

非密着型センサ実用化に向けた 布圧力センサの表面形状推定の検討

加藤 寛貴^{1,a)} 榎堀 優¹ 吉田 直人² 間瀬 健二¹

概要：非密着衣類型センサの最たる問題となっている人体衣類間の位置ズレや皺の影響などを克服する方法の一つとして、衣類型センサの3次元形状推定が考えられる。衣類型センサを着用しつつ日常生活などを行うことを考慮すると、据え置きカメラなどの外部環境や、人体から張り出したモバイルカメラなどの付加装置に依存せず、衣類に付加されたセンサだけで衣類の3次元形状が把握できることが望ましい。これに対し我々は、布に密にセンサ点を配置でき、かつ、布構造の変化で出力値が変動する我々の研究している布圧力センサが好適である可能性を見いだした。本研究では、その検証の第1ステップとして衣類の1部分を布圧力センサに置き換え、布圧力センサの表面形状推定を検討した。衣類の状態を変化させつつRGB画像とセンサ出力値を収集し、正解値をRGB画像からPIFuHDを用いて作成した。センサ出力値に対し、7段の3DCNNによる形状推定を試みたところ、誤差12.23 mmにて形状が推定できることが分かった。

キーワード：圧力画像、3次元形状推定、3次元モデリング、2DCNN、3DCNN

1. はじめに

近年、ウェアブル技術の発展に伴い、衣類型の生体センサが普及している。みずほ情報総研株式会社による生体データの取得に関する取組事例^{*1}で紹介されている衣類型センサは、人体の位置情報を使わないセンサ（導電布を電極として使ったECG）か、人体肌と密着した衣類センサ（hitoe^{*2}など）が多い。しかし、これらの密着型衣類センサは、締め付けなどの心理的障壁や通気性が悪く蒸れやすい問題もあり、普段着として着用することは難しい。

これに対し、非密着衣類型センサは、ほとんど実用化されていない。その大きな要因の一つに日常生活中におけるずり上がり等に起因する人体衣類間の位置ずれ、皺などによるセンサの位置ずれや衣類内への巻き込みなどによるセンサ値への影響を克服する方法が未実現であることが挙げられる。

そこで我々は、我々が衣類型圧力センサの研究など[1][2]で利用している布圧力センサが、圧力だけではなく、曲げ

等によっても微細な出力値変化を起こすことに着目し、布圧力センサで構成した衣類の3次元形状推定を目指す。これにより、どこに皺があるのかなど把握が可能となり、布圧力センサで構成された衣類の上にセンサを配置することで、各種センサが皺などの影響を考慮できるようになる。

本研究では、第1ステップとして衣類の1部分を布圧力センサに置き換え、布圧力センサ部分の表面形状推定を検討した。第1検討として、3DCNNによる時系列圧力値の畳み込みを行い、表面形状の3次元座標を推定する手法を提案する。

本論文の構成は以下のとおりである。第2節では、関連研究を挙げることにより本研究の立ち位置を明確にする。第3節では、提案手法の検討・評価に用いたデータセットについて述べる。第4節では、時系列圧力値から布圧力センサの3次元表面形状を推定する手法について述べる。第5節では、評価実験と結果について述べる。最後に第6節では、本研究の総括および、今後の研究課題を述べる。

2. 関連研究

人体・衣類の表面形状を推定する研究や、圧力画像を用いて人体をモニタリングする研究は盛んに行われている。しかし、圧力画像から、その圧力センサの表面形状を推定する研究は行われていない。本節ではRGB画像からの表面形状推定、圧力画像を用いた研究について述べ、本研究

¹ 名古屋大学 情報学研究科

Graduate School of Informatics, Nagoya university

² 名古屋大学 未来社会創造機構

Institute of Innovation for Future Society, Nagoya university

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

^{*1} みずほ情報総研株式会社:https://www.meti.go.jp/meti_lib/report/H29FY/000379.pdf (最終閲覧:2022/01/21)

^{*2} Toray Group hitoe:<https://www.hitoe.toray/> (最終閲覧:2022/01/21)

