

# 天候・身体状況に基づくオリジナルコーヒー提案システムの改善と評価

木村 伊織<sup>†</sup> 中島 毅<sup>‡</sup>

芝浦工業大学<sup>†‡</sup>

## 1 研究背景

日本におけるコーヒー消費量は年々増加しており、2012年から2019年にかけて15万KLも増加している。また、コーヒーの喫飲場所は家庭が最も多いことが報告されている[1]。このことから、家庭で飲むコーヒーに要求されるクオリティが高くなっているであろうと推測できる。そのため、個人の好みに適したオリジナルコーヒーを作れるようなシステムの登場が望まれる。

## 2 先行研究

### 2.1 先行研究について

先行研究では、個人の身体データと天候データを基にユーザーが一番おいしいと感じられるコーヒーのブレンド比率を推薦するシステムを改善している[3]。

システム改善では、身体・天候データを Web API を用いて収集し、フィードバックをスマートフォンアプリによって収集することで UI の改善に成功した。また、学習に Deep Q Network (DQN) を用いることで提案の精度を高めることにも成功している。図 1 に先行研究のシステム概要を示す。

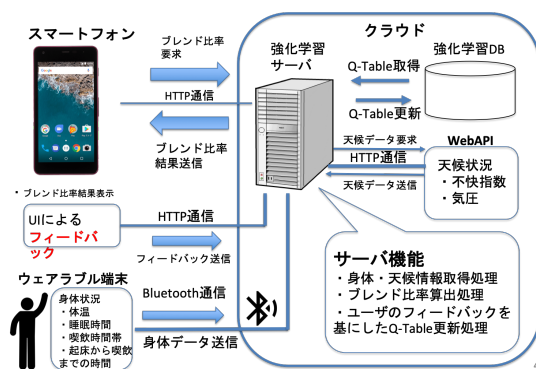


図 1: 先行研究のシステム概要図

示す。

### 2.2 先行研究での課題

先行研究では、プログラムが推定するブレンド

Improvement and evaluation of an original coffee suggestion system based on physical and weather conditions

<sup>†</sup>Iori Kimura, Shibaura Institute of Technology

<sup>‡</sup>Tsuyoshi Nakajima, Shibaura Institute of Technology

比率と被験者の好みの偏差が収束し始めるまでおよそ 80 回程度の試行が必要であった。また、システムの評価を行う実験では、システムの提案するブレンド比率の正答率は 5~60%であった。家庭でのオリジナルブレンド提案システムとして用いることを考えると、先行研究では以下の 2 点が課題となる。

- (A) システムの精度が高くないこと
- (B) 好みに合うまでの試行回数が多いこと

## 3 研究目的と課題解決へのアプローチ

本研究では、個人の好みに素早く合わせられるようにするために、過去の実験データを用いて学習方法を改善することを目的とする。

本研究では、前節の 2 つの課題を解決するため転移学習を適用するアプローチを採用。転移学習とは、別の関連した問題のデータや学習結果を再利用し、効率的に学習することである[4]。転移学習のためのデータとして、過去複数人に対して実施した実験データ[3]を用いた。DQN に転移学習を適用する方法として次の 2 つの方法を考えた。

- ① 初期 Q テーブル作成のための利用
- ② 環境探索のアクション決定に利用

本研究で利用する DQN では、心拍数・喫飲時間帯・睡眠時間・不快指数・肉体的疲労度の 5 つを状態とし、6 種のブレンド比から 1 つを選択する(アクション)モデルを利用している。

## 4 学習方法の改善

DQN では、Q 値をニューラルネットで近似することで学習を行なっている。また、効率の良い学習を行うために  $\epsilon$ -greedy 法と呼ばれる環境探索のためのアクション決定法を採用している。

$\epsilon$ -greedy 法とは、学習回数を変数に取る式から  $\epsilon$  を求め、 $\epsilon$  が所定値以上ならばランダムに行動し、所定値(0 から 1 までの乱数)以下なら学習結果に基づいて行動するというものである。本研究では以下の 3 点に変更を加えた。

- ① 学習の際、過去に行った別の被験者のデータを用いて事前に Deep Q Network の学習モデ

ルを作成し、新規学習時にそのモデルを読み込んでから学習を開始するようにした。

- ② 探索時に、 $\epsilon$ -greedy 法におけるランダム行動のかわりに、別の被験者のデータを SVM によって学習させて作成した分類器に基づいて行動させるようにした(図 2)。




図 2: 変更点 2

## 5 収束性確認実験

### 5.1 実験概要

被験者: 22 歳 ~ 23 歳の 男性 3 名

実験手順:

- ① 初回時、被験者は 10 種類の豆から一番おいしいコーヒー豆を選択(以下メイン豆種)。サブ豆種 2 種類はメイン豆種から自動的に決定する。
- ② 実験時に身体データと天候データを取得し、それぞれのデータを保存する。さらにメイン豆種をベースとしたブレンド率 6 種類のコーヒーをそれぞれ喫飲してもらい、一番おいしいブレンド比率、一番まずいブレンド比率を記録(試行数 100 回)。
- ③ 20 回と 100 回の試行が終わった時点でシステムがおいしいブレンド比率を出力できているかそれぞれ 20 回ずつ実施(被験者 2 名を学習データ、被験者 1 名をテストデータとする)。
- ④ 収集したデータを基に 2 つの学習法に基づいた Q 値収束についての評価をそれぞれ行い比較。

### 5.2 実験結果

先行研究でのシステム(先行システム)と、今研究でのシステム(改善システム)それぞれの学習時の誤差の様子を図 3 に示す。




図 3: 損失関数の値

図 3 では値の推移に大きな違いは見受けられないが、図 4 では学習開始時の初期値に大きな違いがあることが確認できる。このことから、学習開始時点で先行システムより収束に近い段階にあると考えられる。

また、システムの実験結果(20 個のデータテスト 5 回分の平均)を表 1 に示す。

表 1: テスト 20 回における正答数平均率

テスト開始時点	先行システム	変更点①のみ	変更点②のみ	改善システム
20 回	10%	21%	11%	40%
100 回	25%	39%	30%	41%

表 1 ではシステムが出力したブレンド比率とユーザーがその時に一番おいしいと感じたブレンド比率が合致した割合を示している。先行システムの 10~25%に比べ、改善システムは 40%程度と精度の向上が見られた。さらに、20 回時点での正答率が 100 回時点と比べても差がないことから、収束が早まったことも確認できた。また、変更点①のみと②のみのシステムを比較したところ、変更点②のみの方がどちらとも正答率の高い結果となった。

## 6 まとめと今後の課題

ユーザの身体状況・天候状況のデータを収集し、それらのデータからユーザが一番おいしいと感じるブレンド比率を算出するシステムの改善と評価を行った。先行システムと改善システムを用いて比較評価を行った結果、学習速度と精度の向上がみられた。

今後、転移学習として再利用するデータの選別や、適応方法、利用した教師あり学習の部分に関しても条件を変えて評価を行いたいと考える。さらに、実験により Deep Q Network の損失関数が減少傾向であったため、学習回数を増やし、収束性の評価を行う必要があると考える。

## 参考文献

- [1] 全日本コーヒー協会. 統計資料. <http://coffee.ajca.or.jp/data> (2021 年 12 月 29 日参照).
- [3] 清水大聖, & 中島毅. (2020). 身体・天候状況に基づくオリジナルコーヒー提案システムの改善と評価. 第 82 回全国大会講演論文集, 2020(1), 327-328.
- [4] 神畷敏弘. "転移学習." 人工知能 25.4 (2010): 572-580.