

経時変化する味覚からの美味しさの予測と感度分析*

○夏目 滉大 (東京都立大学), 岡本 正吾 (東京都立大学)

Prediction of Food Liking from Time-dependent Changes in Taste and Sensitivity Analysis

Abstract: The temporal dominance of sensations (TDS) method is a method for recording sensory changes such as taste, smell, and texture felt while eating food and drinking beverages. The temporal liking method, a similar method to TDS, records changes in preferences. We used data from coffee drinking experiences measured by both methods to build a machine learning model that predicts preferences from changes in taste and other senses. Using the predictive model, we investigated which sensations affect preferences and to what extent. Furthermore, sensitivity analysis showed that sensations such as "caramel-like," "rich," and "nutty" have a positive effect on preferences, and that the interaction of multiple sensory attributes increases preference for coffee.

1. 緒言

味覚, 嗅覚, 食感など, 食事時の感覚の経時変化を記録するために Temporal Dominance of Sensations (TDS) 法が用いられる^{1),2)}. TDS 法は従来の官能評価法と比較して手軽であることから, 食品科学分野では一般的な手法となっている. Temporal liking 法は体験中の好みの変化を記録する手法である^{3),4)}. この手法は, TDS 法と組み合わせて, 食品に対する嗜好の強度の経時変化を観察するのに用いられる.

われわれは, TDS 法と Temporal Liking 法で記録したコーヒーの飲用体験のデータセットを用いて, 感覚の変化から嗜好の変化を予測する機械学習モデルを構築した. 過去の研究ではイチゴを対象とした予測モデルを扱った⁵⁾. TDS 法と Temporal liking 法の結果の関係を機械学習によってモデル化した例は, 現時点でこれ以外にない. 本研究では, コーヒーで同様の予測を試みることで, われわれの導入した手法を飲食物一般に応用できる可能性を示す. また, 予測モデル出力の感度分析により, コーヒーの美味しさに影響する感覚属性を特定し, その影響の大きさを調査する.

2. TDS 法と Temporal liking 法

2.1 実験手法

TDS 法の実験はコンピュータを用いて行われる. 画面には「甘い」など感覚を説明する属性語のボタンが複数表示される. Fig. 1 は実験に用いられるユーザ・インタフェースである. 参加者が食品を口に入れた瞬間に実験が開始する. 参加者は食品を味わいながら, 現在最も支配的に感じる感覚属性のボタンを押す. 支配的な感覚が変化したら, 別のボタンを押すことで選択を変える. 複数のボタンを同時に選択することはできず, 別のボタンが押されると直近の選択は解除される. 食品を飲み込んだ瞬間に実験は終了する.

Temporal liking 法の実験でも同様にコンピュータが用いられるが, 感覚属性の代わりに数字の書かれたボタンが表示される点で異なる. 参加者は 1 から 9 まで

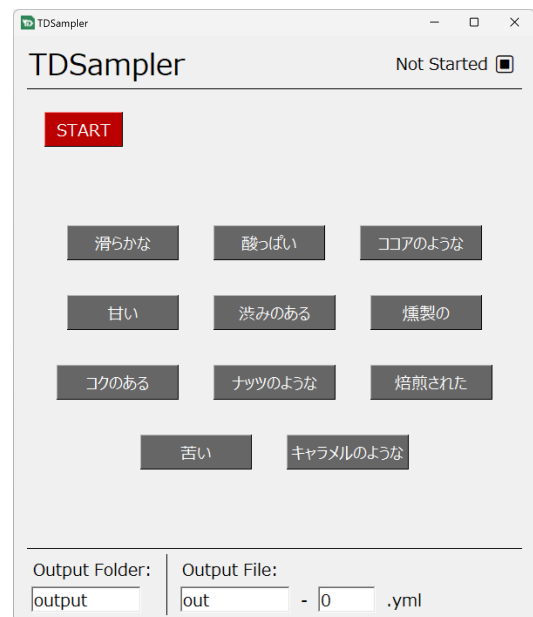


Fig. 1 TDS タスクのためのインタフェース

の 9 段階で食品への好みを評価し, その変化が記録される. 数字の大きさは, 参加者の嗜好の高さを意味する.

2.2 TDS カーブと liking カーブ

TDS 法の実験結果は TDS カーブとして可視化される. ある属性の TDS カーブは, 全試行においてその属性が選ばれた試行の割合の経時変化を表す. Fig. 2 はコーヒーの TDS カーブである.

Temporal liking 法も同様に, カーブとして可視化される. Liking カーブは全参加者の liking スコアの変化を平均したものである. ここで, 実験開始直後から最初のボタンが押されるまでの何も選択されていない期間は, liking スコアは 0 であるとする. Fig. 3 はコーヒーの liking カーブである.

