情報処理学会論文誌 Vol.60 No.10 1780–1795 (Oct. 2019)

推薦論文

分類器の継続更新可能な分散認識センサネットワークのためのオートエンコーダによる通信方式

小向 航平[1,a)] 水谷 伸[2] 岸野 泰恵[2] 柳沢 豊[2] 白井 良成[2]
須山 敬之[2] 大村 廉[3] 澤田 宏[2] 納谷 太[2]

受付日 2018年12月25日, 採録日 2019年7月3日

概要：近年，画像や音声などの高精度のセンサデータの獲得が容易となり，センサネットワークにおいてもこのような高ビットレートのデータを扱うようになってきた．しかし，データをそのままの形でセンサノードからセンタへ送信すると通信量が増大してしまい，通信帯域の圧迫やセンタでの処理負荷の増大が問題となる．そこで，センサネットワークの通信量を減らすために，センサノード側で特徴抽出を行いセンタ側で分類を行う分散認識アーキテクチャが考案された．しかし，従来の分散認識アーキテクチャの多くではセンタ側にセンサデータを保持できないため，分類器の変更や更新が困難であるという問題があった．そこで，本研究では，ニューラルネットワークの一種である AutoEncoder を使用し，分類に使用可能な圧縮データ（特徴量）を得るとともに，そのデータを用いて元のデータ（センサデータ）の復元を可能とする通信方式の提案を行う．本論文では，提案手法の実装と調査を行い，圧縮されたデータが高い認識精度と元データの再現性能を達成し，再現されたデータを用いて分類器の再構築が可能であることを確認した．

キーワード：オートエンコーダ，センサネットワーク，深層学習，分類器，データ圧縮，分散認識

AutoEncoding Communication for Continual Classifier Updating in Distributed Recognition Sensor Networks

Kohei Komukai[1,a)] Shin Mizutani[2] Yasue Kishino[2] Yutaka Yanagisawa[2] Yoshinari Shirai[2]
Takayuki Suyama[2] Ren Ohmura[3] Hiroshi Sawada[2] Futoshi Naya[2]

Received: December 25, 2018, Accepted: July 3, 2019

Abstract: In recent years, sensor networks, high-bit rate data such as image and sound can be aggregated. However, these kind of data require large band width and high computational power at the center. Thus, distributed recognition architecture has been proposed. In the architecture, sensor nodes transmit extracted features and transmit it to the center classifies received data from sensor nodes. However, the most of conventional architecture has a problem that we cannot update classifier because we cannot obtain observed data in the center. In this research, we propose a new communication system that can achieve data compression and classification of sensor data simultaneously by using AutoEncoder and classifier, respectively. In the proposed communication system observed sensor data are compressed to able to reconstruct for classifier update in the center. In this paper, we described implementation and evaluation of the proposed method and verified that the proposed method can update classifier while achieving low reconstruction error and high recognition accuracy.

Keywords: autoencoder, sensor network, deep learning, classifier, data compression, distributed recognition

1. はじめに

近年，センサ技術の発展により高性能で安価なセンサが増え，画像や音声といった高精度のセンサデータを容易に

[1] 豊橋技術科学大学大学院
Graduate School of Toyohashi University of Technology, Toyohashi, Aichi 441–8580, Japan
[2] 日本電信電話株式会社コミュニケーション科学基礎研究所
NTT Communication Science laboratories, Souraku-gun, Kyoto 619–0237, Japan
[3] 豊橋技術科学大学
Toyohashi University of Technology, Toyohashi, Aichi 441–8580, Japan
[a)] komukai@usl.cs.tut.ac.jp

本論文の内容は 2018 年 7 月のマルチメディア，分散，協調とモバイル（DICOMO2018）シンポジウムで報告され，モバイルコンピューティングとパーベイシブシステム研究会主査により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である．

© 2019 Information Processing Society of Japan

獲得できるようになった．これにより，農業分野における画像センシング [1] など，自然環境センシングのような複雑かつ高度な処理を行うセンサネットワークの構築やその研究がさかんに行われている．一般的なセンサネットワークでは，センサデータを収集するだけでなく，センサデータを分析するためにまず分類や回帰（以下，単に「分類」と記載する）を行い，その結果をもとにイベントの検出，トレンドの解析といった処理を行う．しかしこういった分析を行うために，単純にカメラ画像や録音した音声といったセンシングデータをデータセンタ（以下，単に「センタ」と記載する）にすべて送ると，センサノード・センタ間の通信量が膨大になり通信帯域を圧迫し，データの収集自体が行えなくなる可能性が生じる．そこで，センサノード・センタ間の通信量を削減することにより通信帯域圧迫を解消する必要がある [2]．なお，通信データ量の削減には，単に通信量を減少させるだけでなく，送信電力の削減によるシステムの小型化や電池の長寿命化，サーバの負荷軽減などの副次的効果も期待できる．

この問題を解決するために，さまざまなアプローチの手法が提案されている．それらの手法で通信を行う圧縮データは，分類を考えずに圧縮した（単純圧縮）データ，分類を考慮した特徴量（特徴圧縮）データ，分類後ラベル（意味圧縮）データの 3 種に分けることができる．特に，特徴圧縮データで通信を行い，サーバで分類を行うモデルは分散認識アーキテクチャと呼ばれる．一方，意味圧縮データはセンサノード側に計算リソースを必要とするが，最も通信量を削減することができる．

実際のセンサネットワークを想定した場合，末端センサノードに高度な情報処理機能を持たせることは，設置や運用，メンテナンスにかかるコストを考えると非常に困難である．また，センサノード側に分類器を設置し分類ラベルデータのみを通信で送信する場合，センタにラベルデータのみが蓄積され，元のデータは蓄積されなくなってしまう．実環境センシングするうえでは，特に長期的な運用を考慮した場合，運用状況の変化や観測者のニーズの変化に応じてラベルの追加/変更が必要になると考えられるが，ラベルの追加/変更を行うためには学習データ（センサデータとラベルデータの対）が必要となる．しかし，意味圧縮データで通信を行うと，センタにはラベルデータのみが保存されているため，ラベルの追加/変更を行うことが困難である．これに対して，センサで観測したデータを特徴圧縮データで送信しつつも，センタ側でセンサデータを復元できれば，ラベルの追加/変更や，さらには，特徴量の追加/変更が可能な状況を実現できるようになり，センサネットワークをより柔軟に運用できるようになる．

そこで，本研究では，分散認識システムにおいて分類器の更新が可能な通信手法として，Neural Network（NN）の一種である AutoEncoder（自己符号化器，以下 AE）[3] を用いた，センサノード-センタ間通信モデルを提案する．提案手法では，AE によるデータ次元数の削減を活用した通信量の削減を行うとともに，AE の中間層を入力とする分類器を作成して分類を行う．これにより，センタ側にセンサデータを復元可能な状態で蓄積し，必要な場合には復元や再度のラベリングを行うことで，センタに分類器の再学習に必要なデータ対が存在するようになる．また，学習データに特化した圧縮が可能となるため，汎用的な圧縮手法よりも圧縮性能や再現性能を見込むことができる．

以下，本論文では，2 章で本研究の想定環境と関連する研究について述べ，3 章で本研究の提案手法と，その実装手法について述べる．次に，4 章で提案手法の基礎的な性能と実装手法別の性能比較および既存手法との性能比較を行う．さらに 5 章で実際の運用で想定される状況に対し，本提案手法の有用性を実験より示す．最後に 6 章で実験結果をもとに考察を述べ，7 章で本論文をまとめる．

2. 想定環境と関連研究

2.1 想定環境

本研究で想定する環境のモデル図を**図 1** に示す．このように，単一センサノード（画像センサなど）がデータセンタと物理的に離れた場所に設置されていることを想定している．センサノード・センタ間は 1 対 1 で無線通信を行っており，センサネットワークの利用者（監視者）はデータセンタにアクセスしてデータを利用する．センサデータは，センサノード内でセンサデータから特徴量を抽出した圧縮データ（特徴圧縮データ）へ変換される．センタへはこの圧縮データが送信され，センタでは受信した圧縮データをもとに分類を行う．利用者は，分類された結果をもとにイベントの解析・トレンドの分析などを行う．

たとえば，池や沼などにカメラを沈め，まだ明らかになっていない生物の生態調査を行う場合など，センシング対象の挙動などがまだ十分に明らかになっていないようなセンサネットワークでは，利用を進めるうちに，実環境を扱うセンサネットワークでは，分類ラベルの追加や変更が必要になる場合が多い．これらの場合には，圧縮データからセンサデータを復元し，復元データに対して手動でラベリングを行うなどして新たな教師データとし，AE を更新せずに分類器のみを更新することができる．特に，想定していない粒度での分析が必要になった場合や，分析手法自体を試行錯誤しながらセンシングを開始する場合などには，あらかじめ分類手法を確定しておくことは困難である．このような状況に対し，本提案のようにセンタ内のみの処理で，継続的な分類器の変更を可能とすることは，きわめて有用性が高い．

2.2 通信路の圧縮とセンサデータの再現

センサノード・センタ間での通信データ量が増大すると

© 2019 Information Processing Society of Japan

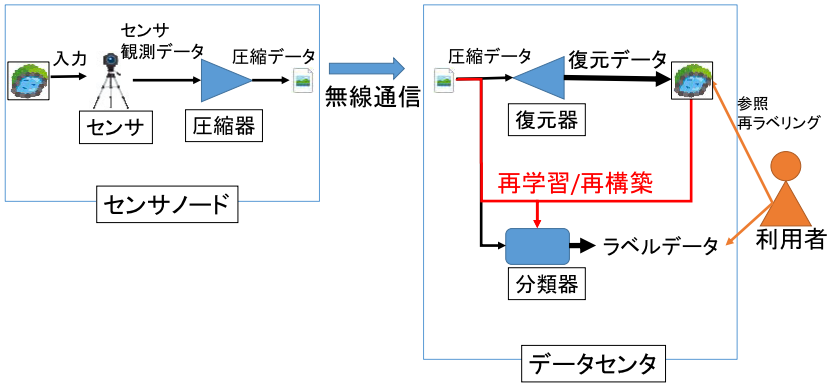

図 1 想定環境
Fig. 1 Assumed environment.

