

業界の関係性を考慮した アニメ作品の特徴量の再抽出

齋藤 悠貴^{1,a)} 清 雄一^{1,b)} 田原 康之^{1,c)} 大須賀 昭彦^{1,d)}

概要：

近年、EC サイト等で「こちらもおすすめ」といったユーザの嗜好に関連したアイテムの機械的な推薦がしばしばみられる。多くの場合、このようなレコメンデーションには協調フィルタリングと呼ばれる推薦手法が採られる。ただし、協調フィルタリングでは購入データや評価データ等の嗜好ベースの情報しか考慮できず、アイテムが持つメタ的な情報が考慮されない問題点が存在する。本研究では、特にアニメ作品に関して、協調フィルタリングの一手法による評価データのみを考慮した特徴量の抽出に加え、アニメ制作業界の関係性を考慮した特徴量の再抽出を試みた。「誰がどの作品を好む」といった情報だけでなく、「誰がどの作品を作ったか」といった情報を組み込んだ特徴量を抽出することを目的とする。業界の関係性の再現にあたっては、グラフを用いた。アニメごとに関連づけられた人・企業の要素を繋いでネットワークとすることで、業界の関係性の再現を試みた。特徴量の再抽出には GCN(Graph Convolutional Network)を用いた。提案プロセスと業界の関係性を考慮しない場合とで特徴量を客観評価によって比較すると、提案プロセスがより高い精度をマークしており、業界の関係性を考慮することの有効性が示唆された。

Feature Re-extraction for Anime Contents Considering Anime Business Network

Abstract:

In recent years, automatic recommendation of items related to the user's preferences, such as "also recommended", is often seen on e-commerce websites. In many cases, a recommendation method called collaborative filtering is used for this kind of recommendation. However, collaborative filtering can only take into account preference-based information such as purchase data and evaluation data, and does not take into account the meta-information of items. In this study, we attempted to extract the feature values of anime contents especially by considering the relationship in anime production business in addition to considering only evaluation data by one method of collaborative filtering. The objective is to extract features that incorporate not only information such as "who likes which work" but also "who created which work". In order to replicate the relationships among anime business, we used a graph. We attempted to replicate the relationships between business by connecting the elements of people and companies associated with each anime to form a network. We used GCN(Graph Convolutional Network) to extract the features. Comparing the feature values of the proposed process and the one without considering the relationship data by objective evaluation, the proposed process marked higher accuracy, suggesting the effectiveness of considering the relationship data.

1. はじめに

近年、EC サイトやストリーミングサービス等で「こちらもおすすめ」といったユーザの趣味嗜好に関連したアイ

テムの機械的な推薦がしばしばみられる。多くの場合、このようなレコメンデーションには協調フィルタリングと呼ばれる推薦手法が採られる。協調フィルタリングの基本的な考え方は、同じ商品を購入・閲覧・評価したユーザは同じ嗜好を持っているという前提に基づいたものである。

協調フィルタリングの手法の一つに、評価値行列に対する非負値行列因子分解という手法が存在する。評価値行列とは、どのユーザがどのアイテムに何点付けたかを説明し

¹ 電気通信大学
UEC, Chofu, Tokyo 182-8585, Japan
a) saito.yuki@ohsuga.lab.uec.ac.jp
b) seiuny@uec.ac.jp
c) tahara@uec.ac.jp
d) ohsuga@uec.ac.jp

た行列であり、これを行列因子分解によって行・列方向に分解することでユーザ・アイテムの特徴量を潜在因子として抽出することが可能である。ただし、いずれの手法でも購入データや評価データ等の嗜好ベースの情報しか考慮できず、アイテムが持つメタ的な情報が考慮されない問題点が存在する。

2. 研究の目的

本研究では、特にアニメ作品に関してユーザの評価データから抽出したアニメ作品の特徴量をもとに、メタ的な情報を考慮した特徴量を再抽出することを目的とする。どの声優がどの作品に出演したか、どの制作会社がどの作品を担当したかなど、アニメ制作業界の関係性をグラフとして表現し、これを特徴量に組み込むことでメタ的な情報を考慮する。端的に言えば、作品 A に声優 X が出演しており、作品 B にも声優 X が出演していた場合、作品 A と作品 B には一定の類似性を見出せると考える。

