機械学習を用いたコーヒー豆の焙煎結果予測における精度の比較と検証

Comparison and Validation of Accuracy in Predicting Roasting Results of Coffee Beans Using Machine Learning

岡村 将生[*1]，曽我 真人[*2]，山田 康弘 [*3]，小畑 和輝[*4]，兼田 大士[*4]
Masaki OKAMURA [*1], Masato SOGA[*2], Yasuhiro YAMADA [*3], Kazuki KOBATA[*4], Daishi KANEDA[*4]
[*1] 和歌山大学大学院システム工学研究科
[*1]Graduate School of Systems Engineering, Wakayama University
[*2] 和歌山大学システム工学部
[*2]Faculity of Systems Engineering, Wakayama University
[*3] ダートコーヒー株式会社
[*3]Dart Coffee co. ltd.
[*4] 株式会社システムキューブ
[*4]System Cube co. ltd.
Email: s226049@wakayama-u.ac.jp

あらまし： コーヒー豆は，熟練の焙煎士が長年の経験を基にして，作りたいコーヒー豆の特徴から，縦軸が温度，横軸が時間の焙煎カーブを設定することで焙煎が行われており，初心者が行うには非常に難しい工程となっている．さらに，焙煎したコーヒー豆は挽かないと中まで火が通っているのかを把握することは非常に困難である．そこで本研究では，焙煎実施前に設定した焙煎カーブで焙煎した場合の，挽く前と挽いた後それぞれのコーヒー豆の焙煎度を確認することが出来るように，様々な焙煎カーブを機械学習を用いて学習させ，できあがるコーヒー豆の色の具合を予測出力する学習モデルを複数構築し，その精度の比較と検証を行った．

キーワード：機械学習， ニューラルネットワーク(NN)，回帰，焙煎

1. はじめに

コーヒー豆の焙煎は，縦軸が温度，横軸が時間の焙煎カーブを呼ばれるグラフを焙煎機に設定して焙煎が行われる(図 1)．焙煎カーブにおける様々なポイントを変えることでできあがるコーヒー豆の色や香りなどの特徴に影響が出てくる．

焙煎した豆の色をローストカラーといい，基本的にはローストカラーが黒に近いほど苦みが強くなり，酸味が弱くなるという傾向がある．

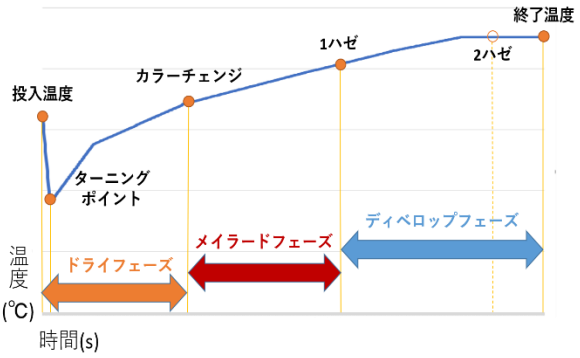

図 1 焙煎カーブと様々なポイント

コーヒー豆は，焙煎士が作りたい豆の特徴を想定してそれに応じた焙煎カーブを設定することで作られる．これは焙煎士が積み重ねてきた経験を基に行われており，初心者が設定するには難しい技術である．また，焙煎の難しさの 1 つに，焙煎をした豆が中まで火が通っているのかを豆を挽く前の状態から判断することが難しいということがある．

2. 研究目的

これらの背景から，本研究では初心者には焙煎カーブを設定する際の指標となるように，熟練者には設定した焙煎カーブで焙煎を行った際の火の通り具合を確認できるように，焙煎カーブを入力するとできあがるコーヒー豆のローストカラーを予測出力するシステムの構築を目指し，様々な焙煎カーブを学習した学習モデルを複数構築し，できあがる豆のローストカラーの予測出力の精度の比較と検証を行った．

3. 関連システム

TUNA SCOPE [(1)] というマグロの品質評価を AI 化したシステムがある．このシステムは評価物のマグロの尾部断面の画像とそれに紐付けた職人による評価数値を紐付けたデータを学習している．一方，本研究で学習に用いるデータは評価物でなく，製造工程となる焙煎カーブであり，品質評価ではなく品質予測を行うことを目的としている．

4. データの収集

豆はブラジルとコロンビアの 2 種類を，焙煎 1 回あたり 30g の豆を 5 分から 20 分の間で焙煎を行い，今回 327 のデータを収集した．専用のアプリと連動

