行動時刻を考慮した条件付き変分オートエンコーダによる推薦システム

Time-Sequential Variational Conditional Auto-encoders for Recommendation

保住 純
Jun Hozumi

東京大学
The University of Tokyo
hozumi@weblab.t.u-tokyo.ac.jp

岩澤 有祐
Yusuke Iwasawa

(同上)
iwasawa@weblab.t.u-tokyo.ac.jp

松尾 豊
Yutaka Matsuo

(同上)
matsuo@weblab.t.u-tokyo.ac.jp

keywords: recommendation system, variational auto-encoder, time information, deep learning

Summary

In this study, we propose a method for adding time of action information to a Variational Auto-encoder (VAE)-based recommendation system. Since time of action is an important information to improve the accuracy of recommendation, many methods have been proposed to use the information of time of action, such as purchase or review of a product, for recommendation. And VAE-based recommendation systems have been reported to be more accurate and robust for small data sets compared to traditional deep learning-based recommendation systems. Existing research on introducing time information into VAEs includes a method of weaving information on the order in which products are preferred by passing the encoding layer consisting of RNN, but the time information of the product preferred is not considered. If the absolute time information is not taken into account when recommending a product, for example, when a temporary boom causes many users to prefer a particular product, it may be judged to be a preference based on the user's preferences, which may adversely affect the recommendation results. Based on the above problems, this study examines a VAE-based recommendation system to improve the recommendation accuracy by adding time information of each action to the input information, and finally proposes Time-Sequential VAE (TSVAE) and confirms its accuracy. In addition, to verify how to add time information to improve the accuracy, we conducted experiments using multiple models with and without absolute time information and different encoders of time interval information, and evaluated the accuracy.

1. はじめに

推薦において行動時刻は精度向上に寄与する重要な情報であるので、これまでに商品の購入や商品のレビューなどの行動をした時刻の情報を推薦に用いる手法が提案されている [Pavlovski 20, Zhu 17]. 一般に、推薦システムの研究ではユーザの購入した商品の情報にユーザの性別や年代といった属性情報や使用している端末の情報などを条件として用いることで推薦精度を高める文脈考慮型推薦システム (Context-Aware Recommender Systems) がこれまでに数多く提案されている [Adomavicius 11]. さらに、これらの情報は入力方法によって大きく推薦精度が変化するため、どのように付与すればよいかについても研究が行われている [Beutel 18].

本研究では、Variational Auto-encoder (VAE) [Kingma 13] ベースの推薦システムに行動の時刻情報を付与する方法を提案する。VAE は深層学習による生成モデルの一種

であり、エンコーダによって入力データから潜在変数の分布の平均や分散を学習し、デコーダによってこの分布からサンプリングした潜在変数から再び入力データと似たデータを復元する手法である。近年では深層学習をベースとした推薦システムの研究においても VAE をベースとした手法が注目されつつある。VAE を用いた推薦システムは、ユーザが各商品に関して行動していたか否かを記録した行動履歴データをエンコーダに入力し、それとデコーダからの出力との差分を見る。その際に、出力結果では復元されているが実際の入力には含まれていなかった商品が、本来関与されていて然るべき商品であったとみなし、そのような商品を推薦していく。VAE ベースの推薦システムは、従来の深層学習を用いた推薦システムに比べ、より小さいデータセットに対する精度が向上し、頑健性も高まることが報告されている [Liang 18]. しかし、[Liang 18] など既存の VAE ベースの推薦手法では、

好んだ商品の情報が順序や時刻を無視した Bag-of-Words 形式で与えられるため、その時刻や時間間隔は無視されてしまっている。そこで、本研究では VAE ベースの推薦システムの精度を時刻情報を考慮することで改善することを目的とする。

時刻情報を VAE に織り込む既存研究として、RNN によるエンコード層を通すことによって商品を好んだ順序の情報を織り込む手法 [Sachdeva 19] が挙げられる。しかし、[Sachdeva 19] では、その商品を好んだ時刻情報は考慮されていない。推薦時に絶対時刻の情報が考慮されていないと、たとえば、一時的なブームによって特定の商品が多くユーザによって好まれる事態が生じた際に、そのユーザの嗜好による選好であると判断され、推薦結果に悪影響を及ぼしてしまう可能性がある。他にも、複数行動の時刻の差である時間間隔情報が考慮されていないと、特に酒類やコンテンツのような時間の経過とともに成熟度が変わることによって趣味嗜好の対象が変化すると考えやすい種類の商品カテゴリを推薦する場合 [McAuley 13] に、観測された行動に反映されていないユーザの内部状態の変遷を追うことができないため、その影響が適切に推薦に反映されない可能性がある。

以上の問題を踏まえ、本研究では入力とする情報に各行動の時刻情報を付与することで推薦精度を高める VAE ベースの推薦システム (Time-Sequential VAE; TSVAE) を提案し、その精度を確認する。また、時刻情報をどのように付与していけば精度の向上に寄与するかを検証するために、絶対時刻情報の有無や時間間隔情報を織り込むエンコードの違いによる複数のモデルを用いた実験を行った。本研究では、提案手法の有効性を確認するために、以下の検証実験を行った。

