

# 観光経路推薦問題におけるスポットの価値推定法の提案

柴田 祐樹 高間 康史

†首都大学東京システムデザイン学部

a) hshibata@tmu.ac.jp b) ytakama@tmu.ac.jp

**概要** 本稿では、辺ベクトルと確率モデルによる経路生成の定式化を用いた経路推薦手法における、スポットの価値を推定する手法を提案する。先行研究では、焼きなまし法により最適な経路を求めることで、経路推薦を行う手法を確立しているが、推薦に必要となるスポットの価値は明示的に定めたものを利用するにどまつており、実在するユーザに適合した推薦手法とまでは至っていない。また、スポット間の途中経路も最適化の対象としているため、存在する道すべての価値を推定する必要があり、問題の規模が非常に大きいため、価値推定手法の構築は容易ではない。この課題に対し、本稿では、行列分解ベースの協調フィルタリングと同様のアプローチにより、道の潜在属性と、ユーザの好みを推定する手法を提案する。また、確率モデルである利点を活かし、モンテカルロ法を用いた汎用的な潜在因子推定手法を構築可能なことを示す。

**キーワード** 観光経路推薦， 情報推薦， 機械学習， 協調フィルタリング， 最適化

## 1 研究背景

観光旅行をする際、ガイドブックや旅行会社が提供する観光ツアーを利用するのではなく、Social Networking Service (SNS)などのWebから入手した情報を用いて旅行者自身で観光計画を立案することも増えてきている。観光情報サイトなどでは、エリアなどの指定条件を満たす観光スポットをランキング形式で提示するサービスを提供しているが、知名度の高いスポットや宣伝に力を入れているスポットが上位に表示される傾向がある。ユーザの検索行動として、ランキング上位の数件のみしか確認しないことが一般的であるため、結果として個人の趣味嗜好に合った観光地を訪れる機会の損失を招き、一部の観光地へ旅行客が集中するなど、旅行客、観光地側双方に不利益を生じる。こういった問題を防ぐためにも、ユーザの好みに応じたスポットを選び、限られた時間で効率よく巡回する経路を提案する観光経路推薦手法は重要であり、研究が進められている[1][2]。

文献[3]ではスポットのみでなく、途中の経路における街並みや景観等もユーザにとって重要な因子であるとし、これらを考慮可能な観光経路推薦手法(以降 Edge Vector: EVと呼ぶ)を提案している。問題の定式化では、スポットおよび経路に関する価値や負荷すべてを辺に対する重みとすることで、スポットと経路の情報を統一的に扱い、最適化の過程において両者を同時に調整しながら最適経路の発見を可能としている。しかしながら、推薦に用いる価値自体の推定方法を提案するには至っていない。

本稿ではEVにおける辺の価値を行列分解ベースの協調フィルタリング[8]と同様のアプローチにより、少

ないユーザの行動履歴から価値に対するモデル変数を推定可能な手法を提案する。また、EVが確率モデルとして定式化されている利点を活かし、モンテカルロ法を用いた汎用的な推定手法を構築可能なことを示す。

## 2 EVによる観光経路推薦問題の定式化

$\mathcal{N}$ を節点の集合、 $\mathcal{E}_p$ を辺の全体集合とする。 $\mathcal{E}_p$ は問題に与えられた辺(定義辺)と後述する自己回帰辺、仮想辺を含む。

$|\mathcal{N}|$ 個の辺からなる、経路を含む辺ベクトルを次のように定義する。

$$\mathbf{e} := (e_1, e_2, \dots, e_{|\mathcal{N}|})$$

辺 $e$ ( $\in \mathcal{E}_p$ )のうち、始点と終点が等しいものを自己回帰辺と呼ぶ。辺ベクトルは自己回帰辺を含むことで、要素数を固定しながら様々な経路を表現することができる。要素数が固定であるため、後述するように Gibbs Sampling (GS)[5]を適用可能となる。

また、この手法では、仮想辺を用いることで、2辺に対する操作のみにより経路の変更をしながら最適化を行う。仮想辺を用いた経路変更の様子を図1に示す。この例では、赤線により仮想辺を示している。定義辺上に乗らない仮想辺を経由することで、本来は4つの自己回帰辺を定義辺に変換する必要がある変化を、2辺への置換を4回繰り返すことで表現している。

