

修士論文

ピエゾセンサの振動情報を用いた料理中の マイクロ行動認識システムの提案と評価

石山 時宗

奈良先端科学技術大学院大学

先端科学技術研究科

情報理工学プログラム

主指導教員: 安本 慶一

ユビキタスコンピューティングシステム 研究室（情報科学領域）

令和5年3月17日提出

本論文は奈良先端科学技術大学院大学先端科学技術研究科に
修士(工学) 授与の要件として提出した修士論文である。

石山 時宗

審査委員：

主査	安本 慶一	(情報科学領域 教授)
	加藤 博一	(情報科学領域 教授)
	諏訪 博彦	(情報科学領域 准教授)
	藤本 まなと	(大阪公立大学 大学院情報学研究科 准教授)

ピエゾセンサの振動情報を用いた料理中の マイクロ行動認識システムの提案と評価*

石山 時宗

内容梗概

調理者の行動を認識することは、レシピの提案やオーブンの自動温度調整など、自炊や料理に不慣れな人への支援を提供でき、料理への負担を減らしつつ、健康的な食生活を維持するために利用できる。調理者の行動を認識する手法としては、カメラやウェアラブルセンサなどを利用する方法が一般的であるが、カメラを用いた方法では死角の発生や、プライバシーの侵害といった懸念があり、ウェアラブルセンサを用いた手法では装着者への負担がある。また、料理行動は、食材を「切る」、「焼く」、「煮る」、「炒める」等の細かな動作であるマイクロ行動から構成されているため、カメラ以外のプライバシーに配慮した行動認識手法では、料理行動の認識が困難である。本研究では、料理行動中に発生する振動の違いに着目し、非接触かつ死角がなくプライバシー保護が可能な設置型センサという利点を持つピエゾセンサを用いて、料理行動中に発生する振動情報に基づくマイクロ行動認識システムを提案する。取得した振動情報に対して前処理を施した後、スペクトログラムに変換することで、2次元画像化およびRGB画像化を行う。その後、それら画像を入力データとしたResNetによる機械学習を用いて、料理中のマイクロ行動を認識する。提案システムの有用性を検証するため、奈良先端科学技術大学院大学内に設置されているスマートホーム内において、提案システムを用いて実験を行った。具体的には、実際の食材を調理する過程を再現しその時に発生する振動データを取得し可視化する先行実験を行った。その結果、行動ごとに特徴が異なるデータを収集できることを確認した。また、提案システムにより、料理中の

*奈良先端科学技術大学院大学 先端科学技術研究科 修士論文, 令和5年3月17日.

マイクロ行動を識別できるか評価するため、実際にカレー、餃子、およびウインナーの調理を行い、料理行動認識を行った。結果として、「茹でる」、「煮る」、「蒸す」、「焼く」、「炒める」、「その他」の6種類の行動を、おおよそ60%の精度で識別可能であることを明らかにした。

キーワード

宅内行動認識; マイクロ行動; スマートホーム

Proposal and Evaluation of Micro-activity Recognition System during Cooking Using Vibration Information Obtained from Piezoelectric Sensors*

Tokimune Ishiyama

Abstract

Recognizing activities performed during cooking can provide support for people who are not familiar with cooking or self-catering, such as suggesting recipes or automatically adjusting the oven temperature, and in that way, facilitate the cooking activity and help the person maintain a healthy diet. The methods of recognizing cooking activities are generally using cameras or wearable sensors. Still, there are concerns such as the occurrence of blind spots and invasion of privacy with the use of cameras and a burden on the wearer with the use of wearable sensors. In addition, cooking activities are composed of micro-activities such as “cutting,” “baking,” “boiling,” and “stir-frying,” making it difficult to recognize cooking activities with a privacy-conscious method other than a camera. In this thesis, we propose a micro-activity recognition system based on vibration information that occurs during cooking activities, using a piezoelectric sensor that has the advantages of being non-contact and having no blind spots while being able to protect privacy. In the proposed method, after preprocessing the obtained vibration information, it is converted into a spectrogram and then into two-dimensional RGB image. Then, by using machine learning with ResNet as the input data, we recognize the micro-activity during cooking. To investigate the usefulness of the proposed system, experiments were conducted using the system in a smart home at

*Master’s Thesis, Graduate School of Science and Technology, Nara Institute of Science and Technology, March 17, 2023.

the Nara Institute of Science and Technology. Specifically, a pilot experiment was conducted to collect and visualize vibration data during the cooking process using actual ingredients. As a result, it was confirmed that data with different characteristics can be collected for each activity. To evaluate the ability of the proposed system to identify micro-activities during cooking, an actual curry, dumplings, and sausage cooking experiment was conducted and cooking activity recognition was performed. As a result, it was revealed that six types of activities, "boiling", "simmering", "steaming," "baking," "stir-frying," and "others" could be identified with an accuracy of approximately 50%.

Keywords:

ADL; Micro-activity; Smart Home

目次

1. 序論	1
2. 関連研究	5
2.1 カメラを用いた行動認識	5
2.2 ウェアラブルデバイスを用いた行動認識	6
2.3 振動センサを用いた行動認識	6
2.4 料理行動に関する研究	7
2.5 調理支援システムに関する研究	8
2.6 本研究の位置づけ	9
3. 提案システム	10
3.1 システムの要件	10
3.2 システム構成	11
3.2.1 ピエゾセンサ	12
3.2.2 増幅回路	13
3.2.3 インターフェイス	14
3.2.4 PC	15
3.2.5 アノテーション用ビデオカメラ	15
3.3 分析手法	15
3.3.1 前処理	16
3.3.2 スペクトログラム	17
3.3.3 RGB 画像化	18
3.3.4 サンプリング	19
3.3.5 機械学習モデル	19
3.3.6 評価手法	20
4. 評価実験	22
4.1 予備実験	22
4.1.1 実験目的	22

4.1.2	実験手順	22
4.1.3	実験条件	23
4.1.4	実験対象	23
4.1.5	データ処理	24
4.1.6	結果と考察	32
4.2	本実験	33
4.2.1	実験目的	33
4.2.2	実験条件	33
4.2.3	実験手順	33
4.2.4	結果と考察	34
5.	結論	37
	謝辞	38
	参考文献	39
	研究業績	44

目 次

1	主食・主菜・副菜を組み合わせた食事の頻度及び目標摂取量を達成したと判断される個人の割合	2
2	外食及び持ち帰りの弁当・惣菜の利用頻度別，主食・主菜・副菜を組み合わせた食事の頻度	2
3	システム構成図	11
4	システム設置の様子	12
5	使用するピエゾセンサ	13
6	使用する増幅回路	14
7	シールドケース	14
8	処理の流れ	16
9	取得される振動データの例	17
10	スペクトログラムの例	18
11	RGB 画像化	19
12	ResNet	21
13	残差ブロック	21
14	取得した振動	24
15	スペクトログラム（行動しない）	25
16	スペクトログラム（洗う）	26
17	スペクトログラム（切る）	26
18	スペクトログラム（焼く）	27
19	スペクトログラム（炒める）	27
20	スペクトログラム（和える）	28
21	スペクトログラム（茹でる）	28
22	スペクトログラム（煮る）	29
23	RGB 画像（行動しない）	30
24	RGB 画像（洗う）	30
25	RGB 画像（切る）	30
26	RGB 画像（焼く）	30

27	RGB 画像 (炒める)	31
28	RGB 画像 (和える)	31
29	RGB 画像 (茹でる)	31
30	RGB 画像 (煮る)	31
31	行動ごとの認識結果	35
32	秒数の違いによる認識結果	36

表 目 次

1	スペクトログラム算出時のパラメータ	17
2	対象行動	23

1. 序論

近年、健康寿命が延伸したことにより、少子高齢化が加速的に進行している。それにより、認知症や身体障害を抱え、生活に支障をきたす高齢者が増えていることが課題となっている。現代の社会においては、核家族化や共働き家庭が多く、個人の家事の負担が増加しているのに加え、高齢者の生活を支える若者の数が減少していることも、家庭内における家事の負担を大きくする原因の1つと考えられる [1, 2].

