

保育士行動認識におけるデータ補間技術を用いた ウェアラブルセンサ数削減

大見 士¹ 藤原 健之¹ 石橋 尚子² 大村 廉¹

概要：保育士の行動に基づく作業分析が、保育業務の質の向上に有望である。行動履歴を取得する方法として、ウェアラブルセンサを用いた行動認識技術が有効であるが、保育士の複雑な行動を取得するには複数のセンサを用いる必要がある一方で、保育士が多くのセンサを装着することは大きな障がいとなる。この問題に対し有効な手段として、センサデータに補間技術を適用することで、少ないセンサ数においても認識精度の低下を抑制することが考えられる。そこで本研究では、センサデータに補間技術を適用し、保育士の行動を認識するために最適なセンサ数と装着位置を調査する。実験では、保育士に6つのセンサを装着してもらい、業務中の加速度・角速度データを取得した。そして、センサ数、装着部位ごとに人工的にデータを欠損させ、欠損したデータを用いた場合と、DAEを用いて欠損した部分を補間したデータを用いた場合のそれぞれで認識精度の比較を行った。これにより、補間手法の有効性と補間技術を用いた場合に適切なウェアラブルセンサ装着数とその位置を明らかにした。その結果、補間技術は有効に働き、3つのセンサを使用した場合 accuracy で0.863の認識精度を得られ、6つのセンサを使用した場合の0.877の認識精度とほぼ同等の認識精度が得られることが分かった。また、ウェアラブルセンサを装着する位置として、左右どちらかの手首、足首、そして背中が適切であることが分かった。

Reducing the number of wearable sensors with data interpolation technique in Nursery teacher activity recognition

Akira Omi¹ Kenshi Fujiwara¹ Naoko Ishibashi² Ren Ohmura¹

1. はじめに

近年、保育施設の急増とそれに伴う保育士不足が、保育現場の負荷を増加させている[8]。また、保育行動の良し悪しに関する研究の余地はまだ多く残されており、特に定量的に保育業務やその行動を分析した研究はまだ少ない。このような背景から、保育士の業務を記録・分析することが求められている。そこで、保育士の行動に対して行動認識技術を適用し日々の業務を記録することで、その分析を促進し、効率のかつ質の高い保育の開発につなげることが期待できる。本研究では、保育士が屋内外など多様な場所で児童の世話をすることがあることから、対象者の場所を限定しないウェアラブルセンサを用いた行動認識技術[12]を用いて保育士の行動履歴の取得を試みる。

多様な保育行動を認識するためには、対象となる保育士が多数のセンサを装着することが望ましい。しかし、多くのセンサの装着は非常に手間のかかる作業となり、業務に支障をきたす可能性が生じるため、使用するセンサ数の削減を行なう必要がある。また、限られたセンサ数において、高精度の認識が可能な装着位置を検討する必要がある。

センサの装着数や装着部位について、センサ数を減少させたときの認識精度からその検討を行う研究[1][2]や、高精

度で認識が可能な特徴量の抽出方法を検討した研究が行われている[3]。これらは基本的にはセンサ数が減少した状態において精度を落とさないことを目的とした研究である。これに対し、センサ数削減を行なった際に削減対象となったセンサデータを補間して復元し、高精度化を図る、といった対応をとる事が考えられる。欠損データの補間処理に関する研究として、例えば、Neural Networkを用いて時系列スマートフォンデータの間欠部分を復元する手法の提案[4]や、降雨量データの欠損箇所の前後が観測されている欠損部分を補間する手法の提案[5]がある。しかし、これらの研究で提案された手法はあるセンサのデータが間欠的に欠損する状況を想定しており、行動認識におけるセンサ数削減に適用するのは難しい。センサ数削減に適用するには複数センサの内あるセンサが恒久的に欠損する状況を想定して行なう必要がある。補間技術を行動認識に応用した研究として、Generative Adversarial Networks(GAN)を用いてセンサデータの長期的な欠損やセンサ数削減に対応する手法が提案されている[6]。しかしながら、[6]の研究では、センサデータ補間が有効であることを示しているが、評価は日常行動のみを対象としている。保育士の行動は子どもと接するために低姿勢で行う行動が多いなど、日常行動とは違う特徴を持つ。そのため、保育行動に対してこのような補間

¹ 豊橋技術科学大学
Toyohashi University of Technology
² 相山女学園大学
Sugiyama Jogakuen University

技術が有効であるか定かではない。

そこで、本研究では、保育士の行動に対して補間技術を用いて少ないセンサ数における認識精度の低下を抑制し、装着センサ数の削減する手法の有効性を評価する。各センサ数、装着部位ごとに、欠損したデータを用いた場合と欠損部分のデータを補間した場合とで認識精度の比較を行い、補間技術を用いた場合に適切なウェアラブルセンサ装着数とその位置を明らかにする。