- [Sachdeva 19] では系列情報を VAE に入力する前のエンコーダとして RNN を用いるが、そこに時間情報を考慮する RNN である Time-LSTM [Zhu 17] を採用し、行動間の時間情報を RNN エンコード前の表現に織り込む手法を検討した。検証実験の結果、時刻情報を取り入れることで推薦精度が向上することが確認された。
- VAE を用いた推薦システムを拡張した CVAE [Sohn 15] による推薦システムによる手法を導入し、その入力条件に最新の行動の時刻情報を用いる手法を検証した。検証実験の結果、単純に時刻情報を条件とした CVAE を用いることによって、単純な VAE による推薦システムに比べて精度が向上することが確認された。
- 以上で検討した手法でより良い結果を残した構造を組み合わせ、精度を向上する手法 (TSVAE) を提案する。この結果、上記の既存手法に比べてより良い精度を記録することが確認された。
- VAE デコーダからの出力時において、商品情報だけではなく時刻情報を同時に再構成する手法を検証し

た。実験の結果、この方法では推薦精度が上がらないことが確認された。

本論文の構成は以下の通りである。2 章では、本研究に関連する研究を説明する。3 章では、提案手法の構成する基礎となる手法の概要を述べる。4 章では、前章の内容を踏まえ、提案手法の詳細について説明する。5 章では、複数の実データセットを用いた検証実験を行い、提案手法の性能を比較対象となる手法と比較することで確認する。6 章ではこれまで実験結果を踏まえて、今後の研究のための考察を行う。最後に、7 章で本研究の総括を述べる。

2. 関連研究

2.1 付加情報を使用した推薦システムの研究

ユーザに推薦をする際にその推定のための情報源として用いるデータは、多くの場合、ユーザの商品の購買履歴や、高評価レビューのログといったユーザごとの行動履歴データである。そして、その他にも推薦精度の向上に寄与すると考えられる情報を推薦時に活用することができれば、推薦システムの精度が向上できることが期待される。このことから、これまでに様々なユーザの購買や評価に関するデータが推薦時に付加する情報として検討され、それが推薦に与える有効性について検証されてきた。たとえば、これまでにユーザごとの履歴データの他に商品の画像情報を加える [Kang 17]、レビュー文章の情報を加える [Zheng 17]、SNS 上のユーザのつながりの情報を加える [Zhao 17]、直前のアクションからの時間間隔を加える [Zhu 17] といったものが挙げられる。特に、近年では深層学習を用いることによって様々な情報を似た形式の内部表現として取り扱うことができるようになったため、これらをまとめて推薦に活用するマルチモーダル推薦 [Liu 19] の試みも行われている。以上の研究から分かる通り、商品やユーザのログデータに関連する様々な種類や形式のデータが、推薦システムの精度向上に利用できる可能性があると言える。

また、これらの情報を単純に行動履歴データと同時に入力するのではなく、その入力方法やタイミングを工夫することによって推薦精度を向上させる研究も存在する。たとえば、[Cheng 16] は追加する情報を履歴データとは別に学習し、最後の層の直前に履歴データ側と組み合わせることによって推薦に使用し、精度の向上を確認している。他にも、[Beutel 18] では、ログデータに対し RNN モデルを通す前および後でこれらの情報を文脈 (Context) 情報として付与する手法がとられている。[Beutel 18] ではこれらの情報を入力する箇所を工夫することによって何層ものネットワークの追加に相当する精度の向上が見込まれることが報告されているため、このような情報付与の方法に関する研究は、推薦システムの研究においても重要性があると考えられる。

2.2 VAE を用いた推薦システムの研究

伝統的な推薦システムの手法の考え方には、アイテムベースや協調フィルタリング、Matrix Factorization など様々なものが挙げられるが、これらの考え方を踏襲しつつ、それらのモデルの一部に深層学習を取り入れることによって、より推薦精度を高めた手法が提案されている。たとえば、[He 17] は多層パーセプトロンを用いた協調フィルタリングによる手法であり、[Xue 17] は Matrix Factorization の一部に深層学習を活用している。

それらのアプローチの中には、VAE をベースとした手法がある。[Liang 18] は協調フィルタリングを拡張する推薦手法である。VAE を用いた推薦システムは、ユーザの行動履歴データを入力し、それと VAE のデコーダからの出力との差分をとることで、その足りない部分の商品を推薦する。VAE ベースの推薦システムは、従来の深層学習を用いた推薦システムに比べて、より小さいデータセットに対する精度が向上し、少しの行動の変化によって推薦結果が大きく悪影響を受けないという、頑健性の向上といったメリットも報告されている [Liang 18]。

他にも、単純な VAE を発展させ、さらに精度を向上させる手法が提案されている。たとえば、[Sohn 15] は、エンコーダとデコーダの入力に条件を付与することで、より再構成誤差を小さくすることができる。このように工夫がなされた VAE を用いた推薦システムの研究も進められている。たとえば、ユーザの行動履歴の順序を考慮して予測に活用できるようにするために、系列情報を扱うよう拡張された手法である SVAE が提案されている [Sachdeva 19]。ただし、[Sachdeva 19] では行動の順序のみが考慮されており、各行動の絶対時刻は考慮されない。そのため、前章で述べたように、推薦時に用いる情報に行動の時間の情報を取り入れることができれば、商品の購入間隔や商品カテゴリに対するユーザの成熟度といった各行動間の時間間隔による情報が取り入れられるようになるため、さらなる推薦精度の向上が期待される。本研究では、エンコーダに時間情報を考慮する Time-LSTM [Zhu 17] を導入することで、精度が向上するかどうかを検証する。さらに、SVAE における VAE 部分に条件付き VAE を使用し、その条件に行動時刻の情報を導入することによって、さらに精度を高める手法を提案する。

