

Data Augmentationを用いた少数寝姿体圧データからの 高精度姿勢識別DNN構築

榎堀 優^{1,a)} 間瀬 健二^{1,b)}

概要：褥瘡予防などを筆頭に、就寝時の体圧データの応用が研究されており、その一つに寝姿勢の識別がある。就寝時の体圧データは、低解像度の画像と見なせるため、深層学習の一手法であるCNNによる識別が有効であると考えられるが、1回の睡眠実験で得られる就寝姿勢数は、深層学習に用いるには少ない。我々の実験の実測値では、19名の各4時間の睡眠で224姿勢であった。学習・検証・テストに等分割するとすると、学習データ数は高々72点弱であり、SVMなどを用いた既存手法以下の精度しか得られなかった。そこで本研究ではData Augmentationとそのパラメータ調整によって、少数データと深層学習による高精度寝姿識別機の作成を試みた。シアー変換、拡大縮小、回転、人体長軸方向移動、人体短軸方向移動についてパラメータを探索したところ、人体長軸・短軸方向に軸長の40%、20%の移動によるData Augmentationによって仰臥位・左右腹臥位の3姿勢において99.7%の識別精度を達成した。

A Study of Data Augmentation to Build High Performance DNN for In-bed Posture Classification

YU ENOKIBORI^{1,a)} KENJI MASE^{1,b)}

1. はじめに

褥瘡予防などを筆頭に、就寝時の体圧データの応用が研究されており、その一つに寝姿勢の識別がある。我々の用いている布圧力センサで取得した寝姿体圧データの例を図1に示す。最下部にあるヒートマップが寝姿体圧データである。

就寝時の体圧データは画像と見なせるため、近年、急速に発展を遂げている深層学習(Deep Neural Network (DNN))による識別、特にConvolutional Neural Network (CNN)を用いた物が有効であると考えられる[1], [2], [3]。DNNを用いた画像認識では、人体の部位別の認識[4], [5], [6]やオクルージョンを考慮した人体姿勢認識[7], [8]なども精力的に研究されている。これらの成果が応用できれば、褥瘡好発部位の同定や追跡、体圧分散クッションによって一部

が隠れた人体姿勢の把握などが可能となり、褥瘡予防の分野でも有効であると考えられる。

しかしながら、寝姿体圧データは1回の実験で得られる姿勢数が少なく、DNNを学習するにはデータ数が不足しがちである。特に姿勢を限定したり回数を指定できない実際の睡眠から姿勢データを取得する実験では、手足の曲げ方や位置、重ね合わせなどによって姿勢のバリエーションが増大するにも関わらず、取得できる姿勢数も少なくなる傾向にある。我々の実験を例にとると、19名の被験者の4時間の睡眠実験から得られた姿勢は仰臥位: 118姿勢/16名、左側臥位: 51姿勢/13名、右側臥位 40姿勢/15名、腹臥位 15姿勢/6名の合計 224姿勢しか取得できていない。加えて、枕の下に手を入れる、膝を立てる、脚を4の字に組むなど、多様な姿勢が含まれていた。人体の長軸方向に沿って左右反転してデータをかき増ししたとしても高々448データであり、バリエーションに富むデータをDNNで学習するには不十分である。

一方で、データ数が少ない場合には、データに対して拡

¹ 名古屋大学情報学研究所
Graduate School of Informatics, Nagoya University
a) enokibori@i.nagoya-u.ac.jp
b) mase@nagoya-u.jp

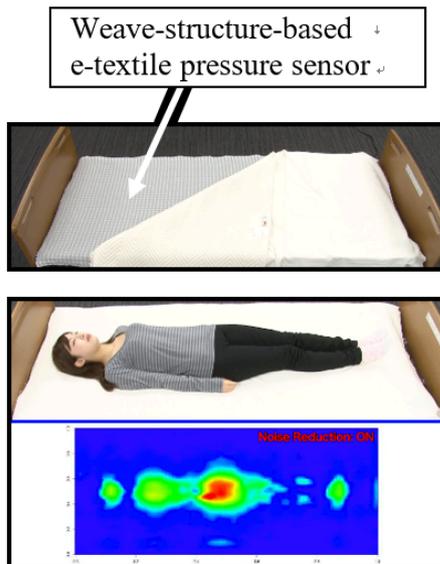


図 1 布センサ及び取得した寝姿体圧データ

Fig. 1 A bed-sheet style e-textile pressure sensor and an example of body pressure data in bed.

