

# 人物領域推定と姿勢情報を用いた 寝姿体圧画像からの関節位置推定の検討

岩瀬 慶<sup>1,a)</sup> 榎堀 優<sup>2</sup> 吉田 直人<sup>3</sup> 間瀬 健二<sup>2</sup>

**概要：**褥瘡発生危険部位の特定などには関節位置まで含めた睡眠姿勢推定が重要である。関節位置まで含めた姿勢推定は、カメラ画像より推定する手法が多数提案されているが、プライバシー問題や、布団などによるオクルージョン問題が存在するため、我々はベッド上に配置した面型圧力センサから得られる寝姿体圧画像からの睡眠推定を検討している。寝姿体圧画像には、布団によるオクルージョンなどが発生しない。一方で、カメラ画像に比べ情報量が少ないことやベッド面のしわやよれに起因するノイズの影響といった問題がある。そこで本稿では、関節位置推定モデルの一つである Convolutional Pose Machine (CPM) に、人物領域推定によるノイズ圧力抑制と姿勢情報を用いた原画像の拡張を組み込み、寝姿体圧画像のみから関節位置を推定する手法を提案する。被験者 8 名の 7 種類の寝姿勢について 16 点の関節点を推定対象とする交差検証の結果、平方平均二乗誤差指標で CPM 単体で推定を行う場合に比べ 13.2%の精度の改善が見られ、許容する誤差の範囲をその人物の頭の直径の半分の距離とした場合の正解関節点割合が 55.2%の精度で推定できた。

**キーワード：**寝姿勢，体圧画像，関節位置推定，人物領域推定，姿勢分類

## 1. はじめに

褥瘡の原因の一つとして、長時間身体の同じ部位に圧力がかかることが挙げられる。一般社団法人日本褥瘡学会発表の褥瘡ガイドブック第 2 版 [1] によると、特に、高齢者や骨盤骨折・脊髄損傷患者は健常者が無意識に行っている体位変換を自身で十分に行えないため、褥瘡の発症リスクが高いとされている。そのため、ベッド上の被看護者の褥瘡予防には、2 時間を超えない間隔で体位変換を行う看護が推奨されている。しかし、2 時間以内の間隔で体位変換を行う看護は 24 時間継続して行う必要があり、看護者の負担が大きい。実際には個人によって圧力のかかり方は異なるため、センサ等を用いて褥瘡の発症リスクを推定することで体位変換の間隔を個人で最適化し、看護負担を軽減できると考えられる。

我々は、布圧力センサで構成したシーツ型圧力センサを用いて褥瘡の発症リスクの推定や低減を試みてきた [2]。し

かし、褥瘡の発症しやすい箇所は身体の向きや姿勢によって異なるため、褥瘡発症リスクが上昇している箇所の特定を行うには患者の関節位置を含めた寝姿勢を把握する必要がある。

関節位置の推定には、カメラ画像を利用する手法が盛んに研究されており [4][3][5]、高精度に関節位置を推定することができる。しかし、寝姿勢の関節位置推定におけるカメラ画像の利用には、被看護者のプライバシーの問題や布団などによるオクルージョンの問題がある。一方で、寝姿体圧画像は、シーツに組み込んだ圧力センサで取得でき、プライバシーの問題や布団によるオクルージョンの問題が少ない。しかし、寝姿体圧画像はカメラ画像に比べ情報量が少なく、シーツやマットレスのよれなどによって人がいない領域からも圧力値が計測されるため関節位置推定に利用するのが難しい。

そこで我々は関節位置推定モデルの一つである Convolutional Pose Machine (CPM) [3] に、人物領域推定によるノイズ圧力抑制と姿勢情報を用いた原画像の拡張を組み込み、寝姿体圧画像のみから高精度に関節位置を推定する手法を提案する。

本稿では、第 2 節にて関連研究についてまとめる。第 3 節にて提案手法である領域推定と姿勢情報を組み込んだ関節位置推手法について述べ、第 4 節にて提案手法の精度評

