

修士論文概要書

Master's Thesis Summary

Date of submission: 01/09/2024 (MM/DD/YYYY)

専攻名 (専門分野) Department	経営システム 工学専攻	氏名 Name	土屋 希琳 Kirin Tsuchiya	指導 教員 Advisor	後藤 正幸 印 Seal
研究指導名 Research guidance	情報数理応用研究	学籍番号 Student ID number	5222C024-3		
研究題目 Title	顧客の嗜好を考慮した商品画像クラスタリングに関する研究 A Study on Product Image Clustering Considering Customer Preferences				

1. はじめに

消費者が花やインテリアなどの視覚的情報が重要な商品を購入する場合、購入目的は先に決まっておき、目的に合わせたカテゴリ検索等によって関連商品を調査し、購入商品を選択することが多い。EC サイトにおいては、各商品の特徴やレビュー情報を中心に購入商品を選択する場合もあるが、基本的にはまず表示された商品画像を見て視覚情報を元に商品を選ぶことが多く、この場合、顧客は商品画像が持つ何らかの視覚的特徴に惹かれて選択している。つまり、各顧客の嗜好や購入目的と各商品画像の視覚的特徴は何らかの潜在的要因のもとで紐づいていると考えられる。

一方、商品を選択する際、同一カテゴリの商品であっても商品ごとに視覚情報は大きく異なり、顧客によって求める商品の特徴も異なると考えられる。例えば、性別や年齢といった顧客属性や、家族や友人、自分へのプレゼントなのかという購入目的によっても、選択される商品は異なる傾向にある。しかし、多くの EC サイトでは、購入データを活用した推薦システムなどのツールは導入されているものの、各顧客の商品画像に対する嗜好を考慮したサイト設計はなされていない。そのため、検索結果の表示順序に顧客の視覚情報からの嗜好を反映させることで、より良いサービスを実現できると考えられる。

そこで本研究では、顧客属性や購入目的に応じて、どのような画像特徴を持つ商品が購入されているかを分析可能な新たな潜在クラスモデル [1] を提案する。具体的には、Variational Auto Encoder (VAE) [2] により商品画像の特徴量を抽出し、顧客属性と購入目的と商品画像の特徴量の背後に潜在クラスを仮定する。そして、購買履歴データからモデルに含まれる各パラメータを推定し、データの背後にある顧客の嗜好を分析可能な手法を提案する。

観測が不可能な変数である潜在クラスを仮定し、ユーザーとアイテムの関係を分析する潜在クラスモデルは、マーケティング業界で広く用いられている。しかし、潜在クラスを用いて画像の特徴量とその他の変数間の関係性を分析するモデルは提案されていない。本提案手法は、顧客属性と

購入目的を併せた画像のソフトクラスタリングを実現し、画像の特徴に基づく顧客の行動傾向を把握することなどに活用できる。また、例えば顧客の商品に対する嗜好の発見や、分析結果に基づく商品検索結果のパーソナライズを実現することもできる。その結果、顧客が嗜好する商品を見つけやすくなる等、サイトの利便性や顧客満足度を高めるための一助となることが期待される。さらに本稿では、提案手法を実際の生花 EC サイトの購買履歴データに適用することで、その有効性を検証する。

2. 関連研究

2.1. Variational Auto Encoder

顧客属性と購入目的と商品画像の関係性を明らかにするための潜在クラスモデルの構築にあたって、商品画像に関する低次元の特徴量を抽出する必要がある。本節では画像特徴量の抽出手法の 1 つである VAE について説明する。VAE とは、始めに入力された画像からエンコーダを用いて正規分布に従う潜在変数の事後分布の形で中間表現を取得し、潜在変数の事後分布を元にデコーダによって入力画像を再現するように出力画像を生成するモデルである。

VAE の構造を図 1 に示す。デコーダから生成される画像を確認することでどれだけ良質な中間表現を得られているか視覚的に確認できる点が強みである。本研究では後に潜在クラスモデルを作成するため、正規分布に従う潜在変数の事後分布の形で中間表現を取得できる VAE を使用する。




図 1. VAE の構造のイメージ

2.2. 潜在クラスモデル

潜在クラスモデルとは、観測される変数の背後に複数の潜在変数を仮定し、複数の変数間の何らかの関係性を分析可能なモデルである。潜在クラスモデルでは、潜在クラスに紐付ける各特徴量の次元数に差がある場合、次元数が大きい特徴量の全体の尤度関数に与える影響が小さくなり、

