

## 骨格センシングを用いた宅内身体活動の品質づけ手法の提案

陳 思楠<sup>†</sup> 佐伯 幸郎<sup>†</sup> 中村 匡秀<sup>†,††</sup>

<sup>†</sup> 神戸大学 〒657-8501 神戸市灘区六甲台町 1-1

<sup>††</sup> 理化学研究所・革新知能統合研究センター 〒103-0027 東京都中央区日本橋 1-4-1

E-mail: <sup>†</sup>chensinan@ws.cs.kobe-u.ac.jp, <sup>††</sup>sachio@carp.kobe-u.ac.jp, <sup>†††</sup>masa-n@cs.kobe-u.ac.jp

あらまし 近年、高齢化社会で在宅介護への転換が進む中、宅内の身体活動をいかに継続するかが健康寿命の延伸に重要である。特に高齢者の場合、自宅での身体活動の量は廃用症候群や認知症の兆候を把握する重要な指標である。本研究では、宅内居住者の身体活動の量を簡便かつ非侵襲的に計測し、身体活動の質的な評価につなげることを目的とする。具体的には、定点カメラで宅内の映像を撮影し、骨格センシングによって居住者の骨格のみを抽出し、特徴点の座標を時系列データとして蓄積する。座標の時系列から居住者の姿勢や位置などの変化量を計算し、身体活動の量を性質づける手法を検討する。提案手法は、従来技術のようにウェアラブル機器を必要とせず、オリジナルの宅内映像を蓄積しないため、非侵襲的に身体活動のセンシングが達成できる。提案手法を姿勢推定機械学習モデル PoseNet を用いて試作し、体の境界領域と 17 の特徴点の座標をリアルタイムに検出し、データベースに蓄積した。蓄積したデータを分析し、座っている、立っている、歩いているなどの基本的な骨格の動き、姿勢の変化、位置の移動の定量化が可能であることを確認した。さらに、メッツなどの標準的な活動スケールとの関連付けも考察し、提案手法の具体的な応用も展望した。

キーワード 在宅介護, 身体活動, 映像, PoseNet, 骨格センシング

## Characterizing Quality of In-home Physical Activities Using Bone-based Human Sensing

Sinan CHEN<sup>†</sup>, Sachio SAIKI<sup>†</sup>, and Masahide NAKAMURA<sup>†,††</sup>

<sup>†</sup> Kobe University Rokkodai-cho 1-1, Nada-ku, Kobe, Hyogo 657-8501 Japan

<sup>††</sup> Riken AIP 1-4-1 Nihon-bashi, Chuo-ku, Tokyo 103-0027 Japan

E-mail: <sup>†</sup>chensinan@ws.cs.kobe-u.ac.jp, <sup>††</sup>sachio@carp.kobe-u.ac.jp, <sup>†††</sup>masa-n@cs.kobe-u.ac.jp

**Abstract** In recent years, with the conversion to home care in the aging society, it is significant for extending healthy life span on how to continue physical activities at home. Especially, to comprehend signs of disuse atrophy and dementia of the elderly, the physical activity amount at home is an important index. The goal of this study is to measure the physical activity amount of residents in a simple, non-invasive manner, and to connect it with the qualitative evaluation of physical activities at home. More specifically, we capture the in-home real-time video with a fixed-point camera, extract the bone data of a resident using the bone sensing techniques, and accumulate solely the coordinate of feature points as the time-series data. We examine a method to characterize the physical activity amount, which calculates the amount of change from the coordinate data on time series, such as the posture and position of residents. It does not require the wearable devices in the proposed method. The non-invasive physical activity sensing can be achieved since the original in-home video is not accumulated. We first used the machine learning model PoseNet for the pose estimation, which detected the coordinates of the body boundary area and 17 feature points in real-time. We then analyzed the accumulated data, to checked the possible with the quantitation of the basic bone movements, posture changes, and position movements. Such as sitting, standing, and walking. Furthermore, we also discussed the association with standard activity scales (ex., METs), and looked ahead to the specific application of the proposed method.