本稿では、定義辺と自己回帰辺を合わせて実辺と呼び、その全体集合を $\mathcal{E}$ ( $\subset \mathcal{E}_p$ )とする。仮想辺の集合は $\mathcal{E}$ の補集合となる。

$\mathbf{e}$ の確率変数を $\mathbf{e}_\Lambda$ 、その分布 $p(\mathbf{e}_\Lambda)$ を式(1)により定義し、経路は Boltzmann 分布[4]から確率的に生成されるとモデル化する。 $\Lambda = \{1, 2, \dots, |\mathcal{N}|\}$ は辺ベクトルの各要素に対する添字の集合である。本稿では、確率

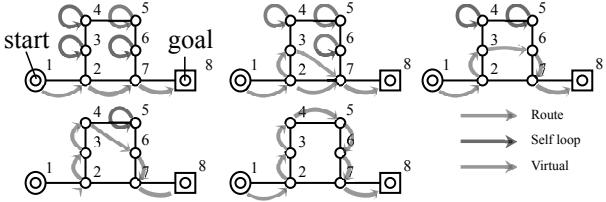


図 1 仮想辺を用いた経路拡張の例. (1) から (5) にかけて経路が拡張されていく様子を描いている.

モデルの表記に文献 [6] で提案されている添字記法を用いる<sup>1</sup>.

$$p(\mathbf{e}_A) = \frac{\exp\left(-\frac{1}{kT}\phi(\mathbf{e}_A)\right)}{\sum_{\mathbf{e}'_A} \exp\left(-\frac{1}{kT}\phi(\mathbf{e}'_A)\right)} \quad (1)$$

ここで,  $T$  ( $\in (0, 1]$ ) は温度である. また,  $k$  は Boltzmann 定数であり,  $T = 1$  においてすべての辺を探索可能となる値を設定する.  $\phi(\mathbf{e}_A)$  は目的関数であり, この値が小さくなる程,  $\mathbf{e}_A$  の出現率が高くなり,  $T$  が小さくなるほどこの傾向が強くなる. 推薦においては, この性質を用いる Simulated Annealing [7] により最適解を求める. このため, 目的関数の値が小さな状態が望ましい経路を表すように  $\phi(\mathbf{e}_A)$  の定式化を行う.

上述した指針に従い,  $\phi(\mathbf{e}_A)$  を式 (2) により定義する.

$$\begin{aligned} \phi(\mathbf{e}_A) = F_{\text{res}} & \left( \sum_{i \in A} f_c(\mathbf{e}_i) + \alpha_s \sum_{i \in A} f_s(\mathbf{e}_i) - C_c \right) \\ & - \sum_{i \in A} f_d(\mathbf{e}_i) + \alpha_{as} \sum_{i \in A} f_s(\mathbf{e}_i) \end{aligned} \quad (2)$$

$f_c(e)$  は  $e$  の負荷,  $f_d(e)$  は  $e$  の価値であり, 両関数の値は辺の向きによらず, 定義辺に対し  $0 \leq f_d(e) < f_c(e)$ , 自己回帰辺, 仮想辺に対し  $f_c(e) = f_d(e) = 0$  を満たすものとする. 定義辺に対する条件は後に説明する経路長に関する制約を無制限に超えた経路が生成されることを防ぐものである.

$f_s(e)$  は仮想辺に対する負荷であり, 式 (3) により定義される.

$$f_s(e) = -f_c(e) + \sum_{s \in S(e)} f_c(s) \quad (3)$$

ここで,  $S(e)$  ( $\subset \mathcal{E}$ ) は辺  $e$  の終始点を結ぶ最短経路を構成する辺の集合であり,  $S(e) = \emptyset \Rightarrow f_s(e) = \infty$  を満たすものとする. このモデル化より, 仮想辺には実辺からなる最短経路負荷以上の負荷が割り当てられ, 仮想辺を含む目的関数の値は実辺のみの状態に比べ高くなるため, 仮想辺は実辺に置換される傾向となる. また,  $\alpha_{as}$  は罰則係数であり, 0 以上でかつ仮想辺が最終的に問題なく消滅する程度にできるだけ小さな値を用いる.

<sup>1</sup>この記法において, 同じ添字集合を添字に持つ確率変数は独立同分布に従う. また,  $\sum_{\mathbf{e}'_A}$  は  $\mathbf{e}'_A$  の状態空間についての総和を示す.

