

推薦論文

# 被災がれき量推定に向けた畳み込みニューラルネットワークを用いた倒壊建造物の自動抽出

利根川 凜<sup>1,a)</sup> 飯塚 博幸<sup>1,b)</sup> 山本 雅人<sup>1,c)</sup> 古川 正志<sup>2,d)</sup> 大内 東<sup>3,e)</sup>

受付日 2015年8月31日, 採録日 2016年3月4日

**概要:** 津波の被害に代表される大規模な家屋の倒壊が起こる災害時において, 被災状況を把握できずに起きる復旧の遅延が問題となっている. 津波により建造物の倒壊が起こり大量のがれきが発生すると, 早急に輸送手段や仮置き場の位置や数の手配が必要になる. しかしながら, 現状では被災地での被害状況の把握, 被災がれき量の推定について短時間で行う手法は確立されていない. 本研究では, 震災後に撮影される被災地の空撮画像を複数用い, 被災地の地図情報から家屋のある範囲を抽出し, 畳み込みニューラルネットワークによる学習から, 家屋倒壊判別を行う. 結果として, 東日本大震災で被災地となった10地域の空撮画像を利用し, 約86%の正答率を得た. また, 使用地域の中で, テストデータの判別正答率の悪かった地域のみをテストデータに絞った場合でも判別を行い, 前実験の結果と比較して, より多くの地域, および, 条件の画像データを用意すれば, 判別器の正答率が向上する可能性を示した.

**キーワード:** 地震, 被災がれき量推定, 畳み込みニューラルネットワーク

## Detecting Collapsed Buildings using Convolutional Neural Network for Estimating the Disaster Debris Amount

RIN TONEGAWA<sup>1,a)</sup> HIROYUKI IIZUKA<sup>1,b)</sup> MASAHITO YAMAMOTO<sup>1,c)</sup>  
MASASHI FURUKAWA<sup>2,d)</sup> AZUMA OHUCHI<sup>3,e)</sup>

Received: August 31, 2015, Accepted: March 4, 2016

**Abstract:** When a massive earthquake that causes Tsunami happens, it is too difficult to get a full picture of the damages caused by the disaster and it causes the delay to recover from it. The debris generated by Tsunami or broken houses block roads and all transportation for people, rescue supply and bringing debris stop. In order to remove the debris and clear the roads, we need to decide which and how many spaces should be allocated for temporal storages immediately. However, there is no method to estimate the amount of generated debris and to get a full picture of the damage for a short time. This paper proposes a novel method that uses a convolutional neural network to classify images taken by a plane into damage or no-damage automatically. The network is trained with the images of 10 different areas stricken by the Great East Japan Earthquake. Our results shows that the trained network can correctly answer with about 86% and we found that the correct rates changes in response to the extents of the damages in different areas. The possibility to create a better network classifier is discussed in the end.

**Keywords:** earthquake, estimating the disaster debris amount, convolutional neural network

<sup>1</sup> 北海道大学大学院情報科学研究科  
Graduate School of Information Science and Technology,  
Hokkaido University, Sapporo, Hokkaido 060-0814, Japan  
<sup>2</sup> 北海道情報大学  
Hokkaido Information University, Ebetsu, Hokkaido 069-  
8585, Japan  
<sup>3</sup> 東北大学  
Tohoku University, Sendai, Miyagi 980-0845, Japan  
a) tonegawa@complex.ist.hokudai.ac.jp

b) iizuka@complex.ist.hokudai.ac.jp  
c) masahito@complex.ist.hokudai.ac.jp  
d) mack@do-johodai.ac.jp  
e) ohuchi@sendaikankyo.co.jp

本稿の内容は2013年10月の情報処理北海道シンポジウム2013にて報告され, 支部長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.

## 1. はじめに

近年、世界各地で大規模な地震災害、および、津波の被害が報告されている。本来、津波をともなう大規模な家屋倒壊を含む災害時は、被災地の早期復旧のため、発生した災害廃棄物（被災がれき）の処理を迅速に行う必要がある。被災がれき処理には、有効な処理計画立案が必要不可欠である。そのため、発生する被災がれき量の早期把握をもとに処理計画を立案できれば、無駄のない予算組みや運用が可能となり、被災地の早期復旧への貢献が期待できる。

しかしながら、被災地で発生した被災がれき量を迅速に推定する手法は確立していない。東日本大震災では、震災直後に推定された量が、実際の処理量の1.5から2倍という大きな乖離が生じた[1]。この原因は、衛星画像を用いて津波の浸水地域を特定し、浸水地域内の建造物の数で被災がれき量の推定を行ったためである。実際の被災がれき量把握には、震災後にがれきを搬入した量から適宜見直し、実態に近い推定量に置き換える経験的手法を用いた[2]。実際に被災地の震災被害が甚大であるほど、震災直後に得られる情報は乏しいため、被害状況把握は困難となる。そのため、現在、被災地から得られる数少ない情報を活用し、すばやく被害状況を把握する手段の確立が望まれる。

被災がれき量推定を行う際に最も重要とされるデータは、被災地で倒壊した建造物の数や面積である。通常、震災直後の被災がれき量推定には災害廃棄物量推定方法[3]を用いる。災害で建造物が倒壊や焼失した際に、被害面積や戸数と、既知の災害発生原単位を乗じて発生がれき量を算出する。そのため、被災地で倒壊した建造物の数や面積が把握できれば、該当地域で発生した被災がれき量はただちに算出可能となる。

以上の背景から本研究では、被災地から得られる数少ない情報として、震災後ただちに情報の入手が可能な空撮画像に着目する。そのため本稿では、空撮画像を用い、建造物倒壊により発生する災害廃棄物量（被災がれき量）推定のための倒壊建造物の自動抽出手法を検討する。従来の画像認識は、事前に認識対象を判別する特徴量を抽出し、教師あり学習を行うのが一般的である。よって高い認識精度を得るためには、有効な特徴量の設定、および、パラメータチューニングが必要となる。機械学習を利用した先行研究では、被災地上空で撮影された空撮画像による被害推定のため、堆積した被災がれきをトレーニングして学習し、空撮画像内の被災がれきを捕捉できる研究が報告されている[11], [12]。ただし津波等で被災がれき等が流失した場合は適用できない。大規模な災害への対応を視野に入れる際、災害が発生した季節や、被災地の地形や建造物の特性、建造物の壊れ方等、流動的に変化する状況への対応力が肝要となる。そのため、特徴量やパラメータ次第では、ある地域で高精度な判別器の作成ができて、判別器が特定の地域や被害状況