大・縮小・回転などの加工を施し、見かけのデータ数を増やして学習を促進する Data Augmentation が有効であることが知られている [9], [10]. ただし、闇雲に増幅すれば良いという物ではなく、識別対象のドメインに適合した適切な加工幅の指定が重要となる。

そこで我々は、睡眠姿勢判定における適切な加工幅をシアー変換・拡大縮小・回転・人体長短軸方向移動の 5 点について探索し、少数の学習データからの高精度な睡眠姿勢識別 CNN の構築を試みた。なお、先に言及した人体長軸方向に沿った左右反転も Data Augmentation の一手法であるが、基本的に常に適用する基礎手法であることから、適用を前提とし検討からは除外した。加えて、データ数が極端に少ない腹臥位姿勢も検討から除外している。上記条件下での探索の結果、人体長軸方向に軸長の 20%、短軸方向に軸長の 40% の範囲内で移動を適用した場合に仰臥位・左右側臥位の 3 姿勢識別において最も精度が向上し、99.7 の識別精度を得ることに成功した。

以下、本稿では第 2 章にて関連研究についてまとめる。第 3 章にて本研究で用いたデータセットについて述べ、第 4 章で姿勢判定に用いた CNN ベース DNN 識別機について述べる。第 5 章にて Data Augmentation の変形パラメータ探索の結果について述べ、第 6 章にて探索結果のパラメータを用いて姿勢識別 DNN を構築した結果について述べる。最後に第 7 章にてまとめる。

2. 関連研究

ベットに敷設した圧力センサから得た寝姿体圧データを用いた就寝姿勢の判別は広く研究されている。SVM (Support Vector Machine) や kNN (k-Nearest Neighbor) を用

いた物が多く、DNN を用いた物は少ない。

SVM を用いた分類としては以下のものがある。ChiChun らは FSR センサにより得られたデータと SVM を用いて腹臥位を含まない 6 姿勢を 83.5% の精度で分類した [11]. また同グループは動画データを併用することで腹臥位を含む 9 姿勢を 94.1% の精度で分類することに成功している。[12]. Mineharu らは寝姿体圧データを複数領域に分割した上で抽出した特徴量と SVM を用いて、腹臥位を含む 9 姿勢を 77.1% の精度で識別した [13]. 著者のグループでも Center of Pressure などの特徴量を用いた SVM で 92.3% で腹臥位を含む 4 姿勢の分類を、96.3% で腹臥位を含まない 3 姿勢の分類を達成している [14].

kNN を用いた研究としては以下のものがある。Yousefi らは二値化した寝姿体圧データに対して PCA と kNN を用いることで、腹臥位を含まない 5 姿勢において 97.7% の精度で識別に成功している [15]. Pouyan らは二値化後の寝姿体圧データとハミング距離類似度を用いた kNN にて腹臥位を含まない 8 姿勢を 97.1% の精度で識別した [16]. Ostadabbas らは GMM と kNN を組み合わせ腹臥位を含まない 3 姿勢を 98.4% の精度で識別した [17].

DNN を用いた研究としては Heydarzadeh らのものがある [18]. Heydarzadeh らは HoG 特徴量を導出し、その HoG 特徴量をオートエンコーダタイプの DNN で学習することで腹臥位を含まない 5 姿勢に対して 98.1% の精度を達成した。本研究では Data Augmentation が用いられているが、その最適パラメータについては議論されていない。また、元のデータ数も不明であるため、少数データから十分な精度を得る Data Augmentation についての議論は不十分である。

3. データセット

本節では、本研究に用いたデータセットについて概説する。本データは 2013 年 9 月に愛知県立大学にて収集した物である。用いたセンサおよび実験条件などは以下の通りである。

3.1 布構造による圧力センサ

本実験で用いた圧力センサを図 2 に、その諸元を表 1 に示す。本センサは布構造によって圧力センサ機能を構築している。カバリングによって絶縁された導電糸の束の縦方向束と横方向束間の静電容量を計測しており、束感の距離が加えられた圧力によって変化すると共に束感の静電容量値が変化することを用いて、布センサ内の相対的な圧力値を得ている。計測周期は最大 10 Hz/面であるが、実験では 2 Hz/面を用いた。感圧点の大きさは約 1 cm 平方であり、図に示すように格子状に並んでいる。従ってセンサ間ピッチは 2 cm \sim 2 $\sqrt{2}$ cm である。本実験では 180 \times 90 cm のシングルベッドサイズを用いた。

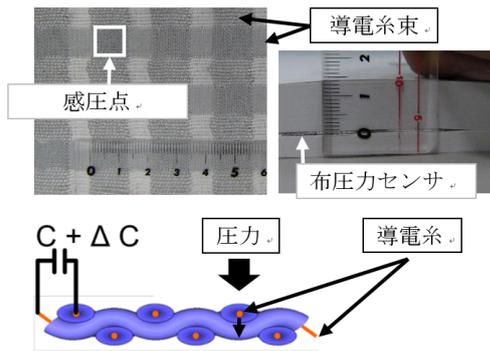


図 2 布構造による圧力センサ

Fig. 2 A overview of textile-weave-structure based pressure-sensor.

