

安価な筋電センサによる食感の異なる複数食品のカテゴリ分類

M2021SC008 野首優斗

指導教員：河野浩之

1 はじめに

食行動の質が下がると、健康に影響を与える可能性がある。実際に、食事バランスが悪いと、心筋梗塞、脳梗塞、肝臓病、糖尿病等のリスクがある。また、偏咀嚼により、歯並びや顔のバランス、顎のゆがみに影響がある。そのため、近年ウェアラブル機器の普及とともに、食事を監視する自動食事モニタリングが提案されている [1]。

食行動に関わる要素として、摂取タイミング、食品カテゴリー、咀嚼周期、食分量、咀嚼のバランス等がある。例えば、本研究で着目する食品カテゴリーの中の食感情報は、現状、中身は、断片的なことしか分かっていないブラックボックスではあるが、様々な食感を咀嚼することは、幅広い効果を発揮する。実際に、かみごたえを含むチューインガムは、噛むと脳が活性化することが科学的に証明されている。また、やわらかい食べ物を食べたマウスは、精神障害になる危険性が上昇すると言われている。他にも、破碎を含む食品はサクサク、カリカリといった音が聴覚を刺激し、魅力の感じやすさや、ストレスの予防・軽減につながる。

食感情報に基づいた食品カテゴリー分類を行っている研究では、過去に筋電センサ [1]、マイクロフォン [2]、咽喉マイク [3] がある。本研究では、力学的な特性を示す筋電センサに着目し、安価な MyoWare を使用する。これらにより、安価な筋電センサを用いて、高い精度で食感の異なる複数食品のカテゴリ分類できることを目的とする。

Rui Zhang et al.[1] では、RF(Random Forest) を用いて分類を行っていたため、本研究で提案する SVM(Support Vector Machine)、CNN(Convolutional Neural Network)、LSTM(Long Short Term Memory)、Transformer との分類精度比較を行う。また、[1] を含め過去の研究では、各食品での分類を行っているため、安価な筋電センサを用いて複数食品での分類可能であるかの評価を行う。

2 食事管理の関連研究

食事モニタリングには、アンケート等の手動で記録する方法がある。しかし、手間がかかるため、センサ等から自動でデータを収集し、解析する自動食事モニタリングが良いと考えられる。

例えば、自動食事モニタリングの中に、咀嚼バランスが悪いと、顔のゆがみ、歯並び等に影響が出るため、左右の咀嚼バランスを検出するものがある。また、咀嚼回数が低いと、口内炎や、顎の筋力の低下につながってしまうため、咀嚼数を推定するものもある。

本研究では、食感情報に着目するため、表 1 に自動食事モニタリングの中の、食感分類の関連研究を示す。各食品ごとに食感分類を行った。

表 1 食感分類の関連研究

測定方法と分類方法	結果 (再現率)
筋電センサ RF, [1]	ビスケット (75%), バナナ (76%), ジェリーベビー (71%), トースト (84%), ニンジン (63%)
マイクロフォン DT, [2]	ポテトチップス (87.15%), リンゴ (80.82%), パスタ (100%), レタス (83.55%)
咽喉マイク DT, [3]	リンゴ (86.3%), ニンジン (84.9%), ポテトチップス (82.9%), クッキー (87.7%), ピーナッツ (75.5%), くるみ (83.4%), 水 (93.3%)

3 咀嚼筋の筋電位を用いた食感の異なる複数食品のカテゴリ分類の提案

3.1 節では、筋電位とはについて、3.2 節では、本研究で採用する筋電センサについて、3.3 節では、本研究での力学的特性に着目した複数食品のカテゴリ分類について述べる。

3.1 筋電位とは

筋電位とは、生物の筋細胞の収縮活動の時に、発生する活動電位のことをいう。また、筋肉の中で発生する微弱な電場の変位を縦軸、時間の経過を横軸にしたものを筋電図 (ElectroMyoGraphy-EMG) という。

