

# ユーザ状態推定における推定精度と消費電力の最適化

山本直樹<sup>†1</sup> 落合桂一<sup>†1</sup> 稲垣章弥<sup>†1</sup> 神山剛<sup>†1</sup> 深澤佑介<sup>†1</sup>

**概要:** スマートフォンのセンサを利用したユーザ状態推定の研究が行われているが、実用性の観点では各種センサを常時稼働させることによる消費電力が課題となる。一方消費電力削減のためログデータの収集頻度を抑制するという方法があるが、ユーザ状態推定精度が悪化することが想定される。そこで本研究では、センサの稼働を抑制することにより省電力化を実現するとともに、サンプリングされたログから元のデータを復元する手法を提案し、評価する。

**キーワード:** ユーザ状態推定, 省電力化

## Optimizing Accuracy-Energy Tradeoff in User Activity Recognition

NAOKI YAMAMOTO<sup>†1</sup> KEIICHI OCHIAI<sup>†1</sup> AKIYA INAGAKI<sup>†1</sup>  
TAKESHI KAMIYAMA<sup>†1</sup> YUSUKE FUKAZAWA<sup>†1</sup>

### 1. 序論

様々なセンサを身体の複数の部位に装着することで、人間の行動や動作、状態、またその周囲の状況を推定する研究は古くから行われている。近年では、スマートフォンの普及・高性能化に伴い、スマートフォンに搭載された様々なセンサから取得したデータが活用されるようになった。このようなスマートフォンを用いたユーザの状態推定に関する研究では、スマートフォンを用いたユーザの趣味嗜好推定に関する研究[1]や、モバイルセンサを基にユーザの精神・身体の両面の健康状態を推定する技術[2]が報告されている。また、Jeffrey W. Lockhartらは既存の行動認識技術の調査結果と今後の展望について報告している[3]。スマートフォンを用いてユーザの行動を高精度に推定することにより、個々の状態に合わせた多様なサービスをスマートフォンを通して提供することが可能になる。これらの研究の多くは、スマートフォンに搭載された加速度センサやジャイロセンサ、GPSといったセンサから収集した情報を元にユーザの状態推定を行っているが、各センサを常時稼働させることによる消費電力が課題となる。スマートフォンを用いるという特性上、ユーザには端末上で実行したいメインのタスクが存在しており、そのような状況においては、限られた電池容量の中でセンシングにて消費する電力を抑える必要がある。また、センシングにおける消費電力の増加に伴い、スマートフォンの稼働時間が短くなり、結果として状態推定に必要なログを十分に収集できない可能性がある。

このような消費電力の課題の解決方法として、センサログの収集頻度を低下させる、という単純な方法が考えられ

る。センサのサンプリング周波数を低下させることや、センサを完全に停止させる時間を設けることにより、消費電力を削減することが可能であるが、この方法では収集されるログが減少することにより、状態推定の精度が悪化することが想定される。したがって、状態推定精度と消費電力はトレードオフの関係にあると考えられる。このため、ログの収集頻度を下げることにより不足するセンサデータを復元することで、推定精度の悪化を抑えるという方法が提案されているが、2章に後述するように、復元できるデータが限定的である等の課題がある。

そこで本研究では、センサのON/OFF状態を一定の時間間隔で制御することにより消費電力を削減するとともに、Stacked Denoising Autoencoder (以下、SDA)を用いて欠損部分を補間することを提案する。センサデータの復元の評価に関しては、従来研究で行われていた行動認識による精度評価ではなく、センサ値の復元精度で評価を行うことで、センサデータを利用した状態推定に汎用的に利用可能な評価を行う。本研究では、既存のユーザ状態推定研究にて多く用いられている加速度、ジャイロ、傾きの3種類のセンサログを対象とする。

以降、2章では関連研究を述べ、3章では提案手法について述べる。4章では対象となるデータに関して説明し、5章で消費電力とログの復元精度の評価を行う。最後に6章で本論文をまとめる。

