



# MEMS 触覚センサを用いたフォークによる 食材刺突時の把持力に基づく食材判別

Automatic Food Identification from Gripping Force of Fork Measured by MEMS Tactile Sensor.

坪倉奏太<sup>1)</sup>, 柴田結衣<sup>1)</sup>, 安藤潤人<sup>1)</sup>, 寒川雅之<sup>2)</sup>, 渡邊淳司<sup>3)</sup>, 野間春生<sup>1)</sup>  
Sota TSUBOKURA, Yui SHIBATA, Mitsuhiro ANDO, Masayuki SOHAWA, Junji WATANABE, and Haruo NOMA

1) 立命館大学 情報理工学部実世界情報コース

(〒525-8577 滋賀県草津市野路東 1-1-1, is0464pf@ed.ritsumeai.ac.jp)

2) 新潟大学 工学部機械システム工学科

(〒950-2181 新潟県新潟市西区五十嵐 2-8050, sohawa@eng.niigata-u.ac.jp)

3) NTT コミュニケーション科学基礎研究所

(〒243-0198 神奈川県厚木市森の里若宮 3-1, junji.watanabe.sp@hco.ntt.co.jp)

**概要**：本研究では，食事の際どの食材を食べているのかユーザに客観的な形で示すことを目的に，我々が開発した超小型 MEMS 触覚センサを柄の裏に搭載したフォークを用い，ユーザがスプーンで刺突している食材の自動判別を試みた．判別手法として Random Forest，各種のディープラーニングのモデルを採用，それぞれにおいて得られた判別結果の比較検討を行なった．最終的に，Deep Learning，特に 1DCNN(1Dimension-CNN)モデルを用いた場合正答率が高いという結果，及び 1DCNN が学習に要するパラメータ数，学習時間ともに最も小さく実用性が高いと考えられるという考察が得られた．

**キーワード**：ハプティクス，Random Forest，Deep Learning

## 1. 研究背景と目的

近年，食器にセンサを搭載，データを収集し様々な形でユーザの利益に沿うように情報を提示する「スマートカトラリー」の研究が進んでいる．特に生育や健康状態などと大きく関係がある，「どのような食材をどれだけ摂取したか」という情報をユーザに提示するべく，ユーザが摂取している食材を自動判別するスマートカトラリーはこれまでいくつか開発されている[1,2].

本研究では実際の利用状況に近い食事の場で，食材の自

動判別を目的とするために超小型 MEMS(Micro Electro Mechanical Systems)触覚センサを搭載したフォークを試作した．ここではフォークで食材を刺す際に触覚センサから得られるアナログ信号を用いて食材の自動判別を試みた．本研究では自動判別技術として Random Forest を用いた機械学習のモデルと複数の Deep Learning による機械学習のモデルを利用して食材判別器を作成し，それぞれの手法による結果について比較検討を行った．




図 1：超小型 MEMS 触覚センサの全体図

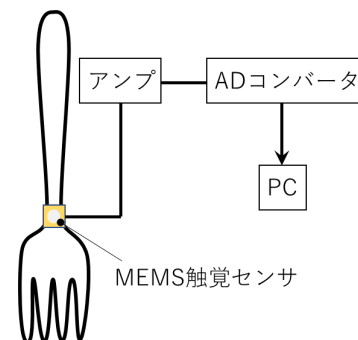


図 2：計測システム



図 3: 実験 1 に用いた計測装置



図 4: 実験 2 に用いた計測装置



図 5: 自動判別の対象とした食材群




図 6: 実験時における様子

## 2. 計測システム

本研究で使用する超小型 MEMS 触覚センサについて説明する。図 1 は超小型 MEMS 触覚センサの写真である。我々が開発した MEMS センサは直径 5mm の Si 基板の上に複数のマイクロカンチレバーが並んでおり、それらがエラストマ(弾性体)で覆われている構造を有している。この弾性体に力を加えるとマイクロカンチレバーが変形し、その変形に応じて電気抵抗が変化する。この電気抵抗の変化に応じてセンサ信号が出力される[3,4]。センサ信号はアンプで増幅され、AD コンバータを介して PC に取り込まれる。

