

平成 30 年 6 月 15 日現在

機関番号：34310

研究種目：基盤研究(B) (一般)

研究期間：2014～2017

課題番号：26280063

研究課題名(和文) 高識別的特徴空間とその探索法の最小分類誤り基準に基づく統一の実現

研究課題名(英文) Minimum Classification Error Criterion-based Development of Highly Discriminative Feature Space Associated with Optimal Class Boundary Search Methods

研究代表者

片桐 滋 (Katagiri, Shigeru)

同志社大学・理工学部・教授

研究者番号：40396114

交付決定額(研究期間全体)：(直接経費) 12,300,000円

研究成果の概要(和文)：高識別的な特徴空間，即ち分類誤り確率の最小値自体がより小さな特徴空間の実現を目指して，可変長パターンのための動的時間軸伸縮に基づく幾何マージンおよびそれを用いた大幾何マージン最小分類誤り学習法の開発と，小規模で高識別的なカーネル分類器実現のためのカーネル最小分類誤り学習法の拡張，深層ニューラルネットワークを用いる音声認識技術のための話者適応学習や補助ネットワークを用いた高識別的音声特徴空間の実現，大規模音声認識器のための高速解候補探索技術の構築を行った．また，推定境界における分類判断の曖昧性に基づく「ベイズ境界らしさ」基準を用い，ハイパーパラメータをパラメータ化し得る学習法開発への道を拓いた．

研究成果の概要(英文)：Aiming at the development of highly discriminative feature space, of which corresponding classification error probability is as small as possible, we developed the following new technologies: a Dynamic-Time-Warping (DTW)-based geometric margin for variable-length patterns, Large Geometric Margin Minimum Classification Error training using the DTW-based geometric margin, a compact kernel classifier using Kernel Minimum Classification Error training, speaker and environment adaptation methods for deep-neural-network-based speech recognizers using Speaker Adaptive Training and auxiliary neural network, and fast search methods for large scale speech recognizers. In addition, we opened a new venue for a new pattern recognizer training method that does not require hyper-parameters but is based on Bayes boundary-ness, which is defined using the ambiguity in classification decision around estimated class boundaries.

研究分野：人間情報学(知覚情報処理)，知能情報学

キーワード：パターン認識 識別学習 最小分類誤り学習 カーネル法 ニューラルネットワーク 音声認識 機械学習

1. 研究開始当初の背景

パターン認識器学習の究極の目標は、与えられたパターン標本に対する分類誤り確率値の最小状態(ベイズリスク状態)をもたらず認識器パラメータ状態(以降、このパラメータ状態を最小分類誤り確率状態と呼ぶ)の実現にある。しかし、無限個標本上で求められるべきこの最小分類誤り確率状態を、有限個の標本しか利用できない現実において正確に推定することは容易ではない。

一方、パターン認識器は、基本的に前段の特徴抽出器と後段の分類器とから成る。特徴抽出器は、入力パターンを正確な分類に適した特徴空間に写像し、分類器は、その空間内において最小分類誤り確率状態の推定を行う。明らかに、特徴空間は、それが持つ分類誤り確率値の最小値自体が小さいほど望ましい。

そうした特徴空間の実現を予感させる手法として、サポートベクターマシン(SVM: Support Vector Machine)に代表されるカーネル写像や深層ニューラルネットワーク(DNN: Deep Neural Network)が注目されるようになった。しかし、例えばSVMにおけるガウスカーネルのカーネル幅の不適切な設定が、最小分類誤り確率値の偏った推定を引き起こすなど、これらの手法も望ましい特徴表現を保証するものではない。また、多くの場合、SVMもDNNも、音声パターンのような時間構造を持つ可変長パターンを十分適切に写像できるわけではない。これらの問題点を克服し、最小分類誤り確率値がより小さな特徴空間とその空間における最小分類誤り確率状態の優れた推定を可能とする学習法の開発が望まれていた。

2. 研究の目的

前項の背景を踏まえ、本研究は、分類誤り確率の最小値状態と一貫した学習基準を用いる最小分類誤り(MCE: Minimum Classification Error)学習法を基盤とし、さらにそのMCE学習の適用範囲を分類器のみならず特徴抽出器まで拡大する「識別的特徴抽出」^{*1)}の考え方に則り、複数の具体的な副課題の解決を通して最小分類誤り確率状態の達成を目指すものであった。

*1) Bien, A., Katagiri, S., Juang, B.-H.; "Pattern Recognition Using Discriminative Feature Extraction," IEEE Trans. SP, vol. 45, no. 2, pp. 500-504 (1997).