$F_{\text{res}} : \mathbb{R} \rightarrow \mathbb{R}$  は経路負荷に対する制約を表現する関数であり,  $C_c$  は制約値である. 観光経路推薦においてこの制約値は, 経路長や旅行時間に対応する. EV ではこの関数を式 (4) で定義している.

$$F_{\text{res}}(x) = \begin{cases} \alpha_g x + c_1 & , \quad x < x_m \\ c_2 x^2 + c_3 x & , \quad x_m \leq x \leq \sigma^2 \\ x + c_4 & , \quad \sigma^2 < x \end{cases} \quad (4)$$

各設定値は,  $c_1 = c_2 x_m^2 + c_3 x_m - \alpha_g x_m$ ,  $c_2 = (1 - c_3)/(2\sigma^2)$ ,  $c_3 = \max(\alpha_g, 0)$ ,  $x_m = (\alpha_g - c_3)/(2c_2)$ ,  $c_4 = c_2 (\sigma^2)^2 + c_3 \sigma^2 - \sigma^2$  と定める. この定式化では, 経路長が  $C_c$  を超えたあたりで目的関数の値が緩やかに上昇するものとなっており, ある程度の制約違反を認める現実的なモデルとなっている.  $\sigma^2$  は制約違反の許容量を決定するパラメータであり, これにより違反の許容度合いを調節することが可能である.  $\alpha_g (> -1)$  は大きな値を設定することで無駄な経路を省く効果を持つ. 通常は 0 に近い値とし, 無駄な冗長経路を省き, 意味のあるスポットを省かない程度の値を設定する.

Boltzmann 分布からの標本抽出には GS を用い, 得られた標本に基づき最適化を行う.

### 3 提案手法

本稿では価値関数  $f_d$  の値を協調フィルタリングの枠組みに基づいて推定する手法を提案する. 具体的には, 行列分解法 [8] ベースの協調フィルタリング手法と同様のアプローチを用い, 少ないユーザの行動履歴から価値を推定可能な手法とする. ただし, 負荷関数  $f_c$  については道に対する標準的な移動時間を仮定し, 本手法による推定の対象としない. 以降, まず価値関数推定問題の定式化と, モデル変数の表記に用いる記号の定義を行う. その後, モンテカルロ法と勾配降下法によるパラメータの学習法について説明する.

#### 3.1 問題の定式化

ユーザの集合を  $\mathcal{U}$  とし, 各ユーザ  $u$  ( $\in \mathcal{U}$ ) の, 属性  $k$  ( $\in \mathcal{K} = \{1, 2, \dots, K\}$ ) に対する好みを  $w_{u,k}$  と表し, すべての  $u, k$  についてまとめた変数を  $w_{\mathcal{U} \times \mathcal{K}}$  と表す. また, 各実辺  $e$  ( $\in \mathcal{E}$ ) が持つ属性  $k$  の値を  $h_{e,k}$  と表し, ユーザの好みと同様にこれらすべてをまとめた変数を  $h_{\mathcal{E} \times \mathcal{K}}$  と表す.

辺ベクトルは, 推論においては各ユーザごとに独立して扱うことができるため, 第 2 節では確率変数を一つのみにより表していたが, パラメータの推定においてはすべてのユーザについて考慮する必要がある. よって, 単一のあるユーザ  $u$  ( $\in \mathcal{U}$ ) の辺ベクトルを  $\mathbf{e}_{u,A}$  と表し, すべての  $u$  についてまとめたものを  $\mathbf{e}_{\mathcal{U} \times A}$  と表すこととする.

以上の定義を用い、パラメータ  $w_{\mathcal{U} \times \mathcal{K}}$  と  $h_{\mathcal{E} \times \mathcal{K}}$  を用いて価値関数  $f_d$  をモデル化することを考える。本稿では、Matrix Factorization [8] で用いられる潜在因子ベクトルの内積モデルを用いることとする。また、 $f_d$  には、 $\forall e, f_d(e) < f_c(e)$  の制約があるため、これと合わせて、辺  $e$  ( $\in \mathcal{E}$ ) のユーザ  $u$  ( $\in \mathcal{U}$ ) に対する価値  $f_d(e, u)$  を式(5)とモデル化する。

$$f_d(e, u) = f_c(e) \tanh \left( \sum_{k \in \mathcal{K}} w_{u,k} h_{e,k} \right) \quad (5)$$