に特化し、他の時期や地域で発生した災害には対応できないリスクが存在する。

本研究では、被災地の空撮画像に対し、近年、物体の画像認識や手書き文字等で高い認識率を誇る畳み込みニューラルネットワークに着目する。畳み込みニューラルネットワークは、畳み込み層、プーリング層を交互に接続した構造を持ち、ネットワーク内で特徴量抽出フィルタを学習する[4], [5]。そのため、対象物の認識を決定付ける有効な特徴量を設計者が定義する必要がない[6]。幅広い災害対応を視野に入れた際、災害が発生した季節や、被災地の地形や建造物の特性、建造物の壊れ方等、多様な状況への対応可能なのは重要な事柄である。よって本研究は、地域や被害状況を多様な状況に対し、あらかじめ様々なサンプルを用い、長い時間をかけて訓練しておけば、様々な状況に対応可能な判別器が期待できる畳み込みニューラルネットワークを採用する。

## 2. 関連研究：情報処理分野からの災害対応

能島らは、地震動情報やフラジリティ関数等を組み合わせた早期被害推定結果を1次情報、リモートセンシング等で把握される情報を2次情報、実際に被災地への立入り調査で得られる情報を3次情報とおき、被害情報を逐次更新するシステムを提案している[9]。しかしながら、3次情報は被害が広域になるにつれ、被害情報の収集、および、確認に多大な時間と人手が必要となる。そこで、空撮画像やハザード情報を活用し、被害状況をリモートセンシングから高精度に被害を把握すれば、復旧への意思決定が3次情報を待たずに可能となる。本研究では、空撮画像の解析、すなわち2次情報の段階で、自動かつ高精度な被害状況の推定手法を提案する。2次情報を使用した被害推定の関連研究として、平山らは、被災地地理情報システムから津波浸水域を同定し、津波浸水による住家被害テーブルを用いた災害廃棄物量の推定を提案している[10]。式(1)の災害廃棄物推定方法に示すように、被災がれき量 $W_D$ は、過去の災害調査より得られる既知の災害発生原単位 $C_i$ と、対応する被害面積や倒壊戸数 $N_i$ を掛け合わせた総和で推定する。 $i$ は災害の区分が倒壊や焼失、建造物の建築材料等で異なる。たとえば、木造一般家屋が倒壊した場合、災害発生原単位は $0.62[t/m^2]$ である[1]。すなわち、倒壊面積が分かれば、各建造物に対応する災害発生原単位と組み合わせ、被災がれき量算出が可能となる。

$$W_D = \sum_i C_i N_i \quad (1)$$

災害廃棄物量推定方法を効果的に行うには、被災地の被害面積や倒壊戸数の正確かつ迅速な捕捉が必要である。ただし、各地域の詳細な津波浸水情報、および、浸水深に対応した被害情報把握には、津波再現計算や浸水深調査が必

要で、詳細な被害状況の推定や広域な被害になるほど、短時間での被害推定が困難となる。

そこで本研究では、短時間でより正確な倒壊建造物の推定を目指す。具体的には、地震が起こるたび、最終的に行われた実際の被害状況から判別器を学習させ、様々な被害状況に対応可能、かつ、精度の良く、建造物ごとに倒壊の有無を判別可能とする手法を提案する。

### 3. 畳み込みニューラルネットワーク

畳み込みニューラルネットワークは、多層パーセプトロン的一种であり、入力層と出力層の間に複数の畳み込み層とプーリング層を交互に並べた多層のニューラルネットワークである。一般的に多層パーセプトロンのニューロンは、1つ前の層のニューロンと全結合しているが、畳み込みニューラルネットワークでは、中間層（畳み込み層とプーリング層）は1つ前の層のニューロンの一部の領域に結合する。この一部の領域を局所受容野と呼ぶ。出力では、ソフトマックス層を使用して、出力層の出力総和を1とし、1つの回答を出力する。最終的に出力層のニューロンに分類するクラスを割り当て、最も大きい出力のニューロンが分類結果となる。

#### 3.1 畳み込み層

畳み込み層は局所受容野にフィルタと呼ばれる重みを持つ。畳み込み層のニューロンの出力は、入力画像に対して位置を変えながらフィルタを走査し、畳み込み計算した結果となる。フィルタの重みは入力画像の位置によって変化しない。

具体的な表記のため、フィルタのサイズを横サイズ × 縦サイズ × チャンネルが  $m_w \times m_h \times N$ 、入力画像に対するフィルタの位置を  $(i, j)$  とし、畳み込み層に入力するチャンネルを  $c$ 、畳み込み層から出力するチャンネルを  $l$  とする。また、畳み込み層への入力を  $x_{ij}$ 、畳み込み層のある1つのチャンネルの出力を  $y_{ijcl}$ 、フィルタの重みを  $W_{ijcl}$ 、出力にあたって使用するバイアスを  $b_l$  で表す。畳み込み層の出力は式 (2)、(3) で計算される。式 (3) は活性化関数であり、次の層に与える出力に変換する。

$$y'_{ijl} = \sum_{c=1}^N \left[ \sum_{p=1}^{m_w} \sum_{q=1}^{m_h} x_{(i+p)(j+q)c} W_{pqcl} \right] + b_l \quad (2)$$

$$y_{ijl} = \tanh(y'_{ijl}) \quad (3)$$

なお本稿では、事前の予備実験により、 $\tanh$  と ReLU の比較実験を行っており、より高い正答率であった  $\tanh$  を使用した。なお、他の活性化関数としてあげられる sigmoid は LeCun ら [7] や Glorot ら [8] が提唱している活性化関数は原点を通すべきという理由から実験を行っていない。また、使用画像の色情報をチャンネル別に扱う。すなわち、RGB で表現されるカラー画像は3チャンネル、グレースケール画

像は1チャンネルである。

#### 3.2 プーリング層

プーリング層は畳み込み層と同様に局所受容野を持つが、重みを持たない。また、プーリング層では、畳み込み層で出力された画像の解像度を下げ、入力画像間の微小な差に対する応答の普遍性を実現する。受容野内の情報を一部捨て、データの中に表れる特徴の微小な位置変化を吸収し、大まかな特徴のみを残す。プーリング層の出力のチャンネル数は、1つ前に配置されている畳み込み層のチャンネル数と同じである。そして、畳み込み層で出力された信号は、プーリング層へ入力信号となる際、同じチャンネルを用いる。