3. 研究の方法

最小分類誤り確率状態の推定は、分類対象の標本が無限個存在し、それらの標本が、異なるクラスに属するにもかかわらず特徴空間のある点において重なり合い得ることを前提とする。しかし、実際の認識器学習においては、標本数は有限で、さらに全く同一の標本が複数あることはめったになく、上記の前提はほとんど成り立たない。その結果として、前述したような最小分類誤り確率値の偏った

過小推定が頻発する。従って、パターン認識器の学習は本質的に、この有限個標本しか利用できない現実と無限個標本から成る理想との溝を埋める必要がある。

上述の溝を埋める主要な方策の1つは、標本を学習用と検証用、試験用とに3分割し、基本的に検証用標本を用いて最適化するハイパーパラメータ(例:SVMのカーネル幅)値を設定した上で、学習用標本上でパラメータ(例:SVMやDNNに用いられる重み係数)を最適化するものである。なお、パラメータの学習もハイパーパラメータの学習も検証用データ上の分類精度が高くなるように行われる。この方策は、パラメータ学習とその結果の評価(分類精度の算出)とに異なる標本群を用いることで、疑似的に上記の溝を埋めようとするものと見做し得る。なお試験用標本は、こうした学習と検証とも独立した評価用に用いる。また、注目すべきもう1つの方策は、幾何マージンを最大化することである。パラメータ学習において、幾何マージンをできるだけ大きくすることは、実際の学習用標本とは異なる学習用標本を仮想的に生成することで上記の溝を埋めようとするものと解釈できる。

無限個標本を用いる学習が理想であることから明らかなように、利用可能な有限個の標本群を3分割し、それぞれの群における個数を減らすことは避けるべきである。また、幾何マージンを大きくすることは、最小分類誤り確率状態の前提となる標本の重なりを無視しているようで、これもまた必ずしも合理的とは思えない。

本研究では、上段落のような問題意識を持ちつつ、まずは既存の方策の利用を優先し、利用可能な標本群を3分割(検証用群を含む)し、また、報告者ら自身が開発した大幾何マージン最小分類誤り(LGM-MCE: Large Geometric Margin Minimum Classification Error)学習法とカーネル最小分類誤り(KMCE: Kernel Minimum Classification Error)学習法をSVM及びDNNと共に用い、次の6つの副課題に焦点を合わせて研究を行った。

- (1) 可変長パターンのための幾何マージンの導出
- (2) 可変長パターンのためのLGM-MCE学習法の開発
- (3) 可変長パターン分類のためのKMCE学習法の開発
- (4) MCE基準に基づくDNNを用いる識別的特徴抽出法の開発
- (5) 超多クラス分類課題のためのMCE学習を利用した高効率解探索法の開発
- (6) 最適化用ハイパーパラメータを要しないMCE学習法の開発

4. 研究成果

- (1) 可変長パターンのための幾何マージンとそれを用いたLGM-MCE学習法との開発

本副課題における究極の目標は、次元数が固定されないパターンどうしの位相関係などを新たに構築し、その結果を用いて可変長パターン分類のための LGM-MCE 学習法を開発することであった。そうした新しいパターン空間の構築は、当初案じていたように容易ではなく、近似的ではあるものの実際的な動的時間軸伸縮 (DTW: Dynamic Time Warping) 法を用いる幾何マージンの導出と、その結果を用いた LGM-MCE 学習法の導出を行った[論文(2)等(以降、「論文」と「発表」はそれぞれ5.における「雑誌論文」と「学会発表」を指す。)]。詳細は省略するが、新しく導出した幾何マージンは、若干の仮定をした上で、以下の通りとなる。

$$\rho \approx (-1) \times \frac{\sqrt{T^T d_y(\mathbf{X}^T; \mathbf{A})}}{2 \sqrt{\sum_{t=1}^{T^+} \left\| \mathbf{r}_{z(\varphi_{y,t}, \theta_{y,t})} - \mathbf{r}_{z(\varphi_{y^*,t}, \theta_{y^*,t})} \right\|^2}}$$

