

投資家の情報選択に対する重みを考慮した金融推奨

高柳剛弘¹ 村山友理¹ 和泉潔¹

¹ 東京大学大学院 工学系研究科

takayanagi-takehiro590@g.ecc.u-tokyo.ac.jp murayama.yuri@sys.t.u-tokyo.ac.jp

izumi@sys.t.u-tokyo.ac.jp

概要

金融市場において個人投資家の目的は多岐にわたる。そのため、株式取引などの金融行動は個人投資家ごとの異質性が大きく、金融行動を予測する投資家行動予測は重要なタスクである。個人投資家は金融意思決定の際に数値情報やテキスト情報など様々な情報を参照するので、これらのプロセスを考慮することでより良い投資家行動予測につながることを期待できる。本研究では投資家の情報選択に対する重みを考慮した金融推奨モデルである Personalized Financial Recommendation with Investors' Attention and Contextual Information (PFRIC) を提案する。個人投資家の取引データを用いて行なった評価実験において、提案手法の精度が既存手法の精度を上回ることを確認し、金融推奨に対して個人投資家の情報選択の選好を考慮することの有用性を示した。

1 はじめに

オンライン証券を利用して資産運用を行う個人投資家の増加に伴い、投資家の目的や行動に合わせて情報や金融アイテム（個別株式や投資信託など）を提示する金融推奨の必要性が増加している。投資行動において投資家が重視する要素は個人ごとに異なるために、個人化（パーソナライゼーション）が重要である。例えば、個人投資家にはより高いリターンを重視する投資家や、個人の興味から特定の投資テーマを好む投資家など多様な目的の投資家が存在する。

Personalized された金融推奨に関する研究では、Order book analysis や multiple criteria decision analysis などの金融のロジックを協調フィルタリングに組み合わせる研究が多い [1, 2, 3]。近年では、Neural Matrix Factorization (NeuMF) [4] や LightGCN [5] などの深層学習を用いた協調フィルタリング (Neural collaborative filtering) の手法が金融推奨に応用さ

れている [6, 7, 8, 9, 10]。しかしながら、これらの深層学習を用いた協調フィルタリングモデルは E-commerce 推薦、映画推薦、音楽推薦など他分野の推薦領域において提案された手法であり、電子商取引などにおける購買行動とは異なり、アイテムの価値が他の市場参加者や社会状況の影響を強く受けるなど金融意思決定特有の課題を考慮することが困難である。

本研究ではこの金融推奨における2つの特有の課題に注目する。1つ目の課題は、投資家の情報選択に対する選好の個性である。個人投資家は株価などの数値情報に加えて、決算短信やニュースなどのテキスト情報を含む様々な情報を探索し分析した上で意思決定を行う。この過程で個人投資家はそれぞれの情報に対する選好を持つ。例えば、株価チャートの情報を重視する投資家は、意思決定において直近のニュース情報や決算の情報よりも株価を重視するだろう。したがって、投資家の金融行動を予測するためには、投資家の情報に対する選好の個性を考慮するパーソナライズされたメカニズムが必要である。

2つ目の課題はコンテキスト情報の影響である。一般的な映画推薦や音楽推薦では、アイテムである映画や音楽の特徴は安定的である一方で、株価など金融推奨のアイテムは特徴が動的に変化し続けるという特性がある。そのため、金融推奨ではユーザーのアイテムに対する選好は時間情報に大きく依存する。加えて、投資家の属性情報である年齢、所得、リスク許容度なども、投資家の意思決定に大きな影響を与えることが知られている [11]。したがって、より良い投資家行動予測を行うためにはアイテム、ユーザー双方のコンテキスト情報を考慮する必要がある。

