

# 行動認識用加速度データの サンプリング周波数推定手法の提案

梶原大暉<sup>1</sup> 村尾和哉<sup>1,2</sup>

**概要：**本研究では、3軸加速度センサの時系列データのみからサンプリング周波数を推定する手法を提案する。3軸加速度の合成値計算、標準化、動作区間抽出を行い、事前にデータとサンプリング周波数のペアを学習した回帰モデルを構築し、サンプリング周波数が未知の加速度センサデータを入力としてサンプリング周波数を推定する。行動認識分野で公開されている複数のデータセットを用いて、ドメイン、ユーザ、行動の種類が同種・異種の条件を変えて評価を行う。3軸加速度の合成値計算、標準化、動作区間抽出を行い、事前にデータとサンプリング周波数のペアを学習した回帰モデルを構築し、サンプリング周波数が未知の加速度センサデータを入力としてサンプリング周波数の推定を行った。同一データセット、行動ラベル既知の場合の推定誤差は14.6%~24.6%、異種データセット、行動ラベル未知の場合の推定誤差は、2つのデータセットで検証し2.2%と6.1%であった。今後は、ダウンサンプリングやアップサンプリングをより多く行い、サンプリング周波数の種類を増やすことで、広範囲のサンプリング周波数を学習する手法を検討する。

## 1. はじめに

スマートフォンやウェアラブルデバイスから収集された加速度センサデータは、人間行動認識、移動手段認識、歩数計測、活動量計測、睡眠状態推定、測位、個人認証、医療、スポーツ、エンタテインメント、などさまざまな分野に応用されている。このような応用の基盤として、フィルタリング、特徴量抽出、機械学習などのセンサデータ処理技術が存在するが、これらの処理技術を適用するには入力される加速度センサデータの取得状況に関する情報が必要である。一般的に、取得状況として、センサに関する情報、ユーザに関する情報、環境に関する情報がある。センサに関する情報として、センサの型番（およびセンサのデータシートから得られる情報）、センサ取得レンジ、単位 ( $G$  か  $m/s^2$ )、サンプリング周波数、センサ装着向き、センサ装着方法、センサ装着場所などがある。ユーザに関する情報として、年齢、性別、国籍、身長、体重、履物などがある。環境に関する情報として、日時、場所、屋内屋外、路面状況、天候、乗り物などがある。

センサデータを処理するシステムを構築する際、ユーザ本人のセンサデータからパラメータ設定やモデル構築を行うと高い性能が得られることが知られており、汎用性の観

点から評価実験ではユーザ本人のデータは使用しない条件設定も必要であり、leave-one-subject-out (LOSO) 方式でトレーニングデータとテストデータが用意される。そのため、テストデータのユーザに関する情報は未知とする想定が一般的である。また、環境に関する情報は、通常は構築したシステムが利用される環境や場所を想定しており、場所、屋内屋外、路面状況に関しては既知（データセット内で条件を統一する）ことが一般的である。一方、日時、天候に関しては未知（考慮しない）とする想定が一般的である。ただし、乗り物に関しては、場所と似ているが、特定の乗り物においてデータが得られる環境のみを想定しているのであれば乗り物に関する情報は既知（統一されている）であるが、行動認識や移動手段認識ではデータから乗り物を推定することが目的の問題設定の場合は乗り物に関する情報は未知である。このように、環境およびユーザに関する情報は一般的には未知である想定である。

これに対して、センサに関する情報として、センサの型番はそもそもスマートフォンによって搭載されているセンサが異なるため、（多くの研究では同じセンサを使用しているが）実環境では未知という想定である。センサ取得レンジは  $\pm 8G$  などの表記がされているセンサの出力幅であるが、実環境では未知でという想定である。単位に関しては既知である研究が多いと思われるが、静止時の加速度は重力加速度であるため、静止時の3軸合成加速度を  $1G$  と

