

7.5 学位論文要旨（別紙様式博5）

学位論文要旨

学位授与申請者

下藤 悟

題目：日本酒解析からみた食品の感覚・嗜好機能の定量化にむけた解析法の構築

本研究は、食品の感覚・嗜好機能の定量化に向けた解析法を構築したものである。日本酒を対象に、感覚・嗜好機能を表す官能評価の結果を物理化学的分析データから高い精度で予測することを目的とし、機械学習、網羅分析といった手法の有用性を明らかにした。さらに官能評価項目の設定に活用するために、おいしさを評価することばについての整理を行った。そして、感覚・嗜好機能の定量化に向けた回帰モデルを得るための解析法を構築した。

序論

食品の感覚・嗜好機能は、主においしさとして表されるものであり、食品産業に携わる人々にとって商品開発や新技術開発の指標となるため、定量的に捉えることが重要な課題である。

感覚・嗜好機能の定量化は、官能評価の結果と物理化学的分析値の関係を回帰分析で解析する手法が一般的である。近年では、網羅分析、機械学習、デジタル端末を用いた官能評価といった技術が活用されてきているが、これらの技術を組み合わせて定量化を行った研究は見られない。また、食品科学分野では汎化性能への影響を基に検討した報告は非常に少ない。そこで本研究では、食品の感覚・嗜好機能の定量化にむけた解析法を構築することを目的とした。

第1章 日本酒の総合評価と物理化学的特徴との関係性の解析における機械学習の適用

第1章では、回帰分析手法として機械学習に着目し、日本酒の品質に関する総合評価に対する物理化学的特徴の寄与をより明確にすることを目的とした。

純米吟醸酒 173 品（2017 醸造年度）を試料とした。目的変数には日本酒の品質に関する総合評価、説明変数には物理化学的分析値を用いた。物理化学的分析として、酸度、アミノ酸度、グルコース含有量、核酸関連物質（OD₂₆₀、OD₂₈₀）、揮発性成分 9 成分（アセトアルデヒド、酢酸エチル、プロパン-1-オール、イソブチルアルコール、酢酸イソアミル、3-メチル-1-ブタノール、カプロン酸エチル、カプリル酸エチル、カプロン酸）の含有量、Brix、pH、導電率を測定した。回帰分析は統計処理ソフト R にて行い、重回帰分析 (Multiple Regression Analysis: MRA)、部分最小二乗法 (Partial Least Squares regression: PLS) と、機械学習 3 種:人工ニューラルネットワーク (Artificial Neural Network: ANN)、サポートベクターマシン (Support Vector Machine: SVM)、ランダムフォレスト (Random Forest: RF) を用いた。解析はトレーニングデータ 158 品とテストデータ 15 品に分けて行い、予測精度を比較した。

トレーニングデータにおける総合評価の予測精度 (Accuracy $T=0.25$) は MRA: 64.6 %、PLS: 60.1 %であったが、ANN:67.1 %、SVM: 80.4 %、RF: 92.4 %であり、機械学習、特に RF がより回帰モデルの適合度が高かった。また、テストデータにおける総合評価の予測精度は、MRA、ANN、SVM、RF で 73.3 %、PLS で 60.0 %であった。絶対平均誤差 (Mean Absolute Error: MAE) は機械学習である SVM と RF が MRA よりも小さく精度が高かった。しかし、品質が低いと評価された試料の予測精度が低く、説明変数に網羅分析のデータが必要であることが示唆された。

次に、物理化学的特徴の寄与について、RF の重要度と MRA の重回帰係数の値から考察したところ、酢酸イソアミルは成分が多いと品質が高い評価につながりやすく、カプロン酸エチルは成分量が総合評価に及ぼす影響が大きく、かつ評価者によって評価が分かれやすい成分であった。また、酢酸エチルのように特徴の寄与が非線形関係となる成分があることが示された。

第 1 章では、機械学習である RF がより正確に評価の特性を把握できていることを示した。また、日本酒の総合評価への物理化学的特徴の寄与について、機械学習から得られる指標と重回帰係数を組み合わせることでより明確にすることができた。