この課題に対して、本研究では図 1 に示すように、投資家の情報選択に対する選好の個性を考慮した金融推奨モデルである Personalized

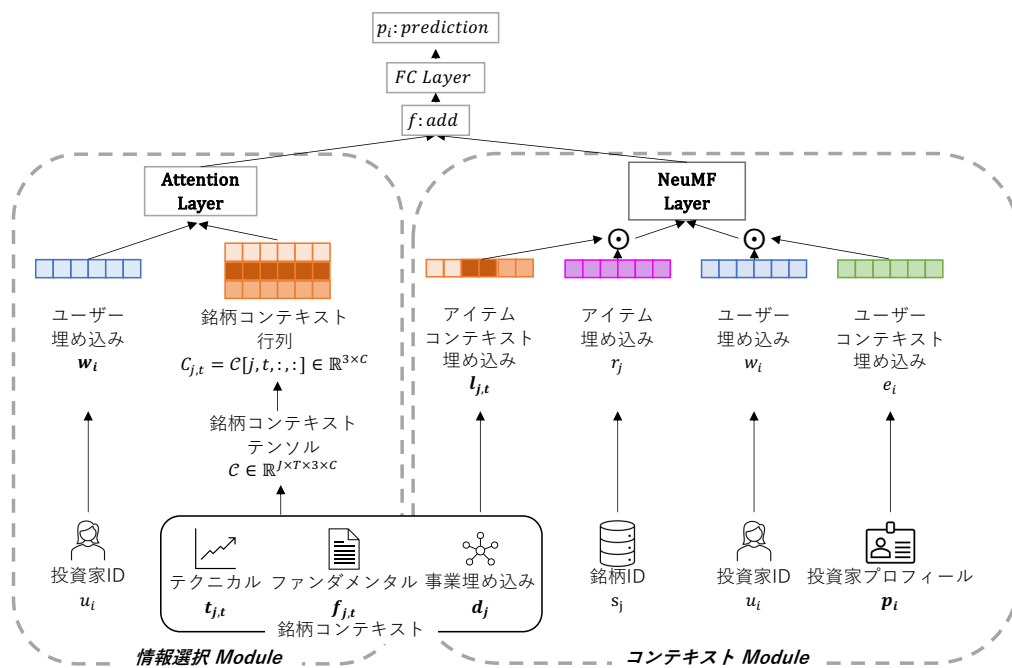


図1 提案モデル (PFRIC) の概要.

Financial Recommendation with Investors' Attention and Contextual Information (PFRIC)を提案する. PFRICは投資家の金融意思決定プロセスを取り入れることを目指し, 情報選択モジュール (information selection module) とコンテキストモジュール (context module) で構成されている. 情報選択モジュールでは投資家の様々な情報に対する重みをモデル化する. 一方で, コンテキストモジュールでは, 株式の動的な特徴や投資家属性などのコンテキスト情報を考慮に入れる. 個人投資家の取引データを用いた評価実験において, 提案手法の精度が既存手法の精度を上回ることを確認し, 金融推奨に対して個人投資家の情報選択の嗜好を考慮することの有用性を示した.

2 提案手法

2.1 問題定義

ユーザー集合を $U = \{u_1, u_2, \dots, u_N\}$, ユーザープロフィール集合を $P = \{p_1, p_2, \dots, p_N\}$, 銘柄集合を $S = \{s_1, s_2, \dots, s_J\}$, および対応する銘柄コンテキスト集合を $C_t = \{c_{1,t}, c_{2,t}, \dots, c_{J,t}\}$ と定義する. 上記の定義に基づいて, 本研究の金融推奨タスクである投資家行動予測はユーザープロフィール $p_i \in \mathbb{R}^P$ と時刻 t における銘柄コンテキスト情報 $c_{j,t}$ をもとに, ユーザー u_i が時刻 t で銘柄 s_j を取引するかどうかを予測する 2 値分類タスクとして定式化できる.

2.2 情報選択モジュール

情報選択モジュールでは, 金融行動に関連する様々な情報に対する投資家の嗜好をモデル化する. 具体的には, 注意機構 (attention mechanism) [12] を用いて, 市場での価格形成に関連するテクニカル指標, 企業の財務状況を表すファンダメンタル指標, 事業内容など, さまざまな情報に対する重みを表す. 銘柄 s_j の時間 t に対するテクニカル指標ベクトル $\mathbf{t}_{j,t} \in \mathbb{R}^T$ とファンダメンタル指標ベクトル $\mathbf{f}_{j,t} \in \mathbb{R}^F$ は次のように計算される.