3. TDS カーブからの liking カーブの予測

3.1 コーヒーの TDS データ

20 代の大学生 21 人が TDS および Temporal liking タスクに参加した. 各参加者は, 4 種類のコーヒーにつ

* This study was in part supported by Lotte Foundation (2023-B1).




Fig. 2 コーヒーの TDS カーブ

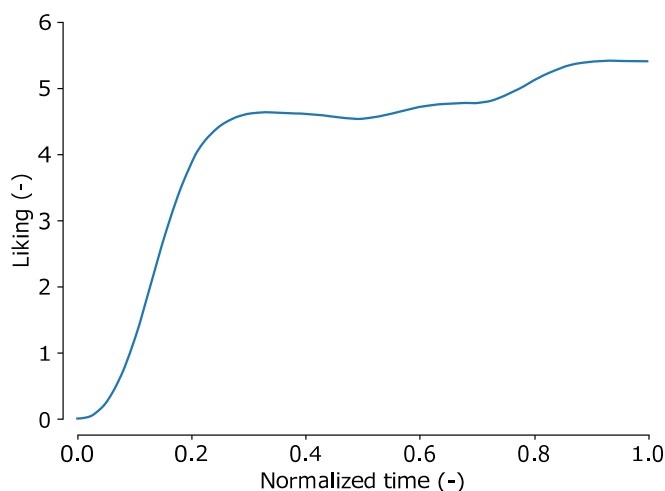


Fig. 3 コーヒーの liking カーブ

いて、TDS タスクと Temporal liking タスクをそれぞれ 2 回または 3 回繰り返した。本研究では、製品は区別せず、参加者ごとに TDS および liking カーブセットを用意する。つまり、参加者 1 人のカーブセットには 8 (4×2) または 12 (4×3) の試行が含まれる。

3.2 リザバ・コンピューティング

リザバ・コンピューティングは時系列データなど文脈を持つ情報や周期的な信号を扱うための機械学習手法である。本研究では、TDS カーブから liking カーブを予測するために、リザバ・モデルの一種であるエコー・ステートネットワーク (ESN) を用いる。ESN は入力層、リザバ、出力層の 3 層で構成される。リザバはスパースなリカレントニューラルネットワークである。リザバ内のノードは互いにランダムな重みで結線されている。入力層からリザバまでの接続強度および重みもランダムに決定され、固定である。リザバから出力層までの重みは、モデルの訓練によって調節される。これにはリッジ回帰などの線形学習機が用いられる。

ESN を含むリザバモデルは、時系列データの記憶に必要な再帰構造を持ちつつ、重みの調節を出力層のみに限定することで、計算コストを抑えている。その軽量さから、ロボット制御などリアルタイム性の求められる領域での活用が期待されている。本研究では、その扱いの簡単さと導入のしやすさから、TDS カーブの学習に ESN を用いた。

3.3 Bootstrap 法による訓練データの再標本化

ESN の訓練および検証用のデータセットを生成するために、TDS カーブと liking カーブの両方に Bootstrap 法⁶⁾を適用した。Bootstrap 法は、元のデータから無作為に標本を復元抽出することによってサンプルの分布を推定する統計的手法である。

まず、各参加者の TDS カーブセットを平均して、参加者ごとに 1 つの TDS カーブセットにした。同様に、liking カーブも参加者ごとに平均化した。この作業により、21 組の TDS カーブと liking カーブのペアが得られた。この 21 組の標本から、重複を許容して新たに 21 組の標本を抽出し、TDS カーブと liking カーブのペアを平均して 1 つのデータセットとした。このプロセスを繰り返すことで、各モデルについて 100 個の訓練データセットと 20 個の検証データセットを作成した。

3.4 予測モデルの構築

TDS カーブから liking カーブを予測するため、独立した 16 個の ESN を構築した。いずれのモデルも、入力層の次元は属性数と同じ 11 である。また、Temporal liking はスカラー値であるため、出力層の次元は 1 である。リザバのニューロン数は、60 から 200 まで変化させて出力の誤差を観察し、最適な値として 128 を選択した。その他の主要なパラメータにはリーク率、スペクトル半径、入力スケールリングがあり、それぞれ 0.01, 0.9, 1 とした。

3.5 モデルの性能評価

構築した 16 のモデルそれぞれに対し、20 の検証データセットを用いて temporal liking の予測を行った。二乗平均平方根誤差は $0.343 \leq RMSE \leq 0.891$ (中央値 0.102) であり、決定係数は $0.650 \leq R^2 \leq 0.995$ (中央値 0.949) であった。

