

# 姿勢情報による特徴量の重み付けを用いた 寝姿体圧画像からの関節位置推定の精度向上

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

概要：寝姿勢時の褥瘡発生危険部位の特定などには関節位置まで含めた姿勢推定が重要である。カメラ画像の利用には、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、我々は寝姿体圧画像からの関節位置推定を検討している。本稿では、我々が提案した、推定人物領域によるノイズ抑制と姿勢情報による元画像拡張を既存の関節位置推定手法である Convolutional Pose Machine に追加する手法に、姿勢情報による特徴量の重み付けを追加することによる推定精度の向上を検討した。被験者 8 名の 7 種類の寝姿勢について 16 点の関節点を推定した結果、特徴量の重み付けを追加することにより、RMSE 指標で約 2.7 % の精度改善が見られた。

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、長時間身体と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を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。そこで、ベッド上の患者の関節位置推定手法について検討した。

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 [3][4][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) [4] 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元画像拡張を組み込み、寝姿勢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した [6]。本稿では、先行研究 [6] にて提案した手法に加え、姿勢情報を用いて CPM 内の特徴量に重み付けを行うことによる精度改善手法を提案する。

本稿の構成は以下のとおりである。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、姿勢情報による特徴量の重み付けについて述べ、その精度評価結果について述べる。第 4 節にて、まとめを述べる。

## 2. 関連研究

人物の関節位置を推定する研究や、寝姿勢を圧力分布から推定する研究は既に多く存在する。本章ではそれぞれに

<sup>1</sup> 名古屋大学 情報学研究科  
Graduate School of Informatics, Nagoya university

<sup>2</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

ついて述べ、本研究の立ち位置を示す。

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 CNN 構造を用いることで、特徴量の抽出から関節位置の推定までを End-to-End で行うネットワークによる推定手法を提案した [3]。Wei らは同一構造の CNN を直列に複数つなげることで、画像のより広い範囲の特徴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、これらのカメラ画像を用いた関節位置推定手法をベッド上の患者の関節位置推定に用いる場合、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発生する。そこで、本稿ではプライバシー問題やオクルージョン問題が少ないベッド面にかかる寝姿体圧画像のみからの関節位置推定手法について検討した。

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 [7]。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 [8]、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 90.8 % の精度で推定している [9]。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 [10]。しかし、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。圧力画像は RGB 画像に比べ情報量が少なく、またベッド面のしわやよれなどの計測環境によって、人物領域外にも圧力値が計測されノイズとなる。そのため、既存手法では姿勢分類や推定は可能であるが関節位置の推定は難しい。

そこで我々は、寝姿体圧画像から推定した人物領域と分類した姿勢情報を用いて高度に関節位置を推定する手法を検討した。

### 3. 姿勢情報を用いた特徴量の重み付けによる関節位置推定精度改善

本節では、我々が提案した、CPM にノイズ抑制と元画像拡張を追加する手法 [6] に、姿勢情報を用いた特徴量の重み付けを追加する手法について述べる。提案手法の概要を図 1 に示す。第 3.1 節にて我々の先行研究 [6] の概要について述べ、第 3.2 節にて姿勢情報を用いた特徴量の重み付けについて述べる。

#### 3.1 ノイズ抑制と元画像拡張を組み込んだ関節位置推定

関節位置推定モデルの一つである Convolutional Pose Machine (CPM) [4] に、人物領域を用いたノイズ抑制と姿勢情報を用いた元画像拡張を追加し、寝姿体圧画像からの関節位置推定精度の向上を図った。

ノイズ抑制について、寝姿体圧画像から領域推定モデルの一つである U-Net[11] 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 の重みを掛け、領域の内外で重み付けをしノイズ圧力を抑制した。

元画像拡張について、寝姿体圧画像を 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。姿勢分類には VGG16[13] を使い、分類した姿勢の種類によって異なる値（仰臥位：0，右側臥位：50，伏臥位：100，左側臥位：150）で姿勢情報チャンネルの全ての値を埋めた。

