情報処理学会論文誌 Vol.61 No.2 351–361 (Feb. 2020)

Stacked Denoising Autoencoderを用いた間欠的測定センサデータの復元

山本 直樹[1,a)] 落合 桂一[1] 稲垣 章弥[1] 神山 剛[1] 深澤 佑介[1]

受付日 2019年4月27日, 採録日 2019年11月7日

概要：スマートフォンに搭載されたセンサを利用し，ユーザの状態を推定する研究が多数報告されているが，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．そこで本研究では，各種センサの稼働を抑制することによりセンシングにおける省電力化を実現するとともに，深層学習のモデルである Stacked Denoising AutoEncoder（SDA）を用いて，サンプリングされたセンサログから元のセンサログを復元する手法を提案する．まず，スマートフォンに搭載された加速度センサとジャイロセンサを用いて，21 名の試験参加者から計 603 日分のログを収集した．次に，収集したログを任意の時間幅でサンプリングすることによって意図的に間欠データを作成し，SDA を用いて間欠部の復元を行うモデルを構築した．その結果，提案手法はベースライン手法と比較して，復元精度が 38.89%以上改善可能であることが示された．

キーワード：ユーザ状態推定，省電力化，欠損値補間

Reconstruction of Intermittent Measurement Sensor Data Using Stacked Denoising Autoencoder

Naoki Yamamoto[1,a)] Keiichi Ochiai[1] Akiya Inagaki[1] Takeshi Kamiyama[1] Yusuke Fukazawa[1]

Received: April 27, 2019, Accepted: November 7, 2019

Abstract: Over the past few decades, a considerable number of studies have been conducted on user activity recognition using sensors mounted on smartphones. These studies have a problem that the power consumption of the smartphone increases because of operating various sensors at all times. To solve this problem, there is a simple method that reduces the sensor logs collection frequency. However, it is assumed that the user activity recognition accuracy decreases if the enough sensor log could not be collected. In this study, we propose a method to reduce the power consumption in sensing by suppressing the operation of various sensors, and reconstruct the original sensor log from sampled sensor log using Stacked Denoising Autoencoder (SDA). First, we collected accelerometer logs and gyro sensor logs for 603 days from 21 participants. Second, we constructed the model which reconstruct the original sensor logs from sampled sensor logs using SDA. Our results showed that the proposed method can improve the reconstruction accuracy by more than 38.89% compared with the baseline method.

Keywords: activity recognition, power consumption, interpolation

1. 序章

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，またユーザの周囲の状況を推定する研究は古くから行われている [1]．近年ではスマートフォンの普及・高性能化にともない，スマートフォンに搭載されている様々なセンサから取得したログを基にユーザの状態を推定する技術が多数報告されている [2]．たとえばユーザの睡眠時間や睡眠中の健康状態を検出する研究 [3]，スマー

1 株式会社 NTT ドコモ
NTT DOCOMO, INC., Chiyoda, Tokyo 100–6150, Japan
a) naoki.yamamoto.kw@nttdocomo.com

© 2020 Information Processing Society of Japan

トフォンを用いたユーザの趣味嗜好推定に関する研究 [4]，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 [5] が報告されている．また，Lockhart らは既存の行動認識技術と今後の展望について報告している [6]．

スマートフォンから取得したセンサログを用いて，ユーザの状態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基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ってスマートフォンの消費電力が増加することが課題となる．著者らの研究 [7] では，ある 1 日のスマートフォンログを基にその日のストレス状態を推定する研究を報告している．この研究では，スマートフォンのセンサを常時 ON 状態とし，長期的なログを取得し続けるために，スマートフォンの消費電力が課題となっている．スマートフォンを用いてセンシングを行うという特性上，ユーザにはスマートフォン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ともない，スマートフォンを長期的に稼働させておくことが困難となり，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，スマートフォンの状態を正確にとらえることが困難となり，結果としてユーザ状態推定の精度が悪化することが想定される．そこで，収集頻度を下げることによって不足したセンサログを復元することで，ユーザ状態推定の精度悪化を抑えるという方法が提案されている．しかしながら，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という課題がある．したがって，ログの復元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．

本研究では，Stacked Denoising Autoencoder（以下，SDA）を用いて，欠損を含むセンサログから元のセンサログを精度良く復元することを目的とする．**図 1**，**図 2** にセンサログの復元手法の概要を示す．提案手法では，スマートフォンから取得したセンサログをサンプリングすることによって，意図的に欠損を含むログを作成し，欠損を含むログから元のセンサログを復元する SDA モデルを構築する．センサログの復元の評価は，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

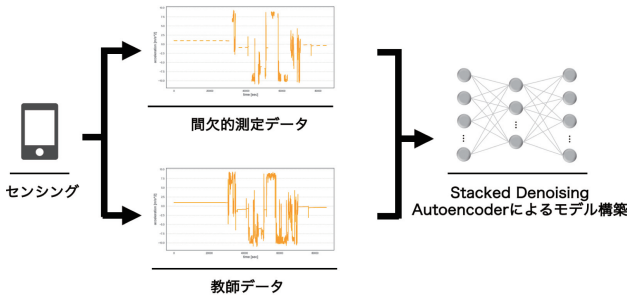

図 1　間欠的測定データ復元モデルの構築

Fig. 1　Overview of learning reconstruction model intermittent measurement sensor data.