$$\mathbf{t}_{j,t} = TC(v_{j,t} \dots v_{j,t-l}) \quad (1)$$

$$\mathbf{f}_{j,t} = FC(\mathbf{w}_{j,t}) \quad (2)$$

ここで, $v_{j,t}$ は銘柄 s_j の時間 t における終値, l はテクニカル指標を計算する期間を示し, $\mathbf{w}_{j,t}$ は銘柄 s_j の時間 t の財務情報の売上高や営業利益などの値を含んだベクトルを示す. TC はテクニカル指標を計算するための関数, FC はファンダメンタル指標を計算するための関数を示す¹⁾. 事業埋め込み $\mathbf{d}_j \in \mathbb{R}^D$ は, Bidirectional Encoder Representation from Transformers (BERT) [13] と Graph Convolutional Networks (GCN) [14] を用いてテキスト情報とネットワーク情報²⁾を付加した埋め込み手法 (SETN) [15]

- 1) 詳細は付録 C を参照.
- 2) Takayanagi et al., 2022 [15] に従ってテキスト情報は決算短信の事業概要, ネットワーク情報は因果チェーンによる企業間ネットワークを使用.

を使用して、以下のように計算される。

$$\mathbf{h}_{\text{BERT},j} = \text{BERT}(\mathbf{x}_j) \quad (3)$$

$$\mathbf{h}_{\text{GCN},j} = \text{ReLU} \left(\sum_{i \in N_j} \hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{-\frac{1}{2}} \mathbf{h}_{\text{BERT},i} W_d + \mathbf{b}_d \right) \quad (4)$$

$$\mathbf{d}_j = \mathbf{h}_{\text{BERT},j} + \mathbf{h}_{\text{GCN},j} \quad (5)$$

ここで、 \mathbf{x}_j は target stock j の事業内容を表すテキストデータ、 $\mathbf{h}_{\text{BERT},j} \in \mathbb{R}^D$ は BERT [13] の出力、 N_j は j の隣接銘柄、 $\hat{A} = A + I$ は自己ループを加えたネットワークの隣接行列を示し、 $\hat{D}_{j,j} = \sum_{i=0} \hat{A}_{ji}$ はその対角次数行列の要素、 $W_b \in \mathbb{R}^{D \times D}$ は重み行列、 $\mathbf{b}_b \in \mathbb{R}^D$ はバイアスを示す。次に、各銘柄コンテキストに対して 1 層の線形層を使用し、その出力を結合することで銘柄コンテキスト行列 $C_{j,t} \in \mathbb{R}^{3 \times C}$ を取得する。これは銘柄、時間、情報の種類、埋め込み次元からなる銘柄コンテキストテンソル $\mathcal{C} \in \mathbb{R}^{J \times T \times 3 \times C}$ を任意の銘柄 s_j と時間 t でスライスした行列 $C_{j,t} = \mathcal{C}[j, t, :, :]$ である。

$$C_{j,t} = [W_t \mathbf{t}_{j,t} + \mathbf{b}_t \parallel W_f \mathbf{f}_{j,t} + \mathbf{b}_f \parallel W_b \mathbf{d}_j + \mathbf{b}_d]^T \quad (6)$$

ここで、 $W_t \in \mathbb{R}^{C \times T}$, $W_f \in \mathbb{R}^{C \times F}$, $W_b \in \mathbb{R}^{C \times D}$ は重み行列、 $\mathbf{b}_t, \mathbf{b}_f, \mathbf{b}_d \in \mathbb{R}^C$ はバイアスであり、 \parallel は結合を示す。最後に、以下のように投資家の金融意思決定における情報に対する選好を表すための注意機構を導入する。

$$\mathbf{q}_i = W_q \mathbf{w}_i + \mathbf{b}_q \quad (7)$$

$$K_{j,t} = C_{j,t} W_k^T + B_k \quad (8)$$

$$V_{j,t} = C_{j,t} W_v^T + B_v \quad (9)$$

$$\mathbf{a}_{i,j,t} = \text{Attention}(\mathbf{q}_i, K_{j,t}, V_{j,t}) \quad (10)$$