#### 3.2 姿勢情報を用いた特徴量への重み付け

先行研究 [6] に SENet[14] の構造を参考にして、4 種類の寝姿勢分類情報を用いて CPM 内で特徴量の重み付けを行い、さらなる推定精度の向上を図る。手法の概要を図 2 に示す。分類した姿勢情報は 4 要素の 1 次元配列とし、仰臥位の場合 [1,0,0,0]，右側臥位の場合 [0,1,0,0]，伏臥位の場合 [0,0,1,0]，左側臥位の場合 [0,0,0,1] とした。その 4 要素の配列を全結合層の入力とし、出力数は本手法を追加する直前の CPM 内の特徴量のチャンネル数とした。その全結合層の出力を CPM 内の特徴量に掛け合わせることで、姿勢情報によって重み付けを行う。

これにより、CPM 内の寝姿体圧画像の特徴量のうち、姿勢の種類毎に重視されるチャンネルを選別し、強調することができるため、姿勢の誤判定による推定関節位置の大きなずれが減らせると考えた。

CPM に特徴量の重み付けを追加した構造の概要を図 3 に示す。特徴量の重み付けは CPM の各層において、画像が入力されてから Convolution 層 4 層と Maxpooling 層 3 層を交互に行った後の箇所を追加した。

### 4. 関節位置推定精度評価実験

本節では、提案手法の姿勢情報を用いた特徴量の重み付けが、関節位置推定精度の向上に有効であるかを検証した。第 4.1 節にて精度評価方法について述べ、第 4.2 節にて評価結果を述べる。第 4.3 節にて評価結果より考察を述べる。

#### 4.1 評価方法

関節位置推定精度の評価には先行研究 [6] と同じデータセットを用いた。8 名の被験者の図 4 に示す 7 種類の姿勢について計測した、1 被験者あたり 140 個、合計 1120 個のデータセットである。各データは、寝姿体圧画像、図 5 に示す 16 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) の関節位置座標、人物領域、姿勢情報

