

複数の販売チャネルでの購入を 促進するための商品推薦手法

志 甫 有 真・谷 川 奈 穂・馬 場 隆

(東京工業大学大学院社会理工学研究科経営工学専攻)

菊 地 宏 治 (京都大学大学院経営管理教育部経営管理専攻)

片 山 翔 太 (東京工業大学大学院社会理工学研究科経営工学専攻)

高 野 祐 一 (専修大学ネットワーク情報学部)

中 田 和 秀 (東京工業大学大学院社会理工学研究科経営工学専攻)

A Recommender Method for Promoting Multi-channel Shopping

Yuma SHIHO, Naho TANIGAWA, Takashi BABA

(Department of Industrial Engineering and Management, Graduate School of Decision Science
and Technology, Tokyo Institute of Technology)

Koji KIKUCHI (Graduate School of Management, Kyoto University)

Shota KATAYAMA (Department of Industrial Engineering and Management, Graduate School of
Decision Science and Technology, Tokyo Institute of Technology)

Yuichi TAKANO (School of Network and Information, Senshu University)

Kazuhide NAKATA (Department of Industrial Engineering and Management, Graduate School of
Decision Science and Technology, Tokyo Institute of Technology)

A growing number of retailers offer products/services via the Internet as well as at brick-and-mortar stores. These multiple marketing channels increase the opportunity for customers to buy. In addition, retailers can analyze detailed customer information gained from multi-channel shopping in order to improve their service quality. In view of these facts, we develop a specialized recommender method based on the weighted non-negative matrix factorization to expand the number of customers that make use of multiple marketing channels. Our method effectively uses the similarities of customers and products to promote customers' multi-channel shopping. Computational results demonstrate that our method delivers better recommendation performance than the existing recommender methods.

キーワード：推薦システム，協調フィルタリング，非負行列因子分解，販売チャネル，オンライン・ツー・オフライン，電子商取引

Key words : Recommender System, Collaborative Filtering, Non-negative Matrix Factorization, Marketing Channel, Online to Offline, E-commerce

1. はじめに

近年のインターネット（以下、ネットとする）やスマートデバイスの普及により、店舗だけではなくネット上でも商品を販売する小売業者が増加した。ネット販売の利点を活用する方法の一つとして、ネット上で顧客の購買意欲を高めて店舗での購入を促す O2O（Online to Offline）型の販売が注目を集めている（Du and Tang [2014], Phang et al. [2014]）。店舗とネットの両方の販売チャネルを活用することで、顧客の購入機会を増やすことができる。また、両方の販売チャネルで取得した顧客情報を分析することで、顧客の嗜好や習慣に合わせた割引クーポンの付与や新商品の開発など、顧客へのサービス向上につなげることもできる。

店舗とネットの両方で商品を販売する小売業者として、本論文では株式会社良品計画が運営する無印良品を分析対象とした。無印良品では、両方の販売チャネルを利用して商品を購入している顧客は全体の 6% と非常に少数であり、店舗でのみ商品を購入する顧客（店舗ユーザ）に対しては携帯アプリを通して、ネットでのみ商品購入する顧客（ネットユーザ）に対してはネットストア上で商品を推薦している。この商品推薦システムを利用すれば、店舗ユーザに対してネットの利用を促すように商品を推薦し、ネットユーザに対して店舗での購入を促すように商品を推薦することが可能である。これにより、両方の販売チャネルを使うユーザ（デュアルユーザ）の増加が期待でき、上述のように顧客の購入機会の増加と顧客へのサービス向上が期待できる。

しかし、無印良品では、店舗で購入される商品とネットで購入される商品は傾向が異なることに注意する必要がある。このために単純な商品推薦手法では、店舗ユーザには店舗で購入されやすい商品が、ネットユーザにはネットで購入されやすい商品が推薦されてしまい、デュアルユーザの増加に効果的な推薦ができない可能性がある。