筋電センサである MyoWare で測定したミカンを食べた時の、整流・平滑化された EMG を図 1 に示す。電圧 (Voltage) は、0[V] から 5[V] の電圧を 0 から 1023 の値に変換している。食品を噛み始めると 0.35(s) から、活動電位が上がり、噛み終わるにつれ 0.44(s) から、活動電位が下がっていく。

3.2 本研究で採用する筋電センサ

表 2 に、安価な筋電センサと高価な筋電センサとの違いについて示す。先行研究 [1] 等で使われている、一般的な筋電センサは、医療やリハビリテーションに用いられるため、10 万円から 20 万円程度と高価である。

本研究では、一般的に自動食事モニタリングシステムとして使用することを目的とするため、安価な筋電センサを採用する。使用する Advancer Technologies 社の筋電センサ (MyoWare) は、6 千円程度と安価である。

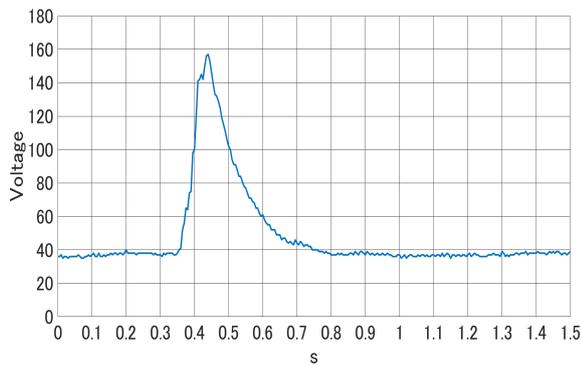


図1 咀嚼筋を MyoWare で測定したミカンの整流・平滑化された EMG

安価な筋電センサを使用すると、高価な筋電センサと比較して、RAW EMG に対してノイズが多い。そのため、直接取得できる信号である、整流・平滑化された EMG を使用する。整流・平滑化された信号は、データにおける重要なパターンを、ノイズ等、重要性の低いものを除去し、値の変化をなだらかにしてデータの傾向が分かりやすくなる。インターフェイスからの距離に関しては、自動食事モニタリングとして利用するため、長距離である必要性がない。

表2 安価な筋電センサと高価な筋電センサとの違い

内容	安価な筋電センサ (MyoWare)	高価な筋電センサ (Biometrics Ltd. 表面筋電図センサ等)
価格	6千円程度	10~20万円程度
直接取得できる信号	RAW EMG 整流・平滑化された EMG	RAW EMG
インターフェイスからの範囲	近距離	長距離 (30m まで無線で可能)
RAW EMG のノイズ	安価なセンサと比較し、高価なセンサは、ノイズが 5 μ V 未満なため少ない	

3.3 本研究での力学的特性に着目した複数食品のカテゴリ分類

食感とは、力学的特性、幾何学的特性、それ以外の特性 (油脂と水) に分けられる。力学的特性とは、かみごたえ、破碎、変形しやすさ、凝集の小ささ、流動となめらかさ、粘りとぬめり、硬さ等を含む。幾何学的特性とは、空気、粒子、なめらかさと均一性、粗さと不均一性、薄さ、密等を含む。また、それ以外の特性 (油脂と水) とは、脂肪、乾燥、水分等を含む。

Rui Zhang et al.[1] は、力学的特性に着目して、筋電位を用いて、ビスケット、バナナ、ジェリーベビー、トースト、

ニンジンで食感分類を行った。筋電位は、咀嚼筋の筋活動を測定することができるため、本研究でも力学的特性に着目して、食品カテゴリ分類を行う。咀嚼筋とは、咀嚼する際に働く筋群を意味する。本研究では、外側からセンサを貼って測定することができる咀嚼筋の筋電位を用いる。咀嚼筋は、咬筋、側頭筋、内側翼突筋、外側翼突筋の4種類である。自動食事モニタリングで、メガネ型のを想定しているため、側頭筋の筋電位を測定することにする。

先行研究 [1][4][5] では、食品カテゴリを各食品ごとに分類を行った。本研究では、食品カテゴリを複数食品に分類を行う。例えば、グミと同じカテゴリにガムを含む。よって、表3の異なる力学的特性に基づいて食品カテゴリに分類を行う。

