

M&A 後の業績変化を考慮した買収候補推薦のための 内容ベースニューラル協調フィルタリング法

Targets Recommendation Considering After M&A Performance by Content based Neural Collaborative Filtering

大知 正直^{*1}
Masanao Ochi

山野 泰子^{*2}
Yasuko Yamano

浅谷 公威^{*1}
Kimitaka Asatani

北内 啓^{*3}
Akira Kitauchi

太田 智之^{*3}
Tomoyuki Ota

坂田 一郎^{*1 *2}
Ichiro Sakata

^{*1}東京大学技術経営戦略学専攻

Graduate School of Technology Management for Innovation, The University of Tokyo

^{*2}東京大学政策ビジョンセンター

Policy Alternatives Research Institute, The University of Tokyo

^{*3}株式会社ユーザベース

*3UZABASE, Inc.

In this paper, we tackled the recommendation of the M&A candidate considering the change in business performance after M&A. By incorporating the multitask learning framework into the Neural Collaborative Filtering method which is one of recommendation method using Deep Learning, we aimed to propose recommendation method considering the post-conversion change. Experimental results show the similar accuracy as the simple logistic regression method. By using this method, it will be possible to not only recommend M&A targets but also to show to acquirers what kind of benefits they can obtain by acquiring.

1. はじめに

ある商品を顧客に推薦し、購買してもらった後で、顧客がその商品に対し満足したかどうかは重要である。特に購買することで、どのような便益を顧客が得ることができるかを提示することは顧客の商品選択の意思決定をこれまでより効率的にすることができるだろう。本稿では、このように顧客の商品購買のような一つの目的を達成したあとに、顧客が購買した商品によって便益を得たのかどうかを考慮することを「ポスト・コンバージョン」と呼ぶことにする。そしてこの「ポスト・コンバージョン」を考慮した推薦を行うことで、顧客に得られる便益を明示した形での商品推薦を行うことが期待できる。

本稿では、従来の協調フィルタリングを利用した推薦手法に深層学習を適用したニューラル協調フィルタリング法にマルチスクラーニングを適用することで「ポスト・コンバージョン」を考慮した商品推薦手法を提案する。

また、今回対象とする事象をM&Aとしている。M&Aの意味する事象は様々に考えられるが、本稿では比較的商品の購買のようなものに近い、企業の株式の50%超の株式を取得する行為を対象とする。企業を商品として考えた場合、決して同一の商品が無い高額で希少な商品に分類できる。不動産がこうした商品の代表だが、このような場合は、商品を商品の持つ様々な属性によって表現し、推薦に用いる方法が取られる[7]。

以上のことから、本稿では、「ポスト・コンバージョン」時代の情報推薦の試みとして、M&A後の業績変化を考慮した買収候補推薦のための内容ベースニューラル協調フィルタリング法を提案する。本稿の貢献を以下にあげる。

- M&Aによる買収候補の推薦タスクの提案と実験
- M&A後の変化を考慮した推薦フレームワークの提案。

本稿は以下のように構成される。まず、2.章で関連する研究について述べ、本研究の位置づけを明らかにする。次に3.章

で本稿で提案する手法について説明する。この手法の評価に用いるデータ、実験の設定について4.章で述べ、その実験結果と考察を5.章で議論する。最後に結論と今後の展望について述べる。こ

2. 関連研究

1990年代に始まった協調フィルタリングを用いた商品推薦の研究[2]は、深層学習を用いたものへと発展している[3]。これによって、ユーザと商品の購買の関係性をこれまでの比較的シンプルな類似度を表す関数からより複雑なものをブラックボックス的に演算することが可能になった。また、マルチタスク学習(MTL)は、関連する2つのタスクを同時に解決するためにそれぞれのタスクで学習した分散表現を活用する学習方法を指す[1]。そして、協調フィルタリングは、ユーザ・商品間の購買の行列を元に商品の購買履歴の類似しているユーザで対象ユーザが未購買の商品を推薦するものであったが、ユーザをユーザが記述したレビュー文から抽出した嗜好を表す表現で構成した行列でも同等の推薦精度を達成できることが報告されている[4]。本研究では、このような技術を複合し内容ベースニューラル協調フィルタリング法を提案する。