<sup>1</sup> 名古屋大学 工学部

School of Engineering, Nagoya University

<sup>2</sup> 名古屋大学 情報学研究科

Graduate School of Informatics, Nagoya university

<sup>3</sup> 名古屋大学 未来社会創造機構

Institute of Innovation for Future Society, Nagoya university

a) iwase@cmc.is.i.nagoya-u.ac.jp

価に用いたデータセットについて述べる。第5節にて提案手法の精度評価結果について述べ、最後に第6節にてまとめる。

## 2. 関連研究

ベッドにかかる圧力分布のみを用いた姿勢推定は広く研究されている。西田らは、221個の圧力センサから呼吸及び体位を監視するシステムを提案した[6]。また、Mineharuらは、計測点が $32 \times 54$ 点の圧力センサを用いて9種類の寝姿勢を77.1%の精度で推定し[7]、Xuらは、計測点が $64 \times 128$ 点の圧力センサを用いて6種類の寝姿勢を90.78%の精度で推定している[8]。Enokiboriらは224個の体圧データを最適なパラメータでData Augmentationし、3種類の寝姿勢を99.7%の精度で分類した。これらの手法はいずれも姿勢の推定や分類であり、関節位置の推定までは行われていない。

人物の関節位置推定は、DNNとカメラ画像を利用する手法が高精度であり、広く研究されている。Toshevらは同一構造のCNNを直列に複数つなげることで、画像全体から関節を推定する手法を提案した[4]。Caoらは多段のCNNで関節位置推定と関節の連関を算出することで複数人の関節位置推定を可能とした[5]。

しかし、寝姿勢の関節位置推定にカメラ画像を利用する場合、ベッド上の患者のプライバシー問題や布団などによるオクルージョン問題が存在する。対して寝姿勢体圧画像は、シーツに組み込んだ圧力センサで取得でき、プライバシーの問題や布団によるオクルージョン問題が少ない。一方で、関節位置の推定では関節点とその周辺の特徴量から関節点を推定するが、体圧画像は1チャンネルの二次元配列であり、解像度は市販のカメラに比べ低い。そのためカメラ画像に比べ情報量が少なく特徴量の抽出が難しい。また、ベッド面のずれやよれなどの計測面の環境や、圧力のかかり方によって人物領域外にも圧力値が計測される。そのため、既存の関節位置推定モデルを直接利用するだけでは体圧画像から関節位置を推定することが難しい。

そこで我々は、既存の関節位置推定モデルに人物領域推定によるノイズ抑制と姿勢分類情報の組み込みによって体圧画像のみから関節位置を推定する手法を提案する。

## 3. 人物領域推定によるノイズ抑制と姿勢分類情報を組み込んだ関節位置推定手法

本節では、関節位置推定モデルに人物領域推定によるノイズ抑制と姿勢分類情報を組み込んだ関節位置推定手法について述べる。提案手法の概要を図1に示す。以降では、まず拡張元の関節位置推定手法であるConvolutional Pose Machine[3]について触れ、人物領域推定によるノイズ抑制と姿勢情報を用いた原画像の拡張についてそれぞれ述べる。

## 3.1 Convolutional Pose Machine 概要

関節位置の推定は関節位置推定モデルの一つであるConvolutional Pose Machine (CPM) [3]を拡張して用いた。CPMは、特徴量の抽出と関節位置の推定を行うCNNを複数回つなげることで、より広い範囲の特徴量を含めて推定を行い精度を向上させる手法である。CPMは各関節毎に位置を推定しているため、特に画像内に1人だけが映っている映像に対して関節点を推定する場合には少ない計算量で高精度に推定ができる。寝姿勢体圧画像は、画像内に1人のみの計測体圧が存在することを前提としているため、CPMで同様少ない計算量で高精度に関節位置が推定できると考えた。

本研究では、入力データを寝姿勢体圧画像、教師データを各関節位置の座標として学習を行うことで、寝姿勢体圧画像から関節位置を推定するモデルを作成した。CPMのステージ数は[3]より6とした。また、学習データ量を補うためMPIIデータセット[10]で事前に学習したモデルをFine Tuningした。

## 3.2 人物領域推定によるノイズ圧力抑制

寝姿勢体圧画像から人物領域を推定し、推定領域を用いてノイズ圧力を抑制する。図2の寝姿勢体圧画像(a)と人物領域画像(b)からシーツ型圧力センサ上の人が乗っていない領域においても圧力値が計測されていることがわかる。寝姿勢の人物領域が把握できれば、その領域外の圧力値がノイズであると判断し抑制できるため、ノイズ圧力を抑制するために人物領域を用いる。計測した体圧画像から領域推定モデルの一つであるU-Net[9]を用いて人物領域を推定し、計測された圧力値のうち推定人物領域外の圧力値に0.2を掛け、領域の内外で重み付けをしノイズ圧力を抑制した。寝姿勢体圧画像(a)と推定人物領域画像(b)よりノイズを抑制した結果が図2の(c)である。