**Key words** Home care, Physical activities, Video, PoseNet, Bone sensing

## 1. はじめに

近年、日本やイタリア、ドイツをはじめとする先進国では、高齢化社会の進行に伴い、人口や社会、疾病の構造が変化し、要介護者の数も年々増加している。医療・福祉の現場では、施設・人材の慢性的な不足が起こっており、施設介護から在宅介護への転換が進む中、宅内の身体活動をいかに継続するかが居住者の健康寿命の延伸に対する重要なポイントである。特に高齢者の場合、自宅での日常生活における身体活動の量は、廃用症候群 [1] や認知症など、身体・精神症状が増悪するといった悪循環に陥る兆候を把握する重要な指標である。

従来の身体活動の計測・評価に関する研究では、センシングデバイスとして加速度、心拍数などのセンサを利用する手法や QOL または IADL に関わる質問紙法が一般である。例えば、身体装着型加速度センサを利用した身体活動の測定 [2] や身体活動質問票を用いた健康関連要因の評価 [3] など、様々なセンサや手法を活用し、身体活動の計測・評価を実現している。しかし、これらの既存手法において、身体への侵襲性やコストの負担があり、個人差や活動時間に曖昧さもあるため、身体活動の評価を宅内で実施するのは煩雑である。本研究では、宅内居住者の身体活動の量を簡便かつ非侵襲的に計測し、身体活動の質的な評価につなげることを目的とする。そのためのアプローチとして、まず宅内身体活動の評価手法を提案し、次に提案手法の有効性を評価するための実験を行う。

提案手法では、まず一部屋の片隅の高い所に定点カメラを設置し、宅内の映像をリアルタイムに読み込む。次に、骨格センシング技術を用い、読み込んである実映像から居住者の骨格データのみを一定間隔で抽出し、骨格における特徴点の座標を時系列データとしてローカルのデータベースに蓄積する。蓄積した座標データの時系列から居住者の姿勢や位置などの変化量を計算し、身体活動の量を性質づける手法を検討する。提案手法は、従来技術のようにウェアラブル機器を必要とせず、オリジナルの宅内映像を蓄積しないため、非侵襲的に身体活動のセンシングが達成できる。

評価実験では、実験場所とする独居者の宅内の一部屋で USB カメラを設置した、提案手法を姿勢推定機械学習モデル PoseNet [4] を用いて試作し、居住者の体の境界領域と 17 の特徴点の座標をリアルタイムに 1 秒ずつ検出し、ローカルの MongoDB に蓄積した。実験期間を 7 日とし、それぞれの日の朝 8 時から晩 20 時までのデータをデータベースから抽出した。座っている、立っている、歩いているなどの基本的な骨格の動き、姿勢の変化、位置の移動を計測するため、PoseNet モデルの出力結果における境界領域の横幅と縦幅、および左右足の中心座標  $xy$  それぞれの時刻前後の差分を計算し、1 分間ずつの差分変化の平均値をグラフ化した。

実験における主要な結果に関し、4 日目と 5 日目および 7 日目の宅内身体活動の量がより小さく、1 日目と 2 日目および 6 日目の宅内身体活動の量がより大きいことがわかった。これらの骨格の計測手法と METs [5] や PASE [6] などの標準的な活動スケールの紙媒体での評価と連携し、宅内の活動内容だけで

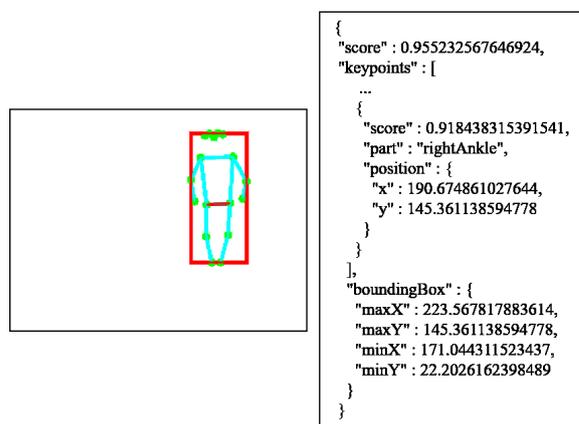


図 1 USB カメラとブラウザを用いた PoseNet モデルの出力例

なく、それぞれ同じ活動内容による異なる質的評価もでき、在宅生活中の様々な疾病の兆候を把握することが期待できる。

## 2. 準備

### 2.1 宅内身体活動の定義

宅内の身体活動とは、安静にしている状態より多くのエネルギーを消費し、日常生活における生活活動や健康維持のための運動を指す。基本的な家事の以外に、疾患の予防や健康寿命の延伸のためには、宅内での身体活動の量を短時間で増加することだけでなく、長い時間帯や生活その自体の中に、一定強度の活動量を確保することが必要である。例えば、骨格や筋肉、関節を活動するためにラジオ体操を宅内で行う。また、一定間隔で立ち座りなどの姿勢の変化や歩行での位置の移動も不可欠である。

### 2.2 身体活動の評価のチャレンジ

身体活動の量的・質的評価には 2 つのチャレンジ課題があると考えられる。1 つ目は身体活動の内容と量の評価結果を完全に一致することが難しい。物理的な装置を利用し、身体活動の量をデータ化することができるが、その内容に対し、身体活動の量の評価には、その動きをする際に温度など外部環境の要因が身体活動の強度に影響を与え、その内容のみに対する評価結果との差別がある。2 つ目は身体活動と健康の要素との関連づけが複雑である。個人差や過去のカルテなどを参考し、独立の身体活動の量的・質的の標準が必要とされる。