表 1 布圧力センサの諸性能

Table 1 Characteristics of e-Textile sensor

センサの大きさ	180 × 90 cm (解像度とセンサ回路に依存)
センサの厚さ	0.6 mm
感圧点の大きさ	1 cm ²
解像度	2 ~ 2√2 cm (中心点間距離)
計測点数	3200 (80 × 40)
計測周波数*	最大 10 Hz / 面
接続形式	Wi-Fi / Bluetooth

* 本研究では 2Hz を用いた。

表 2 被験者の概要

Table 2 Characteristics of Subjects

	高齢者	若年者
年齢	68.8 ± 4.0	21.3 ± 0.8
男性	6	6
女性	4	6
Body Mass Index (BMI)	21.8 ± 3.7	21.3 ± 3.0

* All subjects are healthy.

3.2 被験者

被験者の概要を表 2 に示す。被験者数は合計で 20 名で全て健康者である。高齢者 (男性 6 名, 女性 4 名) の平均年齢は 68.8 ± 4.0, 若年者 (男性 6 名, 女性 6 名) の平均年齢は 21.3 ± 0.8 であった。BMI はそれぞれ 21.8 ± 3.7 と 21.3 ± 3.0 であり, 中肉中背と言える。なお, この内, 高齢者 1 名については機材不良のため欠損データとなっている。従って, 最終的なデータは 19 名分となる。

3.3 実験風景と手順及びサンプルデータ

図 3 に実験時の概要と得られたデータの例を示す。本実験ではベッドシート型布圧力センサを図 1 と同様にベッドとベッドパットの間に配置した。また, 真値の取得のため, 赤外線カメラを 2 台設置した。部屋に照明はなく適温であり就寝に適した環境であった。本環境下で被験者らは

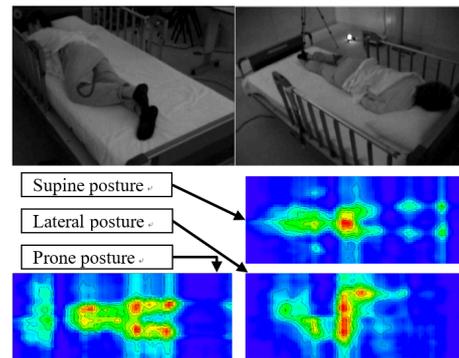


図 3 寝姿勢圧データ収集実験の概要

Fig. 3 A overview of body-pressure data collection.

4 時間の睡眠を取った。なお, 途中でお手洗いへ行くなどの離床は特に制限していない。

図 3 の下段に示したものは計測された寝姿勢圧データの例である。右上より時計回りに, それぞれ仰臥位, 左側臥位, 腹臥位である。ただし, 図 3 に示した例は姿勢が目視で判別可能なものを選択している。本実験では就寝姿勢などは指示しておらず自然な就寝時の寝姿勢圧データとなっている。従って, データには脚を 4 の字に組むんだ仰臥位, 手を枕の下に入れた仰臥位, 両膝を立てた仰臥位, 腕を頭の下に入れた側臥位など, 多様な姿勢が含まれている。

3.4 姿勢データの選別と事後処理

実験で取得したデータには, 体動時や離床時などのデータも含まれている。従って以下に示すポリシーに従って目視でデータを選別した。まず, 5 分以上の体動がない安定した姿勢のみを抽出した。続いて体動がなくなった後の凡そ 1 分後の第 1 フレームをその姿勢の寝姿勢圧データとして抽出した。同一姿勢が継続している間は圧力データに大きな変化が無い場合, 本データセットでは 1 姿勢 1 データとしている。従って単純な分割差検証を行った場合でも同一姿勢のデータが学習とテストの両方に含まれることはない。抽出されたデータは仰臥位: 118 姿勢/16 名, 左側臥位: 51 姿勢/13 名, 右側臥位 40 姿勢/15 名, 腹臥位 15 姿勢/6 名の合計 224 姿勢であった。これらに対してベッド及び人体の長軸方向に沿って反転したデータを追加し, 最終的なデータは仰臥位: 236 姿勢/16 名, 左側臥位: 91 姿勢/13 名, 右側臥位 91 姿勢/15 名, 腹臥位 30 姿勢/6 名の合計 448 姿勢となった。