本論文の構成は以下のとおりである。まず、2章で関連研究について触れ、センサの装着数や装着位置についての研究やセンサの補間手法について述べる。次に3章では本研究を行う目的と実験の手順を述べる。4章では本研究で行った実験の詳細な方法を述べる。そして、実験結果を5章に示し、6章で考察を行う。最後に7章で本論文のまとめを述べる。

2. 関連研究

2.1 センサの装着数や装着部位の検討

センサの装着数や装着部位について、センサ数を減少させたときの認識精度から装着数や装着位置の検討を行う研究[1][2]や、高精度で認識が可能な特徴量の抽出方法を検討した研究が行われている[3]。

[1]の研究では、17箇所にセンサを装着し、立っているや、座っているなどの10種類の人の行動データを取得し、SVMで認識を行い、認識精度から各装着個数におけるウェアラブル加速度センサの適切な装着位置の検討を行っている。

[2]の研究では、公開データセットである「Daily and Sports Activities」[9]を用いて、Convolutional Neural Network(CNN)を構築し、認識精度から適切なウェアラブルセンサの装着位置の検討と機械学習手法との比較を行っている。また、[3]の研究では、公開データセットである「PAMAP2」[10]を用いて、少ないセンサ数でも高精度で認識が可能な特徴量の抽出方法を検討している。

これらの研究は、欠損したセンサ数ごとに各装着部位で認識した場合の精度の比較や、認識の手法や特徴量の抽出方法を工夫することで、センサ数の削減や装着部位の検討を行っている。しかし、欠損したセンサデータに対して補間技術を適用し、認識精度の低下を抑制することで、センサ数の削減や装着部位の検討を行った研究はほとんどない。

2.2 欠損値の補間

データの欠損部分の補間処理を行った研究として、Neural Networkを用いて時系列スマートフォンデータの欠損部分を復元する手法の提案[4]や、欠損箇所の前後が観測されているデータを補間する手法の提案[5]があげられる。

[4]の研究では Stacked Denoising Autoencoder を用いてスマートフォンセンサのサンプリングされたログから欠損した欠損部分のデータを復元する手法を提案している。また、

[5]の研究では Convolutional Long Short Term Memory(LSTM)を用いて XRAIN データ(降雨量データ)[11]の前後が観測されている欠損箇所を補間する手法を提案している。

しかし、これらの手法は行動認識のためのデータを対象にしたものではない。また、間欠的に欠損したデータをその前後関係から補間する手法である。行動認識におけるセンサ数削減では、削減対象となるセンサを恒久的に欠損させ、このデータを補間するように働く必要がある。このため、これらの手法はセンサ数削減に対して用いることは困難である。

恒久的に欠損するセンサデータを補間し、行動認識に応用した研究として石田らは GAN を用いる手法を提案している[6]。この研究では公開データセットである「REALDISP Activity Recognition Dataset」[13]のセンサデータを一部欠損させた場合と欠損部分に対して補間を行った場合について認識精度を比較している。

[6]では、日常行動に対して補間技術を適用しているのに対し、保育士の行動は、子どもを対象としており、低姿勢で行う動作が多いなど日常行動とは違う特徴を持つ。また、補間技術が有効であるか定かではない。また、GAN は非常に計算量が多くなることが予想される。そこで本研究では、Denoising AutoEncoder[14]を用いる。

3. 目的・実験手順

本研究では、少ないセンサで高精度の認識を実現するために、補間技術を用いてセンサ数の削減と装着位置の検討を行う。そして、保育士の行動を認識するために適切なセンサ数と装着位置を明らかにする。

本研究では、実際の保育士に複数のウェアラブルセンサを装着してもらい、業務中の保育士の行動データを取得した。そして、このデータについて、まず装着した全てのセンサデータを用いて行動認識を行ないその精度を確認する。また、各センサデータを任意の数人工的に欠損させた欠損データ、および、欠損したデータを補間した補間データを作成してそれぞれの識別精度を確認する。そして各欠損センサ数や、欠損させたセンサの装着部位ごとに、欠損がないデータを用いた場合の認識精度、欠損したデータを用いた場合の精度、補間手法を適用した場合の認識精度を比較する。これにより、保育士の行動に対する補間手法の有効性と、保育士の行動を認識するために適切なセンサ数と装着位置を明らかにする。

図1に取得したデータに欠損のない場合の実験の流れを示す。図2に取得したデータに欠損がある場合の実験の流れを示す。図3に取得したデータに欠損があり、そのデータに対して補間を行う場合の実験の流れを示す。

