

令和 3 年 5 月 31 日現在

機関番号：11401

研究種目：基盤研究(C)（一般）

研究期間：2018～2020

課題番号：18K02236

研究課題名（和文）生活活動音の深層学習による独居者家庭内事故等の検出方法に関する研究

研究課題名（英文）Study on Detection Method of Abnormal Situation in Daily Life by Machine Learning of Indoor Activity Sound

研究代表者

田中 元志（Tanaka, Motoshi）

秋田大学・理工学研究科・准教授

研究者番号：50261649

交付決定額（研究期間全体）：（直接経費） 3,400,000円

研究成果の概要（和文）：独居生活者の家庭内における事故などの異常検出を目的に、生活活動音（生活音）の機械学習を用いて異常候補を検出する方法について検討した。日中の生活音の自己組織化マップ（SOM）を求め、学習後のニューロンの重みを特徴ベクトルとしてクラスタリングを行い、生活音の確率モデルを作成した。音の発生確率を算出でき、転倒事故を模擬した音では、転倒時に確率が非常に小さくなり、その後の動作が無い時間は変化が小さい結果となった。発生確率の時間変化の観察は異常状態の検出に有効である可能性が示唆された。また、夜間の音の解析と深層学習による足音認識を試み、それらの利用の可能性も得られた。

研究成果の学術的意義や社会的意義

事故時に発生する音の収集は困難であり、個々の音の識別には膨大なデータベースが必要なため、滅多に起きない（日常的ではない）音を検出する方法について検討した。教師無し学習の1つである自己組織化マップ（SOM）の利用を検討し、日常生活音のSOMを用いた確率モデルを作成した。音の発生確率を算出でき、転倒事故を模擬した音を異常状態（候補）として検出できた。今後、本方法を確立できれば、家庭内事故等の検出システムのみならず、故障の診断など他の異常音検出への応用も期待できる。

研究成果の概要（英文）：In order to develop a detection system of abnormal situations (such as accidents) for a person living alone, a detection method using machine learning was investigated. Self-organizing map (SOM) of only sounds of daily activities recorded with a broadband microphone was obtained. The weights of the SOM after learning, as feature vectors, were classified by the hierarchical clustering, and then the stochastic model was obtained. The generation probability of the sound of an activity was calculated, and the probabilities varied corresponding to sound changes. Observing the generation probability is expected to be one of the methods for detecting abnormal situations. Also, sounds produced during sleep were analyzed and footprint recognition with deep learning was investigated, whose results indicated the feasibility of using those for detecting abnormalities.

研究分野：情報通信工学

キーワード：生活活動音 時間-周波数解析 異常検出 機械学習 自己組織化マップ

### 1. 研究開始当初の背景

近年、高齢者を含む独居生活者の増加に伴い、家庭内事故の頻度や怪我の重度が増加する傾向にあり、孤独死も社会的問題となってきている[1]。そのため、生活活動を離れたところで把握でき、家庭内事故、急激な身体状況の変化などに見舞われたときに迅速かつ適切に対応できる在宅ライフサポートシステム(見守りシステムなど)が求められている。身の周りで発生する音を利用した見守り・異常検出システムに関する検討[2]では、過去に発生して(学習されて)いない音を異常として検出する機会が多い。しかし、それらの音がすべて異常と関係があるとは限らない。生活と関連する音をすべて識別・検出するためには、膨大なデータベース、および高速な処理装置が必要となる。また、事故などによる異常状態の発生を予測できないため、異常時に発生する音の採取(教師データの収集)は困難である。

そこで、生活活動において発生する音(生活音)の発生確率に着目した。事故などの滅多に起こらない音の発生確率は低く、日常的な音の発生確率は高いと考えられる。音の発生確率を求め、音声信号処理などでよく利用される MFCC (Mel-Frequency Cepstral Coefficients) や SF (Spectral Flux) を特徴ベクトルとして求め、そのクラスタリング(学習)から確率モデル化を検討した[3]。しかし、階層的クラスタリング手法を用いたため、学習に用いるデータ量が解析システム(コンピュータ)の性能(メモリ容量など)に大きく依存した。音の発生確率の変化から異常な状況を検出するためには、システム性能に依存しない、膨大な生活音(データ)を学習可能な検出方法(アルゴリズム)の検討が必要であり、そのためのパラメータに関する検討も必要と言える。また、検出率向上に向け、日常生活音の確率モデル化の方法、他の音およびその特徴量(SF や未検討のパラメータ)を併用する方法についての検討も必要である。