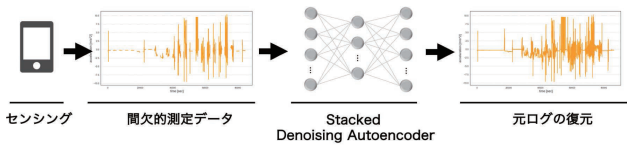

図 2　間欠的測定データの復元

Fig. 2　Reconstruction of intermittent measurement sensor data.

評価を行うことで，センサログ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で多く用いられている加速度，ジャイロの 2 種類のセンサログを対象とする．なお，本論文中では，センサの ON/OFF 状態を一定の時間幅で切り替えることにより収集した欠損を含むログを，間欠的測定データと呼ぶものとする．

本論文の貢献は以下のとおりである．

- 精度良く間欠的測定データから元データを復元するために，ログが測定されていない事前，事後のログの抽象表現を獲得し，それを用いて間欠期間を復元する手法（SDA_average）を提案した．
- センサデータに変化がある場合，変化がない場合が混在している場合にも精度良く復元するために，線形補間と提案手法を組み合わせた手法（SDA_hybrid）を提案した．
- 復元精度と測位間隔にはトレードオフの関係があるが，実データ検証により消費電力の観点で ON/OFF 状態を 30 分の時間幅で切り替え，間欠的測定データを復元することが最も効果が高いことを示した．
- 603 日分のセンサデータを収集し，ベースライン手法（spline 補間）と比較して SDA_hybrid 手法では 38.89%以上の復元精度の改善を示した．

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 章では提案手法の評価に触れ，5 章では間欠的測定データの復元結果を説明し，最後に 7 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，

© 2020 Information Processing Society of Japan

(1) センサログの復元と消費電力に関する研究
(2) Autoencoder を用いた特徴抽出に関する研究
(3) スマートフォンの省電力化に関する研究
(4) 多次元データに対する欠損値補完に関する研究
について述べる．

2.1 センサログの復元と消費電力

センサログの復元と消費電力に関する研究として，中島らの研究 [8] や，Akimura らの研究 [9] がある．

中島らは，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報告している [8]．中島らは，加速度センサを対象として，センシングにおける消費電力を削減するために，(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のもとに一定期間センシングを行わない手法，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比較してほぼ同等の精度でユーザの行動を認識をすることが可能であり，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，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，線形補間やアップサンプリングのような既存の単純なモデルでは精度良く補間することが困難である．したがって，ログ自体を精度良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．

Akimura の研究では圧縮センシング [10] 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 [9]．Akimura らは，90 名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 形式によるデータ圧縮を用いてデータ送信を行ったときと比較して，Akimura らの提案手法では消費電力を 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 Autoencoder を用いた特徴抽出

Autoencoder [11] 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．たとえば，Kumar らは肺がんの早期発見を目的として，医療 CT 画像に対して Autoencoder を適用することによって肺がんの画像特徴を抽出する手法を示している [12]．Wang は，身体に装着された慣性センサと磁気センサから取得したログを基に，Autoencoder を用いて行動特徴を抽出し，人間の行動を認識する手法を提案している [13]．高橋らの研究 [14] では，心電図から不整脈を自動検出する手法を提案している，高橋らは，Stacked Convolutional Denoising Autoencoder を用いて心電図から特徴抽出を行い，事前学習した Stacked Convolutional Denoising Autoencoder の構造および重みを利用した分類器を構築し再学習することで，未知の波形分類が高精度で行えることを示した．

2.3 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 [15], [16], [17]．神山らは，スマートフォン上で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よ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．しかしながら，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している．この知見をセンサログ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，センサ動作にともな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 分の電力消費をともなうことになる．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．

2.4 多次元データに対する欠損値補完

近年，欠損を含む多次元データを対象として，低ランク近似による補間手法が多数報告されている [18], [19], [20], [21]．たとえば，Liu らは画像データに対する低ランク近似を用

© 2020 Information Processing Society of Japan

いた補間手法を提案し，彼らの提案手法は Turcker 法や Parafac 法，SVD 法に対して優位な結果を示しており，かつ少数のサンプルから欠落情報を復元できることを示している [18].

これら低ランク近似を用いた補完手法は，すべての欠損値を同時に推定しており，大局的な考慮が必要となる画像データに適している．しかしながら，これらの手法がセンサデータに対して適用された例は報告されていない．特に人間の行動によって得られたセンサデータにおける欠損部は，欠損部の直前・直後の時系列的に近接したデータ点との関係性が強く，時系列的に大きく離れたデータ点との関係性は限りなく低いと考えられる．上記のことからセンサデータの補間においては，欠損部と時系列的に近いセンサデータの局所的な特徴を抽出し，その特徴に基づき欠損部分を補間することが効果的だと考えられる．

また，Savvaki らは人間の行動認識に必要となる慣性センサデータを対象とし，Xie らは大規模なネットワークから収集されるトラフィックデータを対象として，ランダムなタイミングで発生したデータ欠損を含むデータから，元の完全なデータを復元する手法を提案している [22], [23]. これらの研究は，本研究が着目するような省電力化を目的として，意図的に作成した欠損を含むサンプリングデータの復元は対象としていない．

