

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

石田義人¹ 多田剛史¹ 大村廉¹

概要: 近年、ヘルスケアやフィットネスなどを目的とし、ウェアラブルデバイスを用いて装着者の体の動きを取得し、その行動内容を推定する「行動認識技術」に関する研究が多くなされている。行動認識では、多数のセンサを用いることで複雑な行動が認識可能となる一方で、センサの故障や通信切断によるセンサデータの欠損によって認識性能が大幅に低下するという問題がある。本研究ではデータの欠損による認識性能低下を抑制することを目的とし、GAN (Generative adversarial networks) を用いて欠損したデータを補間する手法を提案する。具体的には、センサデータの部分系列から得られる複数の特徴量をセンサ毎に並べて画像とみなし、その欠損部分について GAN の 1 種である GLCIC (Globally and Locally Consistent Image Completion) を用いて補間を行なうこととした。実験では 33 種類の日常行動に対して 9 個のウェアラブルセンサを用いて被験者の動作を取得したデータセットを用い、センサデータの一部を欠損させた場合と欠損部分に対して補間を行なった場合について、欠損センサデータ数を変更しつつ認識精度を比較した。なお、認識器には Random Forest を使用した。結果、提案する補間手法によって、データ欠損時でも高い F 値を得ることができた。さらに、欠損センサ数が増えても高い識別精度を得ることができ、あらかじめ多くのセンサを用いてデータを取得し、本手法を適用することで、センサ数を減らして高精度の行動認識を行なうことが可能であることが示唆された。

Performance Evaluation of Missing Data Interpolation Using GAN for Activity Recognition

YOSHIHITO ISHIDA¹ TSUYOSHI TADA^{†1} REN OHMURA^{†1}

1. はじめに

近年、ウェアラブルデバイスが生活に身近となり、ヘルスケアやフィットネスなどを目的としてウェアラブルデバイスから取得可能なセンサデータを用いて研究が多行われている。それらの研究を行う上で、取得したセンサデータから装着者がどのような行動を行なっているかを推測する行動認識技術は、さまざまなサービス実現の中核技術として非常に重要となってくる。

行動認識では通常、学習済みの認識器に、センサデータをテストデータとして入力し、認識結果である行動ラベルを得る。しかし、センサデータの取得の最中、センサの故障や通信切断によりセンサデータの欠損が生じることがある。センサデータが欠損した場合、取得されるデータの次元数が低下するため、認識処理自体が困難であったり、認識処理を行なったとしても認識精度が大幅に低下を招いてしまう。特にウェアラブルデバイスは近年無線で接続されることが多く、通信切断によってデータの欠損が生じる可能性が高い。そのため、欠損データをどう扱うかは非常に重要な問題である。

この問題を解決するために、欠損箇所を同じ値で埋める、または周りの値から平均値を算出してその値で埋めるなどの補間を行なう方法がある。しかし、これらの補間方法で

は欠損直前、直後などのデータや周りのデータを参考にして補間データを作成するため、長期的にデータが欠損している場合の補間性能が低く、認識性能も低くなってしまいうという問題がある。

そこで本研究ではディープラーニングを用いたデータ生成ネットワークである Generative Adversarial Networks (GAN) [1]を用いて欠損データの補間を行う手法を提案する。GAN では、学習用データの特徴を学習し、その特徴を持った新たなデータを生成することができる。本研究では特徴量をセンサ位置およびそれぞれのセンサが持つ軸を基準として、各特徴量毎に二次元データを生成する。そして、欠損がない状態で GAN を学習させ、GAN に特徴量データ自体の特徴を学習させる。そして、認識時、データに欠損が生じた場合は欠損部分をこの GAN を用いて補間することで、元の特徴量の特徴を保持したデータ補間を行なう。

本研究では、提案手法の有効性を評価するため、33 種類の日常行動に対して 9 個のウェアラブルセンサを用いて被験者の動作を取得したデータセットを用い、センサデータの一部を欠損させた場合と欠損部分に対して補間を行なった場合の認識精度を比較する。その際、欠損センサデータ数を変更し、欠損データ数毎の精度差を確認する。