ここで、ユーザー埋め込み $\mathbf{w}_i \in \mathbb{R}^W$ はユーザー u_i の埋め込み表現であり、 $q_i \in \mathbb{R}^Q$, $K_{j,t}, V_{j,t} \in \mathbb{R}^{3 \times Q}$ はそれぞれクエリ、キー、バリューに対応し、 $W_q \in \mathbb{R}^{Q \times W}$, $W_k, W_v \in \mathbb{R}^{Q \times C}$ は重み行列、 $\mathbf{b}_q \in \mathbb{R}^Q$, $B_k, B_v \in \mathbb{R}^{3 \times Q}$ はバイアスを表し、 $\mathbf{a}_{i,j,t} \in \mathbb{R}^Q$ は注意層の出力、Attention は注意層³⁾を表す。

2.3 コンテキストモジュール

次に、金融推奨においてユーザーとアイテムのコンテキスト情報を考慮するための NeuMF [4] に基づくコンテキストモジュールを導入する。このモジュールは、投資家の行動に影響を与える株式のダ

3) 詳細は付録 A を参照。

イナミクスと投資家のプロフィールを捉える。コンテキスト情報を考慮するために、ユーザーコンテキスト埋め込み $\mathbf{e}_i \in \mathbb{R}^W$ とアイテムコンテキスト埋め込み $\mathbf{l}_{j,t} \in \mathbb{R}^W$ を以下のように計算する。

$$\mathbf{e}_i = W_e \mathbf{p}_i + \mathbf{b}_e \quad (11)$$

$$\mathbf{l}_{j,t} = W_q \begin{bmatrix} \mathbf{t}_{j,t} \\ \mathbf{f}_{j,t} \\ \mathbf{d}_j \end{bmatrix} + \mathbf{b}_q \quad (12)$$

ここで、 $\mathbf{p}_i \in \mathbb{R}^P$ はユーザープロフィールベクトル、 $W_e \in \mathbb{W}^{W \times P}$, $W_q \in \mathbb{R}^{W \times (T+F+D)}$ は重み行列であり、 $\mathbf{b}_e, \mathbf{b}_q \in \mathbb{R}^W$ はバイアスを表す。最後に、ユーザーコンテキスト埋め込み \mathbf{e}_i とユーザー u_i の埋め込み表現 $\mathbf{w}_i \in \mathbb{R}^W$, アイテムコンテキスト埋め込み $\mathbf{l}_{j,t}$ とアイテム s_j の埋め込み表現 $\mathbf{r}_j \in \mathbb{R}^W$ にそれぞれ Hadamard 積を取り ($\mathbf{g}_i = \mathbf{w}_i \odot \mathbf{e}_i$, $\mathbf{n}_{j,t} = \mathbf{r}_j \odot \mathbf{l}_{j,t}$), NeuMF 層⁴⁾ [4] からコンテキストベクトル $\mathbf{z}_{i,j,t} \in \mathbb{R}^Q$ を取得する。

$$\mathbf{z}_{i,j,t} = \text{NeuMF}(\mathbf{g}_i, \mathbf{n}_{j,t}) \quad (13)$$

2.4 予測

投資家 u_i の株 s_j に対する preference の予測値 $\hat{y}_{i,j,t}$ は以下のように計算される。

$$\hat{y}_{i,j,t} = \sigma(\mathbf{h}_y(\mathbf{a}_{i,j,t} + \mathbf{z}_{i,j,t}) + b_y) \quad (14)$$

ここで、 σ はシグモイド関数、 $\mathbf{h}_y \in \mathbb{R}^Q$, $b_y \in \mathbb{R}$ はバイアスを表す。損失関数は以下のように定義される。

$$\begin{aligned} L &= - \sum_{(i,j,t) \in \mathcal{Y}} \log y_{i,j,t} - \sum_{(i,j,t) \in \mathcal{Y}^-} \log(1 - y_{i,j,t}) \\ &= - \sum_{(i,j,t) \in \mathcal{Y} \cup \mathcal{Y}^-} y_{i,j,t} \log y_{i,j,t} + (1 - y_{i,j,t}) \log(1 - y_{i,j,t}) \end{aligned} \quad (15)$$

ここで、 \mathcal{Y} は正のサンプル、 \mathcal{Y}^- は負のサンプルであり、 $y_{i,j,t}$ は投資家 u_i が時刻 t に銘柄 s_j を取引するかどうかの正解ラベルを表す。負のサンプル \mathcal{Y}^- については、各投資家が以前に取引していない銘柄の集合からランダムサンプリングを行い取得する。

3 実験

3.1 データセット

本研究ではオンライン証券を使用する個人投資家から取引データ、投資家プロフィールデータを収集

4) 詳細は付録 B を参照。

表 1 実験結果とアブレーションスタディ. H@K は HitRatio@K を, N@K は nDCG@K を表す.

