

二肢選択ベイズ最適化によるリップ・チークの色のよい組み合わせの検討

An Interactive Approach for Arrangement of Makeup Colors Using Preferential Bayesian Optimization

小森 政嗣[†]

Masashi Komori

[†]大阪電気通信大学

Osaka Electro-Communication University

komori@osakac.ac.jp

概要

未知の関数の推定をする大域的逐次最適化手法の1つであるベイズ最適化 (Bayesian Optimization) を応用し、化粧画像のリップ・チーク色の「かわいさ」「大人っぽさ」を題材とした対話的な二肢選択課題を行った。選択の結果をもとに、「かわいさ」「大人っぽさ」予測平均値が最大/最小となる色の組み合わせを推定した。本手法は、多変量の物理量が関与する繊細な感性的評価・判断を包括的に検討する有用な手法となりうる。

キーワード：化粧, ベイズ最適化, 感性評価

1. はじめに

色彩の調和は古くから多くの関心を集めてきた問題である。Juddら[1]はそれまでの色彩調和理論を要約し、秩序、親近性、共通性、明瞭性の原理を示している。また、Moon,と Spencer[2]はこれとは別に、色彩の調和・不調和を定量的に求める手法を提案している。このように色彩調和に関しては様々な原理が提唱されてきたが、依然として統一的な見解は得られていないと言えるだろう。

色彩調和原理の統一的な理解が難しい理由は、色彩調和が全体論的で直感的な「良さ」に関する判断であるためである。一般的に色は3次元のパラメータで表現されるため、例えば、単純な2色の組み合わせの「配色の良さ」であってもパラメータは6次元になる。つまり2色の配色の調和の問題は、6次元の物理量に対する良さの評価 (1次元の心理量) を応答とした未知の心理物理関数 (ブラックボックス関数) を求める問題と考えることができる。ここで、各次元を16階調で表現した場合を考えると、色 (物理量) に $2^6=64$ 通りの組み合わせが存在する。したがって、この関数の全容を明らかにするために総当たりに多次元の物理量の全ての組み合わせに対する心理的応答を収集すること (すなわちグリッドサーチ的アプローチ) は、コスト的に不可能である。実際に配色の良さに関する心理

物理関数を検討する場合は、限られた数の応答のみを手がかりとして推定する必要がある。

そこで本研究では、ブラックボックス関数の最大値/最小値の探索や関数の推定をする大域的逐次最適化手法の1つであるベイズ最適化 (Bayesian Optimization) を応用し、化粧画像のリップ、チーク色を題材に、対話的に「配色の良さ」を表す心理物理関数の推定を試みた。ベイズ最適化は以下の3つのステップで構成される；(1)応答の取得：設定したパラメータに対する反応・評価を得る、(2)ガウス過程回帰：事前分布 (ガウス過程) および既知の応答データから未知の関数の予測平均・分散を求める、(3)獲得関数による更新：獲得関数の最適化により次の探索点を決定する、以上の(1)~(3)を繰り返す。ベイズ最適化は、応答の履歴を利用して対話的に次の探索点を決定するので、効率よく優れた解を求められることが知られている (図1)。