本論文の構成は以下の通りである。まず 2 章で関連研究

¹ 豊橋技術科学大学
TOYOHASHI UNIVERSITY OF TECHNOLOGY

について触れ、既存の保管手法について述べる。次に3章で本研究の提案手法について説明する。4章では本研究で用いたデータ補間ネットワークについて説明する。そして5章で評価実験を行い、提案手法の評価を行う。6章で評価実験の結果を示し、考察を行う。最後に7章で本論文をまとめる。

2. 関連研究

行動認識におけるセンサデータに限らず、データに欠損が生じる場合は多く存在する[2][3][4][5]。それらの欠損値に対する既存の対処法を以下に示す。

2.1 欠損値処理法

まず、欠損値が一つでも存在するデータ行そのものを削除する手法としてリストワイズ除去やペアワイズ除去などがある[6]。この方法は、「全てのデータを認識しなくてもよい」ことが許容される状況において、十分な量のデータ資源があり、かつ、欠損が間欠的に生じる場合や欠損が少ない場合には有効な手段となり得る。しかし、逆に、全てのデータを認識しなければならない場合は適応できず、また、許容されたとしても、そもそもデータ数が少ない場合などは認識対象となるデータが大きく減少するなどの問題が生じる。また、長期的なデータ欠損が生じるとその欠損箇所の情報が丸ごと喪失してしまい、重要な情報を得られない可能性があるなどの問題点もある。

次に欠損している箇所を周囲（時系列データの場合は前後）のデータから計算して代入することで補間を行う多重代入法[7][8]がある。例えば平均値代入法や回帰代入法がある。平均値代入法とは欠損が生じたデータに対し、その変数の欠損値がないデータの平均値を計算し、欠損地の代わりに代入する方法である。回帰代入法とは欠損地のある変数を残りの変数から予測する回帰モデルを推定し、その回帰モデルの予測値を欠損箇所に代入する方法である。しかし、これらの方法は欠損箇所前後、欠損値のない変数のデータを用いて計算を行うため、センサの故障などによる長期的なデータの欠損への対応が困難であるという問題点がある。

2.2 Neural Network を用いた欠損値補間法

また、近年ではNeural Networkを用いたディープラーニングによるデータ補間手法が増えている。例えばRecurrent Neural Network(RNN)を用いた時系列データの補間[9]や、Auto Encoder(AE,オートエンコーダ)を用いたデータの補間手法がある[10]。

[9]の論文では、Long Short-Term Memory(LSTM)[11]を用い、欠損箇所の前後が観測されている降雨量データに対する欠損データ補間手法を提案している。しかしこの研究ではデータのある時点の入力からそれ以降の出力を予測する

データの時間的な関係に基づくネットワークであるため、センサの故障による長期的なデータ欠損に対してデータ補間を行うことが難しい。

またAEを用いた手法において、AEは入力データから重要度の高い特徴量を抽出しながら次元圧縮を行うエンコーダと、圧縮したデータを復元するためのデコーダから構成される。AEは元のデータからより重要なデータを選択できるという特徴があるが、データを次元圧縮後復元するため、入力データよりも出力データの情報が少なくなり、十分な補間を行なうことができない可能性がある。

本研究で用いるGANは学習データから特徴量を抽出し、その特徴を持った実在しないデータを生成することが可能である。[1]また、時系列データを画像とみなしてデータ補間を行うことで、センサ自体が故障しても他のセンサのデータから欠損箇所を補間することができる。このことから既存研究では補間できなかった長期的なデータの欠損やセンサごとの欠損にも対応できると考えられる。また、GANの学習時に学習した特徴量を用いて補間するため、AEを用いたときよりも多くの特徴量を持ったデータが生成できると考えられる。これらの特徴から、GANを用いデータ補間を行い、そのデータを行動認識に用いることで認識性能の低下を防ぐことが可能であると考えられる。