	H@5	H@10	N@5	N@10
Pop	0.1726	0.2696	0.0949	0.1258
BPR [17]	0.3821	0.5362	0.2702	0.3199
itemKNN [18]	0.1726	0.2696	0.0949	0.1258
NeuMF [4]	0.4222	0.5855	0.2951	0.3476
MultiVAE [20]	0.4191	0.5686	0.2924	0.3401
NGCF [19]	0.4160	0.5824	0.2887	0.3428
LightGCN [5]	0.4191	0.5794	0.2934	0.3458
RecVAE [21]	0.4083	0.5639	0.2834	0.3338
PSRIC	0.4807	0.6441	0.3772	0.4292
-ISM	-2%	-9%	-7%	-10%
-CM	-2%	-7%	-4%	-7%

し, 969 人の投資家データセットを作成した. アクティブに取引を行う投資家を対象とするために 1 年に 50 回以上の取引を行っている投資家からのサンプリングを行った. 本研究のサンプリング期間は, 2020 年 7 月から 2022 年 9 月までである. 本研究では特に個別株式の購入を抽出して分析を行った. これは事業内容などのデータを使用することに加え, 売却は本研究の対象外である流動性ニーズなどにより引き起こされる可能性が高いからである. 投資家プロフィールとしては年齢, 年収, 金融資産, 投資経験, および投資に対する姿勢の変数を使用した.

3.2 実験設定

He *et al.*, 2017 に従い, 評価には各投資家のデータセット内で最後の取引 (インタラクション) をテストデータとして利用する leave-one-out アプローチを用いる. ハイパーパラメータチューニングのために, ランダムに 1 つのインタラクションを検証データとして用いて, 残りのデータはトレーニングに使用する. 評価指標としては推薦タスクで一般的に用いられる, Hit Ratio@K と nDCG@K (normalized Discounted Cumulative Gain) [16] を使用した. 評価実験では提案モデル PFRIC を以下のベースラインと比較する: ユーザーに最も人気のあるアイテムを推薦する Pop model, BPR[17], itemKNN[18], NeuMF[4], NGCF[19], LightGCN[5], MultiVAE[20], RecVAE[21].

3.3 実験結果

表 1 には提案モデルとベースラインモデルの精度比較と提案モデルの各モジュールの有効性を個別に評価するためのアブレーション分析の結果を示す. ここで ISM は情報選択モジュール, CM はコンテキストモジュールを表す. 表 1 から, 提案手法がベースラインモデルを上回る精度となることが確認できる. アブレーション分析の結果から, 各モジュールが全体のパフォーマンスに貢献しており, 特に情報選択モジュール (ISM) を除外した時の予測精度の低下が大きいことから, 情報選択モジュールが効果的であることが確認できる. 各モジュールを除外すると特に nDCG のパフォーマンス低下がより顕著になり, 情報選択モジュールとコンテキストモジュールの両方を導入することの重要性が示される. 実験結果から, これら 2 つのモジュールを用いて投資家の金融意思決定プロセスを組み込むことが, 金融推奨の精度向上に寄与することが確認できた.