4. おいしさに影響する感覚属性の特定

4.1 モデルのステップ応答

構築したモデルにステップ入力を与える。ある属性のステップ入力とは、その属性の値が常に 1 であり、それ以外の属性が 0 の値をとるような TDS カーブである。この入力に対するモデル応答の最大値を記録する。2 つの属性の値が常に 0.5 となるような TDS カーブを、2 属性のステップ入力とする。1 属性のステップ入力と同様、2 属性のステップ入力を各モデルに与え、応答の最大値を記録する。単一属性 a のステップ応答の最大値を $y(a)$ とする。また、2 属性 (a, b) のステップ応答の最大値を $y(a, b)$ とする。

Table 1 各属性の相互感度. 16 個のモデルの平均と 95%信頼区間.

キャラメルのような	3.10 ± 1.25
コクのある	2.86 ± 1.26
ナッツのような	1.90 ± 1.32
苦い	1.28 ± 0.78
酸っぱい	0.88 ± 0.40
ココアのような	0.66 ± 1.31
燻製の	0.12 ± 1.31
焙煎された	-0.26 ± 1.08
渋みのある	-0.87 ± 0.60
滑らかな	-0.87 ± 1.01
甘い	-0.94 ± 1.10

4.2 感度分析

感覚属性の相互的な影響を調査するため、感度分析を導入する。感覚属性の相互感度を式 1 のように定義する。

$$s(a) = \frac{1}{1 - |A|} \sum_{b \in A} y(a, b) - y(a). \quad (1)$$

ここで、 A は感覚属性の集合であり、 $|A|$ は集合の濃度、つまり属性の数である。相互感度は、ある属性が他の属性と組み合わせさせた際に temporal liking の最大値をどの程度上げるか、もしくは下げるかを示す。相互感度の平均と 95% 信頼区間を **Table 1** に示す。

相互感度において、0 からの有意差があったものは「キャラメルのような」、「コクのある」、「ナッツのような」、「渋みのある」、「苦い」、「酸っぱい」であった。このうち、「渋みのある」は負の値であった。渋み以外の感覚属性はコーヒーへの嗜好にポジティブに寄与し、他の属性の効果を高めると判断する。

ただし、Fig. 2 に見られるように、「苦い」と「酸っぱい」以外の属性は、チャンスレベル (1 を属性数で割った値) をほとんど超えない (これらの属性はあまり選択されていない)。

5. 結論

構築したリザバ・モデルは、決定係数 $0.650 \leq R^2 \leq 0.995$ の精度でコーヒーの TDS データから liking カーブを予測することに成功し、食品および飲料の研究に幅広く応用できる可能性が示された。感覚と好みの関係をモデル化することができれば、官能評価試験の試行回数が少ない場合であっても、別の感覚特性から予測した値を用いて結果を補完することができるだろう。感度分析では、「キャラメルのような」、「コクのある」、「ナッツのような」などの感覚属性がコーヒーの嗜好にプラスの影響を与え、他の属性の効果を強化することが明らかになった。

参考文献

- [1] International Organization for Standardization. *ISO 13299: Sensory analysis—Methodology—General guidance for establishing a sensory profile*. Standard. Geneva, Switzerland: International Organization for Standardization, (2016).
- [2] N. Pineau et al. Temporal dominance of sensations: Construction of the TDS curves and comparison with time-intensity. *Food Quality and Preference* 20.6, pp. 450–455, (2009). DOI: 10.1016/j.foodqual.2009.04.005. URL: <https://www.sciencedirect.com/science/article/pii/S0950329309000603>.
- [3] A. Thomas et al. Temporal Drivers of Liking. *Food Quality and Preference* 40. Tenth Pangborn Sensory Science Symposium, pp. 365–375, (2015). DOI: <https://doi.org/10.1016/j.foodqual.2014.03.003>. URL: <https://www.sciencedirect.com/science/article/pii/S0950329314000366>.
- [4] M. Meyners. Temporal liking and CATA analysis of TDS data on flavored fresh cheese. *Food Quality and Preference* 47, pp. 101–108, (2016). DOI: <https://doi.org/10.1016/j.foodqual.2015.02.005>. URL: <https://www.sciencedirect.com/science/article/pii/S0950329315000361>.
- [5] H. Natsume and S. Okamoto. Prediction of dynamic preference by using temporal dominance of sensations data. *International Symposium on Affective Science and Engineering*. (2024), pp. 1–3. DOI: 10.5057/isase.2024-C000038.
- [6] S. Okamoto. Bootstrap Resampling of Temporal Dominance of Sensations Curves to Compute Uncertainties. *Foods* 10.10, (2021). DOI: 10.3390/foods10102472. URL: <https://www.mdpi.com/2304-8158/10/10/2472>.