<sup>1</sup> 立命館大学大学院情報理工学研究科

<sup>2</sup> 科学技術振興機構さきかけ

して補正できるため、未知であっても問題ない。センサ装着向きに関しては既知である研究と未知である研究に分かれるが、既知である研究では3軸の値を独立して処理する方式をとっている。未知の場合は3軸の合成値に変換すればセンサの向きに関する情報は失われるため問題ない。センサ装着方法とはポケットに入れるか、ゴムバンドで止めるかなどであるが、これは考慮していない場合が多い。センサ装着位置に関しては数多くの研究がなされている。トレーニングデータに使用するセンサの装着位置とテストデータに使用するセンサの装着位置は同じでなければ性能が大幅に低下することが報告されており、一般的には装着位置は既知であることが多い。一方で、実際は端末の装着位置の自由度は高いため、センサ装着位置を推定する研究やセンサ装着位置ずれによるセンサ値のずれを補正する研究が行われている。

このように、既知である必要がある情報に関しては、これらの情報を推定する研究がおこなわれていたり、容易に推定可能であるが、サンプリング周波数に関してはメタデータとして明示的に与えるか、タイムスタンプから推定する以外の手段がなく、そのほかの情報をを用いて推定する手法も提案されていない。サンプリング周波数は1秒間に取得されるデータのサンプル数であり1秒間に60サンプル取得されるならばサンプリング周波数は60Hzと表記される。そのため、移動平均フィルタを適用するならば平均を算出する区間を何サンプル（何秒）と決定するためにサンプリング周波数の情報が必要である。不適切な区間長を設定すると平滑化しすぎて波形の特徴が消えたり、ノイズの除去が不十分であることにつながる。このほか、行動認識では平均や分散、FFTなどの特徴量算出を一定区間から切り出したセンサデータ列をもとに行うが、このときの切り出す長さ（ウィンドウサイズ）もサンプリング周波数の情報が必要である。例えば、歩行動作中のセンサデータから特徴量を抽出する場合、一般的には行動の1周期より長い数秒から数十秒のウィンドウサイズを設定し、少なくとも1周期全体の波形がウィンドウに含まれるようにする必要がある。実際にトレーニングデータとテストデータのサンプリング周波数が異なる場合の行動認識精度の変化を調査した研究があり、精度は低下することが報告されている。

ここで、サンプリング周波数は不明である状況が実際に発生し得るのかについて考える。センサデータが保存されているファイルの各行にタイムスタンプが正確かつ十分な粒度で記録されている場合はタイムスタンプの間隔の逆数から求めるか、サンプル数を経過時間で割ることで求まる。また、メタデータとして、明示的にサンプリング周波数が与えられることも考えられる。しかしながら、本研究では以下の場合、サンプリング周波数が不明であると考えられる。

- タイムスタンプが無く、メタデータも無い。
- タイムスタンプのフォーマットが不明。

- タイムスタンプの粒度が粗く、サンプリング周波数を計算できない。
- リアルタイムでデータを受信している状況だが、値しか来ず、通信経路上でバッファリングされたり、遅延が生じている可能性があるため、受信時刻から単純にサンプリング周波数を計算できない。

また、タイムスタンプやメタデータからサンプリング周波数を知ることができたとしても以下の問題がある。

- サンプリング周波数が一定でない（タイムスタンプが無く、メタデータにサンプリング周波数が明記されているが瞬間最高周波数、理論上の値、偽の値などである）場合。
- 悪意をもった者がタイムスタンプを偽装してシステムを攻撃する場合。

本研究では、3軸加速度センサの時系列データのみからサンプリング周波数を推定する手法を提案する。3軸加速度の合成値計算、標準化、動作区間抽出を行い、事前にデータとサンプリング周波数のペアを学習した回帰モデルを構築し、サンプリング周波数が未知の加速度センサデータを入力としてサンプリング周波数を推定する。行動認識分野で公開されている複数のデータセットを用いて、ドメイン、ユーザ、行動の種類が同種・異種の条件を変えて評価を行う。提案手法は、ユーザが動いている区間を含む3軸加速度データのみを与えるだけで、そのデータのサンプリング周波数を高精度で推定する、極めて汎用的な手法である。センサの向き、装着方法、センサ取得レンジ、単位に非依存な手法であり、既知の情報は提案手法に与えるデータが加速度データであるということだけである。

