

Deep Collaborative Filtering

Deep Learning 技術の推薦システムへの応用

The application of Deep Learning in Recommender System

川上 和也^{*1}
Kazuya Kawakami

松尾 豊^{*2}
Yutaka Matsuo

^{*1} 東京大学工学部システム創成学科

Program for Social Innovation, The Department of Engineering, The University of Tokyo

^{*2} 東京大学工学系研究科

Department of Technology Management for Innovation, The University of Tokyo

Recently, the new machine learning algorithms called Deep Learning has attracted attention. However, they have not been applied to the tasks of Web, such as Recommender System. This is because difficulties in learning sparse data and handling of data which contain missing values. In this study, we propose a recommendation technique that can learn users' preferences. The key idea of proposed method is to remove the effects of fluctuations in the preferences of each user/item before applying Deep Learning. This paper provides finding that it is necessary to centralize preference data when recommender system tries to learn from data that is sparse and contain missing values.

1. はじめに

近年, Deep Learning と呼ばれる機械学習アルゴリズムが注目を集めている。Deep Learning は, 多層ニューラルネットワーク (DNN) を学習することによってデータの高次の表現を獲得することができることで知られており, 画像認識, 物体認識, 音声認識, 化合物の活性予測の精度を競う数々のコンペティションで過去の記録を大幅に塗り替えているが, 画像や音声以外の分野への応用が研究課題となっている。

Deep Learning の適用が進んでいない分野の 1 つとして情報推薦があげられる。情報推薦は, ウェブ上から得られるユーザーの行動履歴やレビューをもとにユーザーの嗜好を推定するものである。推薦に際して使用するユーザーの嗜好データは, サッカーが好きであれば, スポーツ全体も好むというような階層的な構造をなしていることが考えられ, ニューラルネットワークを層状に重ねて段階的に特徴を抽出することによってこのような階層的な表現を学習することができると期待できる。

しかし, Deep Learning 技術を推薦システムに適用する研究はほとんど行われていない。その原因として, 情報推薦で用いる嗜好データが非常に疎で欠損値を含んだデータであるほか, 全体的に高い評価をつけるユーザーや, 全体的に高い評価をうけるアイテムなどの評価値のゆらぎや偏りを含んだデータであるといった嗜好データ特有の問題があると考えられる。

本研究では Deep Learning 技術を用いた推薦手法を提案することを目的として, 評価値に含まれるゆらぎや偏りを取り除くために用いられる推薦特有の前処理である中心化と Deep Learning を組み合わせる手法を提案し, Movie Lens 100K と呼ばれるデータセットを用いた評価実験を行った。中心化を用いない手法では, 予測値との平均二乗誤差 (RMSE) が 1.9 程度と, 学習が進まなかったのに対して, 中心化を施した後に Deep Learning に入力する手法では RMSE = 0.98 となり, 協調フィルタリング法を上回る性能を得ることができた。また, 中心化を行っ

た上で単層のニューラルネットワークを行った予測では RMSE = 1.03 であったのに対し, 2 層の DNN では RMSE = 1.01, 3 層の DNN では RMSE = 0.984 と層を重ねるごとに性能が向上していることが確認できた。

研究により, 評価値の揺らぎに対しては情報推薦で一般的に用いられる中心化と呼ばれる前処理が有効であることがわかり, また, 1 層ずつ順にトレーニングする Pre-Training を用いたことによって, ユーザーの嗜好の階層性を捉えた学習を行い, 性能が向上しているという知見が得られた。

本論文では, まず 2 章で, これまでに行われてきた Deep Learning 技術およびその基礎技術を情報推薦に応用した手法について述べる。つぎに 3 章では, 本研究で提案する中心化を施す Deep Learning 手法について述べる。さらに 4 章では, Movie Lens 100K のデータセットに対して提案手法を適用した評価実験の結果を示し, ベースラインとなる協調フィルタリング法による結果と比較を行ったうえで, 提案手法の有効性を考察する。