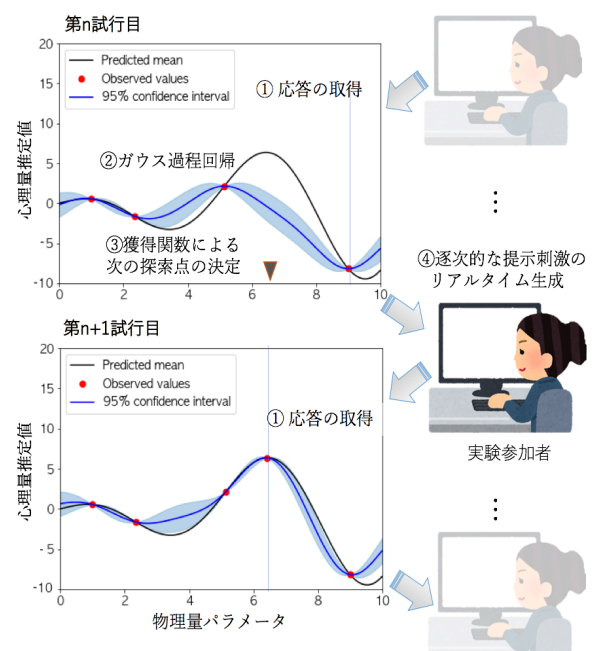


図1 ベイズ最適化による逐次的実験計画のイメージ

機械学習のパラメータ調整や逐次的実験計画などで用いられる一般的なベイズ最適化手法では、直接的に未知のブラックボックス関数からの応答が連続量で取得できる。しかし、人間には評価の強度を連続量で判断・回答することは困難であるため、一般的なベイズ最適化手法をそのまま「良さ」の判断に関する検討に用いることは難しい。そこで、本研究では、二肢選好課題の回答データに基づいてベイズ最適化を行う手法[3,4]を援用し、色彩調和関数の推定を行うを試みる。

ここで M 回の二肢選好の比較結果を

$$D = \{\mathbf{r}_i > \mathbf{c}_i; i = 1, \dots, M\} \quad (1)$$

とする。 $>$ は \mathbf{c}_i より \mathbf{r}_i が好まれたことを示す。この結果をもとにプロビットモデルに基づいて未知の関数 $f(\mathbf{x})$ を推定する手法を Chu と Ghahramani [3]が提案している。プロビットモデルでは選好確率 P を

$$P(\mathbf{r}_i > \mathbf{c}_i | f(\mathbf{r}_i), f(\mathbf{c}_i)) = \Phi(Z_i) \quad (2)$$

ただし

$$Z_i = \frac{f(\mathbf{r}_i) - f(\mathbf{c}_i)}{\sqrt{2}\sigma_{noise}} \quad (3)$$

と考える。ここで、 Φ は正規分布の累積分布関数を示す。

ガウス過程回帰は平均関数 $m(\mathbf{x})$ とカーネル k で定義され(4)、Gaussian カーネルが用いられる事が多い(5)。

$$f(\mathbf{x}) \sim GP(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x})) \quad (4)$$

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{1}{2\theta^2} \|\mathbf{x}_i - \mathbf{x}_j\|^2\right) \quad (5)$$

未知の関数 \mathbf{f} の推定は、ガウス過程によって定義される事前分布 $P(\mathbf{f})$ を尤度 $P(D|\mathbf{f})$ により更新した $P(\mathbf{f}|D)$ を最大化することで行う。 \mathbf{K} は i, j の要素が $k(\mathbf{x}_i, \mathbf{x}_j)$ となる共分散行列である。

$$P(\mathbf{f}) = |2\pi\mathbf{K}|^{-\frac{1}{2}} \exp\left(-\frac{1}{2}\mathbf{f}^T \mathbf{K}^{-1} \mathbf{f}\right) \quad (6)$$

$$P(D|\mathbf{f}) = \prod_{k=1}^m P(\mathbf{r}_k > \mathbf{c}_k | f(\mathbf{r}_k), f(\mathbf{c}_k)) \quad (7)$$

また、 $P(\mathbf{f}|D)$ は(8)に従う。

$$P(\mathbf{f}|D) \propto P(D|\mathbf{f})P(\mathbf{f}) \quad (8)$$

ここで、Laplace 近似を用いて \mathbf{f} の最尤推定 \mathbf{f}_{MAP} を求めることで、導き出された \mathbf{f}_{MAP} から未知の点 \mathbf{x}_{N+1} の予測平均(9)予測分散(10)を求めることができる。

$$m(\mathbf{x}_{N+1}) = \mathbf{k}^T \mathbf{K}^{-1} \mathbf{f}_{\text{MAP}} \quad (9)$$

$$\sigma^2(\mathbf{x}_{N+1}) = k(\mathbf{x}_{N+1}, \mathbf{x}_{N+1}) - \mathbf{k}^T (\mathbf{K} + \mathbf{C}^{-1})^{-1} \mathbf{k} \quad (10)$$