の立ち位置を示す。

2.1 RGB 画像からの表面形状推定

衣類や人物の表面形状推定は、DNN とカメラ画像・深度カメラを利用する手法が高精度であり、広く研究されている。表面形状推定の初期の手法として、多視点のカメラ画像から 3 次元的な構造を推定する手法が多く提案されている [3][4][5]。しかし、これらの手法はメモリを大量に使用するため、解像度が低く、細かい形状を推定できないという問題がある。

そこで、メモリ効率を良くし、解像度が高い推定が可能な PIFu[6] が提案された。PIFu は、服の皺などの表面の形状が豊富な服を着た人間のデータに対して、高品質な表面形状推定を初めて行った。しかし、PIFu は特徴の曖昧性が残っており、全体的な形状のロバスト性に欠ける。PIFu の派生研究として、ARCH[7]、PIFuHD[8] が提案された。ARCH では、パラメトリックな人間メッシュ (SMPL[9] など) と、陰関数を組み合わせることで、人間メッシュにスキンウェイトを割り当て、衣類を着た人物メッシュのアニメーションを可能にした。PIFuHD では、GPU のメモリ制約に対応するため、人体の裏側を先に推定し、パッチベースの特徴抽出を行うことで、PIFu よりも高解像度の入力を活用した。

本研究では、推定が簡単で高精度な PIFuHD を用いて、マネキン画像から 3D モデルを推定し、布圧力センサ部分を切り出すことで、表面形状の正解値の作成を行った。

2.2 圧力画像を用いた人体モニタリング

圧力画像を用いた研究は、様々な場面で人間のモニタリング、モデル化に役立っている。小野瀬ら [10] は布圧力センサを用いた褥瘡予防教育支援システムを構築した。岩瀬ら [2] は寝姿体圧画像からの関節位置推定において、人物領域と姿勢情報を用いることで推定精度を改善出来ることを示した。加藤ら [11] は寝姿体圧画像から 3 次元の関節位置も推定できることを示した。また、Luo ら [12] はカーペット型の圧力センサから得られた時系列圧力画像から、立位状態の関節位置を推定できることを示した。

2.3 本研究の立ち位置

画像分野では、RGB 画像からの 3 次元の表面形状推定が盛んに研究されている。しかし、日常生活において表面形状を推定する際には、据え置きカメラなどの外部環境や、人体からはみ出したモバイルカメラなどの付加装置に依存せず、衣類に付加されたセンサのみで表面形状を推定することが望ましい。用いる圧力画像は、一般的な RGB 画像よりも低い解像度であるが、人体の近くでデータを収集するため、RGB 画像にありがちなオクルージョンの問題がない。さらに、人体が布圧力センサに接しているかどうかなどの情報が得られる。本研究では視覚情報を一切使用せ




図 1 データ計測の様子

ず、圧力画像のみから 3 次元表面形状の推定を目指す。

3. データセットの収集と事後処理

本節では、提案手法の説明に先立ち、本研究で用いる布圧力センサと、評価に用いたデータセットの収集方法と事後処理について述べる。DNN による学習には大量のデータが必要であり、自動的にデータを収集するシステムが必要である。3 次元データの収集には、Kinect などのステレオカメラを用いたものや、光の飛行時間をベースに距離を導出する LiDAR などがある。しかし、将来的には、スカート前面だけではなく、裏側も含めた全面的推定を目的としていることや、皺などが折り重なる部分があることから、Kinect や LiDAR では正確な点群データの収集が難しいと考えられる。そこで、裏側までも推定でき、高解像度な 3 次元モデルを推定できる、PIFuHD によるデータセットの作成を検討する。

3.1 布圧力センサ

本研究では、Enokibori らが提案した布圧力センサ [13] から得られた圧力値を用いて 3 次元表面形状を推定する。導電性繊維を縦糸と横糸の一部に利用しており、それらが交差する各点で、静電容量回路を構成している。布にかかる圧力に応じて、縦横の導電糸間の距離が変化し、それに伴う静電容量の変化を計測して各点の圧力を計算する。本センサの感圧部位は、2.5mm 幅の不感域を挟み、7.5mm 角の計測点が格子状に並んでいるため、不感圧部位が狭い。この布圧力センサは、見た目上は通常の平織り布と同様であり、自由形状を取ることができる。また、柔らかく簡単に形を変えやすいため、様々な表面形状を推定する本研究に好適である。