4 おわりに

本研究では金融推奨の投資家行動予測タスクに対して投資家の情報選択の選好を考慮した Personalized Financial Recommendation with Investors' Attention and Contextual Information (PFRIC) を提案した. 情報選択モジュールでは, テクニカル指標, ファンダメンタル指標, 事業内容など様々な属性に対する投資家の選好をモデル化する. 一方で, コンテキストモジュールでは, 株式の動的な特徴や投資家プロフィールなどのコンテキスト情報を考慮に入れる. 個人投資家の取引データを用いて行なった評価実験において, 提案手法の精度が既存手法の精度を上回ることを確認し, 金融推奨に対して個人投資家の情報選択の選好を考慮することの有用性を示した. 一方で, 金融推奨では投資家行動予測の Accuracy のみではなく, ポートフォリオの資産分散, Profitability, Risk 許容度との合致度など「Beyond Accuracy」の評価も重要である. したがって, 今後の発展として投資家予測に加えて Beyond Accuracy 指標も考慮した金融推奨モデルの研究を進めていきたい.

謝辞

本研究は大和証券グループ本社とそのグループ会社である大和コネクト証券株式会社の支援を受けたものである。

参考文献

- [1] Robin M. E. Swezey and Bruno Charron. Large-scale recommendation for portfolio optimization. In **Proceedings of the 16th ACM Conference on Recommender Systems**, pp. 382–386, 2018.
- [2] Yang Yujun, Li Jianping, and Yang Yimei. An efficient stock recommendation model based on big order net inflow. **Mathematical Problems in Engineering**, Vol. 2016, pp. 1–15, 2016.
- [3] Mona Taghavi, Kaveh Bakhtiyari, and Edgar Scavino. Agent-based computational investing recommender system. In **Proceedings of the 7th ACM Conference on Recommender Systems**, pp. 455–458, 2013.
- [4] Xiangnan He, Lizi Liao, Hanwang Zhang, Liqiang Nie, Xia Hu, and Tat-Seng Chua. Neural collaborative filtering. *WWW '17*, p. 173–182. International World Wide Web Conferences Steering Committee, 2017.
- [5] Xiangnan He, Kuan Deng, Xiang Wang, Yan Li, Yong-Dong Zhang, and Meng Wang. Lightgcn: Simplifying and powering graph convolution network for recommendation. In **Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval**, SIGIR '20, p. 639–648, New York, NY, USA, 2020. Association for Computing Machinery.
- [6] Richard McCreadie, Konstantinos Perakis, Maanasa Srikrishna, Nikolaos Droukas, Stamatios Pitsios, Georgia Prokopaki, Eleni Perdikouri, Craig Macdonald, and Iadh Ounis. **Next-Generation Personalized Investment Recommendations**, pp. 171–198. Springer International Publishing, Cham, 2022.
- [7] Sanz-Cruzado Javier, McCreadie Richard, Droukas Nikolaos, Macdonald Craig, and Ounis Iadh. On transaction-based metrics as a proxy for profitability of financial asset recommendations. In **The 3rd International Workshop on Personalization Recommender Systems in Financial Services**, pp. 1–11, 2022.
- [8] Takehiro Takayanagi, Chung-Chi Chen, and Kiyoshi Izumi. Personalized dynamic recommender system for investors. SIGIR '23, p. 2246–2250, New York, NY, USA, 2023. Association for Computing Machinery.
- [9] Takehiro Takayanagi, Kiyoshi Izumi, Atsuo Kato, Naoyuki Tsunedomi, and Yukina Abe. Personalized stock recommendation with investors' attention and contextual information. SIGIR '23, p. 3339–3343, New York, NY, USA, 2023. Association for Computing Machinery.
- [10] Takehiro Takayanagi and Kiyoshi Izumi. Context-aware stock recommendations with stocks' characteristics and investors' traits. **IEICE TRANSACTIONS on Information and Systems**, Vol. 106, No. 10, pp. 1732–1741, 2023.
- [11] Brad M. Barber and Terrance Odean. Boys will be Boys: Gender, Overconfidence, and Common Stock Investment*. **The Quarterly Journal of Economics**, Vol. 116, No. 1, pp. 261–292, 02 2001.
- [12] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, and Illia Polosukhin. Attention is all you need. In **Proceedings of the 31st International Conference on Neural Information Processing Systems**, 2017.
- [13] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. BERT: Pre-training of deep bidirectional transformers for language understanding. In **Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)**, pp. 4171–4186, Minneapolis, Minnesota, June 2019. Association for Computational Linguistics.
- [14] Thomas N. Kipf and Max Welling. Semi-Supervised Classification with Graph Convolutional Networks. In **Proceedings of the 5th International Conference on Learning Representations**, 2017.
- [15] Takehiro Takayanagi, Hiroki Sakaji, and Kiyoshi Izumi. Setn: Stock embedding enhanced with textual and network information. In **2022 IEEE International Conference on Big Data (IEEE BigData 2022)**, pp. 2367–2372, 2022.
- [16] Kalervo Järvelin and Jaana Kekäläinen. Cumulated gain-based evaluation of ir techniques. **ACM Trans. Inf. Syst.**, Vol. 20, No. 4, p. 422–446, oct 2002.
- [17] Steffen Rendle, Christoph Freudenthaler, Zeno Gantner, and Lars Schmidt-Thieme. Bpr: Bayesian personalized ranking from implicit feedback. *UAI '09*, p. 452–461, Arlington, Virginia, USA, 2009. AUAI Press.
- [18] Fabio Aielli. Efficient top-n recommendation for very large scale binary rated datasets. In **Proceedings of the 7th ACM Conference on Recommender Systems**, RecSys '13, p. 273–280, New York, NY, USA, 2013. Association for Computing Machinery.
- [19] Xiang Wang, Xiangnan He, Meng Wang, Fuli Feng, and Tat-Seng Chua. Neural graph collaborative filtering. In **Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval**, SIGIR '19, p. 165–174, New York, NY, USA, 2019. Association for Computing Machinery.
- [20] Dawen Liang, Rahul G. Krishnan, Matthew D. Hoffman, and Tony Jebara. Variational autoencoders for collaborative filtering. In **Proceedings of the 2018 World Wide Web Conference**, *WWW '18*, p. 689–698, Republic and Canton of Geneva, CHE, 2018. International World Wide Web Conferences Steering Committee.
- [21] Ilya Shenbin, Anton Alekseev, Elena Tutubalina, Valentin Malykh, and Sergey I. Nikolenko. Recvae: A new variational autoencoder for top-n recommendations with implicit feedback. In **Proceedings of the 13th International Conference on Web Search and Data Mining**, *WSDM '20*, p. 528–536, New York, NY, USA, 2020. Association for Computing Machinery.

