法と比較した結果を表 5 に載せる. 一番性能の良かった手法と二番目の手法を太字で表現している. 結果として

MetaCFNet は ml-1m と lastfm においては CFNet とほぼ同等の結果を示し, AMusic と AToy では大きな性能の向上を示した. 前者はコールドユーザーを含まないような前処理が行われているが, 後者は多くのコールドユーザーを含むという点において, 本提案手法が疎なデータセットからの学習に強みを示しており, ml-1m や lastfm といった事前に履歴が豊富になるに従い CFNet と同等の結果を示すのは仮説どおりの結果といえる.

また MetaCF sampling の有用性について, 疎なデータセットにおいては, どのネットワーク機構についても大幅に性能の向上に寄与することが確認された. さらに, ml-1m と lastfm では, マッチング学習の機構で性能の向上が確認されたが, 表現学習の機構では性能が低下した.

## 5.6 不確実性の可視化と性能面との比較

RQ3 に答えるために我々の提案手法を情報理論の観点から検証を行う.  $\phi$  はベルヌーイ分布のパラメータをモデリングしており, それ自体が確信度を表していると解釈する. そこで不確実性の評価を式 (25) に示す二値エントロピー関数  $H$  で表す. 同式は  $\phi = 0.5$  のとき最大値 1.0 を出力し,  $\phi = 0$  もしくは 1 のとき最低値の 0 を出力する.

$$H(\phi) = -\phi \log_2 \phi - (1 - \phi) \log_2 (1 - \phi) \quad (25)$$

ここでは一例として最も性能が向上したデータセット AToy を用いて以下の可視化を行う. 図 2(a) は MetaCF-ml と CFNet-ml それぞれにおける出力のヒストグラムである. 両者ネットワーク機構で唯一の違いは提案手法である MetaCF サンプルングで学習を行ったか否かである. CFNet-ml はほとんどの出力が 0 か 1 に偏っているのに対し, MetaCF-ml はより広範囲に広がっていることが視覚的に確認できる. このことより本提案手法はより明示的に不確実性をモデリングできている手法といえる.

次に不確実性とユーザーとアイテムにおけるスパースさとの関連を調べる. 図 2(b) にユーザーの履歴数 (X 軸) とアイテムの履歴数 (Y 軸) ごとエントロピーの変化のヒートマップを示す. それぞれのマスは CFNet-ml と比較したエントロピーの増大量の平均値に基づいて色分けを行なっている. 図よりユーザー及びアイテムが持つ過去のインタラクションの履歴が少ない場合に, 不確実性が高くなることが明らかとなった.

最後にスコアの向上とユーザー・アイテム間のスパースさとの関連を調べる. 図 2(c) のヒートマップは CFNet-ml と MetaCF-ml 間の HR@10 の向上に基づいて表現している. 図より提案手法を用いることで, アイテムの履歴が少ない場合でも高いスコアを得ることが確認された. これらのことより不確実性のモデリングが最終的な推薦性能の向上に寄与するという仮説が支持された.



表 5: NDCG@10 と HR@10 による結果の比較. ベースライン手法は [Deng 19] から引用. 各データセットの評価指標ごとに、一番性能の良かった手法と二番目の手法を太字で表現している.

Datasets	Measures	Existing Methods			MetaCF			Improvement from CFnet
		CFNet-rl	CFNet-ml	CFnet	MetaCF-rl	MetaCF-ml	MetaCFNet	
ml-1m	HR	0.7127	0.7073	<b>0.7253</b>	0.5354	0.7142	<b>0.7280</b>	0.37%
	NDCG	0.4336	0.4264	<b>0.4416</b>	0.2960	0.4339	<b>0.4353</b>	-1.4%
lastfm	HR	0.8840	0.8834	<b>0.8995</b>	0.8489	0.8925	<b>0.8949</b>	-0.5 %
	NDCG	0.6001	0.5919	<b>0.6186</b>	0.5585	0.6046	<b>0.6074</b>	-1.8%
AMusic	HR	0.3947	0.4071	0.4116	0.5051	<b>0.5456</b>	<b>0.5557</b>	35.0%
	NDCG	0.2504	0.2420	0.2601	0.2753	<b>0.3027</b>	<b>0.3083</b>	18.5%
AToy	HR	0.3746	0.3931	0.4150	0.5413	<b>0.6025</b>	<b>0.6063</b>	44.9%
	NDCG	0.2271	0.2293	0.2513	0.2988	<b>0.3346</b>	<b>0.3405</b>	35.1%