3.2 データ計測手順

本研究では、人型マネキンに着せた衣類の 1 部分に布圧力センサを貼り付け、動画を撮影した様子を図 1 左に示す。



図 2 データセットに含まれる画像

これと同時に、布圧力センサによって、動画の時系列と同期した布圧力センサ値を取得した。

布圧力センサの形状変化をさせるために、センサの人体側に、図 1 右の 15cm の棒を取り付けたサーボモータを入れ、2 秒間隔で上げ下げを行うシステムを作成した。このシステムを利用し、布圧力センサを内側から押し上げることで、布圧力センサの形状変形を行った。押し上げシステムを左右にずらすことで、図 2 のような違う場所を押し上げたデータを含むデータセットを構築した。

学習用データとテストデータで酷似したデータをなくすために、学習用データとテストデータは別日に取得した。データセットには、入力値と出力値のデータ対で、学習データとして 951 対、テストデータとして 100 対のデータが含まれる。

3.3 データセットの事後処理

計測した圧力画像を、単純移動平均により時系列方向で平滑化し 10Hz でリサンプリングを行った。圧力画像は、押し上げが行われた瞬間を起点にして前後 2s、合計 4s (40 フレーム) の時系列圧力値を入力値として使用する。

撮影した動画から、最初に押し上げた時を起点として、4s 間隔で画像を切り出す。切り出した画像を入力画像として、PIFuHD によりマネキンの 3 次元表面形状を作成する。ただし、PIFuHD は照明などの問題により正しく推定できない場合があるため、布圧力センサ部分の推定がうまくできていない画像については、人目で判断し、データセットから除外した。

図 3 中央に示すような 3 次元表面形状から、布圧力センサ部分を切り出すため、布圧力センサ部分をクロッピングし、縦 40 点 × 横 20 点の合計 800 点を PIFuHD 出力から抽出した。抽出には、クロッピングした部分に縦 40 点 × 横 20 点を均等に配置し、それぞれに最近傍法を用いて、正解値を作成した。




図 3 正解値作成方法




図 4 提案手法のネットワーク概要図

作成した正解値を図 3 右に示す。その後、x, y, z 軸それぞれで、平均を 0、分散を 1 にする標準化を行った。

4. 2D/3DCNN を基礎とした表面形状推定手法の模索

本節では、CNN をベースとして、布圧力センサ値から表面形状を推定する手法を模索した結果を述べる。Luo らは、7 段の 2DCNN を用いた Encoder と 6 段の 3DCNN を用いた Decoder により、足下の圧力センサ値から、圧力センサの上に立った人物の各関節位置の 3 次元ヒートマッ

プを推定した。我々の課題においても、同程度の複雑さのネットワークによって、成果を得られる可能性がある。そこで、我々は、研究の第1ステップとして、図4に示す、Luoらの手法と同様のEncoderに全結合層を追加し、推定することを試みた。本実験は、最終的に800点の点群推定を行うため、3DCNNではなく全結合層で推定を行った。

なお、布圧力センサの短辺、長辺をそれぞれx軸・y軸とし、その面の垂直方向をz軸とする。

4.1 布圧力センサ表面形状推定手法

本研究で用いたネットワーク構造を図4に示す。入力圧力画像から表面形状推定は、Convolutionが7層続いた後に全結合層を2層つなげたネットワークである。これは、Luoら[12]の手法の時系列圧力値から特徴量を抽出するEncoder部分に、全結合層を追加した形で実装した。

ネットワークのConvolution部分では、2DCNNと、時系列の関係をより適切に把握できる3DCNNで比較し、それぞれのネットワークによる推定精度を示すことで、今後の圧力センサ値からの布圧力センサ表面形状推定研究におけるベースラインを示す。2DCNNでは、圧力画像は1フレームに対して1次元分しかないため、色チャンネルを畳み込む部分を、時系列情報として畳み込む。これにより、時系列圧力画像の時系列を一括で見ることができる。3DCNNでは、入力深さチャンネルを畳み込む部分を時系列情報とし、色チャンネルは1次元のまま畳み込みを行う。これにより、3次元依存関係をカーネルサイズに区切って見ることができる。