3. 前 提 知 識

本章では、本研究で提案する手法の一部分として用いられている手法について解説する。

3.1 Sequential Variational Auto-encoder (SVAE)

変分オートエンコーダ (Variational Auto-encoder; VAE) とは、通常のオートエンコーダと同様のエンコーダとデコーダの構造を持つ深層学習を用いた生成モデルである [Kingma 13]。通常のオートエンコーダは、エンコーダに

より入力 x から潜在変数 z に変換し、それからデコーダにより x の予測値として $\hat{x}$ を復元、 x と $\hat{x}$ 間の再構成誤差が小さくなるように学習を進める。しかし、VAE では、その潜在変数が確率分布 $\mathcal{N}(0,1)$ に分布に従うことを仮定し、潜在変数の平均 μ および分散 σ を入力データより学習する。そして、VAE は生成モデルであるのでデータの分布 $p(x)$ を推定するよう学習を進めるが、その尤度を直接最大化することはできないため、以下のような式変形を行う。ただし、 E は期待値、 $q(z|x)$ は近似事後分布、 D_{KL} は KL ダイバージェンスを表す。

$$\begin{aligned}\log p(x) &= \int q(z|x) \log p(x) dz \\ &= \int q(z|x) \log \frac{p(x|z)p(z)}{p(z|x)} dz \\ &= \int q(z|x) \log p(x|z) dz \\ &\quad + \int q(z|x) \log \frac{q(z|x)}{p(z|x)} dz \\ &\quad - \int q(z|x) \log \frac{q(z|x)}{p(z)} dz \\ &= E[\log p(x|z)] + D_{KL}(q(z|x)||p(z|x)) \\ &\quad - D_{KL}(q(z|x)||p(z))\end{aligned}$$

最終的にこの式を整理することによって、以下の式を得られる。左辺に表されている尤度を最大化を目指すために、右辺の変分下界 (Evidence Lower Bound; ELBO) の最大化問題を解く。VAE の学習は、この変分下界の最適化問題として実行される。

$$\begin{aligned}\log p(x) - D_{KL}[q(z|x)||p(z|x)] \\ = E[\log p(x|z)] - D_{KL}[q(z|x)||p(z)]\end{aligned}$$

その入力データが系列データとなった SVAE [Sachdeva 19] も、VAE と同様にデコーダによって復元された系列データとの復元誤差が小さくなるようにエンコーダとデコーダの学習を進める。ただし、系列はエンコーダに一度に直接入力するのではなく、系列の順で逐次的に RNN によるエンコーダを通し、その出力を VAE エンコーダ ϕ に入力していく。その後、VAE と同様に VAE デコーダから出力する。デコード時は RNN を通すことはせず、VAE デコーダからの出力をそのまま結果とする。そのため、系列データの順序に関する情報が RNN エンコーダを通した際に織り込まれることによって、VAE によって復元された系列にも反映されると考えられる。ただし、通常の VAE とさらに異なる点として、 x が正規分布ではなく多項 (マルチヌーイ) 分布に従うと仮定することが挙げられる。また、[Sachdeva 19] では RNN エンコーダに Gated Recurrent Unit (GRU) を採用している。

図 1 Time-LSTM(3) の模式図

$$\mu(m), \sigma(m) = \varphi(h_m)$$

$$h_m = \text{RNN}(h_{m-1}, x_{(m-1)})$$

3.2 Conditional Variational Auto-encoder (CVAE)

通常の VAE では入出力の復元対象とする x は $x \sim p(x|z)$ として表されるが、それに条件 c を付け $p(x|z, c)$ に拡張したものを考える。それは CVAE [Sohn 15] と呼ばれる。具体的には、期待値を E 、目的関数を $\mathcal{L}_{\text{CVAE}}$ として以下の式で表される。

$$\begin{aligned} \log p(x|c) &\geq \int \log p(c|x, z) p(z|x) dz \\ &= -D_{KL}(q(z|x, c) \| p(z|c)) \\ &\quad + E[\log p(x|z, c)] \\ &\equiv \mathcal{L}_{\text{CVAE}}(x, c, p, q) \end{aligned}$$

学習の対象が条件付き尤度に拡張されても、エンコーダやデコーダの形状は入力に条件を付与する変更のみでよく、その学習も VAE と同様に変分下界の最大化によって進めることができる。

3.3 Time-LSTM

通常の再帰的ニューラルネットワーク (Recurrent Neural Network; RNN) は系列データをその順番に入力しているが、その系列データが順序のみを考慮すればよい自然言語文ではなく、行動履歴のようなそれぞれの要素に時刻が定義でき、それらに異なる時間間隔があるようなデータの場合、その情報は無視されてしまう。そこで、その時間間隔を同時に入力データとして考慮するゲート付き RNN である Time-LSTM [Zhu 17] が提案された。[Zhu 17] の論文では Time-LSTM のいくつかのバリエーションが提案されているが、本研究では [Zhu 17] にて最も良い精度を示していた Time-LSTM(3) を用いる。