3. 提案手法



図1 行動認識の流れ

まず図1に一般的な認識モデルを示す。一般的な行動認識では、加速度や角速度などのセンサデータを取得し、そのセンサデータに対して、データ選択や正規化、スライディングウィンドウを適用するなどの前処理を行う。次に前処理を行なったデータに対して特徴量抽出を行う。この抽出された特徴量データを使用し、サポートベクトルマシン(Support Vector Machine; SVM)やランダムフォレスト(Random Forest; RF)のような認識器での認識処理を行う。そして、識別結果である行動ラベルを得て、その認識結果を評価する。

センサデータに欠損が生じた場合、欠損したセンサデータからは特徴量を計算することもできなくなり、認識器に入力するデータが十分に得られなくなる。そこで、欠損データを0(ゼロ)などの値で埋めたり、2章で述べた手法を用いてデータの補完を行なう。この時、センサデータを補完し、その補完したセンサデータから特徴量を算出して識別器に入力するデータの次元を揃える方法と、センサデータの欠損により結果として欠損する(算出できなくなる)特徴量を直接補完する事が考えられる。過去の類似研究にお

いて、特徴量を直接補完する方がえられる性能が高かったため、本研究では特徴量レベルでデータ補間を行う。



図2 データ補間のモデル図

図2に本研究における手法のモデル図を示す。まず、センサデータに対してスライディングウィンドウを適用し、部分系列を取得する。その部分系列に対して正規化を行った後、特徴量抽出を行う。センサデータに欠損が生じた場合は、算出できないなどの理由で、この特徴量データに欠損が生じる。特徴データに欠損が生じている場合は、現在得られている特徴量をデータ補完器に入力し、このデータ補完器によって補完されたデータを欠損部分に充当する。そして、充当されたデータを識別器に入力し、行動ラベルを得る。

4. データ補間ネットワーク

4.1 Generative Adversarial Network(GAN)

本研究ではデータ補間ネットワークとしてGANを用いる。図2にGANの構成を示す。




図3 GANの構成図

GANはディープラーニングを用いた画像生成ネットワークであり、画像の生成器と識別器から構成される。生成器ではランダムなノイズから偽物のデータを生成する。また、識別器ではその生成された偽物データと学習用に入力された本物データとを比較し、偽物のデータが本物であるか、偽物であるかを識別する。生成器では生成した偽物のデータが識別器において本物のデータであると識別されるように学習を行う。また、識別器は生成された偽物のデータが偽物であると正確に識別できるように学習を行う。これらを互いに学習し合うことで、生成器から本物と似た特徴をもつ偽物のデータを出力することができるようになる。このようなGANの特徴のため、提案手法においてGANを用いることで、データが欠損した場合にも元々の特徴量の特徴を保持したデータ補間が可能であると考えられる。

4.2 Globally and Locally Consistent Image Completion(GLCIC)

4.1でGANについて説明した。オリジナルのGAN[1]は動

作が不安定、ノイズからしかデータ生成できないなどの問題がある。そのため本研究では、GANの構造を用いた画像補間ネットワークである Globally and Locally Consistent Image Completion(GLCIC)[12]を用いた。GLCICは画像補間ネットワークとして設計され、欠損画像を入力することで補間された画像を出力する。GLCICの概略図を図4に示す。