### 2.3 機械学習に基づく骨格センシング

近年、機械学習オープンソースの積極的な開発に伴い、様々な骨格センシング技術が登場している。OpenPose [7] を代表とする深層学習を用いた骨格センシングと異なり、昨今では姿勢推定機械学習モデル PoseNet [8] や BodyPix [9] が開発され、機械学習ライブラリ TensorFlow [10] の JavaScript バージョンと統合でき、カメラデバイスとブラウザを用い、より些少な計算資源でリアルタイムな骨格センシングが実施可能である。図 1 に USB カメラとブラウザを用いた PoseNet モデルの出力例を示す。PoseNet モデルの出力内容の中、骨格センシングの精度や身体における 17 部位の座標を含まれ、人間の境界領域の座標も検出できる。本稿では、この技術をスマートホームにおける宅内の身体活動量の計測・評価に使うことを考える。

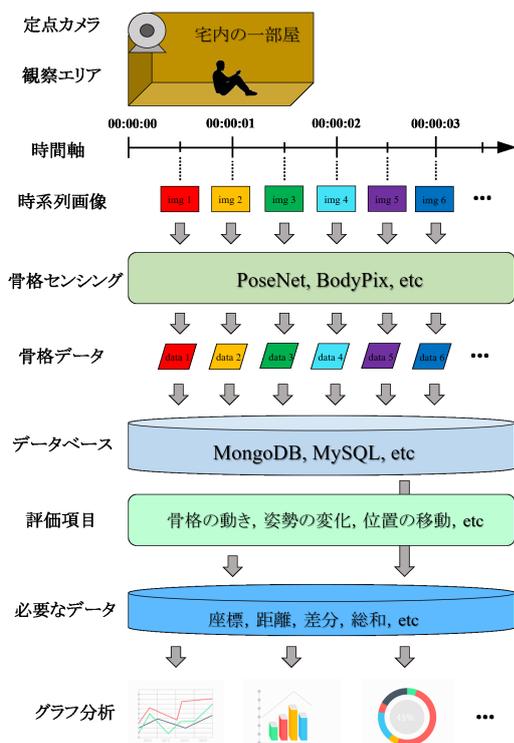


図 2 宅内身体活動の評価のための提案手法の全体アーキテクチャ

### 3. 宅内身体活動の評価手法の提案

#### 3.1 目的

これまでの宅内身体活動の評価に関する研究では、ウェアラブルセンサ[11]の利用に伴う対象者の身体への侵襲性が存在し、身体活動の計測に必要とされる一般装置に対し、コストの負担がある。さらに、質問紙法を用いる場合、回答内容の妥当性に個人差が存在し、記述の漏れや活動時間に曖昧さもあることで、それぞれの被験者の身体活動の量に対する質的な評価に複雑な要因を与えられる。これらの課題を改善するため、本章では宅内居住者の身体活動の量を簡便かつ非侵襲的に計測する手法を提案し、身体活動の質的な評価につなげることを目的とする。

#### 3.2 全体アーキテクチャ

本稿で提案する宅内身体活動の評価手順は 3.3 と 3.4 に述べる。図 2 に宅内身体活動の評価のための提案手法の全体アーキテクチャを示す。主要な内容としては、定点カメラで宅内の映像を読み込み、骨格センシングによって居住者の骨格のみを抽出し、特徴点の座標を時系列データとして蓄積する。座標の時系列から居住者の姿勢や位置などの変化量を計算し、グラフ化した身体活動の量を性質づける。

#### 3.3 宅内骨格データの収集

##### Step1-1: 時系列画像の読み込み

観測対象者がいる宅内の一部屋に、まず USB カメラなど、画像を撮影可能なデバイスを設置し、時系列画像いわゆる実映像を読み込まれるプログラムを作成する。

##### Step1-2: 骨格センシングの呼び出し

Step1-1 で作成したプログラムの内容中に、まず適当な時間間

表 1 実験情報

実験場所	宅内の一部屋
データ蓄積期間	7日
撮影道具	USB カメラ
被験者情報	20代男性 1人
画像読み込み	HTML, JavaScript
骨格センシング	PoseNet モデル
データ転送	jQuery, Ajax
蓄積データベース	MongoDB
評価項目数	3

隔を設定する。次に、設定した時間間隔に従い、Step1-1 で読み込んだ実映像から、画像データを取得して保存せずに、自動的に骨格センシング技術に入力する。ここで、骨格センシング技術は TensorFlow を用いた PoseNet モデルや BodyPix モデルを含まれる。