これより、本提案手法で使用する Time-LSTM(3) の概要を紹介する。まず、重みを W 、バイアス項を b 、セルを c 、セルの重みを w 、入力ゲートを i 、出力ゲートを o と表記すると、Time-LSTM(3) は以下の式で表される。ただし、 σ は活性化関数を表し、 $\sigma_i, \sigma_{\Delta t}, \sigma_o$ はシグモイド関数、 σ_c, σ_h は $\tanh$ 関数である。また、 $\odot$ は要素積 (アダマール積) を表す。

$$i_m = \sigma_i(x_m W_{xi} + h_{m-1} W_{hi} + w_{ci} \odot c_{m-1} + b_i) \quad (1)$$

$$T1_m = \sigma_1(x_m W_{x1} + \sigma_{\Delta t}(\Delta t_m W_{t1}) + b_1)$$

$$\text{s.t. } W_{t1} \leq 0 \quad (2)$$

$$T2_m = \sigma_2(x_m W_{x2} + \sigma_{\Delta t}(\Delta t_m W_{t2}) + b_2) \quad (3)$$

$$\begin{aligned} o_m &= \sigma_o(x_m W_{xo} \\ &\quad + \Delta t_m W_{to} + h_{m-1} W_{ho} + w_{co} \odot c_{m-1} + b_o) \end{aligned} \quad (4)$$

$$\begin{aligned} \tilde{c}_m &= (1 - i_m \odot T1_m) \odot c_{m-1} + i_m \odot T1_m \\ &\quad \odot \sigma_c(x_m W_{xc} + h_{m-1} W_{hc} + b_c) \end{aligned} \quad (5)$$

$$\begin{aligned} c_m &= (1 - i_m) \odot c_{m-1} + i_m \odot T2_m \\ &\quad \odot \sigma_c(x_m W_{xc} + h_{m-1} W_{hc} + b_c) \end{aligned} \quad (6)$$

$$h_m = o_m \odot \sigma_h(\tilde{c}_m) \quad (7)$$

Time-LSTM では、一般的な LSTM で入力される x_m, h_m の他に、ユーザの各行動ごとにそのユーザの直前のアクション x_{m-1} からの時間間隔 Δt を導入する。 Δt を出力に作用させる方法には様々なものが考えられるが、 Δt をより効果的に出力に反映させるために、Time-LSTM(3) では Δt を、直接出力に影響を与えられる出力ゲート o_m の他に、 Δt の直近の推薦への影響を制御する時間ゲート $T1_m$ と Δt の影響を長期にわたって保持するための時間ゲート $T2_m$ を導入して、それらに入力していく。ユーザの直近 (短期) の興味が x から入力されるのに対し、 Δt が入出力ゲートに作用されるとともにそれぞれのセル c_m や $\tilde{c}_m$ にも作用されるため、 Δt の影響が長期間にわたって保持できるようになっている。そして、一般的な LSTM において忘却ゲートとして用いられる機構は、Time-LSTM(3) では、GRU と類似した入力ゲートを用いた機構である $1 - i_m$ に置き換えられている。これを模式図で表すと、図 1 となる。

4. 提案手法

前章の内容を踏まえて、本章では時刻に関する情報を推薦時に織り込む VAE ベースの推薦システム (Time-Sequential Variational Auto-encoder; TSVAE) を提案する。モデル全体の概要を図 2 に示す。具体的には、TSVAE は SVAE [Sachdeva 19] をベースとし、時間情報 Δt を織り込むために RNN エンコーダに Time-LSTM(3) を、時刻情報 t を織り込むために、VAE エンコーダおよびデ

図2 提案手法の模式図

コーダに Conditional VAE を採用したモデルである。実際の推薦タスクを行う際も [Sachdeva 19] と同様に、VAE エンコーダの出力では評価されているが入力（実データ）では評価されていない商品をランキング化し、それらを上位から推薦する。

m を行動の順番とし、行動 x_m では商品 i_m に対し時刻 t_m において行動したものとする。まず、入力データの前処理としての変換 (Embedding) を行う。ID 形式で入力されている商品の系列を、ベクトル表現に変換する。また、時間情報 Δt には、[Zhu 17] でも提案されている通り、行動 x の間隔時間差を直接用いるのではなく、より推薦精度を高めることができるよう以下の式で表される時刻の差に対数をとったものに変換する。ただし、 $t_m = t_{m-1}$ のとき便宜上 $\Delta t_m = 0$ とし、 $\Delta t_1 = 0$ とする。

$$\Delta t_m = \log(t_m - t_{m-1}) \quad (8)$$

4.1 Time-LSTM による Δt のエンコーディング

次に、変換された系列データを SVAE と同じ要領で RNN エンコーダに入力する。SVAE では RNN エンコーダに GRU を採用していたが、本提案手法ではそれを Time-LSTM(3) に置き換える。そうすることで、RNN エンコーダを通した際に順序情報のみならず、 x 中に含まれる時間情報 Δt の情報もエンコードされ、推薦時に考慮されるようになると思われる。具体的には、以下の式で表される。