商品推薦のための代表的な手法として、協調フィルタリングが挙げられる。基本的な GroupLens の方法（Resnick et al. [1994]）では、嗜好が類似する他のユーザの嗜好パターンに基づいて推薦商品を決しており、O2O 戦略にも応用されている（Mo and Chen [2015]）。一方、近年では行列分解に基づいてデータ行列を低ランク近似する手法の有効性が広く認識されており（Koren and Bell [2011], Koren et al. [2009]）、具体的な行列分解の手法として、特異値分解（SVD: Singular Value Decomposition, Billsus and Pazzani [1998]）や非負行列因子分解（NMF: Non-negative Matrix Factorization, Lee and Seung [1999, 2001]）が利用される。特に NMF を用いた場合には、分解した行列が非負かつ疎になるため、行列の解釈が容易になるという利点があり、多くの研究で利用されている（Chen et al. [2009], Lee et al. [2012], Luo et al. [2014], Sindhvani et al. [2009], Zhang et al. [2006]）。また、Gu et al. [2010] は、ユーザ間の類似度行列や商品間の類似度行列を利用したペナルティ付き NMF を提案し、推薦の性能を向上させている。

本論文の目的はデュアルユーザ獲得のために有効な商品推薦手法を提案することとする。そして上述のペナルティ付き NMF（Gu et al. [2010]）において、ユーザ間・商品間の類似度行列を目的に合わせて作成することで有効な商品推薦ができると考え、本論文ではこの手法を利用する。具体的には店舗ユーザとネットユーザに対して、デュアルユーザの嗜好パターンを重視して商品を推薦するようユーザ間の類似度行列を作成する。また、商品間の類似度行列は商品カテゴリに基づいて作成し、店舗における商品とネットにおける商品を関連付ける。数値実験では GroupLens の方法、SVD、NMF と提案手法を比較し、本論文の目的に合わせた類似度行列を利用することで、商品推薦の性能が向上することを検証した。

本論文は次のように構成される。2節では、本研究で提案する商品推薦手法を説明する。3節では、数値実験を通して提案手法の有効性を検証する。4節では、まとめと今後の課題を述べる。

2. 商品推薦手法

本節では、まず商品推薦で使用するデータ行列について説明し、本論文で利用する Gu et al. [2010] の商品推薦手法を紹介する。最後に、本論文の目的に合わせてユーザ間・商品間の類似度行列を作成する。

2.1 データ行列

本論文では表1のように、行をユーザ、列を商品とした購入履歴のデータ行列を使用する。行列の各要素は、期間内にユーザが商品を購入した回数である。ただし本論文では、販売チャネルと対応付けて商品を推薦するために、同じ商品であっても「店舗で購入される商品（店舗商品）」と「ネットで購入される商品（ネット商品）」を区別して扱う。例えば表1では、ユーザAが店舗で商品1を購入した回数は2回であり、ネットで商品1を購入した回数は3回となっている。

表1 購入履歴のデータ行列

ユーザ	店舗商品					ネット商品				
	1	2	3	4	5	1	2	3	4	5
A	2	0	3	0	1	3	4	0	2	0
B	3	2	1	0	0	0	0	0	0	0
C	0	0	3	0	4	0	0	0	0	0
D	0	0	0	0	0	0	1	1	3	2
E	0	0	0	0	0	0	0	0	2	3

2.2 非負行列因子分解

非負行列因子分解（NMF：Non-negative Matrix Factorization, Lee and Seung [1999, 2001]）を用いた協調フィルタリングでは、特徴数 k を指定し、所与のデータ行列 $X \in \mathbb{R}^{m \times n}$ を非負行列 $U \in \mathbb{R}^{m \times k}$, $V \in \mathbb{R}^{k \times n}$ の積に分解する。このとき $X \approx UV$ となるように、以下の最適化問題を解いて行列 U, V を求める：

$$\begin{aligned} & \text{最小化} \quad \|X - UV\|_F \\ & \text{制約条件} \quad U \geq \mathbf{0}, V \geq \mathbf{0} \end{aligned} \quad (1)$$