モデルの学習は、推定値と正解値の二乗平均平方根誤差(RMSE)が最小になるように行う。最適化関数にはAdadeltaを用い、初期学習率は1.0、学習率を2epoch毎に0.7倍し、100epoch学習する。モデルを訓練する際には、10個のランダムシードにより学習を行い、その平均を最終的な精度とする。

正解値の作成方法から、x軸・y軸方向の座標は全てのデータで規則的である。しかし、z軸方向の座標は、布を押上げたデータを使用しているため、変化が大きく、推定が難しいと考えられる。そこで、z軸の変化をより捉えたモデルを構築するため、z軸方向に対するロスの重みを強くした。最終的に、時系列圧力画像を入力として、縦40点×横20点=計800点の布圧力センサ表面点群推定を行う。

5. 評価実験

本節では、布圧力センサから得られた圧力画像を用いた表面形状推定の精度を評価した。その方法と結果について述べる。

5.1 評価方法

提案手法による推定結果を検証するため、定量的結果と

表1 2D/3DCNNによる推定のRMSEと平均3次元距離				
ネットワーク		RMSE [mm]	[mm]	
2DCNN	X	2.38	平均3次元距離	14.00
	Y	2.50		
	Z	13.57		
3DCNN	X	2.28	平均3次元距離	12.23
	Y	2.49		
	Z	11.76		

して正解値と推定値の平均3次元距離を示す。また、x軸、y軸、z軸方向それぞれの推定精度を示すため、それぞれの二乗平均平方根誤差(RMSE)を示す。また、推定結果がどれだけ尤もらしいかを示すため、定性的結果としてRGB画像、正解値、2DCNN推定値、3DCNN推定値を可視化した結果を比較する。z軸方向のロス重みづけを行うことで、平均3次元距離を小さくできると考え、z軸方向ロスの重みを強くした時の有効性の検証を行った。

5.2 2D/3DCNNによる定量的結果

実験結果を表1に示す。2DCNN、3DCNNそれぞれ学習したところ、各点の平均3次元距離が、14.00 mm、12.23 mmであり、3DCNNのほうが精度が良いことを確認した。2DCNNを用いた推定手法における、x軸、y軸、z軸方向のRMSEはそれぞれ2.38 mm、2.50 mm、13.57 mmであった。3DCNNを用いた推定手法の各軸方向のRMSEはそれぞれ2.28 mm、2.49 mm、11.76 mmであった。

5.3 2D/3DCNNによる推定の可視化

時系列圧力値から、2D/3DCNNを用いた推定結果を図5に示す。左列から、RGB画像、正解値、2DCNNによる推定値、3DCNNによる推定値を示しており、点群画像の上段、下段は布圧力センサのそれぞれ右下、左下から見た点群画像となっている。正解値と推定値を比較すると、x軸・y軸方向に一定間隔で点群が推定されており、滑らかな一枚の布のようなものが推定できていることがわかる。

5.4 z軸方向のロス重み付けを強くした時の有効性検証結果

z軸方向のロスを1倍、10倍、100倍した時の2D/3DCNNの精度を比較する。比較結果を表2に示す。2DCNN推定手法における、z軸方向のロスを1倍、10倍、100倍にした全体のRMSEは、それぞれ14.01 mm、17.80 mm、25.69 mmであった。3DCNN推定手法における、同条件の全体のRMSEは、それぞれ12.24 mm、11.81 mm、12.34 mmであった。2DCNN、3DCNNどちらの条件でも、z軸方向のロス重み付けを強くした場合、z軸方向のRMSEは小さくなったが、2DCNNでは、z軸方向のロスを10倍にした段階で、y軸方向のRMSEが4倍程度の大きさとなり、全体のRMSEが大きくなった。3DCNNでは、z軸方向のロスを10倍にした段階では、z軸方向のRMSEの改善率が