特徴量の再抽出には、GCN を用いる。GCN はグラフを入力にとる畳み込みニューラルネットワークである。GCN にはアニメ制作業界の関係性を再現したグラフ (以下、業界グラフ) と、再抽出前の嗜好ベースの特徴量を入力し、ネットワークを学習させる過程で得られるノードの潜在表現を新たな特徴量として再抽出する。「誰がどの作品を好む」といった情報だけでなく、「誰がどの作品を作ったか」といった情報を組み込んだ特徴量を抽出することを目的とする。

3. 提案プロセス

3.1 提案プロセスの概要

本研究では、業界の関係性を考慮したアニメ作品の特徴量の再抽出プロセスを提案する。再抽出のベースとなる特徴量は評価データに基づく嗜好ベースの特徴量とし、業界グラフとノード特徴量を入力とした GCN を学習させることでノードの潜在表現を獲得、アニメ作品の新たな特徴量として再抽出する。




図 1 提案プロセスの全体像

3.2 業界グラフの構築

本研究の中核となる、業界グラフの構築方法について説明する。業界グラフはアニメ作品を中心として、作品に関

わった人・企業を上下に置いた二部グラフを 2 つ結合したような構造を成している。どの作品にどの人・企業関わったかを表すエッジデータをもとに、グラフを構築する。以下では、業界グラフを構成する部分グラフの仕様について説明する。

初めに、アニメと人を結ぶ部分グラフについて説明する。アニメ制作の現場では、各個人が何らかの役職を持って制作に参加しており、キャラクターに声を充てる声優や、監督・脚本・原画といったアニメーションスタッフが代表的なところにある。これら役職をグラフ上で区別するため、エッジタイプを定義する。エッジタイプはエッジに対する意味的な区別であり、ナレッジグラフ等においてしばしば用いられる。グラフ構築の際には、役職に対応したエッジタイプを定義し、グラフ上では異なるエッジとして扱うことが求められる。この想定により、人ノードからアニメノードに接続するエッジが複数個になる場合が考えられる。




図 2 業界グラフにおける空知英明氏とアニメ銀魂の関係性

例として、銀魂の作者である空知英明氏を挙げる。空知氏はアニメ銀魂の原作者として作品にクレジットされている一方、アニメ銀魂に声優としても参加経験がある。こういった場合、空知氏とアニメ銀魂を結ぶエッジは「原作者」と「声優」という 2 種類のエッジタイプが同時に存在することになる。アニメと企業を結ぶ部分グラフについても、同様の想定が成り立ち、アニメに対して企業は直接制作を担当する企業やスポンサー的な企業に大別される。

3.3 入力特徴量の生成

GCN を学習させるにあたって、最初にノードに割り当てる入力特徴量が必要となる。本項では、業界グラフを構成する 3 種のノード (アニメ・人・企業) それぞれに対して、入力特徴量の生成手法を説明する。

3.3.1 アニメ作品の入力特徴量生成

アニメ作品の入力特徴量は、既に述べたように、評価データをベースに生成する。ここで評価データとは、どのユーザがどのアニメ作品に何点付けたかを表す、評価値行列を指す。この評価値行列に対し、非負値行列因子分解を実行することで、アニメ作品の潜在因子行列を得る。得られた潜在因子行列をそのまま入力特徴量として、学習に用いる。

本研究では、評価値行列に対し非負値行列因子分解を実

行することで得られた 32 次元の潜在因子行列をアニメ作品の入力特徴量として用いる。




図 3 評価値行列に対する行列因子分解のイメージ [1]

3.4 人・企業の入力特徴量生成

人・企業については、ユーザの評価データが存在しないため、アニメ作品とは異なる方法で入力特徴量を生成する。

3.4.1 二部グラフの変換

前項で業界グラフを構成する部分グラフについて述べた。部分グラフは人とアニメ、企業とアニメを結ぶ 2 種類があり、それぞれは二部グラフとして解釈できる。二部グラフをどちらか一方のノードで構成されたグラフへと変換する操作は一般に「射影 (projection)」と呼ばれており、部分グラフに対してこの射影変換を適用する。ここでは、射影によって得られたグラフを便宜的に射影グラフと呼称する。射影変換には重み付けに関していくつかのバリエーションがあるが、本研究では、Newman[2] のモデルを用いた重み付けを採用する。

$$w_{u,v} = \sum_k \frac{\delta_u^k \delta_v^k}{d_k - 1}, \quad \delta_x^y = \begin{cases} 1 & x \text{ and } y \text{ is connected} \\ 0 & \text{not connected} \end{cases} \quad (1)$$