局所受容野のフィルタのサイズを  $F_w \times F_h$ 、あるチャンネルの入力データのサイズが  $M_w \times M_h$  で表されるとき、走査する局所受容野の位置は  $(i, j) \in \{1, \dots, M_w - F_w\} \times \{1, \dots, M_h - F_h\}$  になる。この局所受容野に入力される入力層（畳み込み層の出力層）の一部の小領域  $P_{ij}$  に含まれる  $y_{pq}((p, q) \in \{i, \dots, i + F_w\} \times \{j, \dots, j + F_h\})$  をある1つの出力  $\tilde{y}_{ij}$  へと集約する。 $P_{ij}$  の出力をまとめて1つの値に集約する方法として、本研究では式 (4) に示す、 $P_{ij}$  に属するユニット出力の最大値を選ぶ最大プーリングを使用した。

$$\tilde{y}_{ij} = \max_{(p,q) \in P_{ij}} (y_{pq}) \quad (4)$$

#### 3.3 全結合層とソフトマックス層

畳み込みニューラルネットワークの出力層付近では全結合層を配置する。全結合層は、各ノードの結合重みから、プーリング層で得られた特徴をもとに、画像の判別を行う。ソフトマックス層は、多クラス分類では、ソフトマックス層には分類する数と同じだけのニューロンを使用する。入力信号を  $n$  種類に分類するとき、入力を  $x_i (i = 1, 2, \dots, n)$  とするとソフトマックス層の出力  $y_i$  は式 (5) となる。本研究では、建造物の倒壊、または、非倒壊の2クラス分類を行うため、シグモイド関数により分類する。

$$y_i = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (5)$$

#### 3.4 重みの更新

出力を得る適切な重みを学習するために、出力誤差を小さくする手法として、一般的な勾配降下法を使用する。

また、重みの更新は、各バッチの画像入力後、実際の被害情報（倒壊、または、非倒壊）の方にシグモイド値を近づける。momentum 項の導入や weight decay に関しては、予備実験によりどちらも後に示す実験条件にて導入を行ったが、有意な差が見られなかったため、以降の実験結果では導入していない結果を表示する。

誤差関数として式 (6) を使用し、重みの更新は式 (7) で計

算される．ただし， $x$  は入力， $y$  は出力， $w$  は重みである．

$$\mathcal{L}(w) = -\sum_{i=0}^n \ln(P(Y = y_i | x_i)) \quad (6)$$

$$w_{s+1} = w_s - \eta \frac{\partial E(w_s)}{\partial w_s} \quad (7)$$

ただし， $P(Y = y_i | x_i) = \frac{e^{x_i}}{\sum_{i=0}^n e^{x_i}}$  である．

#### 4. 建造物の倒壊判別の流れ

本研究では，震災前後の被災地航空写真，および，被災地建造物の大きさと位置を参照可能な地図データを利用し，以下に示す手法により，建造物の倒壊判別を行う．

- (1) 画像データ取得
- (2) 航空写真内の注目建造物のトリミング
- (3) 畳み込みニューラルネットワークによる判別

##### 4.1 被災地空撮画像内の建造物のトリミング

本研究で使用する空撮画像内の建造物は，同一地域に対し作成された GIS データ上の同位置に該当建造物が存在する．GIS データは建造物の位置と大きさを参照できるため，被災地の建造物について一戸ずつ注目し，被災地航空写真上で同一座標の位置，および，大きさで切り出せば，注目建造物のトリミングが可能となる．本稿では，トリミングする建造物周辺に土砂等が堆積する可能性を考慮し，GIS データ上の建造物の幅と高さに対して 15 px ずつの余白を儲けてトリミングを行った．

##### 4.2 使用空撮画像

本研究では，実際の東日本大震災の被災地空撮画像を利用する．利用する画像データはいずれも，東日本大震災の後に撮影された空撮画像である．図 1 で，本稿が利用する東日本大震災被災地の空撮画像の市町村と，空撮画像内の実際の被害区分調査結果の内訳を示す．空撮画像はいずれも，東日本大震災後（2011 年 5 月から 2012 年 4 月）に撮影された，日本国土地理院の公開空撮画像を用いる．空撮画像はいずれも，各市町村の地域の一部である．また，対応する GIS データは，東日本大震災復興支援調査アーカイブの建造物の被災地域のデータを用いる [13]．

左ほど倒壊の建造物の割合が高く，右に行くほど非倒壊の建造物の割合が高い．図 2 は実際に使用した空撮画像である．左から順に，岩手県陸前高田市，岩手県野田村，青森県八戸市のある地域の空撮画像である．なお，画像内地域の詳細な位置と建造物の被害区分の分布は，個人情報保



図 2 使用空撮画像の例（左から，建造物がほぼ倒壊，倒壊と非倒壊が混在，ほぼ非倒壊の地域）

Fig. 2 Examples of the aerial photographs in 3 different classes of damages.

護の観点から省略する．

空撮画像，GIS データの縮尺はいずれも 1,750 分の 1 であり，空撮画像は日本国土地理院 [13] から提供されている．地図データは，東日本大震災復興支援調査アーカイブ [14] の位置や形状情報を利用する．また，画像の撮影時期はいずれも 2011 年 5 月から 2012 年 4 月に撮影された写真を利用する．以上の情報は，本研究で扱う全地域の空撮画像において共通である．現在，震災後数年経った空撮画像の入手は可能であるが，可能な限り東日本大震災発生に近いデータを使用する．これは，土砂や汚泥といった特徴量となりうる情報を画像内に映り込ませ，震災後時間が経過して行われる整地や建て替え工事等の倒壊建造物抽出と関係ない情報が入る余地を排除するねらいがある．

##### 4.3 被害レベルの定義

用意した建造物データを用いて判別器を訓練，または，テストするには，各建造物に紐づいた被害の把握が必要となる．被災地の建造物の被害区分については，東日本大震災復興支援調査アーカイブの公開するデータを利用する．このデータは，現地調査に基づき，被災した建造物を，以下の 7 区分に分類している．なお，被害の重篤度は上に行くほど高い．

- (1) 全壊
  - (a) 全壊（流失）

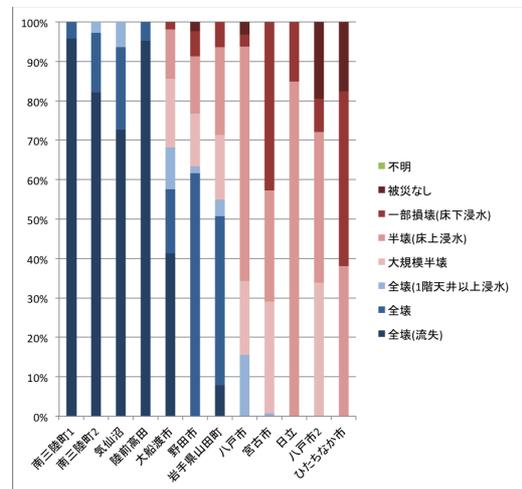


図 1 使用空撮画像の対象建造物被災区分

Fig. 1 Rates of damages classified into 8 classes in 12 different areas where the aerial photographs used in this paper are taken.