表3 本研究で使用する食品

I: 特に、破碎を含む食品: せんべい, おかき
II: 特に、かみごたえを含む食品: グミ, ガム
III: 特に、硬さを含む食品: 飴, 氷
IV: 特に、粘りとぬめりを含む食品: 餅, 団子
V: 特に、変形しやすさを含む食品: ミカン, バナナ

Rui Zhang et al.[1] は、咀嚼筋の筋電位を RF を用いて、74.8% の精度で食感分類を行った。咀嚼筋の筋電位の分類または、咀嚼筋以外の筋電位分類の機械学習またはディープラーニングの適用を調査したところ、SVM, CNN, LSTM, Transformer で高い分類精度が得られていることがわかった。Transformer に関しては、調査したところ咀嚼筋に対する論文は存在しなかったが、咀嚼筋以外に対する論文は存在したため、実験として試すことにする。

よって本研究では、SVM, CNN, LSTM, Transformer を用いて高い精度での分類を行う。Rui Zhang et al.[1] の研究では RF を用いて食感分類を行っていたため、本研究でも RF でも分類を行い、SVM, CNN, LSTM, Transformer との分類精度比較を行う。

4 咀嚼筋の筋電位を用いた食感の異なる複数食品のカテゴリ分類の構築

4.1 節では、構築環境について、4.2 節では、筋電位の取得方法について、4.3 節では、筋電位の分類方法について述べる。

4.1 構築環境

本研究では、Jupyter Notebook で、Python を用いて、プログラムを実行する。Python とは、インタープリタ型の高水準汎用プログラミング言語である。

機械学習の実装には、Scikit-learn を用いる。Scikit-learn は、他の Numpy, Scipy と比較して様々な機械学習の実装を簡単に行うことが可能である。また、ディープラーニングの実装には、Keras, Tensorflow を用いる。Keras は、Tensorflow や PyTorch と比較して、可読性が高く、シ

ンプルであるので、デバッグがほとんどないのが特徴であり、ディープラーニングを実装可能である。Tensorflow は、Keras と比較して速度が速い特徴があり、同様にディープラーニングを実装可能である。

特徴量抽出に MATLAB(EMG Feature Extraction Toolbox) を用いる理由としては、筋電図 (EMG) 用の 40 種類の特徴量を抽出可能なため使用することにする。また、筋電センサには MyoWare、ワンボードマイコンには、Arduino Uno、データ取得ツールには、Excel の Data Streamer を用いる。

4.2 筋電位の取得方法

Advancer Technologies 社の筋電センサ (MyoWare) を用いて、咀嚼時の咀嚼筋の EMG を毎秒 200 回取得する。MyoWare から取得できるデータは、増幅された RAW EMG 信号、整流・平滑化された EMG 信号である。

調査で取得する信号は、整流・平滑化された EMG 信号である。MyoWare の電極は基準電極 1 つと、測定電極 2 つである。本実験では、測定電極は側頭筋に配置し、基準電極は側頭筋ではない筋肉の部分に配置する。

MyoWare を Arduino に接続して、Microsoft 社が提供している Data Streamer を用いて、センサからリアルタイムデータを取得する。その後、センサから取得したデータを csv ファイル形式で保存を行う。

4.3 筋電位の分類方法

Data Streamer で取得した csv ファイルを、MATLAB の EMG Feature Extraction Toolbox を用いて特徴量抽出を行う。本研究では、平均絶対値 (mav)、二乗平均平方根 (rms)、標準偏差 (sd)、中央値 (med)、歪度 (skew)、尖度 (kurt)、単純二乗積分 (ssi)、平方根の平均 (msr)、平方根の合計の絶対値 (ass)、平方絶対偏差 (mad)、四分位範囲 (iqr)、最大値 (max)、最小値 (min) の 13 個を抽出する。取得した特徴量は、csv 形式で保存する。特徴量抽出を行った csv ファイルに、SVM、RF を適用し、食品のカテゴリ分類を行う。