次に、本研究ではM&Aとして買収すべき対象を推薦することを最終的なゴールとしている。しかし、実際の買収者は買収することを目的としているのではなく、買収することによって自社の事業範囲や事業規模を拡大することを目的としているだろう。このようにある対象に目標を達成させた後に、その後実際に対象にとって有益であったかどうかを重視することを本研究では「ポスト・コンバージョン」と呼ぶこととする。ウェブ上の広告における推薦では、表示された広告をクリックした後に実際に購買に至るかどうかを分析するポスト・クリックの分析が行われている[6]。しかし、コンバージョン後に購入した商品がユーザにとって有益であったかということについて分析する研究はほとんど行われていない。

連絡先: 大知 正直, 東京大学技術経営戦略学専攻, 〒 113-8656 東京都文京区本郷 7-3-1,
masanao.ochi@gmail.com

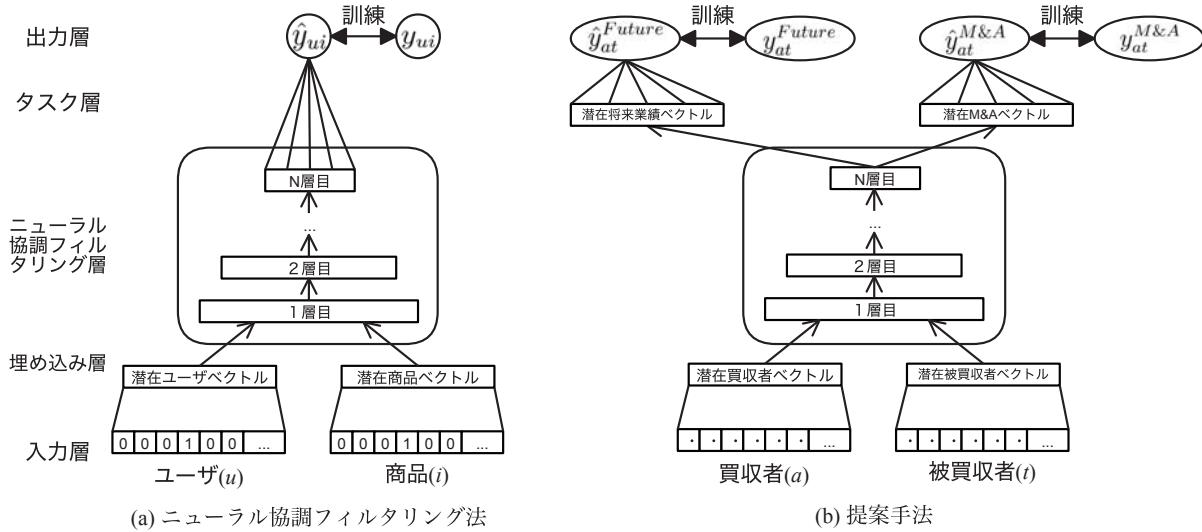


図 1: 従来手法と提案手法の違いを示した概略図.

3. 提案手法

買収者 (a) となる可能性のある事業者数を M , 被買収者 (t) となる可能性のある事業者数を N とする. このとき, 買収者 (a) と被買収者 (t) の間に M&A があったかどうかの関係を行列 $\mathbf{Y}^{M\&A} \in \mathbb{R}^{M \times N}$ によって表すことができる. そして, M&A 後, どのような変化があったかをテンソル $\mathbf{Y}^{Future} \in \mathbb{R}^{M \times N \times K}$ によって表すことができる. ここで, K は M&A 後の将来指標 $\mathbf{H} : \{h_1, \dots, h_K\}$ の多様性を表している. 例えればこれは, M&A が成功したかどうかを表しており, 田村によると売上高上昇, 業界内での寡占度の上昇, コスト削減, 新規事業分野への進出などがあげられる [8]. 以上のことから買収者, 被買収者それぞれの間の関係性を以下のように定める.