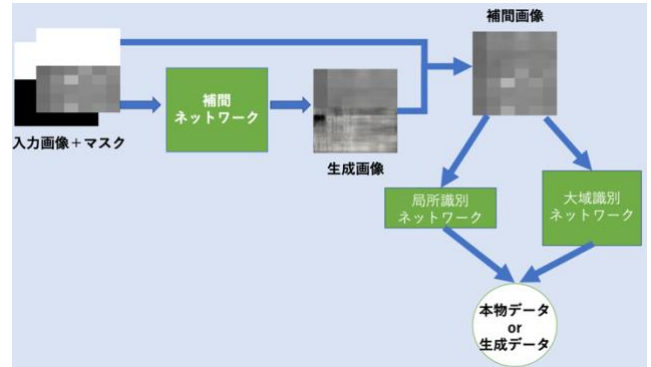


図4 GLCICの概略図

GLCICは1つの補間ネットワークと2つの識別器から構成されるネットワークである。2つの識別器は局所的な識別を行うネットワークと大域的な識別を行うネットワークから構成される。図4右下にあるそれぞれの識別器において、補間ネットワークより生成されたデータが本物の学習用データであるかどうかを識別し、学習を行うことで局所的にも大域的にも本物のデータに近い偽物データを生成することができる。

GLCICでは、欠損が生じた画像データと欠損が生じた領域を示したマスク画像を補間ネットワークに入力する。この時、補間ネットワーク内で入力画像の特徴を持った画像が生成され、さらに、この生成画像のマスク領域を切り取って入力画像の欠損箇所を重ねることで補間画像を生成する。すなわち、GLCICで最終的に出力される画像は欠損箇所のみデータ補間を行い、そのほかの欠損していない部分に関しては元のデータが用いられることとなる。

補間画像は2つの識別器に入力される。大域的識別器には補間データ全体を入力し、局所的識別器には補間されたデータのマスク領域が入力される。それぞれの識別器において、入力されたデータが生成の取れたデータであるかどうかを、損失関数を計算することで判断し、入力されたデータが本物の学習用データか補間ネットワークにより生成されたデータかを識別する。補間ネットワークは識別器において本物データであると識別されるように学習を行い、各識別器は入力されたデータが補間ネットワークにより生成されたデータか本物データかを識別できるように学習が進められる。2つの識別器を用いることにより、オリジナルのGANよりも整合性の取れた、より高精度なデータ生成が見込まれる。

本研究では特徴量データを各特徴量毎に、センサ位置を

縦軸, センサの軸を横軸として 2次元に配置して特徴(2次元)ベクトルとする. そして, センサデータの欠損に応じて, その一部が欠損している特徴2次元ベクトルを GLCIC によってデータ補間を行う. すなわち, 特徴量毎に空間的な関係をもったデータとして捉えることにより, 現在取得できているデータから欠損箇所の補間を行う. RNN や代入法では主にセンサ単体の時間的關係から補間を行なったため, 欠損箇所の前後が長期的に欠損しているようなデータへの対応が困難だったが, 提案手法ではそのようなデータに対してもデータ補間が可能であると考えられる.

4.3 データ補間方法

3章(図2)で述べたデータ補間の具体的な手順について説明する. データ補間の流れを図5, 6に示す. 図5「画像生成」に示すように本研究では各ウィンドウの特徴量データについて, 縦軸センサ位置(例えば, 右腕, 左腕, 胸, 腰, ... など), 横軸センサ軸(例えば, 加速センサ x 軸, 加速度センサ y 軸, 加速度センサ z 軸, ジャイロセンサ x 軸, ... など)として各特徴量毎(例えば, 平均, 分散, エネルギー, など)に2次元ベクトルデータ(画像)を作成する.

生成した2次元ベクトルデータ(画像)は要素数(ピクセル数)がセンサ数×センサ軸数であり, 通常 GLCIC に投入される画像サイズとしては非常に小さいものとなっている. このままのサイズでは GLCIC のデフォルトのネットワーク構造上, 正常に動作しないため, GLCIC に入力する際に画像の拡大を行う.

また, 実験において欠損データを作成する場合, この2次元ベクトルデータ(画像)の拡大画像について, 1からN-1(使用するセンサ数: N)の間で欠損センサ数を変更し, データ欠損させた. 欠損箇所は1で穴埋めをした. なお, 欠損パターンは全部で $\sum_{m=1}^{N-1} N C_m$ パターン存在する.