ただし、 $\|\cdot\|_F$ はフロベニウスノルムとする。

行列 U の第 i 行ベクトルを \mathbf{u}_i とし、行列 V の第 j 列ベクトルを \mathbf{v}_j とすると、 $\mathbf{u}_i, \mathbf{v}_j$ はそれぞれユーザ i 、商品 j の特徴を表す非負ベクトルである。分解した行列の積 UV は購入履歴 X を近似しているため、ユーザ i の商品 j に対する嗜好度は、ユーザと商品の特徴ベクトルの内積 $\mathbf{u}_i^\top \mathbf{v}_j$ によって推定することができる。また、問題 (1) では行列 U, V に非負条件を課しているために、これらの行列の要素に 0 が多くなり、解釈が容易になるという利点がある。

2.3 ペナルティ付き NMF

Gu et al. [2010] は、購入履歴のデータに加えて、ユーザや商品の類似度データを利用することで推薦性能を高める方法を提案している。具体的には、まずユーザ i とユーザ j の類似度 W_{ij}^U と、商品 i と商品 j の類似度 W_{ij}^V を計算し、ユーザ間の類似度行列 $W^U = (W_{ij}^U)$ と商品間の類似度行列 $W^V = (W_{ij}^V)$ を作成する。ユーザ間の類似度はユーザの性別、年齢、職業、ソーシャルメディアにおける関係性などを利用して計算できる。また、商品間の類似度は商品カテゴリなどの情報により計算できる。

類似度の高いユーザ i, j は各々の特徴ベクトル u_i, u_j も似た値になる可能性が高く、類似度の高い商品についても同様である。したがって、Gu et al. [2010] では、これらの類似度に基づくペナルティ項を追加した以下の最適化問題を考えている：

$$\begin{aligned} & \text{最小化} \quad \|X - UV\|_F^2 + \frac{\lambda_U}{2} \sum_{i=1}^m \sum_{j=1}^m \|u_i - u_j\|^2 W_{ij}^U + \frac{\lambda_V}{2} \sum_{i=1}^n \sum_{j=1}^n \|v_i - v_j\|^2 W_{ij}^V \\ & \text{制約条件} \quad U \geq 0, V \geq 0 \end{aligned} \quad (2)$$

ただし、 $\lambda_U, \lambda_V \geq 0$ は、各ペナルティ項の重みを表すパラメータである。問題 (2) の目的関数の第 2 項はユーザに関するペナルティ項で、類似したユーザの特徴ベクトルが似た値になるように働く。同様に第 3 項は、類似した商品の特徴ベクトルが似た値になるように働く。

2.4 求解アルゴリズム

問題 (2) に対しては、行列 U, V を交互に更新するアルゴリズム (Algorithm 1) が Gu et al. [2010] により提案されている。ただし、 D^U は対角成分が $D_{ij}^U = \sum_{j=1}^m W_{ij}^U$ 、非対角成分が 0 の行列とし、 $L_U = D^U - W^U$ とする。また、行列 L_V^+ は行列 L_U の負の要素をすべて 0 に置換した行列とし、 $L_U^- = L_V^+ - L_U$ とする。 L_V^+, L_V^- についても同様に定義する。ただし、 $[\cdot]_{ij}$ は行列の (i, j) 成分を表す。

Algorithm 1 ペナルティ付き NMF

Inputs : $X, W^U, W^V, \lambda_U, \lambda_V$

Initialize : $U = (U_{ij}), V = (V_{ij})$

repeat

$$U_{ij} \leftarrow U_{ij} \sqrt{\frac{[XV^T + \lambda_U L_U^- U]_{ij}}{[UVV^T + \lambda_U L_U^+ U]_{ij}}}, \quad V_{ij} \leftarrow V_{ij} \sqrt{\frac{[U^T X + \lambda_V V L_V^-]_{ij}}{[U^T UV + \lambda_V V L_V^+]_{ij}}}$$

until 終了条件を満たす

return U, V

Algorithm 1 は従来の NMF に対する求解アルゴリズム (Lee and Seung [1999, 2001]) と類似しているが、ユーザ数 \times ユーザ数のサイズの行列 L_U^+, L_U^- とユーザ数 \times 特徴数のサイズの行列 U の積、および特徴数 \times 商品数のサイズの行列 V と商品数 \times 商品数のサイズの行列 L_V^+, L_V^- の積が現れるために、1 回の更新にかかる時間は増加する。特にユーザ数と商品数に大きな差がある場合に、従来の NMF と比較して計算時間の増加が大きくなる。