いう問題に対し，さまざまなデータ削減方法と分散認識システムの実装手法が提案されている．

単純圧縮データで通信を行う手法として，gzip や png，jpeg のような汎用的圧縮手法で圧縮し，圧縮データで通信を行う手法が考えられる．この手法には可逆圧縮，不可逆圧縮の 2 通りの方法があるが，特に可逆圧縮を用いた場合はセンサデータをロスなくセンタに送信することが可能である．一方で，データの内容に特化した圧縮手法ではないため，特徴圧縮データや意味圧縮データと比較した場合，データの圧縮性能が劣ってしまう場合が多いと予想される．さらに，分類を考慮に入れて圧縮しないため，センタ側で分類を行う際，圧縮データを復号化後に特徴量の抽出を行う必要があり，多数のセンサノードからデータを収集する際にはサーバの計算負荷が問題となる．

そこで，センサネットワーク（特に分散認識アーキテクチャ）の分野においてはデータの圧縮と特徴量の抽出を同時に行う特徴圧縮データで通信を行うことが多く研究されている．Gupchup らの論文では環境センサネットワークにおけるデータの処理手法について述べている [4]．著者らは膨大なセンサデータから特徴的なデータを抽出する手法として主成分分析（PCA）を使用している．このような手法を用いて，イベントを検出した場合にのみセンサデータを送信すれば，送信データ量を大幅に削減できる．Wu らの研究では，土壌水分センサを対象として，圧縮センシングを用いて，データの変化を予想して送信頻度を下げても，サーバでデータを復元した際の誤差が少ない手法を提案している [5]．この手法では，雨が降った際にだけ大きくデータが変化するという土壌水分センサの特性を活かすことで，送信データ量の削減に成功している．

そのほか，低消費電力でイベント検出 [6] や広域センシングにおけるセンサノードの負荷軽減 [7] など意味圧縮データで通信を行う手法の研究もなされている．しかし，意味圧縮データで通信を行うためには，あらかじめ分類器が十分に学習されており，分類器の再学習が不必要な環境であることが望ましい．実際のセンサネットワークの運用では，事前に学習データの準備を行うことは困難な場合が多い．また，分類後のラベルデータのみを蓄積するために，分類誤りに気がつくのが困難であるといった問題点もある．

このようにセンサネットワークにおけるデータ圧縮にはさまざまな研究例があるが，多くの研究ではいかに低消費電力でデータを圧縮・解析するか，という点が注目され，通信路の圧縮とセンサデータのサーバ側での再現を両立させ，これによって分類器を継続的に更新することについてはあまり考慮されてこなかった．これに対し，本研究では，AE を活用することによる通信路の圧縮とサーバ側でのセンサデータの再現を両立させ，分類器の更新を可能とするセンサネットワークにおける通信方式の提案を行う．

2.3 AE と分類 NN の活用

AE とは，次元削減を行う NN の一種である．一般的な AE のモデル図を**図 2** に示す [3]．AE は次元削減を行うエンコーダ部（符号器）と入力を復元するデコーダ部（復号器）からなる．AE では，出力と入力が同一になるように教師あり学習を行う．この学習により，エンコーダは入力信号を出力側で再現するために必要な情報を抽出して次元削減し，その情報を基にしてデコーダが出力側で入力信号に近い信号を復元できるようになる．さらに，AE に用いられる構造を利用し，エンコーダの出力値の分布が，設定した確率分布に近くなるように分布の差を表す正則化項を入れ，通常の AE と同じく教師あり学習を行う Variational Autoencoder（VAE）が考案されている [8]．

蔵内らは，センサネットワーク全体を 1 つの NN 分類器と見なし，VAE のエンコーダ部を各センサノードに配置して，各センサノードからデータを集約する際に圧縮されたデータを用いて通信するネットワーク構造（Feature Extrusion Net）を提案している [9]．これにより，使用するセンサノード数が増加した場合でも，通信データの削減を行いつつセンタ側で行う認識の精度の低下を緩やかにすることができている．また，Ghifary らは，センサネットワークを対象とした研究ではないが，本提案手法と同一構

© 2019 Information Processing Society of Japan

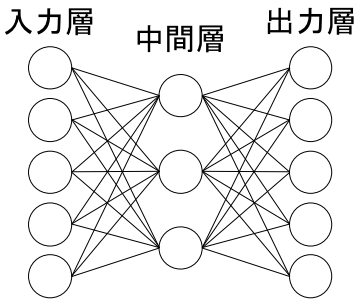

図 2 AutoEncoder モデル
Fig. 2 AutoEncoder model.

造の NN で，分類性能の汎化性を上げる方法を提案している [10].

文献 [9], [10] の手法はともに，AE と分類 NN を同時に使用する点において本研究の提案手法と共通する．しかし，文献 [9] は分散配置されたセンサノードからのデータの集約とその通信量の削減を目的としたものであり，取得したデータを復元して利用することは考慮していない．また，文献 [10] は，単一コンピュータ上での分類器を対象とした研究であり，通信路におけるデータの圧縮と復元については考慮されていない．さらに文献 [10] は，エンコーダとデコーダ，ならびに，分類器を同時に学習させるため，分類器の更新を行う場合は AE を含むモデル全体を学習しなおす必要が生じる．このため，仮にセンサネットワーク上に配置したとしても，分類器の更新を試みる場合は学習にコストがかかるうえに，更新された新しいモデルをセンサノードに書き込む必要が生じる．通信帯域の限られたセンサネットワークでは，このことは実用において困難を生じる可能性が高い．

これに対し，本研究における提案手法は，通信量を削減しつつ，1 度センサノードに配置した AE は更新することなく，圧縮・復元されたデータを用いてセンタ側に配置された分類器のみを再構築・更新する点で既存研究とは異なる．

3. 提案手法

3.1 提案手法

本研究の提案モデルを**図 3** に示す．AE は，データをエンコーダで次元圧縮を行い，デコーダで復元し入力と出力が同じになるように教師あり学習を行う．図 3 で示したとおり，中間層データで通信を行うことで，通信量の削減を行う．同時に AE の中間層データを入力とする分類器を作成する．なお，実センサネットワークに適用する場合，AE は学習済みと想定する．

AE と分類器の学習は，はじめに，全データで圧縮/復元を行う AE のみを学習する．次に，AE の重みを固定したまま，圧縮データから分類 NN を学習する．AE はラベルを必要としない学習を行うため，分類ラベルの追加/変更時の追加学習が不要である．AE の学習にはある程度のデータ量が必要であるが，十分なデータ量があれば汎化も期待できる．よって，センサネットワークの初期構築時に全体を学習し，分類器のみを観測者のニーズの変化に合わせて再学習を行うことが可能となる．

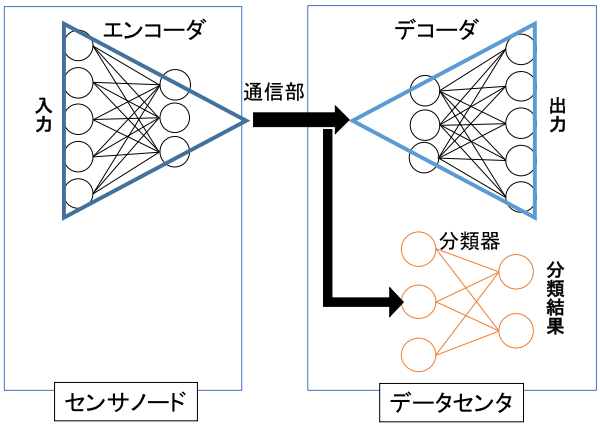

図 3 提案モデル
Fig. 3 Proposed model.

本提案手法では，AE を使用するが，AE の特性として入力データと入力次元数が判明している必要がある．ここでは，解像度が固定された画像センサを想定する．そして，画像センサが観測するデータを，学習データに類似したデータ（データ群 A），圧縮・復元手法の汎化性能により対応可能なデータ（データ群 B），汎化性能では対応できない想定外のデータ（データ群 C）の 3 種に分類する．本論文では，本手法の適応範囲をデータ群 A，B へ限定する．

なお，本研究で分類器の再学習とは，AE のエンコーダ部の学習重みは更新せずに分類器モデルのみを再生成することを指し，AE はセンサノード・センタに搭載する時点で学習済みとする．

3.2 提案手法の利点

本提案手法は，AE を用いて，通信量の削減と分類を同時に行う手法である．提案手法では，AE を用いた次元数削減による通信量の削減と AE 中間層からの分類を並行して行う．これにより，センタ側に分類ラベルだけでなく，センサデータを復元したものを対にして保存できるため，運用方針の変化や観測者のニーズの変化に対応した分類ラベルの追加/変更時の分類器の再学習が可能となる．

AE のエンコーダ・デコーダ間の最もノードが少ない層である中間層のデータを取り出して，分類器の入力とするため，AE に変更を加えることなく，分類器のみを更新することで，分類ラベルの追加/変更に対応できる．このため，分類ラベルの追加/変更時に，センサノードに配置された AE のエンコーダ部を更新する必要はなく，センタの分類器を更新するのみで対応できる．

© 2019 Information Processing Society of Japan

3.3 提案手法の実装

AE にはさまざまな種類が存在する．そこで，本論文では複数の AE で提案モデルを実装し，その比較を行う．入力データとして画像データを扱うことを想定し，使用する AE の選択と提案手法の構築を行った．実験の詳細は 4 章で述べるが，実験では（28 × 28）の入力画像を使用したため，入力データは（28 × 28）のサイズを想定する．実運用においては，入力データのサイズに応じ，隠れ層数やノード数を変更することで対応が可能である．