データ補間では, この欠損データを学習済みの GLCIC に入力することでデータ補間を行う. また補間された GLCIC 出力画像は, 図6に示すようにデータを元のピクセルに対応するように平均値を算出して元のサイズに縮小した.

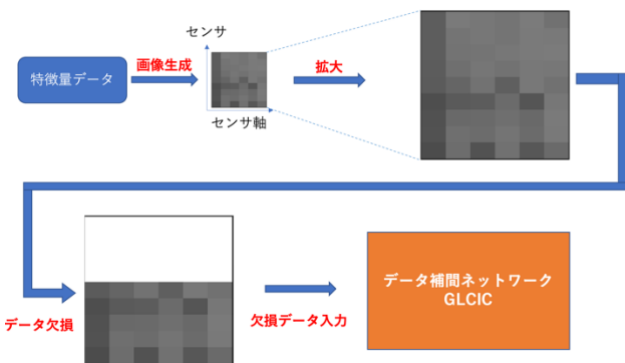


図5 特徴量データの画像化, データ補間までの流れ




図6 データ補間後の流れ

4.4 GLCIC の学習

データ補間を実施する前, すなわち, 行動認識システム稼働前に GLCIC は学習させておかなければならない. GLCIC の学習の流れを図7に示す. 4.3節で述べた欠損データと同様に, 使用するセンサ数全体を N とした時, 1 から N-1 の間で欠損させるセンサ数をランダムに変更してセンサデータから人工的に欠損を生じさせた. なお, 欠損パターンは各欠損センサ数で全パターンを網羅的に欠損させた. この欠損データに正規化などの前処理をおこない, 特徴量に変換して特徴量毎の2次元ベクトルデータ(画像)および, その拡大画像を作成して GLCIC の学習データとした.




図7 図2のデータ補間に用いる GLCIC の学習のモデル図

5. 評価実験

以下, 提案手法の有効性を評価する実験について述べる.

5.1 データセット

本研究で用いたデータセットについて説明する. 本研究ではセンサデータとして, パブリックなデータセットである "REALDISP Activity Recognition Dataset"[13]を用いた. このデータセットでは, 22歳から37歳までの17人(男性10名, 女性7名)の被験者から33種類の行動を観測している. 33種類の行動について, 表1に示す.

表1 REALDISP Dataset の行動内容

L1	Walking
L2	Jogging
L3	Running
L4	Jump up

L5	Jump front & back
L6	Jump sideways
L7	Jump leg/arms open/closed
L8	Jump rope
L9	Trunk twist(arms outstretched)
L10	Trunk twist(elbows bent)
L11	Waist bends forward
L12	Waist rotation
L13	Waist bends(reach foot with opposite hand)
L14	Reach heels backwards
L15	Lateral bend
L16	Lateral bend with arm up
L17	Repetitive forward stretching
L18	Upper trunk and lower body opposite twist
L19	Lateral elevation of arms
L20	Frontal elevation of arms
L21	Frontal hand claps
L22	Frontal crossing of arms
L23	Shoulders high-amplitude rotation
L24	Shoulders low-amplitude rotation
L25	Arms inner rotation
L26	Knees(alternating) to the breast
L27	Heels(alternating) to the breast

L28	Knees bending(crouching)
L29	Knees (alternating) bending forward
L30	Rotation on the knees
L31	Rowing
L32	Elliptical bike
L33	Cycling

データセットにおいて、各被験者は 9 つのセンサを体の各部位（左右ふくらはぎ、左右大腿、左右上腕、左右腕先、背中、胸）に装着した。そして、それぞれのセンサからサンプリングレート 50Hz で 3 軸加速度、3 軸角速度、3 軸磁気、クォータニオン角の 13 次元のデータを収集している。本研究では、このうち 9 つの全てのセンサを使用した。センサデータについては、3 軸加速度、3 軸角速度の合計 6 軸のデータのみを使用した。

実験では Leave-one-subject-out 交差検定での評価を基本とし、識別性能の評価を行なった。この際、認識器と同様に、GLCIC の学習についても、1 人の被験者をテスト対象として除外し、残りの 16 人の被験者データを学習用データとして使用した。