表 1 各空撮画像の撮影地域内の倒壊、および、非倒壊建造物のそれぞれの数

Table 1 Number of collapsed and not-collapsed houses in each area.

type	collapsed	notcollapsed
Minamisanriku	117	0
Minamisanriku2	73	0
Kesennuma	95	0
Rikuzentakata	166	0
Ofunato	109	51
Noda	109	63
Yamada	77	63
Hachinohe	10	54
Miyako	1	130
Hitachi	0	99
Hatinohe2	0	118
Hitachinaka	0	142

(b) 全壊

(c) 全壊 (1 階天井以上浸水)

(2) 大規模半壊

(3) 半壊

(4) 一部損壊

(5) 被害なし

(6) 不明

区分の判定は原則目視調査により判定しており、罹災証明と必ずしも一致していない。なお、全壊や大規模半壊、半壊の定義の違いとしては、全壊は建造物とその居住のための基本的機能を喪失したもの、すなわち、建造物全体が倒壊・流失・埋没・焼失したか、建造物の損壊がはなはだしく、補修により元どおりの再使用が困難なものを指す。大規模半壊以下の被害区分は、居住のための基本的機能を部分的に喪失したものを指す。すなわち、区分で建造物の損壊の程度に差はあるが、補修すれば再使用が可能な建造物を指す。また被害区分の差は、損壊部分の延床面積、および、建造物の主要な構成要素の経済的被害を元に区別される。最後に、被災なしに区分される建造物は、被災地に対象建造物が存在するが、先述の損壊が認められなかったものである。

本稿では建造物を大きく倒壊と非倒壊の 2 分類にする。区分けの基準は、該当建造物が修復可能かに焦点を当てる。そのため、全壊と区分された建造物を倒壊と扱い、それ以外の被害区分を非倒壊とする。各地域における倒壊と非倒壊の内訳を表 1 に示す。そのため、本稿で倒壊と定義し、判別した画像は、実際の被害区分では全壊で、確実にがれきを発生させる建造物である。

## 5. 数値計算実験：畳み込みニューラルネットワークの適用

### 5.1 実験条件

前節の図 1 に示す被災区分どおり、空撮画像の地域は、建造物が著しく倒壊した地域、倒壊建造物と非倒壊建造物がいずれも混在する地域、建造物に被害はあったが修復等が可能であった地域に大別される。

#### 5.1.1 入力画像

倒壊と非倒壊の例について、出力値のバランスの偏りをなくした学習を行うため、訓練データに用いる画像は、倒壊と非倒壊を同数に調整する。出力値のバランスの偏りをなくす具体的アプローチとして、学習訓練データ 1 バッチに、倒壊と非倒壊の例を同数存在させる。ただし、扱うのが実データである都合上、倒壊と非倒壊の建造物の数が完全に同数の地域を用意するのは困難である。そこで、倒壊と非倒壊の訓練データ画像の用意にあたり、データ数の少ない方に数を揃える。また、余剰となる画像は排除するが、訓練データ、テストデータいずれにも使用しない。排除される画像はランダムに決定する。使用画像が少ないために陥る過学習を避けるため、訓練データには上下左右反転の処理を行い、擬似的に画像を増加させた。テストデータとして使用する画像の数は、倒壊と非倒壊の建造物が混在する地域の建造物の総数と合わせる。テストデータは元画像のみを使用し、反転等の処理でデータ数は増加させない。

本実験は、訓練データ数を 3,696 件 (倒壊 1,848 件、非倒壊 1,848 件)、テストデータを 472 件 (倒壊 295 件、非倒壊 177 件) と設定する。ただし、テストデータは、4 節で示した全地域の空撮画像から、倒壊 295 件、非倒壊 177 件となるよう画像をランダムに抽出する。なお、テストデータに選ばれた画像は、訓練データにはいっさい使用しない。

#### 5.1.2 ネットワークの設計

本研究で使用するネットワークは、予備実験により決定した以下の 8 層で構成する。また、畳み込みニューラルネットワークの構築には theano ライブラリを利用した [15], [16]. 畳み込み層を  $C1, C2$ , プーリング層を  $P1, P2$ , 全結合層  $N1, N2$  とし,  $C1, P1, C2, P2, N1, N2$  の順に配置する。具体的なパラメータを表 2 に示す。また、入力はグレースケール画像、または、カラー画像いずれかを入力信号とする。そのため、どちらを入力するかで表 2 に示す画像のチャンネル数とフィルタサイズが異なる。グレースケール画像の場合チャンネル数が 1、カラー画像の場合はチャンネル数が 3 である。また、バッチサイズ 4、学習率 0.01 とする。バッチサイズの決定には、重みの更新時間を考慮に入れた。通常、バッチサイズが大きくなると、重みの更新に時間がかかる。そのため、重み更新時間を短くするには、可能な限りミニマルなバッチサイズが望ましい。倒壊と非倒壊の画像を同バッチ内に同数存在させたいため、最小単

表 2 畳み込みニューラルネットワークの仕様

Table 2 Structure and sizes of convolutional neural network.

	width × height × channel	filter size
input	180 × 192 × 1 or 3	—
C1	176 × 188 × 10	5 × 5 × 1 or 3
P1	88 × 94 × 10	2 × 2 × 1
C2	84 × 90 × 20	5 × 5 × 1
P2	28 × 30 × 20	3 × 3 × 1
N1	1 × 1 × 100	—
N2	1 × 1 × 2	—
softmax	1 × 1 × 2	—

位はバッチサイズ2となる。ただし、おなじ“倒壊”、または、“非倒壊”でも実際の被害区分が様々であるため、1つのバッチ内に被害区分のバリエーションを持たせることを期待し、バッチサイズを4に決定した。