4. 寝姿勢識別のための CNN ベース DNN 識別機

本研究で寝姿勢識別に用いた CNN ベースの DNN 識別機を図 4 に示す。本ネットワークは, 小数の感圧点しか持たない圧力センサのデータに対応できるように, 入力サイズを 28 × 28 とした。従って, 80 × 40 で取得しているセンサデータを前処理でサブサンプリングして縮小して

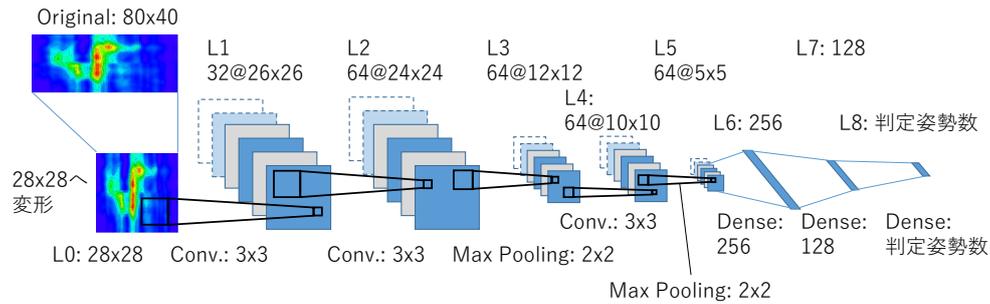


図 4 寝姿体圧データを用いた寝姿姿勢識別 DNN

Fig. 4 A CNN based DNN for in-bed posture classification.

いる。続いて 3×3 のコンボリューション層を 2 層導入している。カーネル数はそれぞれ 32 と 64 である。その後に 2×2 の Max Pooling 層を導入して位置情報のずれに対応した後、もう一度カーネル数 64 のコンボリューション層を通し、再度、 2×2 の Max Pooling 層を導入している。全結合層は 256 カーネル、128 カーネルの 2 段であり、その後には識別姿勢数の全結合層を出力層としている。活性化関数は出力層が softmax, それ以外は全て ReLU である。学習の最適化には Nadam を用いた。

5. 適切な Data Augmentation パラメータの探索

本研究では、小数データにおいて高精度な寝姿姿勢識別機を構築するため、入力画像を変形拡張する Data Augmentation の適切な加工幅をシアー変換・拡大縮小・回転・人体長短軸方向移動の 5 点について探索した。変換後画像の例を図 5 に示す。以下、本章で詳しく述べる。

5.1 パラメータの探索範囲

本稿における各加工幅の探索範囲を以下に示す。

- シアー変換: $\pm 0, 0.2, 0.4, 0.6$
- 拡大縮小: $\pm 0, 0.2, 0.4, 0.6$ 倍
- 回転: $\pm 0, 90, 180, 270, 360$ 度
- 人体長軸方向移動: 軸長の $\pm 0, 0.2, 0.4, 0.6$ 倍幅
- 人体短軸方向移動: 軸長の $\pm 0, 0.2, 0.4, 0.6$ 倍幅

組み合わせ総数は 1,280 組である。入力画像は指定された範囲内で無作為に変換した。なお、各変換は重複して一つの画像に適用した。

5.2 探索手順

第 3 章にて示したデータセットから仰臥位・左右側臥位の 3 姿勢について、奇数番号被験者を学習データ、偶数番号被験者を検証データとして各パラメータの組み合わせ時の学習を行い、Data Augmentation における適切な加工幅を探索した。腹臥位はデータ数が極端に少ないため、本探索では除外した。学習データにのみ Data Augmentation

を適用し、検証データは加工していない。バッチサイズは 64, 1 エポックあたりの学習ステップは 200, 総エポック数は 30 とした。従って、各試行では 384,000 個の変換済み画像が学習される。加工元画像の選出順はランダムである。一通り全ての画像がランダムに選出された場合、全ての画像から再び選出を開始した。各試行での最終結果は、検証ロスが最も少なかったエポックの結果とした。また、各パラメータの組み合わせにおいて、学習を 2 回ずつ実行し、次節以降で用いる学習ロスや検証ロスには、その平均値を用いた。