このセンサデータに対して、ウィンドウ幅 2560ms、50% 重なりでスライディングウィンドウを行い、部分系列を取得した。また、正規化を行った後、1 つのウィンドウから 4 種類の特徴量（最大値、最小値、平均値、分散値）を抽出した。

4 章で述べたよう、本研究では特徴量ごとに使用センサ数（縦軸）×センサデータ軸数（横軸）となる画像を作成した。つまり、1 ウィンドウから 9×6 のサイズの画像を 4 枚作成した。そして、拡大画像として、学習時、および、補間時ともに、288×288 のサイズの画像に拡大して GLCIC に入力した。その後、288×288 で出力された補間画像を対応するピクセル範囲で平均値を取り、再び 9×6 のサイズに戻した画像を認識器の学習および認識処理に用いた。

5.2 評価手順

本研究では提案手法を用いた認識性能を、F-measure を用いて評価する。評価する際、leave-one-subject-out 交差検定を行う。

欠損データへ対応する方法として、本手法のように補間を行なう以外にも、認識器をあらかじめデータが欠損した状態を含めて学習しておくことが考えられる。今回は図 8

のように学習に元データを用いる場合のみの実験を行なった。比較のため、欠損させたままのデータを認識器で認識する場合と、補間を行なったデータを認識させる場合の2パターンの評価を行なった。

以下、5.2.1節で認識器の学習についてより詳しく説明し、その後5.2.2節で認識処理について説明する。




図8 実験パターン

5.2.1 認識器の学習

認識処理に用いる認識器の学習を行う。本研究では認識器としてRandom Forest(RF)を用いる。本実験では認識器の学習は図9の実験1を行なった。実験1として学習に欠損、補間を行う前の元データを用いるパターンである。

まず実験1では被験者17人中16人のデータを学習用データとしてRFに入力し、学習を行う。この時入力するデータは欠損が生じていないデータ(元データ)を用いる。




図9 認識器の学習パターン

5.2.2 認識処理

認識処理について説明する。図10に認識処理のパターンのモデル図を示す。5.2.1節で述べた、学習した認識器を認識処理に用いるが、これに対し、欠損したテストデータをそのまま入力して認識を行なう場合と、これまでに述べた方法で補間したテストデータを入力する場合の2つの方法で認識精度を比較した。この時、全体のセンサ数が9個であるため、1から8の間で欠損させるセンサ数を変更した。

また、欠損パターンは $\sum_m^8 {}_9C_m$ パターン存在するが、認識には全パターンを用い、それらの結果の平均を求めた。これらと比較することで、提案手法による認識精度の違いを比較することができる。




図10 認識処理のパターン

6. 結果

6.1 実験1: RFの学習に欠損なしデータのみを用いた場合

図11に実験1の結果を示す。縦軸がF-measure、横軸が欠損センサ数を示している。

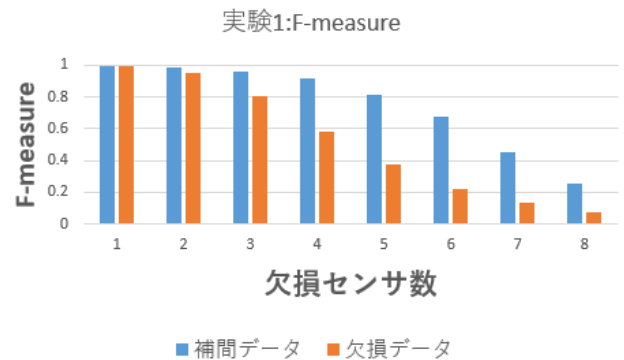


図11 実験1のF-measureの比較

図11より、認識処理に補間データを用いた場合と欠損データを用いた場合では全体的に、補間データを用いた場合の方が認識率の低下を防ぐことができていることがわかる。特に欠損センサ数が4の時、認識処理に欠損データを用いた場合のF-measureの値はおよそ0.6であるが、補間データを用いた場合ではおよそ0.9となっている。