2. 関連研究

2.1 Deep Learning 技術の応用研究

Deep Learning 研究ではアルゴリズムの理論的な研究のほか, 画像, 音声, 自然言語処理の分野における応用も進められている。応用に際して, データの特徴にあわせた入力の方法や, パイプラインの掛け方などで工夫がとりいれられている。本節では, これまでに成功している応用技術について簡単にまとめる。

(1) Convolutional Neural Network (CNN)

CNN [LeCun 1998] は, 主に画像認識の分野で用いられる手法である。この手法では, 画像の近接する画素が強い相関を持つという特徴を用いる。従来のニューラルネットワークでは, 入力と隠れ層が全結合していたが, CNN では入力を近接する画素をまとめた小さい領域に分割し, 小さい領域とだけ隠れ層が結合するようにする。さらに, 畳み込んだ層の小さい一部分を Pooling する。このようにして, 画像の並行移動に対してロバストになることが知られている。画像と同様に, 近接したデータが類

似しているような現象は、時系列データでもみられるため、隣り合った時点のデータを畳み込む Time-Delay Neural Network なども提案されている[Waibel 1989].

(2) Conditional Restricted Boltzmann Machine (CRBM)

CRBM [Taylor 2009] は時系列の情報を表現するために用いられる手法である。この手法では、過去のデータが現在のデータに影響を及ぼすという特徴を用いる。CRBM では、ある時点のデータを学習する際、過去のデータに依存するバイアスをかけるものであり、動作認識や音声認識に適用されている。時系列データの取り扱いとは定まっていなかったが、このように、現在のデータが過去のデータに依存するという系列データの特徴をとりいれる工夫がなされている。

(3) Replicated Softmax (RSM)

RSM [Hinton 2009] は文書分類の分野で用いられる手法である。文書分類では、文書にふくまれる単語の数を素性として入力することが多いが、そのままでは文書の長さを考慮にすることができず、長い文章と短い文章でバイアスのかかり方が異なってしまう。そこで、文書に含まれる単語の数に応じてバイアスの大きさを変化させるものである。このように、データごとに含まれている情報の量が異なるような特徴を取り入れる工夫がなされている。

2.2 Deep Learning 技術の推薦システムへの応用

Deep Learning 技術を情報推薦に応用した研究はほとんどなく、著者の知りうる限りでは 2 件しか存在しない。

1 つ目は、コンテンツベースフィルタリングを行う際の素性づくりを Deep Learning を用いて行ったものである。この研究では、音楽についたタグを予測するタスクに対して、Deep Learning を用いて抽出した音声の特徴を用いた手法が提案されており、既存手法を大きく上回る性能をあげている[Van 2013]。コンテンツベースフィルタリングの場合は、評価値などを用いないため、評価値の揺らぎや欠損値を考慮する必要はなく、音声認識のタスクを発展させた形での推薦システムとなる。Deep Learning 技術は画像認識や音声認識においてデータの特徴を学習することで知られており、画像や音声など、既に Deep Learning の有効性が確認されているコンテンツを対象としたコンテンツベースの推薦には有用であると考えられる。

2 つ目は、コンテンツの情報を使わない協調フィルタリング法への応用である。これまで、RBM を適用する手法が提案されている[Salakhutdinov 2007]。ここで用いられた工夫は、入力に離散値であることを利用してベクトルをつくり、重みのシェアによって異なるユーザ間の特徴を学習するものであり、欠損値を無視してトレーニングすることで良い性能を得られることが示されている。しかし、この研究を Deep Learning に発展させた研究はなく、単層のニューラルネットワークを階層的に重ねた場合にどのようなになるのかは分かっていない。また、入力を連続値としての取り扱う場合についてはまだ研究も行われていないのが現状である。

3. 提案手法

3.1 Deep Learning 技術の単純な適用

情報推薦のデータに対して、最も単純に Deep Learning を適用する手法は、ユーザ i が評価したアイテム j の評点 r_{ij} を成分とする ユーザ-アイテム行列 R の各行 r_i を DNN の入力とし、入力=出力となるように学習する手法であると考えられる。 r_i の成分の値は、1 から 5 の連続値であるため、連続値を学習するための