$$h_{m-1} = \text{Time-LSTM}_3(h_{m-1}, x_{m-1}, \Delta t_{m-1}) \quad (9)$$

4.2 t を条件とした CVAE による入力データの復元

Time-LSTM によるエンコーディングでは時間間隔情報 Δt しか反映されない。それだけでは、1 章で述べたように、一時的なブームによって特定の商品が多くのユーザーによって好まれる事態が生じた際に、そのユーザーの嗜好による選好であると判断され、推薦結果に悪影響を及ぼしてしまう可能性がある。そこで、VAE 側で時刻情報 t を条件として取り入れるようにすることで、その入力の絶対時刻の情報が推薦時に反映できるようにする。SVAE では VAE エンコーダおよびデコーダが通常の VAE であったが、これを時刻を条件とした CVAE に置き換える。RNN エンコーダを通した入力 h_m と VAE エンコーダ φ を通じて得られた潜在変数 z に VAE にユーザーの行動履歴の最新の行動時刻 t_m を条件として付与し、それを VAE デコーダ ϕ に入力することによって最終的にユーザーの行動履歴を復元する。具体的には、以下の式で表される。ただし、 $\mathcal{N}(\mu, \sigma)$ は平均 μ 、分散 σ の正規分布を表す。

$$\mu_{m-1}, \sigma_{m-1} = \varphi(h_{m-1}, t_{m-1}) \quad (10)$$

$$z_{m-1} \sim \mathcal{N}(\mu_{m-1}, \sigma_{m-1}) \quad (11)$$

$$\hat{i}_m = \phi(z_{m-1}, t_{m-1}) \quad (12)$$

以上の方法で t や Δt に関する情報を付与することに

表 1 データセットの概要

データセット	ユーザ数	商品数	平均データ長
MovieLens	2597	705	39.86
LastFM	149	3898	1224
Amazon (Beauty)	16880	32892	8.22
Goodreads	59290	30268	24.94

よって、VAE ベースの推薦システムにユーザの各行動の時間間隔やその絶対時刻といった情報が反映され、従来の SVAE より推薦精度の向上につながると考えられる。

5. 実験

5.1 実験設定

本章では、ユーザの行動時刻情報や提案手法によるその付与の方法の有効性を検証するために、実際の行動履歴データを用いた推薦タスクに、GRU, LSTM, Time-LSTM(3), Latent Cross, CVAE, そして提案手法である TSVAE を用いた推薦システムを用意し、それらを用いてタスクを実行した。これらの中では CVAE のみ唯一 RNN エンコーダが用いられておらず、GRU, LSTM および CVAE は Δt の情報が推薦に反映されない。また、Latent Cross は入力 i_m と条件 Δt_m との要素積を取ったものを RNN に入力していく手法である。さらに、提案手法である TSVAE については、VAE デコーダの出力に時刻の系列 t_n も復元するように誤差の計算方法を変更し、それらも正しく再構成されるようにしたモデルも作成し、精度を比較検証した。どのモデル、データセットも共通して、それぞれ 30 epoch ずつ学習させた。最適化アルゴリズムには Adam を採用し、VAE エンコーダ、デコーダはそれぞれ三層で、25%の DropOut を実行した。

5.2 データセット

本検証実験で用いるデータセットには、映画のレビューサイトのデータセットである MovieLens-1M^{*1}、およびインターネットラジオをベースとした SNS のデータセットである Last.fm の Million Song Dataset^{*2}、EC サイトのデータセットである Amazon (Beauty Products)^{*3}、書籍のレビューサイトのデータセットである Goodreads Datasets (Comics & Graphic) [Wan 18]^{*4}を用いた。データセットの概要を表 1 に記す。

§1 MovieLens

ユーザが 5 段階評価で 5 を付けた作品を本研究の対象とする行動であるとみなし、そのような行動を起こす作品を推薦するタスクとした。総評価数が 50 以上のユーザのみを対象とし、それらユーザから 100 人以上に評価された作品のみを推薦の対象とした。以上のフィルタリ

図 3 MovieLens データセット内での Δt の分布 図 4 Last.fm データセット内での Δt の分布

ングの結果、各推薦モデルは 705 本の作品から各ユーザが次にどの作品を評価するかを予測して推薦することになった。訓練データセットは 2197 件、バリデーションおよびテストデータセットはそれぞれ 200 件である。また、図 3 から分かるように、データセット内の多くのレコードで $\Delta t = 0$ となっており、 Δt の分布がべき乗則に従っているようにも見えることが分かる。これは MovieLens データセットでの t 自体は unixtime (秒単位) で記録されているものであり、同時に多数の作品を評価をした時刻が記録されている。このことから、これはユーザが実際に作品に評価をしたタイミングではなく、その評価情報が収集された時刻であると考えられる。そのため、同一ユーザの履歴の中で $\Delta t = 0$ で記録されている映画の順序については、暫定的に各映画に付与されている ID 順にした。なお、以降に述べるデータセットにおいても $\Delta t = 0$ であるものについては同様の処理をしている。

§2 Last.fm

このサービス上で実際に楽曲を聴くことを本研究の対象とする行動であるとみなし、そのユーザが次に聴く楽曲を推薦するタスクとした。総評価数が 5 以上 2000 以下のユーザのみを対象とし、それらユーザから 5 人以上に評価された作品のみを推薦の対象とした。以上のフィルタリングの結果、各推薦モデルは 3898 本の作品から各ユーザが次にどの曲を聴くかを予測して推薦すること

*1 <https://grouplens.org/datasets/movielens/1m/>

*2 <http://millionsongdataset.com/lastfm/>

*3 <https://www.kaggle.com/skillsmuggler/amazon-ratings>

*4 <https://sites.google.com/eng.ucsd.edu/ucsdbookgraph/home>

表 2 MovieLens 実験結果 (最も良い結果のものを太字で表記)