## 2. 関連研究

本章では加速度センサや角速度センサなどの慣性センサを用いた人間行動認識において、サンプリング周波数の観点から関連する研究および加速度センサ以外の信号の周波数を推定する手法を紹介する。

### 2.1 サンプリング周波数が既知かつ固定の人間行動認識手法

Muraoら[1]は、9個の加速度センサと9個の角速度センサをタブレット端末を想定した盤面上に格子状に配置し、27種類のジェスチャの認識を行い、センサ数やセンサの位置を変更することで認識精度の変化を調査している。盤面の保持位置から遠い加速度センサは有効であり、またジェスチャ動作の軸との交点にジャイロセンサを配置することが有効であると示している。また、分類するジェスチャの数が増えると、認識精度が低下することを示している。Agrawalら[2]は、加速度センサが内蔵されている携帯電話をペンのように持ち、加速度データを文字の軌跡に変換することで、空中に描かれたアルファベットを認識

している。Junkera ら [3] は、「ボタンを押す」、「握手をする」、「受話器を取る」などの日常で行われる 10 種類の動作を、右腕上腕と右腕前腕に慣性センサを装着し、HMM を用いて認識している。Liu ら [4] は、直線や四角形などの 8 種類の図形を描くジェスチャを、加速度センサを用いて認識している。日々のジェスチャ動作の変化に対応するために、4000 試行以上のデータを 1 か月かけて採取している。認識精度は 98.6% を示している。吉田ら [5] は、ジェスチャの加速度データを 7 日分集めることで、ユーザの疲労やジェスチャフォームの忘却がジェスチャ認識に与える影響を調査している。また、リアルタイムで DTW 距離の平均と分散を求めることで、ユーザの状態を考慮した適切な学習データ位置探索手法を提案している。

## 2.2 サンプリング周波数を制御する手法

中島ら [6] は、加速度センサのサンプリング周波数を制御することで、行動認識システムの消費電力を低減させる手法を提案している。また、サンプリング周波数の低下によって生じる欠損データを補完することでサンプリング周波数を一定に保っている。

## 2.3 サンプリング周波数の違いによる認識性能の変化

田淵ら [7] は、センサの装着位置と個数、サンプリング周波数を変化させたときの、日常行動の識別性能の変化を調査している。日常行動を識別するには 12.5Hz 以上のサンプリング周波数が必要であることが確認されている。

## 2.4 サンプリング周波数の違いに依存しない認識手法

長谷川ら [11] は、サンプリング周波数が混在するデータセットに対して、行動認識を行うモデルとサンプリング周波数の分別を行うモデルに分岐し、それぞれが敵対的学習を行うことで、あらゆる周波数に対応した行動認識モデルを提案している。

## 2.5 人間行動加速度データセット

人間行動用加速度データセットの中には、OPPORTUNITY[8] や UniMiB-SHAR[9] のようにデータセット内で統一のサンプリング周波数 (30Hz, 50Hz) で計測されているデータや、HASC[10] のようにサンプリング周波数やセンサデータ収集デバイスが混在しているデータセットもある。

このように、これまでに行われている研究はサンプリング周波数が既知であることが前提であるため、サンプリング周波数が未知の場合、推定する必要がある。

# 3. 提案手法

## 3.1 概要

本研究ではセンサデータの種類として加速度センサを対

象とし、センサ値のみがファイルに一旦格納されたあとにオフラインで処理する環境を想定する。オンライン (リアルタイム) でセンサデータを取得する場合、取得するタイミングからサンプリング周波数を推定できると考えられるためである。しかし、オンラインの場合でも通信経路上でバッファリングされたり、遅延が生じたり、悪意を持った送信者が意図的に送信タイミングを制御している可能性があり、そのような場合にも受信したセンサ値の系列のみから周波数を推定する提案手法は有効であると考えられる。

