

# 前腕動作に着目した食事内容推定

齊藤 隆仁<sup>1</sup> 川崎 仁嗣<sup>1</sup> 太田 賢<sup>2</sup> 片桐 雅二<sup>1</sup> 池田 大造<sup>1</sup>

**概要:** 本研究は摂食に伴う前腕動作に着目した食事内容の推定手法を提案する。既存手法では複数のウェアラブルデバイスを用いた方法が多く、広く一般消費者が活用する上でハードルがある。そこで、提案手法はリストバンド型の汎用的なウェアラブルデバイス 1 台を利き手の前腕に着用し、取得した加速度センサのデータから食事内容の推定を行う。これにより、ユーザに手間をかけさせず食事内容を継続的かつ自動で把握する技術の実現が可能となる。加速度センサによる測定値の平均、分散、標準偏差などの統計的な特徴量を用い、さらに Bag-of-Words 表現に則り、有効な特徴量を k-means でクラスタリングし前腕動作データを複数の特徴的な動作の集合 (words) として表現する。前腕動作データの時系列性を考慮するために words に対して N-gram を適用し、食事内容ごとの前腕動作データを連続する words の出現頻度によって表す。この出現頻度を用いることで Naïve Bayes 分類器を用いた食事内容の推定が可能となる。認識対象の食事内容を 5 種類とし、摂食時の前腕動作データを用いて本手法の有用性を検証する。実験では、食事内容による f1 値の平均が 63%, Accuracy の平均が 70% となり、汎用的なリストバンド型ウェアラブルデバイス 1 台を用いた場合でも、食事の種類を限定した状況では食事内容の推定が可能であることを示した。

## Meal types estimation utilizing fore-arm behaviors

TAKATO SAITO<sup>1</sup> SATOSHI KAWASAKI<sup>1</sup> KEN OHTA<sup>2</sup> MASAJI KATAGIRI<sup>1</sup> DAIZO IKEDA<sup>1</sup>

### 1. 緒言

#### 1.1 背景

ライフスタイルの多様化に伴い、偏食や過食など食生活の乱れが大きな問題となっている。外食や調理済みの食品を利用する人が増えているが、これらの食品は食塩や脂肪を多く含む傾向があり、摂取し続けることで生活習慣病の予備軍が増加すると懸念されている。その一方で健康志向の人は増えており、これらの食品を食生活に取り入れる際には、食事バランスを考慮することが重要である。

農林水産省は国民の健康増進を目的として、食生活指針 [1] を策定し、食生活を習慣的に見直すことの重要性を述べた。更に食生活指針を具体的な行動に結びつける為に、厚生労働省は食事バランスガイド [2] を策定した。しかし、内閣府の調査によると、2 人に 1 人は適切な食生活を送ることができておらず [3]、その理由は、(1) 何をどのように実行したらよいか分からない、(2) 忙しくて時間が無い、といったことが上位にあげられている [4]。

#### 1.2 課題

スマートフォンを利用して、食事の栄養バランスを管理する食生活支援サービスは多く存在するが [5]、ユーザが適切なアドバイスを得るためには、日々の食事に関する情報を、欠損なく継続的に記録することが望ましい。これまで提案された手法では、ユーザは食事の時間や、料理の種類といった食事内容の入力が必要であり、手間がかかるため継続的な利用における課題となっている。食事時間の認識は既に高精度の認識率 [6] が達成され、このような機能を有するウェアラブルデバイス [7] も実用化されている。

食事内容認識では、カメラで撮影した食事画像を用いる方法 [8] や摂食に伴う上肢動作を用いる方法 [9] などがあるが、前者は撮忘れやプライバシー問題がハードルとなり、後者は複数箇所にデバイスを着ける必要があり、広く消費者が活用することを考えると大きな阻害要因となる。

#### 1.3 目的

本研究は、ユーザに手間をかけさせず食事内容を継続的かつ自動で把握できる技術の実現をめざす。ここで食事内

<sup>1</sup> (株)NTT ドコモ, 先進技術研究所, 社会センシング研究グループ

<sup>2</sup> (株)NTT ドコモ, 先進技術研究所, 研究推進グループ

容の認識粒度は厚生労働省が策定した食事バランスガイド [2] に記載された料理品目の粒度を採用する。この粒度の食事内容を認識することで主食、主菜、副菜、牛乳・乳製品、果物の5つの料理グループに分けることができ、サービング数 (SV) と呼ばれる摂取量が求まる。この SV を推奨摂取量と比較し、各料理グループの過不足状態を求めることで食事管理に関するアドバイスを可能とする。

