

選好ベイズ最適化を用いた一対比較 UI による味生成パラメータの探索

本間 大一優* 奥野 達也* 宮下 芳明*

概要. 味センサや味物質の配合デバイスを用いれば、味を味物質の配合比（味生成パラメータ）として記述し、それを制御することで味を生成することができる。これにより、個人がパラメータ空間を探索して、目標とする味や自身の嗜好に合う味を得ることができる。しかし、この探索のためには、ユーザが各味物質を理解していることや、自分の好みを数値や言葉で説明できることが求められる。その結果、ユーザが知っている配合の周辺に探索範囲が偏ったり、求めている味をうまく数値・言語として表現できず探索が進みにくくなったりする。そこで本稿では、一対比較 UI による味生成パラメータ探索手法を提案する。ユーザは提示された2つの味を実際に味わい、「どちらがどの程度好ましいか」を答えるだけでよい。これにより、味物質の知識がなくても、また好みを数値や言葉で表現できなくても探索が可能になる。本稿では選好ベイズ最適化を用いることで、5次元空間で15から20回程度の比較で目標のパラメータ付近に収束に向かうことを可能にした。加えて、短時間での反復を可能にするために高速なカトラリー型の味配合デバイスを試作し利用した。いくつかの探索事例を通して、本手法の有効性を検証した。

1 はじめに

味をデジタルデータとして記録・再生・生成する「味覚メディア」の研究が進んでいる [9]。味覚メディアでは、複数の味物質の配合比（本稿では「味生成パラメータ」と呼ぶ）を調整することで、多様な味を表現・生成する。これにより、ユーザは連続的な味空間の中から、特定の味や自身の嗜好に適合する味を探索し、生成することが可能になる。しかし、この広大な味生成パラメータ空間から、個々のユーザにとって最適な味を見つけ出すことは、依然として難しい。この課題に対し、これまでスライダーで直接パラメータを操作する手法や、LLM との自然言語対話を通じた探索 UI が提案されてきた [7, 12, 11]。しかしこれらのアプローチは、ユーザが味物質の作用をある程度理解し、かつ自らの好みを数値や言語で的確に表現できることを前提としている。そのため、ユーザが十分に熟練していない場合に、既知の味の周辺から探索が離れられない、求める味をうまく表現できずに探索が進まない、といった問題があった。

そこで本稿では、ユーザの味に関する知識や言語化能力に依存しない新たな味探索手法を提案する。本手法は一対比較 UI を採用しており、ユーザは提示された2つの味の候補に対して「どちらがどの程度好ましいか」を判断するだけでよい。システムは、この単純な比較結果から、ユーザの潜在的な好みを表現する関数とそれを最大化するパラメータを推定していく。また、この探索過程を効率化するために、選好ベイズ最適化の枠組みを適用し、最も有益な情

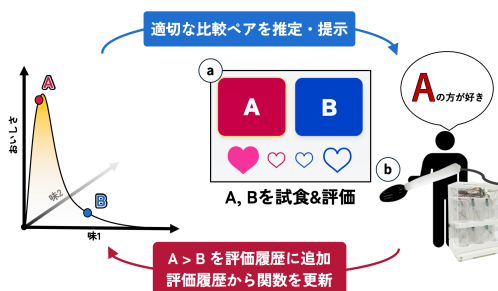


図 1. 探索の流れ。比較結果の提示と評価、目的関数の更新を繰り返す。(a) 実際の一対比較 UI。(b) カトラリー型配合デバイス

報が得られると期待される候補を提示することで、少ない試行回数での収束を目指した。さらに、高速な試行を実現するため、6個の溶液を3秒程度で配合可能なカトラリー型の溶液配合デバイスを試作し利用した。以上の設計により、単純な比較判断を繰り返すだけで、短時間のうちに自身の求める味を得ることのできるシステムの実現を目指した。

2 システム

本システムは、ユーザが求める味生成パラメータを一対比較 UI によって効率よく探索することを目的とする。そのために、選好ベイズ最適化を用いて、最も有益な情報が得られると期待される比較を提示しながら、目的関数の推定と配合の探索を同時に進めていく。ここでの目的関数は、パラメータを入力とし、そのパラメータをどれだけ好むかを出力する関数である。

Copyright is held by the author(s). This paper is non-refereed and non-archival. Hence it may later appear in any journals, conferences, symposia, etc.