SVM、RF 同様に、特徴量抽出を行った csv ファイルに、CNN、LSTM、Transformer を適用し、食品のカテゴリ分類を行う。また、取得したデータに対して特徴量抽出を行わずに、データの取得した csv ファイルを、CNN、LSTM、Transformer に適用し、食品のカテゴリ分類を行う。

5 咀嚼筋の筋電位を用いた食感の異なる複数食品のカテゴリ分類の実験

5.1 節では、実験の手順とデータと結果について、5.2 節では、考察について述べる。

5.1 実験の手順とデータと結果

20 代前半の理工学研究科に所属している学生 2 名と、理工学部にも所属していた 1 名による実験^{*1}を行った。各被験者は、3 章の表 3 の各食品を 5 回ずつ食べる。1 回の咀嚼あたり 1.5 秒間のデータのサンプリングを行う。よって、データ数は、150 とし、5 分割で交差検証を行った。

また、本研究で使用した特徴量の重要度を可視化したものを、図 2 に示す。特徴量重要度を可視化した結果、単純二乗積分 (ssi)、最大値 (max)、尖度 (kurt)、歪度 (skew)、標準偏差 (sd)、平方根の合計の絶対値 (ass) が高い。

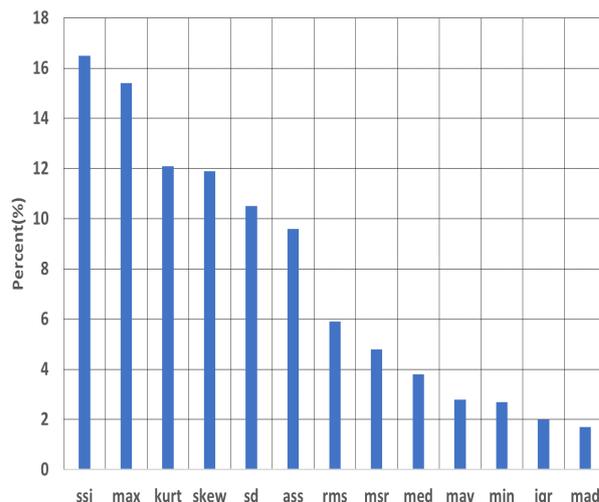


図 2 特徴量の重要度

各分類手法において、パラメータの最適化を行った。SVM は、C は 10、kernel は linear となった。RF は、n_estimators は 50、max_depth は 40 となった。

CNN で入力データに特徴量を用いた時は、畳み込み層は 3 層で、filters は 32、activation は linear となった。また、入力データに整流・平滑化された EMG を用いた時は、畳み込み層は 6 層で、filters は 16、activation は linear が 3 つ、relu が 3 つとなった。

LSTM で入力データに特徴量と整流・平滑化された EMG を用いた時は、両方とも LSTM 層は 1 層で、dropout は、0.2 となった。Transformer で入力データに特徴量を用いた時は、head_size は 70、num_heads は 20、ff_dim は 70、num_transformer_blocks は 7 となった。また、Transformer で入力データに整流・平滑化された EMG を用いた時は、head_size は 10、num_heads は 10、ff_dim は 10、num_transformer_blocks は 6 となった。

機械学習またはディープラーニングを用いて食感の異なる複数食品ごとのカテゴリ分類を行った結果を表 4 に示す。入力データに特徴量を用いた時は、CNN で正解率

^{*1} 実験は南山大学研究審査委員会の審査の上、個人情報保護に十分配慮し実施した

表4 食感の異なる複数食品のカテゴリー分類の結果

手法	RF	SVM	CNN	LSTM	Transformer	CNN	LSTM	Transformer
入力データ	特徴量					整流・平滑化された EMG		
再現率 I:	93.2%	87.5%	100%	100%	100%	86.6%	86.6%	83.4%
II:	85%	88.4%	100%	96.6%	33.2%	80%	79.8%	50%
III:	90.6%	96.6%	100%	93.2%	96.6%	96.6%	93.2%	96.6%
IV:	93.2%	93.2%	96.6%	100%	86.6%	93.2%	100%	96.6%
V:	97.2%	100%	100%	100%	100%	100%	96.6%	100%
正解率	92%	93.2%	99.3%	98%	84%	91.3%	91.3%	85.3%