本研究では、摂食に伴う上肢動作のうち前腕動作のみを用いることで必要なウェアラブルデバイスを減らし、ユーザーに手間をかけさせず食事内容を継続的かつ自動で把握する技術の実現をめざした。リストバンド型の汎用的なウェアラブルデバイス 1 台を利き手の前腕に着用し、取得したセンサデータから食事内容の認識を行う手法を提案する。

## 2. 手法検討

### 2.1 関連研究

これまでに食事内容認識技術として、嚥下動作に伴う音を検知する咽喉付近に装着したスロートマイクや、咀嚼動作に伴う音を検知する耳に装着したイヤホン型マイクなどを用いた方法が提案されているが [9][10]、専用機器や特殊なセンサを利用しているため、広く消費者が活用することを考えると、普及の上で大きな課題がある。また、市販されているウェアラブルデバイスを利用した実践的な実験はあまり見られない。

Amft ら [9][10] は、上腕と前腕に合せて 4 つの加速度センサと角速度センサを装着し、これらセンサから取得した上肢動作データと、スロートマイク及びイヤホン型マイクを使って、食事で発生する一連動作 (食べ物を切るような準備動作や、口に運ぶ動作、咀嚼動作、嚥下動作) のサイクルから食事内容の認識を行っており、画像以外でも食事内容が認識できることを示している。Amft らは一連動作の発生を各センサで検出し、確率文脈自由文法を用いることで、食事内容毎に異なるサイクルを持つモデルを作成した。このモデルを用いた隠れマルコフモデル (HMM) による認識器で食事内容を認識している。この研究からも、食事で発生する動作の時系列的なサイクルが重要であることがいえる。しかし、広く消費者が活用するためには、スロートマイクやイヤホン型マイクの装着や、上肢に多くのセンサを装着する必要がある手法は避けたい。また、分類器に HMM を用いているが、この手法は時系列的に変化する状態の遷移モデルを構築する必要があり、その状態の定義と安定した状態検出が必要となる。Amft らは複数箇所に装着したウェアラブルデバイスのセンサによって、明確に定義が可能な摂食、咀嚼や嚥下といった状態を安定して検出している。しかし本研究では、複数のウェアラブルデバイスを装着するというサービス形態を想定しておらず、複数のウェアラブルデバイスの装着が前提となる HMM を用いた食事内容認識の手法では必要条件を満たせない。

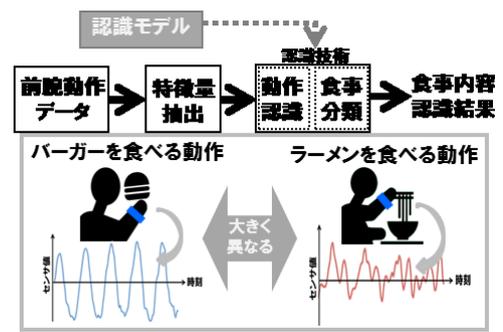


図 1: 提案手法の概要図

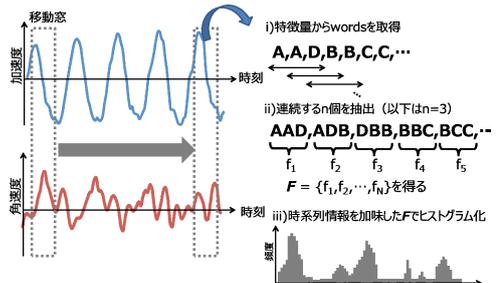


図 2: N-gram を用いた Bag-of-Words 表現

他方、人物の動作認識に関する研究では、状態の遷移ではなく状態の出現頻度に着目した手法があり、人物動作を高い精度で認識している [11]。この手法は、歩行や走行などの動作を複数の特徴的な動作の集合で表現できると考え、Bag-of-Words (BoW) 表現を適用している。これらの関連研究が示すように、食事の前腕動作を認識する際にも、BoW 表現が有効な可能性があると考えられる。そこで、本研究では BoW 表現を用いて前腕動作を特徴的な動作の組み合わせとして認識する方法を用いる。