3.　提案手法

本章ではまず，スマートフォンの省電力化を実現するためのセンシング方法を述べる．次に，提案手法である SDA を用いた間欠的測定データの復元手法について述べる．本研究では，長期的なログを取得したうえで欠損を補間し，元のログを復元する．したがって，従来の時系列データの補間手法に見られるように，過去のログから直後の欠損を補間するだけでなく，加えて未来のログを補間に用いることが可能である．

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の稼働を制御し，一定の時間幅 T で ON/OFF 状態を切り替えた場合における消費電力の削減量を計測する．例として，**図 3** は加速度センサの稼働を制御し，ON/OFF 状態を時間幅 T で切り替えたときのログを表している．センサが ON 状態である期間にのみログを収集し，センサが OFF 状態であるときにはログが収集されない．センサが ON 状態である期間には，加速度，ジャイロセンサから 1 秒間隔でログを収集する．時間幅 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残量のログを基に行う．バッテリ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．

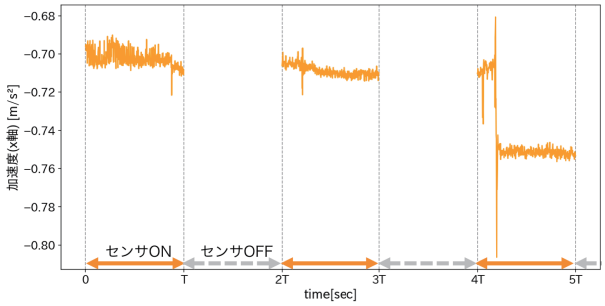

図 3　センシング制御の概要
Fig. 3　Acquisition of intermittent measurement sensor data.

これはバッテリ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

センサから取得されたログは，歩行中や静止状態等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 [24] を適用することが可能だと考えられる．しかしながら，日常生活では様々な行動が組み合わせて行われるため，センサログは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 [25] を用いて，多様に変化するセンサログの欠損を補間する手法を提案する．

Autoencoder [11] は，入力ベクトル x 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 $z = g(x)$ を用いて，隠れ層の出力を入力として z を出力する．

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

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

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．

$$\theta, \theta' = \arg\min_{\theta,\theta'} \frac{1}{N} \sum_{i=1}^{N} (x_i - g(f(x_i)))^2 \tag{3}$$

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 [26] を提案している．この

© 2020 Information Processing Society of Japan

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) [25] である．

ここで，層数 d の Stacked Autoencoder (SA) 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．したがって，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，本研究では以下 3 通りの予測方法を提案する．なお，区間 $[(i \times T), (i+1) \times T)$ を t_i ($i \in \mathbb{N}$) と表し，t_i におけるログを l_i と表すものとする．

(1) 過去のログを基にした欠損データ予測による補間 (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．ログ l_i を予測モデル $f_{normal}(\cdot)$ の入力としたときに，予測結果 $y_{normal,i+1}$ は以下の式で表される．

$$y_{normal,i+1} = f_{normal}(l_i), \quad i \in \mathbb{N} \tag{4}$$

(2) 過去のログによる予測結果と未来のログによる予測結果の平均値による補間 (SDA_average)

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．ログ l_{i+1} を未来から過去を予測するモデル $f_{inv}(\cdot)$ の入力とするときに，予測結果 $y_{inv,i}$ は以下の式で表される．

$$y_{inv,i} = f_{inv}(l_{i+1}), \quad i \in \mathbb{N} \tag{5}$$

このとき，SDA_average の出力 $y_{avg,i}$ は以下の式で表される．

$$y_{avg,i} = \frac{1}{2}\{f_{normal}(l_{i-1}) + f_{inv}(l_{i+1})\}, \quad i \in \mathbb{N} \tag{6}$$

3.3　予測モデルの構築 (Fine-tuinng)

ノイズを付加した入力データ l'_i からノイズを含まない入力データ l_i を復元するように Denoising Autoencoder (DA) を 1 層ずつ学習し，学習済みの DA を積層にすることで SDA を実装する．本研究では，平均 0，標準偏差 1 の標準正規分布 $N(0,1)$ に従い乱数を作成し，SDA の学習データであるセンサログに対してノイズとして付加する．事前学習した SDA の構造および重みを利用した予測器を構築し，再学習することで，間欠部のログを復元可能なモデルを構築する．ノイズを含まないセンサログ l_i を入力データ，ログの間欠部 l_{i+1} を教師データとして，SDA を再学習することで，非間欠部のセンサログから間欠部のセンサログを推定することが可能なモデルを構築する．

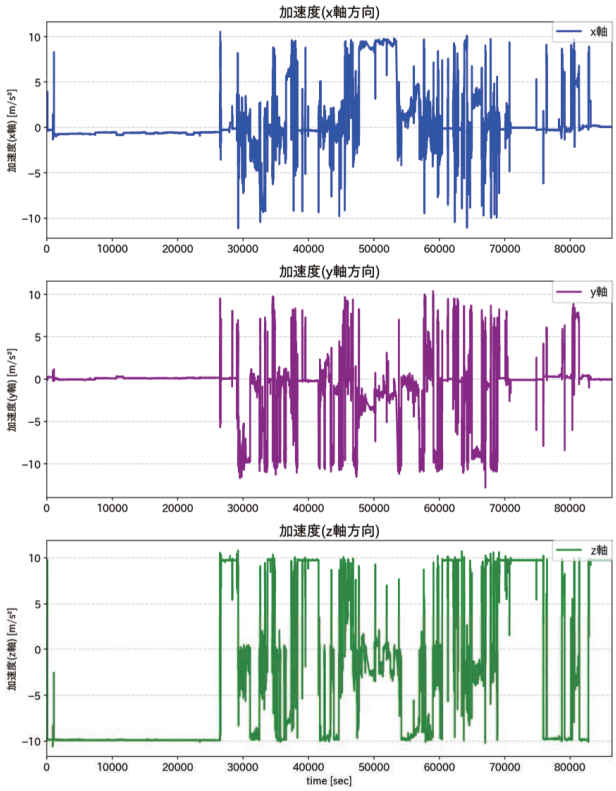

図 4　1 日分の加速度センサログ

Fig. 4　Example of sensor value acquired from 3-axis accelerometer.