導出した幾何マージンを用いた可変長パターンのための LGM-MCE 学習法の有効性、即ち最小分類誤り確率状態の優れた推定力は、複数の音声データセットを用いた、幾何マージン最大化が保証されない関数マージン (FM: Functional Margin) MCE 法との比較実験を通して、表1に示すように明らかにした[論文(2)]。表中、Closed Test と Open Test は、それぞれ学習用標本と試験用標本に対する分類率である。両 Test 間の差が小さく大きな Open Test の結果が、望ましい推定に相当する。

表1 TIMIT データにおける分類率 (%)。

	FM-MCE	LGM-MCE
Closed Test	73.89	73.09
Open Test	66.59	67.76

(2) 可変長パターン分類のための KMCE 学習法の開発

KMCE 法の定式化は、本研究の開始以前に行っていたものの、その有用性の検証は不十分なままであった。そこでまず、カーネル法を代表し、その高い分類性能が広く認められている SVM (多クラス問題を扱うため、特に多クラス用の MSVM (Multi-class Support Vector Machine) を用いた) との性能比較を精査した[発表(4)等]。

複数のデータセットを用い、MSVM 法で構築した分類器中のカーネル数を減らしつつ、KMCE 法と MSVM 法との分類性能を比較した。MNIST データに対する結果を表2に示す。詳細は省略するが、表中 Size はカーネル数(分

類器の規模)であり、TRN と VAL, TST はそれぞれ、学習用標本と検証用標本、試験用標本に対する分類率である。[Size=807]の分類器は MSVM 法で学習して得たものである。表にも示されているように、KMCE 法は、カーネルを減らしても高い分類性能を維持し得ること、即ち MSVM 法のスケーラビリティ問題を大幅に改善し得ることを明らかにした。

また、カーネル写像の数理的な分析を通し、MSVM 法によって得られるカーネル重みの値の観察を通して、学習標本とクラス境界との幾何学的位置関係及び分類の難易度を推定し得ることをも、理論的かつ実験的に実証した。

表2 MNIST データに対する MSVM 法と KMCE 法との分類率 (%) の比較。

T	Size	MSVM			KMCE		
		TRN	VAL	TST	TRN	VAL	TST
No-Red	807	100	91.38	92.13	100	91.13	91.94
0.1	648	100	91.41	92.16	100	91.14	91.91
0.2	456	100	90.97	91.66	100	90.20	90.99
0.3	275	93.5	84.27	84.52	100	89.45	90.33
0.4	152	53.5	50.16	49.64	99.9	88.88	89.61
0.5	80	31.2	30.93	30.33	99.6	88.37	89.13

上記のように MSVM のスケーラビリティ問題を克服し得る KMCE 法の可変長パターン分類における評価を行うとき、それに競合する SVM との比較実験を避けては通れない。しかし、まさにスケーラビリティ問題が原因し、一定以上の規模のデータセットを用いて現実的な時間内に MSVM 学習を行うことは極めて困難であることが判明し、比較実験の実施を断念せざるを得ないこととなった。なお、スケーラビリティ問題を多少でも軽減するアプローチとして、カーネル計算に先立ってパターン長を正規化する手法の動作検証も行った[発表(1)]。

(3) MCE 基準に基づく DNN を用いる高識別的特徴抽出法の開発

本副課題に関しては、主に話者適応学習 (SAT: Speaker Adaptive Training) 法の考え方を DNN-HMM 音声認識器の話者適応課題に適用する枠組みにおいて研究を進めた[論文(4)等]。ここで HMM は隠れマルコフモデル (Hidden Markov Model) である。


DNN を用いる音声認識技術には多くの関心が寄せられ、競争も激しい。そのため、他研究との比較が重要となる。この点を優先し、本研究においては、競合研究と同様の学習基準 (MCE 基準を近似するクロスエントロピー基準) を採用した上で、DNN 内部における新しい情報表現法の構築に研究の主眼を置いた。