### 2. 関連研究

本章では、本研究に関連する従来研究として、1)行動認識と消費電力に関する研究、2)スマートフォンの省電力化

に関する研究について触れ、本研究が実現を目指すセンサデータ復元手法の要件を述べる。

## 2.1 行動認識と消費電力

行動認識と消費電力に関する研究として、先に述べた中島らの研究[4]や、明村らの研究[5]がある。

ログ収集頻度がユーザ状態推定や消費電力に与える影響を分析した研究として、中島らの研究[4]がある。中島らの研究では加速度センサのデータに着目しており、身体に装着した3個の3軸加速度センサを基に、「歩く、走る、階段を上る、階段を下りる、横になる、膝立ちになる、座る、立つ、自転車に乗る」という9種類の行動を意図的に実施し、収集したデータである。中島らは、センシングにおける消費電力を削減するため(1)加速度センサのサンプリング周波数を制御する手法、(2)センサ値の分散の変化が小さい場合は同じセンサ値になるという仮説で一定期間センシングを行わないという2つのサンプリング手法を提案している。しかしながら、これらのサンプリングでは加速度センサから取得されるデータ数が減少し、行動認識精度が低下する可能性がある。そこで中島らはデータの補間手法として、線形補間手法やアップサンプリング手法、同一値補間手法等の複数手法を用いることで元のデータを復元している。その結果、サンプリング制御をしない場合とほぼ同等の精度で行動認識が行え、平均電力削減率 34.4%が達成されたと報告されている。

しかしながら、中島らは欠損データの補間手法として線形補間等の単純な補間手法を適用しているが、加速度センサの値は各ユーザの行動を反映して、複雑かつ多様な変化をしていることから、既存の単純なモデルでは精度よく補間することが困難である。したがって、ログ自体を精度よく復元するためには、ログの様々な変化に基づいた予測モデルの構築が必要になると考えられる。また、中島らの研究では特定の行動認識のためのデータ復元についてのみ検証が行われており、汎用的にデータ復元手法が適用可能であるかは明らかではない。

明村らの研究では圧縮センシング[6][7]と呼ばれる手法を用いてセンシングとデータの送信を行う携帯端末の消費電力を削減する手法を提案している。明村らは、90人の実験協力者から収集した加速度データを基に、基本的な6種類の行動認識を実施し、圧縮センシングによる行動認識精度への影響を評価している。また、一般的なzip形式による圧縮を用いてデータ送信を行った時と比較して、明村らの提案手法を用いた場合には消費電力を16%削減し、かつ復元誤差を10%以内に抑えることが可能であると示されている。

## 2.2 スマートフォンの省電力化

スマートフォンの省電力化に関する研究として、神山らや小西らの研究がある[8][9][10]。神山らは、スマートフォ

ン上にてアプリ等のソフトウェアが動作可能な状態において、CPU等の各コンポーネントの稼働状態に依らず必ず消費する電力(Offset電力)に着目している。スマートフォンのような携帯端末は、待受時間を長く確保するため、ソフトウェアが動作する必要がない場合にはCPU等の主要なコンポーネントをSleep状態に遷移させ、電池消費を抑える機構が備わっている。しかし、近年のスマートフォンアプリは、ユーザがスマートフォンを操作していない画面OFF状態においてもバックグラウンドで動作できるよう端末の待機状態(idle)を維持することが可能である。神山らは、このidle状態での消費電力をOffset電力と呼び、Offset電力が全体に占める割合が大きいケースがあることを指摘している。つまり、アプリ動作時のハードウェアリソース消費を抑えても、端末のSleep状態を確保しないことには実効的な省電力化が見込めないことになる。そこで神山らは、バックグラウンドタスクの起動タイミングを他のタスクと集約することにより、端末をSleep状態にする時間を設け、Offset電力の消費を削減する方法を提案し、従来と比較して約40%程度削減できたと報告されている。

この知見をセンサデータ収集処理にあてはめると、前項であげたセンサのサンプリング周波数を制御する手法では、センサ動作に伴うハードウェアリソースの消費は抑えられるが、端末がSleep状態へ遷移できないためOffset分の消費を伴ってしまう。このため、省電力化の観点では、センシング自体を完全に停止し、端末のSleep状態をできるだけ長く確保できることが望ましい。

## 2.3 要件設定

以上より、本研究では、従来研究では困難であった、1) 複雑かつ多様な変化を伴うセンサデータをも復元の対象にすること、またセンシングによる消費電力を削減するために、神山らの考え方を踏襲し、2) センサのON/OFF状態を切り替える方法を選択する。

## 3. 提案手法

本章では、電力消費を抑えるためのセンシング方法とセンサデータの復元方法について述べる。

### 3.1 センシングの制御による消費電力の削減

本研究では、スマートフォンに搭載された各センサを、一定の時間間隔 $T$ でON状態とOFF状態を繰り返すことによる消費電力の削減量を計測する。概要を図1を用いて説明する。図1は、センサのONとOFFの遷移を時間軸上で示したものであり、濃青のセルがセンサをON状態にし、ログを収集する期間を示している。一方淡青のセルは、センサをOFF状態にし、ログの収集を中断している期間を示している。センサがON状態時には、加速度、ジャイロ、傾きセンサより1秒間隔でログを収集する。



図 1 センシング制御の概要

$T$ は 10 分, 30 分, 60 分の 3 パターンを設定し, 各条件における検証時間は 24 時間とする. また, 消費電力の測定はスマートフォンより取得するバッテリー残量のログを基に行う. バッテリー残量のログ収集は各センサが ON 状態のタイミングで行うものとする. これはバッテリー残量のログを収集するために CPU 等を起動することで, 消費電力が増加することを防止するためである.