ただし

$$\mathbf{C}_{m,n} = -\frac{\partial^2 \sum_{i=1}^M \log \Phi(Z_i)}{\partial f(\mathbf{x}_m) \partial f(\mathbf{x}_n)} \quad (11)$$

次の探索点の決定には獲得関数 $EI(\mathbf{x})$ (Expected Improvement)が最大となる \mathbf{x} を求める(12)。

$EI(\mathbf{x}) =$

$$\begin{cases} (\mu(\mathbf{x}) - f(\mathbf{x}^+) - \varepsilon)\Phi(Z) + \sigma(\mathbf{x})\phi(Z) & \text{if } \sigma(\mathbf{x}) > 0 \\ 0 & \text{if } \sigma(\mathbf{x}) = 0 \end{cases} \quad (12)$$

$$Z = \frac{\mu(\mathbf{x}) - f(\mathbf{x}^+) - \varepsilon}{\sigma(\mathbf{x})} \quad (13)$$

ただし $f(\mathbf{x}^+)$ は既に探索した点の予測平均最大値、 Φ は正規分布の累積分布関数、 ϕ は正規分布の確率密度関数を示す。(12)で求められた探索点と既に探索した予測平均最大値の点 \mathbf{x}^+ との比較評価を行い、比較結果をもとに予測平均・分散を更新する。

以上を繰り返すことにより、二肢選好課題の提示刺激を逐次的に生成し、未知の関数の推定を行うことが可能になる。


本研究では化粧画像を対象とした。化粧の評価においては「良さ」は多義的であると考えられるので、「かわいさ」と「大人っぽさ」それぞれについて配色の良さに関する検討を行った。

2. 方法

実験参加者は、20代の女性8名である。

刺激画像には女性の顔写真を用いた(図2(a))。画像のサイズは960 x 960 pixelsだった。また、チーク領域のレイヤ(図2(b))、および唇領域のレイヤ(図2(c))を作成し、グレースケール化した。各レイヤの色は刺激ごとに設定された色(R, G, B)に対応してそれぞれ変化する。この際、各レイヤ内の最大輝度値となる画素が、指定した色(R, G, B)になるように設定した。またその他の画素については各 R, G, B 値に当該画素の輝度値と最大輝度値の比を乗じた値を設定した。

実験では「かわいい」条件と「大人っぽい」条件を設けた。「かわいい」条件では実験参加者には画面に提示された2つの化粧画像うち「かわいい」と感じられた刺激をキー押しにより選択するよう指示した。また「大人っぽい」条件では「大人っぽい」と感じられた方を選択するよう指示した。各実験参加者は「かわいい」条件、「大人っぽい」条件ともに1セッション行った。



(a)刺激画像 (b)チークのレイヤ (c)リップレイヤ

図2 刺激画像とチーク・リップレイヤ. 実験の際には刺激画像に目線は入っていない

提示される2つの画像のチークおよびリップの色はそれぞれ, RGB それぞれ16階調のいずれかの組み合わせによって作られる. したがって, 各刺激画像について可能なチーク・リップ色の組み合わせは 2^4 種類ありうる.

各セッションは30試行から構成され, 最初の26試行は探索空間内からランダムに選ばれたパラメータから生成された画像が提示される. また次の4試行ではすでに提示された探索点の中で最も予測平均値が高くなる配色と獲得関数が最大値となる配色を施した刺激として呈示した. この際, 画面上に刺激を提示する位置は左右でランダム化した. 獲得関数にはEI(Expected Improvement)を用いた. 実験に使用したアプリケーションは先行研究[4]を参考に PsychoPy 環境で作成した. 刺激の提示は23インチ液晶モニターで行った. また, この際, カーネル k (式5)の θ は0.5とした. 各実験参加者は1セッション行った.

実験後に, 普段どのような色のチークやリップを利用するか, およびチークやリップの色として不適切な色について自由記述で回答させた.