推薦手法	DCG@10	Recall@10	Precision@10	DCG@100	Recall@100	Precision@100
GRU	10.09	9.59	7.95	26.38	51.89	4.49
LSTM	10.70	10.59	8.85	25.96	51.26	4.35
Time-LSTM(3)	10.98	10.44	8.50	26.17	50.86	4.31
CVAE	10.01	9.59	7.95	25.93	51.34	4.39
Latent Cross	8.50	8.49	6.75	24.30	50.60	4.28
TSVAE	11.31	11.19	8.95	29.24	52.29	4.90

になった。訓練データセットは 89 件、バリデーションおよびテストデータセットはそれぞれ 30 件である。図 4 から分かるように、このデータセットでは MovieLens のようなデータのタイミングによって $\Delta t = 0$ となったデータは存在せず、MovieLens とは異なる分布を構成している。

§3 Amazon (Beauty Products)

このサービス上の 5 段階評価で 5 を付けた商品を本研究の対象とする行動であるとみなし、そのような行動を起こす商品を推薦するタスクとした。総評価数が 5 以上 2000 以下のユーザのみを対象とし、それらユーザから 5 人以上に評価された作品のみを推薦の対象とした。以上のフィルタリングの結果、各推薦モデルは 32892 種類の商品から各ユーザが次にどの商品の評価するかを予測して推薦することになった。訓練データセットは 13880 件、バリデーションおよびテストデータセットはそれぞれ 1500 件である。

§4 Goodreads Datasets (Comics & Graphic)

このサービス上の 5 段階評価で 5 を付けた書籍を本研究の対象とする行動であるとみなし、そのような行動を起こす書籍を推薦するタスクとした。総評価数が 5 以上 2000 以下のユーザのみを対象とし、それらユーザから 5 人以上に評価された作品のみを推薦の対象とした。以上のフィルタリングの結果、各推薦モデルは 30268 本の作品から各ユーザが次にどの書籍の評価するかを予測して推薦することになった。訓練データセットは 49290 件、バリデーションおよびテストデータセットはそれぞれ 5000 件である。

5.3 評価指標

評価実験において、各推薦モデルはユーザごとに作品を上位 $n = 10$ か $n = 100$ 本推薦し、それらに対して精度を評価する。精度の評価には、以下に挙げる DCG, Precision@ n , Recall@ n を採用した。

§1 Discounted Cumulative Gain (DCG)

DCG とは、推薦システムの提示した順位が実際の順位とどれだけ近いかを示す指標である。 r_i は i 番目に推薦した作品を評価したか否かを 0,1 で表す。DCG は大きい値をとるほど性能が良いことを示している。

$$DCG@n = \sum_{i=1}^n \frac{r_i}{\log_2(i+1)} \quad (13)$$

§2 Precision, Recall, F-Value

推薦した作品がどれだけ実際にユーザが評価したかを表す Precision (適合率) と、ユーザが推薦リスト中の作品を実際にユーザが評価した割合を表す Recall (再現率) を評価指標として用いる。言い換えるなら、Precision は正解率であり、Recall はどれだけ作品をカバーできたかを表す指標である。 $|R|$ は推薦したアイテム数を表す。どちらもより大きい値をとるほど性能が良いことを示している。

$$Hits = \sum_i r_i \quad (14)$$

$$Precision@n = \frac{Hits@n}{n} \quad (15)$$

$$Recall@n = \frac{Hits@n}{|R|} \quad (16)$$

5.4 実験結果

実験結果を、MovieLens については表 2, Last.fm については表 3, Amazon については表 4, Goodreads については表 5 に記す。既存手法はデータセットが異なると精度の良し悪しに違いが現れているが、提案手法である TSVAE については、他のいずれの既存手法に比べても今回設定した多くの評価指標でより高い精度を示す結果が出たことが確認された。

比較対象とした手法について注目すると、Time-LSTM(3) は、MovieLens データセットでは精度が高いが、Last.fm データセットについては、 Δt をエンコードしない GRU や LSTM に比べて精度が低い結果となっている。このことから、元々の Time-LSTM(3) では、 Δt の情報が精度に活かしていない可能性がある。その原因としては、実験に使用できたデータセット内のユーザの総数が少なかったことが考えられる。提案手法である TSVAE では小さいデータセットに対しても精度を出せる VAE による推薦を取り入れているため、良い精度が出せたと考えられる。

また、Latent Cross [Beutel 18] は、MovieLens データセットでは他の手法と比べて精度が同程度か低い結果と

表 3 Last.fm 実験結果 (最も良い結果のものを太字で表記)

推薦手法	DCG@10	Recall@10	Precision@10	DCG@100	Recall@100	Precision@100
GRU	2.38	1.07	2.33	3.12	4.27	1.10
LSTM	1.93	0.62	2.00	3.20	4.91	1.67
Time-LSTM(3)	1.89	0.66	1.33	2.29	2.50	0.76
CVAE	1.31	0.30	1.40	1.32	2.46	0.70
Latent Cross	4.46	1.62	3.00	3.72	4.85	1.07
TSVAE	4.31	2.30	3.40	4.24	5.29	1.90

表 4 Amazon (Beauty) 実験結果 (最も良い結果のものを太字で表記)