線形ユニットを入力と出力にもちい、入力、出力の次元数は、アイテムの数と同じとする。具体的な入力は、 $(5, 0, 0 \dots 3, 0)$ のようなベクトルとなる。このようなトレーニングを行うことで、1 つ 1 つのデータ r_{ij} に対しては自分自身の値を出力するようにトレーニングするが、トレーニングを行うにつれて重みには他ユーザの情報が反映される。トレーニング終了後、各ユーザのデータ r_i をネットワークに入力し、フォワードプロパゲーションすることによって、別のユーザの情報を含んだ重みを用いて自分自身を再現した $\hat{r}_i$ を得ることができ、これを予測とする。評価指標は、予測値と正解の平均二乗誤差 (RMSE) とする。

Deep Learning には様々なアルゴリズムがあるが、本実験では、連続値を柔軟に扱うことができる Auto-Encoder をベースとしたアルゴリズムを用いた。また、層を重ねることによる効果と、学習方法の違いが性能に及ぼす影響を知るため、以下のような手法を比較した。各アルゴリズムとそれぞれの概要を述べる。

•Auto-Encoder (AE)

AE とは、ニューラルネットワークにおいて入力=出力となるような恒等写像を学習する手法である。AE は入力層、隠れ層、出力層からなり、入力層から隠れ層において低次元表現へのエンコードを行い、隠れ層から出力にかけてデコードし、入力を再構成 (Reconstruction) するように学習する。線形ユニットをもつ 3 層 AE を 2 乗 Reconstruction-Error の最小化によって学習した場合には主成分分析と全く同一となり、隠れ層での表現が主成分に該当するが、ニューラルネットワークを用いることによって非線形変換を行うことができ、より高次の表現を獲得できると考えられている。具体的には、入力層 x が重み W_{vis} によって隠れ層 z にエンコードされ、重み W_{hid} によって出力層 y がデコードする場合

$$z = \sigma(W_{vis}x + b_{vis})$$

$$y = \sigma(W_{hid}z + b_{hid})$$

のように表され、入力の出力との 2 乗誤差を最小化するようにトレーニングするものである。本実験では、活性化関数をシグモイド関数とし、入力と出力の間に用いる 1 層の隠れ層について、ノードの数を 10, 100 の 2 つのパターンで実験を行った。

•Denoising Auto-Encoder (DAE)

Denoising Auto-Encoder は、Auto-Encoder の汎化能力獲得方法の 1 つである。隠れ層の構成については、Auto-Encoder と同様のものとし、ベルヌーイ分布によって生成されたマスクを用いてノードの一部を無効にした。その際に用いたベルヌーイ分布のパラメータを Corruption Rate (p) として $p = 0.3, 0.5$ を用いた。

•Stacked Auto-Encoder (SAE)

SAE は、AE を入力に近い層から 1 層ずつ Pre-Training した上で全体を Fine-Tuning するものである。隠れ層の数 2 層のもと 3 層のものの 2 つで実験を行い、各層に含まれるノードの数は 100 とした。

•Stacked Denoising Auto-Encoder (SDA)

SDA は、SAE をトレーニングする際、DAE で行ったように、ノードの一部を無効化するを同時に行うものである。レイヤーの構成は SAE と同じノード 100 個を含んだ 2 層、3 層のパターンとし、Corruption Rate (p) は DAE と同じ $p = 0.3, 0.5$ とした。

調整すべきパラメータは他にもあるが、今回は上記のパラメータのみの変更とし、学習手法は確率的勾配降下法 (SGD) を用い、学習回数 (エポック数) は各層で 500 回とした。