$$y_{at}^{M\&A} = \begin{cases} 1 : M\&A をした場合 \\ 0 : それ以外 \end{cases} \quad (1)$$

$$y_{atk}^{Future} = \begin{cases} 1 : 将来指標 h_k において正の変化をした場合 \\ 0 : それ以外 \end{cases} \quad (2)$$

次に予測モデルについて説明する. 買収者 (a) の入力を $\mathbf{v}_a \in \mathbb{R}^{D_a}$, 被買収者 (t) の入力を $\mathbf{v}_t \in \mathbb{R}^{D_t}$ と表す. D_a, D_t はそれぞれ買収者の入力次元数, 被買収者の入力次元数を表している. 本稿では, 通常の協調フィルタリングでは商品やユーザの購買を表すような疎ベクトルではなく, 内容ベースの入力を想定している. 例ええば M&A 以前の売上高や現金及び同等物の量がそれに当たる. 学習すべきパラメータのうち, 全てのタスクにおいて共通のものを Θ^{Common} , M&A 予測に必要なパラメータのみを $\Theta^{M\&A}$, 個別の将来指標 h_k の予測に必要なパラメータのみを Θ^{h_k} とする. 以上のことから予測モデルを以下のように定式化する.

$$\hat{y}_{at}^{M\&A} = f(\mathbf{v}_a, \mathbf{v}_t | \Theta^{Common}, \Theta^{M\&A}) \quad (3)$$

$$\hat{y}_{atk}^{Future} = f(\mathbf{v}_a, \mathbf{v}_t | \Theta^{Common}, \Theta^{h_k}) \quad (4)$$

最後に最適化に用いる目的関数について定式化を行う. 本稿では, マルチタスク学習を用いるため以下のように損失を算出

する.

$$\begin{aligned} L = & - \sum_{(a,t) \in \mathcal{Y} \cup \mathcal{Y}^-} (\\ & \sum_{h_k}^{K} y_{atk}^{Future} \log \hat{y}_{atk}^{Future} + (1 - y_{atk}^{Future}) \log(1 - \hat{y}_{atk}^{Future}) \\ & + y_{at}^{M\&A} \log \hat{y}_{at}^{M\&A} + (1 - y_{at}^{M\&A}) \log(1 - \hat{y}_{at}^{M\&A})) \end{aligned} \quad (5)$$

以上定式化した提案モデルを図 1(b) に概略図として示す. 提案手法では, ニューラル協調フィルタリング層部分は M&A 予測でも将来指標予測においても共通で学習する. 一方でそれ以降は個別のタスク用に学習を行い最適化を進める.

4. 実験

使用したデータ, 実験の条件について説明を行う.

4.1 使用するデータ

株式会社ユーザベース^{*1}が提供する企業情報・分析ツールサービスである SPEEDA^{*2} 内にある M&A に関するデータを使用した. 本データは, 2003 年～2016 年の企業情報, 財務情報に関するデータである. M&A には吸収合併, 株式の取得・移管, 事業譲渡, 会社分割, 合併などがあるが本稿では, 単純に対象企業の株式の 50 % 超の株式を取得する行為を対象とする. 株式を取得した側を買収者, された側を被買収者と呼ぶこととする.

入力する特徴量として, M&A の前の年度の売上高合計, 現金及び同等物, 有利子負債残高, 過去に M&A をしたことがあるかを利用し, M&A 後の成功指標として, 売上高合計が M&A 前と比較し上昇しているかどうかを採用した. このようにして取得した M&A を行った企業を正例とした. また, 一方で提案アルゴリズムの訓練では負例のデータが必要となる. そこでランダムに M&A をしていない企業ペアを同一年度で選択して作成した. 使用したデータの概要を表 1 に示す.