### 3.2 SDA(Stacked Denoising Autoencoder)を用いた特徴抽出

センサデータは, 歩行中や静止状態など特定の状態では一定のパターンとなると想定されるため線形補間や時系列データを分析する ARIMA モデル[11]等を適用することができると考えられる. しかしながら, 日常生活では様々な行動が組み合わされて行われるため一定のパターンではなく複雑かつ多様に変化すると考えられる. そこで本研究では, 深層学習のモデルである, SDA(Stacked Denoising Autoencoder)[14] を用いて, ログの欠損部分の補間を行う. Autoencoder[12]は出力データがそのまま入力データを再現する 3 層のニューラルネットワークにより次元圧縮を行う手法である. 次元圧縮を行うことで, 対象とするデータの説明に有効な特徴の抽出が可能となる. 図 2 に Autoencoder の模式図を示す. Autoencoder は, 入力ベクトル  $x = \{x_1, x_2, x_3, \dots, x_n\}$ ,  $x_i \in R$  が与えられたときに, 式(1)のエンコーダ  $y = f(x)$  を用いて入力ベクトル  $x$  を変換し, 出力  $y$  を求める. 次に式(2)のデコーダ  $z = g_{\theta'}(y)$  を用いて, 隠れ層の出力を入力として  $z$  を出力する.

$$y = f_{\theta}(x) = s(Wx + b) \quad (1)$$

$$z = g_{\theta'}(y) = s(W'y + b') \quad (2)$$

式(1)における  $\theta = \{W, b\}$  と, 式(2)における  $\theta' = \{W', b'\}$  はそれぞれパラメータを表しており,  $W$  は重み行列,  $b$  はバイアス項,  $W'$  は逆変換の重み行列,  $b'$  は逆変換のバイアス項である.  $s(\cdot)$  は活性化関数を表しており, 本研究では ReLU 関数を適用した.

復元誤差を最小とするために, 式(3)を用いてモデルのパラメータを最適化する.

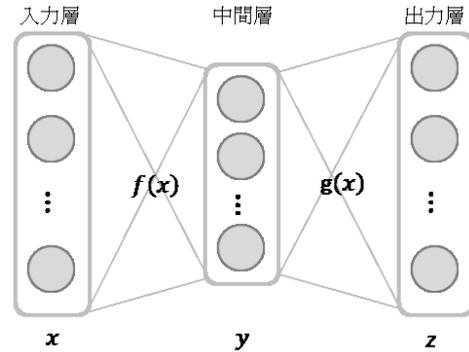


図 2 Autoencoder の模式図

$$\theta, \theta' = \underset{\theta, \theta'}{\operatorname{argmin}} L(x, z)$$

$$= \underset{\theta, \theta'}{\operatorname{argmin}} \frac{1}{N} \sum_{i=1}^N (x_i - g(f(x_i)))^2 \quad (3)$$

以上のようにして獲得されるエンコーダの出力は, 入力を復元する情報を保持したまま, 中間層のノード数の増減を可能とするため, Autoencoder は元の入力から有意な情報を抽出することが可能である.

Vincent ら[13]は入力データにノイズを加えることで, より汎化された特徴を抽出できる Denoising Autoencoder を提案している. この Denoising Autoencoder を複数層積み重ね, 上位層の出力を次の Autoencoder の入力として用いることにより, 表現能力を向上させた手法が Stacked Denoising Autoencoder (SDA)[14]である.

ここで, 層数  $d$  の SA(Stacked Autoencoder)を考える. まず, SA の 1 層目では入力データを基に Autoencoder を学習する. 第 1 層を学習後, 第  $i$  層の中間層の出力を第  $(i + 1)$  層の入力として用いて, 1 層ずつ Autoencoder を学習, 獲得し, 積層にすることにより SA を実装する.