はじめに，3.3.1 項で最も基本的な構成である，ノード間結合を，全結合で構成した AE について示す．次に，3.3.2 項で，画像認識に用いられ，画像の平行移動に対し汎化が期待できる Convolutional Neural Network（CNN）を使用し，AE を構築したモデルを示す．VAE は AE と異なり，生成モデルを有することにより，センサネットワークにおいて，センサデータが欠損した場合に，センサデータの補完が可能であると考える．そこで，VAE を使用し提案手法を構築した．これを，3.3.3 項および 3.3.4 項で示す．

なお，すべての提案モデルにおいて隠れ層ノード数を N_h，中間層ノード数を N_c とし，すべての状態において $N_h > N_c$ が成立するように値を設定する．

3.3.1 Fully Connected-AutoEncoder

まず，最も基本的な全結合方式でモデルを作成する AE を考える．これは以降で述べる提案モデルの基礎となる構成である．**図 4** に Fully Connected-AutoEncoder（FC-AE）モデルを示す．これは，隠れ層を含む全 5 層構成の AE で，各層のノードは 1 つ前の層のノードに全結合状態にある．よって，N_h = 隠れ層ノード数，N_c = 中間層ノード数となる．また，中間層を入力とする分類器も全結合で構成する．

学習に使用したパラメータを**表 1** に示す．活性化関数は，AE では Rectified Linear Unit（ReLU）を使用し，分類器では分類層に Sigmoid 関数を使用し，その他の層には ReLU を使用する．また，AE および分類器を学習する際の損失関数には平均二乗誤差（Mean Squared Error，以下 MSE）を使用する．

3.3.2 Convolutional Neural Network-AutoEncoder

3.3.1 項では AE のノード間を全結合により結合させたが，本研究で想定するセンサネットワークモデルでは画像センサを使用することも想定できる．そこで，AE に，主として画像認識に用いられる CNN を適用したモデルを検討する．

CNN は，画像や 2D パターンを分類するためにノードが 2D 上に並んだ層構造を持つ NN である．Convolution 層では，前層から局所的な重み結合で畳み込みを行う．重み結合は，2D の並進対称性を持ち，同じフィルタ内の 2D 上の異なるノードも前層に対して同じであるため，2D パターンの平行移動に対して，Convolution 層は，同じ反応

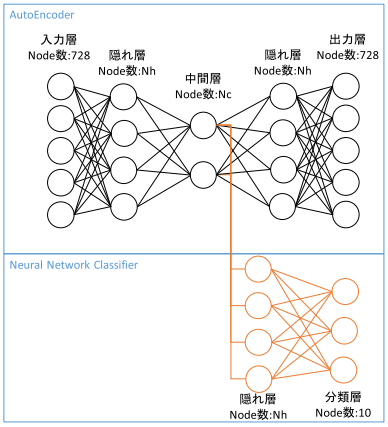

図 4 FC-AE モデル

Fig. 4 Fully Connected-AutoEncoder model.

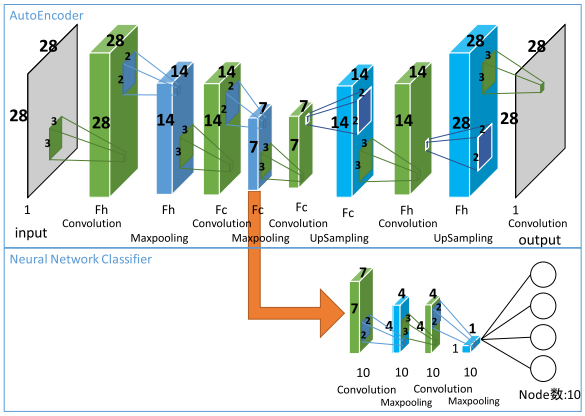

図 5 CNN-AE モデル

Fig. 5 Convolutional Neural Network-AutoEncoder model.

を示す．この層は，異なる局所重み結合ごとに存在する．その後に続く，MaxPooling 層および UpSampling 層では，ノード数を増減させる一方で，Convolution 層の反応の 2D 上の位置情報を表現できるようにしている．分類に使用される代表的な CNN では，Convolution 層と MaxPooling 層もしくは UpSampling 層はセットとなって，それらの数層での処理の後，全結合により各ノードが各々の分類ラベルを表現するような最終出力層で分類の結果を得るようになっている．学習は，入力と分類ラベルの対を使って行われる．

図 5 に Convolutional Neural Network-AutoEncoder（CNN-AE）を示す．全 5 層からなり入力画像（28 × 28）を中間層で（7 × 7）に圧縮する．ここで，隠れ層のフィルタ数を F_h，中間層のフィルタ数を F_c とする．FC-AE と異なり隠れ層，中間層ノード数は式 (1)，(2) により求められる．

$$N_h = 14 \times 14 \times F_h \tag{1}$$

$$N_c = 7 \times 7 \times F_c \tag{2}$$

Convolution 層のカーネルサイズはすべての層で（3 × 3）であり，ストライドは 1 とした．MaxPooling 層ではフィ

© 2019 Information Processing Society of Japan

表 1 各モデルのパラメータ
Table 1 Parameters of each model.

モデル名	AE 学習		分類器学習		初期学習率	ミニバッチサイズ	epoch 数
	Optimizer	損失関数	Optimizer	損失関数			
FC-AE	Adam	MSE	Adam	MSE	0.001	100	100
CNN-AE	Adam	BCE	Adam	MSE	0.001	100	100
FC-VAE	RMSprop	BCE+KLD	Adam	MSE	0.001	100	100
CNN+FC-VAE	RMSprop	BCE+KLD	Adam	MSE	0.001	100	100

ルタサイズは半分になり，UpSampling 層ではフィルタサイズは倍となる．中間層を入力とする分類器は CNN と FC の組合せにより構成される．

学習に使用したパラメータを表 1 に示す．活性化関数は，AE では出力層に Sigmoid 関数を使用し，その他の層に ReLU を使用する．分類器では分類層に Sigmoid 関数を使用し，その他の層には ReLU を使用する．また，AE 学習の損失関数にはバイナリクロスエントロピー（Binary Cross Entropy，以下 BCE）を使用し，分類器の学習には MSE を使用する．

3.3.3 Fully Connected-Variational AutoEncoder

3.3.1 項および 3.3.2 項では AE のノード間結合方式の違いにより，FC-AE と CNN-AE を作成した．次に AE として，VAE を使用したモデルを考える．VAE の学習は，AE の学習である入出力間の差を減らすことに加えて，エンコーダにより，入力データ空間でのデータ（観測変数）の出現する確率分布が，圧縮した次元（潜在変数）の空間で，直交した同一の平均 μ，標準偏差 σ を持つ多変量独立正規分布 $\mathrm{N}(\boldsymbol{\mu}, \sigma^2 I)$ になるように，NN で写像させる．ただし，$\boldsymbol{\mu}$ は，値がすべて同じ平均 μ の圧縮次元数のベクトル，I は，圧縮次元数の単位行列を表す．VAE は，データを観測変数，分類ラベルを含めた圧縮情報を潜在変数とする確率モデルを導入することにより，通常の AE に比べ，潜在変数と入力が持つ人間の解釈可能な属性（分類ラベル）との関係を調べることができ，また，潜在変数を変化させ，再現する観測変数を制御し学習に用いたデータと似たデータを生成できるという利点を持つ．

図 6 に Fully Connected-Variational AutoEncoder（FC-VAE）を示す．これは，隠れ層を含む全 5 層構成の VAE で，各層のノードは 1 つ前の層のノードに全結合状態にある．中間層は，入力に依存した正規分布の平均，標準偏差を基に，そのサンプリング値をデコーダに出力する．ここでは，中間層でのサンプリング値の次元数を中間層（Z）ノード数とする．よって，通信を行うノード数は，このサンプリング値の次元数であり，そのため，N_h = 隠れ層ノード数，N_c = 中間層ノード数となる．また，中間層（Z）を入力とする分類器も全結合で構成される．

学習に使用したパラメータを表 1 に示す．活性化関数は，AE では出力層に Sigmoid 関数を使用し，中間層である

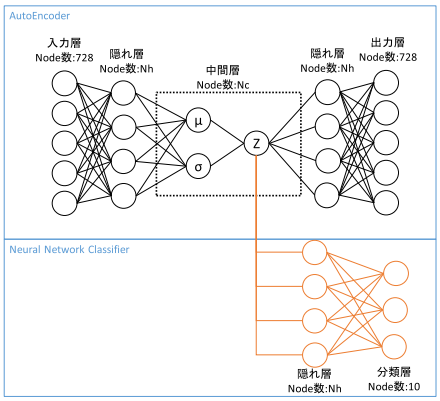

図 6 FC-VAE モデル
Fig. 6 Fully Connected-Variational AutoEncoder model.