5.3 探索結果と考察

DNN では検証ロスによって学習済みモデルが評価されるのが一般的である。これは学習ロスのみで判断すると、過学習になっている事が多いためである。しかし、本実験を試行したところ、学習ロスが高いまま、検証ロスのみが極端に低くなる事例が散見された。これは検証データに過適合していると言える。従って、本稿では、学習ロス及び検証ロスがともに低くなるパラメータ組が良い組み合わせであるとする。図 6 に全パターンでの学習ロス及び検証ロスの平均値を降順に並べたグラフを、図 7 に探索結果のトップ 10 を示す。図 7 は各ランクにおいて左より、赤破線がシアー変換、緑点線が拡大縮小、青鎖線が人体長軸方向移動、水色長破線が人体短軸方向移動、紫長鎖線が回転のパラメータを示す。黒実線は各ランクでの学習ロス及び検証ロスの平均値である。

図 6 からパラメータの選択は、識別機の構築結果に大きく影響を与えることが分かる。また、図 7 のグラフから分かるとおり、回転は探索した範囲内において、有効に働かなかったことが分かる。従って、今改定検討したパラメータ値では回転を用いない方が良いという結論となる。拡大縮小も上位 5 位まで有効ではなく、以下 10 位までには ± 0.2 倍のパラメータのみが散見される。従って、利用するとしても ± 0.2 倍程度が妥当と言える。人体長軸方向の移動は軸長の ± 0.2 幅を限度とすることが妥当と考えられる。人体短軸方向の移動は軸長の ± 0.2 幅ないし ± 0.4 幅を

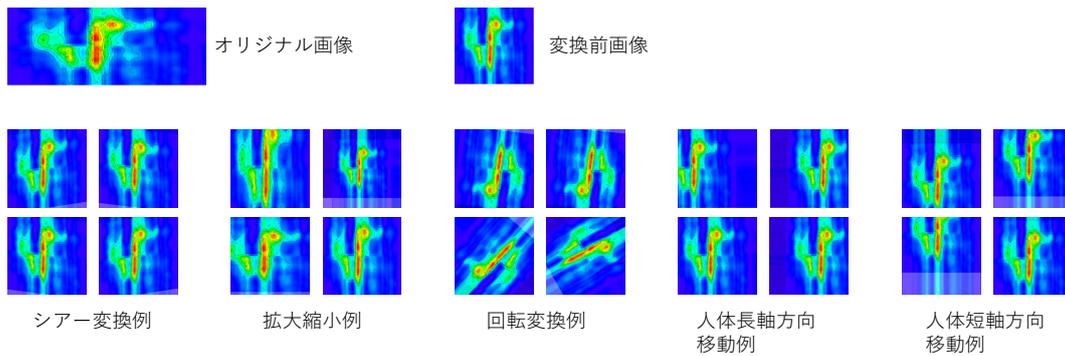


図 5 Data Augmentation の適用例

Fig. 5 Examples images transformed by Data Augmentation.

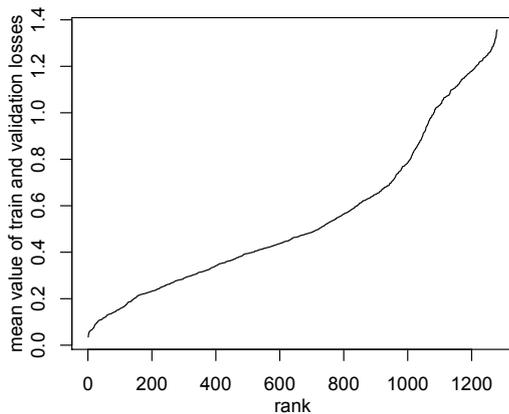


図 6 パラメータ組別の学習ロスと検証ロスの平均値

Fig. 6 Mean values of train and validation losses of all training.

用いるのが妥当と考えられる。本稿では上位 3 位まで、および、上位 5 位までの最頻値である軸長の ± 0.4 幅を用いることが適当とする。シアー変換は有効なパラメータの取り幅が大きい。 ± 0.6 のパラメータも上位 7 位に存在している。しかし、本稿では上位 5 位までの結果ら、 ± 0.0 ないし ± 0.2 を用いるのが妥当と結論づけた。

6. 探索結果パラメータを用いた寝姿姿勢判別 CNN ベース DNN 識別機の構築

前章で得られた結果から、本稿では以下のパラメータを用いて CNN ベース DNN の寝姿姿勢識別機を仰臥位・左右側臥位の 3 姿勢について学習した。

- シアー変換: 0
- 拡大縮小: 0 倍
- 回転: 0 度
- 人体長軸方向移動: 軸長の ± 0.2 倍幅
- 人体短軸方向移動: 軸長の ± 0.4 倍幅

学習・検証・評価は、以下に示す交差検証で行った。

- 固定学習データ: 奇数番号被験者
- 学習・検証・評価データ: 偶数番号被験者の各 1/3 (d_0, d_1, d_2)