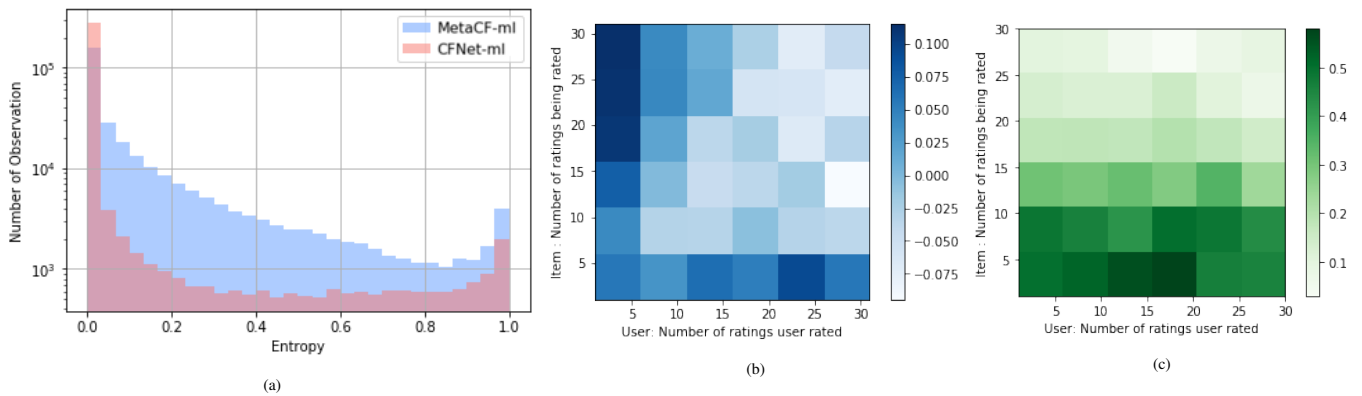


図 2: (a) MetaCF-ml と CFNet-ml のにおけるエントロピーのヒストグラム (b) CFNet-ml から MetaCF-ml へのエントロピーの増大に伴うヒートマップでの可視化 (c) HR@10 における性能の向上に基づくヒートマップ

## 6. 結論と今後の課題

本研究ではメタラーニングに基づいた発想より、協調フィルタリングの手法を拡張し、疎なデータからの学習を効率化し、モデルの出力における不確実性を考慮するモデルの提案を行った。提案手法では NP の枠組みを推薦タスクに適応させた MetaCF を提唱した。提案手法は、従来のコードに数行追加することで実装が行え従来の深層学習ベースの協調フィルタリングモデルのネットワーク機構を変えることなく実装可能である。本論文では、提案手法を事前学習、ネットワーク構造などといった観点から性能を評価し、また既存の state-of-the-art の手法と比較して、より疎なデータにおいて Top-N 推薦タスクで大きな性能の向上を確認した。また提案手法が履歴の少ないユーザーやアイテムに対し不確実性を高く出力しており、それらに対する推論において性能の向上を示していることを確認した。

今後の研究の方針としては以下が考えられる。第一に MetaCF sampling とネットワーク機構の相性に関する理論的考察である。本稿ではマッチング学習についての適用が、表現学習に比べ性能の大幅な向上を示した。またそれらを両方用いた CFNet の機構については、事前学習を行わない場合、性能の劣化が確認された。これら 2 つの原因の解明は今後の課題として扱う。第二にコンテン

ツデータといった外部データを用いる場合の提案手法への組み込み方の検討がある。第三に不確実性が能動学習のようなユーザーの趣向を能動的に学習する際、探索と活用のバランスをとるといったような形で貢献できるかどうかの検証などが考えられる。