提案手法は周波数が未知のセンサデータが保存されたファイルから 3 軸加速度値のみを読み込む。タイムスタンプやサンプリング間隔など時間に関する情報は使用しない。また、加速度センサの装着者の行動 (行動認識における正解ラベル) も使用しない。ただし、評価実験では装着者の行動が既知の場合と未知の場合の両方の条件で評価する。このほか、センサの型番、装着位置、装着向き、単位、センサ取得レンジ、履物、個人の属性 (性別、年齢、身長、体重など) ใดかなる情報も使用せず、3 軸加速度値の列のみからサンプリング周波数を推定する。

提案手法は 3 軸加速度値を読み込んだ後、データの事前処理として静止区間除去、3 軸加速度合成、標準化、ウィンドウイングを行い、固定長の加速度センサの部分系列を得る。そして、部分系列をパワースペクトルに変換する。事前にサンプリング周波数が既知の加速度センサデータから上記の前処理を行ってパワースペクトルを取得し、サンプリング周波数の目的変数としてニューラルネットワークの回帰モデルを学習する。その後、サンプリング周波数が未知の加速度データからパワースペクトルを取得し、学習済みネットワークに入力してサンプリング周波数の推定値を得る。

## 3.2 前処理

### 3.2.1 静止区間除去

はじめに、センサデータが保存されているファイルから  $x$  軸、 $y$  軸、 $z$  軸の加速度データ  $a_x$ ,  $a_y$ ,  $a_z$  を読み込み、静止している区間を除去する。静止している区間の合成加速度はサンプリング周波数に関わらず値が重力加速度の一定値になり、周波数の推定には不要であるため、静止区間のデータを除去する。具体的には、読み込まれた加速度データの長さが  $N$  サンプルであるとき、 $x$  軸  $a_x$  の  $N$  サンプルすべての二乗和平方根  $m_x = \frac{1}{N} \times \sqrt{a_{x1}^2 + a_{x2}^2 + a_{x3}^2 + \dots + a_{xN}^2}$  を求める。同様に加速度  $a_y$ ,  $a_z$  から  $m_y$ ,  $m_z$  を得る。ここで、十分に長い加速度データ全体の平均をみると重力加速度に近い値になるという仮定を置いており、 $m_x$ ,  $m_y$ ,  $m_z$  から、重力加速度の推定値  $m = \sqrt{m_x^2 + m_y^2 + m_z^2}$  を求める。

そして、各時刻の合成加速度  $a = \sqrt{a_x^2 + a_y^2 + a_z^2}$  の値が重力加速度に対して  $\pm 1G$  以内の時、静止区間と判断

する。ウィンドウサイズを 512 サンプルとしオーバーラップ無しでウィンドウをずらしていき、ウィンドウ内のすべての合成加速度  $a$  が  $|a - m| < m$  を満たすとき、そのウィンドウの区間の加速度データをすべて除去する。

### 3.2.2 3 軸加速度合成と標準化

静止区間が除去された 3 軸の加速度  $a_{xrem}$ ,  $a_{yrem}$ ,  $a_{zrem}$  から  $a_{rem} = \sqrt{a_{xrem}^2 + a_{yrem}^2 + a_{zrem}^2}$  を得る。さらに、 $a_{rem}$  を  $m$  で割ることで、重力加速度が 1 になるように標準化を行う。 $a_{rem}$  をウィンドウサイズ 512 サンプルとしオーバーラップ無しでデータを分割する。

### 3.2.3 パワースペクトル

分割されたデータに対して、高速フーリエ変換を行いパワースペクトルを得る。高速フーリエ変換は離散フーリエ変換を計算機で高速に計算するためのアルゴリズムであり、離散フーリエ変換は波形の周波数特性の解析に用いられるアルゴリズムである。512 サンプルのウィンドウから特徴量を抽出する。高速フーリエ変換後の波形は中央を軸として左右対称となるため、出力の次元数の半分の 256 次元のデータを特徴量として用いる。