式 1 において、ノード u, v は変換後のグラフに含まれるノードであり、 $w_{u,v}$ はそれらを結ぶエッジの重みを表している。Newman の重み付けでは、 $w_{u,v}$ を共通する隣接ノード k の次数 $d_k - 1$ の逆数の総和を新たな重みとして定義する。この変換を 2 種類の部分グラフそれぞれに対して実行し、人・企業ノードのみからなる射影グラフを得る。




図 4 二部グラフに対する射影変換のイメージ [5]

3.4.2 重みあり DeepWalk

DeepWalk[3] は Node Embedding の手法の一つである。グラフの構造情報を考慮して、ノードの低次元ベクトルを得る手法であり、DeepWalk はその先駆けとなったアルゴ

リズムである。DeepWalk ではまず、グラフ上において固定長のランダムウォークを複数回実行する。得られたノード系列をコンテキストとみなし、これを word2vec モデル (一般には skip-gram) へ入力する。モデルはノードの潜在表現を学習し、最終的にノードの低次元ベクトルが得られる。以上の流れを射影グラフに対して実行することで、人・企業の入力特徴量を得る。この際、通常の DeepWalk とは異なり、エッジの重みを考慮したランダムウォークを行う。エッジの重みを考慮する場合、ランダムウォークの遷移確率が隣接ノードごとに等価ではなく、エッジの重みを正規化した確率となる。

本研究では、系列長 100 の重みありランダムウォークをグラフ上の各ノードを起点に 10 回ずつ実行する。得られたノード系列をウィンドウサイズ 5 の skip-gram へ入力し、32 次元のベクトルを獲得する。これを入力特徴量として人・企業ノードへ割り当て、後段の学習に用いる。

3.5 R-GCN によるノード特徴量の抽出

R-GCN[4] は特徴量の量み込みの際、エッジの属性と向きを考慮する GCN モデルである。業界グラフと入力特徴量を R-GCN へ入力し、ニューラルネットワークを学習させる。学習では事前にアニメ作品に付与されたクラスラベルを用い、多クラス分類によってネットワークを end-to-end に学習させる。評価データと業界の関係性の両方を考慮した特徴量が、評価データの場合と比べ作品の内容や傾向を反映した表現であることを確認する。学習過程では各ノードの潜在表現が得られるので、これを新たな特徴量として抽出する。

4. 評価

4.1 評価の概要

提案プロセスによって抽出された特徴量を多クラス分類によって評価する。ベースラインと精度を比較することで客観評価を行う。分類のためのラベルについては、ジャンルデータをもとに事前にクラスタリングを行うことで、クラスタラベルをそのままクラスラベルとする。

4.2 データセット

入力特徴量・業界グラフを構成するデータは、全て日本のアニメ・漫画を専門とした海外向けの SNS である MyAnimeList から取得する。放送開始日が 2010 年 1 月～2021 年 1 月の作品を取得範囲とし、これら作品に関わった声優や監督・脚本・原画等の制作スタッフを含めた人の要素、制作会社や放送局、出版社といった企業の要素を非公式の MyAnimeList API である Jikan API[7] により収集する。作品の評価データは Anime Recommendations Database vol.2[8] のうち、評価データが格納された rating.csv を用いる。データに対しては一定の条件を設けフィルタリングを

行う。フィルタリング後のデータ詳細を以下に示す。

表 1 データの詳細

総ノード数	総エッジ数	エッジタイプ数	入力特徴量次元	クラス数
10590	187164	66	32	5

エッジタイプはエッジに付与された属性を指す。ある人が原画担当として制作に関わっていれば、業界グラフにおいてその人とアニメを結ぶエッジには「原画」の属性が付与される。エッジタイプには他にも「主演／助演声優」「監督」「脚本」「キャラクターデザイン」「原作」等がある。