### 2. 研究の目的

機械学習(深層学習など)を活用して、高齢者を含む独居生活者の生活音から事故の有無などの状況を把握するための異常検出方法の開発を目的とする。異常検出のための主な処理の流れを図1に示す。長時間の生活音を広周波数帯域マイクロフォンなどで採集し、時間-周波数解析を行って特徴量を抽出する。その特徴量を自己学習する方法とそれを用いた確率モデル化を検討する。そして、音から得られる情報、確率モデルを用いて算出した発生確率など、の時間変化を観察して、事故などの異常な状況を検出するための方法(異常検出アルゴリズム)を開発する。また、日中の活動音だけではなく、夜間(睡眠中)の音、および個人を特定しやすい足音についても解析を行い、異常検出への利用を検討する。これらについて、次の手順で検討を行った。

- (1) 日常の生活活動と関連する音の周波数解析と特徴抽出
- (2) 生活音の特徴量に合わせた機械学習
- (3) 生活音の確率モデル化とそれを用いた異常候補検出方法の検討



図1. 異常検出の処理の流れ

### 3. 研究の方法

- (1) 日常の生活活動と関連する音の周波数解析と特徴抽出

生活活動と関連する音として、日中の音、夜間(睡眠中)の音、足音に分けて検討した。

- ① 日中の生活音の解析

被験者 A (一人暮らしの健康な男性, 23 歳) の部屋に広周波数帯域 (20 Hz~100 kHz) のマイクロフォンを配置してデジタルレコーダ(周波数帯域 0.02~80 kHz, サンプリング周波数 192 kHz) で取り込んだ約 6 時間の音を用いた, 解析フレーム長(ハミング窓) 500 ms, シフト長(フレーム周期) 250 ms とし, 2<sup>17</sup>点 FFT による時間-周波数解析を行った。特徴量として下記の場合を抽出し, 比較した。

- Case A: 80 kHz までを 15 個に分割(帯域幅 10 kHz, 三角窓, シフト幅 5 kHz) した各サブバンド内の合計電力(15 次ベクトル)
- Case B: 可聴周波数帯域(0.02~20 kHz)を対象とした 12 次 MFCC (12 次ベクトル)
- Case C: 80 kHz までに拡張した 24 次 MFCC (24 次ベクトル)
- Case D: 80 kHz までをメル尺度で 20 個に分割(三角窓)した各サブバンド内の合計電力(20 次ベクトル)
- Case E: Case B の 12 次 MFCC と Case A (0-10 kHz のサブバンドを除く 14 次特徴量)を用いた場合(26 次ベクトル)




図2に、ある時間の日常音のパワ

図2. 生活音のスペクトル例と抽出された特徴量

一スペクトルと Case A~D で抽出した特徴ベクトルを示す。なお、各値は、サブバンドの中心周波数でプロットした。いずれの場合もスペクトルの包絡形状を概ね捉えている。

## ② 睡眠中の音の解析

被験者 B (一人暮らしの健康な男性, 24 歳) の部屋でマイクロフォン (帯域幅 20 kHz) をベッドに仰向けになった頭頂部側に配置し、デジタルレコーダ (サンプリング周波数 44.1 kHz, 16 bit 量子化) を用いて約 4 時間録音した。遮断周波数 1.5 kHz の 8 次 HPF を通し、低周波数帯の雑音を除去した。フレーム長 (ハミング窓) 1 s, シフト長 0.25 s として、 $2^{16}$  点 FFT による時間-周波数解析を行った。特徴量として、12 次 MFCC, スペクトルエントロピー, スペクトル重心を求めた。これら特徴量の時間変化 (ピークなどの間隔) から呼吸間隔の推定を試みた。

## ③ 足音の解析

被験者を 22~24 才の健康な男性とし、秋田大学理工学部 1 号館の廊下 (鉄筋コンクリート建) の床にマイクロフォン (20~20 kHz) を配置し、履物や歩行速度を変えた場合、複数人が同時に歩く場合などの音をデジタルレコーダ (サンプリング周波数 44.1 kHz) で録音した。解析フレーム長 (ハミング窓) 2048 点, シフト長 512 点とし、FFT を用いた時間-周波数解析を行った。フレーム毎のパワースペクトルから 20 次の Log-Mel Spectrum (LMS) [4] を求めた。