本論文では行列 U, V の初期化には、特異値分解の結果を利用した初期行列作成法である NNDSVD

(Boutsidis and Gallopoulos [2008]) を使用した。また、目的関数値の更新率が 1.0×10^{-4} を下回った時点で、Algorithm 1 を終了した。

2.5 ユーザ間の類似度行列

デュアルユーザを増加させるためには、店舗ユーザに対してはネット購入を、ネットユーザに対して店舗購入を促進し、デュアルユーザへと変化させることが必要になる。そこで、目標となるべきデュアルユーザの嗜好を、店舗ユーザとネットユーザに対する商品推薦に強く反映させることを考える。このために、ユーザ間の類似度を表 2 のように定める。この表の縦軸と横軸は 3 種類の顧客（デュアルユーザ・店舗ユーザ・ネットユーザ）を表し、表の数値はそれらの顧客間の類似度を表す。ここでは、デュアルユーザと店舗ユーザ、デュアルユーザとネットユーザの類似度が高く設定されており、この表に従ってユーザ間の類似度行列 W^U を作成する。例えば、店舗ユーザに商品を推薦する場合には、そのユーザと特徴が似ているデュアルユーザの嗜好パターンを参照し、そのデュアルユーザがネットで購入している商品を優先的に推薦することになる。

表 2 ユーザ間の類似度

	デュアル	店舗	ネット
デュアル	0		
店舗	1	0	
ネット	1	0	0

2.6 商品間の類似度行列

今回のデータでは各商品に対して、商品の推薦単位である「商品クラス」の上位に「ライン」「デパートメント」「セクション」という商品分類がある（詳細は 3.1.1 節を参照）。より細かい分類まで一致する商品ほど似ているとみなすことができるため、商品間の類似度は以下のように設定する：

$$W_{ij}^V = \begin{cases} 1 & \text{商品 } i, j \text{ はセクションまで一致} \\ 2 & \text{商品 } i, j \text{ はデパートメントまで一致} \\ 3 & \text{商品 } i, j \text{ はラインまで一致} \\ 4 & \text{商品 } i, j \text{ は商品クラスまで一致} \end{cases}$$

本論文では同じ商品であっても、店舗で購入される店舗商品とネットで購入されるネット商品とを区別しているが、上記の類似度の設定により店舗商品とネット商品の特徴を関連付けることができる。

3. 数値実験

本節では、分析データと予測精度の評価方法について説明し、既存手法と提案手法の比較実験の結果を報告する。

3.1 分析データ

本論文では、経営科学系研究部会連合協議会主催、平成 26 年度データ解析コンペティションで提

供された 2013 年 5 月 15 日から 2014 年 6 月 30 日までの無印良品の購入履歴, ユーザデータ, 商品データを用いた。レコード数は購入履歴が約 4,200 万件, ユーザデータが約 770 万件, 商品データが約 49 万件である。

3.1.1 推薦対象商品

提供された商品データでは, 商品は表 3 のように分類されている。最も大きな分類がセクションであり, デパートメント, ライン, 商品クラス, SJAN コード, JAN コードの順に細かくなっており, JAN コードは具体的な商品名を表す。JAN コードなどを推薦単位とすると分類が細かく予測が困難であること, またデータ行列のサイズが大きくなり膨大な計算時間を要することなどを考慮し, 今回の分析では商品の推薦単位を商品クラスとした。なお, 825 種類の商品クラスのうち, 推薦商品として適切でない商品クラスや, 一部の店舗でしか販売されていない商品クラスを除外し, 推薦対象とする商品を 628 種類とした。したがって, 数値実験で使用した表 1 のようなデータ行列の列数は, $1,256 (=628 \times 2)$ になる。