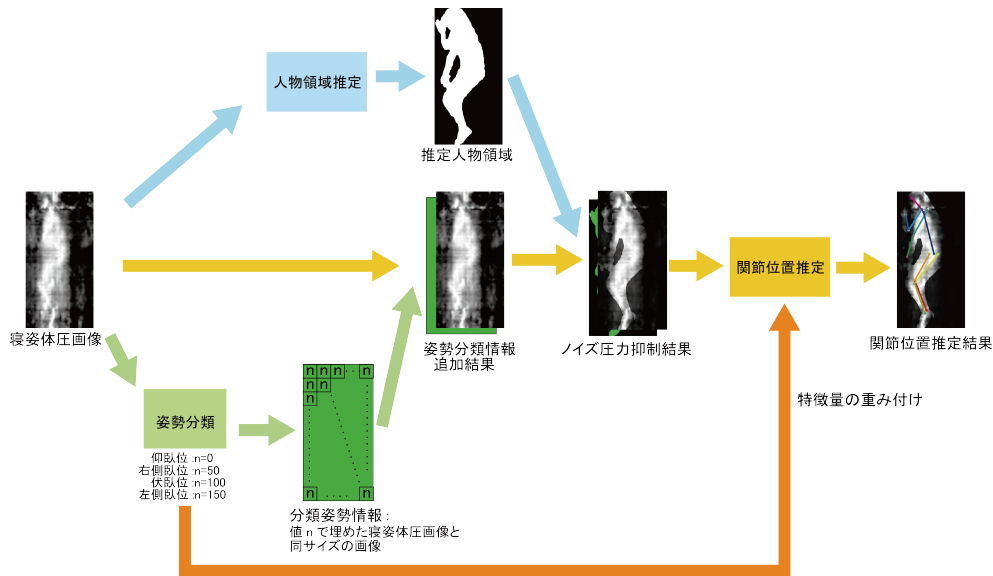


図 1 提案手法概要

Fig. 1 Overview of proposed method

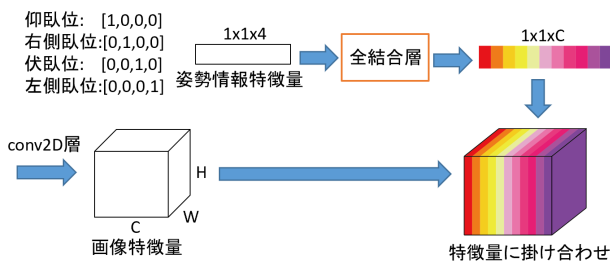


図 2 姿勢情報を用いた特徴量への重み付け

Fig. 2 Feature Weighting using posture information




図 4 参考計測姿勢

Fig. 4 Reference measurement posture

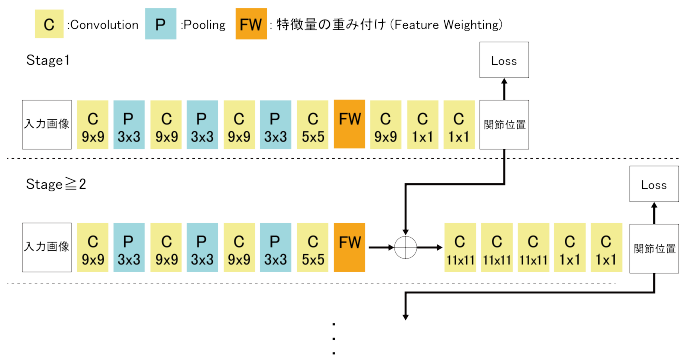


図 3 特徴量の重み付けを追加した CPM 構造概要

Fig. 3 Overview of CPM structure with feature weighting

ラベル (仰臥位, 右側臥位, 伏臥位, 左側臥位) を持つ。データは被験者毎に分割し S1~S8 とした。

提案手法の特徴量の重み付けが推定精度向上に有効であるか検証するために, 表 1 に示す人物領域を用いたノイズ抑制 (NR:Noise Reduction) と姿勢情報を用いた元画像拡張 (IE:Image Expantion) と姿勢情報を用いた特徴量への重み付け (FW:Feature Weighting) の有無の 8 条件でモデルの学習, 評価を行った。以降, 各条件を  $P_{100}^{rew}$  のように




図 5 推定する関節位置

Fig. 5 Estimated joint position

表記する。これは NR, IE, FW がそれぞれ ON (1), OFF (0), OFF (0) の条件を示す。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。以降データの選択パターンを  $DS_{t8}^7$  のように表記する。これは S7 を検証データ, S8 をテストデータ, 残りを学習データとしたパターンを示す。

関節位置推定に用いる人物領域は,  $DS_{t8}^7$  から  $DS_{t1}^8$  のデータ選択方法に従って学習を行ったモデルによる推定値を用い, 姿勢情報は, 学習データは正解値, 検証データと

表 1 比較条件

**Table 1** Comparison condition

Pattern	NR	IE	FW
$P_{000}^{rew}$	OFF	OFF	OFF
$P_{100}^{rew}$	ON	OFF	OFF
$P_{010}^{rew}$	OFF	ON	OFF
$P_{001}^{rew}$	OFF	OFF	ON
$P_{110}^{rew}$	ON	ON	OFF
$P_{101}^{rew}$	ON	OFF	ON
$P_{011}^{rew}$	OFF	ON	ON
$P_{111}^{rew}$	ON	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
$DS_{t8}^v7$	S1,S2,S3,S4,S5,S6	S7	S8
$DS_{t7}^v6$	S1,S2,S3,S4,S5,S8	S6	S7
$DS_{t6}^v5$	S1,S2,S3,S4,S7,S8	S5	S6
$DS_{t5}^v4$	S1,S2,S3,S6,S7,S8	S4	S5
$DS_{t4}^v3$	S1,S2,S5,S6,S7,S8	S3	S4
$DS_{t3}^v2$	S1,S4,S5,S6,S7,S8	S2	S3
$DS_{t2}^v1$	S1,S2,S3,S4,S7,S8	S1	S2
$DS_{t1}^v8$	S2,S3,S4,S5,S6,S7	S8	S1