##### Step1-3: 骨格データの取得と蓄積

Step1-2 によって、まず時系列画像における骨格センシングの出力値を取得する。次に、取得した骨格センシングの出力値と出力時刻の情報を統合し、ローカルのデータベースに転送する。ここで、データベースは MongoDB や MySQL を含まれる。

#### 3.4 宅内身体活動の評価

##### Step2-1: 身体活動の評価項目の定義

観測対象者の身体活動の量を計測するため、評価したい  $m$  個の項目  $I = \{i_1, i_2, \dots, i_m\}$  を定義する。例えば、対象者が座っている、立っている、歩いているなど、骨格の動きや姿勢の変化、位置の移動などを評価項目とすることが可能である。

##### Step2-2: 必要なデータの抽出と整理

評価期間を決定し、Step2-1 の各評価項目  $i_j$  ( $i_j \in I, 1 \leq j \leq m$ ) に対し、3.3 の Step1-3 で蓄積したデータベースから、必要なデータを抽出し、データの整理と計算を行う。例えば、関連する座標や時刻のデータを整理し、さらに、座標間の距離、2つの座標間になる線の斜率などのデータを計算する。

##### Step2-3: データのグラフ分析

Step2-2 で整理・計算したデータと時間軸を結合し、評価期間内における各評価項目  $i_j$  のグラフ分析を行う。例えば、1週間のデータを抽出・整理し、外出や睡眠などを除き、観測対象者の骨格の動きや姿勢の変化、位置の移動などが折れ線や円の様式にグラフ化できる。それに基づき、身体活動の量を評価することも検討できる。

#### 4. 評価実験

3. で提案した評価手法に基づき、実際の環境下で読み込んだ時系列画像をもとに評価実験を行う。表 1 に実験情報を示す。

##### 4.1 宅内骨格データの収集

本実験では、提案手法の有効性を評価するため、まず 20 代の男性 1 人が常に存在する宅内の一部屋を実験場所とし、部屋の片隅の高い所に USB カメラを設置し、撮影角度を適当に調整した。次に、HTML や JavaScript 言語を利用し、ブラウザから USB カメラを自動的に起動し、実験における時系列画像い

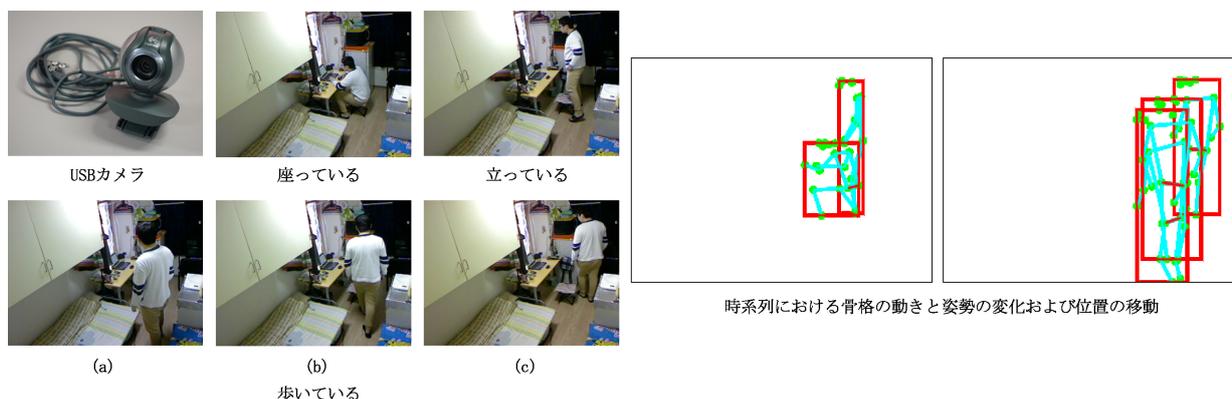


図 3 本実験における USB カメラと時系列画像の骨格センシングの代表例

いわゆる実映像をブラウザ内に読み込まれるプログラムを作成した。そして、作成したプログラム内容の中、1秒の時間間隔を設定した。読み込んでいる実映像から、1秒ずつに画像データを取得して保存せずに、PoseNet モデルの骨格センシングに入力した。さらに、jQuery や Ajax の手法を利用し、PoseNet モデルの出力値と出力時刻の情報を統合し、リアルタイムにローカルの MongoDB にデータを転送した。

## 4.2 宅内身体活動の評価

### 4.2.1 評価項目の定義

本実験では、宅内身体活動の品質づけ手法を実現するため、座っている、立っている、歩いているなどの基本的な骨格の動き、姿勢の変化、および位置の移動を評価項目とし、2020年4月13日から19日までの7日間のデータをデータベースから抽出し、それぞれの日の朝8時から晩20時までのデータの分析を行った。これら3つの評価項目に対し、具体的な内容を以下の節に述べる。図3に本実験におけるUSBカメラと時系列画像の骨格センシングの代表例を示す。