推薦手法	DCG@10	Recall@10	Precision@10	DCG@100	Recall@100	Precision@100
GRU	1.73	0.22	1.17	1.66	3.17	0.53
LSTM	1.71	0.14	1.20	1.45	3.66	0.72
Time-LSTM(3)	1.51	0.39	1.11	1.94	3.42	0.56
CVAE	1.31	0.41	1.25	2.64	4.13	0.72
Latent Cross	1.72	0.58	1.47	3.05	4.10	1.01
TSVAE	1.83	0.61	1.61	3.16	4.19	1.14

なっているが、Last.fm データセットでは、TSVAE に近い高い精度を示している。これは、Latent Cross が Δt の情報が正確にデータに反映されている場合には有効であるが、そうでない場合には精度を下げてしまうことを示唆していると言える。それに対して TSVAE では、どちらのデータセットでも高い精度を示している。

次に、TSVAE を用いた推薦において、CVAE デコーダで再構成する対象として商品 i_n の系列だけではなくその時刻の系列 t_n も対象とし、その再構成誤差の損失関数が小さくなるようモデルを学習させた。そして、Last.fm データセットにおいて他のモデルと同様の推薦実験を行った。その実験結果を表 6 に記す。結果から見て分かる通り、CVAE によって時刻を再構成しないモデルのほうが精度が高くなることが確認された。再構成誤差を小さくする対象を商品のみに限定したほうが、最終的に商品の再構成の精度が高まることが示唆される。

6. 考 察

検証実験によって、RNN エンコーダに Time-LSTM を採用し、VAE に時刻を条件づけた CVAE を用いた提案手法である TSVAE のほうが、他の既存手法に比べて精度が高くなることを示せた。

MovieLens における実験では、RNN エンコーダに時間情報を用いない単純な GRU や LSTM のほうが、時間情報を用いる Time-LSTM に比べて精度が高かった。このことから、正確な行動時刻情報をサンプリングできていないデータセットについては、学習時に時間情報がノイズになってしまっている可能性が考えられる。ただし、時刻情報を用いた本提案手法 TSVAE では、そのいずれの手法よりも精度が勝っていることから、たとえ時間情報が正確に反映されていないデータセットであっても、時

刻情報を学習時に取り入れることができれば、推薦精度の向上につながられることが考えられる。

また、Last.fm データセットにおける実験結果が他と比べて良かったことから、データセット内の時刻のばらつきがあるほど本提案手法の有効性が示されることが示唆される。特に、時間情報を直接学習データに掛け合わせることで学習に反映させる Latent Cross の性能が他のデータに比べて高かった。このことから、時間情報がより正確に収集できている場合には Latent Cross によるシンプルな特徴量の活用も有効であることが示唆される。

以上より、時間情報 Δt を活用することが推薦時には有効であり、推薦システムもそれを活用できるようにすることによって精度を向上させることができることが考えられる。ただし、時間情報が正確に収集されていないデータセットや、行動と紐づいた時間情報にばらつきがない場合は、それを推薦時に用いることが精度を低下させる要因となる可能性があるため、本手法を適用する際にはデータセット内の Δt の収集状況やその分布をあらかじめ確認しておくことが必要であると考えられる。一方で、もしデータ収集の都合で正確な時間情報が得られていない場合においても、その（絶対）時刻 t の情報を取り入れることによって、精度を高めることができると考えられる。以上より、これらをどちらも推薦時に活用する本提案手法である TSVAE は、時間に関する情報を十分に活用して推薦精度を高めた手法であると言える。

本提案手法の制約として、より未来の時刻における予測になると精度が低下していくことが考えられる。これは、学習に用いたデータセットより先の時刻を条件として本手法を適用した場合に、学習されていない将来の流行の影響などが推薦結果に反映されなくなるからである。学習に用いたデータセットの時刻より先の時刻においても推薦精度が担保されるようにすることは、今後の研究

表 5 Goodreads 実験結果 (最も良い結果のものを太字で表記)

推薦手法	DCG@10	Recall@10	Precision@10	DCG@100	Recall@100	Precision@100
GRU	1.51	0.47	1.15	1.94	3.71	0.93
LSTM	1.51	0.42	1.46	1.92	3.82	0.98
Time-LSTM(3)	1.10	0.57	1.49	2.25	3.85	0.93
CVAE	1.41	0.53	1.13	2.70	4.12	1.04
Latent Cross	1.82	0.57	1.26	2.84	4.01	1.14
TSVAE	2.04	0.68	1.69	3.29	4.20	1.23

表 6 TSVAE 時刻情報の再構成の有無による比較実験 (Last.fm, 最も良い結果のものを太字で表記)

再構成対象	DCG@10	Recall@10	Precision@10	DCG@100	Recall@100	Precision@100
x	4.31	2.30	3.40	4.24	5.29	1.90
x, t	2.21	1.62	2.40	3.64	3.36	0.70

課題である。

7. ま と め

本研究では、入力とする情報に各行動の時刻情報を付与することで推薦精度を高める VAE ベースの推薦システムを検討し、最終的に TSVAE を提案し、その精度を確認した。商品系列情報を VAE に入力する前のエンコーダとして Time-LSTM [Zhu 17] を採用し、VAE を用いた推薦システムを拡張し時刻情報を条件とした CVAE を導入することによって、単純な VAE による推薦システムや条件付き推薦システムに比べて精度が向上することが確認された。また、VAE デコードからの出力時において、商品情報だけではなく時刻情報を同時に再構成する手法を検証したが、実験の結果、この方法では推薦精度が上がらないことが確認された。ただし、本研究の提案システムはベースとした手法に比べてパラメータが増加することで計算量が大きくなり、より大規模なデータセットに対して適用しづらくなっている。これは、[Liang 18] が主張する、より小さいデータセットでの推薦精度の確保というメリットを相殺していると言える。このため、今後は計算量を削減しつつ、TSVAE と同様の推薦精度を示せるよう、特に RNN エンコーダ部分についての改善を検討したい。