$\mu \cdot \sigma$ 層には線形関数，その他の層には ReLU を使用した．分類器では分類層に Sigmoid 関数を使用し，その他の層には ReLU を使用した．また，AE 学習の損失関数には BCE と KL ダイバージェンス（Kullback-Leibler divergence，以下 KLD）の和を使用し，分類器の学習には MSE を使用する．

3.3.4 Fully Connected + Convolutional Neural Network-Variational AutoEncoder

FC-VAE ではすべてのノード間結合に全結合を使用したが，一部の結合を CNN に置き換えたモデルも考えられる．たとえば，Kulkarni らによって使用された画像データに対する VAE の構成手法である Deep Convolutional Inverse Graphics Network（DCIGN）[11] などがあげられる．

図 7 に Fully Connected + Convolutional Neural Network-Variational AutoEncoder（FC+CNN-VAE）を示す．FC+CNN では VAE の各層の結合を CNN と FC を使用することで VAE の画像適応性能を強化している．隠れ層に CNN を使用しているため，隠れ層ノード数は，CNN-AE と同様に式 (3) で表される．

$$N_h = 7 \times 7 \times F_h \tag{3}$$

中間層は FC-VAE と同様に中間層（Z）ノード数を参照するため，N_c = 中間層（Z）ノード数となる．なお，CNN 部での各パラメータは CNN-AE と同等である．また，中間層（Z）を入力とする分類器は全結合層で構成される．

学習に使用したパラメータを表 1 に示す．活性化関数

© 2019 Information Processing Society of Japan

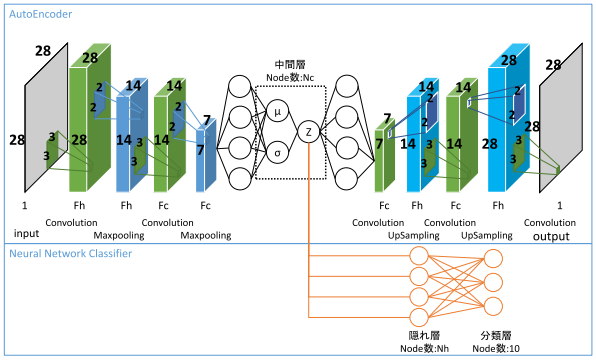

図 7 FC+CNN-VAE モデル
Fig. 7 Fully Connected + Convolutional Neural Network-Variational AutoEncoder model.

は，AE では出力層に Sigmoid 関数を使用し，中間層である $\mu \cdot \sigma$ 層には線形関数，その他の層には ReLU を使用した．分類器では分類層に Sigmoid 関数を使用し，その他の層には ReLU を使用した．また，AE 学習の損失関数には BCE と KLD の和を使用し，分類器の学習には MSE を使用する．

4. 提案手法の基礎性能評価

本章では，提案手法の基本的な性能を調査する．はじめに，4.1 節で実験の概要と評価基準および各モデルの学習パラメータの設定を示す．次に，4.2 節で 3.3 節で説明を行った 4 種のモデルの基本的な性能について調査する．4.3 節ではデータ群 B が入力された場合における各モデルの汎化性能について調査する．最後に 4.4 節で既存手法とデータ圧縮性能と再現誤差の比較を行う．

4.1 実験概要と評価基準，学習パラメータ

本研究では，定点カメラのような画像センサを想定している．そこで，実験では，比較的単純な画像データとして，単色手書き数字画像である，MNIST [*1] データセットを使用した．

データセットのうち，60,000 件を学習データとして用い，10,000 件をテストデータとして用いた．また，epoch 数（学習回数），ミニバッチサイズ（1 学習あたりのデータ数），学習率の初期値などの，学習パラメータは表 1 に示すとおりである．

評価は，圧縮度合いに対する再現誤差と分類精度で行う．再現誤差の評価には平均二乗誤差（MSE）を用い，分類精度の評価には認識正答率（Accuracy）を使用する．また，画像は 0–1 の範囲に正規化されている．

本研究では，再現誤差の指標として，平均二乗誤差を 0–1 の範囲に正規化された画像データの 1 ピクセルあたりの誤差として扱い，定義式を式 (4) に示す．ここで，テストデータ数を N，ピクセル総数を M とする．また，O をオリジナルの 8 bit グレースケール画像の各画素の輝度とし，P を AE の出力データを 8 bit グレースケール画像の各画素の輝度である．

$$\mathrm{MSE} = \frac{1}{M}\frac{1}{N}\sum_{m=1}^{M}\sum_{n=1}^{N}(O_{n,m} - P_{n,m})^2 \tag{4}$$

はじめに，提案手法使用時の符号化率（圧縮度合い）と再現誤差および汎化性能について評価を行った．汎化性能は使用したデータが画像データであったので画像を変形させた場合のテストデータを使用した．各 AE のノード数 N_h，N_c を変化させることで各 AE における再現誤差や分類精度の変化を調査する．その後，N_h を固定し 4 種類の AE の再現誤差と分類精度の比較評価を行った．

次に，提案手法とデータの圧縮に既存の圧縮手法を使用した場合や，AE を使用した場合に考えられるベースライン手法との再現誤差について，比較評価を行った．

すべての実験において，提案手法のパラメータである，N_h，N_c は $N_h > N_c$ とする．N_h，N_c は float 型で定義しており，1 ノードあたり 4 byte で表現されるため，中間層のサイズ（通信を行うサイズ）は式 (5) で求めることができる．また，入力データは（28×28）の単色画像であり，Int8 型で表現されているため入力データサイズは式 (6) で求めることができる．以上より，符号化率は式 (7) と定義される．式 (7) より，符号化率が低いほど圧縮度合いが高いことを示す．

$$\text{中間層サイズ [byte]} = N_c \times 4 \tag{5}$$

$$\text{入力データサイズ [byte]} = (28 \times 28) \times 1 \tag{6}$$

以上より，

$$\begin{aligned}\text{符号化率 [\%]} &= 100 \times \frac{\text{中間層サイズ}}{\text{入力データサイズ}} \\ &= 100 \times \frac{N_c \times 4}{28 \times 28 \times 1}\end{aligned} \tag{7}$$

4.2 提案手法の基礎性能評価

はじめに，FC-AE について**図 8** に符号化率と再現誤差を示し，**図 9** に符号化率と分類精度の関係を示す．2 つの結果より符号化率が高く，N_h が大きいほど，再現性能や分類精度が良いことが分かる．次に，CNN-AE について，**図 10** に符号化率と再現誤差を示し，**図 11** に符号化率と分類精度の関係を示す．2 つの結果より FC-AE と同様に，符号化率が高く N_h が大きいほど再現性能や分類精度が良いことが分かる．

図 12 に 3 章に記載した 4 種の実装手法別の符号化率と再現誤差のグラフを示し，**図 13** に符号化率と分類精度のグラフを示す．図 12，図 13 で使用した N_h は，各 AE 別に実験をした際に最も良い結果を出したものを使用した．これらの結果より，すべての AE において，符号化率が高

[*1] http://yann.lecun.com/exdb/mnist/

© 2019 Information Processing Society of Japan

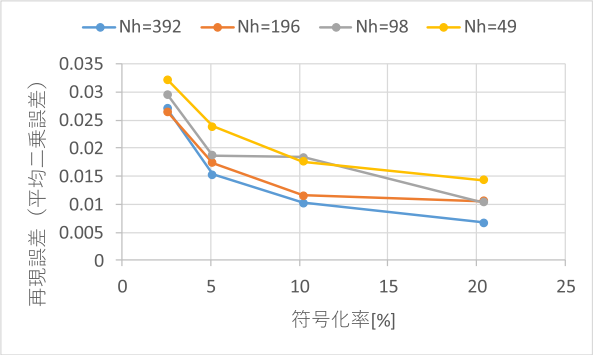

図 8 FC-AE での符号化率と再現誤差
Fig. 8 Encoding rate and reconstruction error in FC-AE.

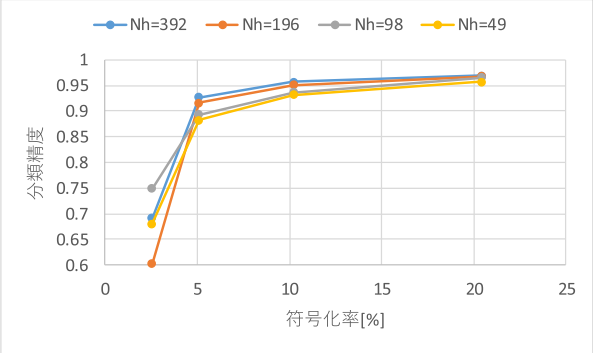

図 9 FC-AE での符号化率と分類精度
Fig. 9 Encoding rate and accuracy in FC-AE.

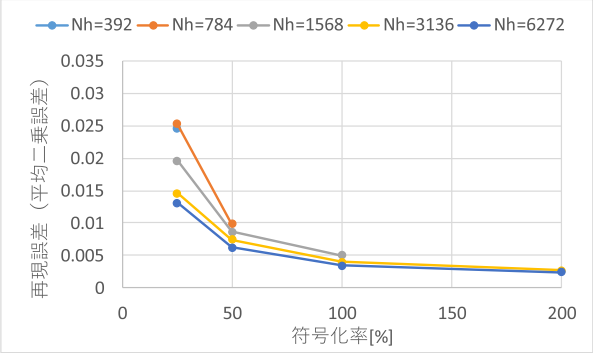

図 10 CNN-AE での符号化率と再現誤差
Fig. 10 Encoding rate and reconstruction error in CNN-AE.

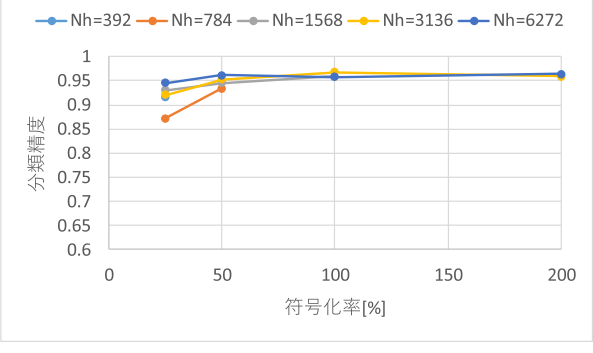

図 11 CNN-AE での符号化率と分類精度
Fig. 11 Encoding rate and accuracy in CNN-AE.