家事負担に関する解決策の1つとして、スマートホームが存在する。現在、スマートホームのシステムを利用することで、モバイルデバイス等を利用し、インターネットを介し家庭で使用する電化製品や家電を遠隔地からコントロールできる。スマートホームを導入することにより、居住者の暮らしを安心して安全・健康・快適・便利にすることができ、生活の質を向上させることができる。さらには、視覚や手が不自由な方も声を発するだけで容易に家電の操作ができるようになる。高齢者が増加している現代において、スマートホームの高度化が必要であると同時に、利便性の向上を図ることで、自立した日常生活を保つためのサポートシステムとしてのスマートホームの実現が求められている。

一方、20歳～59歳の男女2,407人を対象にした調査 [3] では、回答者の過半数以上が1週間に3日以上自炊をしていない上、回答者の25.2%は全く自炊をしないということが報告されている。加えて、図1に示すように、主食・主菜・副菜を組み合わせた食事の頻度が高い者ほど、炭水化物、たんぱく質及び野菜の摂取状況が食事摂取基準等の目標とされる量に合致していると評価される者の割合が、有意に高いと報告されている [1]。一方、図2に示すように、外食及び持ち帰りの弁当・惣菜を定期的に利用している者は、ほとんど利用していない者と比べ、主食・主菜・副菜を組み合わせた食事の頻度が有意に低い傾向が見られたと報告されている。以上のことにより、外食に比べ、自炊をすることが健康的な食生活につながると考えられる。また、調査 [3] では自炊をしない理由として、第一に「面倒だから(回答数 1537)」と報告されている。そこで、調理支援システム [4, 5] を利用することで、自炊を促すことができると考えられる。宅内行動認識を活用することにより、レシピの提案やオーブンの自動温度調整などの調理のサポート

システムとしてのスマートホームの実現が可能である。これらのシステムにより、自炊や料理に不慣れな人への支援を提供でき、料理への負担を減らしつつ、健康的な食生活を維持するために利用できる。行動認識システムの応用先に自炊支援が考えられ、自炊を促すことにより、バランスの良い食事につながると考えています。




図 1: 主食・主菜・副菜を組み合わせた食事の頻度及び目標摂取量を達成したと判断される個人の割合




図 2: 外食及び持ち帰りの弁当・惣菜の利用頻度別、主食・主菜・副菜を組み合わせた食事の頻度

宅内サービスの高度化や居住者の健康寿命の増進を目的として、人感センサや環境センサなどの設置型センサや電力情報などのデータを基に、居住者の宅内行動認識を行う研究が多数提案されている [6, 7, 8, 9]. 特に、入浴や料理等の家事、食事、睡眠などの日常生活行動の認識は、居住者の生活リズムを自動的にデータ化でき、健康寿命延伸のための行動変容やヘルスケアに有用である. しかしながら、従来提案されている日常生活行動の認識手法では、入浴や睡眠行動などに代表されるような場所と時間が対応し、1日の中で行われる時間が大まかに決まっている行動を対象とした場合、人感センサやドアセンサなどの設置型センサで比較的容易に認識が可能である. 一方、料理や食事、パソコンを使用した作業、読書などの行動は、1日の中で行われる時間が定まっておらず、さらに行われる場所も他の行動と重なる場合が多い. そのため、設置型センサでは認識が難しいという課題がある. 特に、料理行動は、食材を「切る」、「焼く」、「煮る」、「炒める」などの時間的に連続して行われない行動をはじめとした細かな行動、所謂マイクロ行動から構成されており、従来の日常生活行動認識の枠組みでは認識が難しい.

カメラやウェアラブルセンサを利用した行動認識手法も存在する [10, 11, 12, 13, 14, 15, 16, 17]. ウェアラブルセンサの利用に関して、近年 AppleWatch をはじめとした高機能スマートウォッチや、Fitbit などのフィットネストラッカーが販売されており、各種センシングに利用されている. また、カメラの行動認識への利用に関して、一般的なプライバシー問題への対策として、画像内の RGB 情報を削除し骨格情報を抽出する手法が存在する. しかしながら、ウェアラブルセンサを常に装着する手間や、カメラを設置すること自体に対する忌避感などの問題から、宅内行動認識のためのセンサとして利用することは難しい.

本研究では、上記の問題を解決するため、料理行動中に発生する振動の違いに着目し、非接触かつ死角がなくプライバシー保護が可能な設置型センサという利点を持つピエゾセンサを用いて、料理行動中に発生する振動情報に基づくマイクロ行動認識システムを提案する. 具体的には、取得した振動情報に対して前処理を施した後、スペクトログラムに変換することで、2次元画像化を行う. なお、ピエゾセンサは3つ使用し、3箇所のデータにより RGB 画像化を行う. その後、それら画像を入力データとした ResNet[18] による機械学習を用いて、料理中のマイ

クロ行動を認識する。

提案システムの有用性を検証するため、奈良先端科学技術大学院大学が所有するスマートホーム内において、提案システムを用いて実験を行った。具体的には、実際の食材を調理する過程を再現し、その時に発生する振動データを取得・可視化する予備実験を行った。その結果、行動ごとに特徴が異なるデータを収集できることを確認した。また、提案システムにより、料理中のマイクロ行動を識別できるか評価するため、実際にカレー、餃子およびウインナーの調理を行い、料理行動認識実験を行った。結果として、「茹でる」、「煮る」、「蒸す」、「焼く」、「炒める」、「その他」の6種類の行動を、約50%の精度で識別可能であることを確認した。

本論文は、これらの成果をまとめたものであり、構成は以下のとおりである。2章では、関連研究として、行動認識および調理支援システムに関する既存研究について述べ、本研究の位置づけを明らかにする。3章では、本研究で提案する料理行動を対象としたマイクロ行動認識システムについての要件、構成及び手法について述べる。4章では、評価実験と実験結果について述べる。最後に、5章では、本論文の結論及び今後の課題について述べる。

2. 関連研究

本章では、本研究に関連する既存研究について説明する。まずはじめに、代表的な手法であるカメラを用いた行動認識について述べる。次に、ウェアラブルデバイスを用いた行動認識について述べる。その後、振動センサに基づく行動認識について述べた後、本研究の対象である料理行動に関する研究と調理支援システムに関する研究について述べる。最後に、本研究の位置付けについて説明する。

2.1 カメラを用いた行動認識

まず初めに、カメラを用いた行動認識に関する既存研究について述べる。近年、カメラを用いた行動認識に関する研究は、世界中で数多く行われている [14, 15]。画像や映像に基づく行動認識の代表的なアプローチとして、CNN をはじめとした深層学習モデルを利用した手法や被撮影者のプライバシーに配慮するために映像内の人物の骨格情報のみを用いた手法などが存在している [17]。

画像には情報量が多く含まれるため、カメラを用いた行動認識では撮影された画像や映像から人の行動に関する特徴的な情報を抽出することで、生活行動を始めとする様々な行動を検出できる。また、骨格情報では、体の位置や向き、動きの情報が取得できる。また、加えて、手の骨格情報を取得することにより、動作主の手の向きや動き、握っているか開いているかが検出できる。一方、カメラで撮影できる情報は限られており、画角が限られていることや死角が存在することにより、観測範囲以外をセンシングすることは不可能となる。つまり、これは1つのカメラのみでは、取得できる範囲に限界があることを意味している。また、使用する器具などが重なるオクルージョンが発生することにより動作している動きが邪魔される場合も、正常に人の行動を認識できない場合がある。そのため、細かい動作を網羅的にセンシングするためには多数のカメラを利用するなどの方法を用いる必要がある。しかし、撮影した情報から骨格情報を抽出するなどして、プライバシーを考慮した行動認識を行う場合においても、宅内にカメラを設置して撮影し続けることは、居住者の抵抗感につながるなど課題が存在する。

2.2 ウェアラブルデバイスを用いた行動認識

ウェアラブルデバイスは、様々な機能を備えたスマートウォッチやフィットネストラッカーなど、身体に装着できるデバイスのことである。ウェアラブルセンサを利用した行動認識に関する研究も多数行われている [10, 19, 12, 13].

入院せずに人々の行動および健康状態をモニタリングすることや、高齢者や障害者の生活を改善し、健康寿命を延伸することが目的とした研究 [19] では、入力として加速度・角速度・地磁気を扱う、ウェアラブルセンサを用いたシステムを提案している。被験者の胸部、右手首、左足首に配置されたセンサーを使用して取得された、加速度・角速度・地磁気の日データセットである MHEALTH [20] を利用している。この研究では、身体センサーデータを解析し、非線形一般化判別分析に基づく効率的な特徴量を抽出し、LSTM (Long Short-Term Memory) に基づく NSL (Neural Structured Learning) を用いて学習する。「歩く」「座る」「ジョギング」をはじめとした 12 種類の活動を、公開データセットでおよそ 99% の再現率を達成している。ヘルスケアサービスにおいて、人間の活動をリアルタイムに分析・予測するためのよりよい選択肢を示している。

近年、AppleWatchをはじめとした高機能スマートウォッチやFitbitなどのフィットネストラッカーが容易に購入できることから、多くの行動認識に関する研究に利用されている。しかし、一日中装着する必要があるウェアラブルデバイスは、近年小型化の傾向にあるとはいえ、依然として装着者に対して煩わしさや負担感を感じさせる。また、ウェアラブルデバイスは、一日中使用するとバッテリーが持たないケースもあるため、頻繁な充電が必要となる。そのため、これらを解決可能な行動認識システムの構築が早急に求められている。