テストデータは  $DS_{t8}^v7$  から  $DS_{t1}^v8$  のデータ選択方法に従って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  $DS_{t8}^v7$  から  $DS_{t1}^v8$  のデータ選択方法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標には、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) を用いた。RMSE は数値が小さいほど精度が高いことを示す。対して PCK は数値が大きいほど精度が高いことを示し、RMSE と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。なお、PCK は許容誤差を 10 pixel から 100 pixel まで 10 pixel 毎に導出し、その AUC (Area Under the Curve) を評価に用いた。これは、本実験では 1 pixel あたり約 0.2 cm の誤差であるため、許容誤差は 2 cm から 20 cm まで 2 cm 毎に評価したこととなる。以降では、本指標を PCK-AUC@2-20cm とする。

#### 4.2 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 のデータ選択方法の組み合わせに従って学習、評価した。RMSE の結果を表 3 に示し、その箱ひげ図を図 6 に示す。PCK-AUC@2-20cm の結果を表 4 に示し、その計算元となったグラフを図 7 に示す。




図 6 RMSE による評価結果分布

**Fig. 6** Evaluation result distribution by RMSE

表 3 RMSE による評価結果

**Table 3** Evaluation result by RMSE

各条件、平均差: RMSE (pixel)  
改善率: FW 実装前から実装後の RMSE の減少率

	先行研究 [6]	+FW( * <sub>001</sub> *)	平均差	改善率
$P_{000}^{rew}$	99.8 ± 16.7	87.7 ± 13.9	12.1	0.121
$P_{100}^{rew}$	94.9 ± 16.4	85.8 ± 12.7	9.1	0.096
$P_{010}^{rew}$	124.6 ± 14.4	102.0 ± 15.4	22.6	0.181
$P_{110}^{rew}$	86.6 ± 11.7	<b>84.3 ± 8.9</b>	2.3	0.027

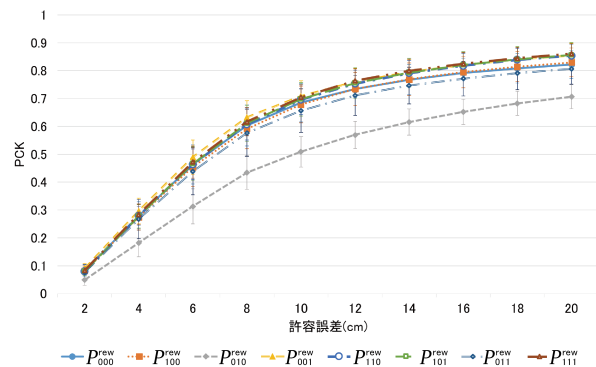


図 7 PCK による評価結果

**Fig. 7** Evaluation result by PCK

表 4 PCK-AUC@2-20cm による評価結果

**Table 4** Evaluation result by PCK-AUC@2-20cm

各条件、差: PCK-AUC@2-20cm  
改善率: FW 実装前から実装後の PCK-AUC@2-20cm の増加率

	先行研究 [6]	+FW( * <sub>001</sub> *)	平均差	改善率
$P_{000}^{rew}$	0.621	<b>0.646</b>	0.025	0.040
$P_{100}^{rew}$	0.619	0.636	0.017	0.027
$P_{010}^{rew}$	0.482	0.600	0.118	0.245
$P_{110}^{rew}$	0.635	0.643	0.008	0.013

RMSE では、どの組合せでも FW を併用することで、精度の改善が見られた。 $P_{000}^{rew}$  から  $P_{001}^{rew}$  では 12.1 pixel (12.1 %),  $P_{100}^{rew}$  から  $P_{101}^{rew}$  では 9.1 pixel (9.6 %),  $P_{010}^{rew}$  から  $P_{011}^{rew}$  では 22.6 pixel (18.1 %), 先行研究 [6] における最良手法

表 5 RMSE による各関節ごとの評価結果 (pixel)