図 2 は本研究で使用した計測システムの模式図である。超小型 MEMS 触覚センサはフォークの柄に取り付け、食材を刺す時に生じるセンサ信号を計測する。なお、フォークの持ち方に関しては、親指と人差し指でフォークの柄をつまみ、中指が触覚センサに触れるような持ち方で実験を行った。

## 3. 実験手法

学習データを用意するために測定した条件について説明を行う。実験は以下に示すように、使用する学習モデル別に 2 回の実験を行った。

実験 1 : Random Forest のための学習データ収集

実験 2 : Deep Learning のための学習データ収集

図 3, 4 はそれぞれ実験で使用した計測装置の写真を示す。実験 1 に用いた実験装置では、フォークに取り付けた触覚センサから得られたアナログ信号を適切な値のゲインに設定したアンプ(INA121)で増幅し、AD コンバー

タ(NI USB-6008)を用いて分解能 32bit, サンプル周波数 2kHz で計測を行なった。実験 2 では、フォークに取り付けた触覚センサから得られたアナログ信号を適切な値のゲインに設定したアンプ(LT1167)で増幅し、Arduino Nano に搭載された AD コンバータを用いて分解能 10bit, サンプル周波数 300Hz でデジタル信号に変換し計測を行なった。

刺突の対象としたのは 7 種類の食材(マッシュマロ、グミ、かまぼこ、こんにゃく、キュウリの内側、キュウリの外側、ナス)である。図 5 は実験に使用した判別対象の食材の写真である。マッシュマロ、グミは切る等の加工を加えない状態で用意し、かまぼこ、こんにゃく、キュウリの内側、ナスは厚さ約 1cm に切ったものを使用した。

計測は 3 秒間隔で「刺す」、「抜く」、という動作を繰り返してもらい、各動作 10 回の繰り返しを 1 セットとし、被験者 1 人につき 2 セット、計 20 回の計測を行った。被験者には食材の下に敷いたまな板にフォークが到達するまで刺すように指示する。もし、刺す動作が 3 秒以内に終わった場合は、フォークが食材の下のまな板に到達した状態のまま 3 秒経過するのを待ってもらった。その際、待つ間は力を抜くように被験者に指示をした

被験者数は、実験 1 の実施時は全員が右利きの男性 2 名、女性 1 名、実験 2 の実施時は全員が右利きの男性 3 名である。図 6 は実験時における様子の写真である。

## 4. Random Forest を用いた食材の自動判別

Random Forest を用いて学習させた食材の判別器を作成し、フォークで刺した食材の自動判別を行った。なお、この時に用いたデータは、計測環境の関係で 3 軸のカンチ




図 7: 実験 1 にてセンサから得られた波形データ

レバーのうち 2 軸から得られたものである。センサから得られた波形データを図 7 に示す。

判別はデータの平均、分散、ピーク、面積、傾き、歪度、尖度、ピークまでの時間、ピークまでの時間をパーセンテージで表した値、波形の重心をそれぞれ 2 軸分、2 軸の値の相関係数と横幅を固定しないヒストグラムの縦軸の数値 10 個を 2 軸分の計 41 個の特徴量を用意し、




図 8: 実際に得られた波形データ

表 2: 学習に要したパラメータと学習時間

	1DCNN	CNN	RNN	LSTM	GRU
パラメータ数	17,223	7,188,295	836,615	3,337,991	2,504,967
学習時間(s)	140	980	140	170	170




図 9: CNN の学習に用いたグラフ画像(青枠内)