次元数が小さい特徴量を強く考慮するような偏った学習がされてしまう。本研究においても各特徴量間に次元数の差が生じるため、次元数の差に対応するための従来研究として、各特徴量の生起確率にハイパーパラメータを用いて重みづけをした坂元らの手法 [3] について述べる。

坂元らの手法は、就活ポータルサイトにおける企業のアピールポイントと学生の志望理由の間に潜在クラスを仮定して両者の関係性を分析するための手法である。就活ポータルサイトにおいて、企業は 11 個のアピールポイントから 3 つを選んでその特徴をアピールする。一方、閲覧した就活生は志望する企業の志望理由を 20 個の選択肢の中から 3 つ選択し志望する。坂元らの手法では、企業のアピールポイントと就活生の志望理由をそれぞれ 11 次元と 20 次元のベクトルで表現し、両者の間に潜在クラスを仮定する。全 N 件のデータのうち n 番目のデータにおける潜在クラスを z_n 、企業のアピールポイントベクトルを \mathbf{x}_n 、就活生の志望理由ベクトルを \mathbf{y}_n とすると、確率モデルは式 (1)、グラフィカルモデルは図 2 のように表現される。

$$P(\mathbf{x}_n, \mathbf{y}_n, z_n) = P(z_n)P(\mathbf{x}_n|z_n)P(\mathbf{y}_n|z_n) \quad (1)$$




図 2. 坂元らの手法のグラフィカルモデル

ここで、アピールポイントと志望理由に関する確率 $P(\mathbf{x}_n|z_n), P(\mathbf{y}_n|z_n)$ はそれぞれ各要素分の二項分布の確率質量関数の掛け合わせで表現される。つまり、アピールポイントと志望理由どちらかの次元数が大きい場合には、次元数が大きい特徴量の尤度関数全体に与える影響が小さくなり、次元数が小さい特徴量をより考慮したモデルとなる。そこで坂元らは、パラメータ学習のための学習アルゴリズムにおいて、各特徴量における生起確率にハイパーパラメータ α, β を用いて重みづけすることで次元数の差に対応している。 α, β によって重み付けされた修正尤度関数は式 (2) のように表される ($\alpha, \beta > 0$)。

$$P(\mathbf{x}_n, \mathbf{y}_n, z_n)^\prime = P(z_n)P(\mathbf{x}_n|z_n)^\alpha P(\mathbf{y}_n|z_n)^\beta \quad (2)$$

坂元らはハイパーパラメータ α, β を実験結果から探索的に決定しており、明確な設定方法がない点は課題である。

3. 提案手法

3.1. 概要

本研究では、例えば「中年の女性が母の日に、母の日に贈る花として一般的なカーネーションを購入しているのか、もしくは全く別の視覚的特徴を持つ花束を購入しているのか」などを分析するために、顧客属性と購入目的と商品画像の関係性を分析する。始めに VAE により低次元の商品画像特徴量を抽出し、抽出した画像特徴量を用いて顧客属性と購入目的との関係を明らかにする潜在クラスモデルを

提案する。ここで、顧客属性と購入目的はあらかじめ購買履歴データ等から得られることを前提としている。本実験で使用する生花 EC サイトでは、顧客属性は EC サイトで商品を購入する際のログイン情報から、購入目的は商品購入時のアンケート情報から得ている。また、顧客属性としては性別と年齢の情報を使用し、購入目的としてはお供えや母の日といった情報を使用する。

3.2. 変数の定義

K 個の潜在クラス集合を $\mathcal{Z} = \{z_k: 1 \leq k \leq K\}$ 、 L 個の顧客属性集合を $\mathcal{A} = \{a_l: 1 \leq l \leq L\}$ 、 M 個の購入目的集合を $\mathcal{R} = \{r_m: 1 \leq m \leq M\}$ 、 S 次元の商品画像の特徴量集合を $\mathcal{I} = \{i_s: 1 \leq s \leq S\}$ と定義する。全 N 件の購買履歴のうち、 n 番目に購入した顧客の顧客属性ベクトルを $\mathbf{t}_n = (t_{n,1}, t_{n,2}, \dots, t_{n,L})$ 、購入目的ベクトルを $\mathbf{u}_n = (u_{n,1}, u_{n,2}, \dots, u_{n,M})$ 、 n 番目に購入された商品の商品画像ベクトルを $\mathbf{w}_n = (w_{n,1}, w_{n,2}, \dots, w_{n,S})$ とする。ただし、 n 番目の顧客に関する l 番目の顧客属性 $t_{n,l}$ と m 番目の購入目的 $u_{n,m}$ は、それぞれ n 番目の購入履歴で顧客属性 a_l 、購入目的 r_m が選択されていれば 1、そうでなければ 0 を取る二値変数である。また、 n 番目に購入された商品の s 次元目の商品画像特徴量の要素 $i_{n,s}$ はそれぞれ独立した正規分布に従うと仮定し、潜在クラス k における商品画像の s 次元目の平均を $\mu_{k,s}$ 、分散を $\sigma_{k,s}$ とする。