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 4 に加速度センサのログを示す．図 4 はある 1 日の x 軸，y 軸，z 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，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．図 4 から分かるように，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上に放置しているといった状況が考えられる．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．

本研究では，一般にユーザの行動が少ないと仮定される，0 時から 6 時のセンサログを基に閾値を決定した．SDA の

© 2020 Information Processing Society of Japan

モデル構築におけるトレーニングデータのみを対象として，0 時から 6 時の加速度センサログ，ジャイロセンサログに対して各軸方向の分散値をそれぞれ求め，SDA と線形補間の手法判定における閾値として設定した．図 3 において，t_{i-1} の期間の分散値と，t_{i+1} の分散値がいずれも閾値以下であるときに，t_i に対して線形補間を行い，それ以外の場合には SDA を適用するものとする．

4.　提案手法の評価

本章では，

- 消費電力の検証用データと復元対象であるセンサログの収集方法
- 提案手法との比較手法
- 復元精度の評価指標

について述べる．

4.1　データ収集方法

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 [*1] 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．$T = 10, 30, 60$ [分] の時間幅で，各センサの ON/OFF 状態を切り替えながら検証を行い，それぞれの場合における消費電力の削減量を計測した．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 ON/OFF 状態の切替えにおける時間幅の関係性を検証するために，3 軸加速度，ジャイロセンサ，バッテリ残量のログを検証対象として収集した．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．

SDA による補間に用いるログは，21 名の実験協力者を対象としてスマートフォンの機種を問わず収集した．実験期間は 1 カ月と設定し，この期間中は各協力者のスマートフォンよりログを 24 時間収集し続けた．本実験により，21 名の実験協力者から合計 603 日分のセンサログを獲得した．

対象とするログは 3 軸加速度，ジャイロセンサの計 6 種類であり，これらのログを 1 秒間隔で常時収集した．このうち，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ログに関しては検証用データから除外した．図 3 に示すように，収集した各ログから

*1　富士通株式会社
http://www.fmworld.net/product/phone/f-02g/

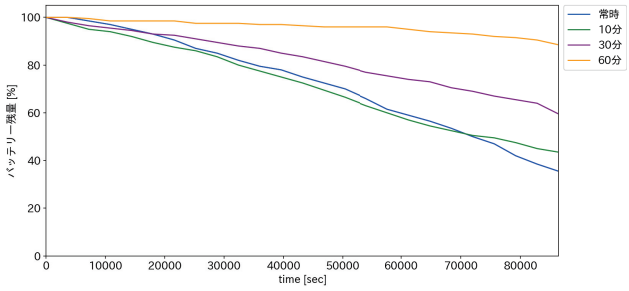

図 5　加速度，ジャイロセンサにおけるバッテリ残量の推移
Fig. 5　Transition of remaining battery values at different sampling time interval .

時間幅 T で各センサログをサンプリングし，復元対象となる間欠的測定データを作成した．

4.2　比較手法

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 [27] をベースライン手法とした．この補間手法は先行研究で採用されていた手法である．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，2 次補間，最近傍点による補間の 4 通りの補間手法を適用した．

4.3　評価指標

評価指標には $RMSE$ を採用した．常時センサを稼働して取得したデータと，時間幅 T でサンプリングしたデータから復元したログを基に，$RMSE$ を算出した．d 日のセンサログのデータ点数を N，正解データを y_d，予測値を $f(x)_d$ とすると，$RMSE_d$ は式 (7) で表される．

$$RMSE_d = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(y_{d,i} - f(x)_{d,i})^2} \tag{7}$$

評価には n 日分のセンサデータを用い，n 日分の $RMSE_d$ の平均値 $RMSE_{avg}$ をその手法における復元精度とした．本検証では $n = 10$ と設定した．

$$RMSE_{avg} = \frac{1}{n}\sum_{d=1}^{n} RMSE_d \tag{8}$$

5.　評価結果

本章では，以下の 2 点の結果を説明する．

- サンプリングにおけるパラメータ探索
- センサの稼働制限にともない欠損が生じたセンサログの復元精度

5.1　サンプリング頻度のパラメータ探索

図 5 に，加速度，ジャイロの 2 センサを同時に稼働させ

© 2020 Information Processing Society of Japan

表 1 加速度センサログの復元精度（$T = 10$）
Table 1 Reconstruction accuracy of accelerometer values ($T = 10$).