図 5 2D/3DCNN による推定結果




図 6 z 軸方向のロス重み付けをした 3DCNN による推定結果

高く、全体の RMSE が小さくなった。しかし、z 軸方向のロスを 100 倍にした段階では、z 軸方向の RMSE は小さくなったが、x 軸・y 軸方向の RMSE が大きくなったため、全体の RMSE が大きくなった。

RMSE 指標で精度が高い 3DCNN において、それぞれの学習時ロスの収束グラフを図 7、推定結果を図 6 に示す。収束グラフは、上段から、z 軸方向のロスを 1 倍、10 倍、100 倍にした学習時ロスのグラフを示している。それぞれ学習が進むにつれ、ロスが小さくなり学習が進んでいることがわかる。

推定結果図 (6) は左列から、正解値、z 軸方向のロスを 1 倍、10 倍、100 倍した時の 3DCNN による推定結果を示している。z 軸方向のロスを 10 倍にした推定結果に注目すると、精度としては z 軸方向の重み付けを強くしていない推定精度よりも良い精度であるはずだが、点群がまばらな推定になってしまい、布圧力センサの表面とはいえない推定となった。

5.5 考察

表 1 より、z 軸方向の RMSE は、x 軸・y 軸方向の RMSE と比較して、4.5 倍の大きさがあることがわかる。これより、正解値を作成する際、縦 40 点 × 横 20 点を均等に配置し、それぞれに対して最近傍法により抽出しているため、x 軸・y 軸座標の並びは、等間隔で規則的であるため推定は簡単であるが、z 軸方向は不規則な値であるため、推定

表 2 z 軸方向のロス重み付けによる定量的結果

ネットワーク		RMSE [mm]		
		$Z_{loss} \times 1$	$Z_{loss} \times 10$	$Z_{loss} \times 100$
2DCNN	X	2.38	5.82	10.50
	Y	2.50	10.99	20.77
	Z	13.57	12.73	10.88
	全体	14.01	17.80	25.69
3DCNN	X	2.28	3.72	4.23
	Y	2.49	6.55	7.72
	Z	11.76	9.10	8.65
	全体	12.24	11.81	12.34

が難しく、RMSE が大きいことが確かめられた。

また、3DCNN はカーネルの動きが 3 次元になり、3 次元内の依存関係をより適切に把握でき、入力時系列圧力値を適切に畳み込むことができるため、2DCNN より、3DCNN が良い精度となると想定してネットワークを作成した。表 1 より、3DCNN による推定は 2DCNN による推定よりも、平均 3 次元距離指標で 1.77 mm の誤差改善が行われており、3DCNN により適切に学習が行われたことが確かめられた。

z 軸方向のロス重み付けを行うことで、z 軸方向の RMSE が小さくなり、全体の RMSE も小さくなると期待した。しかし、表 2 より、z 軸方向の RMSE は小さくなったが、同時に x 軸・y 軸方向の RMSE が大きくなるため、全体的に精度が向上したのは 3DCNN で学習した場合の z 軸方向の




図 7 z 軸方向の重み付けを重くした学習時ロスの収束グラフ

ロスに 10 倍した時だけであった。また、図 6 より、z 軸方向の重み付けを行っていない場合は、滑らかな布平面が推定されていたが、重み付けを行うと、点群がまばらな推定になってしまい、布圧力センサの表面とはいえない推定となった。この問題の解決法として、滑らかな平面を推定するために、隣り合う点の傾きの差を 0 に近づけるロスを導入することで解決できるのではないかと考えられる。

6. 結論

本研究では、非密着衣類型センサ実用化に向けた、衣類に付加されたセンサのみで衣類の 3 次元形状を推定する第 1 検討の、布圧力センサからその表面形状推定を行った。それに伴い、布圧力センサの表面形状を変えながら、動画を撮影すると同時に布圧力センサ値を取得した。時系列圧力画像の入力データと布圧力センサの表面形状点群の出力データを対にしてデータセットを作成した。作成したデータセットにより、2D/3DCNN による推定モデルを評価することで、時系列圧力値から布圧力センサ表面形状を推定することが可能であることを示した。平均 3 次元距離による評価では、2DCNN では 14.00 mm、3DCNN では 12.23 mm であった。