99.3%となった。次に高いので、LSTMで、98%となった。また、SVMでは、LSTMと比べて4.8%と低い結果とはなったが、次に高い正解率93.2%となった。Transformerは、正解率84%と入力データが特徴量の時、最も低い分類精度となった。入力データに整流・平滑化されたEMGを用いた時は、CNN、LSTMで91.3%となった。また、Transformerでは、CNN、LSTMと比べて6%低い結果となり、正解率85.3%となった。全体としては、CNNで入力データに特徴量を用いた時が、最も高い正解率となり、Transformerで入力データに特徴量を用いた時が、最も低い正解率となった。

入力データに特徴量を用いた時は各再現率が、SVMではV、CNNではI、II、III、V、LSTMではI、IV、V、TransformerではI、Vの時に、100%となった。入力データに整流・平滑化されたEMGを用いた時は各再現率が、CNNではV、LSTMではIV、TransformerではVの時に、100%となった。

5.2 考察

入力データに特徴量を用いて、CNNで分類を行うことで、今回使用した食品において最も高い精度で99.3%で分類することが可能になった。

また、入力データに整流・平滑化されたEMGを用いて、CNN、LSTMで100%の正解率を得られなかったが、91.3%の正解率を得ることができたため、特徴量抽出の時間を削減し、高い精度で分類を行うことが可能になった。

取得する信号を、整流・平滑化されたEMGにしたことで、安価な筋電センサであるMyoWareでも、複数食品で5つの食品カテゴリーに、最も低くてTransformerモデルで、84%で分類可能になった。

そのことから、安価な筋電センサで、RF、SVM、CNN、LSTM、Transformerのどの分類手法を用いても、複数食品でカテゴリーを分類できる可能性を示すことができた。しかし一部、Transformerで、IIの再現率が低くなったのは、他のカテゴリーと比較すると、全体的にIIの再現率が低いため、モデルの精度が原因だと考えられる。

また、Rui Zhang et al.[1]で分類手法として使われていたRFよりも、1.2%であるがSVMが分類精度が高く、6%から7.3%と、CNN、LSTMで分類精度が高くなった。

しかし、RFよりも入力データに特徴量を用いた場合、Transformerで8%、整流・平滑化されたEMGを用いた場合、CNN、LSTMで0.7%、Transformerで6.7%分類精度が低くなることがわかった。よって、RFよりも入力データに特徴量を用いた場合、SVM、CNN、LSTMが高い分類精度を得られることを示すことができた。

6 むすび

本研究では、自動食事モニタリングにおける食行動に関わる要素として、食品カテゴリーに着目し、食感情報に基づいて安価な筋電センサで複数食品のカテゴリー分類の提案を行った。

Rui Zhang et al.[1]では高価な筋電センサを用いていたが、自動食事モニタリングにおいては、安価な筋電センサである必要があるため、本研究では安価な筋電センサであるMyoWareを採用した。

被験者実験を通して、筋電センサから取得する信号を整流・平滑化されたEMGを用いたことで、5つの食感の異なる複数食品のカテゴリーに分類することができた。よって、安価な筋電センサでも、高い精度で食感の異なる複数食品のカテゴリーに分類可能性を示すことができた。

また、Rui Zhang et al.[1]で使用されていた分類手法であるRFよりも、SVM、CNN、LSTMの方が高い分類精度を得ることが可能となった。

参考文献

- [1] Rui Zhang et al., "Diet eyeglasses: Recognising food chewing using EMG and smart eyeglasses," 2016 IEEE 13th International Conference on Wearable and Implantable Body Sensor Networks, pp.7-12, 2016.
- [2] O Amft et al., "Analysis of Chewing Sounds for Dietary Monitoring," Proceedings of the 7th International Conference on Ubiquitous Computing, pp.56-72, 2005.
- [3] Yin Bi et al., "AutoDietary: A Wearable Acoustic Sensor System for Food Intake Recognition in Daily Life," IEEE Sensors Journal, vol. 16, pp.806-816, 2016.