### 2.2 提案手法

提案手法の概要を図 1 に示す。本研究は、摂食時の前腕動作が食事内容によって異なることに着目し、前腕動作の違いから食事内容を推定する。例えば、バーガーの摂食時は、口に運ぶ動作や噛みしめる箇所を変える動作が生じる。一方でラーメンの摂食時は、麺を持ち上げる動作や、麺を冷ます動作、吸る動作などが時系列的に生じる。これらの食事内容による動作の違いを、動作が発生する順序の時系列情報として加味し認識することで食事内容を推定する。

提案手法では、利き手の前腕にウェアラブルデバイスを着用し、摂食時の前腕動作に伴うセンサデータを取得する。本稿ではこのセンサデータを前腕動作データと呼ぶ。この前腕動作データから特徴量を抽出し、Naïve Bayes 分類器 (以下、NB 分類器) によって動作認識を行い、食事内容を推定する。利き手に装着するウェアラブルデバイスを市販のリストバンド型デバイス 1 台のみとすることで、既存手法に比べて必要となるデバイス数を減らし、ユーザーに手間をかけさせず食事内容を継続的かつ自動で把握する技術を実現する。前節で述べた既存手法では複数のウェアラブル

表 1: 検討対象及び採用した特徴量

インデックス	検討 (各軸のセンサ値)	採用
1~6	平均値	○(加速度センサ 3 軸)
7~12	標準偏差	○(加速度センサ 3 軸)
13~18	分散	○(加速度センサ 3 軸)
19~24	中央値	○(加速度センサ 3 軸)
25~29	絶対値の平均値	×
30~35	平均値の絶対値	×
36~41	平均値の絶対値の偏差	×
42~47	ゼロ交差点の数	×
48~53	ゼロ交差点間の平均時間幅	×
54	文献 [6] の特徴量 $f_{1,w}$	×
55	文献 [6] の特徴量 $f_{2,w}$	×
56	文献 [6] の特徴量 $f_{3,w}$	×
57	文献 [6] の特徴量 $f_{4,w}$	×

デバイスの着用が必須であり、1 台のウェアラブルデバイスで同様の手法を実現することは困難である。そこで、提案手法は利き手の前腕に着用する 1 台のウェアラブルデバイスを用いて食事内容推定を実現するために、摂食時の動作を細かな動作の集合として捉えて表現する BoW 表現を用いる。そして動作の発生順序によって時系列情報を考慮できる N-gram に拡張した。このようなアプローチによって、従来手法では難しかったウェアラブルデバイスの数を低減させた食事内容推定を実現する。

前腕動作データは加速度センサ及び角速度センサの各 3 軸の計 6 自由度として、この前腕動作データにガウシアンフィルタをかけることでノイズを抑える。その後、一定幅の移動窓内のセンサデータより特徴量を抽出する。特徴量の次元数を不必要に増加させると分類器の性能低下に繋がる。そこで本研究に用いる特徴量は、まず、移動窓内における平均、分散、標準偏差などの統計量や、ゼロ交差点の数やゼロ交差点間の時間幅、各センサの 3 軸成分の絶対値を全て加算したエネルギーなど合計 57 次元 (表 1) を検証対象とする。その上で、主成分分析の寄与率に基づく評価実験を行い、再度選定した加速度センサの統計量の 12 次元の特徴量を用いることとする。なお、57 次元の特徴量はイヤホン型及びリストバンド型デバイスを統合した食事内容認識技術 [12] や、リストバンド型デバイスのみを用いた食事時間認識技術 [6] で利用されている特徴量を参考にした。

摂食時の前腕動作に関しても、動作が発生する順番を考慮した認識手法が有効であると考えられる。そこで、選定した特徴量を BoW 表現によって複数の動作 (以下、要素動作と呼ぶ) の集合として表現する。その上で、要素動作が発生する順番を考慮して、複数の要素動作をまとめたもの (以下、一連要素動作と呼ぶ) の集合を考え、前腕動作データを一連要素動作が発生する頻度で表現し、NB 分類器に適用することで食事内容を推定する。図 2 に示すように、前腕動作データを要素動作の集合で表現したのち、N-gram に拡張することで、一連要素動作の集合を表すことができる。このとき要素動作は words として表現され、一連要素