## ◇ 参 考 文 献 ◇

- [Bennett 07] Bennett, J., Elkan, C., Liu, B., Smyth, P., and Tikk, D.: KDD Cup and Workshop 2007, *SIGKDD Explor. Newsl.*, Vol. 9, No. 2, pp. 51–52 (2007)
- [Chen 18] Chen, F., Dong, Z., Li, Z., and He, X.: Federated Meta-Learning for Recommendation, *CoRR*, Vol. abs/1802.07876, (2018)
- [Chollet 15] Chollet, F., et al.: Keras, <https://keras.io> (2015)
- [Cremonesi 10] Cremonesi, P., Koren, Y., and Turrin, R.: Performance of Recommender Algorithms on Top-n Recommendation Tasks, in *Proceedings of the Fourth ACM Conference on Recommender Systems, RecSys '10*, pp. 39–46, New York, NY, USA (2010), ACM
- [Deng 19] Deng, Z.-H., Huang, L., Wang, C.-D., Lai, J.-H., and Yu, P. S.: DeepCF: A Unified Framework of Representation Learning and Matching Function Learning in Recommender System (2019)
- [Dos Santos 17] Dos Santos, L., Piwowarski, B., and Gallinari, P.: Gaussian Embeddings for Collaborative Filtering, in *Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval, SIGIR '17*, pp. 1065–1068, New York, NY, USA (2017), ACM
- [Finn 17] Finn, C., Abbeel, P., and Levine, S.: Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks (2017)
- [Garnelo 18] Garnelo, M., Rosenbaum, D., Maddison, C., Rasmalho, T., Saxton, D., Shanahan, M., Teh, Y. W., Rezende, D.,