表 1: Random Forest を用いて得られた混同行列

	グミ	こんにゃく	かまぼこ	きゅうり(中)	きゅうり(外)	マッシュマロ	なす	precision	recall	f1-score
グミ	19	2	0	2	0	2	0	0.73	0.76	0.75
こんにゃく	0	7	4	3	3	0	1	0.35	0.39	0.37
かまぼこ	0	2	9	2	0	0	1	0.47	0.64	0.55
きゅうり(中)	1	3	2	10	5	1	3	0.43	0.40	0.42
きゅうり(外)	1	2	0	1	11	2	0	0.48	0.65	0.55
マッシュマロ	5	0	1	2	2	13	2	0.62	0.52	0.57
なす	0	4	3	3	2	3	6	0.46	0.29	0.35

Random Forest に学習させるという形で行った。学習の結果得られた混同行列を表 1 に示す。食材ごとの正答率の平均値は 51.7%であった。

### 5. Deep Learning のモデルを用いた食材自動判別

数種類の Deep Learning モデルを用いて学習させた食材の判別器を作成し、フォークで刺した食材の自動判別を行った。なお、使用したモデルは CNN, 1D-CNN, RNN, LSTM, GRU である。

1D-CNN, 各種の RNN(RNN, LSTM, GRU)を用いた学習においては、計測した電気信号データを時系列方向に少しずつ新しいデータとすることによって学習データの数を約 70 倍にかさ増しさせ学習に利用した。実際にセンサから得られた波形データを図 8 に示す。CNN を用いた学習においては、計測したセンサ信号をバタワースフィルタにてノイズを除去した後、1D-CNN, RNN の学習データと同様にデータ数を約 30 倍にかさ増して、それらを図 9 に示すような 400×400 ピクセルのグラフ画像にしたデータを学習に利用した。バッチサイズは CNN 以外のモデルにおいて 1024, CNN において 256 とした。

図 10 に各種のモデルにおける学習で得られた Validation Accuracy(検証用データにおける正答率), Validation Loss(検証用データにおける損失)を、表 2 に各種のモデルにおける学習にて用いたパラメータ数, 学習に要した時間を、図 11 に各種のモデルにおける学習で得られた混同行列を示す。なお、学習は GeForce RTX 1080 を 4 個用いて