Table 5 Joints' RMSE on evaluation

Pattern	r-ankle	r-knee	r-hip	l-hip
$P_{000}^{rew}$	107.4 ± 18.2	112.4 ± 26.5	47.1 ± 9.0	47.6 ± 10.7
$P_{001}^{rew}$	95.8 ± 23.1	99.8 ± 27.6	<b>41.9 ± 8.7</b>	<b>42.3 ± 9.7</b>
$P_{100}^{rew}$	110.5 ± 19.4	98.2 ± 27.9	48.8 ± 9.3	47.2 ± 10.6
$P_{101}^{rew}$	100.0 ± 18.9	94.0 ± 25.0	44.8 ± 13.5	44.9 ± 11.7
$P_{010}^{rew}$	137.2 ± 19.6	143.2 ± 21.3	74.3 ± 7.2	72.0 ± 7.9
$P_{011}^{rew}$	112.2 ± 15.2	119.3 ± 20.4	55.1 ± 11.3	54.1 ± 14.4
$P_{110}^{rew}$	<b>93.4 ± 19.3</b>	87.6 ± 22.1	42.1 ± 8.9	43.1 ± 11.0
$P_{111}^{rew}$	93.5 ± 16.5	<b>86.1 ± 20.0</b>	44.2 ± 7.9	45.3 ± 10.2
Pattern	l-knee	l-ankle	pelvis	thorax
$P_{000}^{rew}$	113.5 ± 31.4	107.8 ± 19.9	32.2 ± 8.9	26.3 ± 5.5
$P_{001}^{rew}$	97.3 ± 24.2	<b>89.4 ± 17.2</b>	<b>28.4 ± 6.9</b>	25.3 ± 6.1
$P_{100}^{rew}$	95.0 ± 30.1	111.4 ± 24.3	34.8 ± 9.6	25.4 ± 5.6
$P_{101}^{rew}$	90.8 ± 25.2	99.6 ± 19.3	35.3 ± 9.5	<b>24.5 ± 4.6</b>
$P_{010}^{rew}$	140.2 ± 17.0	138.7 ± 16.7	46.8 ± 7.3	33.1 ± 10.0
$P_{011}^{rew}$	122.1 ± 21.6	112.9 ± 14.7	40.7 ± 8.4	26.9 ± 5.2
$P_{110}^{rew}$	86.8 ± 24.8	93.0 ± 22.4	30.4 ± 6.7	25.2 ± 3.9
$P_{111}^{rew}$	<b>86.2 ± 22.0</b>	92.0 ± 20.1	34.6 ± 6.8	24.8 ± 4.9
Pattern	upper neck	head top	r-wrist	r-elbow
$P_{000}^{rew}$	30.8 ± 11.4	48.9 ± 14.1	167.0 ± 35.2	128.9 ± 37.7
$P_{001}^{rew}$	32.4 ± 9.0	54.4 ± 15.0	155.6 ± 25.4	108.6 ± 25.2
$P_{100}^{rew}$	29.7 ± 10.0	52.4 ± 15.5	167.1 ± 21.9	118.9 ± 30.8
$P_{101}^{rew}$	30.7 ± 10.1	50.7 ± 10.5	<b>148.0 ± 23.8</b>	<b>95.9 ± 21.5</b>
$P_{010}^{rew}$	39.2 ± 11.4	60.6 ± 18.1	207.7 ± 35.0	164.3 ± 30.3
$P_{011}^{rew}$	31.6 ± 7.3	51.2 ± 13.2	179.3 ± 35.6	112.3 ± 13.2
$P_{110}^{rew}$	30.1 ± 9.1	51.3 ± 16.2	153.0 ± 19.3	102.8 ± 19.3
$P_{111}^{rew}$	<b>29.2 ± 10.4</b>	<b>46.6 ± 9.3</b>	151.7 ± 14.4	96.5 ± 14.5
Pattern	r-shoulder	l-shoulder	l-elbow	l-wrist
$P_{000}^{rew}$	59.2 ± 16.7	61.7 ± 14.9	129.3 ± 37.4	168.5 ± 30.4
$P_{001}^{rew}$	51.9 ± 14.1	52.7 ± 14.3	104.1 ± 29.5	<b>148.5 ± 31.8</b>
$P_{100}^{rew}$	55.3 ± 12.2	55.3 ± 12.8	114.8 ± 31.8	164.4 ± 25.3
$P_{101}^{rew}$	<b>46.5 ± 10.1</b>	46.6 ± 11.7	98.4 ± 24.3	154.9 ± 20.5
$P_{010}^{rew}$	78.6 ± 18.8	75.4 ± 17.9	155.8 ± 34.4	201.4 ± 36.8
$P_{011}^{rew}$	54.6 ± 13.2	52.9 ± 13.2	123.0 ± 36.1	177.0 ± 30.2
$P_{110}^{rew}$	51.5 ± 10.1	50.4 ± 11.0	108.2 ± 24.3	159.3 ± 18.8
$P_{111}^{rew}$	47.0 ± 9.4	<b>46.2 ± 9.6</b>	<b>95.4 ± 20.0</b>	159.4 ± 19.7