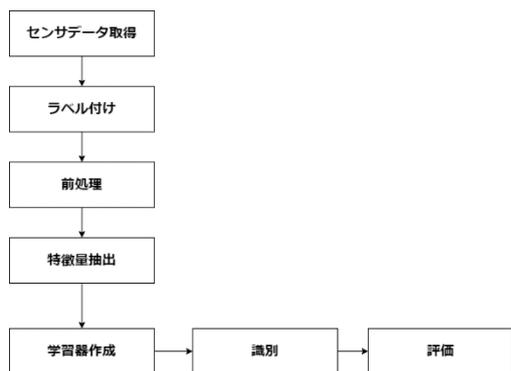


図1 欠損なしの場合の実験の流れ

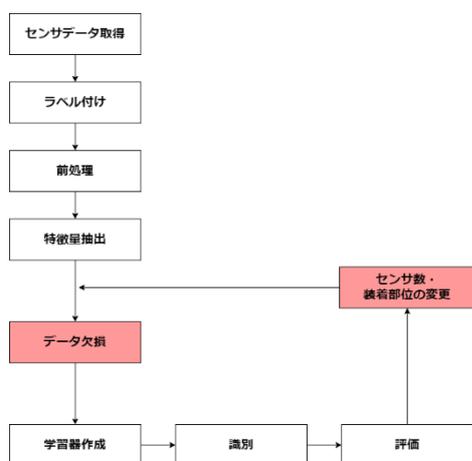


図2 欠損ありの場合の実験の流れ

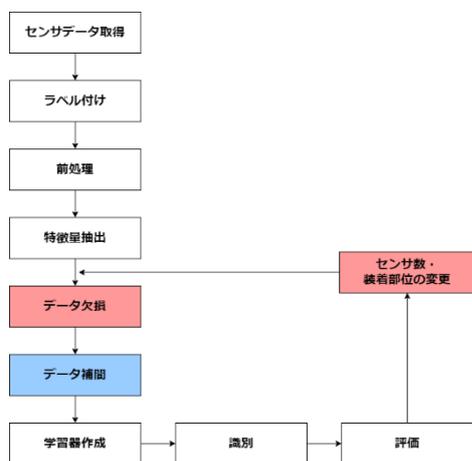


図3 欠損あり、かつ、補間を行う場合の実験の流れ

それぞれセンサデータの取得から特徴量の抽出を行うまでは同じだが、その先の処理が異なる。図2、図3で赤く示された部分は、取得したセンサデータに欠損がある場合に行う手順であり、図3で青く示された部分は、欠損のあるセンサデータに対して補間を行う場合に行う手順である。図1(欠損なし)の場合には、その特徴量データを識別器に学習させ、識別を行う。

図2(欠損あり)の場合には、特徴量の抽出後に欠損を想定するセンサに対応する特徴量を0で埋め、識別を行う。なお、欠損部位ごとにそれぞれ識別器を作成し、学習データとしても欠損データを用いて学習を行なう。欠損データは欠損センサ数や、欠損させたセンサの装着部位ごとに識別器を作成し、それぞれ識別を行うことで各欠損センサの認識精度の平均を計算する。欠損のパターンについては4.4節で述べる。

図3(欠損あり、かつ、補間を行なう)の場合には、まず、図2の説明と同様に欠損データを作成する。つぎに、欠損データを Denoising AutoEncoder に入力し、欠損部分を補間したデータを作成する。そして、欠損部位ごとに補間したデータを識別器に学習させ、補間したデータで識別を行う。欠損センサ数や、欠損させたセンサの装着部位ごとに識別器を作成し、それぞれ識別を行うことで、各欠損センサの認識精度の平均を計算する。

以上のように、各欠損センサ数や、欠損させたセンサの装着部位ごとに、欠損がないデータを用いた場合の認識精度、欠損したデータを用いた場合の精度、補間手法を適用した場合の認識精度を比較する。

4. 実験方法

4.1 保育士の行動データの取得

本実験では実際にこども園にて勤務する保育士1名にウェアラブルセンサを装着し、屋内外での業務のデータを取得した。対象園児の年齢は5歳で、9時~11時、13時~15時の計4時間における行動を記録した。実験の様子を図4、図5に示す。



図4 こども園での屋内の実験の様子



図5 こども園での屋外の実験の様子

行動データの取得には、TSND121/151(ATR-Promotions

社製[7])を用いた。このセンサは3軸加速度・角速度をサンプリング周波数最大1kHzで取得でき、加速度レンジは±16G、角速度レンジは±2000dpsである。本実験ではサンプリング周波数100Hzでデータを取得した。図6に使用したセンサを示す。



図6 実験に使用したウェアラブルセンサ

被験者となった保育士のウェアラブルセンサの装着位置を図7に示す。保育士の行動の妨げにならないような装着位置を検討した結果、センサを左右の手首と足首、腰、背中(密集しているポーチの内部)の6か所に装着した。