表 2: 食事内容と食器具の対応

食事内容	食器具
丼もの (牛丼, かつ丼, 親子丼, 天丼, 海鮮丼)	箸
カレーライス	スプーン
パン類 (菓子パン, サンドウィッチ, ピザ, ハンバーガー)	素手
パスタ (スパゲティ)	フォーク
麺 (らーめん)	箸

動作は例えば、麺を啜る動作や丼ものを口に掻き込む動作が表現されることを想定している。また、口に運ぶ動作や咀嚼中に前腕を動かさない動作はあらゆる食事内容で発生し、これらの words は食事内容の推定に対して有効となり難い。そこで tf-idf (Term Frequency-Inverse Document Frequency) により頻出する words の重みを軽減し、食事内容ごとの特有な動作を強調する。摂食時には要素動作が繰り返し発生したり、交互に行われるが、HMM では 1 回の食事に含まれる状態遷移すべての連続性を考慮することに対して、NB 分類器を用いた動作の頻度に着目した本手法は局所的な連続性を捉えることが可能である。そのため、突発的に生じるノイズや食事内容で食べる順序が変わる場合でもロバスト性の向上が期待できる。

### 3. 実験及び精度評価

#### 3.1 実験条件

認識対象とする食事内容は、食事バランスガイドに記載があり、なおかつ高頻度に食べられている食事内容である表 2 に示す 5 種類とし、被験者が摂食時に利用する食器具を記載した。Android Wear を搭載するリストバンド型デバイス (Huawei Watch W1) によって前腕動作データとして加速度センサと角速度センサの値を取得する。本研究では以下の 2 つの条件で集めた前腕動作データを用いる。条件 (1) のデータは、摂食時の前腕動作に対する適切なデータ取得頻度の確認や特徴量の検討のために用いる。その上で、データ取得頻度を設定して条件 (2) のデータを収集し、条件 (2) のデータを用いた提案手法の精度評価を行う。

**条件 (1)** 摂食時の前腕動作を模した繰り返し動作を短時間行う

**条件 (2)** 摂食時の前腕動作を 1 食分行う

条件 (1) は図 3 に示す模擬実験であり、被験者は表 2 で示す各食事内容に対応する食器具を利き手に把持した状態で 10 秒間摂食動作を繰り返す。例えば、麺であれば箸を利き手に把持した状態で、麺を持ちあげ、後に啜るといった動作を繰り返す。被験者は 20~50 代の計 14 人 (男性 12 人、女性 2 人) とし、被験者の男性 12 人のうち 2 名は左利き、他の被験者は右利きであり被験者は自身の利き手の首にリストバンド型デバイスを装着する。実際に摂食する必要がないため、データ取得が容易であり食事内容ごとに同一の被験者で 10 回繰り返し取得した。条件 (2) の実験では表 2 で示す食事内容を実際に摂食した際の前腕動作として 1

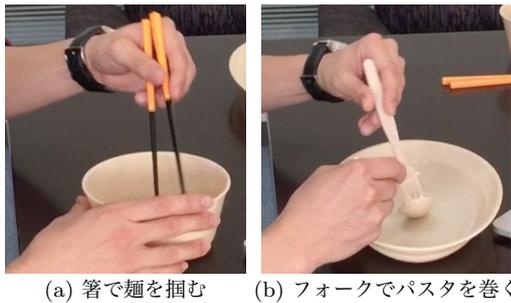


図 3: 条件 (1) による模擬実験: 被験者左利き

表 3: 前腕動作データの取得条件とデータ数内訳

食事内容 (食器具)	条件 (1)	条件 (2)
丼もの (箸)	140	29
カレーライス (スプーン)	140	32
パン類 (素手)	140	26
パスタ (フォーク)	140	27
麺 (箸)	140	33

食当たり約 7 分間取得したデータを用いる。被験者は 20～40 代の計 9 人 (男性 7 人, 女性 2 人) であり, 男性のうち 1 名が左利きで他の被験者は右利きである。以上の収集条件によって取得した前腕動作データの各食事内容におけるデータ数の内訳を表 3 に記載した。なお, Amft ら [9] の研究で用いられたデータ数を参考に, 条件 (2) の前腕動作データは食事内容 1 種類に対して約 30 食分をめざして収集を行ったが, 被験者の日常生活で指定の食事内容の前腕動作データを収集しているため, 被験者や食事内容によってデータ数に差がある。また, この前腕動作データは職場の食堂や自宅, レストランなどで取得しており, 同一の食事内容でも全く同じものを摂食したデータとは限らない。