表 6 PCK-AUC@2-20cm による各関節ごとの評価結果

Table 6 Joints' PCK-AUC@2-20cm on evaluation

Pattern	r-ankle	r-knee	r-hip	l-hip
$P_{000}^{rew}$	0.555	0.608	0.700	0.701
$P_{001}^{rew}$	<b>0.586</b>	0.639	0.735	0.735
$P_{100}^{rew}$	0.512	0.619	0.714	0.717
$P_{101}^{rew}$	0.540	0.640	0.739	0.733
$P_{010}^{rew}$	0.376	0.375	0.455	0.483
$P_{011}^{rew}$	0.503	0.567	0.656	0.667
$P_{110}^{rew}$	0.550	0.634	0.740	<b>0.740</b>
$P_{111}^{rew}$	0.549	<b>0.646</b>	<b>0.743</b>	0.735
Pattern	l-knee	l-ankle	pelvis	thorax
$P_{000}^{rew}$	0.596	0.546	0.812	0.843
$P_{001}^{rew}$	0.665	<b>0.588</b>	<b>0.840</b>	0.854
$P_{100}^{rew}$	0.629	0.514	0.819	0.854
$P_{101}^{rew}$	0.655	0.539	0.812	0.860
$P_{010}^{rew}$	0.377	0.371	0.614	0.747
$P_{011}^{rew}$	0.565	0.515	0.752	0.840
$P_{110}^{rew}$	0.655	0.546	0.833	0.861
$P_{111}^{rew}$	<b>0.668</b>	0.551	0.824	<b>0.863</b>
Pattern	upper neck	head top	r-wrist	r-elbow
$P_{000}^{rew}$	0.813	<b>0.716</b>	0.341	0.482
$P_{001}^{rew}$	0.800	0.677	<b>0.369</b>	<b>0.507</b>
$P_{100}^{rew}$	0.822	0.670	0.324	0.473
$P_{101}^{rew}$	0.812	0.681	0.364	0.505
$P_{010}^{rew}$	0.696	0.603	0.235	0.312
$P_{011}^{rew}$	0.802	0.685	0.355	0.475
$P_{110}^{rew}$	0.818	0.684	0.353	0.479
$P_{111}^{rew}$	<b>0.830</b>	0.705	0.349	0.484
Pattern	r-shoulder	l-shoulder	l-elbow	l-wrist
$P_{000}^{rew}$	0.689	0.679	0.488	0.358
$P_{001}^{rew}$	0.720	0.714	<b>0.513</b>	<b>0.397</b>
$P_{100}^{rew}$	0.705	0.698	0.471	0.338
$P_{101}^{rew}$	0.735	0.740	0.495	0.333
$P_{010}^{rew}$	0.497	0.513	0.325	0.255
$P_{011}^{rew}$	0.695	0.702	0.463	0.356
$P_{110}^{rew}$	0.711	0.719	0.478	0.357
$P_{111}^{rew}$	<b>0.742</b>	<b>0.745</b>	0.504	0.342