A Attention 層に関して

本研究の $\mathbf{q}_i \in \mathbb{R}^Q$, $K_{j,t}, V_{j,t} \in \mathbb{R}^{|A| \times Q}$ はクエリ, キー, バリュースである. ここで, A は投資家が参照する情報の種類 (株価情報, ニュース情報など) の集合であり, 本研究ではテクニカル指標, ファンダメンタル指標, 事業内容の3種類の情報を用いて実験を行うために $|A| = 3$ となる. Attention 層は以下のように計算される. また, ここでは簡単のため j, t の添え字を外し, $\mathbf{a}_i = \text{Attention}(\mathbf{q}_i, K, V)$ の説明を行う. 本文中ではキー $K_{j,t}$ とバリュース $V_{j,t}$ に銘柄 s_j , 時間 t の添え字がついており, 時間と銘柄ごとに異なる値が出力される.

はじめにキーとクエリからユーザー u_i の e 番目の情報に対するアテンション $\alpha_{i,e}$ を以下のように計算する. アテンションを用いて投資家の情報選択の重みを考慮したベクトル $\mathbf{a}_i \in \mathbb{R}^Q$ が計算できる.

$$\alpha_{i,e} = \frac{\exp(\mathbf{k}_e^T \mathbf{q}_i)}{\sum_{e=1}^{|A|} \exp(\mathbf{k}_e^T \mathbf{q}_i)} \quad (16)$$

$$\mathbf{a}_i = \sum_{e=1}^{|A|} \alpha_{i,e} \mathbf{v}_e \quad (17)$$

ここで $\mathbf{k}_e \in \mathbb{R}^Q$, $\mathbf{v}_e \in \mathbb{R}^Q$ はそれぞれ, K, V 行列の e 列目のベクトルである.

B NeuMF 層に関して

本研究の NeuMF 層の計算は以下の通りである. ここでは簡単のため t の添え字を外し, $\mathbf{z}_{i,j} = \text{NeuMF}(\mathbf{g}_i, \mathbf{n}_j)$ の説明を行う. 本文中では時間 t の添え字がついており, 時間ごとに異なる値が出力される.