従って、交差検証の回数は計 6 回である。

表 3 Data Augmentation を用いない場合の精度

Table 3 Accuracy of each training w/o Data Augmentation

データ				精度
学習	検証	評価		
d_0	d_1	d_2	7.592	
d_1	d_2	d_0	9.655	
d_2	d_1	d_0	9.655	
d_0	d_2	d_1	9.756	
d_1	d_0	d_2	7.777	
d_2	d_0	d_1	9.756	
平均 ± 標準偏差			0.903 ± 0.095	

表 4 Data Augmentation を用いない場合の混合行列

Table 4 Confusion matrix w/o Data Augmentation

		識別結果			recall	F ¹
		左側臥	右側臥	仰臥		
真値	左側臥	67	3	6	0.882	0.865
	右側臥	3	69	4	0.908	0.885
	仰臥	9	8	219	0.928	0.942
precision		0.848	0.863	0.956		
		Total Accuracy			0.916	
		Weighted F ¹ -score			0.915	

6.1 適切なパラメータと Data Augmentation を用いて構築した識別機の性能

各検証において 10 回の学習を試行し、最も検証ロスが小さかったエポックの学習結果を、その検証での学習結果とし、評価データに対する識別精度 ($\frac{TP}{TP+FP+TN+FN}$) を導出した。Data Augmentation を用いなかった場合の各検証の精度、及び、全検証を統合した混合行列を表 3 と表 6 に示す。Data Augmentation を用いた場合の各検証の精度、及び、全検証を統合した混合行列を表 5 と表 4 に示す。

混合行列の下部と右部に姿勢別の precision ($\frac{TP}{TP+FP}$) と recall ($\frac{TP}{TP+FN}$) が示されており、最右列に示しているのは F¹-score ($2 \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}}$) である。Total

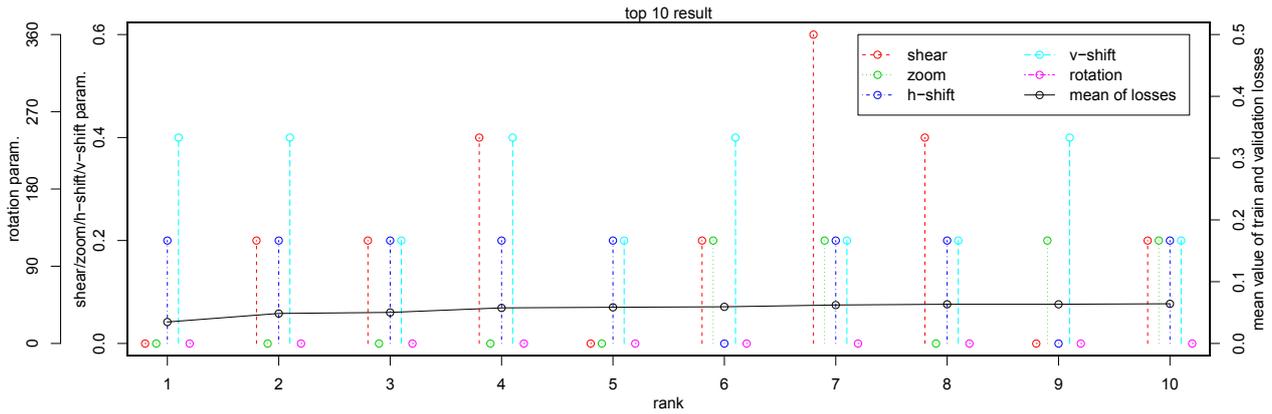


図 7 パラメータ探索結果のトップ 10
Fig. 7 Top 10 result of parameter search.

表 5 Data Augmentation を用いた場合の精度

Table 5 Accuracy of each training w/ Data Augmentation

データ			
学習	検証	評価	精度
d_0	d_1	d_2	1.000
d_1	d_2	d_0	1.000
d_2	d_1	d_0	1.000
d_0	d_2	d_1	1.000
d_1	d_0	d_2	1.000
d_2	d_0	d_1	9.878
平均 ± 標準偏差			0.998 ± 0.005

表 6 Data Augmentation を用いた場合の混合行列

Table 6 Confusion matrix w/ Data Augmentation

		識別結果			recall	F ¹
		左側臥	右側臥	仰臥		
真値	左側臥	76	0	0	1.000	1.000
	右側臥	0	75	1	0.987	0.993
	仰臥	0	0	236	1.000	0.998
precision		1.000	1.000	0.996		
		Total Accuracy			0.997	
		Weighted F ¹ -score			0.997	

racy は混合行列全体における精度である。最下段にある Weighted F¹-score は各クラスのサンプル数に従って重み付けをした数値であり、クラス毎のサンプル数の不均等を補正している。定義は以下の通りである。

$$\text{Weighted F1-score } (F_i^1) = \sum_i w_i F_i^1$$

$$w_i = n_i/N$$

where i : i-th class,

F_i^1 : F¹-score of i-th class,

n_i : sample size of i-th class,

N : total size of samples.