4.2 実験条件

入力した特徴量は買収者, 被買収者とともに共通で, 各業者の業種, M&A 前の売上高, 現金及び同等物, 有利子負債残高, 過去に M&A の経験があるかを入力として, 661 次元とした.

*1 株式会社ユーザベース : <https://www.uzabase.com/>

*2 SPEEDA: <https://www.ub-speeda.com/>

表 1: 実験に使用する M&A データの概要.

| | 売上高上昇 | それ以外 | 合計 |
|----------|-------|------|------|
| M&A ベア | 104 | 162 | 266 |
| 非 M&A ベア | 2669 | 1331 | 4000 |
| 合計 | 2773 | 1493 | 4226 |

提案手法では、これを埋め込み層を 3 層、ニューラル協調フィルタリング層を 3 層、タスク層を 1 層として、出力層にシグモイド関数を用いた。学習率は 0.001、最適化関数として Adam を用いた。テストデータを全体の 30%、バリデーションデータを全体の 10% とし、1,000 エポック実行した。出力は M&A、将来の予測指標として M&A 1 年後の買収者の売上高が上昇したかどうかをそれぞれ採用した。M&A 予測の比較手法として、最も基本的な CTR 予測手法として用いられる、ロジスティック回帰による手法 [5] を用いた。これに買収者、被買収者の特徴量を用いて作成したベクトルを入力した

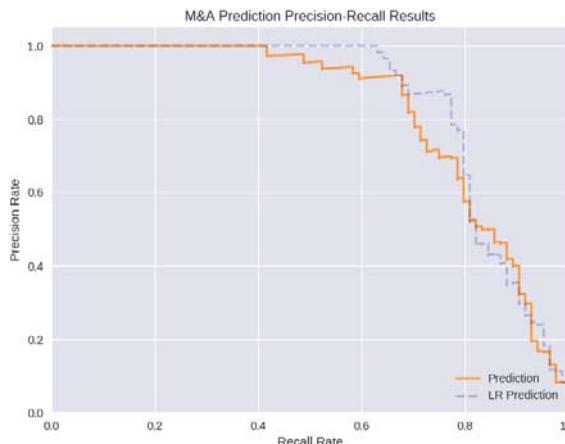


図 2: M&A の予測結果。

表 2: M&A の予測結果

| Method | Precision | Recall | F-value |
|------------------------------|-----------|--------------|---------|
| 提案手法 ($P_{th} = 0.20$) | 0.590 | 0.639 | 0.613 |
| 比較手法 [5] ($P_{th} = 0.67$) | 0.881 | 0.514 | 0.649 |

5. 結果と考察

M&A の予測結果を図 2 に示す。この図は、出力された M&A の確率 ($y_{at}^{M\&A}$) で M&A すると判断する閾値を推移することで変化する、Precision, Recall の曲線を表したものである。全体的に、比較手法のロジスティック回帰モデルと提案モデルで同等の精度を示していることが観察できる。具体的な値は最終段のロジスティック回帰で出力される値の閾値 (以下、 P_{th} とする) によって変動するため、提案手法、比較手法の両方で最も F 値の高くなるような P_{th} を選択した結果を表 2 に示す。提案手法は、Recall において比較手法を 12%ほど上回っているが、最終的な F 値において 3.6%ほど下回っていた。