### 4.2.2 骨格の動き

宅内居住者の骨格の動きに関し、主に手や腕など関節の動きを指すと想定し、骨格の動きに伴う境界領域の横幅の変化を宅内身体活動の評価項目の一つとした。

### 4.2.3 姿勢の変化

宅内居住者の姿勢の変化に関し、本実験では主に立ち座りの姿勢を注目し、それに伴う境界領域の縦幅の変化を宅内身体活動の評価項目の一つとした。

### 4.2.4 位置の移動

宅内居住者の位置の移動に関し、検出された任意の骨格特徴点の座標  $x$   $y$  を注目し、位置の移動に伴う  $x$   $y$  それぞれ数値の変化を宅内身体活動の評価項目の一つとし、本実験では検出された左右足の midpoint 座標の変化を分析対象とした。

### 4.2.5 データのグラフ化分析

実験期間で収集したデータから、骨格の動き、姿勢の変化および位置の移動との3つの評価項目に必要なデータを整理し、それぞれ時系列データの時刻前後の差分を計算した。さらに、時系列データを平滑化する手法を利用し、それぞれ1分間ずつの差分の平均値を算出してグラフ化した。

## 4.3 実験結果

### 4.3.1 各実験日の評価項目の時系列データの結果

図4に本実験における各実験日の評価項目の時系列データを示す。図4の結果から、実験期間7日におけるそれぞれのグラフの中に骨格の動き、姿勢の変化、および位置の移動の各時間帯の変化を評価する。

骨格の動きに関し、1日目の16-19時により大きい骨格の動きの量があり、2日目の18時以降には骨格の動きの量がより小さかった。3日目の12-19時にわずかな骨格の動きの量が変化し、19時以降に骨格の動きの量の増加があった。4日目の14時以降の骨格の動きの量がより増加の傾向があり、5日目の10時以降には顕著な骨格の動きの量が小さかった。6日目の10-15時と18時以降の骨格の動きの量の変化が明らかであり、7日目の11時と12時および13時前後の骨格の動きの量があることがわかった。

姿勢の変化に関し、1日目の18時前後に一瞬で姿勢の変化の量が急増し、13-14時と16-17時により大きい姿勢の変化の量があり、14-16時には姿勢の変化の量が小さかった。2日目の11時半前後には姿勢の変化の量の増減が顕著であり、12-17時に姿勢の変化の量が小さかった。3日目の8時半と10時半、12時、14時、17時、18時および20時前後に姿勢の変化の量が大きかった。4日目の10時半、14時半、17時半、18時半の前後および19-20時に姿勢の変化の量が大きかった。5日目の8-9時と9時半-10時半、16時半-17時には、姿勢の変化の量がより顕著であった。6日目の9時-10時半と13-14時、17-19時に姿勢の変化の量が小さかった。7日目の8-20時に姿勢の変化の量が全体的に小さいことがわかった。

位置の移動に関し、1日目の19時前後に被験者がカメラ撮影範囲外に出ることがあり、9-12時に位置の移動がより大きく、14-16時半までの時間帯に位置の移動の変化の量がより小さかった。2日目の9時半-10時に被験者がカメラ撮影範囲外に出ることがあり、18-19時に位置の移動の変化の量がより小さかった。3日目の8時半と20時前後に被験者のより速いスピードで位置の移動があり、11時半-12時と13時半-14時に被験者がカメラ撮影範囲外に出ることがあった。4日目の16時と17時半、および19-20時までの時間帯に位置の移動の変化の量がより大きかった。5日目の8-9時に位置の移動の変化の