4.3 ノード分類

先述の方法で生成したノードラベルを用い、特徴量を分類タスクによって評価する。評価は2種類のベースラインと分類精度を比較することで行う。

4.3.1 評価の設定

分類タスクのため、ベースラインにはサポートベクターマシン (SVM) と多層パーセプトロン (MLP) を採用する。入力には評価値行列から生成したアニメ作品の潜在因子行列を与え、作品ごとに付与された5種類のノードラベルを予測する。提案プロセスのうち、R-GCN については、潜在因子行列に加え、業界グラフを入力に与える。同様にアニメ作品のクラスラベルを予測することで、ベースラインに対する精度を検証する。学習に際しては、モデルの汎化性能をテストするため、いずれの手法においても5分割交差検証とハイパーパラメータのグリッドサーチを行う。

4.4 結果

分類タスクにおける各手法のパラメータ構成とアーキテクチャについて代表的な値を以下にまとめる。なお、以下の値はグリッドサーチを行い、最も高い精度を記録した際の構成である。

表 2 各手法のパラメータ構成とアーキテクチャ

	パラメータ構成など
SVM	$C = 10, \gamma = 1$
MLP	学習率 = 0.1, 最適化 = Adam, 活性化関数 = ReLU レイヤ構成 = (32, 32, 5)
提案プロセス	学習率 = 0.01, 最適化 = Adam, Weight Decay = 0.0005 Dropout = 0.2, レイヤ構成 = (32, 32, 5)

アニメ作品 ($n = 1761$) を5分割交差検証によって80%の訓練データ、20%の検証データに分け、それぞれの分割の精度を平均することでモデルの最終的な精度とする。R-GCN については200エポックの学習を繰り返した。以上の設定を踏まえ、ノード分類の精度 (Accuracy) を以下に示す。

表 3 ノード分類の精度

SVM	MLP	提案プロセス
54.64	55.10	60.30

5. 考察

ノード分類の結果を確認すると、ベースラインと比べ提案プロセスが5%程度高い精度を記録していた。これは、ユーザの評価データだけでなく、業界の関係性を考慮して特徴量を再抽出することの有効性を示唆していると考えられる。ことアニメ作品に関しては、協調フィルタリングに用いられる嗜好ベースの情報に加え、どの声優がどの作品に出演したか、どの制作会社がどの作品を担当したかなど、メタ的な情報を考慮した方がより高精度な分散表現を獲得するに至った。

6. 今後の展望

今後の展望として、エッジタイプごとに偏りを持たせた畳み込み処理を導入することが考えられる。本研究で用いたR-GCNでは、エッジタイプごとに得られた特徴量を集約する際に、全体の平均を取る設計とした。つまり、業界グラフにおいては役職ごとに得られた特徴量を等しく評価していた。実際の制作現場においては、原画スタッフといった末端を担う役職と、監督や脚本、原作者といった中核を担う役職とでは制作上の重要度が異なるはずである。こうした違いを設計に反映することができれば、より実世界に則したモデル、特徴量の抽出が実現できると考える。

謝辞 本研究はJSPS 科研費 JP18H03229, JP18H03340, JP18K19835, JP19H04113, JP19K12107, JP21H03496 の助成を受けたものです。

参考文献

- [1] "Recommender Systems with Python — Part III: Collaborative Filtering (Singular Value Decomposition)", <https://heartbeat.comet.ml/recommender-systems-with-python-part-iii-collaborative-filtering-singular-value-decomposition-5b5dcb3f242b> (最終アクセス: 2022年1月10日)
- [2] Scientific collaboration networks: II. Shortest paths, weighted networks, and centrality, M. E. J. Newman, Phys. Rev. E 64, 016132 (2001).
- [3] Bryan Perozzi, Rami Al-Rfou, Steven Skiena, DeepWalk: Online Learning of Social Representations, arXiv:1403.6652v2 [cs.SI], 27 Jun 2014
- [4] Michael Schlichtkrull, Thomas N. Kipf, Peter Bloem, Rianne van den Berg, Ivan Titov, Max Welling, Modeling Relational Data with Graph Convolutional Networks, arXiv:1703.06103v4 [stat.ML], 26 Oct 2017
- [5] Kumar, P., Sharma, D. A potential energy and mutual information based link prediction approach for bipartite networks. Sci Rep 10, 20659 (2020).
- [6] "MyAnimeList", <https://myanimelist.net/> (最終アクセス: 2021年10月)
- [7] "Jikan API", <https://jikan.moe/> (最終アクセス: 2021年10月)
- [8] "Anime Recommendations Database vol.2", <https://www.kaggle.com/noiruuuu/anime-recommendations-database-vol2> (最終アクセス: 2021年10月)