* 明治大学




図 2. 合成データを用いた検証の結果

探索の流れ 探索の流れを図1に示す。まず、システムは現在の目的関数から、最も有益な情報が得られると期待される二つの候補を計算し、比較ペア A・BとしてUI上に提示する(図1a)。ユーザは、任意のタイミングでカトラリー型デバイス(図1b)を用いてA・Bを試食できる。ユーザは両方を味わった後、「Aが好み/ややAが好み/ややBが好み/Bが好み」の4段階で回答する。システムは回答を評価履歴に追加し、評価履歴をもとに目的関数を更新する。このステップを反復することで、目的関数が最大値となる点を効率よく推定していく。なお、初回の比較ペアはランダムにサンプリングされる。また、ユーザはいつでも現時点で推定される最適パラメータを出力して味わえる。

最適化手法 最適化手法として選好ベイズ最適化を採用した。ベイズ最適化は評価コストの高いブラックボックス関数に対し、限られた試行で大域的に良好な解を得る枠組みである[6]。本稿では、一対比較の導入のために、比較結果を観測値とし、観測値から潜在効用関数(好みの分布)を推定し目的関数とする選好ベイズ最適化[5]を用いた。選好ベイズ最適化では、AかBかの二値選好を観測値とするモデル[3]が一般的だが、収束が遅く実用的なレベルではなかった。そこで、新たに4段階の回答を観測値とするモデルを導入した。これは、BTL(Bradley-Terry-Luce)モデル[2]を複数段階の順序尺度に拡張したBTL(k)モデル[10]を従来のガウス過程モデル[3]の尤度関数とすることでモデル化した。これにより、AとBの距離情報を観測可能にし、一回の試行で得られる情報量を増やした。モデルの実装にはBoTorch[1]のPairwiseGPを拡張した。また、パラメータは総和1の組成データであるため、距離をそのままユークリッド距離で測るには適さない。そこで、探索空間をisometric log-ratio(ILR)変換[4]により変換している。ILR変換の基底には、Helmert基底を用いた。獲得関数にはBoTorchのEUBO[8]を用い、最適化領域はILR空間で各次元 $[-3, 3]$ とした。

図2に、合成データを用いた実験の結果を示す。横軸は試行回数、縦軸はその時点での最適予測点における真の効用関数値の平均($N = 50$)である。真の効用関数は多変量ガウス型の単峰関数($\mu = 0, \sigma = 1$)とし、順序尺度のしきい値は $\theta = [-0.3, 0, 0.3]$ とし

た。これは、好みが単峰性をもち連続的に変化する仮定に基づく。提案手法であるBTL(k)モデルは、3次元で10回程度、5次元で15-20回程度で収束に向かっている。従来の二値モデルに比べ、収束速度と精度の改善が確認できる。

3 探索事例と考察

本手法の有効性を検証するために、(1)特定の味の探索、(2)個人の好みの探索の事例を検証した。まず、「卵焼きの味」の探索を行った。グラニュー糖(20% w/v)、L-グルタミン酸ナトリウム(2% w/v)、塩化ナトリウム(4% w/v)の3成分を溶液とした。15試行の結果、最適なパラメータとして $[0.57, 0.35, 0.09]$ が得られた。この配合を試食したところ、卵焼きの味が感じられた。さらに、第三者3名に対し卵焼きの名前を伏せて試食させたところ、1名が「卵焼きの味である」と回答した。卵焼きであると明かした後は、「確かに卵焼きだ」というように全員がその再現性に納得を示した。また、同一条件で別の参加者が探索を行った結果、 $[0.53, 0.42, 0.05]$ という類似した配合が得られた。

次に、「好みの味噌汁の味」の探索を行った。溶液には、赤味噌、八丁味噌、白味噌をそれぞれ12%(w/v)で溶解した3種類の溶液を用いた。著者2名(A,Bとする)がそれぞれ15試行の探索を行った結果、最適なパラメータとして、A: $[0.05, 0.48, 0.47]$ 、B: $[0.82, 0.15, 0.02]$ が得られた。これらは大きく異なっているが、両名とも試食の結果、それぞれ自身の好みに合う味であると回答した。特に白味噌の比率が高い著者Aに関しては、家庭の味が甘めの味噌汁であることに由来する可能性を指摘しており、個人の嗜好背景を反映した結果の可能性はある。

このように本手法は、広大な味空間から特定の目標味を探索する用途、および比較的狭い味空間内で個人の嗜好を発見する用途の両方に応用できる可能性がある。また、卵焼きの例においては、味がコンポータージュっばいという意見が試食の際に得られた。これは、香りや食感に関するパラメータを導入することで、同じパラメータ空間からコンポータージュと卵焼きを生成できる可能性を示している。今後、そのようなパラメータの導入を行う予定である。

制約として、6次元以上を扱う場合には、最適な配合を得るために20回以上の試行が必要となることが予測される。加えて、ユーザの嗜好が多峰性を持つ(好ましい配合が複数存在する)場合には、最適解への収束が遅れる可能性がある。また、探索事例において「もう少ししょっぱいほうがいい」のような言語化可能な要望が思い浮かぶことがあった。そのため、本手法と自然言語対話やスライダー操作を随時切り替えることによって、より収束を早めることができる可能性がある。