Method	RMSE		
	x 軸	y 軸	z 軸
spline（0 次）	1.18	1.68	8.17
spline（1 次）	2.00	1.19	3.19
spline（2 次）	2.56	3.58	7.58
spline（最近傍点）	2.02	1.82	2.87
SDA_normal	0.39	0.42	1.44*
SDA_average	0.38*	0.40	1.40*
SDA_hybrid	**0.37***	**0.38***	**1.28***

表 2 加速度センサログの復元精度（$T = 30$）
Table 2 Reconstruction accuracy of accelerometer values ($T = 30$).

Method	RMSE		
	x 軸	y 軸	z 軸
spline（0 次）	3.04	3.22	8.33
spline（1 次）	4.40	4.14	4.04
spline（2 次）	236.85	78.94	131.82
spline（最近傍点）	4.53	4.31	4.21
SDA_normal	2.50	2.37	3.35
SDA_average	1.72*	1.48*	3.21
SDA_hybrid	**1.55***	**1.37***	**2.14***

表 3 加速度センサログの復元精度（$T = 60$）
Table 3 Reconstruction accuracy of accelerometer values ($T = 60$).

Method	RMSE		
	x 軸	y 軸	z 軸
spline（0 次）	3.35	3.33	8.42
spline（1 次）	4.73	4.56	4.56
spline（2 次）	292.79	195.77	192.77
spline（最近傍点）	5.24	4.96	4.79
SDA_normal	2.41	2.42	3.62
SDA_average	**2.31**	2.40	3.51
SDA_hybrid	2.43	**2.39**	**3.46**

表 4 ジャイロセンサログの復元精度（$T = 10$）
Table 4 Reconstruction accuracy of gyro sensor values ($T = 10$).

Method	RMSE		
	x 軸	y 軸	z 軸
spline（0 次）	0.22	0.23	0.21
spline（1 次）	0.18	0.25	0.22
spline（2 次）	7.71	12.67	7.20
spline（最近傍点）	0.22	0.23	0.22
SDA_normal	0.19	0.20	0.20
SDA_average	0.12*	0.17	0.19
SDA_hybrid	**0.11***	**0.11***	**0.12***

表 5 ジャイロセンサログの復元精度（$T = 30$）
Table 5 Reconstruction accuracy of gyro sensor values ($T = 30$).

Method	RMSE		
	x 軸	y 軸	z 軸
spline（0 次）	0.24	0.27	0.31
spline（1 次）	0.26	0.30	0.24
spline（2 次）	56.72	76.12	58.74
spline（最近傍点）	0.28	0.26	0.33
SDA_normal	0.22	0.27	0.22
SDA_average	0.15*	0.14*	0.15*
SDA_hybrid	**0.13***	**0.12***	**0.12***

表 6 ジャイロセンサログの復元精度（$T = 60$）
Table 6 Reconstruction accuracy of gyro sensor values ($T = 60$).

Method	RMSE		
	x 軸	y 軸	z 軸
spline（0 次）	0.62	0.59	0.62
spline（1 次）	0.52	0.57	0.49
spline（2 次）	91.52	85.13	88.65
spline（最近傍点）	0.61	0.61	0.59
SDA_normal	0.46	0.45	0.49
SDA_average	0.48	0.44	0.46
SDA_hybrid	**0.40**	**0.41**	**0.43**

た場合のバッテリ残量の変化を示す．縦軸はスマートフォンから取得したバッテリ残量 [%]，横軸は時間 [sec] を表しており，常時センサを稼働させた場合と，$T = 10, 30, 60$ [分] の時間幅でセンサを制御したそれぞれの場合におけるバッテリ残量の変化を表している．この結果から，センサのサンプリングの時間幅が大きいほど消費電力を削減できていることが確認された．2 センサを常時稼働させた場合のバッテリ残量を基準として，$T = 10$ [分] で ON/OFF 状態を切り替え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，$T = 30$ [分] の時間幅で 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，$T = 60$ [分] 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かかわらず，サンプリングの時間幅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．$T = 10$ [分] の時間幅で 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．

サンプリングにおける時間幅とログの復元精度はトレードオフの関係にあり，センサを OFF にする時間を長く設定するほど，スマートフォンの消費電力を低減することが

© 2020 Information Processing Society of Japan

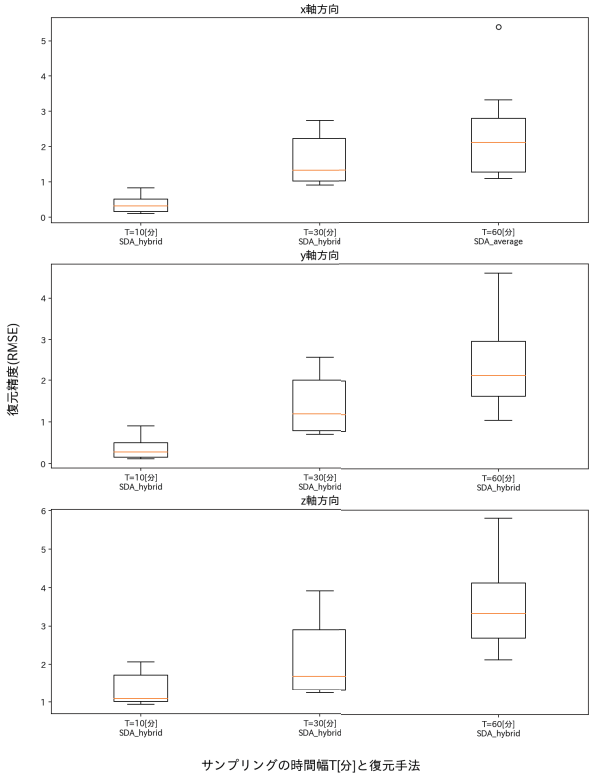

図 6　加速度センサにおけるサンプリングの時間幅と復元精度（上段：x 軸，中段：y 軸，下段：z 軸）

Fig. 6　Reconstruction accuracy of accelerometer values at different sampling time interval.