また、畳み込みニューラルネットワークの利点は学習に際し特徴量の選定やパラメータ設定が必要のない点である。学習率といった畳み込みニューラルネットワーク自身のハイパーパラメータの選定に関しては、予備実験にて決定した。訓練データ数を  $N_{train}$  とし、バッチサイズを  $b_s$  とすると、全訓練データの入力に対し重みの更新が行われる回数は  $N_{train}/b_s$  回である。本稿では、全訓練データの入力にあたり、 $N_{train}/b_s$  回重みが更新された後、テストデータを入力し、正答率を算出する。この際、用意したテストデータでの正答率を算出するほか、学習に用いる訓練データについてもテストする。これを1エポックとし、10エポック行う。学習停止のエポックを決定する際、事前に予備実験として、本稿で扱う訓練データで重みを更新し、訓練データを便宜上のテストデータとして学習の収束を観測した。その結果、10エポック程度で正答率の収束が確認されている。また、訓練データをバッチ分けする際は、バッチサイズ4のうち、倒壊と非倒壊のデータが同数の2ずつ配置される。全訓練データを入力して重みを更新後、テストデータ、および、訓練データを入力し、正答率をそれぞれ算出する。

## 5.2 実験結果

各地域での10エポックまでの正答率の推移を図3に示す。図3は、横軸は各エポック回数、縦軸は、color-test、および、grayscale-testは、テストデータ入力時の正答率である。また、color-validation、および、grayscale-validationは、訓練データセットに対する正答率である。よって縦軸が100%に近づくほど、正解が多い結果となる。

グレースケール画像を入力した際は、全テストデータ472件中、398件正解し、正答率は84%となった。また、カラー画像を入力とした場合は、全テストデータ472件中、411件正解し、正答率は86%となった。訓練データ、およ

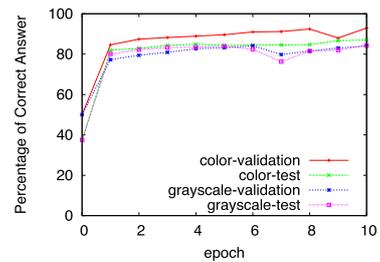


図 3 全地域からランダムにテストデータを作成した際の学習の推移  
Fig. 3 Percentages of correct answers during learning.

び、テストデータは、入力信号の色情報によらず、同一のデータを使用する。そのため、カラー画像は訓練、および、判別の際に画像内の色情報を利用できる点以外、グレースケール画像を入力信号としたときの差異はない。ただし、最も良かった正答率以外でカラー画像とグレースケール画像を入力した際の違いを確認すると、grayscale-validationでは、エポック1は77%、エポック2は79%であり、エポック7周辺を見てみると、エポック6が84%、エポック7が80%、エポック8が82%であり、正答率が一時的に下がっている。一方で、grayscale-testでは、エポック1は80%、エポック2は82%であり、エポック7周辺のエポック6が82%、エポック7が76%、エポック8が82%であり、急激に正答率が下がっている。以上の事象から、判別にあたり、色情報を利用した方が高精度な判別器といえる。

以降に判別器の正答率や判別に失敗した例を議論する際は、原則としてカラー画像を入力信号とした場合を前提とする。

図3のエポック1と9を比較すると、color-validationの正答率が下がっているように見える。しかしながら、エポック1は85%、エポック2が87%という推移に対し、エポック8が92%、エポック9が87%、エポック10が93%であるため、落差からエポック1よりも悪く見えるが、正答率自体は悪化していない。また、正答率が途中で低くなる原因として、ミニバッチによる訓練を行う最中、重みの更新によって判別器の出す回答に変化が起こり、似た画像がまとめて正解から不正解に転じることで生じうる。

次に、カラー画像で最も正答率の高い際の、判別失敗例について考察する。判別に失敗した61件の内訳は、倒壊建造物を非倒壊と判別する例が30件、非倒壊建造物を倒壊と判別する例が31件であった。それぞれの判別失敗例が、どの地域の画像であるかを表3に示す。また、括弧内は各地域のテストデータに含まれている画像の数である。各地域を建造物が著しく倒壊した地域、倒壊建造物と非倒壊建造物が混在する地域、建造物に被害はあったものの修復等が可能であった地域に大別した際に、倒壊建造物と非倒壊建造物がいずれも混在する3つの地域で、その他の地域より判別の失敗が多い傾向がある。ただし、倒壊建造物と非倒壊建造物がいずれも混在する3つの地域で、テストデー



図 4 使用空撮画像の例 (左から, 大船渡市, 野田村, 山田町)

Fig. 4 Examples of the aerial photographs of Ofunato (left), Noda (center) and Yamada (right) areas.

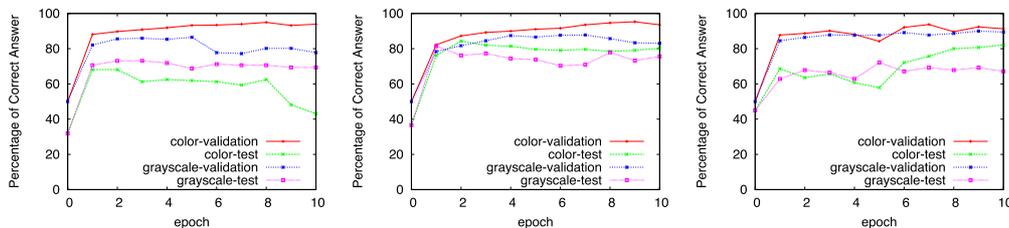


図 5 1 地域をテストデータと定義した際の正答率の推移 (左から, 大船渡市, 野田村, 山田町)

Fig. 5 Percentage of correct answers by networks trained with different training and evaluated with Ofunato, Noda and Yamada test data from the left.

表 3 各地域から選出されたのテストデータ数, および, 判別失敗数  
Table 3 Number of wrong answers and test data in each area.

Area	Num of Collapsed Error num (Test num)	Num of Not-Collapsed (Test num)
Minamisanriku	1 (50)	0 (0)
Minamisanriku2	0 (22)	0 (0)
Kesennuma	0 (36)	0 (0)
Rikuzentakata	10 (72)	0 (0)
Ofunato	8 (40)	4 (11)
Noda	8 (46)	5 (18)
Yamada	1 (26)	9 (17)
Hachinohe	2 (3)	3 (14)
Miyako	0 (0)	0 (22)
Hitachi	0 (0)	0 (28)
Hatinohe2	0 (0)	8 (31)
Hitachinaka	0 (0)	2 (36)
Total	30 (295)	31 (177)

タに選ばれた数から正答率を算出すると, 大船渡市 75%, 野田市 80%, 山田市 77%と大きな差がない. すなわち, 倒壊建造物と非倒壊建造物がいずれも混在する 3 地域は, 他の地域と比較して判別が困難な地域である.