3.2 中心化を用いた提案手法

中心化の事前処理を行う手法の実験手法について述べる。先に述べた通り、DNN にユーザ-アイテム行列 r から、アイテム平均を差し引いた

$$r_{ij}' = r_{ij} - b_j$$

を入力する手法を実験する。具体的な入力値は、あるユーザ i のアイテム j に対する評点が $r_{ij} = 4$ で、アイテム j についての評点の平均が $b_j = 1.2$ の場合、入力値は $r_{ij}' = 4 - 1.2 = 2.8$ となる。予測値については、ネットワークから出力された値 $\hat{r}_{ij}'$ にアイテム平均を加えた

$$\hat{r}_{ij} = \hat{r}_{ij}' + b_j$$

を予測値とする。例えば、先の例で用いたユーザ i のアイテム j に対する評点からアイテム平均を引いた r_{ij}' に対応する予測値が $\hat{r}_{ij}' = 2.2$ であったとすると、この値に対してあらかじめ差し引いていたアイテム j についての評点の平均 $b_j = 1.2$ を加えた $\hat{r}_{ij} = 2.2 + 1.2 = 3.4$ となる。入力以外は 3.1 項と変更を加えず実験を行い、その比較によって効果を検証する。各手法のパラメタ設定は 3.1 項と同様にした。

4. 実験

(1) データセット

本研究で用いる Movie Lens-100K は、映画の推薦サービス Movie Lens においてユーザが映画を 5 段階評価した記録を収集したデータセットであり、情報推薦アルゴリズムの検証のために用いられる標準的なデータセットである。データの概要は表 1 にまとめた。実験では、データの 80% を訓練データ、残りの 20% をテストデータとした。

表 1 Movie Lens 100K の概要

項目	Movie Lens 100K
ドメイン	www.movielens.org
収集期間	Sept. 20, 1997 – Apr. 22, 1998
データの種類	5 段階評価
ユーザ数	943
アイテム(映画)数	1682
評価数	100,000
スパース度	93.5%

(2) ベースライン手法

本研究ではベースラインとして、各ユーザのアイテムに対する評点 r_{ij} を① 1 から 5 のランダムな値にする方法と②全評点の平均とする方法(全体平均)、③予測対象のユーザの評点の平均とする方法(ユーザ平均)、④予測対象のアイテムの評点を平均とする方法(アイテム平均)、⑤k-近傍法を用いた協調フィルタリングを用いた。協調フィルタリング法(CF)では、バイアスにユーザ平均、アイテム平均を用いたもの、近傍として用いるユーザを 20, 30 人としたものを用いた。ベースライン手法での実験結果を表 2 にまとめた。

表 2 ベースライン手法での実験結果

手法	RMSE
ランダム	1.892
全体平均	1.124
ユーザ平均	1.073
アイテム平均	1.063
CF (アイテム平均, k=20)	1.061

CF (アイテム平均, k=30)	1.055
CF (ユーザ平均, k=20)	1.051
CF (ユーザ平均, k=30)	1.053

(3) 結果

各アルゴリズムの予測値と正解の平均二乗誤差(RMSE)を計測した結果を表 3, 4 にまとめる。

表 3 Deep Learning を単純に適用した場合における実験結果

実験手法	RMSE
AE(10)	1.942
AE(100)	1.940
DAE(10, p=0.3)	1.944
DAE(10, p=0.5)	1.942
DAE(100, p=0.3)	1.956
DAE(100, p=0.5)	1.909
SAE(100-100)	1.961
SAE(100-100-100)	1.953
SDA(100-100,p=0.3)	1.963
SDA(100-100,p=0.5)	1.960
SDA(100-100-100,p=0.3)	1.964
SDA(100-100-100,p=0.5)	1.953

表 4 中心化を用いた提案手法における実験結果

実験手法	RMSE
AE(10)	1.033
AE(100)	1.031
DAE(10, p=0.3)	1.021
DAE(10, p=0.5)	1.020
DAE(100, p=0.3)	1.012
DAE(100, p=0.5)	1.017
SAE(100-100)	1.005
SAE(100-100-100)	0.984
SDA(100-100,p=0.3)	0.990
SDA(100-100,p=0.5)	0.944
SDA(100-100-100,p=0.3)	0.944
SDA(100-100-100,p=0.5)	1.001