### 3.2 模擬動作による予備実験

加速度センサや角速度センサを用いて, 歩行やランニングなどの動作を認識する場合は 100Hz 程度の周波数で計測されることが多い [11]。これらセンサデータの取得周波数は標本化定理に従って決定する必要がある。しかし Android Wear を搭載したリストバンド型デバイスのセンサ取得頻度は, Android が提供する API によって 100.0Hz 前後に制限されている [13]。また各センサの値に変動が生じた場合のみ API はセンサデータを返すため, 被験者の動きが小さい場合, 取得できる頻度は変動し, 必ずしも所望の頻度を満たさない。そのため, 市販のウェアラブルデバイスを用いて本手法を検証するためには, 食事内容における前腕動作の周波数を確認し, 市販のウェアラブルデバイスを用いた場合でも標本化定理を満たしたセンサデータを得る必要がある。そこで条件 (1) の模擬実験のデータを用いて加速度センサ及び角速度センサの取得頻度を確認したところ, 表 2 の食事内容に伴う動作は平均 50.0Hz でセンサ値取得が可能であることを確認した。

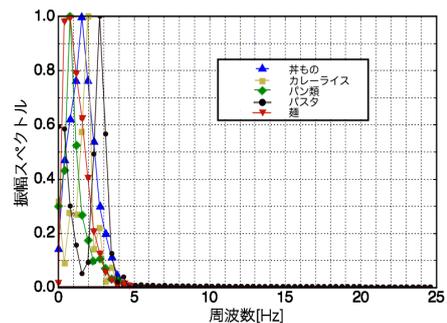


図 4: 条件 (1) による食事内容毎の振幅スペクトル

動作認識の研究ではセンサ取得頻度が 100Hz 程度であることが多いが, 身体が行う動作は 99% が 15Hz 未満であると言われている [14]。また, 実生活で手首に着用したウェアラブルデバイスから得られる食事動作の周波数は 0.2～0.6Hz であることが示されている [15]。ただし, ウェアラブルデバイスの着用条件や食事内容による前腕動作の周波数の違いに関しては不明なため, 本稿では前腕動作データに対して, 離散化フーリエ変換を実施することで, 食事内容ごとの前腕動作の周波数帯域を確認する。条件 (1) は摂食時の前腕動作を模しているため, 条件 (2) に比べると咀嚼や嚥下にかかる時間が短く, 前腕動作の速度が大きくなる傾向がある。そのため条件 (1) で摂食時の周波数の上限を把握し, 条件 (2) の取得頻度を定めることで標本化定理を満たした条件を設定できる。

条件 (1) において, 50.0Hz で前腕動作データを集め, ハミング窓を使用した離散化フーリエ変換によって振幅スペクトルを取得する。条件 (1) の前腕動作データは約 10 秒間であるためサンプリング点数  $N = 128$ , 窓の移動量はサンプリング点数に対して 50% と設定し振幅スペクトルを観測した。図 4 に, 同一被験者の食事内容ごとの加速度センサによる振幅スペクトルを示す。食事内容によって振幅スペクトルのピークとなる周波数に大きな違いはなく, 食事動作が含む周波数は 5.0Hz よりも低いことが分かる。同様の傾向が, 異なる被験者及び角速度センサの場合でも確認できていることから, 本研究では, 標本化定理を満たすため, 50.0Hz で取得した前腕動作データを 20.0Hz にサブサンプリングすることとした。その後, ノイズを低減させるため 1.0 秒分のサンプルを対象とした移動窓にガウシアンフィルタを適用する。窓の移動量は窓幅に対して 50% とする。

次に, 条件 (1) の前腕動作データを用いて特徴量を検討する。特徴量は加速度センサ及び角速度センサの各軸の値を用いて導出した表 1 の 57 次元に対して検討した。特徴量の検討にあたり, Incremental Principle Component Analysis(IPCA) 及び Radial Basis Function(RBF) をカーネル関数とした Kernel PCA を行うことで食事内容ごとにその特徴量の分離可能性を確認する。