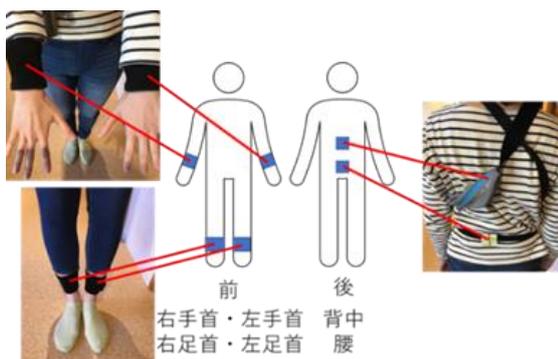


図7 センサ装着位置

4.2 ラベル付け

実験時にビデオカメラを設置し、実際に実験の様子を見ながら取得したセンサデータのラベル付けを行った。行動ラベルは、保育学の専門家に依頼し、行動ラベルの候補を決定してもらい、その候補から選択した。また、行動の総時間数が20秒以下のものを認識には不十分として、認識対象の行動としなかった。その結果、表1に示す行動を認識対象とした。

表1 認識対象とした行動一覧

行動表					
ラベル番号	ラベル名	インスタンス数	ラベル番号	ラベル名	インスタンス数
0	座って話している	3386	14	歩いて話している	288
1	物を出し入れしている	1114	15	しゃがんで話している	331
2	歩いている	1549	16	書いている	293
3	物を受け渡ししている	386	17	ドアを開け閉めしている	113
4	前かがみで話している	1167	18	拾っている	52
5	連絡帳を読んでいる	113	19	子供を数えている	168
6	立って話している	7882	20	足で線を引きしている	215
7	電話をしている	168	21	手をたたいている	317
8	見回している	178	22	棚を開け閉めしている	72
9	物を数えている	288	23	座っている	349
10	物を持って歩いている	1864	24	物を持っている	814
11	片づけている	289	25	紙を折っている	360
12	子供に触れている	321	26	紙を切っている	219
13	立っている	679			

4.3 前処理・特徴量抽出

スライディングウィンドウを用いてセンサデータを部分系列に分割し、部分系列から特徴量を算出した。本実験では、ウィンドウサイズ $W = 640ms$ 、スライド幅 $S = 50%$ の条件で特徴量抽出を行った。特徴量は、最大値、最小値、平均値、中央値、分散、ゼロクロス数、センサ内軸相関係数、エネルギー、ピーク周波数の9種類を抽出した。

4.4 データの欠損

図2, 図3におけるデータ欠損は下記のように行なった。収集したデータ(装着センサ数6個)から各センサが欠損した状態を想定し、欠損センサ数ごとに対応する特徴量データを欠損させた。図8にセンサの欠損パターンを示す。図8上部の数は稼働しているセンサ数を表す。すなわち「6個」は欠損なくセンサが動作している場合、「5個」は装着しているセンサの内1個が欠損している場合を表す。また、人体の図に記載されている青い四角が稼働しているセンサを示している。mをセンサ数、nを欠損させるセンサ数としたとき、各欠損センサ数の装着部位の欠損パターン数は mC_n となり、各欠損パターンをすべて計算すると63パターンとなる。そして、欠損させるセンサから得られるはずであった特徴量を0で埋めることで欠損データとした。

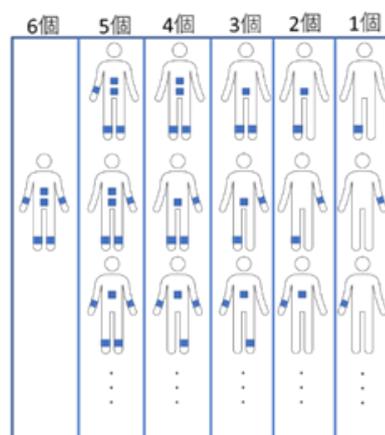


図8 各センサ装着数における装着部位欠損パターン

4.5 データの補間

図3におけるデータ補間は以下のように行なった。欠損したセンサ部分の特徴量データを Denoising Auto Encoder(DAE)を用いて補間を行った。図9にセンサデータの補間状況を示す。図9左側はセンサの欠損状況を示しており図8と等しい。そして、図9右側の赤く示された部位から得られる特徴量を DAE によって補間するようにした。DAE から出力されるデータは欠損が生じていない部分も修正されている。DAE から出力されたデータをそのまま用いた場合、欠損していないデータも書き換えられてしまうため、図9に示すように欠損しているセンサ部位の特徴量データのみを補間し、欠損が生じていない部分はセンサデータから算出した特徴量データをそのまま用いた。