## 3.3 姿勢情報を用いた原画像の拡張

寝姿勢体圧画像から寝姿勢を分類し、その情報によって原画像の拡張を行う。寝姿勢体圧画像をRGB画像のように多チャンネル化し、その一つに圧力情報を、別の一つに姿勢情報を格納し、DNNによる畳み込み時にはRGB画像と同様に全チャンネルを合わせて畳み込み処理を実施した。姿勢の分類にはVGG16[11]の構造を用いた。寝姿勢は仰臥位、右側臥位、左側臥位、伏臥位の4つに分類し、分類した姿勢の種類によって異なる値で姿勢情報チャンネルの全ての値を埋めた。各姿勢毎のチャンネルを埋める値は、仰臥位の場合0、右側臥位の場合50、左側臥位の場合150、伏臥位の場合100とした。

## 4. データセット

本節では、提案手法のモデルの評価に用いたデータセッ

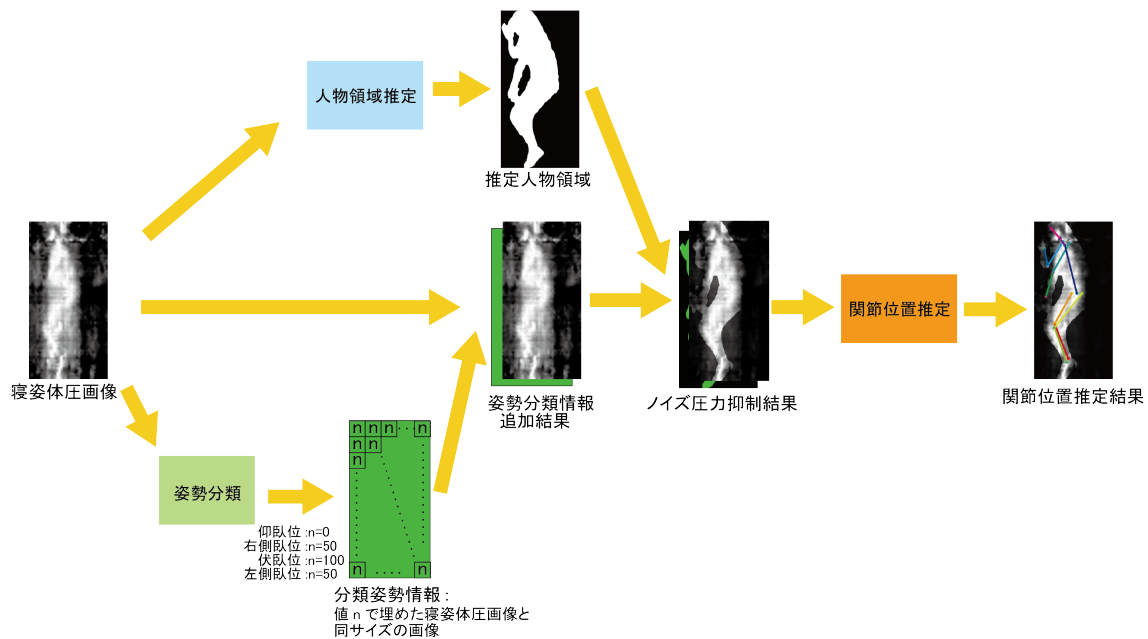


図 1 提案手法概要

Fig. 1 Overview of proposed method




図 2 (a) 寝姿勢体圧画像, (b) 人物領域画像, (c) ノイズ抑制結果  
Fig. 2 (a) Measured image of sleeping posture (b) Detected person area (c) Denoised image

トの収集方法と事後処理について述べる。

#### 4.1 データ計測条件

寝姿勢体圧の計測では、図 3 に示すように、マットレス上に、防湿カバーをかぶせたシート型圧力センサを敷き、その上で被験者は寝姿勢をとり圧力を測定した。シート型圧力センサは先行研究 [12] と同様の装置で測定した。計測点は 3200 (80 × 40) 点であり、サンプリング周波数を 6Hz とした。また、正解関節位置座標と人物領域を得るために、図 4 のようにシートから垂直方向に 2280 mm 上部のカメラで寝姿勢を撮影した。カメラ設定は画素数を 1920 × 1080, FPS を 60Hz とした。

#### 4.2 データ計測手順

本研究では、男子大学生 8 名 (S1~S8) を対象に計測を行った。被験者は年齢 22.1 ± 0.9 歳, 身長 172.0 ± 5.6 cm, 体重 64.1 ± 10.5 kg の健康者であった。図 5 に示す仰臥位 2 種類 (a) (b), 右側臥位 2 種類 (c) (d), 伏臥位 1 種類