2.3 振動センサを用いた行動認識

振動センサを利用した行動認識に関する研究 [21, 22, 23] も多数提案されている。

VibroSense [21] は、レーザードップラー振動計により計測した振動データをディープラーニング (CNN) により解析し、ドライヤーやシャワーなどを含む 18 種類の生活行動を認識するシステムである。このシステムは、天井のある一点に向

けてレーザードップラー振動センサを設置することで壁や天井の構造振動パターンを計測し、各生活行動において生じる微小な振動の違いを認識する。取得した振動データは処理され、訓練されたディープニューラルネットワークにより、シャワーや暖房器具の使用をはじめ電気製品や水回り製品に関する最大 18 種類の行動を区別する。

オフィスにおける人間の行動を認識し、生産性向上や健康監視を目的とした OAC[22] では、振動を測定するジオフォンセンサにより周囲の構造物の振動を計測することで、歩く、タイピング、話すなどの行動を識別する。机の上に設置されたジオフォンセンサの信号は増幅器により増幅され、アナログデジタルコンバータ（ADC）でデジタル化される。そして、信号がウィンドウ化されて特徴抽出モジュールに送られ、さらに分析される。教師あり学習には、SVM は活動検知によく使われる標準的な機械学習アルゴリズムであるサポートベクターマシン（SVM）を 2 段階使用している。8 人の異なる被験者のそれぞれ一人の活動だけでなく、信号を人数で分割するブラインド信号分離やクラスごとに個別の分類器を利用し、複数人での活動の分類も評価している。この多段階活動分類モデルでは、4 種類の活動（静粛、話す、タイピング、筆記）において 97 % の活動分類精度を、2 番目の活動（座る、立つ、歩く）で 90 % の分類精度を、そして重複する活動セットを組み合わせたセットにおいても 90 % の分類精度を達成している。

このように、振動センサを利用した手法は、振動はテーブルや床などの構造物を伝わるため、カメラなどを利用する手法と比較して死角が存在しないという利点を持つ。また、人の音声や画像を保存したり、入力された内容や書かれた内容を理解したりしないため、プライバシーが保たれる。加えて、身体に装着する必要がなく、デバイスによる煩わしさや負担感を有しない。一方、構造物と接触を必要としない行動は原理的に区別することが不可能であるという欠点がある。また、現在の研究では、料理行動のマイクロ行動認識を対象とした研究も存在しない。

2.4 料理行動に関する研究

数ある日常生活行動の中でも、料理行動を扱う研究は多数提案されている [24, 25, 26, 27]。画像により調理行動を識別する研究 [24] では、CNN により調理作

業のマイクロ行動認識手法を提案している。提案では、対象とする調理作業として「調理器具を取り出す」「食材を取り出す」「洗う」などを想定している。また、Jinna Lei らによる、RGB-D (Kinect スタイル) カメラを用いた料理行動のきめ細かな認識に関する発表 [25] がある。提案されたプロトタイプシステムは、奥行き (形状) と色 (外観) を組み合わせて、手の位置、オブジェクトとその機能の識別、行動の認識、行動によるオブジェクトの状態変化の追跡を実現している。例えば、ホットケーキミックスに砂糖をスプーン何杯分入っているか、どれくらいの時間混ぜているかなど、調理活動の詳細な手順を、計測器を使用せずに追跡し、正確に認識することが可能となっている。また、深度カメラ KinectV2 を用いて、調理作業の認識を行っている研究 [26, 27] がある。RGBD カメラの深度データから計算した骨格情報をもとに、調理者のキッチンにおける相対位置および胴体と上肢の位置関係・角度を算出する。そして、これらを特徴量として機械学習を行うことで、5 種類の調理作業を平均 72.3 % の精度で分類可能である。これらの提案では、設置型センサを利用していることから、ユーザーの行動を阻害せずに調理を行うことが可能である。しかし、「洗う」のように正解率の高い動作がある一方で、「食材を取り出す」や「粉をまぶす (49.5 %)」のように正解率の低い行動がある。

2.5 調理支援システムに関する研究

複数レシピに対する最適調理手順の作成が可能である最適調理手順提示システムが提案されている [4]。調理に不慣れな初心者は、調理時間を効率化する方法を知らないため、調理に長時間を要する。このシステムは、調理に不慣れな初心者をサポートする手段として、調理環境に応じて、調理時間を短縮できる最適調理手順の自動作成が可能である。複数レシピで並行調理する際の調理環境に応じた最適調理手順を提示するため、調理手順をタスクスケジューリング問題として捉えた最適調理手順探索アルゴリズムとして提案されている。評価実験により、提案した最適調理手順探索アルゴリズムを用いることで、想定した献立に対する最適調理手順を求めることが可能であることが示されている。

また、認識技術により自動的に表示を切り替えるレシピ提示システムである

CHIFFON[5] が提案されている。CHIFFON は表示部 (Viewer), 認識部 (Recognizer), 指示部 (Navigator) の 3 つのモジュールから構成され, 認識技術により自動的に表示を切り替えるような, レシピ提示システムの研究用プラットフォームとして開発されている。このプラットフォームを使うことにより, 認識技術を HCI に応用する研究などにおいて, インターフェイスの開発に割くコストを最小限にしながら, 研究を進めることができるとしている。また, レシピは Hand-Work Markup Language (HWML)[5] と呼ばれる言語により記述されている必要がある。これは, 人間があらゆる種類の手作業を行うための指示をレシピとして記述することを目的として開発された言語である。

これらのシステムを利用して宅内行動認識を活用することにより, レシピの提案やオーブンの自動温度調整などの調理支援が実現が可能である。

2.6 本研究の位置づけ

本研究の目的は, ピエゾセンサから得られる振動情報を用いた料理中のマイクロ行動認識システムを構築することである。近年, 行動認識に関する研究は多数提案されているが, プライバシーを保護しつつ, 正確に料理中の行動を認識することは, 依然として困難である。既存の料理行動の認識は, 多数のセンサを用いることで実現しているが, その多くはカメラを利用するものである。カメラを利用した手法は, ユーザに対するプライバシー上の問題が存在するため, その使用がしばしば制限される。本研究では, プライバシーを保護しつつ, ピエゾセンサから得られる振動情報を用いて, 料理行動中のマイクロ行動を正確に認識する新たな手法を提案する。ピエゾセンサは, 振動センサの一種であり, カメラと比べて非常に小型であることが知られており, 非常に薄型なセンサでもあるため, 様々な環境にも適応できる。また, インテリアを損ねる事なく周囲に溶け込むように設置できるため, 装着負担が軽減できるという利点もある。

3. 提案システム

本章では、ピエゾセンサから得られる振動情報を用いた料理中のマイクロ行動認識システムを新たに提案する。まず初めに、提案するシステムの概要について説明する。その後、提案システムの構成および分析手法について説明する。

3.1 システムの要件

本節では、提案システムを実現する上で、満たすべき要件について説明する。我々が提案する料理中のマイクロ行動認識システムは、家庭内での使用を想定している。第2章の関連研究を通して、本提案システムを実現するには、以下の要件を満たす必要があることがわかった。

要件 (1): プライバシ侵害が少ないシステムであること

要件 (2): 装着負担が少ないシステムであること

要件 (3): 環境に溶け込むように設置できるシステムであること

要件 (4): 料理中のマイクロ行動を認識できること

既存の料理行動認識システムの多くは、多数のカメラを環境側に設置し、料理行動に関する特徴的な情報を入力データとした機械学習・深層学習を用いることで高精度な行動認識率を実現している。しかし、本人が判別できる映像情報は個人情報に該当する [28] ため、法律に沿った適正な取り扱いや管理が必要となる。また、撮影角度によっては近隣住宅の家の中が撮影範囲に入り込む可能性も生じる。本研究では、要件 (1) を満たすため、画像・映像のようなプライバシーと密接に関連したデータを収集するセンサを用いるのではなく、プライバシーと関連しないデータを収集できるセンサを使用する必要がある。プライバシーと関連しないデータを収集する方法として、ウェアラブルデバイス等を利用する方法も考えられる。しかし、行動認識率向上のため、一日中装着することを義務付けられるウェアラブルデバイスを用いた手法は、近年小型化の傾向にあるとはいえ、依然としてユー

ザに対して煩わしさや負担感を感じさせる。本研究では、要件 (2) を達成するため、ユーザに対してウェアラブルデバイスの装着を必要としない、環境設置型のセンサを採用する必要がある。環境設置型のセンサは様々あるが、家庭内での使用を想定した場合、部屋のインテリアなどを損ねることなく設置可能なセンサが望まれる。本研究では、要件 (3) を満たすため、小型でありながら、設置場所を選ばないセンサを採用する必要がある。料理中のマイクロ行動を認識するには、料理中に生じる微細な振動の微妙な違いを正確に捉える必要がある。その場合、振動情報を画像情報として扱うことにより、区別しにくい微妙に異なる振動情報を正しく認識できる可能性がある。本研究では、要件 (4) を満たすため、画像情報に関する解析を得意とする CNN をベースとした深層学習を利用する。