3.3. 潜在クラスモデル

n 番目の購買履歴データにおける顧客属性と購入目的と商品画像の潜在クラスモデルのグラフィカルモデルは図 3、確率モデルは式 (3) で表される。ただし、式 (3) における \bar{a}_l, \bar{r}_m は顧客属性 a_l 、購入目的 r_m が選択されない事象のことであり、 $P(a_l|z_n) + P(\bar{a}_l|z_n) = 1$ 、 $P(r_m|z_n) + P(\bar{r}_m|z_n) = 1$ を満たす。また、潜在クラスモデルにおける、確率モデルの対数尤度関数を最大化する各パラメータは、EM アルゴリズム [4] によって推定する。




図 3. 提案モデルにおけるグラフィカルモデル
 $P(\mathbf{t}_n, \mathbf{u}_n, \mathbf{w}_n, z_n)$

$$\begin{aligned} &= P(z_n)P(\mathbf{t}_n|z_n)P(\mathbf{u}_n|z_n)P(\mathbf{w}_n|z_n) \\ &= P(z_n) \times \prod_{l=1}^L P(a_l|z_n)^{t_{n,l}} P(\bar{a}_l|z_n)^{1-t_{n,l}} \\ &\quad \times \prod_{m=1}^M P(r_m|z_n)^{u_{n,m}} P(\bar{r}_m|z_n)^{1-u_{n,m}} \\ &\quad \times \prod_{s=1}^S \frac{1}{\sqrt{2\pi\sigma_{n,s}^2}} \exp\left\{-\frac{(i_{n,s} - \mu_{n,s})^2}{2\sigma_{n,s}^2}\right\} \quad (3) \end{aligned}$$

画像を次元圧縮して S 次元の特徴量ベクトルを得たとしても、サービス運営側が設定した L 次元の顧客属性や M 次元の購入目的と比較すると、次元数は一般に $S > L, M$ であり、このままでは学習時に問題が生じる。そこで本研究では、坂元らの手法 [3] を参考に、各特徴量における生起確率にハイパーパラメータ α, β, γ を用いて重みづけることで次元数の差に対応する。本研究では、ハイパーパラメータ α, β, γ を各特徴量が尤度関数全体に与える影響が均一になるように事前に自動で決定する。具体的には、顧客属性と購入目的に関する確率 $P(\mathbf{t}_n|z_n)$ と $P(\mathbf{u}_n|z_n)$ がそれぞれ L, M 個の二項分布の確率質量関数の掛け合わせで表現されるのに対して、商品画像に関する確率 $P(\mathbf{w}_n|z_n)$ は S 個の正規分布の確率密度関数の掛け合わせで表現される。よって本研究の場合には、顧客属性は $S - L$ 個分、購入目的は $S - M$ 個分商品画像よりも確率が乗算される累積数が少なく、その分各特徴量の生起確率が大きくなる。そこで本研究では、顧客属性に $S - L$ 個分、購入目的に $S - M$ 個分確率が追加で乗算されるようにハイパーパラメータによる重みづけを行う。ここまでを踏まえ、次元数の差による影響を調整するための修正尤度関数を式 (4) のように表し、ハイパーパラメータ α, β, γ はそれぞれ式 (5) ~ (7) のように設定する ($\alpha, \beta, \gamma > 0$)。

$$P(\mathbf{t}_n, \mathbf{u}_n, \mathbf{w}_n, z_n)' = P(z_n)P(\mathbf{t}_n|z_n)^\alpha P(\mathbf{u}_n|z_n)^\beta P(\mathbf{w}_n|z_n)^\gamma \quad (4)$$

$$\alpha = \frac{\max(L, M, S)}{L} \quad (5)$$

$$\beta = \frac{\max(L, M, S)}{M} \quad (6)$$

$$\gamma = \frac{\max(L, M, S)}{S} \quad (7)$$

4. 実験

本章では始めに、生花 EC サイトの実データに対して提案手法と従来の潜在クラスモデル（従来手法）の双方を適用し、学習回数ごとの各特徴量の生起確率が尤度関数に与える影響を分析することにより、提案手法の有効性を確認する。次に、提案手法から得られた各パラメータを分析することにより、顧客の嗜好を分析し、提案手法の有用性を示す。