DAE への入力データは特徴量データを 2 次元に配置して作成するようにした。4.1 章で述べたように、本研究では 6 個のセンサを使用しており、各センサからはそれぞれ加速度 3 軸、角速度 3 軸の計 6 軸のデータが取得できる。また、4.3 章で述べたように、軸ごとに 9 種類の特徴量を算出している。図 10 に示すように、特徴量毎に 6 (センサ) × 6 (軸) の 2 次元にデータを配置し、9 チャンネル (特徴量数) のデータとした。なお、DAE の学習には欠損のない状態でのデータを教師データとして与えた。そして、補間時の入力として欠損させるセンサから得られるはずであった特徴量を 0 で埋めたデータを入力し、補間された出力を得た。

DAE は図 11 に示すように、エンコーダ部 3 層、デコーダ部 3 層から成る全 6 層で構成した。この DAE をエポック数 30、バッチサイズ 10 のパラメータで学習させ、補間を行った。

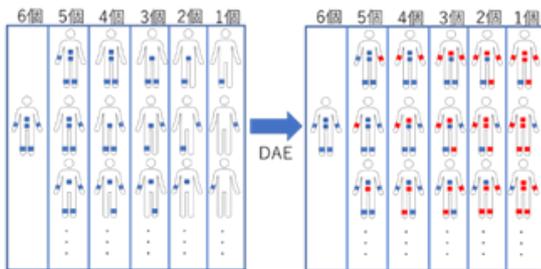


図9 DAE を用いた
欠損部位の特徴量データ補間

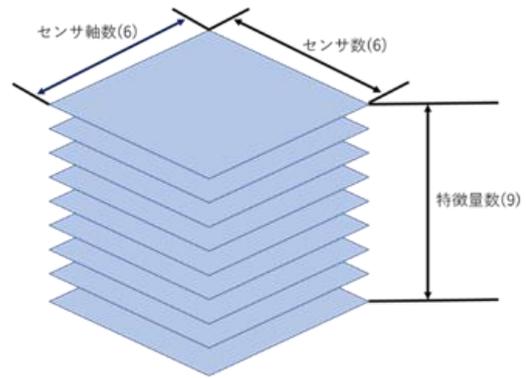


図10 DAE 入力図

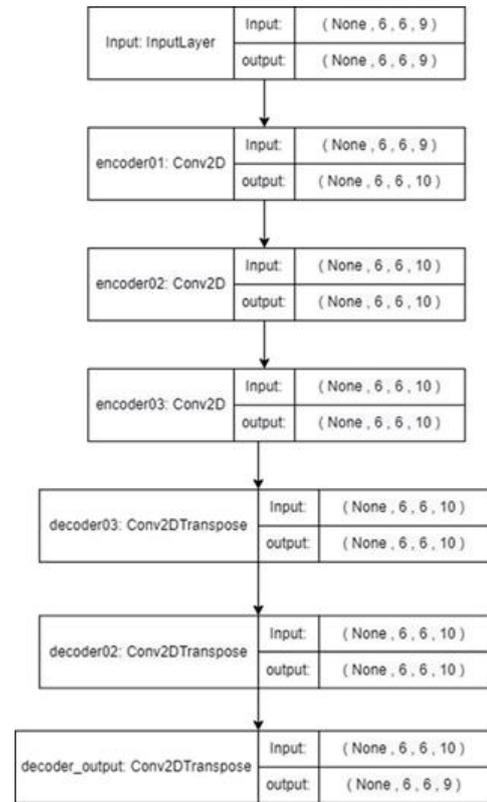


図11 DAE モデル図

4.6 識別・評価

識別には Random Forest を用いて学習器を作成した。実装の際には、Python のライブラリである sklearn に含まれる RandomForestClassifier を利用し、木は 100 本、その他のパラメータは初期設定のものを使用した。識別器に学習させるデータとして、図 1 (欠損なしの場合) には欠損のないデータを、図 2 (欠損ありの場合) には欠損を想定するセンサに対応する特徴量を 0 で埋めたデータを、図 3 (欠損あり、かつ、補間を行なう場合) には欠損ありの場合に作成したデータを DAE に入力し、欠損部分を補間したデータをそれぞれ用いた。

また、評価指標には Accuracy を、検証手法として K=5 の Stratified K-Fold Cross Validation(SKFCV)を用いた。

5. 実験結果

本章では実験結果について述べる。実験で収集したデータの特徴量を抽出した結果、総インスタンス数は 22975 個であった。また、インスタンス数の最大値は 7882、最小値は 52、中央値は 317 とかなりばらつきのあるデータとなった。表 1 に行動別のインスタンス数を示す。