### 3.3 回帰

説明変数を加速度のパワースペクトル、目的変数をサンプリング周波数としてニューラルネットワークを作成する。作成したニューラルネットワークを図 1 に示す。入力の次元数は [1, 256] である。本研究で作成したネットワークは畳み込み層が 13 層、プーリング層が 5 層、全結合層が 2 層のニューラルネットワークである。畳み込み層のカーネルサイズは 32 が 2 つ、64 が 2 つ、128 が 3 つ、256 が 6 つである。全結合層の隠れ層の数は 1024 であり、出力層には torch.nn のライブラリの中にある nn.hardtanh を用いる nn.hardtanh は、任意の引数  $A$ ,  $B$  ( $A > B$ ) を設定し、入力の値  $X$  に対して以下のような値を返す。

$$f(X) = \begin{cases} A & \text{if } X > A \\ B & \text{if } X < B \\ X & \text{otherwise} \end{cases} \quad (1)$$

ニューラルネットワークが予測する周波数の範囲であり、 $A$  が最大値、 $B$  が最小値を意味する。本研究では、 $A = 1000$ ,  $B = 0$  と設定した。また、損失関数には平均絶対誤差を用いる。学習時は Adam (Adaptive Moment Estimation) を用いてパラメータを更新する。

## 4. 評価

本章では提案手法の有効性を評価するために行った実験について述べる。

### 4.1 データセット

本研究では 2 つのデータセットを使用した。使用した

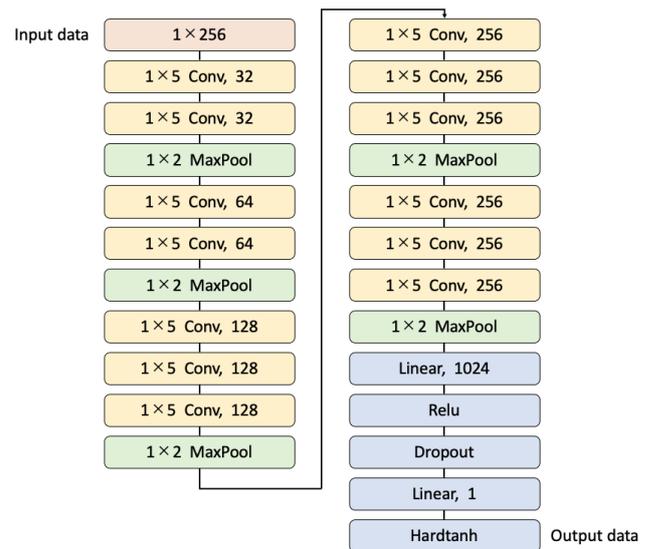


図 1 作成したニューラルネットワークの構造

データセットは HASC コーパスと OPPORTUNITY である。いずれも人間行動認識用のデータセットで、ユーザの体に加速度、角速度、地磁気などのセンサを装着または所持した状態で日常行動を行ったときのデータである。

#### 4.1.1 HASC コーパス

HASC コーパス [10] は、stay (静止), walk (歩く), jog (走る), skip (スキップ), stUp (階段を上る), stDown (階段を下る) の 6 種類の行動および、sequence と呼ばれる 6 種類の行動を連続して行ったときのデータ、realworld と呼ばれる行動の種類の制約無しに被験者が自由に行動した時のデータの 8 種類のフォルダが存在する。HASC コーパスは 2010 年版, 2011 年版, 2012 年版, 2013 年版, 2014 年版が存在するが、今回は 2014 年版を使用した。8 種類のフォルダの下には被験者ごとにデータがフォルダ分けされている。データはスマートフォンやウェアラブルセンサなどのさまざまなデバイスで収集されており、デバイスの装着位置は腕, 手首, 胸ポケット, 尻ポケットなどさまざまなである。また、被験者ごとにサンプリング周波数は異なる。表 1 に 8 種類の行動ごとの被験者数と最大サンプリング周波数と最小サンプリング周波数を示す。被験者数は、6 種類の行動はすべて 61 名, sequence が 60 名, realworld が 14 名であった。最小サンプリング周波数は、walk が 46.9Hz, jog が 47.3Hz, realworld が 20Hz で、それ以外の行動は 50Hz であった。最大サンプリング周波数は、realworld が 100Hz, stay と walk が 330Hz, それ以外の行動は 333Hz であった。