3.2 システム構成

本章では、我々が提案したシステムの構成について述べる。図 3 に、システムの構成図を示す。本研究では、3.1 節で述べたシステム要件の全て満たしうるものとして、5つの要素（ピエゾセンサ、増幅回路、インターフェース、PC、アノテーション用ビデオカメラ）からなる行動認識システムを新たに提案する。以下に、各構成要素について詳細について述べる。




図 3: システム構成図

3.2.1 ピエゾセンサ

提案システムで使用するセンサについて説明する．料理行動におけるマイクロ行動を認識するため，提案システムでは，振動センサを使用する．振動センサは，主に料理行動時に発生する振動を効率よくセンシングするために使用する．本システムでは，料理行動を行う際に発生する多種多様な振動を取得するための振動センサとして，piezoセンサを利用する．本研究において使用するpiezoセンサは，図5に示す村田製作所の7BB-41-2L03を使用する．使用するpiezoセンサは，直径5cm程度の大きさであり，非常に薄型であるため，環境に溶け込むように配置でき．また，多少の障害物が周辺に存在しても，回折効果によって振動を比較的捉えやすいという利点を有することで知られている [29]．料理行動は，場所によって異なった行動となるため，複数のpiezoセンサを利用して振動を取得する．それらを，図4に示すように，キッチン内のそれぞれ異なった設置場所に設置することで，料理行動中に発生する異なる振動を効果的に補足する．本研究では，具体的に，3つのpiezoセンサを用意し，それぞれ蛇口周辺（キッチン左側），作業台周辺（キッチン中央），コンロ周辺（キッチン右側）に設置することで，複数のセンサにて異なった振動を取得している．




図 4: システム設置の様子




図 5: 使用するピエゾセンサ

3.2.2 増幅回路

本研究で使用するシステムにおいて，センサ信号を取り込むハードウェアは，料理行動によって引き起こされる微小な振動を効果的に取得できるよう，以下のように設計されたものを利用する．一般的に，ピエゾセンサは，電氣的に高インピーダンスであり，信号を劣化なく取り込むには，アンプの入力回路も高インピーダンスである必要がある．このため，センサの入力部には FET 入力タイプのオペアンプを用いた回路構成とし，ピエゾセンサの出力インピーダンスに対して増幅回路の入力インピーダンスを十分高くすることで，電圧降下によるロスを防ぐ工夫を行なっている．図 6 に使用した回路を示す．また，高いインピーダンスを持つ回路は，周囲環境からのノイズに非常に敏感であるため，図 7 に示すシールドケースを用いて，その影響を軽減している．




図 6: 使用する増幅回路




図 7: シールドケース

3.2.3 インターフェイス

センサデータは、PCに入力する際にインターフェイスが必要となる。3つのピエゾセンサにより取得された料理行動による3ch分の振動は、上記で説明した増幅回路により、信号強度が増幅された後、オーディオインターフェイスであるRoland Rubix44によってA/D変換され、PCに入力される。

3.2.4 PC

インターフェースを経由した振動情報は、インターフェースに接続された PC に記録される。本システムでは、振動情報を保存するためのソフトウェアとして、誰でも自由に使うことのできるフリーのデジタルオーディオエディタとして知られている Audacity を利用し、同時に 3ch 分の振動情報を保存する。加えて、後述する分析手法も PC を通して実行される。

3.2.5 アノテーション用ビデオカメラ

ユーザが料理行動を行う際、振動情報を取得するとともに、正解データとして、動画により料理行動が記録される。記録された動画データは、教師データのラベル付けを行う際に利用するため必要となる。ビデオカメラは学習モデル構築後は使用しないため、実際の運用時には必要としない。

3.3 分析手法

本節では、提案システムで用いる具体的な分析手法について説明する。大まかな処理の流れを図 8 に示す。提案システムによりセンシングされた振動データは、1 つのサーバに集約される。集約されたデータは、前処理を施されたあと、機械学習モデルの入力データとして使用する。具体的には、行動により引き起こされる振動は、ピエゾセンサにより計測され、短時間フーリエ変換により 2 次元画像に変換された後、深層学習の一つである CNN を用いて、ユーザの料理行動中のマイクロ行動を推定する。以下に、詳細を記述する。

1. 料理行動による振動をピエゾセンサにより取得
2. 前処理およびスペクトログラムにより、振動を 2 次元画像化
3. ResNet をもちいた機械学習、行動認識

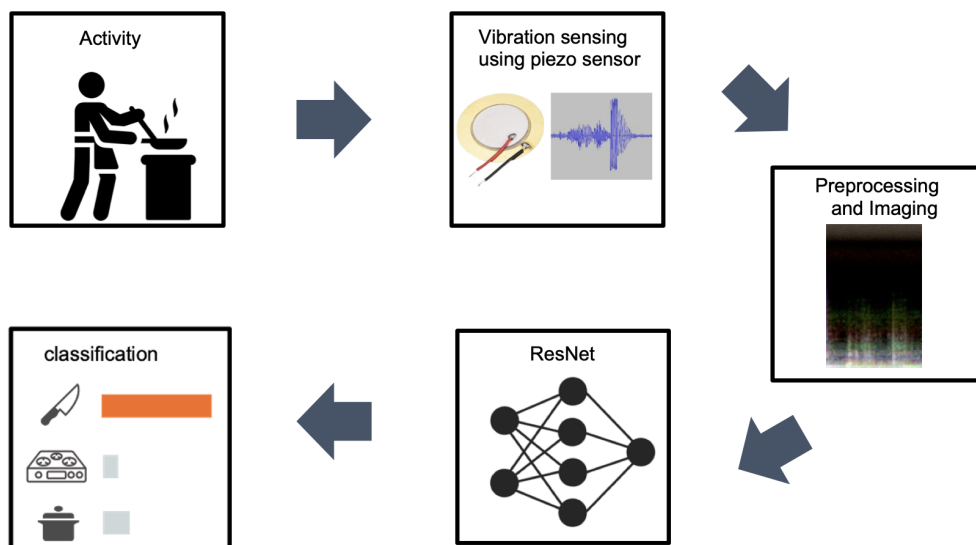


図 8: 処理の流れ

3.3.1 前処理

本項では、提案システムの処理の中で行われる前処理について説明する．前処理として、WAV フォーマットである振動データ数秒ごとに切り出し、それぞれの信号について画像化する．取得した振動データの一例を 9 に示す．本実験においては、それぞれの料理行動による振動が収まると考えられる秒数として、1 秒間のタイムウィンドウを用いている．また、取得した振動データはピエゾセンサによるアナログデータを変換して取得している．そのため、実験ごとに信号の大小があることが考えられる．それらの誤差を吸収するため、minmax スケーリングによる正規化を行い、過学習の改善を図る．また、正解の行動ラベルをアノテーションには、振動データを取得すると同時に、料理中の行動を記録した動画を利用し、ラベリングを手作業で行う．




図 9: 取得される振動データの例

3.3.2 スペクトログラム

取得した振動データは，WAV 形式で保存されるため，後述する CNN の機械学習モデルである ResNet34 で利用するため，2 次元画像の形式に変換する．時系列データである振動データを画像化するために，STFT を適用し，スペクトログラムを生成する．図 1 に，スペクトログラム算出時のパラメータを示す．生成した振動データの一部を図 10 に示す．これは，横軸を時間軸とし，縦軸を周波数とし，短時間フーリエ変換により 2 次元配列に変換したものである．

表 1: スペクトログラム算出時のパラメータ

sample_rate [Hz]	44100
n_fft	2048
n_mels	128
win_length	2048
hop_length	512
window_fn	hann




図 10: スペクトログラムの例

3.3.3 RGB 画像化

ResNet では、入力に 3 チャンネル (RGB) の二次元画像が必要である。そのため、3 つのピエゾセンサからそれぞれ取得した信号を処理し、合わせて 3 チャンネルのデータ行列を構築し RGB 画像とすることで、深層学習モデルの入力とする。生成した RGB 画像の一例を図 11 に示す。これにより、画像認識タスクで一般的に用いられる機械学習モデルである ResNet が行動認識に適用可能となり、構造化されているため事前学習、転移学習が容易に利用できる。また、それぞれのセンサ位置と色が対応することとなる。これにより、CNN 等の機械学習モデルが関連づけて学習すること可能とする。