4.1. 実験条件

本実験では生花 EC サイトの実データを使用する。画像は 5,823 枚であり、全画像を VAE によって圧縮する。画像特徴量を抽出する際の次元数を 64、バッチサイズは 128、学習率は 1.0×10^{-4} 、エポック数は 5,000 とした。

潜在クラスモデルで使用する購買履歴データのデータ数は 642,560 である。また、顧客属性の次元数 L は 26、購入目的の次元数 R は 41、商品画像特徴量の次元数 S は

64、潜在クラス数 K は 32 とした。潜在クラス数は、商品画像特徴量を Gaussian Mixture Models (GMM) [5] によりクラスタリングし、得られたクラスタの特徴の解釈のしやすさにより決定した。また、各潜在クラスが生起確率 $p(z)$ と商品画像特徴量の生起確率 $p(\mathbf{w}_n|z_n)$ の初期値は GMM から得られた値を使用し、顧客属性と購入目的の生起確率 $p(\mathbf{t}_n|z_n)$, $p(\mathbf{u}_n|z_n)$ の初期値はランダムとする。さらに本実験では、潜在クラスモデルに関する対数尤度の変化率が 1.0×10^{-3} 以下となった場合に学習終了とする。

4.2. 実験結果

4.2.1. 提案手法の有効性

従来手法と提案手法（式 (3) と式 (4)）それぞれにおける顧客属性に関する値 ($P(\mathbf{t}_n|z_n), P(\mathbf{t}_n|z_n)^\alpha$) と購入目的に関する値 ($P(\mathbf{u}_n|z_n), P(\mathbf{u}_n|z_n)^\beta$) をデータ n 、潜在クラス k ごとに平均をとり、学習回数ごとにどのような変化があるか分析する。分析結果を図 4 に示す。




図 4. 各特徴量に関する値が尤度関数に与える影響の推移

図 4 より、従来手法では、顧客属性と購入目的に関する値それぞれの平均値が異なり、尤度に対する影響度合いが異なっているとわかる。対して、提案手法による潜在クラスモデルでは、顧客属性と購入目的に関する値の平均値が従来手法よりも近くなっており、尤度に対する影響度合いが従来手法ほどは異なっていないとわかる。以上より、各特徴量における生起確率にハイパーパラメータを用いて重みづける提案手法の有効性を確認することができた。

4.2.2. 提案手法による実験結果

本節では、実験により得られた 32 クラスのうち 2 つの潜在クラスを抜粋し、その結果について述べる。潜在クラス 6,9 の生起確率と、各潜在クラスに所属する生起確率の高い上位 5 件の顧客属性と購入目的、それぞれの生起確率は表 1 のようになった。また、潜在クラス 6,9 における、潜在クラスごとの各商品の生起確率 $P(\mathbf{w}|z)$ が高い上位 10 件の商品画像を図 5 と図 6 に示す。

表 1. 各潜在クラスの特徴（一部抜粋）

潜在クラス	生起確率	顧客属性	生起確率	購入目的	生起確率
6	0.015	女性.55~59 歳	0.262	お供え	0.892
		女性.45~49 歳	0.258	お彼岸	0.028
		男性.40~44 歳	0.112	お盆	0.025
		男性.その他	0.098	喪中見舞い	0.020
		男性.60~64 歳	0.095	その他	0.018
9	0.066	女性.35~39 歳	0.114	母の日	0.937
		女性.40~44 歳	0.109	母の日遅れてごめんね	0.063
		女性.30~34 歳	0.108	お祝い	3.33E-04
		女性.45~49 歳	0.088	季節行事	3.33E-05
		男性.45~49 歳	0.083	お誕生日	3.33E-05