5.1 欠損のないデータで欠損したデータを認識した結果

図 12 は欠損のないデータで学習した識別器で欠損したデータを認識した場合に、欠損センサ数ごとのすべての装着部位の欠損パターンにおいて accuracy を計算し、その平均を取ったものである。なおエラーバーは標準偏差を示す。

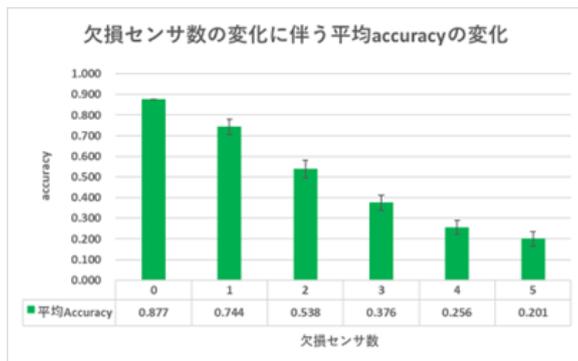


図 12 欠損のないデータで学習した識別器で欠損したデータを認識した場合の欠損センサ数ごとの平均 accuracy

図 12 より欠損センサ数が増えるとともに認識精度はかなり低下することがわかる。欠損のないデータで学習した識別器は、欠損のないデータを識別することを想定している。しかし、欠損するセンサ数が増えると、認識に必要なデータ量が減少する。そのため、認識精度がかなり低下してしまったのだと考える。

5.2 補間技術を用いたときに適切なセンサ数

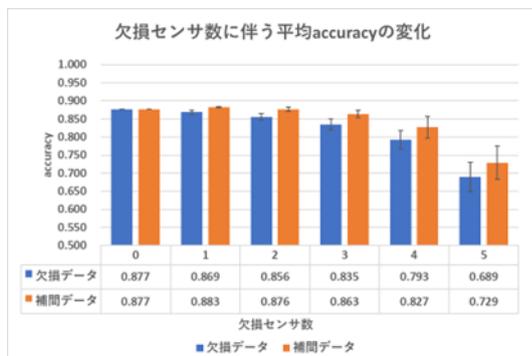


図 13 欠損センサ数ごとに欠損したデータ、補間したデータを学習した場合の平均 accuracy

図 13 は、欠損センサ数ごとに欠損したデータを学習さ

せ、欠損したデータを識別した場合（欠損データ）、補間したデータを学習させ、補間したデータを識別した場合（補間データ）の結果である。欠損センサ数ごとにすべての装着部位の欠損パターンに対する accuracy を取得し、その平均を算出した。なおエラーバーは標準偏差を示す。

図 13 より、いずれの欠損センサ数においても欠損したデータを識別した場合より補間したデータを識別した場合において、認識精度が高くなることが示されている。よって、補間手法が有効に働くことがわかる。

また、補間データを識別した場合、図 13 における欠損センサ数 0 のデータ（無欠損）と図 13 における欠損センサ数 3 のデータ（欠損センサ数が 3 個）の場合、無欠損の場合の認識精度が 0.877 に対し、3 個のセンサを欠損させた場合の認識精度は 0.863 であり、認識精度の差は 0.01 程度である。このことから、補間手法を用いた場合、3 個のセンサを欠損させた場合においてもセンサを 6 個全てを使用した場合と同等な認識精度を得られることがわかった。

5.3 補間技術を用いたときに適切なセンサ装着位置

5.2 節で補間手法を用いた場合、3 個のセンサを欠損させた場合においてもセンサを 6 個使った場合と同等な認識精度を得られるとわかった。このため、センサを 3 個欠損させた場合（3 個のセンサを装着する場合）の有効な装着部位を検討する。図 14 に補間手法を用いた場合、装着センサ数 3 個において高い認識精度を得られた装着部位の上位 5 パターンを示す。図 14 において一番左が最も識別精度が高かった場合であり、一番右が 5 番目に精度が高かった場合である。

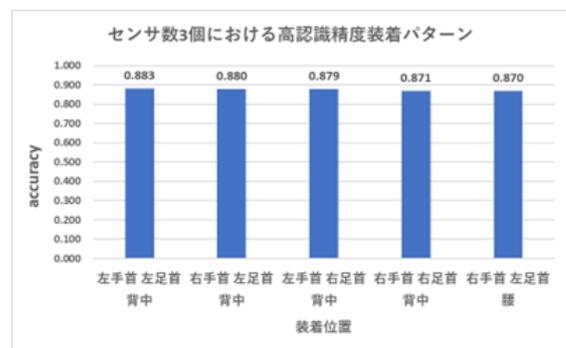


図 14 センサ数 3 個において高い認識精度を得られた装着パターン

図 14 より上位 4 パターンを見ると、左右どちらかの手首、足首、背中となっている。また、その 4 パターンにおいて最大の認識精度は 0.883 であるのに対し、最小の認識精度は 0.871 となっている。認識精度の差は 0.012 であり、大きな差はないと言える。また、5 番目に認識精度が高いパターンにおいてもほとんど認識精度に差はないが、背中ではなく腰に装着することで弱冠の認識精度の低下が見られる。このことから、センサ数 3 個において補間手法を用