本研究では, リアルタイムにログを補間するのではなく, オフラインでの補間を想定している. 一般的な時系列データの予測では, 現時点までのデータを基に, 未来のデータを予測することが行われているが, オフライン分析では, 未来のログを予測に用いることが可能である. そこで, 本研究では下記 3 通りの予測方法を提案する.

(1) 過去のログによる欠損データの予測 (SDA-normal)

一般的な時系列データの解析手法と同様に, 過去のログを基に事前学習を行い, 欠損したログの予測を行う. 例えば, 図 2 の  $t=0$  から  $t=T$  のログを基に,  $t=T$  から  $t=2T$  の期間のログを予測する.

(2) 過去のログによる欠損データの予測結果と, 未来のロ

### グから欠損データの予測結果の利用 (SDA-avg)

過去のログによる欠損データの予測は上述した手法と同様である。さらに、未来のログから欠損データの予測を行う。図1を例に述べると、 $t=2T$ から $t=3T$ のログを基にして、 $t=T$ から $t=2T$ の予測を行う、というものである。ここまでで、過去から未来を予測した結果と、未来から過去を予測した結果の2通り予測結果が得られる。この2つの予測結果の平均を最終的な予測結果とする。

### (3) 欠損データの直前と直後のデータを利用 (SDA-bi-direction)

予測対象の直前と直後のログデータを利用する手法である。図2において、予測対象が $t=T$ から $t=2T$ の期間である時に、 $t=0$ から $t=T$ のログと、 $t=2T$ から $t=3T$ のログを連結し、このログを基に事前学習を行い、予測を行う。

### 3.3 予測モデルの構築 (fine-tuning)

SDAの学習により得られたモデルより、エンコーダ部分を抽出し予測モデルを構築する。特徴抽出では、ノイズを加えた入力データから元のデータを復元する様に Denoising Autoencoder を一層ずつ学習し、学習済みの層を積層することで SDA を実装する。fine-tuning では、SDA に対する入力データは、前述した 3.2 項の(1), (2), (3)のそれぞれの方法から変更せずに、教師データをログの補間期間とし、モデルを構築する。

### 3.4 SDA と線形補間のハイブリッド手法 (SDA-hybrid)

各センサから収集されたログには、その値に大きな変化が見られない期間が存在する。例として図3に加速度センサのログを示す。図3はある1日の $x$ 軸方向の加速度センサの変化を表しており、縦軸が加速度の大きさ $[m/s^2]$ 、横軸が時間軸 $[s]$ である。横軸の左端は0時0分0秒で、右端は23時59分59秒を表している。この図から分かるように、一定時間ログの値に大きな変化が見られない時間帯が存在しており、これは就寝中やスマートフォンを机の上に放置しているといった状況が考えられる。加速度センサの $y$ 軸、 $z$ 軸方向やジャイロセンサ、傾きセンサでも同様な傾向が確認できる。センサ値の変化が少ない部分では、深層学習のような自由度の高いモデルでは過学習が起こる場合があり、センサ値に変化がない部分でも値の変化が大きいと予測してしまう場合がある。そのため、センサ値の変化が少ない部分では線形補間のような単純なモデルで補間した方がよいと考えられる。

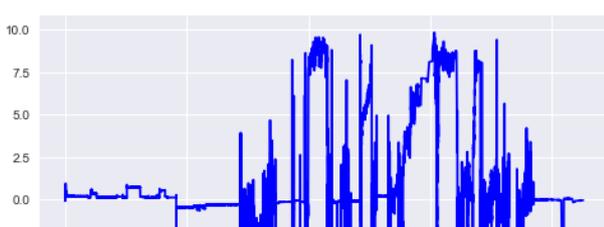
そこで、補間対象の前後の期間におけるログに大きな変化が見られない場合には、補間対象の期間においてもログに大きな変化は見られないと仮定し、線形補間を行う。一方ログの値が大きく変化する時間帯に対して SDA のモデルを適用することで補間を行う。線形補間と SDA のモデルを切り替える閾値として、前後の期間の分散の値を用いる。図1において、 $t=0$ から $t=T$ の期間の分散の値と、 $t=2T$ から $t=3T$ の分散の値が閾値以下であるときに線形補間を行い、それ以外の場合には深層学習を適用するものとする。