図 5. 潜在クラス 6 に所属する商品画像




図 6. 潜在クラス 9 に所属する商品画像

表 1 より各潜在クラスには類似した顧客属性や購入目的が所属しており、図 5 と図 6 のように似たような色味や同じ種類の花が多く所属していることから、適切な学習がなされていると判断できる。これらの中身を見ると、潜在クラス 6 に所属している主に中年の顧客は、お供えやお彼岸、お盆、喪中見舞いに、白色や淡い青色、ピンク色の花束を購入する傾向にあるとわかる。日本ではお供え等に白色といった落ち着いた色の花を供えることが一般的であることが反映された結果である。また、潜在クラス 9 に所属する主に 30,40 代の女性は母の日に、ピンク色や赤色、黄色やオレンジ色といった暖色の花束を購入する傾向にあるとわかる。加えて、花束だけでなくボックスに装飾された花も好まれている。カーネーションの花束が多く所属していることも、母の日の慣習を反映した結果であると言える。

5. 考察

5.1. 実験結果に関する考察

本実験では、お供えやお彼岸、お盆といった哀悼行事には、白色や淡い青色といった寒色やピンク色の花束が多く所属していた。また、母の日や誕生日、お祝いといった祝福行事には反対にピンク色や黄色といった暖色の花束が多く所属していた。以上の結果から、一般的に、哀悼行事には白色や寒色の花束など落ち着いた色やピンク色の花束、祝福行事には暖色の花束など色鮮やかで華やかな花束を贈ることが多いと考えられる。

5.2. 得られた結果の活用方法に関する考察

本研究では生花 EC サイトの実データセットに提案手法を適用することで、顧客の嗜好を分析した。4.2.2 節の実験結果より、母の日用の花束を探している主に 30,40 代の女性にはカーネーションを使用したピンク色や赤色、黄色やオレンジ色といった暖色の花束やボックスに装飾された花などをサイト上で推薦すれば良いと考えられる。これにより、顧客は好みの花束をより見つけやすくなり、顧客満足度が向上すると考えられる。また、サイト運営側にとっ

ても顧客に商品を購入してもらえらる確率が向上し、売上向上に繋がると期待できる。

5.3. 他のサービスへの発展可能性に関する考察

本研究では、商品画像の視覚的情報が購入時に重要と思われる生花 EC サイトに提案手法を適用した。しかし、インテリアや服など花以外にも商品の画像情報が重要となりうるものはある。生花は季節といった時期により購入できるものが制限され、購入する花は購入時期の季節に強く影響を受ける。一方で、特にインテリアといったものは季節による影響を受けにくく、提案手法により、よりの確に顧客の嗜好を捉えられると考えられる。以上より、提案手法は生花 EC サイトのみならず多くのサービスにおいて活用可能であると考えられる。

6. 結論と今後の課題

本研究では、顧客属性や購入目的に応じて、どのような画像特徴を持つ商品が購入されているかを分析可能なモデルを提案した。具体的には、VAE によって商品画像から特徴量を抽出し、その画像特徴量と顧客属性情報と購入目的情報の関係性を表現した新たな潜在クラスモデルを提案した。また、潜在クラスモデルにおいて、各特徴量に次元数の差がある場合に生じてしまう偏った学習を防ぐために、あらかじめ自動的に決定したハイパーパラメータを用いる学習方法を提案した。生花 EC サイトの実データセットを用いた実験により、顧客属性や購入目的といった顧客の嗜好ごとにどのような花を好むのか分析し、提案手法の有効性を示した。

今後の課題としては、データ数が少ない顧客属性や購入目的に関する分析や、各潜在クラスの特徴と一度も購入されていない商品の特徴を捉え、新たな画像を生成すること等が挙げられる。

謝辞

本研究は、株式会社花キューピットと早稲田大学の共同研究であり、データ提供元である株式会社花キューピットの皆様に深く感謝致します。

参考文献

- [1] Thomas Hofmann. Probabilistic latent semantic analysis. In *Proceedings of Uncertainty in Artificial Intelligence, UAI'99*, pp. 289–296, 1999.
- [2] Welling Max Kingma, Diederik P. Auto-encoding variational bayes. In *Proceedings of the International Conference on Learning Representations*, 2014.
- [3] 坂元哲平, 山下遥, 荻原大陸, 後藤正幸. 就職ポータルサイトにおける企業のアピールポイントと学生の志望理由のマッチング分析モデルに関する一考察. *情報処理学会論文誌*, Vol. 58, No. 9, pp. 1535–1548, 2017.
- [4] T.K. Moon. The expectation-maximization algorithm. *IEEE Signal Processing Magazine*, Vol. 13, No. 6, pp. 47–60, 1996.
- [5] Douglas A Reynolds. Gaussian mixture models. *Encyclopedia of biometrics*, No. 741, pp. 659–663, 2009.