図 10 各モデルの Validation-Accuracy Loss の結果

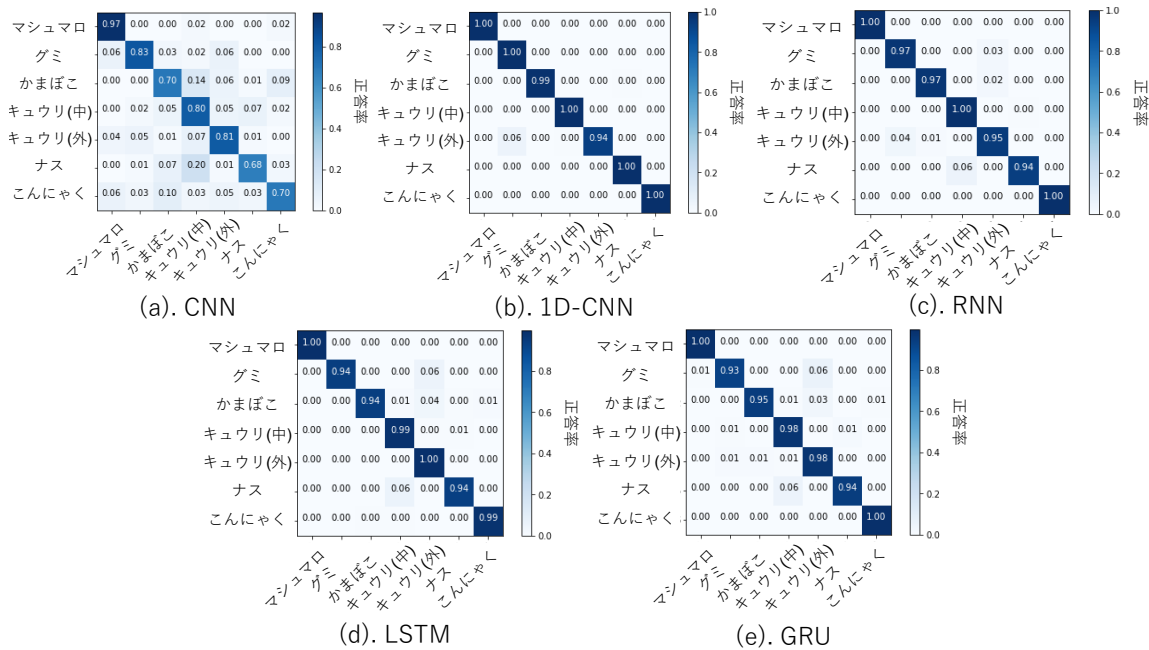


図 11: Deep Learning を用いて得られた混同行列

行った。これらに示すように、CNN を用いた場合には Validation-Accuracy が 8 割、その他のモデルを用いた場合には 9 割を超え、特に 1D-CNN においては正答率が 10 割近い結果が得られた。

## 6. 考察

Random Forest と Deep Learning による食材自動判別器をそれぞれ用いて得られた結果の比較について述べる。全体として、Random Forest を用いた場合に比べ、Deep Learning を用いた場合の方がより高い正答率を得られた。Deep Learning にて用いた学習データは Random Forest にて用いた学習データと比べ分解能、サンプリング周波数ともに低精度なものだということを鑑みれば、Deep Learning を採用した方がより広い条件で計測でき、かつ高い識別率で食材を判別できると言える。特に、学習に利用するモデルのパラメタ数、学習に要する時間を鑑みれば、食材判別に際し最も実用性が高いモデルは 1DCNN だと考える。なお、CNN より 1D-CNN、各種の RNN の方が Validation-Accuracy、Loss の収束が早いのは、CNN の学習に用いたデータはグラフ画像化を行ったことにより情報が抜け落ちてしまったことが原因であると考えられる。

## 7. まとめ

本研究では、実際の利用状況により近い環境に対応し食材の判別ができるスマートカトラリーを開発することを目的に、我々が今まで開発を続けている超小型 MEMS 触覚センサを取り付けたフォークを用いて食材の判別を試みた。結果、各種ディープラーニングのモデルを採用

した場合、低精度な条件にて計測したデータを用いても正答率が 9 割を超える結果が得られ、特にスマートカトラリー開発に際し 1D-CNN の実用性が最も高いという考察が得られた。先の展望としては、加熱や調味料の添加といった加工を加えた食材の判別、既に学習が進んだモデルに対し未知の食材を判別させようとした場合における結果の考察、切り出されたデータではなく連続的にデータが入力される場合の判別を構想している。

## 参考文献

- [1] 西尾遙菜, 双見京介, 村尾和哉, アクティブ音響センシングを用いた食材認識カトラリーの設計と評価, 情報処理学会インタラクショナル 2021.
- [2] 門村亜珠沙, 李争原, 陳嚴章, 朱浩華, 塚田浩二, 椎尾一郎. フォーク型センサとスマートフォンを連携した食行動改善手法の提案, 情報処理学会研究報告 Vol.2013-UBI-39 No.10, 2013.
- [3] 橋弘人, 釜鳴志朗, 美馬達也, 寒川雅之, 金島岳, 奥山雅則, 山下馨, 野田実, 野間春生, 樋口誠良, 方向カンチレバーを用いた多軸触覚センサの作製と基礎特性, 電気学会論文誌 E (センサ・マイクロマシン部門誌), Vol. 130, No. 6, pp. 223–229, 2010.
- [4] Ryoma Araki, Takashi Abe, Haruo Noma, and Masayuki Sohawa, Miniaturization and high-density arrangement of microcantilevers in proximity and tactile sensor for dexterous gripping control, Micromachines, Vol. 9, No. 6, p.301, 2018.