表 3 と表 5 の比較から、Data Augmentation を適切なパラメータで用いることで劇的に精度が向上していることが分かる。表 6 と表 4 の混合行列の比較からも同様の結果が言える。また、Total Accuracy と Weighted F¹-score はどちらの混合行列においても同程度であり、サンプル数の多い姿勢のみが優先的に学習されたわけでもないことが分かる。

6.2 関連研究との精度比較

表 7 に関連研究との比較結果をまとめた。表 7 に示すように、他の関連研究と比較して、提案手法で構築した DNN は高い識別精度を示している。なお、同様に DNN を用いている関連研究 [18] は左右 2 種類の側臥位 (計 4 姿勢) と仰臥位の識別であり、左右側臥位および仰臥位の 3 姿勢に補正すると識別精度は 100% となる。しかし、本研究で用いたデータは、収集時に就寝姿勢を指示しておらず、脚を 4 の字に組んだ仰臥位や腕を枕の下に入れた側臥位などの多様な姿勢データを含んだデータであり、提案手法はその学習と識別において同等の精度を示している。加えて、元となる学習データ数がごく少数でも高い精度を示している。また、HoG 特徴などを事前に抽出することなく得られた圧力データを画像として直接 DNN に投入していることから、画像処理分野の DNN 研究において提案された新手法を導入しやすいという特徴が有る。

7. まとめ

本稿では、少数の就寝時の体圧データからの高精度な DNN 学習を実現するため、適切な Data Augmentation パラメータを探索した。シアー結果、人体長軸・短軸方向に軸長の 40%、20% の移動による Data Augmentation によって 99.7% の識別精度を達成した。提案手法は HoG 特徴などを事前に抽出することなく得られた圧力データを画像として直接 DNN に投入していることから、画像処理分

野のDNN研究において提案された新手法を導入しやすいという特徴が有る。また、本研究で用いたデータは、収集時に就寝姿勢を指示しておらず、脚を4の字に組んだ仰臥位や腕を枕の下に入れた側臥位などの多様な姿勢データを含んだデータであり、提案手法は非管理環境下でに置ける寝姿識別でも同様に高い識別性度を示すことが期待できる。今後は、腹臥位や左右側臥位のバリエーションなど、より細かな姿勢の識別について検討を続ける。

謝辞 本研究の一部は、JSPS 科研費 15H02736, 総務省が進める戦略的情報通信研究開発推進事業 (SCOPE), 「知の拠点 あいち」重点プロジェクト事業の支援を受けて実施されました。また、実験データの収集・分析にあたり愛知県立大学看護学部の皆様にご協力頂きました。ここに感謝の意を表します。

