

ニューラルネットワークを用いたコーヒー豆の焙煎予測システムの構築と学習効果の検証

Development of a coffee bean roasting prediction system using neural networks and Verification of the learning effect

岡村 将生^{*1}, 曾我 真人^{*2}

Masaki OKAMURA ^{*1}, Masato SOGA^{*2}

^{*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}Faculty of Systems Engineering, Wakayama University

Email: s226049@wakayama-u.ac.jp

あらまし：コーヒー豆の焙煎は焙煎した豆の設計図となる焙煎カーブを設定して行われる。その設定は焙煎士の経験を元に行う。しかし、焙煎士にとっても焙煎したコーヒー豆が中まで火を通して火を粉砕する前から判断することが困難という課題がある。また、業務用の焙煎機では一度に焙煎する量がKg 単位となり、焙煎自体にも時間を要するため容易に焙煎カーブとできあがるコーヒー豆との関連性を学ぶための試行錯誤が行えず、焙煎初学者が経験を積むにも敷居が高い。そこで本研究ではニューラルネットワークを用いて焙煎カーブと焙煎に関する情報から豆の状態を出力する機械学習モデルから上記の課題の改善を図る焙煎予測システムを構築し、システムの評価を行った。

キーワード：ニューラルネットワーク(NN)、回帰、焙煎、ローストカラー

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と呼ばれるグラフを設定し、その温度推移に沿って焙煎機内の温度を調節して行う。焙煎カーブは、作りたい豆の特徴によって調節をする様々なポイント(表 1)があり、これらを考慮して設定される。焙煎した豆は焼き具合から 8 種のローストカラーに分類でき、これは味わいにも相関を持つため、焙煎の指標になっている。また、豆は水分が蒸発して焙煎される。焙煎前後の豆の重要変化量はモイスチャーロスという水分変化量として把握可能で、ローストカラーより容易に定量的に得られる。この要素から同じ焙煎度でも水分量の違いによる味の雑味の把握や、生焼け状態になる焙煎の理解につながる。

1.1 研究背景

焙煎工程の課題として、初心者は焙煎カーブと豆の関係性を知らず、焙煎機を用いて学ぶにも焙煎に最低 10 分ほどの時間と豆が必要になり、試行錯誤することが困難である。また、経験値にかかわらず、焙煎した豆が芯まで火が通っているのかを粉砕する前の状態から判断することが難しいといった点もある。

表 1 焙煎カーブにおける様々なポイント

1 投入温度	焙煎開始時の焙煎機内温度
2 ターニングポイント	投入後の下がった投入温度が再び上がる点
3 カラーチェンジ	豆がきつね色に変化するタイミング
4 ファーストクラック	豆が音を立てて割れるタイミング
5 セカンドクラック	4 が起こった後、豆が割れるタイミング
6 終了温度(時間)	焙煎終了時の温度(時間)
7 ドライフーズ	投入温度～カラーチェンジ
8 メイラードフェーズ	カラーチェンジ～ファーストクラック
9 デベロップフェーズ	ファーストクラック～終了温度(時間)

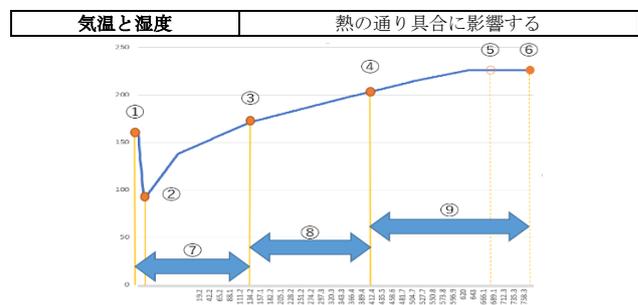


図 1：焙煎カーブ

2. 研究目的

焙煎カーブからローストカラーと水分変化量を予測出力するモデルを構築，コーヒー豆の焙煎予測システムとして活用し，その有用性を検証することを目的とする。このシステムの有用性は，焙煎のシミュレータに利用できることにあり，システム上で様々なパターンの焙煎カーブと豆の特徴の把握が可能になることである。これにより様々な焙煎カーブを効率よく学習でき，豆の状態も事前に把握できる。

3. 関連事項

3.1 関連システム

TUNASCOPE(1) は、マグロの尾部断面から品質評価をする目利き技術を職人レベルで評価する。これは、評価物の画像に紐付けた評価数値をディープラーニングで学習し開発された。本研究は、焙煎したコーヒー豆の品質の予測に焙煎カーブを学習し、評価物の製造工程から品質予測を行っている。