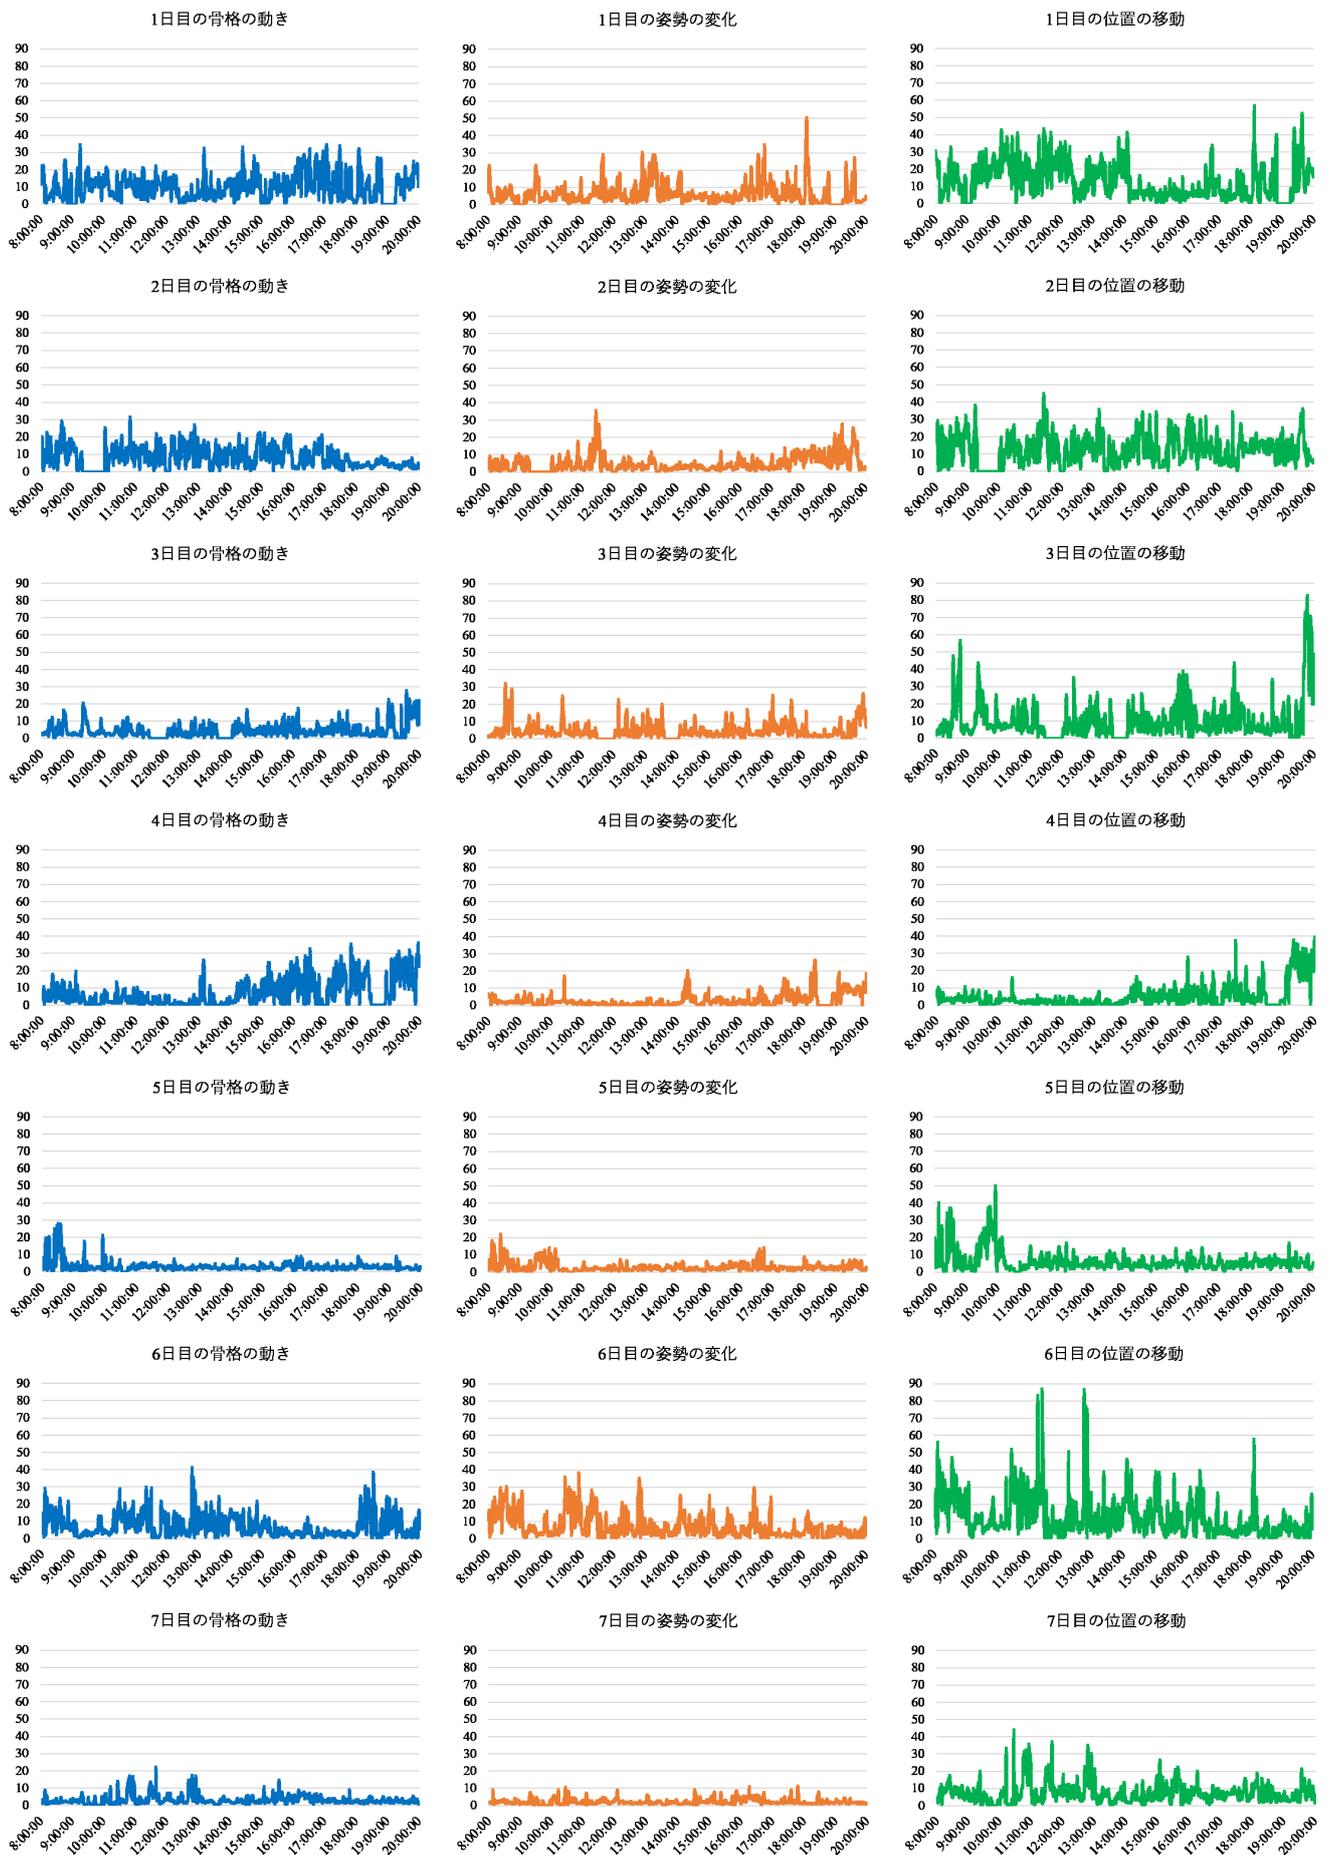


図 4 本実験における各実験日の評価項目の時系列データ

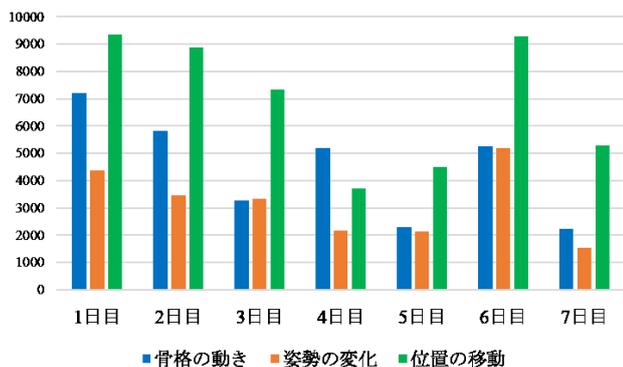


図5 本実験における各実験日の評価項目のデータ総和

量がより大きく、9-10時までの時間帯に位置の移動の変化の量が増加し、それ以外の時間帯により小さかった。6日目の11時半と13時、18時半前後に被験者のより速いスピードで位置の移動があり、9-10時半と17-18時までの時間帯、および18時半-20時に位置の移動の変化の量がより小さかった。7日目の10時半-11時と12時、15時、および16時前後に位置の移動の変化の量がより大きいことがわかった。

#### 4.3.2 各実験日の評価項目のデータ総和の結果

図5に本実験における各実験日の評価項目のデータ総和を示す。図5の結果から、7日間のそれぞれの日の各項目のデータ総和を比較する。骨格の動きに関し、1日目の変化量の総和が最も大きく、7日目の変化量の総和が最も小さかった。姿勢の変化に関し、6日目の変化量の総和が最も大きく、7日目の変化量の総和が最も小さかった。位置の移動に関し、1日目と6日目の変化量の総和が最も大きく、4日目の変化量の総和が最も小さいことがわかった。

#### 4.4 考察

本実験で抽出・整理したグラフの評価結果に関し、4日目と5日目および7日目の宅内身体活動の量がより小さく、長い時間で座っていることが存在すると推察される。これに対し、1日目と2日目および6日目の宅内身体活動の量がより大きいことは、衣服の洗濯や部屋の掃除など基本の家事をする可能性が高い。その一方、骨格の動きと姿勢の変化および位置の移動との3つ項目の間には、ある程度の関連性があると考えられる。姿勢の変化に伴う骨格の動きが存在し、位置の移動に伴うカメラの視角から人間の正面と側面を転換することで、骨格の動きとすることもある。