## 4. 対象データ

### 4.1 センシングの制御による消費電力の削減

消費電力の検証に利用するスマートフォンは富士通製の Android 端末 ARROWS NX F-02G 2 台で、搭載された Android のバージョンはどちらも 5.0.2 である。検証期間中、このスマートフォンを日常生活と同様に持ち歩き、行動のセンシングのみに利用した。各センサの稼働を 10 分、30 分、60 分間隔で制御しながら検証を行い、それぞれの場合における消費電力の削減量を計測する。なお、今回検証に用いた2台のスマートフォンの通信機能は OFF 状態になっており、また特定のアプリケーションを起動することはなく、ログ収集のために限って利用するものとする。また、収集された各ログはスマートフォンの内部ストレージに1日単位で保存した。

消費電力とサンプリング間隔の関係性を検証するために収集したログは3軸加速度、ジャイロ、傾きセンサとバッテリー残量のログである。これらのセンサは既存のユーザ状態推定研究において多く用いられているため、これら3センサに関して、センサの稼働を抑制することによる消費電力の削減量を計測した。



## 4.2 SDA による補間に用いるセンサログ

SDA による補間に用いるログは、スマートフォンの機種を問わず収集した。3 軸加速度、ジャイロ、傾きセンサの計 9 種類のログを 1 秒間隔で常時収集した。この内、ログに大きな欠損を含んでいる場合や、1 日を通してログの値に変化が見られないデータに関しては収集したデータから除外した。このログを 10 分間隔、30 分間隔でサンプリングし、補間を行うデータを作成した。

## 5. 評価実験

本章では、センサの ON/OFF 状態の制御による消費電力の削減量を評価する。また、センシングを制御し欠損を含むログから、元のログを復元した時の復元精度を評価する。

### 5.1 サンプリング頻度と消費電力の関係性

図 4 に、加速度センサを単体で 24 時間稼働させた場合と、センサのサンプリング間隔を 10 分、30 分、60 分と制御した場合のバッテリー残量の変化を示す。縦軸はスマートフォンで収集されるバッテリー残量(%), 横軸は経過時間(hour)を表している。図 4 より、加速度センサを常時 ON 状態にした場合と、10 分間隔で ON/OFF 状態を繰り返した場合では、24 時間経過後もバッテリー残量に大きな違いは見られない。一方で、30 分間隔で ON/OFF 状態を繰り返した場合の消費電力は、常時加速度センサを稼働させた場合の約 50% に抑えることが出来ている。また、60 分間隔で ON/OFF 状態を繰り返した場合の消費電力は、常時加速度センサを稼働させた場合の約 30% に抑えることが出来ている。ジャイロセンサ、傾きセンサをそれぞれ単独で稼働させた場合も同様の傾向であった。

図 5 は、加速度、ジャイロ、傾きの 3 センサを同時に稼働させた場合において、センサの稼働時間を制御した場合のバッテリー残量の変化を示している。3 センサを稼働させることで、センサを単独で稼働させた場合よりも消費電力が増加していることが分かる。また、各センサを単独で動作させた場合と同様に、センサのサンプリング間隔が大きいほど消費電力を削減できていることが分かる。3 センサを常時稼働させた場合のバッテリー残量を基準として、10 分間隔で ON/OFF 状態を繰り返した場合の消費電力は 15% 程度の削減にとどまったのに対して、30 分間隔で ON/OFF 状態を繰り返した場合には約 40% 消費電力を削減することが可能であり、60 分間隔の場合には約 80% 消費電力の削減が可能であるという結果になった。いずれのサンプリング間隔の場合も、検証時間内で各センサが ON 状態である総時間は同じであるにも関わらず、サンプリング間隔が大きいほど消費電力が削減されるという結果になった。

これは一定時間センサを OFF 状態とすることにより、各センサやセンサへ ON/OFF の命令を出している CPU 等のコ

ンポーネントが Sleep 状態となることにより消費電力が抑えられたと考えられる。10 分間隔で ON/OFF 状態を繰り返した場合における消費電力の削減量が少なかったのは、各センサや CPU 等のコンポーネントが Sleep 状態になるための時間が不十分であったためだと考えられる。

### 5.2 ログ補間精度の評価

本研究で検証したログの補間手法と、補間精度に関して述べる。本研究の提案手法である SDA を用いた補間と精度比較を行うために、補間手法としてよく知られている Spline 補間[15]をベースライン手法とした。Spline 補間とは、補間対象となるデータ領域をデータ間隔  $[x_i, x_{i+1}]$  に区切り、その近傍のデータ点を用いて低次の多項式により近似し、既知の全データ点を通るように補間する手法である。本研究では 0 次補間、1 次補間、最近傍点による補間の 3 通りの補間手法を適用した。0 次補間は、 $[x_i, x_{i+1}]$  を  $x_i$  の値により補間を行い、1 次補間は  $[x_i, x_{i+1}]$  を直線的に補間する手法である。最近傍点による補間は、 $[x_i, x_{i+1}]$  において、近傍にあるデータ点の値により補間を行う手法である。