参考文献

- [1] M. Balandat, B. Karrer, D. Jiang, S. Daulton, B. Letham, A. G. Wilson, and E. Bakshy. BoTorch: A framework for efficient Monte-Carlo Bayesian optimization. *Advances in neural information processing systems*, 33:21524–21538, 2020.
- [2] R. A. Bradley and M. E. Terry. Rank analysis of incomplete block designs: I. the method of paired comparisons. *Biometrika*, 39(3/4):324–345, 1952.
- [3] W. Chu and Z. Ghahramani. Preference learning with Gaussian processes. In *Proceedings of the 22nd international conference on Machine learning*, pp. 137–144, 2005.
- [4] J. J. Egozcue, V. Pawlowsky-Glahn, G. Mateu-Figueras, and C. Barcelo-Vidal. Isometric log-ratio transformations for compositional data analysis. *Mathematical geology*, 35(3):279–300, 2003.
- [5] B. Eric, N. Freitas, and A. Ghosh. Active preference learning with discrete choice data. *Advances in neural information processing systems*, 20, 2007.
- [6] P. I. Frazier. A tutorial on Bayesian optimization. *arXiv preprint arXiv:1807.02811*, 2018.
- [7] N. Kasahara, M. Fukaike, and H. Miyashita. TTTV4: Cutlery-Type Taste Display Toward Personal Taste Media. In *Adjunct Proceedings of the 38th Annual ACM Symposium on User Interface Software and Technology*, pp. 1–3, 2025.
- [8] Z. J. Lin, R. Astudillo, P. Frazier, and E. Bakshy. Preference exploration for efficient bayesian optimization with multiple outcomes. In *International Conference on Artificial Intelligence and Statistics*, pp. 4235–4258. PMLR, 2022.
- [9] H. Miyashita. Taste Media: Innovative Technology Transforms the Eating Experience. In *International Conference on Modeling Decisions for Artificial Intelligence*, pp. 8–16. Springer, 2024.
- [10] G. Tutz. Bradley-Terry-Luce models with an ordered response. *Journal of Mathematical Psychology*, 30(3):306–316, 1986.
- [11] 安地遥, 千田知佳, 宮下芳明. Sweet Synthesizer: 甘味をパーソナライズする味覚メディア. エンタテインメントコンピューティングシンポジウム 2025 論文集, 2025:404–407, 2025.
- [12] 笠原暢仁, 深池美玖, 宮下芳明. TTTV4: 一口ごとに味を提示する味覚のパーソナルメディア. 第32回インタラクティブシステムとソフトウェアに関するワークショップ (WISS2024) 予稿集, 2024.

未来ビジョン

本稿では、選好ベイズ最適化を用いて一対比較により味生成パラメータ空間を探索する手法を提案した。この選好ベイズ最適化と呼ばれる技術はパラメータ探索支援としても有用であるが、少ない試行から個人の嗜好の傾向を記述する関数（以下、嗜好関数）を推定できる点に真の価値があると考えられる。なぜなら、嗜好関数を得ることができれば、多数のユーザから得た平均嗜好関数と個人の嗜好関数との「差分」を求めることができるからだ。この差分を利用することで、マス向けの味生成パラメータ（料理本のレシピ等）を自動的にパーソナライズされたものとして利用できると考えられる。

また、嗜好はコンテキストによって変わる。たとえば、運動後は軽くさっぱりした味を欲し、長時間の集中作業のあとは甘味やコクを求めることがある。体調が優れない日は塩味や辛味を弱めたいかもしれないし、カフェで作業するときには香りは高く後味は軽いほうがよいこともある。

ベイズ最適化は、これまでの推定結果を事前分布として導入し、そのときの比較の結果を取り込みながら嗜好関数を更新できるため、ユーザが「今どんな味を求めているか」を言語化していなくても、少ない試行でコンテキストに合った味を得ることができると考えられる。

さらに、味覚配合デバイスを日常的に使い、その日の状況（気分・体調・活動量・時間帯など）の比較の履歴が少しずつ蓄積されていけば、システムは状況に応じた嗜好の変化を学ぶことができると考えられる。これにより、現在の嗜好だけでなく、未来の嗜好も予測することができるのではないかと。例えば、「今日は会議続きで疲れているから塩味は控えめ、香りは少し強め」といった予測にもとづき、調味システムや調理ロボットが夕飯の味付けを整えておくといったことが想像できる。瞬間ごとの最適化にとどまらず、長く寄り添いながらユーザとともに育っていく、伴走型のパーソナライズとしての可能性を秘めていると考えている。