#### 4.1.2 OPPORTUNITY

OPPORTUNITY [8] は、被験者の体, 部屋のドア, 食器などに加速度センサなどを装着して、日常行動およびシナリオに沿った行動を行ったときのデータである。23 種類の物体に対して 13 種類の動きのラベル, 人に対して 17 種類

表 1 HASC コーパスの被験者数, 最小サンプリング周波数, 最大サンプリング周波数

	stay	walk	jog	skip	stUp	stDown	sequence	realworld
Number of subjects	61	61	61	61	61	61	60	14
Min sampling frequency[Hz]	50	46.9	47.3	50	50	50	50	20
Max sampling frequency[Hz]	333	333	330	330	330	330	330	100

のジェスチャのラベル, 5種類の状況のラベルが付与されている。被験者は4名で被験者ごとにフォルダが分かれており, サンプリング周波数はすべて30Hzである。

## 4.2 評価環境

評価で使用するデータセットを

$$[C \times U \times A \times N_{session} \times N_{segment} \times N_{sequence} \times N_{channel}] (2)$$

と表現する。ただし, 変数は以下の通りである。

- $C$ : データセット  
データセットの種類を指す。
- $U$ : 被験者  
被験者 ID を指す。データセットごとに被験者は異なる。
- $A$ : 行動  
行動認識における正解ラベル群を指す。データセットごとに行動は異なる。
- $N_{session}$ : 試行  
1人の被験者が1つの行動に対するデータの採取回数を指す。一般的にはデータが格納されているファイル数を指す。
- $N_{segment}$ : セグメント  
1回のデータ採取(ファイル)を一定の長さに分割した部分時系列データを指す。ひとつのファイルは複数のセグメントに分割される。
- $N_{sequence}$ : センサデータシーケンス  
1つのセグメントに含まれるセンサ値(ベクトル)を指す。入力チャンネル数の次元を持ち, 3軸加速度センサの場合センサ値は3次元である。
- $N_{channel}$ : チャンネル  
1つのセンサ値に含まれるセンサ値(スカラー)を指す。

評価実験は, 3種類の条件(実験1~3)で実施した。実験1は同一データセット, 行動ラベル既知の場合, 実験2は同一データセット, 行動ラベル未知の場合, 実験3は異種データセット, 行動未知の場合である。実験1はHASC コーパスのみを使用し, 実験2, 実験3ではHASC コーパスと OPPORTUNITY を使用した。また, オリジナルのデータセットに含まれるデータのサンプリング周波数だけではバリエーションが少ないため, もとの周波数の1/2倍と1/3倍にダウンサンプリングを行い, サンプリング周波数の種類を増やした。

評価指標は, 予測結果の周波数を  $P$ , 正解の周波数を  $T$  とすると, 予測誤差  $E = (|P - T|/T) \times 100$  とした。  $E$  の