次に、M&A 後の将来予測の精度について結果について説明する。まず、M&A 後の 1 年後に被買収者の売上が下がり、買

取者の売上が上昇するという予測に関しては Precision 0.066, Recall 0.875, F-value 0.123 であった。また、M&A 後の 1 年後に被買収者の売上がり、買取者の売上も上昇するという予測に関しては Precision 0.003, Recall 0.080, F-value 0.006 であった。個別の正しく予測できたケースについても示すと、例えば、日立建機による TCM の買収 (2009) 等があげられる。この M&A は、当時の世界的な建設機械の需要落ち込みの中で経営を一体化させることで収益改善を計ることを目的としたものだと報道されている^{*3}。実際には M&A 後に被買収者 (TCM) の売上は下がり、買取者 (日立建機) の売上は上昇している。本提案手法によるユースケースを想定すると、これは TCM にとっては大きなメリットの無い買収であった可能性が示唆される。一方で、ゲオホールディングスによるセカンドストリートの買収 (2006) については、双方ともに売上が M&A 後に上昇している。グループ内での顧客 ID の一元化などが行われたこともあり、相乗効果のある M&A であったと言えるだろう。

本提案手法を用いることで、このように M&A 後にどのような変化が双方の企業に起こるかということも含めて予測することが可能になることが示唆されている。

6. 結論と今後の展望

本稿では、M&A 後の業績変化を考慮した M&A の予測手法を提案した。特にニューラル協調フィルタリングの枠組みにマルチタスク学習を組み合わせることで、自然な形での「ポスト・コンバージョン」を考慮した推薦モデルが構築できることを示した。一方で深層学習ならではの問題点も指摘される。特に M&A は回数が少ないもので、深層学習の特徴である層を重ねた場合のパラメータ数の増加に耐えるデータ量を揃えることが難しいことがあげられる。また、M&A の成功を表す指標の難しさもあげられる。今回は単に買収者の売上高の M&A 後の増加を成功指標として採用したが、被買収者が買収者と比較し小規模な会社である場合、買収者の売上高の寄与は小規模であり、それ以外の要因による変化が大きい場合が非常に多くみられる。今後は M&A の成功的指標としてより適切なもののデータ取得、開発が必要であると考えられる。

参考文献

- [1] Andreas Argyriou, Theodoros Evgeniou, and Massimiliano Pontil. Multi-task feature learning. In B. Schölkopf, J. C. Platt, and T. Hoffman, editors, *Advances in Neural Information Processing Systems 19*, pages 41–48. MIT Press, 2007.
- [2] David Goldberg, David Nichols, Brian M. Oki, and Douglas Terry. Using collaborative filtering to weave an information tapestry. *Commun. ACM*, 35(12):61–70, 1992.
- [3] Xiangnan He, Lizi Liao, Hanwang Zhang, Liqiang Nie, Xia Hu, and Tat-Seng Chua. Neural collaborative filtering. In *Proceedings of the 26th International Conference on World Wide Web, WWW ’17*, pages 173–182, Republic and Canton of Geneva, Switzerland, 2017. International World Wide Web Conferences Steering Committee.

^{*3} <https://jp.reuters.com/article/idJPJAPAN-11265420090831>

- [4] Masanao Ochi, Makoto Okabe, and Rikio Onai. Rating prediction using feature words extracted from customer reviews. In *Proceedings of the 34th International ACM SIGIR Conference on Research and Development in Information Retrieval*, SIGIR '11, pages 1205–1206, New York, NY, USA, 2011. ACM.
- [5] Matthew Richardson, Ewa Dominowska, and Robert Ragno. Predicting clicks: Estimating the click-through rate for new ads. In *Proceedings of the 16th International Conference on World Wide Web*, WWW '07, pages 521–530, New York, NY, USA, 2007. ACM.
- [6] Rómer Rosales, Haibin Cheng, and Eren Manavoglu. Post-click conversion modeling and analysis for non-guaranteed delivery display advertising. In *Proceedings of the Fifth ACM International Conference on Web Search and Data Mining*, WSDM '12, pages 293–302, New York, NY, USA, 2012. ACM.
- [7] 大知正直, 関喜史, 川上登福, 小野木大二, 野村真平, 吉永恵一, and 松尾豊. 推薦そのものがユーザに与える影響を考慮した情報推薦. *人工知能学会全国大会論文集*, 28:1–4, 2014.
- [8] 田村俊夫. *MBA のための M&A*. 有斐閣, 2009.