常時センサを稼働して取得したデータを正解データとした。評価指標には、10、30 分間隔でサンプリングしたデータから補間した値と正解データとの RMSE を用いた。評価には 10 日分のセンサデータを用い、10 日分の RMSE の平均値をその手法における補間精度とした。

加速度センサに関して、10、30 分間隔でサンプリングした場合の補間精度を表 1, 2 に示す。表中の † はベースライン手法で最も精度が高かった 1 次 spline 補間に対して有意水準 0.1% で有意な差があること、‡ は有意水準 1% で有意な差があること、\* は有意水準 5% で有意な差があることを示す。10 分間おきにサンプリングした場合には、spline 補間を行った場合の補間精度と比較すると、SDA を用いた補間の方が精度よく補間できていることが確認できる。30 分おきにサンプリングした場合には、既存手法の方が SDA を用いた場合よりも精度よく補間できる場合も存在している。また、SDA による欠損期間の予測においては、過去のログのみを用いた場合よりも、補間対象期間よりも未来のログを組み合わせる場合の方が精度よく補間できていることが分かる。SDA のみを用いた予測では、図 3 に示したようにログの値に大きな変化が見られない期間において補間精度が低くなる傾向が見られたことから、深層学習と線形補間を組み合わせたハイブリッドモデルを用いて、ログの変化が小さい期間に対して線形補間を適用することにより、x, y, z 軸方向の補間精度において、それぞれ 27%、28%、43% 程度の補間精度の改善が見られた。

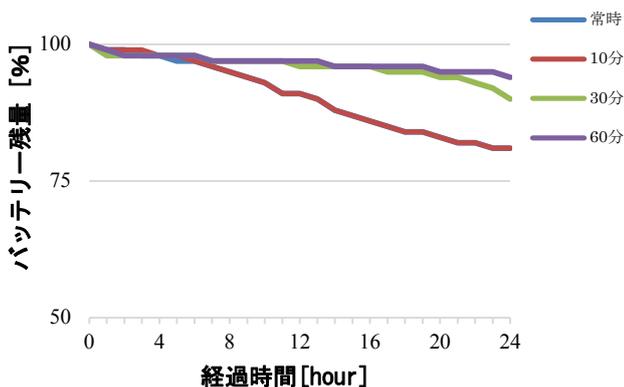


図 4 加速度センサにおける消費電力

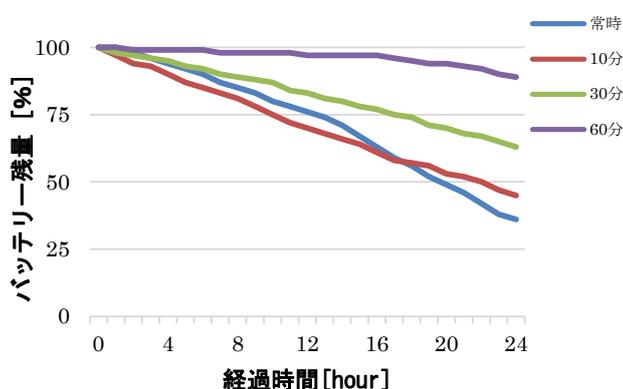


図 5 3 センサの稼働と消費電力の関係

既存手法において最も精度良く補間が出来る 1 次 spline 補間による補間精度と、提案手法である SDA(ハイブリッドモデル)による補間精度の差が統計的に有意な検証するために、有意水準 5%で両側検定の t 検定を行った結果を表 5 に示す。この結果より、提案手法と既存手法の復元精度の差は有意であり、提案手法により既存手法よりも精度よく補完出来ることが示された。

同様に SDA(ハイブリッドモデル)を 30 分間隔でサンプリングしたジャイロセンサ、傾きセンサの補間に適用した場合の結果を表 3, 4 に示す。表中の † はベースライン手法で最も精度が高かった 1 次 spline 補間に対して有意水準 1%で有意な差があること、‡ は有意水準 0.1%で有意な差があることを示す。ジャイロセンサに関しては、x, y, z 軸方向の補間精度で、それぞれ 64%, 39%, 63%程度の補間精度の改善が見られた。傾きセンサに関しては、x, y, z 軸方向の補間精度で、それぞれ 31%, 21%, 23%程度の補間精度の改善が見られた。