表 3 商品の分類

分類名	種類数
セクション	9
デパートメント	35
ライン	151
商品クラス	825
SJAN コード	160,574
JAN コード	490,655

3.1.2 データセット

複数のデータセットを用いることで評価の信頼性は高まるが, データセットの期間を短く設定するとデータ量が少なくなり予測が難しくなる。以上を考慮して提案手法の予測精度を検証するために, 提供データから学習期間を 3 ヶ月間, 検証期間を 1 ヶ月間とするデータセットを表 4 のように 11 通り作成した。学習期間の購入履歴を用いて推薦商品を決定し, 検証期間の購入履歴と照らし合わせて予測精度を検証する。ただし, 過去に購入した商品を推薦するだけになることを避けるために, 学習期間にユーザが購入した商品は検証期間の購入履歴から除外した。

表 4 データセットの学習期間と検証期間

データセット	学習期間	検証期間
1	2013 年 5 月-7 月	2013 年 8 月
2	2013 年 6 月-8 月	2013 年 9 月
⋮	⋮	⋮
11	2014 年 3 月-5 月	2014 年 6 月

3.1.3 分析対象ユーザ

分析対象とするユーザタイプと購入実績を表 5 に示す。デュアルユーザは学習期間に両方の販売チャネルで購入実績があるユーザとし, 店舗ユーザとネットユーザは学習期間にそれぞれ一方の販売チャネルのみで購入実績があるユーザとする。本論文の主な目的は, これまでに購入実績の無い販売チャ

ネルで購入される商品を適切に推薦することである。このことを考慮し、店舗ユーザとネットユーザに関しては、学習期間に購入実績の無い販売チャネルで検証期間に購入したユーザを抽出した。またデュアルユーザに関しては、検証期間でも両方の販売チャネルで購入したユーザのみを抽出した。各データセットでは以上の条件を満たすユーザの中から、ランダムに 5,000 人のユーザを抽出して分析を行なった。

表 5 ユーザタイプと購入実績

ユーザタイプ	学習期間	検証期間
デュアルユーザ	両方	両方
店舗ユーザ	店舗	ネット・両方
ネットユーザ	ネット	店舗・両方

3.2 予測精度の評価方法

以降では、以下の 4 種類の手法の予測精度を比較する：

GroupLens GroupLens の方法 (Resnick et al. [1994])

SVD 特異値分解によってデータ行列を分解

NMF 非負行列因子分解 (1) によってデータ行列を分解

提案手法 2.5, 2.6 節の類似度行列を用いたペナルティ付き NMF (2) によってデータ行列を分解

各手法のパラメータは予備実験により以下のように設定した。SVD, NMF および提案手法の行列分解における特徴数は、すべてのデータセットに対して $k=10$ とした。また、提案手法のペナルティ項の重みを表すパラメータは、すべてのデータセットに対して $\lambda_U=0.8$, $\lambda_V=0.004$ とした。各ユーザに対して、嗜好度の推定値の高い順に店舗商品とネット商品を 5 個ずつ合計 10 個推薦する。再現率と適合率の調和平均である F1 値を評価指標として使用し、表 4 の 11 通りのデータセットに対する F1 値の平均によって、各手法の予測精度を比較する：

$$\text{再現率} = \frac{|\text{新規購入した商品} \cap \text{推薦商品}|}{|\text{新規購入した商品}|}$$

$$\text{適合率} = \frac{|\text{新規購入した商品} \cap \text{推薦商品}|}{|\text{推薦商品}|}$$

$$\text{F1 値} = \frac{2}{1/\text{再現率} + 1/\text{適合率}} = \frac{2 \cdot \text{再現率} \cdot \text{適合率}}{\text{再現率} + \text{適合率}}$$

3.3 計算結果

各手法による F1 値の平均を図 1-4 に示す。ここでは、店舗商品 5 個のみを推薦した場合の結果を「店舗商品」、ネット商品 5 個のみを推薦した場合の結果を「ネット商品」とし、両方を合わせて 10 商品を推薦した場合の結果を「合計」としている。なお表 4 の 11 通りのデータセットに対して、NMF の計算時間は平均 7.9 秒、提案手法は平均 11.1 秒であった。