- and Eslami, S. M. A.: Conditional Neural Processes, in Dy, J. and Krause, A. eds., *Proceedings of the 35th International Conference on Machine Learning*, Vol. 80 of *Proceedings of Machine Learning Research*, pp. 1704–1713, Stockholmsmässan, Stockholm Sweden (2018), PMLR
- [He 17] He, X., Liao, L., Zhang, H., Nie, L., Hu, X., and Chua, T.-S.: Neural Collaborative Filtering, in *Proceedings of the 26th International Conference on World Wide Web, WWW '17*, pp. 173–182, Republic and Canton of Geneva, Switzerland (2017), International World Wide Web Conferences Steering Committee
- [Hu 08] Hu, Y., Koren, Y., and Volinsky, C.: Collaborative Filtering for Implicit Feedback Datasets, in *Proceedings of the 2008 Eighth IEEE International Conference on Data Mining, ICDM '08*, pp. 263–272, Washington, DC, USA (2008), IEEE Computer Society
- [Hu 17] Hu, Q.-Y., Zhao, Z.-L., Wang, C.-D., and Lai, J.-H.: An Item Orientated Recommendation Algorithm from the Multi-view Perspective, *Neurocomput.*, Vol. 269, No. C, pp. 261–272 (2017)
- [Järvelin 02] Järvelin, K. and Kekäläinen, J.: Cumulated Gain-based Evaluation of IR Techniques, *ACM Trans. Inf. Syst.*, Vol. 20, No. 4, pp. 422–446 (2002)
- [Jiang 17] Jiang, S., Ding, Z., and Fu, Y.: Deep Low-rank Sparse Collective Factorization for Cross-Domain Recommendation, in *Proceedings of the 25th ACM International Conference on Multimedia, MM '17*, pp. 163–171, New York, NY, USA (2017), ACM
- [Jiang 19] Jiang, J., Yang, D., Xiao, Y., and Shen, C.: Convolutional Gaussian Embeddings for Personalized Recommendation with Uncertainty, pp. 2642–2648 (2019)
- [Kim 19] Kim, H., Mnih, A., Schwarz, J., Garnelo, M., Eslami, S. M. A., Rosenbaum, D., Vinyals, O., and Teh, Y. W.: Attentive Neural Processes, *ArXiv*, Vol. abs/1901.05761, (2019)
- [Kingma 14] Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization (2014), cite arxiv:1412.6980Comment: Published as a conference paper at the 3rd International Conference for Learning Representations, San Diego, 2015
- [Koren 09] Koren, Y., Bell, R., and Volinsky, C.: Matrix factorization techniques for recommender systems. *IEEE, Computer Journal*, 42(8), 30–37, *Computer*, Vol. 42, pp. 30–37 (2009)
- [Pan 08] Pan, R., Zhou, Y., Cao, B., Liu, N. N., Lukose, R., Scholz, M., and Yang, Q.: One-Class Collaborative Filtering, in *Proceedings of the 2008 Eighth IEEE International Conference on Data Mining, ICDM '08*, pp. 502–511, Washington, DC, USA (2008), IEEE Computer Society
- [Rasmussen 06] Rasmussen, C. E.: Gaussian processes for machine learning, MIT Press (2006)
- [Rendle 19] Rendle, S., Zhang, L., and Koren, Y.: On the Difficulty of Evaluating Baselines: A Study on Recommender Systems, *CoRR*, Vol. abs/1905.01395, (2019)
- [Salakhutdinov 08] Salakhutdinov, R. and Mnih, A.: Bayesian Probabilistic Matrix Factorization Using Markov Chain Monte Carlo, in *Proceedings of the 25th International Conference on Machine Learning, ICML '08*, pp. 880–887, New York, NY, USA (2008), ACM
- [Sedhain 15] Sedhain, S., Menon, A. K., Sanner, S., and Xie, L.: AutoRec: Autoencoders Meet Collaborative Filtering, in *Proceedings of the 24th International Conference on World Wide Web, WWW '15 Companion*, pp. 111–112, New York, NY, USA (2015), ACM
- [Srivastava 14] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R.: Dropout: A Simple Way to Prevent Neural Networks from Overfitting, *J. Mach. Learn. Res.*, Vol. 15, No. 1, pp. 1929–1958 (2014)
- [Vartak 17] Vartak, M., Thiagarajan, A., Miranda, C., Bratman, J., and Larochelle, H.: A Meta-Learning Perspective on Cold-Start Recommendations for Items, in Guyon, I., Luxburg, U. V., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., and Garnett, R. eds., *Advances in Neural Information Processing Systems 30*, pp. 6904–6914, Curran Associates, Inc. (2017)
- [Wang 18] Wang, X., He, X., Feng, F., Nie, L., and Chua, T.-S.: TEM: Tree-enhanced Embedding Model for Explainable Recommendation, in *Proceedings of the 2018 World Wide Web Conference, WWW '18*, pp. 1543–1552, Republic and Canton of Geneva, Switzerland (2018), International World Wide Web Conferences Steering Committee
- [Xue 17] Xue, H.-J., Dai, X., Zhang, J., Huang, S., and Chen, J.: Deep

Matrix Factorization Models for Recommender Systems, in *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence, IJCAI-17*, pp. 3203–3209 (2017)

[Zhu 18] Zhu, D., Cui, P., Wang, D., and Zhu, W.: Deep Variational Network Embedding in Wasserstein Space, in *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, KDD '18*, pp. 2827–2836, New York, NY, USA (2018), ACM

〔担当委員：馬場 雪乃〕

2019 年 12 月 18 日 受理

## 著者紹介



福馬 智生

2018 年から東京大学大学院工学系研究科システム創成学専攻の博士後期後期課程に入学。2016 年に株式会社 TDAI Lab を設立。研究興味は機械学習を用いた人の意思決定における事前情報が及ぼすバイアスの調査。特技は競技ダンスで、2015 年第 60 回全日本学生競技ダンス選手権で個人団体共に全国優勝。2016 年から 2019 年の間日本代表選手を兼任する。



鳥海 不二夫(正会員)

2004 年東京工業大学大学院理工学研究科機械制御システム工学専攻博士課程修了。同年、名古屋大学情報科学研究科助手。2007 年同助教。2012 年東京大学大学院工学系研究科准教授。エージェントベースシミュレーション、ソーシャルメディア、計算社会科学、ゲームにおける AI 等の研究に従事。電子情報通信学会、日本社会情報学会各会員。博士(工学)。