いる場合、左右どちらかの手首、足首、そして背中に装着するのが適切であると考えられる。

6. 考察

これまでの評価は、4.2節で述べたように、1日のデータ取得実験の中で現れた27種類の行動(表1)を対象におこなった。分析する状況を限定し、認識する対象を限定することによって、さらに必要となるセンサ数を減らしても高精度の認識が可能となる可能性がある。

ここでは、「子どもへの直接的な指導」に限定して分析することを想定し、認識対象とする行動を限定して、その際に必要なセンサ数やその精度を明らかにするための実験を行った。なお、表1の行動と同様、この時識別対象とする行動は保育学の専門家に依頼して選択を行なってもらった。表2に選択された行動を示す。

表2に示す○の行動セットと○+△の行動セット、また、すべての行動セットで認識精度を比較し、センサ数やセンサ装着位置を検討する。表2の○の行動データセットと○+△のデータセット、また、すべての行動のデータセットで認識精度の比較を行った結果を図15に示す。

表2 子どもへの直接的な指導において必要な行動表
(○:特に必要 △:特化していないが必要)

ラベル番号	ラベル名	
0	座って話している	○
1	物を出し入れしている	
2	歩いている	△
3	物を受け渡ししている	○
4	前かがみで話している	○
5	連絡帳を読んでいる	
6	立って話している	○
7	電話をしている	
8	見回している	○
9	物を数えている	
10	物を持って歩いている	
11	片づけている	
12	子どもに触れている	○
13	立っている	○
14	歩いて話している	○
15	しゃがんで話している	○
16	書いている	
17	ドアを開け閉めしている	
18	拾っている	
19	子どもを数えている	○
20	足で線を引いている	
21	手をたたいている	○
22	棚を開け閉めしている	
23	座っている	△
24	物を持っている	△
25	紙を折っている	○
26	紙を切っている	○

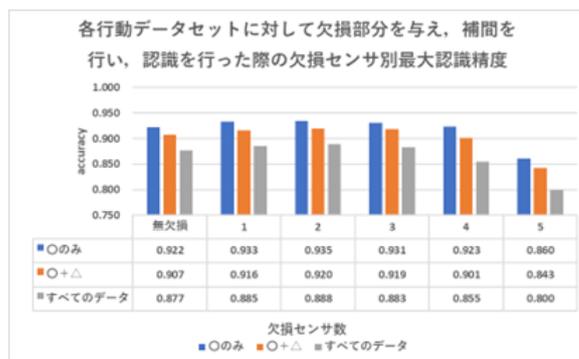


図15 「子どもへの直接的な指導」の分析に必要な行動セットにおける欠損センサ数毎の最大認識精度

図15では、○の行動データセットと○+△のデータセット、また、すべての行動のデータセットにおいて、欠損センサ数ごとのすべての装着部位の欠損パターンのデータを作成し、そのデータに対してDAEを用いて補間を行った。そのようにして補間したデータを作成し、そのデータを用いて識別器を作成し、認識を行った結果、各欠損センサ数における最大の認識精度を示している。

図15より、いずれの欠損センサ数においても行動セットを限定したほうが、すべての行動セットより高い認識精度を得られていることがわかる。○の行動データセットで学習した場合、1個のセンサを装着した場合でも認識精度は0.860であり、2個のセンサを装着すれば、認識精度は0.923となっている。○+△の行動セットでは、1個のセンサを装着した場合では認識精度は0.843であり、2個のセンサを装着すれば、認識精度は0.901となっている。これらのことから、認識対象とする行動セットを「子どもへの直接的な指導」の分析に必要なものだけに絞ったとき、1個のセンサのみを使用した場合でも約85%、2個のセンサを使用すれば90%以上の精度で認識が可能となることがわかる。この時、○の行動セット、○+△の行動セットいずれにおいても、1個のセンサのみ用いる場合は左足首に装着、2個のセンサを用いる場合では左足首と背中に装着した場合に最大の認識精度となった。

このことは「子どもへの直接的な指導」の分析の事例であるため、他の分析事例においても検証する必要があるものの、分析対象とする内容に応じて識別対象とする行動セットを限定することで、さらに必要とするセンサ数を削減することが可能であることが示唆された。

7. まとめ

本研究では、保育士行動の認識において必要とするセンサ数の削減を目的とし、センサデータ補間手法を用いて高精度で認識が可能なセンサ数と装着位置を調査した。実験では、保育士の業務のデータを収集すると共に、取得した