## 6. 数値計算実験: 倒壊判別が高難度の地域の判別

### 6.1 実験条件

全地域からランダムにテストデータを抽出し, それ以外を訓練データとして判別器の学習を行った. 結果, 倒壊建造物と非倒壊建造物が混在する 3 つの地域から選ばれたテストデータが, 他地域より正答率が低い傾向が見られた.

表 4 1 地域をテストデータと定義した際の訓練データ, および, テストデータの数  
Table 4 Number of training data, and test data.

Area	Num of Test Data (Collapsed houses, not-collapsed houses)	Num of Training Data (Collapsed houses, not-collapsed houses)
Ofunato City	160 (109, 51)	5,184 (2,592, 2,592)
Noda Village	172 (109, 63)	5,184 (2,592, 2,592)
Yamada Town	140 (77, 63)	5,176 (2,588, 2,588)

本節では, 全地域からテストデータを無作為に選んだ際, 他より正答率の低かった倒壊建造物と非倒壊建造物がいずれも混在する地域に着目する. テストデータとして利用する地域の使用空撮画像を図 4 に示す. 3 つのうち, テストデータとして選ばれた地域以外は, すべて訓練データとして利用する. ただし, 訓練データは倒壊と非倒壊を同数とし, データ数の少ない方に合わせる. 畳み込みニューラルネットワークの設定は表 2 に示す. 数合わせの際に余剰となる画像はランダムに決定し, 訓練データ, テストデータいずれにも使用しない. 前実験と同様, 訓練データには上下左右反転の処理を行い, テストデータは元画像のみ使用する. また, テストデータに選ばれた画像は訓練データにはいっさい使用しない. 表 4 に, 以上の設定における訓練データとテストデータの数, および, 内訳を示す. 括弧内は倒壊, 非倒壊の建造物の内訳の数である.

### 6.2 実験結果

図 5 に各地域の正答率の推移, 表 5 に各地域の最も高い正答率を示す. 前実験と同様, カラー画像使用の方が正答率が高い傾向がある. グレースケール画像入力との差は, 訓練, および, テストの際に画像内の色情報を利用可

表 6 各地域をテストデータにした際の被害区分内訳

Table 6 Advanced disaster classification of test data in each area.

Hazard Type	Collapsed (washed away)	Collapsed	Collapsed (inundation)	Partially Collapsed (more serious)	Partially Collapsed	Some Damaged	No Damaged	Total
Ofunato	7 (66)	11 (26)	10 (17)	13 (28)	9 (20)	1 (3)	0 (0)	51 (160)
Noda	0 (0)	13 (103)	1 (3)	7 (23)	4 (25)	2 (11)	0 (4)	27 (172)
Yamada	0 (11)	6 (60)	2 (6)	5 (23)	10 (31)	2 (9)	0 (0)	25 (140)

表 5 各地域をテストデータとした際の最も良かった正答率

Table 5 Best percentage of correct answers in each area.

Area	Grayscale (%)	Color (%)
Ofunato City	73	68
Noda Village	81	84
Yamada Town	72	82



図 6 各被災区分の判別失敗例

Fig. 6 Example of incorrect answers in disaster classification.

能な点のみである。よってテストデータがある地域に限定しても、土砂や建築物流失でむき出しになった地表や、建築物の屋根等の色情報は判別に重要な要素といえる。ただし、入力画像がカラー、グレースケールの場合いずれの場合も、大船渡市の正答率が他 2 地域と比較して低い。大船渡市以外の 2 地域については、カラー画像を用いれば正答率 80%以上となる。

大船渡市では、エポック 1 の際の正答率は 82%、エポック 2 は 86%であり、学習中盤のエポック 5 が 86%、エポック 6 が 78%、エポック 7 が 77%、エポック 8 が 80%であり、エポック 5, 6 で大きく正答率が下がっている。この際、同じく大船渡市の grayscale-test の正答率を見ると、エポック 1 の際の正答率は 71%、エポック 2 は 73%であり、エポック 5 が 69%、エポック 6 が 71%、エポック 7 が 71%、エポック 8 が 71%と、ほぼ同じような挙動を示している。

この理由として、ミニバッチによる訓練を行う最中、重みの更新によって判別器の出す回答に変化が起り、似た画像がまとめて正解から不正解に転じた結果であるといえる。

図 6 はカラー画像を入力した際に、失敗した画像例を 3 地域からランダムに抽出した図である。全壊（流失）のほぼすべて、および、全壊に区分される画像の大部分に関しては、津波被害や揺れ等により建築物の痕跡がほぼ土砂や汚泥になっている例がほぼすべてを占める。一方で、全壊（一階天井以上浸水）の建築物に関しては、屋内に大規模な浸水が認められ、建築物としての機能を失い全壊に区分さ

れている建築物であるため、屋根を基準に考えると屋根が残っている。そのため、全壊（一階天井以上浸水）と大規模半壊の空撮画像上の違いは、筆者らが見比べても判別が難しい。また、半壊、一部損壊、被害なしの建築物に関しては、空撮画像上ではほぼ建築物が完全に無事であるように推察される例が大半であった。

表 6 はカラー画像入力時に各地域をテストデータに設定した際の、実際の被害区分、および、判別失敗数である。括弧内は、各被害区分のテストデータ数である。大船渡市の倒壊の建築物が、判別器では非倒壊され、判別失敗となる例が他の 2 地域よりも多い。大船渡市のカラー画像をテストデータにすると、重みの更新後に訓練データでテストしたときの判別正答率は向上しても、テストデータを入力した際は判別正答率がかわらない\*1。すなわち、大船渡市の画像をテストデータにする際は、訓練データから学習された特徴量がテストデータ判別に有効でない。ただし、5 章の実験で大船渡市から抽出されたテストデータが判別に失敗した割合は、現在比較対象である野田村、および、山田町と比べて大きく劣らない。以上の点の原因については、考察で論じる。

## 7. 考察

全地域からテストデータをランダム抽出した際には、倒壊と非倒壊の建築物が混在する 3 地域が、他と比較して正答率が低かった。ただし、当該 3 地域間で大きな差はなく、正答率は 75~80%程度であった。一方で、倒壊と非倒壊の建築物が混在する 3 地域から 1 地域をテストデータとし、その他を訓練データとすると、特定の地域（大船渡市）が他の地域と比較して正答率が低く、カラーの場合で 68%であった。このとき、他 2 地域は 80%以上の正答率である。そのため、大船渡市の空撮画像内の建築物が、他の地域とは異なる特徴を保有する可能性がある。その理由として、空撮画像の画像的特徴がある。他地域の画像と調査結果の被害区分が同じでも、建築物の倒壊の仕方や残り方、撮影時期や天候による画像の写り方の差が、地域により異なる