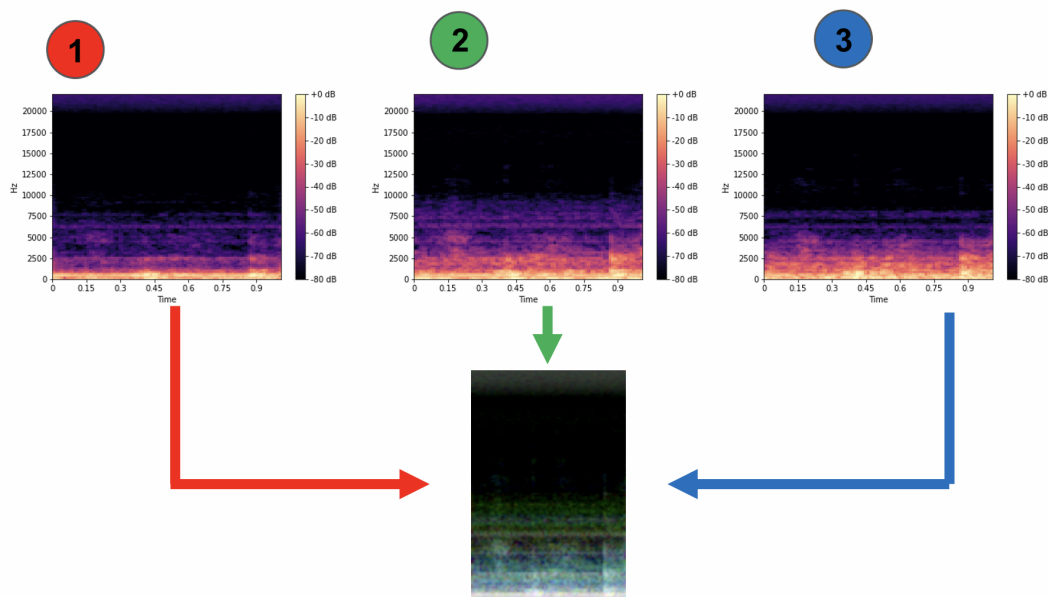


図 11: RGB 画像化

3.3.4 サンプリング

実際の料理行動を学習データとした場合，取得できるそれぞれの行動のデータ量が均一ではなく，最多行動のデータ量と最小行動のデータ量で 20 倍ほどの差がある．そのため，不均衡データにより，学習することとなり，過学習の原因となる．そのため，教師データを学習時にサンプリングする際に工夫が必要となる．しかし，ダウンサンプリングを行うと，少量のデータに合わせる必要があるため，学習されたモデルの汎化性が落ちるという問題が生じる．これらを解消するための対策として，学習時にミニバッチごとに重複を許すようなサンプリングを行う．

3.3.5 機械学習モデル

本研究において，機械学習モデルとして ResNet[18] を用いる．利用する深層学習モデルの構造を図 12 に示す．ResNet は，残差ブロックを導入することにより，ネットワークを深くする際の精度の劣化を防いぎ，従来の CNN とくらべてより

画像分類の精度を高めたものである。図 13 のように，ResNet の 1 つのブロックにはいくつかの畳み込み演算が含まれており，それぞれにバッチ正規化と正規化線形ユニット (ReLU) の層が連続する構成となっている。ResNet の末端には，グローバル平均プーリングが接続され，スペクトログラムのベクトル表現が抽出される。そして，抽出されたベクトルは，ReLU を挟んだ 2 つの全結合層とドロップアウト層に入力される。最終的に全結合層によって認識結果が出力されることとなる。本手法での深層学習モデルの出力は，最後の層の次元を料理行動を分類するカテゴリ数とし，One-hot ベクトルとして学習を行う。One-hot ベクトルとは，0 か 1 のみで表されたベクトルのことであり，推論された行動に対応する次元のみが 1 の値をとり，その他の行動を表す次元は 0 の値となる。

3.3.6 評価手法

行動認識モデルの評価は，過学習をさけるため，複数セッションによる検証を行う。本実験では，Leave One Session Out 交差検証を実施し，場所，料理を固定し評価を行う。




図 12: ResNet




図 13: 残差ブロック

4. 評価実験

本章では、提案するピエゾセンサの振動情報を用いた料理中のマイクロ行動認識システムを用いた評価実験について述べる。本研究での評価実験では、可視化を目的とした予備実験と、実際に料理行動の認識を実施する本実験の2種類の実験を行う。各実験における目的と概要を述べた後、実験方法および評価方法について述べる。

4.1 予備実験

提案システムを利用して振動データの画像化が可能か確認するために、図4に示す奈良先端大内に設置されたスマートホーム環境において評価実験を行う。

提案手法により画像化することにより、振動センサで取得したデータを機械学習モデルとしての ResNet の入力に対応する形式に変換するとともに、提案システムを利用して振動データの収集が可能か、行動ごとの特徴量が抽出できているかを目視で確認することを目的とする。

4.1.1 実験目的

3章で述べた行動認識システムの実現に向け、提案システムでの行動認識の可能性を検証するため、データ収集実験を行う。具体的には、実験環境の構築、振動の取得、データの可視化を目的とし、実験を行う。実験を通して、行動ごとに区別できる特徴量をもつデータを取得できるかを確認する。

4.1.2 実験手順

本項では、実験手順について説明する。実験では、被験者により調理行動を行い、我々が開発した提案システムを利用して振動データを取得する。被験者は、後述する8種類の行動をニンジンを対象として行う。提案システムは、調理行動を行う直前に電源を入れ、調理行動の振動データの取得を開始し、保存する。得

られた振動データを可視化するため、本研究の提案手法を実装した Python プログラムを用いて画像化を行う。

4.1.3 実験条件

データ収集実験は、奈良先端大スマートホーム内のキッチンに提案システムを設置し、実施する。本実験では、被験者が実際に料理をつくる際の振動を提案したシステムを利用して収集する。スマートホームは、365 日いつでも In-the-wild な環境を想定した実験ができるため、本研究の実験場所として適している。また、過学習によるテストデータでの性能悪化を避けるため、複数セッションによる検証を実施する。場所、料理、人は同一とし、Leave One Session Out 法により検証する。また、センサによる振動取得の際の S/N 比を向上させることを意図し、ピエゾセンサ上に真鍮製のおもり 200g を乗せる。Roland Rubix44 を用いて、サンプリング周期 440kHz の振動データをラップトップ上に記録する。

4.1.4 実験対象

以下の 8 行動の振動を、ニンジンを対象にそれぞれ 1 分間取得する。詳細について記述する。

対象行動 実験において対象とする料理行動について、詳細を以下の表 2 に示す。

表 2: 対象行動

行動ラベル	説明
行動しない	静止したまま、動作を行わない
洗う	手を使って水道水で洗う
切る	半分に切った後、みじん切り
焼く	半分に切ったあと、フライパンで焼く
茹でる	水が入った鍋で茹でる
炒める	みじん切りされたものを、フライパンで炒める
煮る	水が入ったフライパンで煮る
和える	菜箸を使って、ボウルの中で混ぜる

4.1.5 データ処理

取得したセンサデータはWAV形式で保存される。また、Pythonプログラムにてデータ処理され、スペクトログラムに変換した後に、RGB化される。

センサ波形 料理行動により生じる振動を取得したセンサデータの波形の例を図14に示す。センサデータの強度の時間推移を表している。横軸は時間、縦軸は信号の大きさを表している。




図 14: 取得した振動

スペクトログラム スペクトログラムとは、信号に対して周波数分析を時間的に連続して行い、色によって強さを表すことで、強さ、周波数、時間の3次元表示を行ったものである。本研究では、オープンソースの機械学習フレームワークであるPyTorchを使用したオーディオおよび信号処理用のライブラリであるTorchaudioのメソッドSpectrogramを利用する。図1に、スペクトログラム算出時のパラメータを示す。行動ごとに取得したセンサデータをスペクトログラムに変換したものを図15～22に示す。横軸は時間、縦軸が周波数、色が信号の強度を表している。信号の強度が強ければ、色も白く表示されることとなる。

図より、行動ごとの特徴が表現されていることが見て取れる。例えば、洗う行動は広い周波数に渡って強い信号が確認できることや、炒める、切るなどの行動

は不連続な行動であるため、間隔が一定ではない強い入力があることが画像から確認できる。また、煮る行動や炒める行動などの特定の行動のスペクトログラムには、画像の下側に白い線状の模様が出現していることが確認できる。