また、欠損センサ数が5の時、認識処理に欠損データを用いた場合のF-measureの値はおよそ0.4であるが、補間データを用いた場合ではおよそ0.8となっている。

これらの結果から、認識処理に提案手法を用いることで認識精度の低下を防ぐことが可能であるとわかる。

7. まとめ

実験の結果より本提案手法を用いることで、欠損データが生じた時でも認識精度の低下を防ぐことが可能であることが示された。特に欠損センサ数が5の時、認識処理に欠損データを用いた場合のF-measureはおよそ0.4であるのに対し、補間データを用いた場合のF-measureはおよそ0.8となっており、使用センサ数の半分以上が欠損した場合であっても高い認識精度を保つことができるとわかる。

また、この結果からあらかじめ多くのセンサを用いてデータを取得し、本手法を適用することで、センサ数を減らし

て高精度の行動認識を行なうことが可能であることが示唆された。

参考文献

- [1] I Goodfellow, J Pouget-Abadie, M Mirza, B Xu, D Warde-Farley, S Ozair, A Courville and Y Bengio, "Generative Adversarial Nets", Advances in Neural Information Processing Systems 27(NIPS 2014)
- [2] Cleaning Disguised Missing Data: A Heuristic Approach, Ming Hua, Jian Pei, KDD'07, August 12-15, 2007, San Jose, California, USA, Copyright 2007 ACM 98-1-59593-609-7/07/0008
- [3] Missing Data Problem in Predictive Analytics, Heru Nugroho, Kridento Surendro, 2019 Association for Computing Machinery. ACM ISBN 978-1-4503-6573-4/19/02
- [4] I. Myrtevit, E. Stensrud, and U. H. Olsson. Analyzing data sets with missing data: An empirical evaluation of imputation methods and likelihood-based methods. IEEE Transactions on Software Engineering, Vol. 27, No. 11, pp. 999-1013, 2001
- [5] 柿元健, 角田雅照, 門田暁人, 松本健一, 佐藤慎一, 協調フィルタリングに基づく工数見積もり手法のデータの欠損に対するロバスト性の評価, 電子情報通信学会論文誌, Vol. J89-D, No. 12, pp. 2602-2611, 2006
- [6] K. Strike, K. El Eman, and N. Madhavji. Software cost estimation with incomplete data. IEEE Transactions on Software Engineering, Vol. 27, No. 10, pp. 890-908
- [7] 高橋将宜, 渡辺美智子, 欠測データ処理: Rによる単一代入法と多重代入法(統計学 One Point), 共立出版, 2017/12/9
- [8] R. J. A. Little and D. B. Rubin. Statistical Analysis with Missing Data. John Wiley and Sons, New York, 2nd edition, 2002.
- [9] 篠田拓樹, 稲毛惇人, 大枝真一, LSTMを用いた降雨量データの欠損補間, 2019年電子情報通信学会ソサイエティ大会, A-19. 安全・安心な生活とICT, A-19-15, 2019.
- [10] Stacked Denoising Autoencoderを用いた間欠的測定センサーデータの復元, 山本直樹, 落合桂一, 稲垣章弥, 神山剛, 深澤佑介, 情報処理学会論文誌, 61-2, pp. 351-361, 2020-02-15
- [11] Hochreiter Sepp, and Jurgen Schmidhuber, Long short-term memory, Neural computation, 9.8, pp. 1735-1780, 1997.
- [12] Satoshi Iizuka, Edgar Simo-Serra, and Hiroshi Ishikawa. "Globaly and Locally Consistent Image Completion". ACM Transaction on Graphics (Proc. of SIGGRAPH), 2017.
- [13] Toth M. A. Damas M. Pomares H. Rojas I. Banos, O. Dealing with the effects of sensor displacement in wearable activity recognition. Sensors, 14(6):9995-10023, 2014.