3. 結果

各実験参加者について, 色の組み合わせ \mathbf{x} に対する評価の予測平均値を「かわいい」「大人っぽい」についてそれぞれ求めた. 全実験参加者の応答を要約するため, パラメータ \mathbf{x} における各実験参加者 i の予測平均値から平均予測平均 μ_{allx} , および予測分散 σ_{allx}^2 を求めた.

$$\mu_{allx} = \frac{1}{N} \sum_{i=1}^N \mu_{ix} \quad (14)$$

$$\sigma_{allx}^2 = \frac{1}{N} \sum_{i=1}^N (\mu_{ix}^2 + \sigma_{ix}^2) - \mu_{allx}^2 \quad (15)$$

これをもとに, μ_{allx} が最大値および最小値を取る \mathbf{x} をそれぞれ求めた. ただし N は実験参加者数である.

「かわいい」平均予測平均値が最大となるリップとチークの組み合わせは, リップが赤, チークがピンク色であった. また最も「かわいい」予測平均値が低いのは, 黒いリップに灰色のチークであった(図3). 一方, 最も「大人っぽい」評価が高くなるのはリップが赤, チークが水色, 逆に最も「大人っぽい」評価が低くなるのは黄緑色のチークとリップの組み合わせであった(図4).

実験後にインタビューを行った結果では, 黒および緑はチークやリップとして不適切な色であるとの回答があった.

4. 考察

本研究ではベイズ最適化による逐次的実験計画に基づき化粧の最適な配色の探索を行い, 平均的に最も「かわいい」, 最も「大人っぽい」と評価される配色を推定した. また, 「かわいい」および「大人っぽい」の評価が最も低い配色も同様に推定した.



(a) 最大値 (b) 最小値

図3 「かわいい」評価の平均予測平均値が最大となる色の組み合わせと最小となる組み合わせ



図4 「大人っぽい」評価の平均予測平均値が最大となる色の組み合わせと最小となる組み合わせ

最も「かわいい」とされた配色のリップの色と、最も「大人っぽい」とされたリップの色はともに赤系統の色であり、共通性が認められる。一方、チークの最も「かわいい」色はピンクであるのに対し、「大人っぽい」チークは水色であった。このことは、適切なリップの色が状況によって変化しにくいのに対して、適切なチーク色は文脈によって大きく変化する、すなわち自由度が高いことを示唆している。

本研究はあくまでもトイプロブレムの域を出るものではないが、推定されたチーク・リップ色は事後の自由記述の結果と矛盾しておらず、二枝選択ベイズ最適化が配色の適切さに関する心理物理関数を推定する上で有用な手法である可能性を示唆している。

今後、二枝選択ベイズ最適化を用いた心理物理関数の推定手法を確立する上で解決しなければならない問題が2つある。1つ目は、適切なハイパーパラメータの設定に関する問題である。本研究ではガウス過程回帰を行う際のハイパーパラメータを事前に決定しているが、今後はハイパーパラメータ自体の推定も同時に行っていく必要がある。2つ目は二枝選択データによるガウス過程回帰によって得られた結果の妥当性を示す手法を確立する必要があるという問題である。これらの問題を解決することで、応用可能生の高い心理物理学的手法を確立することが可能だろう。

謝辞

本研究はJSPS 科研費 19K03375, 17H02651 の助成を受けた。

文献

- [1] Judd, D. B., Wyszecki, G., & Wrintringham, W. T. (1963). Color in business, science, and industry. *Physics Today*, 16, 74.
- [2] Moon, P., & Spencer, D. E. (1944). Geometric formulation of classical color harmony. *Journal of the Optical Society of America*, 34(1), 46-59.
- [3] Chu, W., & Ghahramani, Z. (2005). Preference learning with Gaussian processes. In *Proceedings of the 22nd international conference on Machine learning* (pp. 137-144). ACM.
- [4] Brochu, E., Cora, V. M., & De Freitas, N. (2010). A tutorial on Bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. *arXiv preprint*, arXiv:1012.2599.