まず, IPCA によって 57 次元の寄与率を確認し, 各特徴

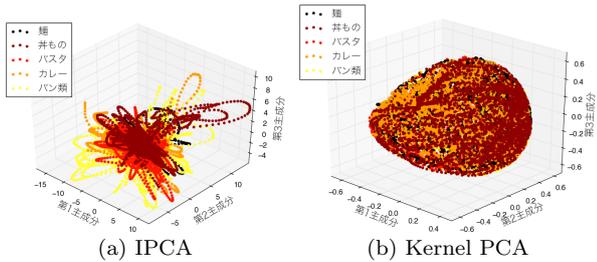


図 5: 特徴量 (12 次元) に対する PCA の結果

量の寄与率のうち最大値が40%を超えるまで寄与率の小さい特徴量を削減した。その後、表1に示す加速度センサの12次元の特徴量を用いた提案手法で利用することとした。この12次元の特徴量を用いて再度 IPCA と Kernel PCA を実施した結果を図5に示す。この結果から、特徴量のみを機械学習に適用した方法では分離できる可能性は低いことが伺える。

そこで、さらにこの特徴量に対して BoW 表現を適用する。BoW 表現は、抽出した特徴量をその特徴空間の中でクラスタリングすることで代表ベクトル (words) を収録した codebook を作る。codebook が含む全 words の数を Vocabulary と呼ぶことにする。本研究では、クラスタリング手法として広く用いられる k-means を利用して前述の特徴量を用いて words を作成する。文書分類に対して BoW 表現を適用する際は Vocabulary が膨大となることが多いが、動作認識に BoW 表現を適用した場合は比較的 Vocabulary を小さい値にすることが効果的であると示されている [11]。そこで条件 (1) の前腕動作データから抽出した特徴量に対して Vocabulary = 20 とした BoW 表現を適用し、食事内容ごとの words の分布を図6に示す。すべての食事内容において word ID=5, 7, 10 が頻出しており、これらは口に食べ物を運ぶ動作や咀嚼中に前腕を動かさない動作である可能性が高いと考えられる。

BoW 表現に対して、さらに連続して発生した  $N$  個の words に注目し N-gram を適用することで、麺を吸る動作やパスタをフォークで巻く動作のように時間幅を持つことで意味を成す動作の表現を試みる。N-gram を適用すると words の組み合わせが爆発的に増加するため、本研究では  $N = 3$  を採用する。この値は、20.0Hz でサブサンプリングした前腕動作データに対して1秒分の移動窓を0.5秒ずつ移動させるため、2秒分のサンプルを表現することになるため、麺を吸る動作やパスタをフォークに巻く動作などを継続する時間幅を考慮した。口に食べ物を運ぶ動作や咀嚼中に前腕を動かさない動作は全ての食事内容で発生するため、tf-idfにより頻出する words の重みを軽減し、食事内容ごとの特有な動作の強調する。

特徴量を N-gram に拡張した BoW 表現し、NB 分類器を用いて食事内容を推定する。NB 分類器は事前確率を設定する必要があり、本研究では条件 (2) の前腕動作データ