参考文献

- [1] Krizhevsky, A., Sutskever, I. and Hinton, G. E.: ImageNet classification with deep convolutional neural networks, *Advances in neural information processing systems*, pp. 1097–1105 (2012).
- [2] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A.: Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1–9 (2015).
- [3] He, K., Zhang, X., Ren, S. and Sun, J.: Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778 (2016).
- [4] Toshev, A. and Szegedy, C.: Deeppose: Human pose estimation via deep neural networks, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1653–1660 (2014).
- [5] Pishchulin, L., Insafutdinov, E., Tang, S., Andres, B., Andriluka, M., Gehler, P. V. and Schiele, B.: Deepcut: Joint subset partition and labeling for multi person pose estimation, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 4929–4937 (2016).
- [6] Insafutdinov, E., Pishchulin, L., Andres, B., Andriluka, M. and Schiele, B.: Deepcut: A deeper, stronger, and faster multi-person pose estimation model, *European Conference on Computer Vision*, Springer, pp. 34–50 (2016).
- [7] Wang, H., Lin, X., Zhang, Y. and Lee, T. S.: Learning Robust Object Recognition Using Composed Scenes from Generative Models, *arXiv preprint arXiv:1705.07594* (2017).
- [8] Sun, Z., Ozay, M. and Okatani, T.: Improving Robustness of Feature Representations to Image Deformations using Powered Convolution in CNNs, *arXiv preprint arXiv:1707.07830* (2017).
- [9] Lin, M., Chen, Q. and Yan, S.: Network in network, *arXiv preprint arXiv:1312.4400* (2013).
- [10] Xu, Y., Jia, R., Mou, L., Li, G., Chen, Y., Lu, Y. and Jin, Z.: Improved relation classification by deep recurrent neural networks with data augmentation, *arXiv preprint arXiv:1601.03651* (2016).
- [11] Hsia, C., Liou, K., Aung, A., Foo, V., Huang, W. and Biswas, J.: Analysis and comparison of sleeping posture classification methods using pressure sensitive bed system, *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, IEEE, pp. 6131–6134 (2009).
- [12] Huang, W., Wai, A. A. P., Foo, S. F., Biswas, J., Hsia, C.-C. and Liou, K.: Multimodal sleeping posture classification, *Pattern Recognition (ICPR), 2010 20th International Conference on*, IEEE, pp. 4336–4339 (2010).
- [13] Mineharu, A., Kuwahara, N. and Morimoto, K.: A study of automatic classification of sleeping position by a pressure-sensitive sensor, *Informatics, Electronics & Vision (ICIEV), 2015 International Conference on*, IEEE, pp. 1–5 (2015).
- [14] 林千尋, 原健翔, 榎堀優, 間瀬健二ほか: 布圧力センサを用いた睡眠時の姿勢分類, 研究報告コンピュータビジョンとイメージメディア (CVIM), Vol. 2016, No. 7, pp. 1–6 (2016).
- [15] Yousefi, R., Ostadabbas, S., Faezipour, M., Farshbaf, M., Nourani, M., Tamil, L. and Pompeo, M.: Bed posture classification for pressure ulcer prevention, *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, IEEE, pp. 7175–7178 (2011).
- [16] Pouyan, M. B., Ostadabbas, S., Farshbaf, M., Yousefi, R., Nourani, M. and Pompeo, M.: Continuous eight-posture classification for bed-bound patients, *6th International Conference on Biomedical Engineering and Informatics*, IEEE, pp. 121–126 (2013).
- [17] Ostadabbas, S., Pouyan, M. B., Nourani, M. and Kehtarnavaz, N.: In-bed posture classification and limb identification, *Biomedical Circuits and Systems Conference (BioCAS), 2014 IEEE*, IEEE, pp. 133–136 (2014).
- [18] Heydarzadeh, M., Nourani, M. and Ostadabbas, S.: In-bed posture classification using deep autoencoders, *Engineering in Medicine and Biology Society (EMBC), 2016 IEEE 38th Annual International Conference of the*, IEEE, pp. 3839–3842 (2016).
- [19] Liu, J. J., Xu, W., Huang, M.-C., Alshurafa, N., Sarrafzadeh, M., Raut, N. and Yadegar, B.: Sleep posture analysis using a dense pressure sensitive bedsheets, *Pervasive and Mobile Computing*, Vol. 10, pp. 34–50 (2014).

表 7 関連研究との精度比較
Table 7 Accuracy comparison with related works.

参考文献	センサ	センサ点数	識別機	精度	姿勢数	腹臥位の有無	被験者数	総データ数	姿勢指定	同一姿勢内のパ リエーション	学習/評価デー タにおける同一 姿勢データの明 確な排除
[11]	Pressure (FSR)	56	RawData + SVM	83.5	6	NO	8	43200	YES	NO	YES (3 subject / 5 subject)
[12]	Pressure (FSR) + Video	60+video	PCA + SVM	94.1	9	YES	3	> 10800	YES	NO	YES (Leave one subject out CV)
[13]	Pressure Array	3536	CoP, etc. + SVM	77.1	9	YES	10	270	YES	NO	YES (one data for each posture)
[14]	Pressure Array	3200	CoP, etc. + SVM	92.3	4	YES	19	2240	NO	YES	YES (Leave one subject out CV)
[15]	Pressure Array	2048	PCA + kNN Hamming	97.7	5	NO	6	NA	YES	NO	YES (Leave one subject out CV)
[16]	Pressure Array	2048	distance similarity + kNN	97.1	8	NO	20	3200	YES	NO	NA
[17]	Pressure Array	1728	GMM + kNN Sparse	98.4	3	NO	9	NA	YES	YES	NA
[19]	Pressure Array	8192	Classifier with Minimum Class Residual	83.2	6	YES	14	3360	YES	NO	YES (Leave one subject out CV)
[18]	Pressure Array	2048	HOG+DNN	98.1	5	NO	10	NA+DataAug	YES	NA	NA
ours	Pressure Array	(subsampling from 3200) 784	DNN	99.7	3	NO	19	224+DataAug	NO	YES	YES (one data for each posture)