データについて人工的に各センサが欠損した状況が発生させ、欠損部分のデータを DAE により補間して認識を行うようにした。

実験結果より、補間技術を用いれば、センサ数を 3 個に限定した場合の accuracy は 0.863 であり、全てのセンサ (6 個) を使用した場合の accuracy の 0.877 と同等の認識精度を得られることがわかった。また、3 個の装着位置として、左右どちらかの手首、足首に 1 つ、および背中に 1 つずつ装着するのが適切であることが分かった。

さらに、「子どもへの直接的な指導」の分析において必要な行動に限定して認識を行った場合、補間を用いれば、1 個のセンサを装着した場合でも accuracy は約 0.85、2 個のセンサを装着すれば 0.90 以上で認識が可能であることがわかった。このことから分析対象とする内容に応じて識別対象とする行動セットを限定することで、さらに必要とするセンサ数を削減することが可能であることが示唆された。

本研究は保育士の行動を対象としたが、補間を用いる手法は多くの行動セットで有効な手法であると考えられ、本研究の結果は行動認識におけるセンサ数に関わる装着や管理の手間の問題を緩和し、実用性の向上に貢献すると思われる。

謝辞

本研究を実施するにあたり、多大なご協力を戴いた相山女学園大学附属相山こども園の皆様には感謝いたします。

また、本研究は令和 3 年度相山女学園研究費助成金 (A) の助成を受けて実施したものであり、ここに謝意を表します。

参考文献

- [1] Chengshuo Xia, Yuta Sugiura. "Wearable Accelerometer Optimal Positions for Human Motion Recognition", 2020 IEEE 2nd Global Conference on Life Sciences and Technologies (LifeTech), pp.19-20
- [2] Lina Tong, Qianzhi Lin, Chuanlei Qin, Liang Peng, "A Comparison of Wearable Sensor Configuration Methods for Human Activity Recognition Using CNN", 2021 IEEE International Conference on Progress in Informatics and Computing (PIC), pp288-292
- [3] Di Wang, Edwin Candinegara, Junhui Hou, Ah-Hwee Tan, Chuan Miao, "Robust human activity recognition using lesser number of wearable sensors", 2017 International Conference on Security, Pattern Analysis, and Cybernetics (SPAC), pp290-295
- [4] 山本 直樹, 落合 桂一, 稲垣 章弥, 神山 剛, 深澤 祐介, "Stacked Denoising Autoencoder を用いた間欠的測定センサデータの復元", 情報処理学会論文誌 61 (2), 351-361, 2020-02-15
- [5] 篠田 拓樹, 稲毛 敦人, 飯棲 俊介, 大枝 真一, "Convolutional LSTM を用いた降雨量データの欠損補間", 情報処理学会第 82 回全国大会, 7ZG-02, pp661-662
- [6] 石田義人, 多田剛史, 大村廉, "行動認識における GAN を用いた欠損データ補間手法の性能評価", マルチメディア, 分散, 協調とモバイルシンポジウム, pp.277-283
- [7] ATR-Promotions, "小型無線多機能センサ「TSND121/151」", http://www.atr-p.com/products/TSND121_151.html, 2022-05-18
- [8] 厚生労働省, "②保育所等関連状況取りまとめ (令和 2 年 4 月 1 日)", <https://www.mhlw.go.jp/content/11922000/000678692.pdf>, 2022-05-19
- [9] UCI Machine Learning Repository, "Daily and Sports Activities Data Set", <https://archive.ics.uci.edu/ml/datasets/daily+and+sports+activities>, 2022-05-19
- [10] UCI Machine Learning Repository, "PAMAP2 Physical Activity Monitoring Data Set", <https://archive.ics.uci.edu/ml/datasets/pamap2+physical+activity+monitoring>, 2022-5-18
- [11] DIAS, "XRAIN リアルタイム雨量情報システム", <https://diasjp.net/service/xrain/>, 2022-05-19
- [12] Abhay Gupta, Kuldeep Gupta, Kshama Gupta, Kapil Gupta, "A Survey on Human Activity Recognition and Classification", International Conference on Communication and Signal Processing, July 28 - 30, 2020, India, pp.0915-0919
- [13] UCI Machine Learning Repository, "REALDISP Activity Recognition Dataset Data Set", <https://archive.ics.uci.edu/ml/datasets/REALDISP+Activity+Recognition+Dataset>, 2022-05-20
- [14] Pascal Vincent, Hugo Larochelle, Yoshua Bengio, Pierre-Antoine Manzagol, "Extracting and Composing Robust Features with Denoising Autoencoders", Machine Learning, Proceedings of the Twenty-Fifth International Conference (ICML 2008), pp1096-1103