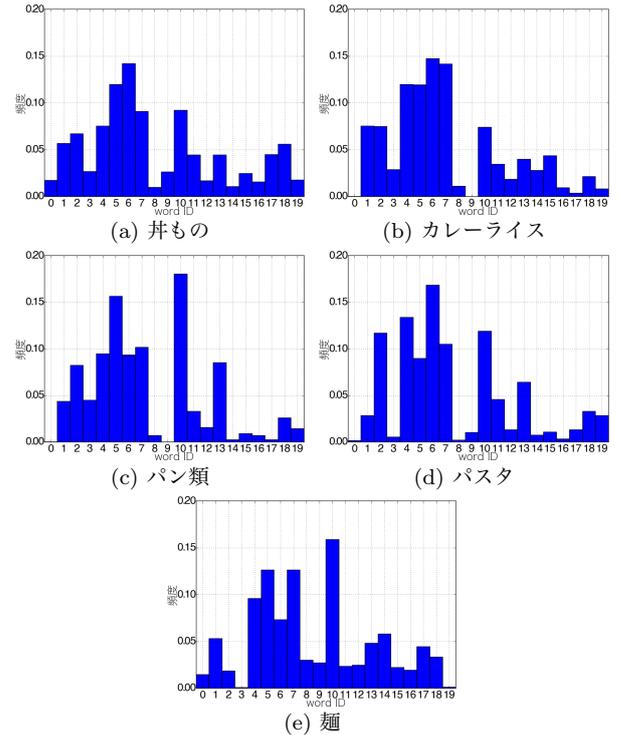


図 6: BoW 表現による食事内容ごとのヒストグラムの総数に対する食事内容ごとのデータ数の比とした。

### 3.3 摂食時の前腕動作データによる精度評価

本節では、条件 (2) の前腕動作データを用いて NB 分類器を学習し、その推定性能を測る。ただし条件 (2) の前腕動作データは機械学習の分類器の検証データとして少ないため、収集した条件 (2) の全ての前腕動作データの中から1食分のデータを評価用とし、残りのデータを学習用とする Leave-One-Out Cross Validation (LOOCV) による評価を行った。評価指標は分類器の精度評価指標として一般的な Recall, Precision の調和平均である F1 値及び、前腕動作データの総数に対する食事内容ごとの真陽性と真陰性の総数の比である正解率 Accuracy を用いる。

表4に LOOCV の混合行列を示す。この表は縦方向が前腕動作データが属する食事内容の真値であり、横方向が分類器の推定結果である。背景色が黒色に近いほど推定結果の中で占める割合が高いことを示している。混合行列から、特に麺類の推定結果が他の食事内容に比べて高いことが分かる。一方で、カレーライスはパスタや麺として誤って推定されることが多かった。これは、PCA の結果から寄与率の低い角速度センサの特徴量を削減していることで、手首の回転に関する特徴が反映され難かったことが原因と考えられる。具体的には、カレーライスを食べる際には、カレーのルーとライス寄せ集める動作の後、口に運ぶ動作が発生する。このとき、表1で採用した特徴量では口に運ぶ動作と同一視され、他の食事内容との区別が難しくなった可能性があり、事前確率が最も高い麺として誤推定する

表 4: 食事内容推定：混合行列

真値	推定結果				
	丼もの	カレー	パン類	パスタ	麺
丼もの	0.55	0.00	0.00	0.17	0.28
カレー	0.16	0.09	0.00	0.34	0.41
パン類	0.04	0.04	0.68	0.12	0.16
パスタ	0.19	0.04	0.04	0.62	0.08
麺	0.03	0.00	0.00	0.06	0.91

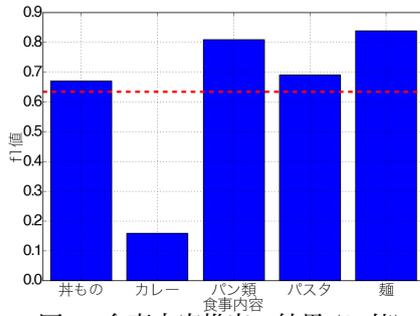


図 7: 食事内容推定の結果 (f1 値)

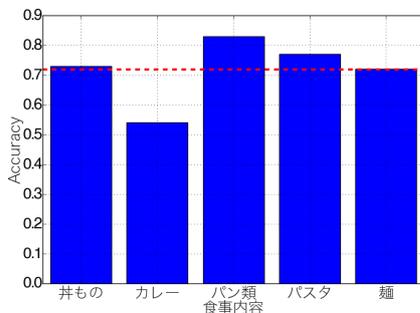


図 8: 食事内容推定の結果 (Accuracy)

ことが多くなったと考えられる。特に、条件 (1) の前腕動作データをヒストグラムにした図 6 の wordID= 5, 7 の頻度が他の食事内容に比べて多くなっていることが分かる。

食事内容推定の結果として、図 7 に f1 値、図 8 に Accuracy を示す。食事内容に対する f1 値の平均値は 63% で、Accuracy の平均値は 70% となった。カレーライスは Precision, Recall とともに著しく低いため、f1 値及び Accuracy の両方で最も推定精度が低いが、その他の食事内容は f1 値で 65% 以上、Accuracy は 70% 以上を保っており、食事の種類をある程度限定できる状況では前腕動作データによって食事内容推定が可能であることが示された。

