

KL ダイバージェンスにもとづく 顔画像に対する選好判断の類似性の評価

Evaluation of Individual Differences in Face Image Preferences Based on KL Divergence

寺地 哲平[†], 城下 慧人[†], 小森 政嗣[†], 中村航洋[‡], 小林 麻衣^{‡*}, 渡邊 克巳^{‡*}
Teppei Teraji, Keito Shiroshita, Masashi Komori, Koyo Nakamura, Mai Kobayashi, Katumi
Watanabe

[†] 大阪電気通信大学大学院 工学研究科 工学専攻, [‡] ウィーン大学, ^{‡*} 早稲田大学理工学術院

[†]Graduate School of Engineering, Osaka Electro-Communication University, [‡]University of Vienna, ^{‡*}Faculty
of Science and Engineering, Waseda University
mi22a007@oecu.jp

概要

多次元の特徴をもつ刺激に対する感性評価関数 (効用関数) の個人差を KL ダイバージェンスにより評価することを試みた。4 名の実験参加者に、StyleGAN2 により生成された顔を提示し、魅力の判断する二肢選択により課題を行わせた。その結果に対してガウス過程選好学習 (GPPL) を適用し各参加者の効用関数を推定した。さらに各実験参加者の効用関数同士の KL ダイバージェンスを求め、これを判断の類似度の指標とした。KL ダイバージェンスと、判断の一致率、予測平均値の相関係数を比較し、KL ダイバージェンスによる判断の類似度の評価の特徴を検討した。

キーワード：ガウス過程回帰, 顔魅力, 効用関数

1. 序論

顔のように高次元の特徴を持つ刺激に対して、我々は魅力評価のように 1 次元の応答を瞬時に行うことができる。このようなプロセスの解明は、高次元の特徴を持つ刺激に対する心的な感性評価関数 (ここでは効用関数と呼ぶ) の推定とみなすことができるが、効用関数はブラックボックス関数である。一般に、未知の多変数関数の推定にはガウス過程回帰 (Gaussian process regression: GPR) が有効な方法であることが知られている。GPR は、ノンパラメトリックなベイズ回帰分析モデルの一つである [2]。GPR は過学習が起きにくく、不確実性を表現できるといった特徴を持つ。

ガウス過程回帰は、複雑な刺激に対する効用関数の検討にも有効であることが示されてきた [1, 3]。Komori ら [1] の研究は、顔を刺激画像とした二肢選択でどちらの顔が魅力的かを判断させ選好データに基づいて顔の魅力について評価している。また、GPR と

Thurstone の一対比較モデル (Probit モデル) を組み合わせたガウス過程選好学習 (Gaussian Process with Preference Learning: GPPL) [4] を用いて、多次元の特徴を持つ刺激に対する選好判断から、心的な効用関数を推定している。

さらに、この研究 [1] では、各実験参加者の効用関数の予測平均値が最大値/最小値となった顔特徴間の顔空間内での距離を比較することで、実験参加者間の判断の類似性について論じている。しかし、最大値/最小値となる特徴を比較するだけでは、個人間の効用関数全体の類似度を評価したことにはならないため、このような手法では十分に個人差が検討できるとはいえない。

そこで本研究では、効用関数の各実験参加者間の類似度を評価する手法を検討する。GPR により推定された効用関数は事後分布とみなすことができるため、参加者の判断の非類似度は KL ダイバージェンス (Kullback-Leibler divergence)(式 (1)) で評価することができる。GPR により推定された効用関数は無限次元の事後分布に相当するが、共通の事前分布を持つ場合、観測点に限定した有限次元として扱っても良いことが知られている [2, 5]。

$$D(p, q) = E_p[\log p(x) - \log q(x)] \quad (1)$$

本研究では、顔の二肢強制選択課題による魅力評価課題を行い、各参加者の効用関数を推定した上で、効用関数間の隔たりを KL ダイバージェンスにより評価し、その有効性について検討する。

2. 効用関数の KL ダイバージェンス

2.1 ガウス過程回帰

ガウス過程 (GP) とは, 入力 $x \in \mathcal{D}$ と $y \in \mathbb{R}$ の間の写像 $f: \mathcal{D} \rightarrow \mathbb{R}$ の確率分布を表すものである [5]. 任意の入力集合 $\mathcal{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$ に対する出力 $\mathbf{f}(\mathcal{X}) = (f(\mathbf{x}_1), \dots, f(\mathbf{x}_n))$ が n 次元のガウス分布に従うものであり, 平均 $m(\mathbf{x})$ と共分散関数 $k(\mathbf{x}, \mathbf{x}')$ から式 (2) として定義できる.