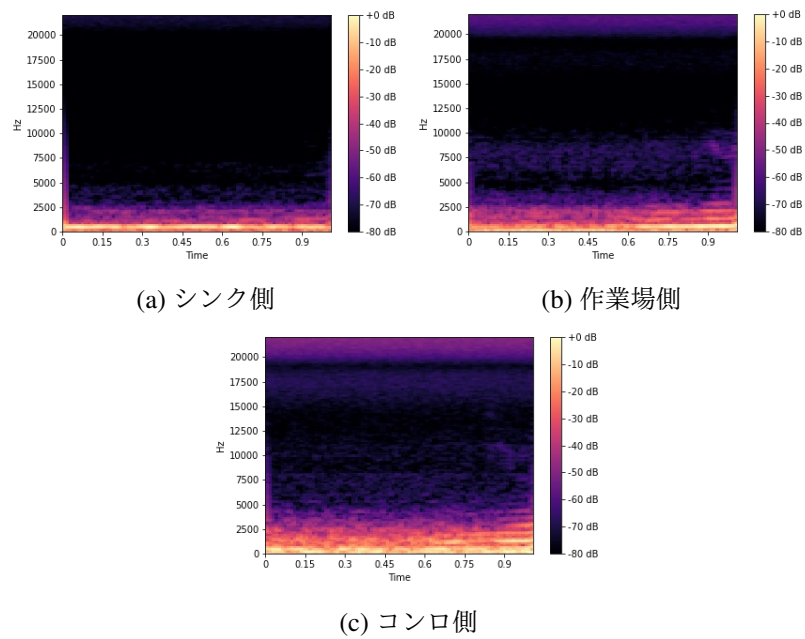


図 15: スペクトログラム（行動しない）

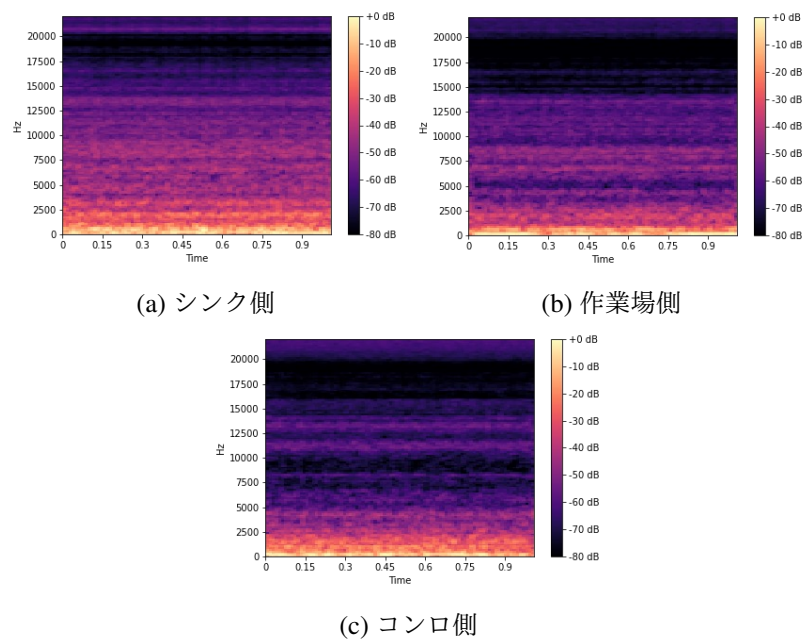


図 16: スペクトログラム (洗う)




図 17: スペクトログラム (切る)

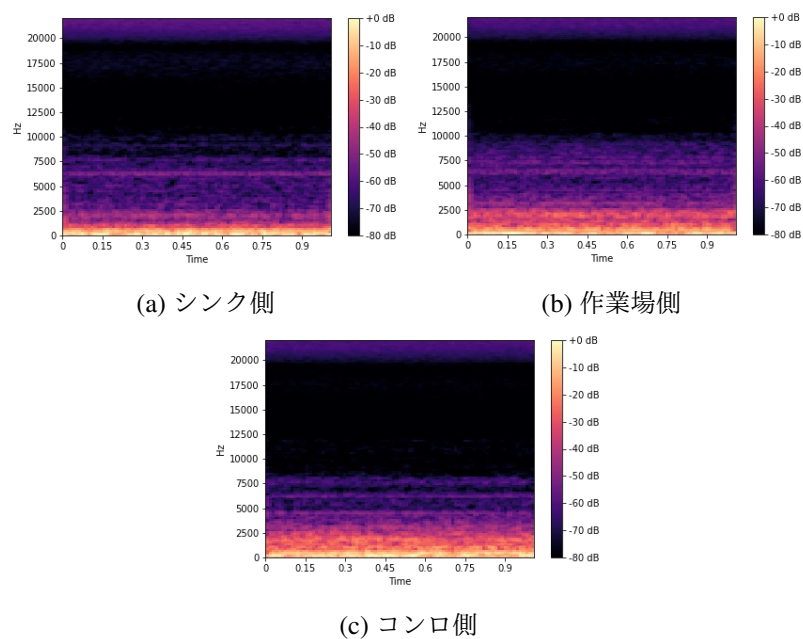


図 18: スペクトログラム（焼く）




図 19: スペクトログラム（炒める）




図 20: スペクトログラム（和える）

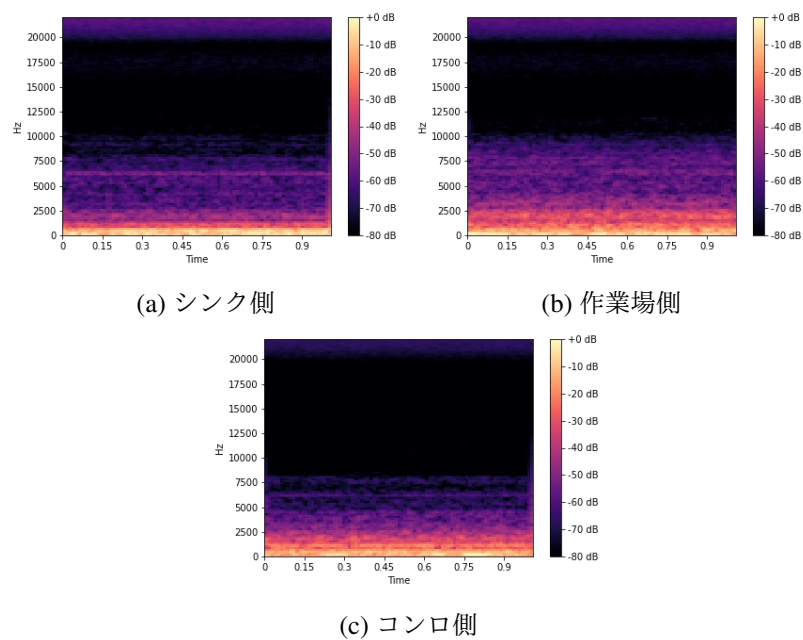


図 21: スペクトログラム（茹でる）

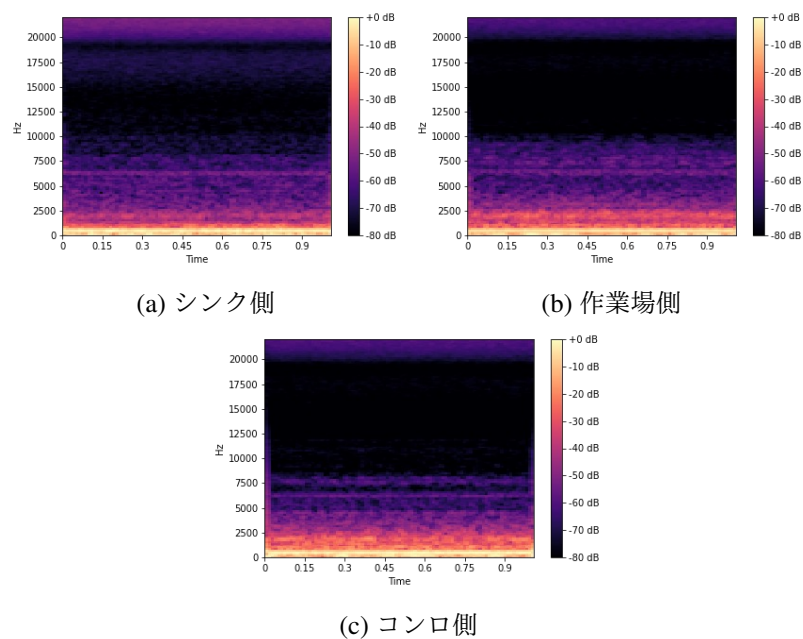


図 22: スペクトログラム（煮る）

RGB 画像 図 23 ～ 30 は、それぞれの行動ごとのスペクトログラムを RGB 画像に変換したものである。前述のスペクトログラムと同様に、横軸は時間、縦軸が周波数、色が信号の強度を表している。画像の画素の位置が時間と周波数に対応し、色が 3 つのセンサそれぞれの信号の強度を表している。シンク側の信号強度が高ければ赤色が強くなり、作業場の信号強度が高ければ緑色が強くなり、コンロ側の信号強度が高ければ黄色が強くなる。洗うなどは赤と黄色の成分が多く、切る行動は赤と青、焼く・炒める・茹でるなどのコンロを使用する行動は、緑色の成分が強く反映されていることが確認できる。