であった  $P_{110}^{rew}$  から  $P_{111}^{rew}$  では 2.3 pixel (2.7%) の改善が見られた。

PCK-AUC@2-20cm でも、RMSE で評価した場合と同様に、どの組合せでも FW を併用することで、精度の改善が見られた。  $P_{000}^{rew}$  から  $P_{001}^{rew}$  では 0.025 (4.0%),  $P_{100}^{rew}$  から  $P_{101}^{rew}$  では 0.017 (2.7%),  $P_{010}^{rew}$  から  $P_{011}^{rew}$  では 0.118 (24.5%), 先行研究 [6] における最良手法であった  $P_{110}^{rew}$  から  $P_{111}^{rew}$  では 0.008 (1.3%) の改善が見られた。しかし、3つの追加手法をすべて用いた場合ではなく、FW 単体を用いた場合が最良の結果となった。また、図 7 より、許容誤差が 10 cm までは FW 単体を用いた場合が最も精度が良く、12 cm 以上では 3つの追加手法全てを用いた場合が最良の結果となった。

関節点毎の RMSE を表 5 に示す。平均値を見ると全 16 点の関節のうち、  $P_{000}^{rew}$  から  $P_{001}^{rew}$  では 14 点、  $P_{100}^{rew}$  から

$P_{101}^{rew}$  では 15 点、  $P_{010}^{rew}$  から  $P_{011}^{rew}$  では 16 点全て、  $P_{110}^{rew}$  から  $P_{111}^{rew}$  では 11 点の関節で精度改善が見られた。ただし、NR, IE, FW の 3 手法全てを用いた場合が必ずしも全ての関節点で最良とは限らず、最良精度の関節点は  $P_{001}^{rew}$  の場合が 5 点、  $P_{101}^{rew}$  の場合が 4 点、  $P_{011}^{rew}$  の場合が 0 点、  $P_{111}^{rew}$  の場合が 6 点であった。

関節点毎の PCK-AUC@2-20cm を表 6 に示す。全 16 点の関節のうち、  $P_{000}^{rew}$  から  $P_{001}^{rew}$  では 13 点、  $P_{100}^{rew}$  から  $P_{101}^{rew}$  では 13 点、  $P_{010}^{rew}$  から  $P_{011}^{rew}$  では 16 点全て、  $P_{110}^{rew}$  から  $P_{111}^{rew}$  では 11 点の関節で精度改善が見られた。RMSE と同様に、NR, IE, FW の 3 手法全てを用いた場合が必ずしも全ての関節点で最良とは限らず、最良精度の関節点は  $P_{001}^{rew}$  の場合が 7 点、  $P_{101}^{rew}$  の場合が 0 点、  $P_{011}^{rew}$  の場合が 0 点、  $P_{111}^{rew}$  の場合が 7 点であった。

### 4.3 考察

特徴量の重み付けのみを用いた場合、全ての組み合わせで精度の改善が見られた。よって特徴量の重み付けは、精度の向上に有効であることが分かる。またノイズ抑制と元画像拡張を用いた場合よりも、ノイズ抑制と特徴量への重み付けを用いた場合の精度が良い。よって、特徴量への重み付けの方が元画像拡張よりも効果的に姿勢情報を扱えると考えられる。しかし、ノイズ抑制、元画像拡張、特徴量への重み付けのすべてを用いた方が、ノイズ抑制と元画像拡張を用いた場合より精度が良いことから、元画像拡張と特徴量への重み付けでは、姿勢情報の解釈方法が異なり、併用により相乗効果が期待できることも分かった。

図 7 より、PCK では許容誤差が 10 cm 以下では特徴量の重み付けのみの場合が最も精度が良く、12 cm 以上では 3 つの手法全てを用いた場合が最も良い。そのため、目標とする許容誤差によって用いる手法を選択すべきと考えられる。また、表 5、表 6 より、関節によって最も精度が良い条件が異なるため、位置を求めたい関節によっても手法を選択すべきと考えられる。しかし、RMSE では、全 16 点の関節のうち 15 点、PCK-AUC@2-20cm では、14 点の関節が特徴量の重み付けを用いた場合が最良となっているため、本稿の提案手法である特徴量の重み付けは多くの利用条件下で有効であると考えられる。