した小型の焙煎機で焙煎を行い，豆の明度を測定してローストカラーを出力する装置で焙煎した豆を測定し，データを集めた．焙煎カーブの温度は全て 15 秒毎にサンプリングをすることで取得している．

5.　学習モデル

5.1 特徴量

教師あり学習の回帰問題であり，入力は焙煎士からいただいたアドバイスを基に表 1 のものを選んでいる．出力は焙煎したコーヒー豆の粉砕前と粉砕後それぞれの明度の数値となっている．

表 1 入力一覧

入力(単位)
気温(℃)
湿度(%)
焙煎時間(s)
焙煎カーブのサンプリング温度(℃)
ターニングポイントの時間と温度(s･℃)
カラーチェンジの時間(s)
焙煎終了時の温度(℃)
ディベロップフェーズに要した時間(s)

5.2 学習モデルの構築･比較

本研究では表 2 に示した 5 つの学習手法を用い，10 分割交差検証による評価方法で比較を行った．NN は隠れ層が 3 層の全結合層で構成されており，隠れ層の 2 層目に過度に学習データに適合することを抑制するドロップアウト層を挿入している．

結果が表 2 となっており，予測する数値範囲によって精度にばらつきが見られた．比較結果から精度の良い上位 3 つのランダムフォレスト･SVR･NN(全結合)を用いてさらに検証を行った．

表 2 学習モデルの比較結果(10 分割交差検証)

モデル名	粉砕前 MAE	粉砕後 MAE	粉砕前 RMSE	粉砕後 RMSE
線形回帰	6.86	5.46	21.12	10.15
決定木	4.36	5.48	5.70	7.26
ランダムフォレスト(100 本)	3.18	4.06	4.10	5.34
SVR	3.01	3.98	4.29	5.76
NN (全結合)	3.94	4.25	5.21	5.86

5.3 学習モデルの検証･考察

学習モデルの汎用性を見るために，検証では 50g で焙煎して得た焙煎カーブのデータを 8 種類用いた．粉砕前と粉砕後それぞれの明度数値と，粉砕後から粉砕前を引いた色数値差の 3 種類の数値を，測定した値と予測した値との絶対差を誤差として評価している．色数値差は焙煎した豆の火の通り具合の評価に相当する．

結果が表 3 となる．ランダムフォレストと SVR にはグリッドサーチを行っている．色数値差はランダムフォレストが最も良いものの，全体的には NN が最も精度が高かった．この検証において，どのモデルも全体的に測定値より予測値が低く，つまりより焙煎していると予測していた．これはおそらく 50g より 30g の方が火が通りやすかったことによるものと思われる．また，豆はチャンバーに投入されてそのチャンバーを回転させることで豆全体に火を通していく．よって今後精度の向上にはデータセットの増加はもちろん，豆のグラム数やチャンバーの回転数も特徴量として検討する必要があると考えられる．

表 3 学習モデルの検証結果

モデル名	粉砕前	粉砕後	色数値差
ランダムフォレスト(50 本)	4.86	5.39	2.44
SVR	5.44	8.31	3.45
NN (全結合)	4.55	4.92	2.52

6.　まとめ

本研究では焙煎を行うための助力システムの構築のため，焙煎に影響する要素を加味した様々な焙煎データから，できあがるコーヒー豆の焙煎度を予測する学習モデルの精度の比較と検証を行った．ある程度の精度はみられたものの，データセット内でローストカラー別でみたときに数の少ないデータに対しての予測にはばらつきがみられた．

今後，学習モデルの精度向上には，学習データ数の増加や，特徴量の見直しをする必要がある．また，今回同じ小型の焙煎機を用いてモデルの評価を行ったため，別の焙煎機に対してこの予測モデルを適用した際の精度検証も必要になる．したがって，事前に設定した焙煎カーブから予測に用いるデータを自動入力するシステムも構築していく．

謝辞

本研究グループの結成には，わかやま産業振興財団の加藤木健氏，井上真理氏にお世話になりました．深謝いたします．

参考文献

(1) 匠の目利きを、AI に託す – TUNA SCOPE
https://tuna-scope.com/jp/
(2021/06/06 参照)
(2) Aurelien Geron, scikit-learn と Tensorflow による実践機械学習，下田　倫大 監訳，長尾　高弘 訳．