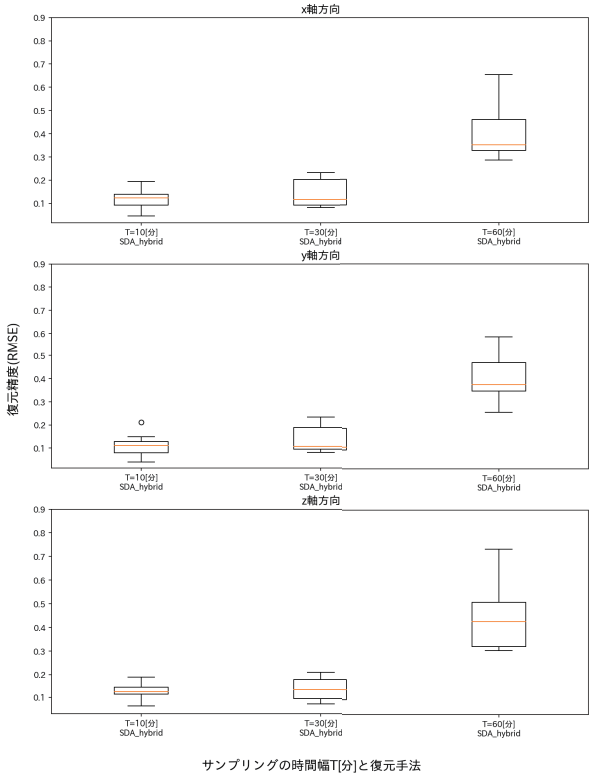

図 7　ジャイロセンサにおけるサンプリングの時間幅と復元精度（上段：x 軸，中段：y 軸，下段：z 軸）

Fig. 7　Reconstruction accuracy of gyro sensor values at different sampling time interval.

可能だが，元ログの復元精度は悪化することが想定される．本研究では，サンプリングの時間幅 T を $T = 10, 30, 60$ [分] と設定し，それぞれの場合におけるセンサログの復元精度を検証する．

5.2　センサログの復元精度

加速度センサに関して，$T = 10, 30, 60$ [分] の時間幅でサンプリングした各軸方向のログに対する復元精度を**表 1**，**表 2**, **表 3** に示す．同様にジャイロセンサに関して, $T = 10, 30, 60$ [分] の時間幅でサンプリングした各軸方向のログに対する復元精度を**表 4**，**表 5**，**表 6** に示す．

ここで，既存手法である Spline 補間の中で最も復元精度が良い結果を $RMSE_{spline}$，提案手法における $RMSE$ を $RMSE_{proposed}$ と表現するとき，表中の $*$ は，$RMSE_{spline}$ に対して $RMSE_{proposed}$ が有意水準 5%で有意な差があることを示す．なお，提案手法は SDA_{normal}，$SDA_{average}$，SDA_{hybrid} の各手法を指す．また，既存手法に対する提案手法の復元精度の改善値 R [%] を式 (9) により算出する．

$$R = \left(1 - \frac{RMSE_{proposed}}{RMSE_{spline}}\right) \times 100 \qquad (9)$$

加速度センサの復元精度に関して，表 1–3 より $T = 10, 30$ [分] の時間幅でサンプリングした場合，提案手法はいずれの軸方向においても既存手法に対して優位な結果となっている．$T = 10$ [分] でサンプリングした場合，復元精度の改善値 R は x，y，z 軸方向それぞれに対して 68.64%，68.07%，55.40%となった．同様に $T = 30$ [分] でサンプリングした場合，復元精度の改善値 R は x，y，z 軸方向それぞれに対して 49.01%，57.45%，47.03%となった．一方で，$T = 60$ [分] でサンプリングした場合には，既存手法に対して優位な結果は得られなかった．

ジャイロセンサの復元精度に関して，表 4–6 より $T = 10, 30$ [分] の時間幅でサンプリングした場合，提案手法はいずれの軸方向においても既存手法に対して優位な結果となっている．$T = 10$ [分] でサンプリングした場合，復元精度の改善値 R は x，y，z 軸方向それぞれに対して 38.89%，52.18%，42.86%となった．同様に $T = 30$ [分] でサンプリングした場合，復元精度の改善値 R は x，y，z 軸方向それぞれに対して 45.83%，53.85%，50.00%となった．一方で，$T = 60$ [分] でサンプリングした場合には，既存手法に対して優位な結果は得られなかった．

また，$T = 10$ における z 軸方向加速度センサのログを除いて，SDA_{normal} を用いた復元精度は，既存手法と比較して有意な差は確認できなかった．$SDA_{average}$ が SDA_{normal} よりも精度良くセンサログを復元できた理由として，SDA_{normal} では補間対象期間の直前のログの変化のみを考慮した補間となっているのに対して，$SDA_{average}$