$$f \sim \mathcal{GP}(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}')) \quad (2)$$

GP を用いて写像 f をベイズ推定することを GPR と呼び, n 個の入力集合 $\mathcal{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$ に対応する出力 $\mathbf{y} = (y_1, \dots, y_n)^T \in \mathbb{R}^n$ のペアが与えられたとき, 平均が 0 であるゼロ平均ガウス過程の場合の事前分布を式 (3) で表現される.

$$p(f) = \mathcal{GP}(f|0, k(x, x')) \quad (3)$$

事前分布が定義された上で GPR を行なって得られた事後分布 $p(f|\mathcal{X}, \mathbf{y})$ は式 (4) で与えられる.

$$p(f) = \mathcal{GP}(f|m(x), S(x, x')) \quad (4)$$

$$m(x) = \mathbf{k}^T(x) (\mathbf{K}_{nn} + \sigma^2 \mathbf{I})^{-1} \mathbf{y} \quad (5)$$

$$= \mathbf{k}^T(x) \alpha \quad (6)$$

$$S(x, x') = k(x, x') - \mathbf{k}^T(x) (\mathbf{K}_{nn} + \sigma^2 \mathbf{I})^{-1} \mathbf{k}(x') \quad (7)$$

$$= (x, x') - \mathbf{k}^T(x) \mathbf{A}^{-1} \mathbf{k}(x') \quad (8)$$

ここで, $k(\mathbf{x}, \mathbf{x}')$ は共分散関数であり, $\mathbf{k}(\mathbf{x})$ と \mathbf{K}_{nn} はそれぞれ $\mathbf{k}(\mathbf{x}) = k(\mathcal{X}, \mathbf{x}) \in \mathbb{R}^n$, $\mathbf{K}_{nn} = k(\mathcal{X}, \mathcal{X}) \in \mathbb{R}^{n \times n}$ である.

2.2 ガウス過程選好学習

GPPL は二肢選択判断に対する回答に基づいて GPR を行う手法である [4]. 2つの刺激を提示して, それらの刺激のうちより高い心理量をもたらした刺激を選択させる二肢選択課題を m 回行わせた選好関係 D を

$$D = \{v_k \succ u_k; k = 1, \dots, m\} \quad (9)$$

とする. \succ は u_k より v_k が好まれたことを示している.

潜在関数値 $f(x_i)$ はゼロ平均ガウス過程における簡素値であると仮定する. その後, ガウス過程は共分散行列 (カーネル \mathcal{K}) によって指定できる. GPR では,

一般的によくガウシアンカーネルが用いられる (式 (10)).

$$\mathcal{K}(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\kappa}{2} \sum_{l=1}^d (\mathbf{x}_i^l - \mathbf{x}_j^l)^2\right) \quad (10)$$

したがって, これらの潜在関数値 $f(x_i)$ の事前確率は次のようになる.

$$\mathcal{P}(\mathbf{f}) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left(-\frac{1}{2} \mathbf{f}^T \Sigma^{-1} \mathbf{f}\right) \quad (11)$$

ここで, $\mathbf{f} = [f(x_1), f(x_2), \dots, f(x_n)]^T$, Σ は $n \times n$ の共分散行列で, ij 番目の要素は式 (10) で定義されたカーネルである.

式 (9) の選好関係を捉えるため新しい尤度関数が提案されている. 入力や選好関係のノイズを許容するため, 出力の正規ノイズ $\mathcal{N}(\delta; \mu, \sigma^2)$ が加わり実験参加者の反応が決定されると仮定している. 尤度関数は以下のようになる (式 (12)).

$$\begin{aligned} & \mathcal{P}(v_k \succ u_k | f(v_k), f(u_k)) \\ &= \iint \mathcal{P}_{\text{ideal}}(v_k \succ u_k | f(v_k) + \delta_v, f(u_k) + \delta_u) \\ & \quad \mathcal{N}(\delta_v; 0, \sigma^2) \mathcal{N}(\delta_u; 0, \sigma^2) d\delta_v d\delta_u \\ &= \Phi(z_k) \end{aligned} \quad (12)$$

ただし,

$$\begin{aligned} z_k &= \frac{f(v_k) - f(u_k)}{\sqrt{2}\sigma_{\text{noise}}} \\ \Phi(z) &= \int_{-\infty}^z \mathcal{N}(\gamma; 0, 1) d\gamma \end{aligned} \quad (13)$$

とする.