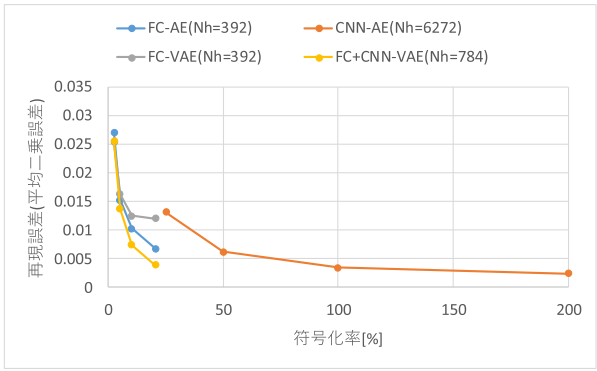

図 12 提案手法毎の符号化率と再現誤差の比較
Fig. 12 Encoding rate and reconstruction error in proposed methods.

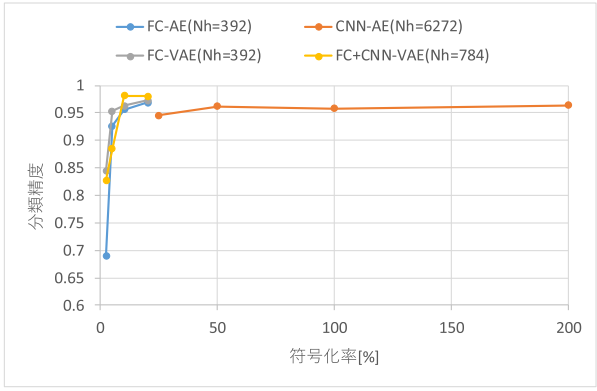

図 13 提案手法毎の符号化率と分類精度の比較
Fig. 13 Encoding rate and accuracy in proposed methods.

いほど再現性能が向上した．また，AE のノード間結合構成に CNN を使用した場合，符号化率は高いが，再現誤差は低くなることが分かる．一方で，FC を使用した場合には符号化率は低いものの再現誤差は大きくなってしまう．そのため，CNN と FC を組み合わせ，中間層で FC-VAE と同等の構成を持つ，FC+CNN-VAE は符号化率が低くても再現性能が高い．FC+CNN-VAE の場合は符号化率が10%以下の場合は他の FC と大きな差はないが，それよりも高い場合は CNN と同程度の再現誤差となる．符号化率と分類精度の関係をみると符号化率が 10%よりも大きい場合はすべての提案手法の分類精度には大きな差はない．また，図 13 に示すようにすべての実装手法において，符号化率が高くなると分類精度が向上する．符号化率 20%以上になるとノード間結合方式の種類によって，分類精度に大きな差はみられなかった．

以上より，符号化率を低く抑えつつ分類精度と再現性能を高くとる場合は FC+CNN-VAE を使用すればよいと考えられる．

4.3 提案手法の汎化性能評価

4.2 節ではデータ群 A が入力された場合の提案手法の性能を評価した．次に，データ群 B が入力された場合の提

© 2019 Information Processing Society of Japan

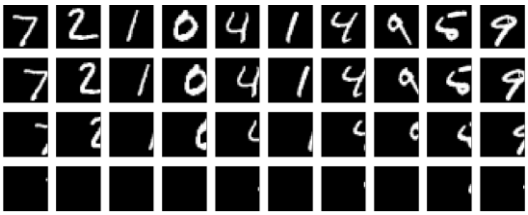

図 14 右に移動させた画像
Fig. 14 Right shifted images.

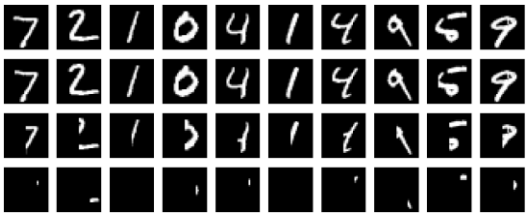

図 15 左を塗りつぶした画像
Fig. 15 Left filled images.

案手法の汎化性能を調査する．学習に使用した MNIST は文字画像データであるため，上下左右への移動データや上下左右の塗りつぶしデータで汎化性能を調査する．NN や CNN の汎化作用により，上下左右のいずれかに平行移動した場合でも AE はすべての方向に対し，同様の振舞いをすると考えられる．そのため，本実験ではテストデータを “画像を右に移動した場合” と “画像を左端から塗りつぶした場合” の 2 種類の加工を行うことで汎化性能の調査を行った．本実験のパラメータとして，変化量 N [pixel (以下 px)] をとる．この変化量は，元画像を $N = 0$ [px] とし，変化量 N [px] のとき，元画像から N [px] 右に移動させた，または，元画像の左 N [px] を塗りつぶしたことを表す．実験では，N を $0 \leq N \leq 28$ の範囲で 1 ずつ変化させ，そのときの再現誤差と分類精度を調査した．**図 14** に画像を右に移動させた場合の画像の一例と元画像の比較を示し，**図 15** に画像を左端から塗りつぶした場合の画像の一例と元画像の比較を示す．図 14，図 15 ともに，最上段に $N = 0$ の場合の画像（オリジナル入力データ）を示し，2 段目に $N = 7$ の場合，3 段目に $N = 14$ の場合，4 段目に $N = 21$ の場合の加工後の画像を示す．

図 16 に画像を右に移動させた場合の再現誤差を示し，**図 17** に画像を右に移動させた場合の分類精度を示す．結果より，CNN-AE 以外の AE では画像の変化量が増大するにつれ分類精度は低下した．CNN-AE は $N = 10$ 程度までは対応できていたが，それ以上の変化には対応できなかった．再現誤差は変化量が $N = 9$〜12 の場合をピークとし，その後減少した．再現誤差の変化には AE の種類によって違いが見られ，ノード間結合に CNN が用いられている CNN-AE と FC+CNN-VAE は再現誤差の増加割合は他の AE と比較すると，少ないことが分かる．これは，CNN が 2 次元ノードにおいて，自身の上下左右のノード

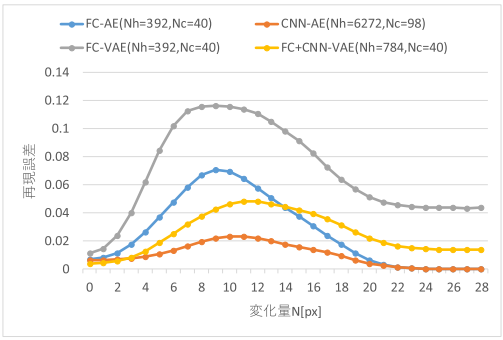

図 16 画像を右に移動させた場合の再現誤差
Fig. 16 Reconstruction error by right shifted images.

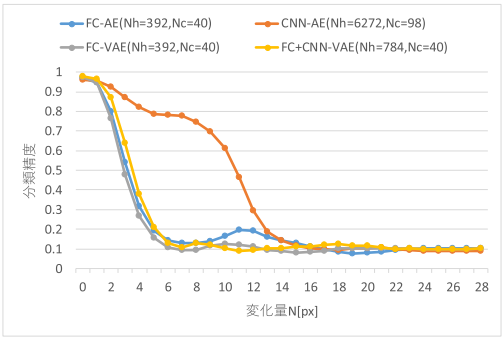

図 17 画像を右に移動させた場合の分類精度
Fig. 17 Accuracy by right shifted images.

を参照するため，ある程度の画像の変形を吸収できると考えられる．一方で FC-AE や FC-VAE などでは学習データと変形テストデータとの差を吸収しきれずに大きな誤差を出してしまう．これは，1 次元ノード配列では画像の変形による差を吸収できないため，誤差が大きくなりやすいと考えられる．

図 18 に画像を左側から塗りつぶした場合の再現誤差を示し，**図 19** に画像を左側から塗りつぶした場合の分類精度を示す．結果より，すべての AE において画像の変化量が増大するにつれ分類精度は低下したが，低下し始めるタイミングは右に移動させた場合よりも遅かった．再現誤差は FC-VAE のみ増大し，他の 3 種の AE ではあまり変化は見られなかった．これは，CNN では画像の移動対し汎化能力はあるものの，データの欠損に対しては，汎化能力がないためである．

4.4 既存手法との比較

センサネットワークでセンサノード・センタ間の通信量を削減する手法として，センサノード側でデータを単純に圧縮することが考えられる．そこで，提案手法による符号化率や再現誤差と，ベースライン手法や既存手法との比較を行う．これにより，提案手法は既存手法と同程度の通信量の削減が可能であることを示す．

比較する手法として，AE をデータ圧縮のみに使用したベースライン手法と，データを可逆圧縮し通信を行う手法，

© 2019 Information Processing Society of Japan

表 2 提案手法と比較手法の比較
Table 2 Comparison between proposed methods and conventional methods.

モデル	平均符号化率[%]±標準偏差[%]	再現誤差±標準偏差
FC-AE （N_h=392， N_c=40）	20.41±0	0.004135±0.02448
CNN-AE （N_h=6272， N_c=98）	50.00±0	0.006137±0.03309
FC-VAE （N_h=392， N_c=40）	20.41±0	0.01203±0.05288
FC+CNN-VAE （N_h=784， N_c=40）	20.41±0	0.003894±0.02210
ベースライン手法 （N_c=128）	65.31±0	0.01202±0.05238
可逆圧縮手法 1 （zlib）	35.04±2.255	0
可逆圧縮手法 2 （gzip）	35.65±2.265	0
可逆圧縮手法 3 （bz2）	57.84±3.490	0
不可逆圧縮手法 （jpg）	25.03±0.01622	0.005101±0.01622

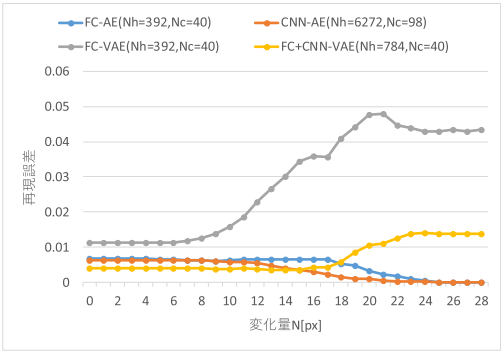

図 18 画像を左側から塗りつぶした場合の再現誤差
Fig. 18 Reconstruction error by left filled images.