### 5. 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た。

我々の先行研究である、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元画像の拡張を組み込む手法に、姿勢情報を用いた特徴量の重み付けを追加することでさらなる精度改善を図った。先行研究 [6] の最良手法であるノイズ抑制と元画像拡張を用いた推定結果と比べ、本稿の提案手法である特徴量の重み付けを追加した場合、RMSE に約 2.7 %、PCK-AUC@2-20cm に約 1.3 %の精度改善が見られた。従って、提案手法の姿勢情報を用いた特徴量の重み付けは、関節位置推定精度の改善に有効であることが示された。

今後は、関節位置推定ネットワークの改良や学習・評価データの再検討を行う。関節位置推定ネットワークの改良について、先行研究 [6] 及び提案手法で用いているノイズ抑制や元画像拡張に用いた係数は、手動で事前に設定している。そのため、最適係数探索により精度がより向上する可能性がある。また、人物領域推定、姿勢分類、関節位置推定 DNN は完全にそれぞれ別々の DNN として学習・推定を行っている。そのため、それらの DNN を一体化することで、より関節位置推定に適した人物領域や姿勢情報の利

用ができる可能性がある。学習・評価データについて、本稿の推定精度評価実験で用いたデータは、関節位置推定のデータとしては数が少なく、計測環境も利用目的と近いとは言えない。そのため、より多くの、利用目的とする実際の病院のベッド環境に近い環境、寝姿勢の特徴を持つデータによる学習・評価を検討する。

謝辞 本研究は JSPS 科研費 15H02736 の支援、総務省 SCOPE 地域 ICT 振興型の支援ならびに立石科学技術振興財団の研究助成を受けたものです。

### 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, Hirofumi 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, New York, NY, USA, ACM, pages 207-210, 2013.
- [3] A. Toshev and C. Szegedy. Deeppose: Human pose estimation via deep neural networks. In IEEE Conference on Computer Vision and Pattern Recognition, IEEE, pages.1653-1660, 2014.
- [4] S.-E. Wei, V. Ramakrishna, T. Kanade, and Y. Sheikh. Convolutional pose machines. Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, pages.4724-4732, 2016.
- [5] Z. Cao, G. Hidalgo, T. Simon, S. Wei, Y. Sheikh: Real-time Multi-Person 2D Pose Estimation using Part Affinity Fields. In IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, pages.7291-7299, 2017
- [6] 岩瀬慶, 榎堀優, 吉田直人, 間瀬健二. 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. ユビキタスコンピューティングシステム研究会 (UBI), IPSJ. 2019.
- [7] 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, vol.16, no.5, pages.705-711, 1998.
- [8] Aya Mineharu, Noriaki Kuwahara, and Kazumari Morimoto. A study of automatic classification of sleeping position by a pressure-sensitive sensor. In 2015 International Conference on Informatics, Electronics & Vision (ICIEV), IEEE, pages.1-5, 2015.
- [9] 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, pages. 1-4, 2015
- [10] 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
- [11] Olaf Ronneberger, Philipp Fischer, and Thomas Brox.U-Net: Convolutional Networks for Biomedical Image Segmentation.In Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS, Vol.9351, pages.234-241, 2015
- [12] M. Andriluka, L. Pishchulin, P. Gehler, and B. Schiele. 2D human pose estimation: New benchmark and state of the art analysis. In IEEE Conference on Computer Vi-

- sion and Pattern Recognition, IEEE, pages.3686-3693, 2014.
- [13] Karen Simonyan, Andrew Zisserman. VERY DEEP CONVOLUTIONAL NETWORKS FOR LARGE-SCALE IMAGE RECOGNITION. International Conference for Learning Representations, IEEE, 2015.
- [14] Jie Hu, Li Shen, Samuel Albanie, Gang Sun, Enhua Wu. Squeeze-and-Excitation Networks. Computer Vision and Pattern Recognition(CVPR), IEEE, pages.7132-7141, 2018.