\*1 重みの更新がまったく行われていないときには乱数により初期重みが設定される。そのため、重みの更新前はランダムにテスト画像を判別することになる。しかしながら、テストデータの内訳は 1:1 ではないため、ランダムに判別した結果、テストデータの倒壊と非倒壊の比率が 0 エポック目の正答率となる。

可能性は十分にある。たとえば、大船渡市をテストデータにした際、入力信号はカラー画像よりもグレースケール画像の方が正答率が高い。色情報である入力信号のチャンネル以外の条件は同一のため、訓練データで学習してテストデータを判別する際、画像の色情報が正しい判別の妨げとなったのは自明である。すなわち、テストデータ（大船渡市）と訓練データ（それ以外の地域）の間での空撮画像の色調等の差は、判別失敗の一因となる。

また、全壊（流失）に関しては、建造物の基礎や付近の道路と思われる物体が存在している例で間違っている例だが、全壊（流失）の場合、津波等の被害により、建造物が跡形もなくなっているため、テストデータ数に対し判別失敗する例は、全壊、全壊（1階天井以上浸水）より少なく、比較的判別が簡単といえる。しかし一方で、どの地域に関しても全壊（一階天井以上浸水）と大規模半壊はテストデータ数に対して判別失敗の割合が高い。また、6.1節に記述したとおり、全壊（一階天井以上浸水）と大規模半壊や半壊については、空撮画像のみでは目視による判読が困難である。この理由として、各画像の被災区分は、長期間の調査結果から細分化された被災区分を利用するため、ほぼ建造物の屋根とその周辺の土砂だけしか情報を得られない空撮画像から浸水を推定するためである。

実際に、非倒壊と区分される画像でも、屋根の色によってはほぼ灰色である画像が散見される。カラー画像よりもグレースケール画像を入力した場合の方が正答率が高い地域の画像を詳細に見てみると、実際に灰色の屋根の建造物が多い地域であった。

対照的に、工業地帯といった理由で屋根の色が青色でほぼ統一されている地域も本稿でのデータに含まれる。地面の色と屋根の色に明確に差がある場合、色情報が特徴量として有効となるため、カラー画像を入力の方がグレースケール画像を入力する場合より、正答率の高い結果となる結果が多くなりうる。

また、影等の色情報については、同じ時刻の撮影時期に統一した画像を利用するのが望ましいが、現状として、災害初動時は情報入手が優先されるため、使用できる空撮画像の撮影時刻は選べない。また、撮影地域等の日照条件は地形的な特性も存在するため、キャリブレーションには限界がある。以上の面からも、対応策としてあらかじめ様々な災害や地域の画像を膨大に用意し、学習しておく重要性は高い。

図7は、倒壊と非倒壊の建造物が混在する各地域をテストデータにした際、判別失敗した画像である。実際の被災区分は全壊である。また、図7の大船渡市の画像2例は、全地域からテストデータを作成した実験でテストデータとして選ばれ、両方正しく倒壊と判別された。

全地域からテストデータをランダム抽出する場合、訓練データとテストデータは同じ地域の建造物を使用するが、



図7 被害区分全壊の判別失敗例（左から大船渡市、野田村、山田町）  
**Fig. 7** Examples of discrimination mistakes in the category of ‘collapsed’ (answers (Ofunato, Noda and Yamada from the left)).

建造物の形状、および、壊れ方は1例ずつ異なる。ただし、図1や表6で各地域の被災区分の割合に注目すると、倒壊建造物数が近くても、建造物がほぼ流失した例が90%以上の地域や、全壊（1階天井以上浸水）だが外形は一見被害なく見える地域が存在する。同地域では地震震度や津波の高さ等が近いほか、建造物の区画や地盤に適した構造の建造物が多く、被害の特徴が類似する可能性が高い。よって、訓練データで対応可能な幅が広がり、判別の適用能力が高くなる。以上の理由から、訓練データ内に同じ地域の画像や、似た系統の地域の画像が含まれると、倒壊判別の適用能力が上がる。

関連研究として、2015年に浅沼らが畳み込みニューラルネットワークを使用した人検出器の作成を行い、少量の学習サンプルに対して、平身・スケーリング・回転・輝度変化の変形を適用し、大量の学習サンプルを作成するアプローチを報告している [17]。この結果、人検出器の誤検出率 0.001 における人の未検出率が 28.2% となり、従来の人検出器誤検出率 0.001 における人の未検出率 77.5% と比較して、大きく未検出率が改善した。こういった事例から、本研究でも、より多様な画像を用意し学習を行えば、判別器の画像分類精度の向上ができると期待できる。

すなわち、今後の震災対応等での実用化を視野に入れる際、可能な限り多くの地域、および、条件の画像を用意し、判別器を作成しておくのが望まれる。

## 8. おわりに

本研究は、東日本大震災の被災地空撮画像に対し、畳み込みニューラルネットワークを用い、建造物倒壊判定を行った。結果、被災地 10 地域すべての画像を駆使し、86% の正答率を得た。また、倒壊と非倒壊の建造物が混在する地域をテストデータにした場合では、68～84% の正答率を得た。

被災がれき処理のために震災後直後の処理計画立案に必要なのは被災がれき量の概算値であり、災害発生原単位に乗ずる被害面積である。東日本大震災では、実際の発生がれき量より 1.5～2 倍程度多く、実際の必要処理量との差が問題となった。本稿で倒壊と定義し、判別した画像は、実際の被災区分では全壊であり、確実にがれきを発生させる。そのため、現在も用いられる津波浸水域抽出等で倒壊地域を大まかに同定し、提案手法と組み合わせれば、より高精度ながれき量推定手法の提案が期待できる。また、本稿の実験の中では、全地域の中でも正答率の低かった地域