図 1 から分かるように、表 5 のユーザをすべて合わせた全ユーザタイプに対する推薦結果では、提




図1 全ユーザタイプに対する推薦結果




図2 デュアルユーザに対する推薦結果




図3 店舗ユーザに対する推薦結果




図4 ネットユーザに対する推薦結果

案手法の予測精度が最も高かった。特に NMF と比較して提案手法の予測精度が優れていることは、本論文で提案した類似度行列に基づくペナルティが有効に機能したことが理由だと考えられる。また、行列分解に基づく手法と比較して、GroupLens の予測精度は非常に低かった。行列分解によるデータ行列の低ランク近似はデータの次元縮約と同等であり、データ行列の疎性による悪影響を軽減できる。実際に多くの研究で行列分解に基づく協調フィルタリングの有効性が主張されており (Koren and Bell [2011], Koren et al. [2009]), 本論文の結果は既存研究 (Lee et al. [2012]) の実験結果とも整合的である。

デュアルユーザに対する推薦結果 (図2)、店舗ユーザに対する推薦結果 (図3) およびネットユーザに対する推薦結果 (図4) を見ると、「合計」ではいずれの場合も提案手法の予測精度が最も優れていた。提案手法は、これまでに購入実績の無い販売チャネルでの購入を促進することを目的としており、実際に「店舗ユーザに対するネット商品の推薦」と「ネットユーザに対する店舗商品の推薦」では他の手法を大きく上回る予測精度を示したことが図3、4から分かる。以上の結果により、本論文で提案した類似度行列に基づくペナルティは、購入実績の無い販売チャネルにおける嗜好度の推定に有効に機能したと言える。

一般に購入商品の予測は非常に難しく、購入すると予測された商品であっても実際に購入される確率は今回の実験のように数パーセント程度である場合が多い。このような状況では、購入確率が高い商品を推薦することは、推薦しなければ購入しない多数の顧客に対して購入を後押しするような効果が期待できる。

4. おわりに

本論文では、店舗とネットの両方の販売チャネルの使用を促進するための商品推薦手法を提案した。提案手法ではペナルティ付き NMF (Gu et al. [2010]) を利用し、ユーザ間・商品間の類似度行列を目的に合わせて作成した点に新規性がある。数値実験の結果、提案手法は既存手法の予測精度を上回ることが確認でき、これまでに購入実績の無い販売チャネルの商品を推薦する場合に特に高い予測精度を示した。

提案手法を利用することで、店舗ユーザには携帯アプリを通して商品を推薦し、ネット購入を促すことができる。またネットユーザに対しては、ネットストア上で商品を推薦し、店舗への来店を促すことができる。このことにより、店舗とネットの両方を利用する顧客の増加が期待でき、顧客の購入機会の増加と顧客へのサービス向上が実現できる。本論文の提案手法は無印良品だけに限らず、複数の販売チャネルを持つ他の企業でも有効であると考えられる。また提案手法では、類似度行列を目的に合わせて作ることで予測精度を向上させており、ペナルティ付き NMF (Gu et al. [2010]) の有用性と新しい適用可能性を示したことも本研究の一つの貢献と言える。

今後の課題としてはペナルティ項（類似度行列）の改良が挙げられる。予備実験ではユーザの性別や年齢に基づく類似度行列も作成したが、結果は良くなかった。このことから、提案手法のように目的に合わせた類似度行列の作成が重要であると言える。ペナルティ項の重みを表すパラメータ λ_u, λ_v は 0~10 の範囲で値を変化させて実験を行なったが、値によって F1 値に差が見られた。また、パラメータ数が多くなり煩雑になることを防ぐために類似度行列の値は固定していたが、この値を調整することで推薦性能がさらに向上する可能性がある。

本論文では商品の推薦単位として商品クラスを用いたが、商品名を推薦単位として分析することや、商品クラスから個別の商品を選ぶロジックを構築することは今後の課題となる。また今回提供されたデータには、購入履歴以外にも店舗でのチェックインやネットストアにおけるコメントなどのデータがあった。これらを上手く活用してユーザ間・商品間の類似度行列を作成することは、新しい研究の方向性として有望だと考える。