なお、これらの音の採取においては、秋田大学手形地区人を対象とした研究に関する倫理委員会の承認を受け、被験者に実験内容を十分に説明し、同意を得た上で行った。また、解析・処理ツールとして、足音では Python を、その他の生活音については Matlab を主に利用した。

## (2) 生活音の特徴量に合わせた機械学習

深層学習手法の多くは教師あり学習であり、異常音の教師信号の作成は困難である。そこで、生活音については、教師データを必要としない自己組織化マップ (SOM: Self-Organizing Map) [5] の利用を検討した。一方、足音については、個人毎のデータを作成可能であり、たたみ込みニューラルネットワーク (CNN: Convolutional Neural Network) の利用を検討した。

### ① 生活音の自己組織化マップ

生活音 (約 6 時間) について、Case A~E の場合の SOM をそれぞれ求めた。マップのニューロン数が約 5,000 になるように、学習データの主成分分析による第一と第二主成分の比を縦横比として決定した。学習回数を 10,000 回とした。各 SOM について、勝者ニューロン数が多いニューロンの周辺を平滑化し、学習に用いたデータ数のうち 98.9%, 1.0%, および 0.1% が含まれる領域をそれぞれ領域 1, 2, および 3 とした。異常模擬音 (転倒後 5 分間活動がない場合) を入力し、その結果から、確率モデル化に用いるときの特徴量を選定した。

### ② 足音の深層学習による歩行認識

学習用データとして 1 秒毎に切出した LMS を用いた。深層学習に用いる NN の構造として、画像認識に有効とされる、代表的な CNN である LeNet[6] を利用した。歩く速さと履物を変えた場合の歩行者の識別、および複数歩行者の識別を試みた。

## (3) 生活音の確率モデル化とそれを用いた異常候補検出方法の検討

SOM の学習後のニューロンの重みを特徴ベクトルとして、クラスタリングを行う。各クラスターで、中心から近い順に多くのベクトルを含む領域を日常的な音、それ以外のベクトル領域を異常の可能性がある領域に設定し、領域の内と外で異なるシンボルを出力するように設定した。また、距離の近いクラスターを統合し、「状態」と定義した。確率モデルのイメージ図を図 3 に示す。3 フレーム間の状態遷移を考え、時刻  $n$  における音の発生確率を、

$$P_n = \pi_{q_{n-2}} a_{q_{n-2}q_{n-1}q_n} b_{s_{n-2}} b_{s_{n-1}} b_{s_n}$$

から求めた。但し、 $\pi_{q_{n-2}}$  は状態遷移系列の最初 (時刻  $n-2$ ) の状態が  $q_{n-2}$  である初期状態確率、 $a_{q_{n-2}q_{n-1}q_n}$  は状態が  $q_{n-2}$ ,  $q_{n-1}$  と順に遷移した後に  $q_n$  に遷移する条件付確率、 $b_{s_n}$  は状態  $q_n$  においてシンボル  $s_n$  が出力される確率である。

次に、この確率モデルを用いて音の発生確率を求め、異常候補の検出方法の検討を行う。ここでは、転倒模擬音 (転倒後 5 分間動きが無く、事故の可能性のある音) 10 音と、悲鳴後に活動がある音 (事故の可能性がない音) 5 音を用意した。また、状態数 3, クラスター内の領域の大きさを 98% が含まれる範囲とした場合の確率モデルとした。




図 3. 確率モデルの説明図 (状態数 3)

## 4. 研究成果

日中の生活音の自己組織化マップ化、睡眠時の寝息音からの呼吸検出、足音の深層学習による歩行認識、生活音の確率モデル化とそれを用いた異常候補検出の検討の順にまとめる。

### (1) 生活音の自己組織化マップ化の検討

得られた自己組織化マップ (SOM) の例 (Case A) を図 4 に示す。多くの勝者ニューロンが集まった領域が観察されるが、その境界は明確ではない。そこで、各 SOM を、学習されたベクトル数の 98.9, 1.0, および 0.1% を含む 3 つの領域に分割した。図 5 に 3 領域に分類した SOM