文献[3]では、 $0 \leq f_d(e)$  の制約も課しているが、本稿では負の好みも表せるようにし、価値関数の一般性を向上させるためにこの制約を無視したモデル化としている。ここで、 $k = 1$  の属性は全ユーザで共通の嗜好（人気度）を表すと定め、 $\forall u, w_{u,1} = 1$  とする。また、 $k = K$  の属性はユーザ毎の辺に対する好みの平均値を表すとして、 $\forall e, h_{e,K} = 1$  とする。この結果、ユーザ毎に固有の潜在因子として有効である属性数は  $K - 2$  となる。

ユーザ全体の辺ベクトル  $\mathbf{e}_{\mathcal{U} \times \Lambda}$  はユーザ間の相互作用、例えば、ユーザを分散させ混雑の発生を抑えるための最適化等、は考慮しないとし、このため、 $\mathbf{e}_{\mathcal{U} \times \Lambda}$  の分布は各ユーザ間で互いに独立な形となり、式(6)のように書ける。

$$p(\mathbf{e}_{\mathcal{U} \times \Lambda}) = \prod_{u \in \mathcal{U}} p(\mathbf{e}_{u,\Lambda}) \quad (6)$$

また、右辺の因子  $p(\mathbf{e}_{u,\Lambda})$  は式(1)と同様のモデル化を用いて、式(7)で定義する。ただし、要素  $u$  に応じて価値関数は選ばれるものとする。

$$p(\mathbf{e}_{u,\Lambda}) = \frac{\exp\left(-\frac{1}{kT}\phi(\mathbf{e}_{u,\Lambda})\right)}{\sum_{\mathbf{e}'_{u,\Lambda}} \exp\left(-\frac{1}{kT}\phi(\mathbf{e}'_{u,\Lambda})\right)} \quad (7)$$

次に、データセットを定義し、パラメータ推定に用いる尺度である Kullback-Leibler (KL) 情報量を定式化する。各ユーザ  $u$  ( $\in \mathcal{U}$ ) の行動履歴を与える経験分布<sup>2</sup>を  $q(\mathbf{e}_{u,\Lambda})$  とし、全ユーザの行動履歴に対する経験分布  $q(\mathbf{e}_{\mathcal{U} \times \Lambda})$  を式(8)と定義する。

$$q(\mathbf{e}_{\mathcal{U} \times \Lambda}) = \prod_{u \in \mathcal{U}} q(\mathbf{e}_{u,\Lambda}) \quad (8)$$

ユーザの行動履歴とは、ユーザが実際に移動した経路を辺ベクトルにより表し、それらを集めた集合のことである。

式(6)と式(8)を用いて、KL 情報量  $D_{\text{KL}}$  を式(9)で与える。

$$D_{\text{KL}} = - \sum_{\mathbf{e}_{\mathcal{U} \times \Lambda}} q(\mathbf{e}_{\mathcal{U} \times \Lambda}) \ln p(\mathbf{e}_{\mathcal{U} \times (\Lambda \setminus L)} | \mathbf{e}_{\mathcal{U} \times L}) \quad (9)$$

<sup>2</sup>データセット中の各要素に対し、等しい確率値を与える。つまり、 $X$  をデータセットを構成する事例の集合としたとき、 $\forall e \in X, q(e) = \frac{1}{|X|}$  を満たす。

式(9)では、経路の終止点を構成する辺への添字の集合を  $L$  ( $\in \Lambda$ ) とし、この集合を用いて  $q$  から得られる経路の終止点と  $p$  で生成する経路の終止点が一致するよう定式化している。終止点が一致しているものについてのみ尺度を作ることで、行動履歴が存在しない辺のパラメータを推定することによるノイズが全体の推定過程に悪影響を及ぼすことを防ぐことができる。

$D_{\text{KL}}$  を小さくする  $w_{\mathcal{U} \times \mathcal{K}}, h_{\mathcal{E} \times \mathcal{K}}$  が尤もらしいパラメータであり、この最小化問題をモンテカルロ法と勾配降下法を用いた学習法により解くことで、パラメータの推定を行う。