© 2020 Information Processing Society of Japan

では，補間対象期間の直前直後におけるログの変化を考慮しているため，スマートフォンの状態をより正確にとらえることができているためだと考えられる．たとえば，t_{i-1} と t_{i+1} においてユーザが歩行中であるときに，t_i においてもユーザが歩行状態である可能性が高い．そのため，本提案手法のように補間対象期間の前後のログを用いることで，その時点でのユーザ状態を考慮した補間が可能となり，線形補間のような補間対象期間の前後のデータ点のみを基に補間している従来手法よりも，精度良くログを復元することができたと考えている．また，SDA のみを用いた予測では，図 4 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復元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復元精度の向上が確認された．

5.3 センサログの復元精度と消費電力のトレードオフ

5.1 節で示したサンプリングにおける時間幅と消費電力の関係性，および 5.2 節で示した復元精度の評価結果を基に，センシングにおける消費電力を削減しつつ，かつ精度良く間欠的測定センサデータを復元することが可能なサンプリングの時間幅 T は $T = 30$ [分] であると結論づける．

図 5 に示したように，サンプリングの時間幅 T を大きくすることで，センシングにおける消費電力を削減できる一方で，**図 6**，**図 7** に示すように，T が大きくなるにつれてセンサログの復元精度の劣化が課題となり，$T = 60$ [分] の場合，本提案手法では既存手法に対して優位な差を示すことができていない．一方で，$T = 10, 30$ [分] の場合には，既存手法に対して優位な復元精度を示すことができている．ただし，$T = 10$ [分] の場合には消費電力の削減量が約 15%にとどまっており，序章で述べたとおり，ユーザにはスマートフォン上で実行したいメインのタスクが存在しており，そのような状況下では，限られた電池容量の中でセンシングに消費する電力を抑える必要がある．$T = 30$ [分] の場合には，約 40%消費電力を削減することが可能であり，かつ，既存手法に対して優位な復元精度が得られている．特にジャイロセンサに関して，$T = 10, 30$ [分] のいずれの時間幅でサンプリングした場合にも同程度の復元精度が示されていることから，本提案手法では時間幅 $T = 30$ [分] でサンプリングし，復元を行うことが最適だと判断した．

6. まとめ

本研究では，サンプリングされた少数のセンサログから元のセンサログを精度良く復元することを目的とした．10 分，30 分，60 分の時間幅でサンプリングしたログに対して，本研究の提案手法である SDA を用いた復元手法を適用することで，10 分，30 分の時間幅でサンプリングした加速度センサ，ジャイロセンサの各センサにおいて，従来手法である spline 補間よりも精度良くセンサログを復元することが可能であると示された．

一方で，スマートフォンの消費電力の観点からは，センサが OFF 状態の時間を長期的に確保することが省電力化に効果的であることが示された．センサログの復元精度と消費電力の両観点から，本研究では 30 分の時間幅でセンサの ON/OFF 状態を切り替えることが最も効果的であると結論づけた．

本研究で提案したセンサログの復元手法は，センサの稼働を抑制することによって減少したセンサログから元のログを復元する手法であるため，特定の行動認識に特化したものではなく，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．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良く復元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，より精度良く元のログを復元することが可能になると考えている．

参考文献

[1] Chen, L., Hoey, J., Nugent, C.D., Cook, D.J. and Yu, Z.: Sensor-based activity recognition, *IEEE Trans. Systems, Man, and Cybernetics, Part C* (*Applications and Reviews*), Vol.42, No.6, pp.790–808 (2012).

[2] Shoaib, M., Bosch, S., Incel, O., Scholten, H. and Havinga, P.: A survey of online activity recognition using mobile phones, *Sensors*, Vol.15, No.1, pp.2059–2085 (2015).

[3] Ong, A.A. and Gillespie, M.B.: Overview of smartphone applications for sleep analysis, *World Journal of Otorhinolaryngology-head and Neck Surgery*, Vol.2, No.1, pp.45–49 (2016).

[4] Mehrotra, A., Hendley, R. and Musolesi, M.: PrefMiner: mining user's preferences for intelligent mobile notification management, *Proc. 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp.1223–1234, ACM (2016).

[5] Rabbi, M., Ali, S., Choudhury, T. and Berke, E.: Passive and in-situ assessment of mental and physical well-being using mobile sensors, *Proc. 13th International Conference on Ubiquitous Computing*, pp.385–394, ACM (2011).

[6] Lockhart, J.W., Pulickal, T. and Weiss, G.M.: Applications of mobile activity recognition, *Proc. 2012 ACM Conference on Ubiquitous Computing*, pp.1054–1058, ACM (2012).

[7] Yamamoto, N., Ochiai, K., Inagaki, A., Fukazawa, Y., Kimoto, M., Kiriu, K., Kaminishi, K., Ota, J., Okimura, T., Terasawa, Y., et al.: Physiological Stress Level Estimation Based on Smartphone Logs, *Proc. 2018 Eleventh International Conference on Mobile Computing and Ubiquitous Network* (*ICMU*), IEEE, pp.1–6 (2018).