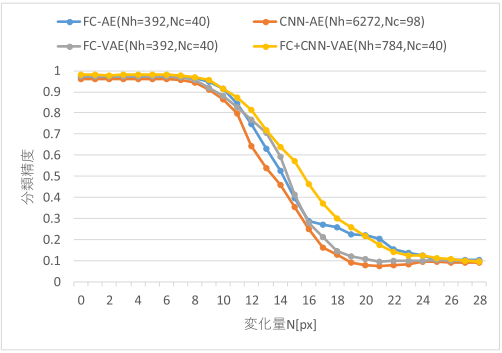

図 19 画像を左側から塗りつぶした場合の分類精度
Fig. 19 Accuracy by left filled images.

画像データの不可逆圧縮し通信を行う手法の 3 種類で比較を行う．評価実験には MNIST のテストデータ（10,000 データ）を使用し，符号化率と再現誤差（MSE）で評価する．

ここで，ベースライン手法として，AE でデータを圧縮し，AE の出力から分類を行うことを想定したモデルを構築する．なお，ベースライン手法には単純な CNN モデルを使用する．**図 20** にベースライン手法モデルを示す．このとき，中間層サイズ N_c は $N_c = 128$ となる．

可逆圧縮手法は，一般的な圧縮手法である zlib，gzip，

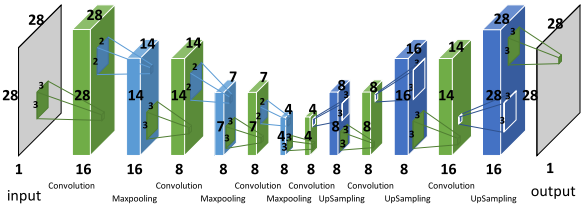

図 20 ベースライン手法における AE モデル
Fig. 20 Baseline AE model.

bz2 の 3 種類を使用し，Python ライブラリを用いて実装した．画像を 1 枚ずつ圧縮することを想定するため，符号化率は式 (8) に示すように，すべてのデータの平均値をとる．なお，可逆圧縮のため，再現誤差は 0 として扱う．

$$\text{符号化率 [\%]} = 100 \times \frac{1}{N} \sum_{n=1}^{N} \frac{\text{圧縮データサイズ}_n}{\text{入力データサイズ}_n} \quad (8)$$

不可逆圧縮手法は jpeg を使用し，opencv-python により実装を行った．符号化率は式 (8) を使用した．

実験結果を**表 2** に示す．結果より，FC-AE，CNN-AE，FC-VAE，FC+CNN-VAE の画像の再現性能はベースライン手法や jpeg 圧縮と同等以上であることが示された．これは，AE が jpeg のような汎用的な画像圧縮手法とは異なり，扱うデータに特化した圧縮手法となっているためであると考えられる．よって，提案手法は少ないデータ量であっても既存の画像圧縮手法と同等以上の再現誤差や分類精度を持つと判断できる．そのため，実センサネットワークに搭載した場合でもより少ないデータ量で，データを送信でき，電池の長寿命化や通信コスト削減が期待できる．

5. 復元データを用いた分類器更新実験

本章では，実際のシステム運用で発生すると考えられる状況を想定して実験を行う．より具体的には，デコーダを用いて復元したデータに対して再ラベリングを行い，このデータを用いて，分類器の更新が十分に可能であることを示す．5.1 節では，学習データを追加で得ることができた場合に分類器の更新が可能であることを示す．5.2 節では，

© 2019 Information Processing Society of Japan

分類ラベル数が増加した場合においても分類精度を維持したまま分類器の更新が可能であることを示す．最後に，5.3 節では AE 復元データを使用し，異なる観点から分類器を新たに作成した場合でも十分な分類精度を得ることが可能であることを示す．ここで AE 復元データとは学習済み AE にデータを入力し AE の出力として得られたデータを示す．また，オリジナルデータとはデータセット元々のデータを示す．

5.1 節から 5.3 節の実験において，分類器の学習データとして AE 復元データを使用するが，そのラベルは，元々オリジナルデータに付与されていたラベルと同じものを使用する．また，使用した学習パラメータは 4.1 節と同様のもので，表 1 に示す．なお，AE は 60,000 個のオリジナルデータで学習し，いずれの場合においても AE の再学習は行わなかった．

5.1 分類器の学習データ数の変化による分類精度の変化

はじめに，分類器の学習データ数を増加させた場合の分類精度の変化を調査する．本実験では，「センサ設置時には十分なラベル付き教師データを得ることができていなかったが，次第にラベル付きデータを獲得できた場合」を想定し，分類器の更新を行うことで分類精度を向上できることを確認する．

具体的には，学習データ数を 60，600，6,000，60,000 個の 4 段階に増加させた場合の分類精度を比較した．各条件において，60 個のデータは初期学習データ（MNIST オリジナルデータ）とし，残りのデータは AE 復元データを用いた．たとえば，学習データが 60 個の場合は分類器を初期学習データのみで学習させ，600 個の場合は分類器を 60 個の初期学習データと 540 個の AE 復元データで学習させた．分類精度の評価には，4 章と同様にテストデータとして 10,000 個の未知データを使用した．結果を**図 21** に示す．

図 21 より，すべての分類器において学習データ数の増加にともない分類精度が向上していることが分かる．さらに，60,000 個の学習データ（60 個の初期学習データと 59,940 個の AE 復元データ）を用いた場合には，すべての分類器の分類精度は 1.00 にきわめて近くなっている．すなわち，提案手法によって，AE 復元データとして，オリジナルデータに非常に近いデータを取得可能であり，このデータを学習データとして用いることで分類器の改善が可能であることが示された．

5.2 分類ラベル数による分類精度の変化

次に，提案手法において分類に使用するラベル数を増加させた場合における分類精度の変化を調査する．たとえば，「運用開始時に分類対象としていなかったラベルが運用後に必要となり，分類対象を加える必要が生じた場合」

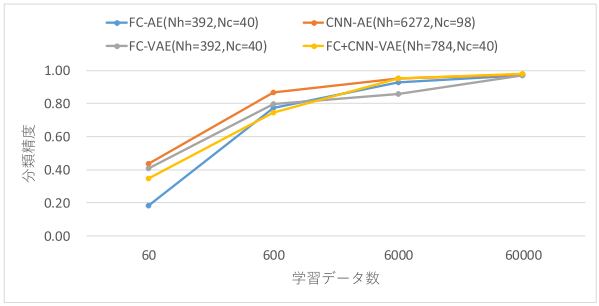

図 21 学習データ数増加時の分類精度の変化
Fig. 21 Classification accuracy versus the number of learning data.

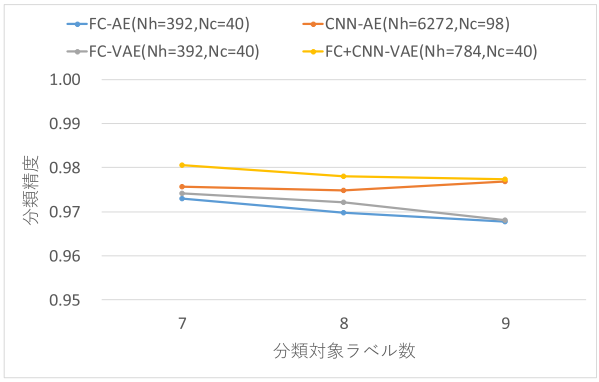

図 22 分類対象ラベル数増加時の分類精度の変化
Fig. 22 Classification accuracy versus the number of classification label.

を想定し，分類ラベルを加えた場合にも精度を維持しつつ分類器の更新が可能であることを確認する．

実験では，MNIST データセットを対象とし，明示的な分類対象データを段階的に増加させた．まず，初期状態として 0〜5 をそれぞれ分類対象とするとともに，6〜9 を一括りに「その他」とした．このときの分類対象数は 7 種類である．また，この初期状態では分類器の学習データには MNIST オリジナルデータを使用した．その後，分類器の更新として，「その他」に分類されていた 6〜9 のデータについて，1 つずつ明示的な分類対象に移動させた．つまり，1 度目の更新では 0〜6 を分類対象とし，7〜9 を「その他」として計 8 種類の分類を行った．また，2 度目の更新では，0〜7 を分類対象とし，8〜9 を「その他」として計 9 種類の分類を行った．1 度目の更新以降，分類器の学習データにはすべて AE 復元データを使用した．また，いずれの場合においても，5.1 節と同様に，テストデータには未知データ 10,000 個を用いた．また，AE の再学習は行わなかった．結果を**図 22** に記す．

図 22 では，分類対象となるラベル数が増加するにともない分類精度が低下してしまう傾向にある．しかしながら，その低下はいずれの分類器においても 0.01 に満たない．また，CNN-AE においては 7 ラベル時（初期状態）より 9 ラベル時の方が若干精度の向上が見られる．いずれにおいて

© 2019 Information Processing Society of Japan

も，分類器の更新前後での分類精度はおおよそ同程度であるといえる．よって，分類対象となるラベルを増やし，分類器を更新したとしても，分類器の精度にはほとんど変化がないことが確認できた．このことは，AE 復元データを用いて，もともと分類対象であったラベルのデータだけでなく，追加したラベルのデータについても適切に学習できていることを示している．すなわち，AE の更新を行わずに，AE 復元データを用いて分類対象となるラベル数を増加させたとしても，適切に分類器の更新が可能であることが示された．