の例 (Case A) を示す。領域 1 は日常の多くの音が含まれる領域であり、領域 2 と 3 には稀な音や未知の音の領域として期待された。

異常模擬音として、利用者が転倒して動けなくなった状況を想定し、「転倒し、約 5 分間動き無し」の音を 10 音用意した。図 5 中の赤丸プロットは、転倒時のニューロンである。転倒時にニューロンが領域 1 から 2 または 3 に遷移した場合を「転倒」、その後の 5 分間にニューロンの遷移が無い (領域 1 のまま) 場合を「動き無し」として検出し、どちらも観測された場合を「異常候補」として検出した。結果を表 1 に示す。Case A が最もよい結果であった。しかし、生活の状況 (音の発生の仕方) によっては今回の異常候補判定条件の状態が現れる可能性があり、日常状態との区別が課題となった。そこで、(4)では、Case A の特徴量で求めた SOM を用いて、確率モデル化を検討することとした。




図 4. 生活音 (6 h) の自己組織化マップ (Case A)




図 5. 3領域に分けられたSOMの例 (Case A)


表 1. 異常模擬音を用いた検出結果.

	Case A	Case B	Case C	Case D	Case E
転倒の検出	10/10	10/10	1/10	4/10	8/10
動き無しの検出	10/10	0/10	0/10	0/10	10/10
異常としての検出	10/10	0/10	0/10	0/10	8/10


## (2) 睡眠時の寢息音からの呼吸検出の検討

寢息音の波形例とそのスペクトルエントロピー (SE) を図 6 に示す。呼吸に対応する周期的な変化 (ピークなど) が確認できる。特徴量として、MFCC の 3 次と 7 次成分, SE, スペクトル重心の微分を求め、ピーク (またはヌル点) の時間を抽出し、それらの平均値を呼吸の時刻として呼吸間隔を求めた。振幅が小さい呼吸音の箇所については、周期的な呼吸を仮定して、特徴量のピーク時刻を推定し、呼吸間隔を求めた。

睡眠時の音 (約 4 時間) について、呼吸間隔を推定した結果を図 7 に示す。図中の×点は、約 20 分毎に 3 分間の時間波形の間隔から求めた平均呼吸間隔であり、約 3.1~3.6 s であった。プロットが等間隔ではないが、寝返りなどによってマイクロフォンとの距離が遠くなり、波形からは呼吸を検出できない区間があったためである。図中の赤線は本方法で推定した結果である。呼吸間隔をおおよそ推定できており、連続的に呼吸を検出できる可能性が示された。しかし、いずれの特徴量からもピークを検出できない区間が数分以上継続する場合 (図 7 の 40 分頃など) があり、そのような区間での推定は今後の課題である。



(a) 時間波形



(b) スペクトルエントロピー

図 6. 寢息音の波形と抽出された特徴量の例




図 7. 睡眠中の呼吸間隔の推定結果例

## (3) 足音の深層学習による歩行認識の検討

足音 8 歩分の時間波形の例とその 20 次 LMS を図 8 に示す。歩行時の音色の変化の様子が確認できる。はじめに、歩行者を 1 名として、歩行条件として歩く速さと履物を変えて、歩行者を識別した。履物が異なる場合は認識率が約 58% であった。履物によって音色が異なるために LMS のパターンも異なったためと考えられる。しかし、対象とするすべての歩行条件をあらかじめ学習させた場合は約 99% で識別できた。

次に、複数人が同時に歩いたときの足音から特定歩行者の検出を試みた。同時歩行時の学習用データとして、複数の被験者毎の足音を朝寝合わせて疑似的に作成した。結果 (識別率) を表 2 に示す。比較的高い識別率が得られ、同時歩行時の足音を準備しなくても複数歩行者を検出できる可能性が示された。しかし、今回の検討では、歩行者の足音を全て学習させておく必要があり、

未学習の足音が含まれる場合の識別方法が今後の課題となった。

表 2. 足音の識別結果の例

歩行人数の識別	94.0%
歩行人数 1 人の識別	99.7%
歩行人数 2 人の識別	99.2%
歩行人数と被験者の同時識別	85.7%

#### (4) 生活音の確率モデル化とそれを用いた異常候補検出方法の検討

SOM (図 4) のニューロンの重みを特徴ベクトルとし、階層的クラスタリングの Ward 法を用いて 15 クラスタに分類した。クラスタ毎に、中心から近い順に 98% のベクトルを含む領域を日常的な音、それ以外のベクトルの領域を異常の可能性のある領域と設定した。また、距離の近いクラスタを統合し、3 つの状態とした。図 9 に 3 状態に分けられた SOM を示す。この場合の確率モデルを作成し、生活音の発生確率を求めた結果の例を図 10 に示す。音の発生に対応して発生確率が変化した。