## 6. まとめ

本研究では、スマートフォンで収集したセンサログに基づくユーザ状態推定において、推定精度を維持しつつログ収集に要する端末消費電力を低減させることを目的とし、サンプリングされた少数のログから欠損部分を補間することで、ログ収集頻度の低減による省電力化を図ることに着目した。さらに、効果的な省電力化を見込むためには、CPU 等の端末を構成するコンポーネントの電力消費が最も低い Sleep 状態を長く確保できることを前提としたログ補間を実現させる必要があることに着目し、10 分オーダーの間隔でセンサ稼働を停止させることが可能な SDA を用いた補間手法を提案し、電力削減効果と共にログの復元精度を評価した。

センサの稼働を制御することによる消費電力の削減に関しては、現状では 30 分間隔でログを収集することにより、常時センサを稼働させた場合と比較して、消費電力を約 50%削減することが可能となる。評価対象データが異なるが、従来手法のサンプリング周波数を制御する手法では常時測位と比較した電力削減率が 34.4%であるのに対して、提案手法ではセンサの稼働 30 分間隔に制御することで約 50%削減可能である。

ログの復元に関しては、30 分間隔でサンプリングしたデータに対して、本研究の提案手法である SDA を用いた手法を適用することで、加速度、ジャイロ、傾きセンサのいずれの補間精度に関しても、従来手法である spline 補間より精度よく補間し、データを復元することが可能であると示された。各センサの補間精度は、加速度センサに関しては、x, y, z 軸方向のログに対してそれぞれ 27%, 28%, 43%程度、ジャイロセンサに関してはそれぞれ 64%, 39%, 63%程度、傾きセンサに関してはそれぞれ 31%, 21%, 23%程度補間精度の改善が見られた。線形補間の様な単純な補間手法では、補間対象の前後のデータ点のみを基に補間しているのに対して、SDA を用いた補間では、補間対象の前後におけるセンサの値の変化を基に予測モデルを作成し、補間を行っているために、精度が向上したと考えられる。

本研究で提案したセンシングにおける省電力化とユーザ状態推定精度の維持に関する技術は、センサの稼働を抑制し、サンプリングされた少数のログから元のログを復元するため、特定の行動認識に特化したものではなく、元のデータを復元することが可能であるため、どのような行動認識においても省電力化実現のために汎用的に適用可能な技術であると考えている。

本研究の今後の課題として、深層学習のモデルの高度化や時系列情報を考慮したモデルの作成がある。本研究で提案したモデルに対して、さらに時系列情報を考慮したモデルを作成することで、多様な変化をするログをより精度よく補間することが可能になると考えている。また、ハイブ

リッドモデルにおいて手法の切り替えを閾値により行ったが、最適なモデルを自動で選択できるようにすることで、より精度よく補間することが可能になると考えている。

表 1 10分おきにサンプリングしたログの  
 補間精度 (加速度)

手法	RMSE		
	x	y	z
spline (0次)	0.97	1.04	1.61
spline (1次)	0.81	1.02	1.03
spline (最近傍点)	0.91	1.05	1.19
SDA-normal	0.80	0.92	1.02
SDA-avg	0.81	0.94	1.12
SDA-bi-direction	0.76	0.82	0.85
SDA-hybrid	0.69 <sup>*</sup>	0.76 <sup>†</sup>	0.80 <sup>*</sup>

表 2 30分おきにサンプリングしたログの  
 補間精度 (加速度)

手法	RMSE		
	x	y	z
spline (0次)	1.32	1.51	2.49
spline (1次)	1.31	1.5	2
spline (最近傍点)	1.41	1.56	2.11
SDA-normal	1.42	1.45	1.51
SDA-avg	1.35	1.42	1.53
SDA-bi-direction	1.21	1.36	1.41
SDA-hybrid	0.95 <sup>‡</sup>	1.07 <sup>‡</sup>	1.14 <sup>‡</sup>

表 3 30分おきにサンプリングしたログの  
 補間精度 (ジャイロ)

手法	RMSE		
	x	y	z
spline (0次)	0.61	0.6	0.56
spline (1次)	0.53	0.54	0.52
spline (最近傍点)	0.54	0.55	0.52
SDA-hybrid	0.19 <sup>*</sup>	0.33 <sup>*</sup>	0.19 <sup>*</sup>

表 4 30分おきにサンプリングしたログの  
 補間精度 (傾き)

手法	RMSE		
	x	y	z
spline (0次)	60.47	42.15	9.48
spline (1次)	54.42	37.55	8.49
spline (最近傍点)	56.15	38.99	8.5
SDA-hybrid	37.3 <sup>†</sup>	29.74 <sup>†</sup>	6.55 <sup>*</sup>