図 3 圧力センサの配置 (左) と計測の様子 (右)

Fig. 3 Pressure sensor placement (left) and measurement (right)




図 4 計測模式図

Fig. 4 Setup for measurement

(e), 左側臥位 2 種類 (f) (g) の計 7 種類の姿勢について計測した。ただし、被験者にはあくまで図 5 の寝姿勢を参考にした被験者の自然な寝姿勢をとるように指示した。そのため被験者間で全く同じ姿勢となることはない。姿勢の変更は音声ガイドに従い (a) から (g) の順に、姿勢変更 5 秒と姿勢停止状態 5 秒を繰り返した。(a) から (g) までの




図 5 参考計測姿勢

Fig. 5 Reference measurement posture




図 6 推定する関節位置

Fig. 6 Estimated joint position

姿勢変更を 1 セットとし、これを 10 セット行った。従って 1 被験者あたり 70 姿勢データを計測した。

#### 4.3 体圧データの事後処理

計測した体圧データを 2Hz でリサンプリングし、時系列方向で平滑化を行った。各姿勢について、寝姿勢の変更による圧力の変動がない状態の圧力画像を選択するため、姿勢停止状態を開始してから 4 秒後の圧力画像を各姿勢の寝姿勢圧力画像とした。得られた  $80 \times 40$  点の寝姿勢圧力画像を、ネットワークの入力に合わせて、重み付け関数による曲線的な補間法である BICUBIC 法により  $800 \times 400$  点にリサイズした。これらに対してシーツの長軸方向に沿って反転したデータを追加した。

#### 4.4 姿勢データの生成

寝姿勢における関節座標を得るために、カメラで撮影した寝姿勢画像から OpenPose[5] を用いて図 6 に示す 16 点の関節点 (0:r-ankle, 1:r-knee, 2:r-hip, 3:l-hip, 4:l-knee, 5:l-ankle, 6:pelvis, 7:thorax, 8:upper neck, 9:head top, 10:r-wrist, 11:r-elbow, 12:r-shoulder, 13:l-shoulder, 14:l-elbow, 15:l-wrist) の推定を行った。寝姿勢動画のうち、体圧データから選択した各寝姿勢体圧画像に対応するカメラ姿勢画像を選択するため、姿勢停止状態を開始してから 3.75 秒から 4.15 秒の 30 フレームについて関節位置の推定を行い、各推定関節点について信頼度が 0.3 を超えるもののみで平均値をとり一つの姿勢の関節位置情報とした。推定ができなかった関節点については手動で座標を取得した。各座標を  $800 \times 400$  の画像上の座標に変換し、各寝姿勢の関節位置座標データとした。

表 1 手法条件

Table 1 Method conditions

	NR	IE
条件 1	OFF	OFF
条件 2	ON	OFF
条件 3	OFF	ON
条件 4	ON	ON

表 2 データ選択方法

Table 2 Data selection method

pattern	学習データ	検証データ	テストデータ
1	S1,S2,S3,S4,S5,S6	S7	S8
2	S1,S2,S3,S4,S5,S8	S6	S7
3	S1,S2,S3,S4,S7,S8	S5	S6
4	S1,S2,S3,S6,S7,S8	S4	S5
5	S1,S2,S5,S6,S7,S8	S3	S4
6	S1,S4,S5,S6,S7,S8	S2	S3
7	S1,S2,S3,S4,S7,S8	S1	S2
8	S2,S3,S4,S5,S6,S7	S8	S1

また、人物領域は各姿勢について姿勢停止状態を開始してから 4 秒後のカメラ画像から手動で人物領域データを作成した。

最後に、上記の手順で作成した関節座標、人物領域に対し体圧データと同様に反転したデータを追加した。

### 5. 関節位置推定精度評価

本節では、前節で述べたデータセットを用いて提案手法を評価した結果について述べる。

#### 5.1 評価方法

表 1 に示す人物領域推定によるノイズ抑制 (NR:Noise Reduction) と姿勢情報を用いた原画像の拡張 (IE:Image Expantion) の有無の 4 条件でモデルの学習、評価を行った。各条件について学習用データを被験者 6 名分、検証用データを被験者 1 名分、テスト用データを被験者 1 名分とし、表 2 のデータ選択方法に従い、被験者単位でデータを選択し関節位置推定精度を評価した。領域推定は、表 2 と同様の選択方法で学習を行ったモデルによる推定値を用いた。姿勢分類情報は学習データは正解値、検証データとテストデータは表 2 と同様の選択方法で学習を行ったモデルによる推定値を用いた。領域推定モデルと姿勢分類モデルを表 2 に従って評価した結果、領域推定の精度は正解画素比率が  $0.855 \pm 0.012$  であり、姿勢分類の精度は分類成功比率が  $0.944 \pm 0.028$  であった。