図 23: RGB 画像 (行動しない)




図 24: RGB 画像 (洗う)




図 25: RGB 画像 (切る)



図 26: RGB 画像 (焼く)




図 27: RGB 画像 (炒める)




図 28: RGB 画像 (和える)



図 29: RGB 画像 (茹でる)




図 30: RGB 画像 (煮る)

4.1.6 結果と考察

図より、行動ごとに作業する場所に対応した色の特徴が出ていることが見て取れる。例えば、洗うなどは赤と黄色の成分が多く、切る行動は赤と青、焼く・炒める・茹でるなどのコンロを使用する行動は、緑色の成分が強く反映されていることが確認できる。また、炒める、切るなどの行動は不連続な行動であるため、間隔が一定ではない強い入力があることが画像から確認できる。また、煮る行動や炒める行動などの特定の行動のスペクトログラムには、画像の下側に白い線状の模様が出現している。これは、コンロから生じる振動により生じる一定の周波数が分布が反映されていることが推察できる。また、煮る行動はその他の加熱する行動と比較して、画像に赤色の成分が多く見られる。これは、沸騰による振動が生じるため、その特徴が反映されていると考えられる。スペクトログラムにより、行動ごとの特徴量を表現できていることが確認できた。

また、RGB 画像化することにより、より直感的に違いがより分かることが確認できた。加えて、カラー画像であるため、本研究で提案手法する分析手法に用いる ResNet で利用できる。また、その他の画像分類タスクで提案される機械学習モデルを Fine-Tuning することで、様々なモデルでの適用が可能となると考えられる。

以上より、提案システムを用いて、圧電センサを利用した信号取得がスペクトログラムによる信号の可視化により確認できた。また、実験により、それぞれの行動ごとに特徴的な振動を持つことが確認できた。

4.2 本実験

ピエゾセンサを用いた料理行動認識手法の有効性の評価を行うため，図 4 に示す奈良先端大内に設置されたスマートホーム環境において評価実験を行う．カレー，餃子，およびウインナーを実際に調理し，行動認識の精度を評価する．

4.2.1 実験目的

本実験では，3 章で述べた行動認識システムの有効性を検証するため，提案システムを用いて行動認識実験を行う．加えて本実験では，予備実験で確認した提案システムを利用した手法である分析手法が，実際の料理中のマイクロ行動を識別できるか評価するために実施する．

4.2.2 実験条件

本実験は，奈良先端大スマートホーム内のキッチンに提案システムを設置し，実施する．スマートホームは，365 日いつでも In-the-wild な環境を想定した実験ができるため，本研究の実験場所として適している．また，過学習によるテストデータでの性能悪化を避けるため，複数セッションによる検証を実施する．場所，料理，人は同一とし，Leave One Session Out 法により検証する．また，センサによる振動取得の際の S/N 比を向上させることを意図し，ピエゾセンサ上に真鍮製のおもり 200g を乗せる．Roland Rubix44 を用いて，サンプリング周期 440kHz の振動データをラップトップ上に記録する．

4.2.3 実験手順

被験者は，カレー，餃子，およびウインナーを実際に調理する．実験での対象になる料理行動は，茹でる，煮る，蒸す，焼く，炒める，その他の 6 種類の行動とする．対象とする料理は，一人暮らしであることを前提に，認識可能であることと一般的な料理行動 [30] を網羅していることを考慮し選択する．提案システムは，調理行動を行う直前に電源を入れ，調理行動の振動データの取得を開始し，

保存する。被験者により調理行動を行い、提案システムを利用して振動データを取得する。本実験では、セッションごとのセンサ感度の誤差を吸収するために前処理に min-max スケールでの正規化する工夫を行う。さらに、提案システムで取得した振動データを、予備実験で確認した分析手法を利用して2次元画像化をおこなう。加えて、本実験では、2次元画像とCNNを利用して、料理のマイクロ行動認識認識を実施し、場所、料理、人は同一としたホールドアウト法を行う。また、実際の料理を対象とするために、データ数が多い行動と少ない行動の差が大きくなる。そのため、不均衡データへの対策として、少数データのオーバーサンプリングを行う。

4.2.4 結果と考察

図31に、機械学習を行い推論した結果を示す。これは、3セッションのうちセッション1, 2を学習データとして、セッション3をテストデータとして推論した結果の混合行列である。全体の Accuracy は0.572である。識別精度が高い行動は「煮る」で92%である一方、「蒸す」行動は1%であった。これは、「煮る」行動は、本実験において一番長い行動となっており、多くのデータを取得することができる。結果的に汎化性が向上し、認識精度が比較的高いと考えられる。一方、「蒸す」行動はデータ量が少ないことに加えて、他の加熱を伴う行動と比較して加熱を開始してからの時間が短い。そのため、調理が定常状態である時間が少ない。結果として、行動が持つ特徴を学習できておらず、精度が低いと考えられる。また、本研究では動作と対象を一組に認識しているが、調理支援システムにおいては、対象となる材料を具体的に認識することが必要になると考えられる。また、一般的なマイクロ行動の認識を対象としているため、調理支援システムへの応用には、要件の整理が必要だと考えられる。




図 31: 行動ごとの認識結果

加えて，図 32 に，前処理の項で記述したタイムウィンドウの秒数を変化させたときの全体の Accuracy を示す．この結果により，タイムウィンドウサイズが変化した際の精度への影響は限定的であることが見て取れる．また，秒数が少ないほど精度が高い傾向にある．これは，原因としてはタイムウィンドウサイズを小さくすることが結果的に教師データの数が増加し，精度向上につながったと考えられる．




図 32: 秒数の違いによる認識結果

5. 結論

本研究では、ピエゾセンサを利用し、調理中に発生する振動の違いに基づくマイクロ行動認識システムを提案した。提案システムでは、非接触、死角のないプライバシー保護といった圧電センサーの利点を活用する。提案システムでは、ピエゾセンサを利用して振動を取得し、前処理を通してスペクトログラムに変換する。得られた2次元画像とRGB画像は、ResNetによる機械学習の入力データとして利用される。これにより、調理中のマイクロ行動を認識することができる。

本研究では、奈良先端科学技術大学院大学が所有するスマートホーム内において、提案システムの有用性を検証するための実験を実施した。具体的には、実際の食材の調理過程を再現し、その時に発生する振動データを収集し可視化する予備実験を行った。結果として、本システムを用いることにより、行動ごとに特徴が異なるデータを収集することが可能であることが確認された。この結果から、本システムによる行動認識の実現可能性が示された。また、提案システムによるマイクロ行動の識別能力を評価するため、カレー、餃子、およびウインナーの調理において料理行動認識を実施した。その結果、「茹でる」、「煮る」、「蒸す」、「焼く」、「炒める」、「その他」の6種類の行動を約50%の精度で識別することが可能であることが確認された。しかし、行動全体に対して少数となる行動は予測精度が低く、実用に十分とはいえない。そこで、適切な学習データの水増しを行い、さらなる少数データに対する対策を講じる必要がある。オーバーサンプリング時に足音など事前に取得した現実的なノイズを付与することや、少数行動のみのデータを収集することなどが挙げられる。

今後の課題としては、本研究の行動認識実験においては主に加熱を伴う行動を対象としたため、本システムの実用に向けてより多くの調理行動種類への対応が挙げられる。また、間取りや環境の違いによっての精度への影響も調査する。加えて、行動全体に対して少数となる行動は予測精度が低いという問題を解決するために、より多くの学習データを収集するために追加実験を行う予定である。

謝辞

本研究を進めるにあたり、安本慶一 教授には、研究全般に関し、多大なるご指導・ご助言を賜りました。また、充実した研究環境の整備など、研究活動を手厚くご支援いただきました。感謝の意を表すとともに、心より厚く御礼申し上げます。

加藤博一 教授には、ご多忙の中、論文審査委員を引き受けてくださった上で、様々なご助言をいただきました。感謝の意を表すとともに、心より厚く御礼申し上げます。

大阪公立大学の藤本まなと 准教授には、プロジェクトの推進や論文執筆時の基礎、研究に関する様々なご指導・ご助言をいただきました。また、研究に行き詰まった際には、的確なアドバイスを賜りました。感謝の意を表すとともに、心より厚く御礼申し上げます。

諏訪博彦 准教授には、本研究やその他プロジェクトにおいて、丁寧なご指導・ご助言をいただきました。論文文執筆時においてもご助言をいただき、感謝の意を表すとともに、心より厚く御礼申し上げます。