の空撮画像のみをテストデータとして判別を行い、前実験の結果と比較して、より多くの地域や季節の画像データを用意すれば、判別器の正答率が向上する可能性を示した。

**謝辞** 本研究は仙台環境開発株式会社からの助成による成果を含んでおります。ここに深謝いたします。

### 参考文献

- [1] 国立環境研究所：災害廃棄物の発生原単位について（第一報），入手先 (<http://www.nies.go.jp/shinsai/>).
- [2] 環境省廃棄物・リサイクル対策部：災害廃棄物総量推計値の見直しについて，入手先 ([http://kouikishori.env.go.jp/disaster\\_waste/processing/processing\\_status/index.html](http://kouikishori.env.go.jp/disaster_waste/processing/processing_status/index.html)).
- [3] 高谷敏彦, 佐藤真哉, 大内 東：東日本大震災から学ぶ災害廃棄物量推定システムに関する考察，情報処理学会全国大会講演論文集，Vol.74, No.3, pp.1287–1288 (2012).
- [4] LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P.: Gradient-based learning applied to document recognition, *Proc. IEEE*, pp.2278–2324 (1998).
- [5] LeCun, Y., Boser, B., Denker, J.S., Henderson, D., Howard, R.E., Hubbard, W. and Jackel, L.D.: Back-propagation applied to handwritten zip code recognition, *Neural Computation*, Vol.1, pp.541–551 (1989).
- [6] 岡谷貴之：画像認識のための深層学習，人工知能学会誌，Vol.28, No.6, pp.962–974 (2013).
- [7] LeCun, Y.A., Bottou, L., Orr, G.B and Müller, K.R.: Efficient backprop. In *Neural networks: Tricks of the trade*, pp.9–48, Springer Berlin Heidelberg (2012).
- [8] Xavier, G. and Bengio, Y.: Understanding the difficulty of training deep feedforward neural networks, *International Conference on Artificial Intelligence and Statistics* (2010).
- [9] 能島暢呂, 杉戸信太, 金澤伸治：被害情報の逐次処理による地震時緊急対応の意思決定支援モデル，土木学会論文集，No.682/I-56, pp.129–142 (2001).
- [10] 平山修久, 河田恵昭, 奥村与志弘：東日本大震災における災害廃棄物量の推定と災害対応，廃棄物資源循環学会論文誌，Vol.23, No.1, pp.3–9 (2012).
- [11] 鈴木大輔, 丸山善久, 山崎文雄：デジタル航空画像を用いた新潟県中越沖地震の建物被害抽出，日本地震学会論文集，Vol.10, No.3, pp.33–45 (2010).
- [12] 三富 創, 松岡昌志, 山崎文雄：最近の地震災害の空撮画像を用いた建物被害地域の自動抽出の試み，土木学会論文集，Vol.703, No.I-59, pp.267–278 (2002).
- [13] 国土交通省国土地理院，被災地域の空中写真（電子国土Web システム版），入手先 (<http://portal.cyberjapan.jp/site/mapuse2/index3.tohoku.html>).
- [14] 国土交通省都市局，東日本大震災復興支援調査アーカイブ，入手先 (<http://fukkou.csis.u-tokyo.ac.jp/>).
- [15] Bergstra, J., Breuleux, O., Bastien, F., Lamblin, P., Pascanu, R., Desjardins, G., Turian, J., Warde-Farley, D and Bengio, Y.: Theano: A CPU and GPU Math Expression Compiler, *Proc. Python for Scientific Computing Conference (SciPy)* (2010).
- [16] Bastien, F., Lamblin, P., Pascanu, R., Bergstra, J., Goodfellow, I., Bergeron, A., Bouchard, N., Warde-Farley, D. and Bengio, Y.: Theano: New features and speed improvements, *NIPS 2012 deep learning workshop*.
- [17] 浅沼 仁, 岡本一志, 川本一彦：特徴学習による全方位画像からの人検出，知能と情報，Vol.27, No.5, pp.813–825 (2015).

### 推薦文

本稿は情報処理北海道シンポジウム 2013 に投稿された論文で 6 ページを超えるもののうち、実行委員による審査により最も優れたものと判断したものである。本稿は航空写真による被災地域の特定および被災に関する量の推定について、実際の東日本大震災の被災地域について取り組んだものであり、その社会貢献の観点からの有意義さと将来性を高く評価し、推薦するものとした。

(情報処理学会北海道支部支部長 山本雅人)



利根川 凜 (学生会員)

2014 年北海道大学工学部情報エレクトロニクス学科卒業。同年同大学大学院修士課程課程入学。同年同大学大学院博士後期課程入学。災害廃棄物、被災情報システムの研究に従事。精密工学会、廃棄物資源循環学会各会員。



飯塚 博幸 (正会員)

2004 年東京大学大学院総合文化研究科博士課程修了(博士(学術))。2005 年日本学術振興会特別研究員 (PD, はこだて未来大学), イギリスサセックス大学客員研究員, 2008 年大阪大学大学院情報科学研究科助教。2013 年北海道大学大学院情報科学研究科准教授。人工生命, 複雑系科学, 人間情報工学に従事。



山本 雅人 (正会員)

1991 年北海道大学工学部情報科学科卒業。1993 年同大学大学院修士課程修了。1996 年同大学院博士課程修了。工学博士。1996 年日本学術振興会特別研究員 (PD)。1997 年北海道大学大学院工学研究科助手。2000 年同大学院研究科研究科助教。2007 年同大学院情報科学研究科准教授, 2012 年同大学院情報科学研究科教授。科学技術振興機構さきがけ研究員, デューク大学客員研究員。複雑ネットワーク, DNA コンピューティングの研究に従事。電子情報通信学会, 人工知能学会, 計測自動制御学会, 精密工学会, 日本オペレーションズ・リサーチ学会等各会員。



古川 正志 (正会員)

1971年北海道大学大学院工学部精密工学科卒業。1973年同大学大学院工学研究科修士課程修了。同年旭川工業高等専門学校電気工学科助手，同機械工学科助教授，同制御情報工学科教授。2006年北海道大学大学院情報科学研究科教授を経て2013年北海道情報大学経営情報学部教授。この間，コーネル大学NSF研究員，イーストアンゲリア大学客員教授。1981年工学博士（北海道大学）。自律分散システム，インテリジェント・エンジニアリング，複雑ネットワークの研究に従事。計測自動制御学会，精密工学会各会員，機械学会（フェロー）。



大内 東 (正会員)

1974年北海道大学大学院工学研究科博士課程修了。2004年北海道大学大学院情報科学研究科教授，2011年北海商科大学大学院商学研究科教授，2013年東北大学大学院環境科学研究科客員教授。日本コンペティティブ・インテリジェンス学会，環境科学会，廃棄物資源循環学会各会員，観光情報学会名誉会長，日本オペレーションズ・リサーチ学会フェロー。