## 参考文献

- [1] Abhinav Mehrotra, Robert Hendley, Micro Musolesi: "PrefMiner: Mining User's Preferences", UBIComp '2016, SEPTEMBER 12-16, 2016, OSAKA, JAPAN, HEIDELBERG, GERMANY
- [2] Mashfiqui Rabbi, Shahid Ali, Tanzeem Choudhury, Ethan Berke: "Passive and In-situ Assessment of Mental and Physical Well-being using Mobile Sensors", UBIComp '2011, SEPTEMBER 17-21, 2011, Beijing, China
- [3] Jeffrey W. Lockhart, Tony Pulickal, Gary M. Weiss: "Applications of mobile activity recognition", UBIComp '2012 SEPTEMBER 5-8, 2012, Pittsburg, USA
- [4] 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, 2455-2466 (Aug. 2011)
- [5] 明村 大登: "圧縮センシングを用いた行動モニタリングのための携帯端末省電力化手法"
- [6] 田中 利幸: "圧縮センシングの数理", IEICE Fundamentals Review Vol. 4 No. 1
- [7] 三村 和史: "圧縮センシング-疎情報の再構成とそのアルゴリズム-", 数理解析研究所議事録 第1803巻 2012年 25-56
- [8] 神山 剛, 稲村 浩, 太田 賢: "電力モデルに基づくアプリ消費電力可視化ツールの評価", 情報処理学会論文誌 Vol. 55 No. 8 1866-1875 (Aug. 2014)
- [9] 小西 哲平, 稲村 浩, 川崎 仁嗣, 神山 剛, 大久保 信三, 太田 賢: "画面オフ状態におけるバックグラウンドタスク同時実行による Android 端末の省電力化", 情報処理学会論文誌 Vol. 55, No. 2, 587-597 (Feb. 2014)
- [10] 川崎 仁嗣, 神山 剛, 小西 哲平, 大久保 信三, 太田 賢, 稲村 浩: "Android OS における状態変化通知による通信集中の削減手法", 情報処理学会論文誌 コンピューティングシステム Vol. 7, No. 1, 23-34 (Mar. 2014)
- [11] 北川源四郎: "時系列解析入門", 岩波書店, 2005
- [12] Hinton, G. E. and Salakhutdinov, R. R.: Reducing the dimensionality of data with neural networks, science, Vol. 313, No. 5786, pp. 504-507 (2006).
- [13] Vincent, P., Larochele, H., Bengio, Y., and Manzagol, P. A. Extracting and composing robust features with denoising autoencoders. ICML '08, pp. 1096-1103 ACM, (2008)
- [14] Vincent, P., Larochele, H., Lajoie I., Bengio, Y., Manzagol, P.-A., : "Stacked Deoising Autoencoders : Useful Representations in a Deep Network with a Local Denoising Criterion", Journal of Machine Research 11 (2010) 3371-3408,
- [15] 森口繁一: "数値計算工学", 岩波書店, 1994

## 正誤表

大変申し訳ございません。

お詫びの上、訂正させていただきます。

4 項

### 3.4 SDA と線形補間のハイブリッド手法 (SDA-hybrid)

(誤)

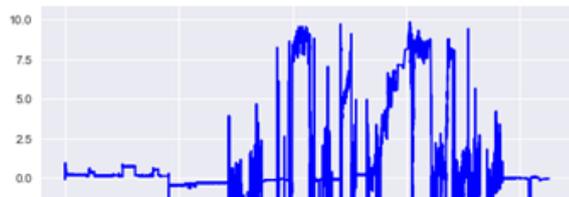


図 3 加速度センサ x 軸方向のログ

(正)

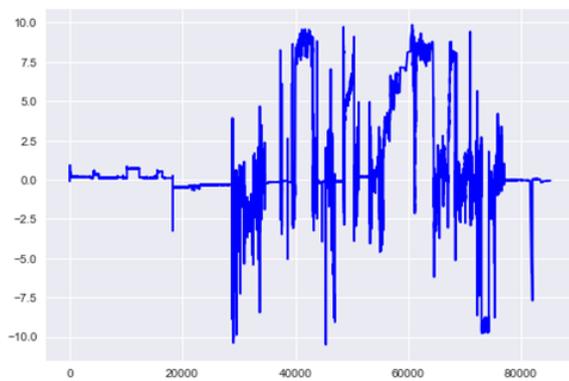


図 3 加速度センサ x 軸方向のログ