表 2 同一データセット, 行動ラベル既知の場合(実験1)の推定誤差

	walk	jog	skip	stUp	stDown	sequence
error	14.6%	20.3%	24.6%	15.9%	22.8%	22.1%

表 3 同一データセット, 行動ラベル未知の場合(実験2)の推定誤差

	HASC	OPPORTUNITY
error	2.2%	6.1%

値が小さければ, 推定結果の周波数と正解結果の周波数の誤差が少なく, 正しく推定できていることを意味する。実験1と実験2のHASCは被験者を3分割にし, 1つをテストデータ, 残りの2つを学習データとし, テストデータと学習データの組み合わせを変える3-fold交差検証を行った。実験2のOPPORTUNITYは, 被験者を4分割にし, 1つをテストデータ, 残りの3つを学習データとし, テストデータと学習データの組み合わせを変える4-fold交差検証を行った。実験3では, HASCのrealworldを学習データ, OPPORTUNITYをテストデータにした場合, OPPORTUNITYを学習データ, HASCのrealworldをテストデータにした場合, HASCのrealworldとsequenceを学習データ, OPPORTUNITYをテストデータにした場合の3種類で評価を行った。いずれの実験も学習時のバッチサイズは2000, エポック数20000とした。

## 4.3 結果

### 4.3.1 実験1: 同一データセット, 行動ラベル既知

表2に同一データセット, 行動ラベル既知の場合の推定誤差を示す。walkの推定誤差が14.6%と最も小さく, skipの推定誤差が24.6%と最も大きかった。また, sequenceは, 複数の行動が含まれているデータであるが, 単一の行動しか含まれていないデータと推定誤差はあまり変わらなかった。

### 4.3.2 実験2: 同一データセット, 行動ラベル未知

表3に同一データセット, 行動ラベル未知の場合の推定誤差を示す。HASCの推定誤差は2.2%と, 実験1の結果よりも推定誤差が小さかった。また, OPPORTUNITYの推定誤差は6.1%であり, どちらのデータセットも実験1より推定誤差は小さかった。

### 4.3.3 実験3: 異種データセット, 行動ラベル未知

表4に異種データセット, 行動ラベル未知の場合の推定誤差を示す。学習データがHASCのrealworld, テストデータがOPPORTUNITYの時, 推定誤差は321.5%であ

表 4 異種データセット, 行動ラベル未知の場合 (実験 3) の推定誤差

	Train:real Test:opp	Train:opp Test:real	Train:real+seq Test:opp
error	321.5	48.5	65.1

り, 実験 1, 実験 2 と比べて誤差が大きかった. 学習データが OPPORTUNITY, テストデータが HASC の realworld の場合, 推定誤差は 48.5%であり, この結果も実験 1, 実験 2 に比べて誤差が大きかった. 学習データが HASC の realworld と sequence, テストデータが OPPORTUNITY の時, 推定誤差は 65.1%であり, この結果も実験 1, 2 に比べて認識誤差は大きかったが, 学習データを HASC の realworld だけではなく sequence のデータを加えることで, 推定誤差が小さくなり, 推定精度が改善されていることが分かった.

#### 4.4 考察

本研究では 3 つの実験を行ったが, 異種データセット, 行動ラベル未知の場合の推定結果が最も悪かった. これは, 学習データに用いた, サンプル周波数の種類が少ないからだと考えられる. 学習データに用いた HASC の realworld のサンプル周波数を確認すると, 100Hz, 50Hz, 33.3Hz の 3 種類だった. しかし, テストデータの OPPORTUNITY のサンプル周波数は, 30Hz, 15Hz, 10Hz と, 学習データに用いたサンプル周波数の範囲外であったため, 上手く推定できなかつたと考えられる. 同じ理由で, 学習データに OPPORTUNITY, テストデータに HASC の realworld を用いた場合も上手く推定できなかつたと考えられる. 解決策として, ダウンサンプリングやアップサンプリングをより多く行い, サンプル周波数の種類を増やすことで, 広範囲のサンプル周波数を学習することができ, 推定精度が改善できると考えている.

### 5. おわりに

本研究では, 3 軸加速度センサの時系列データのみから サンプル周波数を推定する手法を提案した. 3 軸加速度の合成値計算, 標準化, 動作区間抽出を行い, 事前にデータとサンプル周波数のペアを学習した回帰モデルを構築し, サンプル周波数が未知の加速度センサデータを入力としてサンプル周波数の推定を行った. 同一データセット, 行動ラベル既知の場合の推定誤差は 14.6%~24.6%, 異種データセット, 行動ラベル未知の場合の推定誤差は, 2 つのデータセットで検証し 2.2%と 6.1%であった.