◇ 参 考 文 献 ◇

- [Adomavicius 11] Adomavicius, G. and Tuzhilin, A.: Context-aware recommender systems, *Recommender Systems Handbook*, pp.217-253, Springer, Boston, MA (2011)
- [Beutel 18] Beutel, A., et al.: Latent cross: Making use of context in recurrent recommender systems, *Proceedings of the 11th ACM International Conference on Web Search and Data Mining*, pp.46-54 (2018)
- [Cheng 16] Cheng, H.-T., et al.: Wide & deep learning for recommender systems, *Proceedings of the 1st Workshop on Deep Learning for Recommender Systems*, pp.7-10 (2016)
- [He 17] He, X., et al.: Neural collaborative filtering, *Proceedings of the 26th International Conference on World Wide Web*, pp.173-182 (2017)

- [McAuley 13] McAuley, J. J. and Leskovec, J.: From amateurs to connoisseurs: Modeling the evolution of user expertise through online reviews, *Proceedings of the 22nd International Conference on World Wide Web*, pp.897-908 (2013)
- [Kang 17] Kang, W.-C., et al.: Visually-aware fashion recommendation and design with generative image models, *Proceedings of 2017 IEEE International Conference on Data Mining*, pp.207-216 (2017)
- [Kingma 13] Kingma, D. P. and Welling, M.: Auto-encoding variational bayes, *Proceedings of 2nd International Conference on Learning Representations* (2014)
- [Liang 18] Liang, D., et al.: Variational autoencoders for collaborative filtering, *Proceedings of the 2018 World Wide Web Conference*, pp.689-698 (2018)
- [Liu 19] Liu, H., et al.: Joint representation learning for multi-modal transportation recommendation, *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol.33, No.01, pp.1036-1043 (2019)
- [Pavlovski 20] Pavlovski, M., et al.: Time-aware user embeddings as a service, *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp.3194-3202 (2020)
- [Sachdeva 19] Sachdeva, N., et al.: Sequential variational autoencoders for collaborative filtering, *Proceedings of the 12th ACM International Conference on Web Search and Data Mining*, pp.600-608 (2019)
- [Sohn 15] Sohn, K., Lee, H. and Yan, X.: Learning structured output representation using deep conditional generative models, *Advances in Neural Information Processing Systems*, Vol.28, pp.3483-3491 (2015)
- [Wan 18] Wan, M. and McAuley, J.: Item recommendation on monotonic behavior chains, *Proceedings of the 12th ACM Conference on Recommender Systems*, pp.86-94 (2018)
- [Xue 17] Xue, H.-J., et al.: Deep matrix factorization models for recommender systems, *Proceedings of the 26th International Joint Conference on Artificial Intelligence*, Vol.17, pp.3203-3209 (2017)
- [Zhao 17] Zhao, Z., et al.: Social-aware movie recommendation via multimodal network learning, *IEEE Transactions on Multimedia*, Vol.20, pp.430-440 (2017)
- [Zheng 17] Zheng, L., Noroozi, V. and Yu, P. S.: Joint deep modeling of users and items using reviews for recommendation, *Proceedings of the 10th ACM International Conference on Web Search and Data Mining*, pp.425-434 (2017)
- [Zhu 17] Zhu, Y., et al.: What to do next: Modeling user behaviors by time-LSTM, *Proceedings of the 26th International Joint Conference on Artificial Intelligence*, Vol.17, pp.3602-3608 (2017)

[担当委員：吉川 友也]

2020 年 11 月 30 日 受理

著 者 紹 介

保住 純

2013 年 3 月東京大学工学部システム創成学科知能社会システムコース卒業。2015 年 3 月同大学院工学系研究科技術経営戦略学専攻修士課程修了。現在、同大学院博士課程在籍中。専門は機械学習・深層学習応用。

岩澤 有祐(正会員)

2012 年に上智大学(情報理工学科, 矢入研究室)を卒業。2014 年に上智大学大学院 博士前期課程(情報学領域, 矢入研究室)を修了。2017 年に東京大学大学院 博士後期課程(技術経営戦略学専攻, 松尾研究室)を修了。2017 年より東京大学松尾研究室にて特任研究員, 特任助教を経て 2020 年 12 月より特任講師(現職)。博士(工学)。専門は深層学習, 特にウェアラブルセンシングへの応用と, 知識転移に関する技術。

松尾 豊(正会員)

1997 年東京大学工学部卒業。2002 年同大学院博士課程修了。博士(工学)。産業技術総合研究所, スタンフォード大学を経て, 2007 年より, 東京大学大学院工学系研究科技術経営戦略学専攻 准教授。2019 年より同大学院人工物工学研究センター/技術経営戦略学専攻 教授。2014 年より 2018 年まで人工知能学会倫理委員長。2017 年より日本ディープラーニング協会理事長。人工知能学会論文賞, 情報処理学会長尾真記念特別賞, ドコモモバイルサイエンス賞など受賞。専門は, 人工知能, 深層学習, Web 工学。