異常候補の検出方法の検討のため、「転倒後 5 分間動きがない場合 (異常模擬音)」10 音と、「悲鳴の後 5 分間活動を続けた場合 (異常なし音)」5 音を用意した。定常的な生活音の発生確率の最小値が  $2.2 \times 10^{-9}$  であったことから、異常音の検出しきい値を  $10^{-9}$  とした。動作が無い場合のしきい値は、それより大きい  $10^{-8}$  とした。検出結果を表 3 に示す。異常模擬音では、転倒 (イベント) およびその後の 5 分間の無動作を検出でき、10 音全てを異常候補として判別できた。一方、異常なし音では、悲鳴 (イベント) を全て検出できたが、その後の 5 分間の行動については 1 音を「動き無し」と誤検出した。検出精度向上のためには、学習量を増やし、確率モデルの状態数やクラスタ内の領域の大きさ、判別時のしきい値などの調整が必要と考えられる。

生活音の自己組織化マップ (SOM) を用いた確率モデルから発生確率を求め、その時間変化を観察することで、異常状態を検出できる可能性が示唆された。しかし、約 6 時間の生活音の SOM を求めるための学習時間は数 10 時間であった。長時間データおよび継続的な利用に対応した学習方法および自己更新可能な確率モデルの構築も、今後の課題として挙げられる。

#### 参考文献

- [1] 内閣府, 平成 27 年版高齢社会白書, “平成 26 年度 高齢化の状況及び高齢社会対策の実施状況”, 2015.
- [2] 例えば, A. Ito, A. Aiba, M. Ito, and S. Makino: “Detection of Abnormal Sound Using Multi-Stage GMM for Surveillance Microphone”, 5th Int. Conf. on Information Assurance and Security (Xi’an, China), pp.733- 736, 2009.
- [3] 入江建悟, 田中元志: “屋内生活活動時の広帯域音響信号の確率モデル化に関する一検討”, 電子情報通信学会総合大会, A-5-11, 2017.
- [4] H. Purwins, B. Li, T. Virtanen, J. Schlüter, S. Chang, and T. Sainath: “Deep Learning for Audio Signal Processing”, Journal of Selected Topics of Signal Processing, Vol.13, No.2, pp.206-219, 2019.
- [5] T. Kohonen: Self-Organizing Maps, Springer-Verlag, Berlin Heidelberg, 2001.
- [6] Y. LeCun, P. Haffner, L. Bottou, and Y. Bengio: “Object Recognition with Gradient-Based Learning”, Shape, Contour and Grouping in Computer Vision, pp.319-345, Springer, 1999.




図 8. 足音の波形例 (上) とその LMS (下)




図 9. SOM (図 5) を 3 状態に分けた結果




図 10. 算出された生活音の発生確率の例

表 3. 異常模擬音を用いた異常候補の検出結果.