第 2 章 機械学習によるフラッシュ GC ノーズと電子味覚システムを用いた日本酒成分の予測

第 1 章で総合評価の予測精度をより高めるためには網羅分析のデータの必要性が示唆された。そこで第 2 章では、フラッシュ GC ノーズ (E-Nose) と電子味覚システム (E-Tongue) により日本酒の主要な成分を網羅的に予測することを目的とした。

純米吟醸酒 179 品 (2018 醸造年度) を試料とした。目的変数には日本酒の成分値 (酸度、アミノ酸度、グルコース含有量、揮発性成分の含有量)、説明変数には E-Nose、E-Tongue、簡易分析 (Brix、pH、導電率、核酸関連物質、簡易アルコール含有量、簡易グルコース含有量) のデータを組み合わせて用いた。回帰分析はトレーニングデータ 141 品に対して、PLS、MRA、SVM、RF、勾配ブースティング (Gradient Boost: GB) を行い、テストデータ 38 品の予測精度を比較した。

その結果、最良の予測精度となる説明変数と回帰分析手法は成分により異なるが、E-Nose、E-Tongue、簡易分析のデータから日本酒の主要な成分を平均約 5 % の誤差で予測できた。

第 3 章 網羅分析と機械学習を用いた日本酒の総合評価の予測

第 3 章では、機械学習、網羅分析を組み合わせることで日本酒の品質に関する総合評価の予測精度を向上させることを目的とした。

日本酒 97 品 (2018・2019 醸造年度) を試料とした。目的変数には日本酒の品質の総合評価、説明変数には官能評価による特徴評価 (香り全体・吟醸香以外の香り・甘味・酸味の強弱、辛口ー甘口・淡麗ー濃醇の程度) と物理化学的分析データ (主要な成分分析、網羅分析) を用いた。主要な成分分析として、酸度、アミノ酸度、グルコース含有量、核酸関連物質、揮発性成分の含有量を測定した。網羅分析には E-Nose、E-Tongue を用いた。回帰分析はトレーニング

データ 89 品に対して PLS、SVM、RF、GB を行い、テストデータ 8 品の予測精度と比較した。

特徴評価での総合評価の予測は MAE: 5.71、自由度調整済み決定係数 (adjusted R²: adjR²): 0.61 と予測精度が高かった。一方で、主要な成分分析データでの予測は MAE: 7.41、adjR²: 0.44 と予測精度が低かったが、網羅分析データを追加することで MAE: 5.98、adjR²: 0.62 と予測精度が向上した。特徴評価からの予測では GB (機械学習)、物理化学的分析データからの予測では PLS (線形回帰) の予測精度が高かった。目的変数が同じでも、説明変数によって最適な回帰分析手法が異なるため、複数の手法で解析を行い、決定する必要があることが示唆された。

第 3 章では、網羅分析データを用いることで分析データからも、人の感覚による特徴評価データからの予測と遜色のない精度で日本酒の総合評価を予測することができた。

第 4 章 おいしさを評価することば —五感表現の収集分類と抽象的表現の特性解析—

第 3 章までは、日本酒の官能評価項目について、評価者の共通認識のあることばを用いてきた。しかし、品質以外の評価を定量化するためには、そのことばの特性を把握する必要がある。そこで第 4 章では、抽象的なことばで形容された日本酒に対する評価者の認識を明確にすることを目的とした。「(形容詞 180 語) + 日本酒」ということばから受ける印象を第 3 章で用いた官能評価項目で評価を行った。評価結果に対し、局所的に重み付けされた散布図平滑化法を行うことで、評価者により認識が共通する語群や相違がある語群を視覚的に捉えることができた。

第 4 章では、抽象的なことばに対する評価者の認識の特性を把握する方法を提示した。

総括

本論文では、日本酒を対象に感覚・嗜好機能を定量化する際に、物理化学的分析として網羅分析を用いることや、適切な回帰分析手法を選択することで予測精度を高めることができた。さらに、汎化性能によって解析条件を比較することで、機械学習、網羅分析の有用性を明らかにした。

そして、各章で得られた知見を基に、官能評価の結果を物理化学的分析データからより正確に予測するための解析条件を汎化性能によって検証する一連の解析法を構築したという点において本研究は、食品産業における商品開発や新技術開発に貢献できることに意義がある。