関節位置推定の評価指数には、回帰問題に用いられる平方平均二乗誤差 (RMSE:Root Mean Squared Error) と、関節位置推定に用いられる正解関節点割合 (PCK:Percentage of Correct Key-points) のうち許容誤差範囲が人物の頭の直径の半分である指標 (PCKh@0.5) を用いた。RMSE は数




図 7 RMSE 指標による評価結果分布

Fig. 7 Evaluation result distribution by RMSE

表 3 RMSE 指標による評価結果

Table 3 Evaluation result by RMSE

NR	IE	評価結果 (pixel)
OFF	OFF	99.8 ± 16.7
ON	OFF	94.9 ± 16.4
OFF	ON	124.6 ± 14.4
ON	ON	86.6 ± 11.7

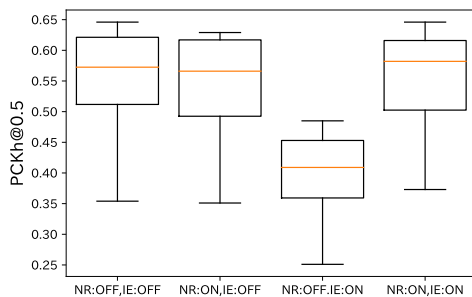


図 8 PCKh@0.5 指標による評価結果分布

Fig. 8 Evaluation result distribution by PCKh@0.5

値が小さいほど精度が高いことを示す。対して PCKh@0.5 は数値が大きいほど精度が高いことを示し、RMSE 比べ外れ値に影響されにくい小さな精度改善を捉えることには向かない。

## 5.2 評価結果

各条件における推定モデルの評価結果について、表 2 の順に評価した結果を、評価指数が RMSE の場合、表 3 に示し、箱ひげ図を図 7 に示す。評価指数を PCKh@0.5 とした場合、結果を表 4 に示し、箱ひげ図を図 8 に示す。

RMSE 指標で評価した場合、表 3 と図 7 の条件 1 (NR:OFF, IE:OFF) と条件 2 (NR:ON, IE:OFF) の結果に着目すると、条件 2 は条件 1 に比べ少し平均の数値が減少し、分布も小さい値に寄っているため、若干の精度の向上が見られた。条件 1 (NR:OFF, IE:OFF) と条件 3 (NR:OFF, IE:ON) の結果に着目すると、条件 3 は条件 1

表 4 PCKh@0.5 指標による評価結果

Table 4 Evaluation result by PCKh@0.5

NR	IE	評価結果
OFF	OFF	0.549 ± 0.095
ON	OFF	0.540 ± 0.092
OFF	ON	0.392 ± 0.080
ON	ON	0.552 ± 0.086

に比べ大きく数値が増加しており、精度が低くなった。提案手法である条件 4 (NR:ON, IE:ON) の結果に着目すると、他の全条件と比較して数値が小さくなり、ばらつきも小さくなっているため、最も精度の向上が見られた結果となった。

しかし、PCKh@0.5 指標で評価した場合、条件 1 (NR:OFF, IE:OFF), 2 (NR:ON, IE:OFF), 4 (NR:ON, IE:ON) 間で数値やばらつきに大きな変化はなかった。条件 3 (NR:OFF, IE:ON) の場合は、RMSE 指標を用いた場合と同様に、推定精度が低くなった。

次に、関節点毎の評価結果を表 5、箱ひげ図を図 9 に示す。評価指数は RMSE とした。条件 1 (NR:OFF, IE:OFF) と条件 2 (NR:ON, IE:OFF) の結果に着目すると、条件 2 では条件 1 に比べ、l-knee, r-knee, l-shoulder, r-shoulder, l-elbow, l-wrist の 6 点で精度の向上が見られた。条件 1 (NR:OFF, IE:OFF) と条件 3 (NR:OFF, IE:ON) の結果に着目すると、条件 3 では条件 1 に比べ、すべての関節点で推定精度が低くなっていた。条件 2 (NR:ON, IE:OFF) と条件 4 (NR:ON, IE:ON) の結果に着目すると、条件 4 では条件 2 に比べ、upper neck, head top を除く 14 点で精度の向上が見られた。