したがって, 潜在関数値で与えられた選好関係は同時確率であり尤度は以下のようになる.

$$\mathcal{P}(D|\mathbf{f}) = \prod_{k=1}^m \mathcal{P}(v_k \succ u_k | f(v_k), f(u_k)) \quad (14)$$

2.3 ガウス過程の KL ダイバージェンス

2つのデータセット $(\mathcal{X}_1, \mathbf{y}_1)$, $(\mathcal{X}_2, \mathbf{y}_2)$ について, 共通の事前分布を持ち GPR によって得られた事後分布 $p_1(f|\mathcal{X}_1, \mathbf{y}_1)$, $p_2(f|\mathcal{X}_2, \mathbf{y}_2)$ 間の KL ダイバージェンスは, 式 (15) で定義されている [5].

$$D_{KL}[p_1(f) \| p_2(f)] = D_{KL}[p_1(\mathbf{f}(\mathcal{X}_{12})) \| p_2(\mathbf{f}(\mathcal{X}_{12}))] \quad (15)$$

ここでの $\mathcal{X}_1, \mathcal{X}_2$ は入力データの集合であり、 $\mathcal{X}_{12} = \mathcal{X}_1 \cup \mathcal{X}_2$ である。これは、観測データの入力点を有限次元ガウス分布で表現し、その KL ダイバージェンスを測ることで GP 間の KL ダイバージェンスを評価できることを示している。また、観測データの入力異なるときは、その和集合に関して評価すればよいことを意味している。

KL ダイバージェンスは、2つの確率分布 $p_1(\mathcal{X}) = \mathcal{N}(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1)$, $p_2(\mathcal{X}) = \mathcal{N}(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2)$ の多変量確率密度関数から KL ダイバージェンス (式 (16)) を求めることができる。

$$D_{KL}(p_1, p_2) = \frac{1}{2} \log \det(\boldsymbol{\Sigma}_2 \boldsymbol{\Sigma}_1^{-1}) + \text{tr}(\boldsymbol{\Sigma}_1^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^T + \boldsymbol{\Sigma}_1 - \boldsymbol{\Sigma}_2) \quad (16)$$

ここでの $\boldsymbol{\mu}$ は予測平均であり、 $\boldsymbol{\Sigma}$ は予測共分散行列を示す。

KL ダイバージェンスの値は、 $D_{KL}(p_1, p_2) \geq 0$ であり正の値を取り、2つの確率分布が等しいときはゼロとなる。KL ダイバージェンス自体は距離の公理を満たしていないため、 $D_{KL}(p_1, p_2)$ と $D_{KL}(p_2, p_1)$ の値は等しくならない性質を持つ。

本研究では、GPPL で推定された効用関数間の隔たりを、KL ダイバージェンスを用いて評価を行う。

3. 評価実験

3.1 顔の潜在空間の構築

Komori ら [1] の手続きに従い、Flickr-Face-HQ (FFHQ) [6] で学習された StyleGAN2 の潜在空間と参照顔画像を用いて、アジア人の顔だけで構成される潜在空間の低次元部分空間を構築した。日本の大学生 53 名 (全て女性) 真顔の顔写真を撮影しこれを参照顔画像とし、これらの写真を StyleGAN2 の潜在空間に埋め込み、その潜在表現に対し主成分分析を行った。第 8 主成分 (累積寄与率: 29.5%) までを分析対象とした。

3.2 実験方法

実験参加者は大学生 4 名 (男性 4 名, 平均年齢 22.5 歳) である。

実験参加者に提示する刺激画像は、部分顔空間内でランダムに生成した 8 次元のパラメータから生成された。ただし、実験参加者に対して提示する画像の組み合わせは実験参加者間で共通とした。これらの組み合わせを提示する順序はランダムにした。実験参加者には 2 枚の刺激画像をモニタ上に提示し、これらのうちど

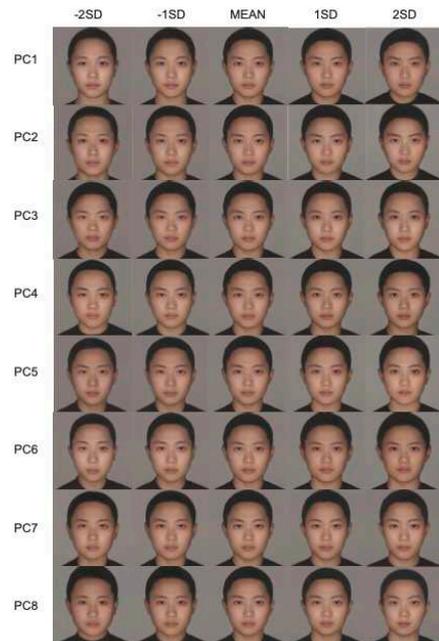


図 1: 顔部分空間の各次元に沿った顔画像の変化 (-2SD/Mean/+2SD)