### 3.2 学習法

$D_{\text{KL}}$  の最小値を解析的に求めることが困難であるため、本稿では勾配降下法を用いた学習法により最適なパラメータを求めるこれを提案する。また、その際必要となる  $D_{\text{KL}}$  の勾配は、Boltzmann 分布の状態数が膨大であることから、解析的に求めることは困難であるため、Markov Chain Monte Carlo (MCMC) 法 [4] を用いて近似的に求める。

#### 3.2.1 KL 情報量の勾配

ここでは勾配降下法に用いる KL 情報量のパラメータについての勾配の導出結果を示す。

$w_{u,k}$  に対する  $D_{\text{KL}}$  の勾配は、式(10)となる。ただし、命題  $P$  に対し、 $\delta(P)$  は  $(P \Rightarrow \delta(P) = 1) \wedge (\neg P \Rightarrow \delta(P) = 0)$  を満たし、 $f'_d(e, u)$  は式(12)により定義される。

$$\frac{\partial D_{\text{KL}}}{\partial w_{u,k}} = -\frac{1}{kT} \sum_{e \in \mathcal{E}} \sum_{\mathbf{e}_{u,\Lambda}} \sum_{i \in \Lambda \setminus L} f'_d(e, u) h_{e,k} \delta(e = \mathbf{e}_{u,i}) \{ q(\mathbf{e}_{u,\Lambda}) - p(\mathbf{e}_{u,\Lambda \setminus L} | \mathbf{e}_{u,L}) q(\mathbf{e}_{u,L}) \} \quad (10)$$

$h_{e,k}$  に対する  $D_{\text{KL}}$  の勾配は式(11)となる。

$$\frac{\partial D_{\text{KL}}}{\partial h_{e,k}} = -\frac{1}{kT} \sum_{u \in \mathcal{U}} \sum_{\mathbf{e}_{u,\Lambda}} \sum_{i \in \Lambda \setminus L} f'_d(e, u) w_{u,k} \delta(e = \mathbf{e}_{u,i}) \{ q(\mathbf{e}_{u,\Lambda}) - p(\mathbf{e}_{u,\Lambda \setminus L} | \mathbf{e}_{u,L}) q(\mathbf{e}_{u,L}) \} \quad (11)$$

$$f'_d(e, u) = f_c(e) \operatorname{sech}^2 \left( \sum_{k \in \mathcal{K}} w_{u,k} h_{e,k} \right) \quad (12)$$

#### 3.2.2 勾配降下法

式(10)、式(11)で得られた勾配により、式(13)の更新式でパラメータを更新する。

$$\theta(t + \Delta t) = \theta(t) + \Delta t \left\{ -\frac{\partial D_{\text{KL}}}{\partial \theta} - \lambda \theta(t) \right\} \quad (13)$$

$\Delta t$  は学習係数であり、 $\lambda$  は重み減衰係数である。式(13)では一般的に表記しており、 $\theta \leftarrow w_{u,k}, h_{e,k}$  を代入することでそれぞれの更新式を得ることができる。

式(10), 式(11)の  $p(\mathbf{e}_{u,A \setminus L} | \mathbf{e}_{u,L}) q(\mathbf{e}_{u,L})$  に関する期待値の計算は指標時間の計算量を必要とし, 厳密な算出が困難である. これに対し, 本稿では, Boltzmann Machine (BM) [7] の学習法と同様のアプローチにより, この期待値を MCMC 法により近似する. このとき, 目的関数の値が同程度となる経路は複数存在すると考えられ, それらを網羅的に生成しなければ, この期待値を正しく計算できないため, 同じユーザを多数複製し, 並列して計算することで標本数を確保する必要があると考える.

式(13)では,  $p(\mathbf{e}_{u,A \setminus L} | \mathbf{e}_{u,L}) q(\mathbf{e}_{u,L})$  に関する期待値と  $q(\mathbf{e}_{u,A})$  に関する期待値の差に比例したパラメータの更新が行われる. つまり, ユーザの行動履歴に含まれる辺は高価値, 含まれない辺は低価値となるように更新される. また,  $L$  により  $p(\mathbf{e}_{u,A \setminus L} | \mathbf{e}_{u,L})$  に従う  $\mathbf{e}_{u,A \setminus L}$  に含まれる経路は終止点が固定されているため, 制約値から通る可能性の無い辺上の価値が修正されることはない, また, 辺の価値を考慮しなければ通る可能性が十分に高いにもかかわらず, ユーザの行動履歴に含まれない辺については低価値となるように更新される. しかしながら, あるユーザの行動履歴に含まれなかつたとしても, 他のユーザの行動履歴に含まれていれば, 協調フィルタリングの効果により価値の値が高く推定される可能性もあると考える. これにより, ユーザあたりについて少ない行動履歴であっても, たくさんのユーザについて集めれば, 妥当なパラメータの推定を行うことが可能であると考える.