## 5.3 考察

人物領域推定によるノイズ抑制について、CPM 単独の推定では、特に手足の圧力がノイズと混同し推定ができない場合が見られたため、人物領域推定によりノイズを抑制することで手足の関節位置が正しく推定できることを期待した。評価結果より、RMSE 指標では、手足の 12 点の関節のうち 6 点の関節の推定の精度の向上が見られ、全体を通して精度の向上が見られた。よって人物領域推定によるノイズ抑制は関節位置推定の精度向上に有効であると分かった。したがって、より関節領域推定の精度を向上させるためには、人物領域推定の精度を向上させることが有効であると考えられる。人物領域推定の精度を向上のために、人物領域推定に用いるネットワーク構造や、より多くのデータの学習を検討する必要がある。

姿勢情報による現画像の拡張について、人物領域推定によるノイズ抑制なしで姿勢情報による現画像の拡張を行った場合、CPM 単独の推定精度より低くなった。しかし、人物領域推定によるノイズ抑制と組み合わせることで、人



A...NR:OFF, IE:OFF B...NR:ON, IE:OFF C...NR:OFF, IE:ON D...NR:ON, IE:ON

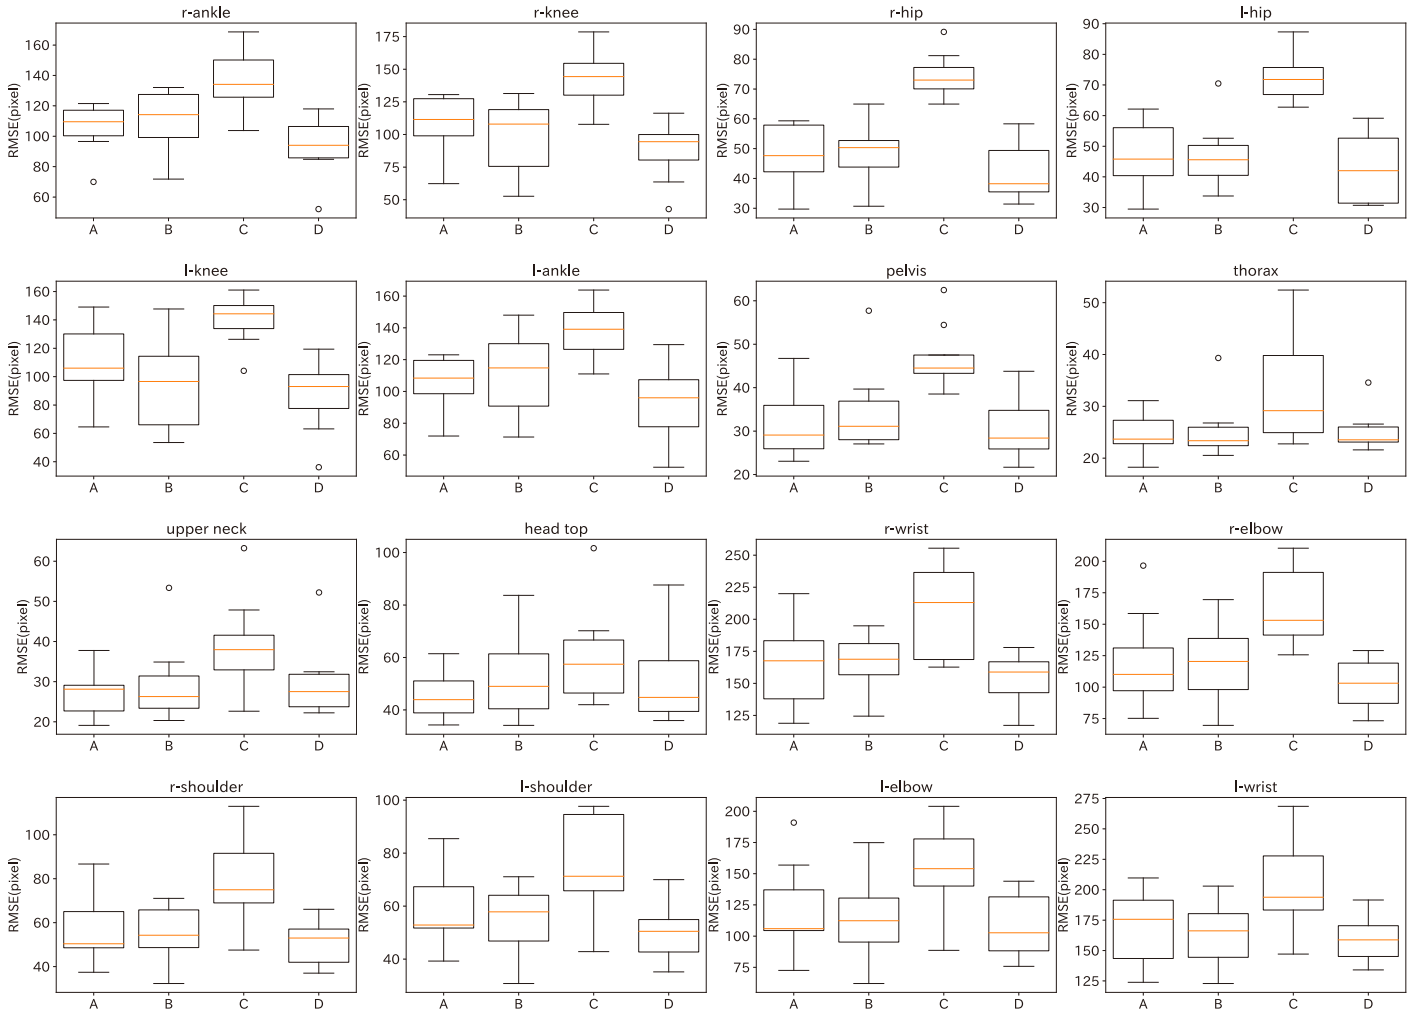


図 9 RMSE 指標による各関節ごとの評価結果分布

Fig. 9 Evaluation results distribution for each joint by RMSE

表 5 RMSE 指標による各関節ごとの評価結果

Table 5 Results of each joint by RMSE

NR	IE	r-ankle	r-knee	r-hip	l-hip	l-knee	l-ankle
OFF	OFF	105.7 ± 16.1	108.8 ± 21.3	48.0 ± 9.6	47.0 ± 10.0	110.1 ± 27.2	105.5 ± 16.7