松田裕貴 助教には、日常的な研究室内の活動をはじめとした様々なことに対してご助言を頂きました。感謝の意を表すとともに、心より厚く御礼申し上げます。

金岡恵 事務補佐員，山内奈緒 事務補佐員には、学会や出張に関する事務処理をはじめ、研究生生活の様々な場面でご支援頂きましたこと、謹んで感謝申し上げます。

研究の推進に協力頂いた、松井智一先輩，吉田誠先輩，三崎慎也先輩をはじめとするユビキタスコンピューティングシステム研究室の先輩，後輩の皆様，共に研究生生活を過ごした同輩には、公私ともにお世話になりました。心より感謝申し上げます。

最後に、今日まで学生生活を様々な面から支えてくださった両親をはじめ、家族に心より感謝申し上げます。

参考文献

- [1] 国立社会保障・人口問題研究所. 第6回全国家庭動向調査. p. 3, 2018.
- [2] 内閣府. 令和3年度高齢社会白書. 2021.
- [3] 一般社団法人日本唐揚協会. 自炊の有無・頻度に関するアンケート, 2022.
<https://karaage.ne.jp/contents/?p=405>.
- [4] Jin Nakabe, Teruhiro Mizumoto, Hirohiko Suwa, and Keiichi Yasumoto. Optimal cooking procedure presentation system for multiple recipes and investigating its effect. *Algorithms*, Vol. 14, No. 2, 2021.
- [5] Atsushi Hashimoto, Jin Inoue, Takuya Funatomi, and Michihiko Minoh. How does user's access to object make hci smooth in recipe guidance? In *Proc. of 6th International Conf. on Cross-Cultural Design, Held as Part of HCI International 2014*, pp. 150–161, 2014.
- [6] Asma Benmansour, A. Bouchachia, and Mohammed Feham. Multioccupant activity recognition in pervasive smart home environments. *ACM Computing Surveys (CSUR)*, Vol. 48, pp. 1 – 36, 2015.
- [7] Anubhav Natani, Abhishek Sharma, and Thinagaran Perumal. Sequential neural networks for multi-resident activity recognition in ambient sensing smart homes. *Applied Intelligence*, Vol. 51, pp. 6014 – 6028, 2021.
- [8] Eri Nakagawa, Kazuki Moriya, Hirohiko Suwa, Manato Fujimoto, Yutaka Arakawa, and Keiichi Yasumoto. Toward real-time in-home activity recognition using indoor positioning sensor and power meters. In *2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pp. 539–544, 2017.
- [9] Kotaro Ishizu, Teruhiro Mizumoto, Hirozumi Yamaguchi, and Teruo Higashino. Home activity recognition using aggregated electricity consumption data. In

2020 IEEE International Conference on Smart Computing (SMARTCOMP), pp. 302–307, 2020.

- [10] Oscar D. Lara and Miguel A. Labrador. A survey on human activity recognition using wearable sensors. *IEEE Communications Surveys & Tutorials*, Vol. 15, pp. 1192–1209, 2013.
- [11] Philipp Urbauer, Matthias Frohner, Veronika David, and Stefan Sauermann. Wearable activity trackers supporting elderly living independently: A standards based approach for data integration to health information systems. DSAI 2018, p. 302–309, New York, NY, USA, 2018. Association for Computing Machinery.
- [12] Johann P. Wolff, Florian Grützmacher, Arne Wellnitz, and Christian Haubelt. Activity recognition using head worn inertial sensors. In *Proceedings of the 5th International Workshop on Sensor-Based Activity Recognition and Interaction*, iWOAR '18, New York, NY, USA, 2018. Association for Computing Machinery.
- [13] Manuel Dietrich and Kristof van Laerhoven. A typology of wearable activity recognition and interaction. In *Proceedings of the 2nd International Workshop on Sensor-Based Activity Recognition and Interaction*, iWOAR '15, New York, NY, USA, 2015. Association for Computing Machinery.
- [14] Zhiwei Deng, Arash Vahdat, Hexiang Hu, and Greg Mori. Structure inference machines: Recurrent neural networks for analyzing relations in group activity recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 4772–4781, 2016.
- [15] Muhammad Ehatisham-Ul-Haq, Ali Javed, Muhammad Awais Azam, Hafiz MA Malik, Aun Irtaza, Ik Hyun Lee, and Muhammad Tariq Mahmood. Robust human activity recognition using multimodal feature-level fusion. *IEEE Access*, Vol. 7, pp. 60736–60751, 2019.
- [16] Tsukasa Okumura, Shuichi Urabe, Katsufumi Inoue, and Michifumi Yoshioka. Cooking activities recognition in egocentric videos using hand shape feature with

- openpose. In *Proceedings of the Joint Workshop on Multimedia for Cooking and Eating Activities and Multimedia Assisted Dietary Management*, pp. 42–45, 2018.
- [17] Sumaira Ghazal, Umar S Khan, Muhammad Mubasher Saleem, Nasir Rashid, and Javaid Iqbal. Human activity recognition using 2d skeleton data and supervised machine learning. *IET image processing*, Vol. 13, No. 13, pp. 2572–2578, 2019.
- [18] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition, 2015.
- [19] Md. Zia Uddin and Ahmet Soylu. Human activity recognition using wearable sensors, discriminant analysis, and long short-term memory-based neural structured learning, 02 2021.
- [20] Oresti Baños, Rafael García, Juan Antonio Holgado Terriza, Miguel Damas, Héctor Pomares, Ignacio Rojas, Alejandro Saez, and Claudia Villalonga. mhealthdroid: A novel framework for agile development of mobile health applications. In *International Workshop on Ambient Assisted Living and Home Care*, 2014.
- [21] Wei Sun, Tuochao Chen, Jiayi Zheng, Zhenyu Lei, Lucy Wang, Benjamin Steeper, Peng He, Matthew Dressa, Feng Tian, and Cheng Zhang. Vibrosense: Recognizing home activities by deep learning subtle vibrations on an interior surface of a house from a single point using laser doppler vibrometry. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 4, No. 3, September 2020.
- [22] Amelie Bonde, Shijia Pan, Mostafa Mirshekari, Carlos Ruiz, Hae Young Noh, and Pei Zhang. Oac: Overlapping office activity classification through iot-sensed structural vibration. In *2020 IEEE/ACM Fifth International Conference on Internet-of-Things Design and Implementation (IoTDI)*, pp. 216–222, 2020.

- [23] Shijia Pan, Mario Berges, Juleen Rodakowski, Pei Zhang, and Hae Young Noh. Fine-grained recognition of activities of daily living through structural vibration and electrical sensing. In *Proceedings of the 6th ACM International Conference on Systems for Energy-Efficient Buildings, Cities, and Transportation, BuildSys '19*, pp. 149—158. Association for Computing Machinery, 2019.
- [24] Shinya Michibata, Katsufumi Inoue, Michifumi Yoshioka, and Atsushi Hashimoto. Cooking activity recognition in egocentric videos with a hand mask image branch in the multi-stream cnn. In *Proceedings of the 12th Workshop on Multimedia for Cooking and Eating Activities, CEA '20*, pp. 1–6. Association for Computing Machinery, 2020.
- [25] Jinna Lei, Xiaofeng Ren, and Dieter Fox. Fine-grained kitchen activity recognition using rgb-d. In *Proceedings of the 2012 ACM Conference on Ubiquitous Computing, UbiComp '12*, p. 208–211, New York, NY, USA, 2012. Association for Computing Machinery.
- [26] Teruhiro Mizumoto, Alberto Fornaser, Hirohiko Suwa, Keiichi Yasumoto, and Mariolino De Cecco. Kinect-based micro-behavior sensing system for learning the smart assistance with human subjects inside their homes. In *2018 Workshop on Metrology for Industry 4.0 and IoT*, pp. 1–6, 2018.
- [27] Alberto Fornaser, Teruhiro Mizumoto, Hiroiko Suwa, Keiichi Yasumoto, and Mariolino De Cecco. The influence of measurements and feature types in automatic micro-behavior recognition in meal preparation. *IEEE Instrumentation & Measurement Magazine*, Vol. 21, No. 6, pp. 10–14, 2018.
- [28] 個人情報保護委員会. 「個人情報の保護に関する法律についてのガイドライン」に関するQ & A | 個人情報保護委員会.
- [29] Keisuke Umakoshi, Tomokazu Matsui, Makoto Yoshida, Hyuckjin Choi, Manato Fujimoto, Hirohiko Suwa, and Keiichi Yasumoto. Non-contact person identifi-

cation by piezoelectric-based gait vibration sensing. In *AINA (I)*, pp. 745–757, 2021.

[30] wotopi. 焼・茹・炒・揚・煮・和・蒸…今さら聞けない基礎の調理方法, 2022.

研究業績

国内会議

1. 石山時宗, 松井智一, 藤本まなと, 諏訪博彦, 安本慶一: マルチモーダルセンシングに基づく料理中のマイクロ行動認識の提案, 2021 年度 情報処理学会 関西支部 支部大会, pp.1-4, オンライン, 2021 年 9 月.