#### 4. 結言

ユーザーに手間をかけさせずに食事内容を継続的かつ自動で把握する技術の実現をめざし、前腕動作に着目した食事内容の推定手法を検討した。認識精度は本実験条件において、f1 値で平均 63%、Accuracy は平均 70% を達成した。これは市販のリストバンド型ウェアラブルデバイス 1 台で、食事の種類をある程度限定した状況では食事内容推定が可能であることを示した。課題として、本実験では対象とした食事内容の種類は少なく、今後は更なる対象数拡大と精度向上が必要である。本研究では特徴量として、一般

的な統計量を採用したが、一部の食事内容の推定精度が低いことから、前腕動作をより詳細に表現出来る特徴量が必要といえる。また、同一の食事内容では、被験者間の前腕動作に違いがあることを確認しており、今後の精度向上には個人毎に認識モデルや特徴量の調整を行うことが有効であると考えられる。

#### 参考文献

- [1] 農林水産省:食生活指針, 入手先 (<http://www.maff.go.jp/j/syokuiku/shishinn.html>)(参照 2017-04-20)
- [2] 厚生労働省:食事バランスガイド, 入手先 (<http://www.mhlw.go.jp/bunya/kenkou/eiyou-syokuji.html>)(参照 2017-04-20)
- [3] 内閣府:食育に関する意識調査(平成 28 年), 入手先 (<http://www.maff.go.jp/j/syokuiku/ishiki/h28/>)(参照 2017-04-20)
- [4] 厚生労働省:平成 26 年度版厚生労働白書, 入手先 (<http://www.mhlw.go.jp/wp/hakusyo/kousei/14/>)(参照 2017-04-20)
- [5] 株式会社 NTT ドコモ:d ヘルスケアパック, 入手先 (<https://www.nttdocomo.co.jp/service/dmarket/health-care/>)(参照 2017-04-20)
- [6] Dong, Y., Scisco, J., Wilson, M., et al.: Detecting Periods of Eating During Free-Living by Tracking Wrist Motion, *Proc. IEEE Journal of Biomedical and Health Informatics*, Vol.18, No.4, pp.1253-1260(2013).
- [7] TDK 株式会社, 入手先 ([https://product.tdk.com/info/ja/products/biosensor/biosensor/silmee\\_w20/index.html](https://product.tdk.com/info/ja/products/biosensor/biosensor/silmee_w20/index.html))(参照 2017-04-20)
- [8] Aizawa, K., Maruyama, Y., He Li, et al.: Food Balance Estimation by Using Personal Dietary Tendencies in a Multimedia Food Log, *Proc. IEEE Transaction on Multimedia*, Vol.15, No.8, pp.2176-2185(2013).
- [9] Amft, O., Kusserow, M. and Tröster, G.: Probabilistic parsing of dietary activity events, *Proc. International Workshop on Wearable and Implantable Body Sensor Networks*, Vol.13, pp.242-247(2007).
- [10] Amft, O. and Tröster, G.: On-Body Sensing Solutions for Automatic Dietary Monitoring, *Proc. IEEE Pervasive Computing* Vol.8, No.2, pp.62-70(2009).
- [11] Zhang, M. and Sawchuk, A.A.: Motion Primitive-based Human Activity Recognition Using a Bag-of-features Approach, *Proc. of the 2nd ACM SIGHIT International Health Informatics Symposium*, pp.631-640(2012).
- [12] Mirtchouk, M., Merck, C. and Kleinberg, S.: Automated Estimation of Food Type and Amount Consumed from Body-worn Audio and Motion Sensors, *Proc. of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp.451-462(2016).
- [13] Laput, G., Xiao, R. and Harrison, C.: ViBand: High-Fidelity Bio-Acoustic Sensing Using Commodity Smartwatch Accelerometers, *Proc. of the 29th Annual ACM Symposium on User Interface Software and Technology*, pp.321-333(2016).
- [14] Karantonis, D.M., Narayanan, M.R., Mathie, M., et al.: Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring, *Proc. IEEE Transactions on Information Technology un Biomedicine*, Vol.10, No.1, pp.156-167(2006).
- [15] 矢野和男, 栗山裕之:「人間×センサ」センサ情報が変わる人・組織・社会, 日立評論, Vol.89 No.07, pp.572-573(2007)