謝 辞

貴重なデータを提供していただいたデータ解析コンペティション関係者の皆様に、心より感謝申し上げます。また、有益なコメントをいただいた 2 名の査読者に心より御礼申し上げます。

参 考 文 献

- Billsus, D. and Pazzani, M.J., “Learning Collaborative Information Filters”, *Proceedings of the International Conference on Machine Learning (ICML '98)*, 1998, pp. 46-54.
- Boutsidis, C. and Gallopoulos, E., “SVD Based Initialization : A Head Start for Nonnegative Matrix Factorization”, *Pattern Recognition*, Vol. 41, No. 4, 2008, pp. 1350-1362.
- Chen, G., Wang, F. and Zhang, C., “Collaborative Filtering Using Orthogonal Nonnegative Matrix Tri-Factorization”, *Information Processing & Management*, Vol. 45, No. 3, 2009, pp. 368-379.
- Du, Y. and Tang, Y., “Study on the Development of O2O E-Commerce Platform of China from the Perspective of Offline Service Quality”, *International Journal of Business and Social Science*, Vol. 5, No. 4, 2014, pp. 308-312.
- Gu, Q., Zhou, J. and Ding, C.H., “Collaborative Filtering : Weighted Nonnegative Matrix Factorization Incorporating User

- and Item Graphs”, *Proceedings of the SIAM International Conference on Data Mining (SDM '10)*, 2010, pp. 199–210.
- Koren, Y. and Bell, R., “Advances in Collaborative Filtering”, Kantor, P.B., Rokach, L., Ricci, F. and Shapira, B. (eds.), *Recommender Systems Handbook*, Springer, 2011, pp. 145–186.
- Koren, Y., Bell, R. and Volinsky, C., “Matrix Factorization Techniques for Recommender Systems”, *Computer*, Vol. 42, No. 8, 2009, pp. 30–37.
- Lee, D.D. and Seung, H.S., “Learning the Parts of Objects by Non-Negative Matrix Factorization”, *Nature*, Vol. 401, No. 6755, 1999, pp. 788–791.
- Lee, D.D. and Seung, H.S., “Algorithms for Non-Negative Matrix Factorization”, *Proceedings of the Advances in Neural Information Processing Systems (NIPS '00)*, 2001, pp. 556–562.
- Lee, J., Sun, M. and Lebanon, G., “A Comparative Study of Collaborative Filtering Algorithms”, *arXiv preprint*, arXiv : 1205.3193, 2012.
- Luo, X., Zhou, M., Xia, Y. and Zhu, Q., “An Efficient Non-Negative Matrix-Factorization-Based Approach to Collaborative Filtering for Recommender Systems”, *IEEE Transactions on Industrial Informatics*, Vol. 10, No. 2, 2014, pp. 1273–1284.
- Mo, C. and Chen, C., “Offline Shop Recommendation Based on Online Shopping History”, *Proceedings of the International Conference on Education Technology, Management and Humanities Science (ETMHS '15)*, 2015, pp. 962–965.
- Phang, C.W., Tan, C.H., Sutanto, J., Magagna, F. and Lu, X., “Leveraging O2O Commerce for Product Promotion : An Empirical Investigation in Mainland China”, *IEEE Transactions on Engineering Management*, Vol. 64, No. 4, 2014, pp. 623–632.
- Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P. and Riedl, J., “GroupLens : An Open Architecture for Collaborative Filtering of Netnews”, *Proceedings of the ACM Conference on Computer Supported Cooperative Work (CSCW '94)*, 1994, pp. 175–186.
- Sindhwani, V., Bucak, S.S., Hu, J. and Mojsilovic, A., “A Family of Non-Negative Matrix Factorizations for One-Class Collaborative Filtering Problems”, *Proceedings of the ACM Recommender Systems Conference (RecSys '09)*, 2009.
- Zhang, S., Wang, W., Ford, J. and F. Makedon, “Learning from Incomplete Ratings Using Non-Negative Matrix Factorization”, *Proceedings of the SIAM International Conference on Data Mining (SDM '06)*, 2006, pp. 548–552.