本研究では、第 1 検討ということで、推定にはシンプルなネットワークである 2DCNN や 3DCNN を用いたが、学習済みの ResNet や、DenseNet などから転移学習などを行うことで、より推定精度を上げられると考えられる。また、本研究に用いた学習・評価用データは、複雑なモデルの学習を行うにはデータ数・バリエーションが少ない。そこで、

より多くのバリエーションを持ったデータ、また、実際に人が着た際のデータにより学習・評価を行う必要がある。

本研究ではスカートに布圧力センサを付加してその部分の表面形状推定を行ったが、今後の研究としてスカート自体を布圧力センサで作成することにより、スカート全体の表面形状を推定することを検討している。

謝辞 本研究は JSPS 科研費 21H03481 の助成ならびに 栢森情報科学振興財団の研究助成を受けたものです。

参考文献

- [1] 小野瀬良佑, 榎堀優, 間瀬健二: 褥瘡看護ケア支援に向けた体表圧を計測可能な衣類型圧力センサの研究, 情報処理学会論文誌, Vol. 59.10, pp. 1827–1836 (2018).
- [2] Iwase, K., Enokibori, Y., Yoshida, N. and Mase, K.: Joint Position Estimation for Body Pressure Images during Sleep: An Extension for CPM Using Body Area and Posture Estimation Mashups, *Journal of Information Processing*, Vol. 29, pp. 620–629 (2021).
- [3] Choy, C. B., Xu, D., Gwak, J., Chen, K. and Savarese, S.: 3d-r2n2: A unified approach for single and multi-view 3d object reconstruction, *European conference on computer vision*, Springer, pp. 628–644 (2016).
- [4] Ji, M., Gall, J., Zheng, H., Liu, Y. and Fang, L.: Surfacenet: An end-to-end 3d neural network for multiview stereopsis, pp. 2307–2315 (2017).
- [5] Kar, A., Häne, C. and Malik, J.: Learning a multi-view stereo machine, *arXiv preprint arXiv:1708.05375* (2017).
- [6] Saito, S., Huang, Z., Natsume, R., Morishima, S., Kanazawa, A. and Li, H.: Pifu: Pixel-aligned implicit function for high-resolution clothed human digitization, pp. 2304–2314 (2019).
- [7] Huang, Z., Xu, Y., Lassner, C., Li, H. and Tung, T.: Arch: Animatable reconstruction of clothed humans, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 3093–3102 (2020).
- [8] Saito, S., Simon, T., Saragih, J. and Joo, H.: Pifu-hd: Multi-level pixel-aligned implicit function for high-resolution 3d human digitization, pp. 84–93 (2020).
- [9] Loper, M., Mahmood, N., Romero, J., Pons-Moll, G. and Black, M. J.: SMPL: A skinned multi-person linear model, *ACM transactions on graphics (TOG)*, Vol. 34, No. 6, pp. 1–16 (2015).
- [10] Onose, R., Enokibori, Y., Harasawa, Y. and Mase, K.: Educational Support System for Pressure Ulcer Prevention using Textile Pressure Sensor, 情報処理学会論文誌ジャーナル (Web), Vol. 61, No. 3, pp. 746–755 (2020).
- [11] Kato, H., Enokibori, Y., Yoshida, N. and Mase, K.: Toward Fine-Grained Sleeping Activity Recognition: 3d Extension and an Estimation Try on Joint Position of SLP Dataset, pp. 322–327 (2021).
- [12] Luo, Y., Li, Y., Foshey, M., Shou, W., Sharma, P., Palacios, T., Torralba, A. and Matusik, W.: Intelligent Carpet: Inferring 3D Human Pose From Tactile Signals, pp. 11255–11265 (2021).
- [13] Enokibori, Y., Suzuki, A., Mizuno, H., Shimakami, Y. and Mase, K.: E-textile pressure sensor based on conductive fiber and its structure, *Proceedings of the 2013 ACM conference on Pervasive and ubiquitous computing adjunct publication*, pp. 207–210 (2013).