NeuMF の入力 is ユーザー埋め込み $\mathbf{g}_i \in \mathbb{R}^W$ とアイテム埋め込み $\mathbf{n}_j \in \mathbb{R}^W$ である. NeuMF は Generalized Matrix Factorization (GMF) 層と Multilayer Perceptron (MLP) 層からなる. はじめに, GMF と MLP に対応したユーザー埋め込み $\mathbf{p}_i^G \in \mathbb{R}^G$, $\mathbf{p}_i^M \in \mathbb{R}^M$ とアイテム埋め込み $\mathbf{q}_j^G \in \mathbb{R}^G$, $\mathbf{q}_j^M \in \mathbb{R}^M$ を計算する.

$$\mathbf{p}_i^G = W_u^G \mathbf{g}_i + \mathbf{b}_u^G \quad (18)$$

$$\mathbf{q}_j^G = W_h^G \mathbf{n}_j + \mathbf{b}_h^G \quad (19)$$

$$\mathbf{p}_i^M = W_u^M \mathbf{g}_i + \mathbf{b}_u^M \quad (20)$$

$$\mathbf{q}_j^M = W_h^M \mathbf{n}_j + \mathbf{b}_h^M \quad (21)$$

ここで, $W_u^G, W_h^G \in \mathbb{R}^{G \times W}$, $W_u^M, W_h^M \in \mathbb{R}^{M \times W}$ は重み行列で, $\mathbf{b}_u^G, \mathbf{b}_h^G \in \mathbb{R}^G$, $\mathbf{b}_u^M, \mathbf{b}_h^M \in \mathbb{R}^M$ はバイアスである. 次に GMF 層により線形の相互作用を捉えるベクトル $\Phi^{GMF} \in \mathbb{R}^G$, MLP 層により非線形の相互作用を捉えるベクトル $\Phi^{MLP} \in \mathbb{R}^M$ を得る.

$$\Phi^{GMF} = \mathbf{p}_i^G \odot \mathbf{q}_j^G \quad (22)$$

$$\Phi^{MLP} = a_L(W_L(a_{L-1}(\dots a_2(W_2 \begin{bmatrix} \mathbf{p}_i^M \\ \mathbf{q}_j^M \end{bmatrix} + b_2)) \dots)) + b_L, \quad (23)$$

ここで MLP 層は L 層の線形層で a は活性化関数を示す. 本研究では活性化関数に ReLU を使い, $L = 4$, $G + M = Q$ となるように実験を行った. 最後に結合を行い $\mathbf{z}_{i,j} \in \mathbb{R}^Q$ を得る.

$$\mathbf{z}_{i,j} = \begin{bmatrix} \Phi^{GMF} \\ \Phi^{MLP} \end{bmatrix} \quad (24)$$

C TC, FC に関して

TC はボリンジャーバンド, MACD (移動平均収束拡散法), RSI (相対力指数), ADX (平均方向性指数) やストキャスティクスなど代表的なテクニカル指標を計算する関数であり, 実装には TA-Lib ライブラリ⁵⁾⁶⁾を用いた. 一方で, FC は EPS (1株当たり純利益), BPS (1株当たり純資産), PER (株価収益率), ROE (自己資本利益率) などのファンダメンタル指標を計算する関数であり, それぞれのファクターは以下のように計算される.

$$\text{EPS (1株当たり純利益)} = \frac{\text{当期純利益}}{\text{発行済み株式数}} \quad (25)$$

$$\text{BPS (1株当たり純資産)} = \frac{\text{純資産}}{\text{発行済み株式数}} \quad (26)$$

$$\text{PER (株価収益率)} = \frac{\text{株価}}{\text{EPS (1株当たり純利益)}} \quad (27)$$

$$\text{自己資本利益率 (ROE)} = \frac{\text{当期純利益}}{\text{自己資本}} \quad (28)$$

5) https://ta-lib.github.io/ta-lib-python/doc_index.html

6) テクニカル指標の具体的な実装は以下に記載した. https://github.com/TTsamurai/technical_indicators