ON	OFF	110.5 ± 19.4	98.2 ± 27.9	48.8 ± 9.3	47.2 ± 10.6	95.0 ± 30.1	111.4 ± 24.3
OFF	ON	137.3 ± 19.6	143.2 ± 21.3	74.6 ± 7.1	72.3 ± 7.6	140.1 ± 17.0	138.6 ± 16.7
ON	ON	93.4 ± 19.3	87.5 ± 22.1	42.1 ± 8.9	43.1 ± 11.0	86.8 ± 24.8	93.0 ± 22.4
NR	IE	pelvis	thorax	upper neck	head top	r-wrist	r-elbow
OFF	OFF	32.2 ± 8.9	24.6 ± 3.7	27.1 ± 5.5	45.3 ± 8.3	165.1 ± 34.3	120.8 ± 36.7
ON	OFF	34.8 ± 9.6	25.4 ± 5.6	29.7 ± 10.0	52.4 ± 15.5	167.1 ± 21.9	118.9 ± 30.8
OFF	ON	46.9 ± 7.3	33.1 ± 10.0	39.2 ± 11.4	60.7 ± 18.1	207.7 ± 35.0	164.4 ± 30.3
ON	ON	30.1 ± 9.1	25.2 ± 3.9	30.1 ± 9.1	51.3 ± 16.2	153.0 ± 19.8	102.8 ± 19.3
NR	IE	r-shoulder	l-shoulder	l-elbow	l-wrist		
OFF	OFF	57.9 ± 17.0	59.8 ± 15.0	121.3 ± 34.8	168.9 ± 30.7		
ON	OFF	55.3 ± 12.2	55.3 ± 12.8	114.8 ± 31.8	164.4 ± 25.3		
OFF	ON	78.7 ± 18.8	75.4 ± 17.9	155.7 ± 34.4	201.2 ± 36.9		
ON	ON	51.5 ± 10.1	50.4 ± 11.0	108.2 ± 24.3	159.3 ± 18.8		