#### 5. おわりに

本研究では、宅内居住者の身体活動の量を簡便かつ非侵襲的に計測するため、身体活動の質的な評価につなげる手法を提案した。評価実験では、独居者の宅内の一部屋で、定点カメラと機械学習モデル PoseNet を利用し、骨格の動きと姿勢の変化および位置の移動との3つの項目から、7日間の身体活動の量を評価した。主要な結果として、1日目と2日目および6日目の宅内身体活動の量がより大きく、4日目と5日目および7日目の宅内身体活動の量がより小さいことがわかった。

今後の課題として、位置の移動に伴う骨格の動きや姿勢の変化の際に、境界領域の横幅と縦幅の変化基準を求め、その値をより正確に計測するには正規化が不可欠である。さらに、本稿における骨格センシング技術の出力による座標の変化量の評価から、METs や PASE [12] などの標準的な活動スケールとの関連付けには、単純な骨格の検出・計測だけでなく、実際の活動内容も対象者から補助データとして記述する手法も検討する必要があると考える。また、カメラデバイスの設置場所や部屋の明るさ、対象者の着服の色など、骨格センシングの精度に影響する要因もあり、これらの課題も今後解決すべきと考える。

謝辞 本研究の一部は JSPS 科研費 JP19H01138, JP17H00731, JP18H03242, JP18H03342, JP19H04154, JP19K02973 の助成を受けている。

#### 文献

- [1] W.M. Bortz II, "The disuse syndrome," *Western Journal of Medicine*, vol.141, no.5, p.691, 1984.
- [2] A.V. Rowlands, "Measuring physical activity with body-worn accelerometers," *The Routledge Handbook of Youth Physical Activity*, 2020.
- [3] R. Crevenna and T.E. Dorner, "Association between fulfilling the recommendations for health-enhancing physical activity with (instrumental) activities of daily living in older austrians," *Wiener klinische Wochenschrift*, vol.131, no.11-12, pp.265-272, 2019.
- [4] G. Papandreou, T. Zhu, N. Kanazawa, A. Toshev, J. Tompson, C. Bregler, and K. Murphy, "Towards accurate multi-person pose estimation in the wild," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.4903-4911, 2017.
- [5] M. deAlmeida Mendes, I. daSilva, V. Ramires, F. Reichert, R. Martins, R. Ferreira, and E. Tomasi, "Metabolic equivalent of task (mets) thresholds as an indicator of physical activity intensity," *PloS one*, vol.13, no.7, 2018.
- [6] R.A. Washburn, K.W. Smith, A.M. Jette, and C.A. Janney, "The physical activity scale for the elderly (pase): development and evaluation," *Journal of clinical epidemiology*, vol.46, no.2, pp.153-162, 1993.
- [7] Z. Cao, G. Hidalgo, T. Simon, S.-E. Wei, and Y. Sheikh, "Openpose: realtime multi-person 2d pose estimation using part affinity fields," *arXiv preprint arXiv:1812.08008*, 2018.
- [8] G. Papandreou, T. Zhu, L.-C. Chen, S. Gidaris, J. Tompson, and K. Murphy, "Personlab: Person pose estimation and instance segmentation with a bottom-up, part-based, geometric embedding model," *Proceedings of the European Conference on Computer Vision (ECCV)*, pp.269-286, 2018.
- [9] Dan Oved, "Introducing bodypix: Real-time person segmentation in the browser with tensorflow.js," <https://medium.com/tensorflow/introducing-bodypix-real-time-person-segmentation-in-the-browser-with-tensorflow-js-f1948126c2a0>. visited on April 23, 2020.
- [10] D. Smilkov, N. Thorat, Y. Assogba, A. Yuan, N. Kreeger, P. Yu, K. Zhang, S. Cai, E. Nielsen, D. Soergel, et al., "Tensorflow.js: Machine learning for the web and beyond," *arXiv preprint arXiv:1901.05350*, 2019.
- [11] P. Alinia, R. Saeedi, R. Fallahzadeh, A. Rokni, and H. Ghasemzadeh, "A reliable and reconfigurable signal processing framework for estimation of metabolic equivalent of task in wearable sensors," *IEEE Journal of Selected Topics in Signal Processing*, vol.10, no.5, pp.842-853, 2016.
- [12] M. Dinger, F. Oman, E. Taylor, S. Vesely, and J. Able, "Stability and convergent validity of the physical activity scale for the elderly (pase)," *Journal of Sports Medicine and Physical Fitness*, vol.44, no.2, p.186, 2004.