ちらが魅力的かを判断する課題を行わせた (図 2)。回答はキーボードで行わせた。試行回数は 100 試行であり、これを 1 セッションとする。

実験に用いたアプリケーションはオープンソースの心理実験環境である PsychoPy を用いた。

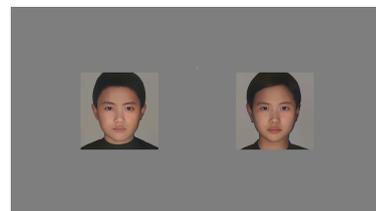


図 2: 実験画面

3.3 結果

各実験参加者について、探索空間内の探索点 (200 点) に対する予測平均と予測共分散を GPR により求めた。推定した予測平均と予測共分散を用いて実験参加者のすべての組み合わせについて KL ダイバージェンスを求めた (表 1)。またこれと比較するため、実験参加者ペア内での判断の一致率および、探索点の予測平均値の相関係数を実験参加者間の類似度の指標として求めた。

図 3 に KL ダイバージェンスと判断の一致率の関係を示す。一致率と KL ダイバージェンスの間には明確

な関係は認められなかった。次に KL ダイバージェンスと相関係数の関係を示す (図 4)。相関係数と KL ダイバージェンスにおおまかに負の関係が認められる。KL ダイバージェンスは非類似度、相関係数は類似度の指標であることから、この KL ダイバージェンスと相関係数による類似度評価の結果は符合していると言える。ただ、KL ダイバージェンスが高いペアについては相関係数との関係は明確ではなかった。

表 1: 実験参加者間の KL ダイバージェンス

participant	A	B	C	D
A	0	146.19	389.94	250.20
B	86.58	0	289.40	181.07
C	361.86	481.38	0	414.41
D	168.45	200.08	290.17	0

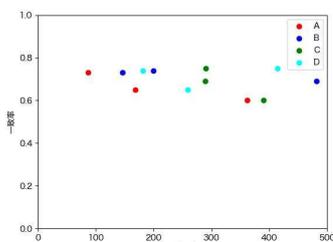


図 3: KL ダイバージェンスと一致率の関係

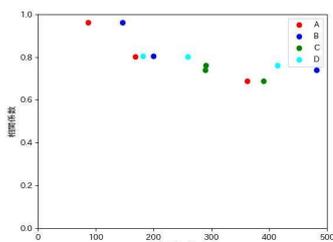


図 4: KL ダイバージェンスと相関係数の関係

4. 考察

本研究では、多次元の刺激に対する応答を表す効用関数の個人間の類似度を評価する手法の検討を行った。二肢強制選択法により顔の魅力の判断する課題を行わせ、ガウス過程回帰の拡張である GPPL にもとづいて各参加者の効用関数を推定した。さらに推定された事後分布である効用関数間の KL ダイバージェンスを判断の類似度の指標として求めた。

KL ダイバージェンスと、判断の単純な一致率、予測平均同士の相関係数を比較した結果、KL ダイバー

ジェンスと一致率との間に明確な関係は認められなかったが、予測平均の相関とは関連していたことが示された。ガウス過程回帰は探索点間の距離を考慮に入れることができ、予測の不確を表現できるという特長を有していることから、本研究の手法は判断の個人差を評価する新たな手法として活用できる可能性がある。

文献

- [1] Komori, M., Shiroshita, K., Nakagami, M., Nakamura, K., Kobayashi, M., & Watanabe, K. (2021, September). Investigation of Facial Preference Using Gaussian Process Preference Learning and Generative Image Model. In *International Conference on Computer Information Systems and Industrial Management* (pp. 193–202). Springer, Cham.
- [2] 赤穂昭太郎 (2018). ガウス過程回帰の基礎. システム/制御/情報, 62(10), 390–395.
- [3] Shiroshita, K., Komori, M., Nakamura, K., Kobayashi, M., & Watanabe, K. (2021, December). Application of Gaussian Process Preference Learning for Visualizing Facial Features Related to Personality Traits. In *2021 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)* (pp. 1–6). IEEE.
- [4] Chu, W., Ghahramani, Z. (2005, August). Preference learning with Gaussian processes. In *Proceedings of the 22nd international conference on Machine learning* (pp. 137–144).
- [5] 石橋英朗・古川徹生・赤穂昭太郎 (2017). 事後分布推定されたガウス過程間の KL ダイバージェンスは有限次元の正規分布間の KL ダイバージェンスで評価できる. 電子情報通信学会技術研究報告, 117(293), 155–160.
- [6] Karras, T., Laine, S., & Aila, T. (2019). A style-based generator architecture for generative adversarial networks. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 4401–4410).