	転倒 (異常模擬音)	悲鳴 (異常なし音)
イベントの検出	10/10	5/5
動き無しの検出	10/10	1/5
異常としての検出	10/10	1/5

## 5. 主な発表論文等

〔雑誌論文〕 計4件（うち査読付論文 4件/うち国際共著 0件/うちオープンアクセス 1件）

1. 著者名 Tanaka Motoshi、Takata Naru	4. 巻 16
2. 論文標題 A Study on Self Organizing Map of Indoor Activity Sound for Detecting Abnormal Situation in Daily Life	5. 発行年 2021年
3. 雑誌名 IEEJ Transactions on Electrical and Electronic Engineering	6. 最初と最後の頁 488 ~ 490
掲載論文のDOI（デジタルオブジェクト識別子） 10.1002/tee.23321	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -
1. 著者名 Tanaka Motoshi	4. 巻 14
2. 論文標題 A calculation method of generation probability of indoor activity sound in daily life	5. 発行年 2019年
3. 雑誌名 IEEJ Transactions on Electrical and Electronic Engineering	6. 最初と最後の頁 1881 ~ 1882
掲載論文のDOI（デジタルオブジェクト識別子） 10.1002/tee.23016	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -
1. 著者名 田中元志	4. 巻 23
2. 論文標題 生活音の確率モデルを用いた家庭内異常候補検出システム	5. 発行年 2020年
3. 雑誌名 エレクトロニクス実装学会誌	6. 最初と最後の頁 124 ~ 127
掲載論文のDOI（デジタルオブジェクト識別子） 10.5104/jiep.23.124	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -
1. 著者名 田中元志	4. 巻 39号
2. 論文標題 12平均律を用いた一般化調和解析による打楽器音の音高抽出の試み	5. 発行年 2018年
3. 雑誌名 秋田大学大学院理工学研究科研究報告	6. 最初と最後の頁 7-8
掲載論文のDOI（デジタルオブジェクト識別子） なし	査読の有無 有
オープンアクセス オープンアクセスとしている（また、その予定である）	国際共著 -

〔学会発表〕 計12件（うち招待講演 0件 / うち国際学会 0件）

1. 発表者名 田中元志, 高田 鳴
2. 発表標題 屋内生活音のSOMを用いた確率モデルに関する検討
3. 学会等名 令和3年 電気学会全国大会
4. 発表年 2021年

1. 発表者名 董天格, 田中元志
2. 発表標題 屋内生活音の定期的自己更新クラスタリング方法の検討
3. 学会等名 第3回東北地区音響学研究会
4. 発表年 2020年

1. 発表者名 藤原 涼, 田中元志
2. 発表標題 足音の深層学習による複数歩行者の検出の試み
3. 学会等名 第3回東北地区音響学研究会
4. 発表年 2020年

1. 発表者名 畑瀬慎也, 田中元志, 室賀 翔
2. 発表標題 寢息音の時間-周波数解析による連続的な呼吸検出の試み
3. 学会等名 第3回東北地区音響学研究会
4. 発表年 2020年

1. 発表者名 畑瀬慎也, 田中元志, 室賀翔
2. 発表標題 寝息音からの呼吸間隔の推定に関する検討
3. 学会等名 2020年 電子情報通信学会総合大会
4. 発表年 2020年

1. 発表者名 田中元志
2. 発表標題 屋内生活音の自己組織化マップとその利用 ~異常候補検出の試み~
3. 学会等名 エレクトロニクス実装学会インテリジェント実装技術研究会 令和元年度第1回公開研究会
4. 発表年 2019年

1. 発表者名 藤原涼, 田中元志
2. 発表標題 歩行条件が異なる足音の深層学習に関する一検討
3. 学会等名 第2回東北地区音響学研究会
4. 発表年 2019年

1. 発表者名 高田鳴, 田中元志
2. 発表標題 広帯域屋内生活音のSOMを用いた異常候補検出に関する一検討
3. 学会等名 2019年 電子情報通信学会ソサイエティ大会
4. 発表年 2019年



1. 発表者名 畑瀬慎也, 田中元志, 室賀翔
2. 発表標題 横臥位時の呼吸音検出と特徴抽出に関する一検討
3. 学会等名 平成31年度 電気関係学会東北支部連合大会
4. 発表年 2019年

1. 発表者名 高田鳴, 田中元志
2. 発表標題 自己組織化マップを用いた屋内生活音の確率モデル化に関する検討
3. 学会等名 2019年 電子情報通信学会総合大会
4. 発表年 2019年

1. 発表者名 藤原涼, 田中元志
2. 発表標題 MFCCの深層学習による足音認識の試み
3. 学会等名 第1回東北地区音響学研究会
4. 発表年 2018年

1. 発表者名 高田鳴, 田中元志
2. 発表標題 自己組織化マップを用いた生活活動音の異常候補検出に関する検討
3. 学会等名 平成30年度 電気関係学会東北支部連合大会
4. 発表年 2018年

〔図書〕 計0件

〔産業財産権〕

〔その他〕

-

6. 研究組織

	氏名 (ローマ字氏名) (研究者番号)	所属研究機関・部局・職 (機関番号)	備考
--	---------------------------	-----------------------	----

7. 科研費を使用して開催した国際研究集会

〔国際研究集会〕 計0件

8. 本研究に関連して実施した国際共同研究の実施状況

共同研究相手国	相手方研究機関
---------	---------