

## 機械学習を用いたカクテルの味推定

武藤 真弘<sup>†</sup>慶應義塾大学大学院理工学研究科  
開放環境科学専攻<sup>†</sup>櫻井 彰人<sup>‡</sup>慶應義塾大学理工学部<sup>‡</sup>

## 1. 背景

近年、個人が料理のレシピを投稿できるようになり、インターネット上には多種多様な料理レシピが存在するようになった。しかしながら同じ料理にも複数のレシピがあり、慣れない人にはその選択が難しい。ランキングや協調フィルタリングによるレコメンデーションに頼ることもできるが、レシピや写真を参考にしても、出来上がりの味を想像するのは難しい。例えば、料理レシピから味が推定できればこのような不便は解消する。

料理の味の推定に関する研究はあまり行われていないため、まずは複雑な調理手順を踏まない単純なレシピについて味の推定を試みる。その例として、調理をせず、しかし複数の味が作られるカクテルの味の推定を行うこととした。カクテルは様々な酒や果汁などを混ぜて作るアルコール飲料で、材料の分量や組み合わせによって味が構成される。

## 2. 提案手法

## 2.1 データセット

カクテルレシピを掲載している Web サイト<sup>1</sup>から得た 3176 個のレシピを用いる。レシピのうち材料と味の情報をベクトルで表現する。また材料に関して銘柄を指定しているものに関しては、対応する一般的な名称に置き換えた。表 1 に代表的なレシピである Old Fashioned の材料と味の記載例を示す。

表 1: Old Fashioned のレシピ

量	単位	材料	味
2	Part	Bourbon	Bitter
2	Dash	Bitter	Herb
1	Whole	Sugar Cube	
1	Twist	Orange	

## 2.1.1 入力値

材料の種類は 394 種類あり、単位は 25 種類ある。そこで各カクテルは次のようなベクトルで表される。

$$X = [x_1, x_2, \dots, x_{394}]$$

$$x_i = [\text{量}, \text{単位ID}]$$

使用しない材料  $x_i$  は  $[0, 0]$  と表す。単位については、例えば、重さなら g、体積なら ml で統一できるとよいのだが、大匙やダッシュといった換算できない量の表記が使われている。そのため、レシピに使われている単位をそのまま用いることとした。

## 2.1.2 出力値

味の種類は 9 種類 (Berry, Bitter, Fresh, Fruity, Herb, Sour, Spicy, Spirits palpable, Sweet) がある。出力値は長さ 9 の 0/1 ベクトルとした。従って目標値はレシピに表記されている味を 1, 他を 0 としたベクトルである。

表 1 の Old Fashioned の場合、正解ベクトル  $Y$  は、

$$Y = [0, 1, 0, 0, 1, 0, 0, 0, 0]$$

となる。

## 2.2 モデル

本研究で行う味推定は、1 つのサンプルが複数のクラスに所属するマルチラベル分類問題である。マルチラベル分類問題では、問題を複数の 2 値分類や  $2^n$  個 ( $n$  はラベル数) の寡集合をラベルに変換して解く [1]、またはマルチラベル分類問題を扱えるアルゴリズムを適用して解く方法がある。前者の複数の 2 値分類を解く手法として SVM、後者の手法としてニューラルネットワークを用いる。本研究では両者を試み比較する。

Prediction of cocktail taste using machine learning

<sup>†</sup> Muto Masahiro, Graduate School of Science and Technology, Keio University<sup>‡</sup> Sakurai Akito, Faculty of Science and Technology, Keio University

### 2.2.1 FFNN

本研究では、出力層の活性化関数にシグモイド関数、誤差関数に二乗誤差を用いる順伝播型ニューラルネットワーク (Feedforward Neural Network) (以下, FFNN) を提案する. シグモイド関数は,

$$f(x) = \frac{1}{1 + e^{-x}}$$

で定義され,  $[0, 1]$  の値を取る. その他, 出力層以外の層では正規化線形関数 (ReLU), 最適化手法に Adam[3] を用いた.

### 2.2.2 SVM

提案手法の比較対象として, SVM を用いて 9 つの 2 値分類を行う. それぞれの label に対して別々の SVM 分類器を用いる. またグリッドサーチによりパラメータチューニングを行った.

## 3. 実験及び評価

全データ 3176 個のうち 3000 個を学習データとし, 176 個をテストデータとした. それぞれランダムに選び, 10 回実験を行った. FFNN の出力は各 label に対して  $[0, 1]$  の連続値を取るため, 各 label の値  $y$  に対して以下の変換を行い, テストセットの正答率を計算した (表 2 及び表 3).

$$y' \leftarrow 1 \text{ if } y \geq 0.5 \text{ else } 0$$

### 3.1 実験 1

入力ベクトルに関して, '量' と '単位' の情報を使わずに, 各材料を使用する/しないの 2 値からなるベクトルとした. 後述する実験 2 おいて, '量' と '単位' の情報がどのように影響するかを調べるためである. FFNN, SVM どちらもパラメータチューニングを行った. 特に SVM に対しては label ごとに設けたそれぞれで最適化を行った.

表 2: 実験 1 の結果

Label	FFNN	SVM
Berry	96%	94%
Bitter	94%	76%
Fresh	72%	57%
Fruity	89%	63%
Herb	89%	56%
Sour	80%	75%
Spicy	97%	89%
Spirits palpable	89%	90%
Sweet	81%	71%
平均値	87%	74%

### 3.2 実験 2

入力ベクトルを 2.1.1 で定義したまま使い, 実験した. FFNN, SVM どちらも実験 1 と同様の方法でパラメータチューニングを行った.

表 3: 実験 2 の結果

Label	FFNN	SVM
Berry	94%	95%
Bitter	93%	78%
Fresh	78%	69%
Fruity	84%	63%
Herb	84%	80%
Sour	85%	73%
Spicy	97%	89%
Spirits palpable	97%	92%
Sweet	81%	72%
Average	88%	79%

### 3.3 考察

表 2, 3 より平均値を比較すると, '量' と '単位' の分量情報が推定精度の向上に寄与することがわかる. しかし FFNN では SVM ほどの精度向上はなかった. またどちらの実験でも 提案手法 (FFNN) のほうが精度は良かった. また味によって精度に差があり, FFNN の場合, 'Fresh' の精度が他より明確に低かった.

## 4. まとめ

カクテルレシピの材料と分量の情報からカクテルの味を平均精度 88% で推定することができた. また材料の分量情報が精度向上に影響があることがわかり, 本研究では使用しなかった, 材料を入れる順番や混ぜ方などの手順情報を利用することで更なる精度向上を図りたい.

## 参考文献

- [1] Grigorios Tsoumakas, Ioannis Katakis, and Ioannis Vlahavas, Mining Multi-label Data, <http://lps.csd.auth.gr/publications/tsoumakas09-dmki.pdf>
- [2] 岡谷貴之 (2015), 機械学習プロフェッショナルシリーズ 深層学習, 講談社
- [3] Diederik Kingma, Jimmy Ba, Adam: A Method for Stochastic Optimization, <http://arxiv.org/pdf/1412.6980v8.pdf>

<sup>1</sup> <http://www.absolutdrinks.com/>