今後は, ダウンサンプリングやアップサンプリングをより多く行い, サンプル周波数の種類を増やすことで, 広範囲のサンプル周波数を学習する手法を検討する.

**謝辞** 本研究は, 科学技術振興機構戦略的創造研究推進事業さきがけ (JPMJPR1937) の支援を受けたものである.

ここに記して謝意を表す.

#### 参考文献

- [1] K. Murao, T. Terada, A. Yano, and R. Matsukura, "Evaluating Gesture Recognition by Multiple-Sensor-Containing Mobile Devices," in Proceedings of International Symposium on Wearable Computers (ISWC 2011), PP. 55–58 (2011).
- [2] S. Agrawal, I. Constandache, S. Gaonkar, R. Choudhury, K. Caves, and F. DeRuyter, "Using Mobile Phones to Write in Air," in Proceedings of the International Conference on Mobile Systems, Applications, and Services (Mobisys 2011), PP. 15–28 (2011).
- [3] H. Junkera, O. Amfta, P. Lukowiczb, and G. Tröstera, "Gesture Spotting with Body-worn Inertial Sensors to Detect User Activities," Pattern Recognition, pp. 2010–2024 (2008).
- [4] J. Liu, L. Zhonga, J. Wickramasuriya, and V. Vasudevanb, "uWave: Accelerometer-based Personalized Gesture Recognition and its Applications," in Proceedings of the IEEE International Conference on Pervasive Computing and Communication (PerCom 2009), pp. 1–9 (2009).
- [5] 吉田 楽, 村尾和哉, 寺田 努, 塚本昌彦, "加速度センサを用いたジェスチャ認識に疲労および忘却が与える影響の評価," 情報処理学会研究報告 (ユビキタスコンピューティングシステム), Vol. 2012-UBI-33, No. 20, pp. 1–8 (2012).
- [6] 中島 悠貴, 村尾 和哉, 寺田 努, 塚本 昌彦, "サンプリング制御とデータ補完による行動認識システムの省電力化手法," 情報処理学会論文誌, Vol.52, No.8, pp.2455–2466 (2011)
- [7] 田淵勝宏, 納谷太, 大村廉, 野間春生, 小暮潔, 岸野文朗, "加速度センサを用いた日常行動識別におけるデータ収集条件の識別性能への影響評価" 日本バーチャルリアリティ学会論文誌, Vol.12, No.1, pp.25–36 (2007)
- [8] Ricardo Chavarriaga a, Hesam Sagha, Alberto Calatroni, Sundara Tejaswi Digumarti, Gerhard Tröster, José del R. Millán, Daniel Roggen, "The Opportunity challenge: A benchmark database for on-body sensor-based activity recognition," Pattern Recognition Letters, Vol.34, No.15, pp.2033–2042 (2013)
- [9] Daniela Micucci, Marco Mobilio, and Paolo Napolitano, "UniMiB SHAR: A Dataset for Human Activity Recognition Using Acceleration Data from Smartphones," Applied Sciences, Vol.7, No.10 (2017)
- [10] Nobuo Kawaguchi, Nobuhiro Ogawa, Yohei Iwasaki, Katsuhiko Kaji, Tsutomu Terada, Kazuya Murao, Sozo Inoue, Yoshihiro Kawahara, Yasuyuki Sumi, Nobuhiko Nishio, "HASC Challenge: Gathering Large Scale Human Activity Corpus for the Real-World Activity Understandings," In proceedings of the Augmented Human International Conference, No.27, pp1–5 (2011)
- [11] 長谷川 達人, 木村 洋文, "敵対的訓練を用いたサンプリング周波数の相違に頑健な行動認識," マルチメディア, 分散, 協調とモバイルシンポジウム (DICOMO2020), pp. 534–543 (2020).