(4) 考察

本研究で行った実験の結果、嗜好データを直接 DNN で学習すると、予測値との平均二乗誤差(RMSE)がもっとも小さい場合でも 1.909 と大きくもっとも単純なランダム手法よりも性能が悪かった。これは、①出力がマイナスの値や 5 以上の値をとってしまうこと、②ユーザ、アイテムごとのばらつきの影響が大きく、学習が進まないことが原因であると考えられる。より具体的には、未評価の値が 0 となっていることによって、全体の評点が小さくなるように学習が進められてしまったことによるものであると考えられる。評価していない値を 0 としてしまうと、最も悪い評価である 1 よりさらに悪い評価をつけたこととなる。一方、中心化を行うことで、評価していない商品が好きでも嫌いでもない中間の評価として取扱うことができるため、ユーザの嗜好の特徴を上手く学習できたものと考えられる。これによって、SAE(100-100-100) において協調フィルタリング法を上回る性能を得ることができた。

ここで、隠れ層のノードの数について考察する。ノードを増やすことによって精度が向上しているものの、それほど大きな変化は得られていないことがわかる。原因としては、隠れ層ノードが10個でもある程度のデータを表現することができていることによるものと考えられる。

次に多層にした効果について考察する。ノイズを加えないAEを多層に重ねると、性能が層を重ねるごとに向上していることが分かる。同様に、 $p = 0.3$ とした場合にも層を重ねるごとに精度が向上するが、 $p = 0.5$ の場合には2層から3層にした際に性能が落ちていることがみてとれる。ノイズの掛け方にはランダム性があるため、一概にはいえないが、入力を破壊しすぎたことによって特徴を上手く学習出来なかったと考えられる。

5. まとめ

本研究では、これまで情報推薦のタスクに応用されていなかったDeep Learning技術を情報推薦に適用する手法を提案し、実験による性能の評価を行った。

映画に対する評点を予測するタスクを対象に、生のデータを直接学習する単純な適用を行い、単純な適用では、既存手法として一般的な協調フィルタリング法を上回る性能を得られないことを確認した。その上で、情報推薦特有の中心化と呼ばれる前処理を施したデータを入力として学習を行うことで、協調フィルタリング法を上回る性能が得られることを確認し、提案手法の有効性を確認した。

また、ユーザごとに評点のつけかたが大きく異なる情報推薦のタスクにおいては、データごとの特徴を取り除いた上で学習を行うための前処理として中心化が必要であることを指摘し、考察を加えた。

本研究の実験では、ニューラルネットワークをトレーニングする際のパラメタとして、層の数と汎化能力を獲得するために入力を壊す際のCorruption Rateのみを用いたが、他にも誤差関数、重みの初期化方法、学習計画の設定など性能に影響を与えると考えられるパラメタは多くある。本研究の実験でも、協調フィルタリング法を上回る性能が得られることが確認できたため、今後はその他のパラメタについても詳細に設定することで、さらなる性能の向上が見込まれると考えている。

さらに、今回は標準的なデータセットとして映画に対しての5段階評価を含んだMovie Lens-100Kを用いたが、より大規模なデータへの適用や、5段階の離散値ではない、閲覧数などの連続値が与えられた場合、コンテキスト情報を考慮する場合の適用手法に関しても検討していきたい。

参考文献

- [LeCun 1998] LeCun, Yann, et al. : "Gradient-based learning applied to document recognition." Proceedings of the IEEE 86.11, 1998
- [Waibel 1989] Waibel, Alex, et al. : "Phoneme recognition using time-delay neural networks." Acoustics, Speech and Signal Processing, IEEE Transactions on 37.3, 1989
- [Taylor 2009] Taylor, Graham W., and Geoffrey E. Hinton. : "Factored conditional restricted Boltzmann machines for modeling motion style." Proceedings of the 26th annual international conference on machine learning. ACM, 2009
- [Hinton 2009] Hinton, Geoffrey E., and Ruslan Salakhutdinov. "Replicated softmax: an undirected topic model." Advances in

neural information processing systems. 2009

- [Van 2013] : Van den Oord, Aaron, Sander Dieleman and Benjamin Schrauwen : "Deep content-based music recommendation", Advances in Neural Information Processing Systems, 2013

- [Salakhutdinov 2007] Salakhutdinov, Ruslan and Andriy Mnih and Geoffrey E. Hinton : "Restricted Boltzmann machines for collaborative filtering", Proceedings of the 24th international conference on Machine learning, 2007