物領域推定によるノイズ抑制のみの場合より精度が向上した。従って、姿勢情報による原画像の拡張をした場合、拡

張をする前の体圧画像にノイズを加えたこととなり、推定精度を下げてしまったと予測できる。人物領域推定による

ノイズ抑制と組み合わせることで、姿勢情報による原画像の拡張によるノイズとしての影響を抑え、姿勢情報が精度向上に役立ったと思われる。

関節位置推定精度の評価結果より、RMSE 指標では提案手法による精度の改善が見られたが、PCKh@0.5 指標では RMSE 指標に比べ変化が少なかった。5.1 節で述べたように RMSE 指標は外れ値に影響されやすく、PCKh@0.5 指標は正解値と推定値の距離が閾値を超えない限り正解とならないため多少の精度改善では評価値が変化しない。従って本評価結果より、CPM 単独の関節位置推定に比べ、大きく推定値が正解値と離れることを改善したが正解域に達するほどの改善にはいたっていないということが予測できる。

評価結果より、どの評価条件についても特定の被験者をテストデータに選択した場合について精度が悪くなっていた。これは特定の被験者の寝姿勢や体圧画像が、他のどの被験者のものとも類似していないためと考えられる。本研究では計測した被験者数が 8 名と少ないために、評価する際に選択するデータによって精度が大きく変化する恐れがある。より安定した高い精度を出すために、異なる体格の様々な寝姿勢を計測し学習する必要がある。

## 6. まとめ

本稿では、ベッド上の患者の褥瘡の発症リスクが上昇している部位を特定するために、寝姿勢の関節位置を推定する手法として、プライバシーの問題などが少ない寝姿体圧画像から関節位置を推定する手法を検討し、関節位置推定モデルの一つである CPM に人物推定領域によるノイズ圧力抑制と姿勢情報による原画像の拡張を組み込む手法を提案し評価した。CPM 単独で推定を行う場合と比べ RMSE 指標にて 13.2%精度が向上し、PCKh@0.5 指標にて 55.2%の精度で推定ができた。

今後は、人物領域推定の精度の向上や特徴量の追加手法を検討し、より高い精度で関節位置が推定できるよう手法を改善していく。

謝辞 本研究は、JSPS 科研費 15H02736 の支援、ならびに総務省 SCOPE 地域 ICT 振興型の支援を受けたものです。

## 参考文献

- [1] 一般社団法人 日本褥瘡学会. 褥瘡ガイドブック 第 2 版 褥瘡予防・管理ガイドライン (第 4 版) 準拠. 照林社, 2015.
- [2] Yu Enokibori, Akihisa Suzuki, Hirotaka Mizuno, Yuuki Shimakami, and Kenji Mase. E-textile pressure sensor based on conductive fiber and its structure. In Proceedings of the 2013 ACM Conference on Pervasive and Ubiquitous Computing Adjunct Publication, UbiComp '13 Adjunct, pages 207–210, New York, NY, USA, 2013. ACM.
- [3] S.-E. Wei, V. Ramakrishna, T. Kanade, and Y. Sheikh.

- Convolutional pose machines. In 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- [4] A. Toshev and C. Szegedy. Deeppose: Human pose estimation via deep neural networks. In 2014 IEEE Conference on Computer Vision and Pattern Recognition.
- [5] Z. Cao, G. Hidalgo, T. Simon, S. Wei, Y. Sheikh: Real-time Multi-Person 2D Pose Estimation using Part Affinity Fields. In 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- [6] 西田佳史, 武田正資, 森武俊, 溝口博, 佐藤知正. 圧力センサによる睡眠中に呼吸・体位の無侵襲・無拘束な計測. 日本ロボット学会誌, 16(5):705–711, 1998.
- [7] Aya Mineharu, Noriaki Kuwahara, and Kazunari Morimoto. A study of automatic classification of sleeping position by a pressure-sensitive sensor. In 2015 International Conference on Informatics, Electronics & Vision (ICIEV), pages.1–5. IEEE, 2015.
- [8] Xu X, Lin F, Wang A, Song C, Hu Y, Xu W. On-bed sleep posture recognition based on body-earth mover's distance. In: Biomedical circuits and systems conference 2015. (BioCAS). IEEE; 2015. pages. 1–4.
- [9] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-Net: Convolutional Networks for Biomedical Image Segmentation. Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS, Vol.9351: 234–241, 2015
- [10] M. Andriluka, L. Pishchulin, P. Gehler, and B. Schiele. 2D human pose estimation: New benchmark and state of the art analysis. In CVPR, 2014.
- [11] Karen Simonyan, Andrew Zisserman. VERY DEEP CONVOLUTIONAL NETWORKS FOR LARGE-SCALE IMAGE RECOGNITION. ICLR, 2015.
- [12] Yu Enokibori and Kenji Mase. "Data Augmentation to Build High Performance DNN for In-bed Posture Classification", Journal of Information Processing, Vol. 26, pages.718-727, 2018