5.3 分類ラベルの細分化時による分類精度の変化

次に，提案手法において，分類器を新たに再構築した場合の分類精度を調査する．たとえば「システム運用開始時に構築した分類器について，運用が進むにつれさらに詳細な分類が必要になったため，運用中に得られた AE 復元データを用いてより詳細なラベルに分類可能な分類器の再構築を行う場合」を想定し，異なる観点から分類器を新たに作成した場合でも十分な精度を得ることが可能であることを確認する．

実験にはデータセットとして Fashion-MNIST [*2]（以下，F-MNIST）を使用する．F-MNIST は MNIST と同様のデータ形式で，画像を数字からシャツやズボン，靴，鞄などの衣装の画像に置き換えたものである．F-MNIST では，10 種類のラベルを持つ（後述）．F-MNIST のデータ形式は MNIST と互換性があるため，各 NN の構成は 3 章で示した構成を使用することができる．

実験では，まず画像を服，靴，鞄の 3 種類に分類し，この分類器を生成して分類を行う．その後，より詳細なラベルとして，入力データを T シャツ/トップス，ズボン，プルオーバなど 10 種類に分類することとし，AE 復元データに対して 10 種類のラベルを付与して分類器の再構築を行った．以下，最初の 3 種類の分類ラベル，および，分類器を大分類ラベル，および，大分類器と呼ぶ．また，分類器更新後の 10 種類の細分化されたラベル，および，分類器を小分類ラベル，小分類器と呼ぶ．大分類ラベルと小分類ラベルとの関係性を**表 3** に示す．なお，大分類ラベルは著者らが付与したもので，小分類ラベルは F-MNIST に元々付与されているラベルである．大分類器は F-MNIST オリジナルデータを用いて構築した．また，小分類器は AE 復元データを用いて学習を行った．そして，10,000 個の未知データに対して，大分類器，小分類器の分類精度の評価を行った．さらに，小分類器については，F-MNIST オリジナルデータで学習した場合についても精度の評価を行った．なお，5.1 節，5.2 節と同様，AE の再学習は行わなかった．結果を**図 23** に示す．

[*2] https://github.com/zalandoresearch/fashion-mnist

表 3 大分類ラベルと小分類ラベルの対応
Table 3 Two categorical levels of labels.

大分類ラベル	小分類ラベル
服	T シャツ/トップス
服	ズボン
服	プルオーバー
服	ドレス
服	コート
靴	サンダル
服	シャツ
靴	スニーカー
鞄	バッグ
靴	アンクルブーツ

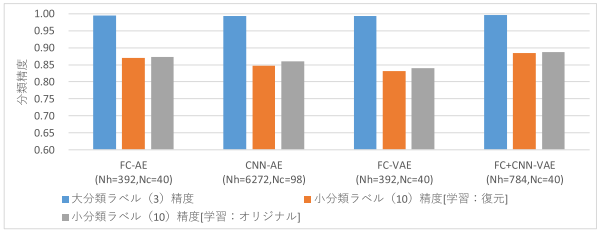

図 23 F-MNIST での分類ラベル細分化時の分類精度の変化
Fig. 23 Classification accuracy changing on the categorical levels of labels using F-MNIST.

図 23 において，大分類器の精度の平均は 0.99 であり，小分類器については AE 復元データを用いた場合の平均は 0.86，オリジナルデータを用いた場合の平均は 0.87 であった．大分類器に比べ，小分類器の分類精度は大きく低下している．しかし，大分類器はクラス数 3 の分類器，小分類器はクラス数 10 の分類器である．一般に，クラス数が多いほど，分類精度は低下することが知られている．一方，小分類器について，学習に AE 復元データとオリジナルデータを用いた場合の比較を行うと，その差はごくわずかである．すなわち，大分類器の分類精度と小分類器（AE 復元データ）の分類精度を比較した場合の分類精度の低下は，分類対象となる問題の複雑さに起因する分類精度の低下であり，学習に使用したデータに起因する分類精度の低下ではないといえる．このことから，提案手法によって，AE 復元データを用い，新たな分類器を作成したとしても，オリジナルデータを用いて作成した場合とほぼ同程度の分類精度を持つ分類器を構築可能であるといえる．以上より，提案手法によって，対象データに対し，異なる観点から新たな分類器を新たに再構築した場合でも十分な分類精度を得ることが可能であることが示された．

6. 考察

6.1 提案手法と既存の圧縮手法の比較

4.5 節の実験結果より，FC-AE，CNN-AE，FC-VAE，

© 2019 Information Processing Society of Japan

FC+CNN-VAE の画像の再現性能はベースライン手法や jpeg 圧縮と同等以上であることが示された．これは，AE が jpeg のような汎用的な画像圧縮手法とは異なり，扱うデータに特化した圧縮手法となっているためであると考えられる．よって，データ群 A，B のデータに対しては，提案手法は少ないデータ量であっても既存の画像圧縮手法と同等以上の再現性能や分類精度を持つと判断できる．そのため，実センサネットワークに搭載した場合でもより少ないデータ量で，データを送信でき，電池の長寿命化や通信コスト削減が期待できる．

一方で，AE の性質上学習データと大きくかけ離れたデータ群 C のデータが入力されたときには，サーバで画像を復元しても誤差が非常に大きく，十分な復元画像を得られなくなる．実際のセンサネットワークを運用した場合を想定すると，通常の状態では，1 つの生成確率分布により生成されたデータが入力されているが，さまざまな原因により突発的に確率分布を逸脱したデータが入力される場合もときには発生すると考えられる．そのため，実運用するうえでは，データの分布の変化を検出し，十分に復元できない状態になった場合に一般的な jpeg のような圧縮手法に切り替える，といった仕組みを合わせて運用する必要がある．

提案手法は，センサノードで識別の前処理である特徴抽出を行い，サーバで分類器を用いた状況の識別およびユーザの追加ラベリングによる分類器の更新を行う．そのため，特に多数のセンサノードから同時にデータを収集するような状況において，サーバの計算負荷の軽減が期待できる．一方で，データの圧縮という観点からは，データの再現性を考慮して圧縮を行っている．このため再ラベリングを考慮に入れず，圧縮のみに特化した手法や，固定の分類器に特化してチューニングした手法には，圧縮性能や分類性能で劣る可能性がある．

6.2 他圧縮・分類手法への適応

本論文では，画像センサを例として提案手法の有効性を調査したが，AE は画像センサに限られたモデルではない．そのため，温度や湿度といった単純なセンサデータ，加速度やジャイロのようなモーションセンサデータ，音声データなども同じ枠組みで扱うことができる．さらにこれらを複合的に扱いマルチモーダルセンサデータから識別を行うことも可能である．

また，本提案手法は圧縮手法や分類器の種類を限定したものではない．本論文中では圧縮手法と分類手法の親和性や対象とするセンサを考え，AE と NN による分類器を使用した．しかし，使用するセンサやデータの形式によって，適切な分類器や圧縮手法は異なると考えられる．本提案手法はさまざまな分類器や圧縮手法に対応可能である．

さらに圧縮器，復元器，分類器の配置に関しても，同様である．本論文で提案したセンサノード・センタ間の通信モデルでは，センサノードに圧縮器，センタに復元器と分類器を配置し，圧縮・復元器と分類器を別々に学習したものだった．しかし，圧縮・復元器，分類器を，どのようにセンサノードとセンタに各々配置するか，また，どのように各々を構成し学習させるかにより，さまざまなバリエーションが考えられる．たとえば，分類器をセンサノード側に配置することにより，センタ側で圧縮データと分類ラベルを同時に受け取ることができれば，圧縮データを復元する際に，分類ラベルの条件付き復元器にすることができる．また，分類器をセンタ側に配置する場合では，復元データから分類を行うことも考えられる．配置の問題と同様に，センサノードとセンタは 1 対 1 でなくてもよい．多数のセンサノードがセンタに情報を集約するようなセンサネットワークでも，提案手法を使用できる．たとえば，センタに存在する分類器が，複数センサノードからの圧縮データを用いて分類を行うような場合である．以上のように，使用目的や使用環境からの要請に応じて，さまざまな構成がありうる．しかし，現実的には，実際の各計算リソースを考慮して各機能を配置する必要がある．

本論文では，単純グレースケール画像（MNIST）による実験結果を報告した．提案手法で用いた AE および VAE は画像の再現誤差を小さくするように学習するが，全体的な誤差を小さくするため，細部を詳細に再現せず，全体的にぼやけた画像が復元され，細部の認識が難しい場合がある．固定的な背景の中に限られた種類の物体が出現するような定点カメラにおいては，今回調査した手法でも対応可能だと考えているが，背景も識別対象の物体もバリエーションに富んだ自然環境の画像を処理した際の性能は不明であり，今後検討を進める予定である．

このように使用するセンサの種類やデータによって最適な圧縮（特徴量抽出）方法，分類器は異なると考えられる．そのため，今後，さまざまな種類のデータに対してそれぞれ適したデータ処理方法を検討し，提案手法の適用範囲を広げていきたいと考えている．たとえば，細部がぼやけると人が目で見ても識別ができなくなるような画像を扱う際には，細部の復元を重視するような圧縮手法を用いる，といった方法が考えられる．

6.3 復元データを用いた分類器更新

5 章で，実際のシステム運用時に想定される問題に対し，提案手法が有用であることを示すことを目的として実験を行った．実験では，想定される状況として，学習データを追加で得ることができた場合（5.1 節），分類対象となるラベルが増加した場合（5.2 節），識別対象に対して異なる観点からラベル付けを行い分類器の再構築をする場合（5.3 節）を設定した．これらの実験結果から，提案手法によって得られる AE 復元データを用いて，適切な分類器の更新が可能であることが分かった．