### 3.2.3 学習時の温度について

BM のエネルギー関数では, パラメータと  $T$  が線形に結合していることから,  $T$  の違いが学習時にパラメータへ吸収されるため,  $T = 1$  とすることが一般的である[7]. しかしながら本稿で扱うモデルでは, 学習で決定するもの以外にもパラメータがあるため,  $T$  の値が学習結果に影響を及ぼす. これについて設定方法を考案する必要があり, 本稿では, 総経路長を制約値より短くするもののうち, できるだけ大きな  $T$  を用い学習を行うことを提案する. 学習される  $f_d$  は,  $f_d(e) < f_c(e)$  の制約より,  $C_c$  以上の経路長となる場合に, 経路に影響を及ぼすほどの値とはならない. しかしながら, 制約値を満たす経路長となる  $T$  を用いれば,  $f_d$  には経路を左右する効果をもつものが存在することとなり, ユーザの行動履歴を反映するように価値の推定が行われると考える. この学習結果を用いた上で, 推論時には学習時に用いた  $T$  よりも低い値まで温度を低下させることで, 学習された価値の値は経路を決定するのに十分な効果を持つことを保証できると考える.

### 3.2.4 その他のパラメータ

式(2)では,  $\phi$  の定式化に  $C_c, \sigma^2$  がパラメータとして含まれている.  $C_c$  についてはデータセット中の経路長をそのまま用いるとし,  $\sigma^2$  を経路データのみから推定することは困難であるため, 学習時には  $\sigma^2 = 0$  とする.  $k$  は探索を十分に行える程度に大きな値を全ユーザに共通で設定するが[3], 設定のために必要となるのは  $f_c$  の分布だけであり,  $f_d$  に依存しないため, 学習時にも予め求めておく固定の値を用いる.

## 4 まとめ

辺ベクトルと確率モデルによる経路生成の定式化を用いた経路推薦手法における, スポットの価値を推定する手法を提案した. 行列分解ベースの協調フィルタリングと同様のモデル化に対するパラメータの推定手法として, 本手法が確率モデルとして定式化されている利点を活用し, モンテカルロ法による学習法を提案した. 今後, 人工データセットによる実験を行うことで, 手法全体を洗練するとともに, どの程度の行動履歴が学習を妥当に行うために必要であるのか検討する予定である.

## 参考文献

- [1] Lim, K., Chan, J., Karunasekera, S.: Personalized itinerary recommendation with queuing Time awareness, Proc. of the 40th International ACM SIGIR Conference, pp. 325-334, 2017.
- [2] 松田善臣, 名嘉村盛和, 姜東植, 宮城隼夫: 最適観光経路問題とその解法, 電気学会論文誌 C, Vol. 124, No. 7, pp. 1507-1514, 2004.
- [3] 柴田祐樹, 高間康史: 辺ベクトルを用いた経路推薦問題の解法における目的関数の改善に関する提案, 第 21 回 インタラクティブ情報アクセスと可視化マイニング研究会, 2019.
- [4] Metropolis, N., Rosenbluth, A., Rosenbluth, M., Teller, A.: Equation of state calculations by fast computing machines, The Journal of Chemical Physics, Vol. 21, No. 6, pp. 1087-1092, 1953.
- [5] Geman, S., Geman, D.: Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of Images, IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol. PAMI-6, No. 6, pp. 721-741, 1984.
- [6] Shibata, H., Takama, Y.: Index-based notation for random variable and probability space, Journal of Advanced Computational Intelligence and Intelligent Informatics, Vol. 23, No. 4, 4 pages, 2019.
- [7] Shibata, H., Takama, Y.: Crystallizing effect of simulated annealing on Boltzmann machine, Journal of Advanced Computational Intelligence and Intelligent Informatics, Vol. 23, No. 3, 11 pages, 2019.
- [8] Koren, Y., Bell, R., Volinsky, C.: Matrix factorization techniques for recommender systems, Computer, , Vol. 42, No. 8, pp. 30-37, 2009.