3.2 関連研究

浅煎り中心の焙煎カーブで焼く豆の焙煎中の状態を視覚的品質評価するモバイルシステム開発を行っ

た研究(2)がある。この研究は焙煎中の豆に着目し、焙煎を止める適切なタイミングを図ることを目的としている。本研究では焙煎後の豆の状態に着目し、焙煎カーブとの関係性の学習に用いる。

4. 学習モデル

4.1 学習データ詳細

ブラジルとコロンビア産の豆を用いて 1 回 30g、焙煎時間 5~20 分で総計 399 のデータを収集した。入力は表 2 に示しており、これらは焙煎士からいただいたアドバイスを元に選出した。出力は焙煎した豆の粉碎前後の焙煎度合いを表すアグトロン値という測定数値である。モイスチャーロスの予測には、表 2 の焙煎カーブの温度サンプリングデータとターニングポイントの温度を除き、粉碎前後のアグトロン値を入力に追加して学習を行った。

表 2 入力

特徴量名	詳細
Finish-t	焙煎時間
Dt-t	デベロップフェーズの時間
Turning-point-t	ターニングポイントの時間
cc-t	カラーチェンジの時間
Finish	焙煎終了時の温度
Turning-point	ターニングポイントの温度
Columbia-brazil	ワンホットエンコーディング
0~80(1=15秒)	焙煎カーブの温度サンプリングデータ

4.2 各予測モデルの構築

予測モデルの構築にあたり、気温と湿度の要素は今回用いた機材の関係上、予測に対して影響が見られなかったため入力から除いている。ローストカラーのモデル構築に全結合のニューラルネットワーク(NN)を 3 層構造で構築した。入力ノード数は 89、出力は粉碎前後のアグトロン値、中間層 2 層目には過学習抑制にドロップアウト層を 0.2 の割合で挿入している。モイスチャーロスのモデル構築も同様 NN で、入力層は 9、中間層 2 層で構築した。どちらもエポック数 200、10 分割交差検証を行って学習している。表 3 が各予測モデルの結果となる。

表 3 各モデル学習結果(10 分割交差検証)

モデル	MAE	MSE
粉碎前モデル(アグトロン値)	3.79	5.22
粉碎後モデル(アグトロン値)	4.64	6.22
モイスチャーロスモデル(%)	0.42	0.57

4.3 予測モデルの評価

いずれのモデルに関しても、焙煎の概要を学ぶ範囲内であればまだしも、焙煎カーブとローストカラーとの関係性を詳細に把握するためにはまだ改善が必要であると考えられる。改善のためには学習に用いたデータの偏りや今回未測定だった関係性をもつ要素(チャンバーの回転数など)の調査などが挙げられる。

5. 焙煎予測システムへの活用と評価

構築したモデルを焙煎予測システムとして活用し、本システムを用いて統制群法で評価実験を実施し、また、焙煎士にも触れていただき評価をいただいた。



図 2 焙煎予測システム画面

表 4 統制群法テスト結果

対象	事前テスト(点数)	事後テスト(点数)	向上値(点数)	学習時間(MM:SS)	焙煎回数(回)
統制	49.7	78.3	28.7	67:45	3.5
実験	50.3	74.8	24.3	36:01	99.2

6. 結果と考察

焙煎士からは高評価であった。システムの活用法としても納得いただける内容であり、研修や現場で活用できるとの評価をいただいた。統制群法による実験の結果(表 4)、学習システムとして活用するには焙煎機に置き換わるほどではないが、学習時間に大きな差が見られ、効率性の高さが実証された。焙煎機との併用によって体験を伴う効率的な焙煎学習を望める可能性がある。

謝辞

本研究におきまして、多大なご協力をいただきましたダートコーヒー株式会社様に深く感謝申し上げます。

本研究の一部は科研費課題番号 17H01996 の支援を受けて推進した。

参考文献

- (1) 匠の目利きを、AI に託す-TUNA SCOPE <https://tuna-scope.com/jp/> (2023/01/10 参照)
- (2) Muslih Hakim, Taufik Djatna, Indah Yuliasih “ Deep Learning for Roasting Coffee Bean Quality Assessment Using Computer Vision in Mobile Environment ” 2020 ICACSI, IEEE 363-370
- (3) 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.
- (4) 著 田口護 旦部幸博 ”コーヒー おいしさの方程式 ”NHK 出版, 2014