[8] 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

© 2020 Information Processing Society of Japan

手法，情報処理学会論文誌，Vol.52, No.8, pp.2455–2466 (2011).
[9] Akimura, D., Kawahara, Y. and Asami, T.: Compressed sensing method for human activity sensing using mobile phone accelerometers, *2012 9th International Conference on Networked Sensing* (*INSS*), pp.1–4, Citeseer (2012).
[10] Lustig, M., Donoho, D. and Pauly, J.M.: Sparse MRI: The application of compressed sensing for rapid MR imaging, *Magnetic Resonance in Medicine: An Official Journal of the International Society for Magnetic Resonance in Medicine*, Vol.58, No.6, pp.1182–1195 (2007).
[11] Hinton, G.E. and Salakhutdinov, R.R.: Reducing the dimensionality of data with neural networks, *Science*, Vol.313, No.5786, pp.504–507 (2006).
[12] Kumar, D., Wong, A. and Clausi, D.A.: Lung nodule classification using deep features in CT images, *2015 12th Conference on Computer and Robot Vision*, pp.133–138, IEEE (2015).
[13] Wang, L.: Recognition of human activities using continuous autoencoders with wearable sensors, *Sensors*, Vol.16, No.2, p.189 (2016).
[14] 高橋　柊，落合桂一，深澤佑介：Stacked Convolutional Denoising Autoencoders を用いた 2 誘導心電図からの特徴抽出および不整脈分類，情報処理学会論文誌，Vol.59, No.12, pp.2213–2220 (2018).
[15] 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, pp.1866–1875 (2014).
[16] 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, pp.587–597 (2014).
[17] 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（ACS），Vol.7, No.1, pp.23–34 (2014).
[18] Liu, J., Musialski, P., Wonka, P. and Ye, J.: Tensor completion for estimating missing values in visual data, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.35, No.1, pp.208–220 (2012).
[19] Gandy, S., Recht, B. and Yamada, I.: Tensor completion and low-n-rank tensor recovery via convex optimization, *Inverse Problems*, Vol.27, No.2, p.025010 (2011).
[20] Hu, Y., Zhang, D., Ye, J., Li, X. and He, X.: Fast and accurate matrix completion via truncated nuclear norm regularization, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.35, No.9, pp.2117–2130 (2012).
[21] Wang, H., Nie, F. and Huang, H.: Low-rank tensor completion with spatio-temporal consistency, *28th AAAI Conference on Artificial Intelligence* (2014).
[22] Savvaki, S., Tsagkatakis, G., Panousopoulou, A. and Tsakalides, P.: Matrix and tensor completion on a human activity recognition framework, *IEEE Journal of Biomedical and Health Informatics*, Vol.21, No.6, pp.1554–1561 (2017).
[23] Xie, K., Wang, L., Wang, X., Xie, G., Wen, J., Zhang, G., Cao, J., Zhang, D., Xie, K., Wang, X., et al.: Accurate recovery of internet traffic data: A sequential tensor completion approach, *IEEE/ACM Trans. Networking* (*TON*), Vol.26, No.2, pp.793–806 (2018).
[24] 北川源四郎：時系列解析入門 (2005).
[25] Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y. and Manzagol, P.-A.: Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion, *Journal of Machine Learning Research*, Vol.11, No.Dec, pp.3371–3408 (2010).
[26] Vincent, P., Larochelle, H., Bengio, Y. and Manzagol, P.-A.: Extracting and composing robust features with denoising autoencoders, *Proc. 25th International Conference on Machine Learning*, pp.1096–1103, ACM (2008).
[27] 森口繁一：数値計算工学 (1989).

山本 直樹

2014 年金沢大学理工学域電子情報学類卒業．2016 年同大学院自然科学研究科電子情報科学専攻博士前期課程修了．同年株式会社 NTT ドコモ入社，サービスイノベーション部所属（～現在）．スマートフォンを用いたユーザ状態認識，モバイルヘルスケアに関する研究開発に従事．

落合 桂一　（正会員）

2006 年千葉大学工学部情報画像工学科卒業．2008 年同大学院博士前期課程修了．同年株式会社 NTT ドコモ入社．2017 年東京大学大学院工学系研究科技術経営戦略学専攻博士後期課程修了．博士（工学）．SNS や位置情報，ヘルスケアデータやスマートフォンログ解析の研究開発に従事．ACM，日本データベース学会，人工知能学会各会員．

稲垣 章弥

2015 年東京工業大学大学院理工学研究科機械宇宙システム専攻博士前期課程修了．同年株式会社 NTT ドコモ入社．商品企画，マーケティング業務に従事．

神山 剛　（正会員）

NTT ドコモ IoT ビジネス部勤務．2003 年（株）イージス代表取締役，2006 年同社退社，東京大学新領域創成科学研究科修士課程修了を経て，同年（株）NTT ドコモ入社．先進技術研究所（～2016 年），サービスイノベーション部（～2017 年），IoT ビジネス部（～現在）にて，モバイルコンピューティング，ソフトウェア省電力化，分散システム，ユーザ行動センシング，次世代交通需要予測に関する研究開発に従事．博士（工学），九州大学客員准教授．

© 2020 Information Processing Society of Japan

深澤 佑介　（正会員）

2002 年東京大学工学部卒業．2004 年同大学院工学系研究科修士課程修了．同年株式会社 NTT ドコモ入社．2011 年東京大学大学院工学系研究科博士後期課程修了．同年 10 月より東京大学人工物工学研究センターにて協力研究員，2017～2019 年客員研究員兼任．機械学習・時空間分析・深層学習のビジネス活用およびモバイルヘルスケアに関する研究開発を行っている．IEEE，電子情報通信学会，人工知能学会各会員．博士（工学）．

© 2020 Information Processing Society of Japan