© 2019 Information Processing Society of Japan

7. まとめ

本研究では，AE を使用した通信量の削減と AE 中間層からの分類を同時に行うことにより，分類モデルの再学習が容易なセンサノード・センタ間通信モデルの提案とその評価を行った．提案手法では，先行研究で行われているセンサネットワークモデルの省電力化などの技術と比較し，センサネットワークの使用者のニーズの変化に対応した分類モデルの再学習が可能である点が優れている．

さらに本研究では，画像センサの使用を想定して MNIST データセットを使用し，4 種類の AE の構築モデルについて調査を行い，それぞれの比較を行った．その後，既存手法との比較を行った．既存手法には，AE を使用した場合におけるベースライン手法，可逆圧縮手法，不可逆圧縮手法の計 5 種の手法を想定した．実験結果より，提案手法では，4 種類の AE では通信を行うデータの符号化率において FC+CNN-VAE が優れ，再現性能と分類精度，汎化性能において CNN-AE が優れていた．また，4 種類の AE は既存手法と比較し，再現性能と分類精度は同等であることが分かった．これより，提案手法はベースライン手法と同等の働きができるといえる．最後に，使用するラベル数を変化させた場合の分類精度の変化を調査し，使用ラベル数が増加した場合でも分類器のみの再学習で，分類精度が変化しないことを示した．また，MNIST と F-MNIST を使用し，実際の運用時に想定されるような分類器の更新状況を想定し実験を行い，分類器の更新が可能であることを示した．以上の実験結果より，本論文の提案手法は画像センサを使用した場合のセンサネットワークにおいて，データの圧縮と分類を同時に行うことができ，使用するラベルの変化にも対応できることを示した．

本論文では，画像センサを想定した MNIST を用いた実験結果についてのみ報告したが，実際のセンサネットワークにおいては，気温や湿度のような単純なセンサデータ，音声などさまざまな種類のセンサデータが存在しうる．また，6 章で述べたように本論文で提案した以外の構成による通信方式もありうる．今後，このような実際のセンサネットワークでの実運用を想定した手法の考案や，異なる状況を想定した別の構成による通信方式を検討して提案手法の適用範囲を広げていく予定である．

参考文献

[1] 深津時広：農業分野におけるセンサネットワーク技術の利用と課題，電子情報通信学会誌，Vol.97, No.8, pp.688–694 (2014).

[2] Choochotkaew, S., Yamaguchi, H., Higashino, T., Shibuya, M. and Hasegawa, T.: EdgeCEP: Fully-Distributed Complex Event Processing on IoT Edges, *Proc. International Conference on Distributed Computing in Sensor Systems* (*DCOSS*), pp.121–129 (2017).

[3] Hinton, G.E. and Salakhutdinov, R.R.: Reducing the Dimensionality of Data with Neural Networks, *Science*, Vol.313, No.5786, pp.504–507 (2006).

[4] Gupchup, J., Terzis, A., Burns, R. and Szalay, A.: Model-Based Event Detection in Wireless Sensor Networks, *Proc. Workshop on Data Sharing and Interoperability on the World-Wide Sensor Web* (2008).

[5] Wu, X. and Liu, M.: Insitu Soil Moisture Sensing: Measurement Scheduling and Estimation Using Compressive Sensing, *Proc. ACM/IEEE 11th International Conference on Information Processing in Sensor Networks* (*IPSN*), pp.1–11 (2012).

[6] Keally, M., Zhou, G. and Xing, G.: Watchdog: Confident Event Detection in Heterogeneous Sensor Networks, *Proc. 16th IEEE Real-Time and Embedded Technology and Applications Symposium*, pp.279–288 (2010).

[7] Dutta, P., Grimmer, M., Arora, A., Bibyk, S. and Culler, D.: Design of a Wireless Sensor Network Platform for Detecting Rare, Random, and Ephemeral Events, *Proc. Fourth International Symposium on Information Processing in Sensor Networks* (*IPSN '5*), pp.492–502 (2005).

[8] Kingma, D.P. and Welling, M.: Auto-Encoding Variational Bayes, *Proc. 2nd International Conference on Learning Representations* (*ICLR*) (2014).

[9] 蔵内雄貴，西村拓哉，西田京介，小西宏志，瀬下仁志：ニューラル特徴抽出による省通信センサフュージョン，DICOMO2018 シンポジウム (2018).

[10] Ghifary, M., Kleijn, W.B., Zhang, M., Balduzzi, D. and Li, W.: Deep Reconstruction-Classification Networks for Unsupervised Domain Adaptation, *European Conference on Computer Vision* (*ECCV*) *2016*, Part IV, LNCS 9908, pp.597–613, Springer (2016).

[11] Kulkarni, T.D., Whitney, W., Kohli, P. and Tenenbaum, J.B.: Deep Convolutional Inverse Graphics Network, *Advances in Neural Information Processing Systems* (*NIPS'15*), Vol.28, pp.2539–2547 (2015).

[12] Doersch, C.: Tutorial on Variational Autoencoders, arXiv:1606.05908 [stat.ML] (2016).

[13] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y.: Generative Adversarial Nets, *Advances in Neural Information Processing Systems* (*NIPS'14*), Vol.27, pp.2672–2680 (2014).

[14] Kingma, D.P., Rezende, D.J., Mohamed, S. and Welling, M.: Semi-supervised Learning with Deep Generative Models, *Advances in Neural Information Processing Systems* (*NIPS'14*), Vol.27, pp.3581–3589 (2014).

推薦文

本論文では，センサネットワークで収集された生データをすべてデータセンタに送信することが困難な環境を対象に，将来における再ラベリングを考慮したデータ圧縮方式を提案している．性能評価では，提案手法によりデータ圧縮と再ラベリング時の分類性能維持が両立できることを示しており，センサーセンタ間のネットワーク負荷を軽減できる有用な研究と認められる．

（モバイルコンピューティングとパーベイシブシステム研究会主査　河口信夫）

© 2019 Information Processing Society of Japan

小向 航平 （正会員）

2018年3月豊橋技術科学大学情報・知能工学課程卒業．同年4月同大学大学院博士前期課程進学，在籍中．リハビリを対象とした行動識別やセンサネットワークなどのユビキタスシステムに関する研究に従事．

水谷 伸

1991年大阪大学大学院基礎工学研究科生物工学専攻修士課程修了．同年日本電信電話（株）ヒューマンインタフェース研究所入所．1998年コミュニケーション科学研究所．現在，コミュニケーション科学基礎研究所．博士（理学）．ニューラルネットワーク，非線形系，センサの研究開発に従事．

岸野 泰恵 （正会員）

2002年大阪大学工学部卒業．2004年同大学大学院情報科学研究科博士前期課程修了．2007年同研究科博士後期課程修了，日本電信電話（株）入社．博士（情報科学）．ユビキタスコンピューティング，センサネットワークに関する研究に従事．

柳沢 豊 （正会員）

NTTコミュニケーション科学基礎研究所客員研究員．博士（工学）．1998年大阪大学大学院工学研究科博士後期課程修了．同年日本電信電話（株）に入社，基礎研究所に所属．以後，西日本電信電話（株）勤務を経て，2013年9月より現職．神戸大学大学院工学研究科学術研究員，およびm plus plus（株）CTOを兼務．センサネットワーク，ウェアラブルコンピューティング，プログラミング言語の研究に従事．IEEE会員．

白井 良成 （正会員）

1998年慶應義塾大学環境情報学部卒業．2000年同大学大学院政策・メディア研究科修士課程修了．同年日本電信電話（株）入社．博士（工学）．HCI，センサネットワークの研究に従事．ヒューマンインタフェース学会，日本バーチャルリアリティ学会各会員．

須山 敬之 （正会員）

1992年大阪大学大学院工学研究科機械工学専攻修士課程修了．同年日本電信電話（株）コミュニケーション科学研究所入所．2014年より2017年まで（株）国際電気通信基礎技術研究所出向．現在，日本電信電話（株）コミュニケーション科学基礎研究所主幹研究員．博士（情報学）．ユビキタスコンピューティング，センサネットワークに関する研究に従事．IEEE，ACM，電子情報通信学会各会員．

大村 廉 （正会員）

2004年慶應義塾大学大学院理工学研究科開放環境科学専攻後期博士課程修了．博士（工学）．同年（株）国際電気通信基礎技術研究所研究員．2007年慶應義塾大学理工学部情報工学科助教．2010年豊橋技術科学大学情報・知能工学系講師．2019年より同大学准教授．電気情報通信学会，IEEE，ACM各会員．ユビキタスコンピューティング，ウェアラブルコンピューティング，コンテキストアウェアシステム，センサネットワーク，行動認識技術などの研究に従事．

© 2019 Information Processing Society of Japan

澤田 宏

1991 年京都大学工学部情報工学科卒業．1993 年同大学大学院工学研究科情報工学専攻修士課程修了．2001 年京都大学博士（情報学）．1993 年日本電信電話株式会社（NTT）入社．以来，同社コミュニケーション科学基礎研究所およびサービスエボリューション研究所において，VLSI 設計技術および計算機アーキテクチャ，信号処理技術（音響信号の分離技術），機械学習技術（多次元データ分析技術）の研究に従事．現在，NTT コミュニケーション科学基礎研究所協創情報研究部部長（上席特別研究員）．IEEE Fellow，電子情報通信学会フェロー，日本音響学会会員．

納谷 太

1994 年慶應義塾大学大学院理工学研究科計算機科学専攻修士課程修了．同年日本電信電話（株）コミュニケーション科学研究所入所．2003 年より 2009 年まで（株）国際電気通信基礎技術研究所出向．現在，日本電信電話（株）コミュニケーション科学基礎研究所企画担当主席研究員．博士（工学）．ヒューマン・ロボットインタラクション，センサネットワークによる行動・状況・環境理解，スマートシティにおける都市状況把握・集団最適誘導，テーラーメイド型教育支援環境等の研究開発に従事．

© 2019 Information Processing Society of Japan