研究ではまず、SAT に基づく DNN-HMM 音声認識器の学習法を提案した。提案手法は、均一な構造を持つ標準的な DNN に代えて各話者に対応する話者モジュールを持つ DNN を採用し、認識器の学習段階において学習用話者データ毎に話者モジュールを入れ替えて学習

を行うものである．図 1 に，話者モジュールを交換しながら DNN の学習を行う過程を図解する．図では DNN の第 2 層を話者モジュール層とし，学習用話者毎にモジュールを交換している．

評価実験では，教師付き適応のみならず教師無し適応においても評価を行い，そのいずれにおいても，モジュール構造を持たない標準的な DNN を用いる DNN-HMM 音声認識器に対する提案手法の優位性を実証した．

図 1 SAT 型 DNN-HMM 音声認識器の学習．



また，最小分類誤り確率状態の推定力に関する決定要因の一つである正則化を適切に制御することを目指し，線形変換ネットワーク (LTN: Linear Transformation Network) を話者モジュールに挿入することによって，提案した DNN-HMM 音声認識器のための SAT 型学習法の改良も行った[発表(8)]．

表 3 は，LTN 型話者モジュールを用いる手法 (表中の SA-SAT-L) と，その基礎となった図 1 の手法 (表中の SA-SAT-SD)，標準的な DNN を用いる手法 (表中 SA-SI-SD) に関する，Ted Talks 音声データを用いた話者適応実験における試験用標本群に対する単語誤分類率 (最小分類誤り確率値の推定値に対応) をまとめている (表中の他の欄については省略)．表中， l_{SD} は話者モジュールを挿入した DNN の層番号である．表から，話者モジュールの位置 (層) にかかわらず，提案手法，特に LTN 型手法が優れた結果をもたらしたことがわかる．また，話者モジュールは DNN の内部に置くほど適応効果が大きくなるという興味深い傾向も読み取ることができる．

表 3 SAT 型 DNN-HMM 音声認識器の話者適応における単語誤分類率 (%) ．


l_{SD}	SI-DNN	SA-SI-SD	SA-SAT-SD	SA-SI-L	SA-SAT-L
1	26.4	20.0	18.9	20.8	20.5
2	26.4	19.0	18.2	19.3	17.2
3	26.4	18.7	18.0	19.0	17.5
4	26.4	19.0	18.4	19.0	17.5
5	26.4	19.5	19.0	19.2	18.0

更に，DNN の内部情報表現力の効率化を目指し，LTN 型話者モジュールを持つ DNN の重み行列のランクに基づいて過剰な情報表現

力を削減する方法[発表(7)等]や，DNN 内部の層の重みに Group Lasso と呼ばれる正則化法を用いて学習と同時にノード間接続を選択・集約する方法[発表(5)等]を提案した．ランクに基づく方法では，元々各層に 2048 ノードを持つ DNN の重み行列を，そのわずかに 6.25%にまで削減した上で話者適応力をさらに改善し得ることを明らかにした．また，Group Lasso 正則化を用いる方法からは，分類課題あるいはデータに対して本質的に必要となる DNN の規模と構造 (結果的にその情報表現力) をほぼ十分な水準で自動的に抽出し得ることを明らかにした．

最小分類誤り確率状態の推定がより困難になる適応学習のために補助情報ネットワークを用いる解決法も開発した (図 2) [論文(1)]．CHiME3 などの 3 種の音声認識課題を通して，本手法が，わずか 1 発話程度の極めて短い適応標本を用いるだけで高速に発話者や発話環境に適応可能であることを明らかにした．

図 2 補助情報ネットワークを用いる DNN 音声認識器の高速適応学習手続き．



(4) 実時間処理あるいは全数探索が困難な超多クラス分類課題のための MCE 学習を利用した高効率探索法の開発

標本の正確なクラス情報が得られない困難な学習環境において，分類結果の型，即ち正分類と，置換誤り，挿入誤り，脱落誤りとの生起確率から単語正解率等を正確に推定する手法を開発した．また，MCE 基準と関係がある条件付きマルコフ場を用いて推定結果を製錬することによって，本手法が正解所属クラス情報を用いた評価結果に極めて近い評価を行い得ることも明らかにした[論文(3)等]．

更に，同様の学習環境にある教師無し話者適応課題において，MCE 基準を含む統一的識別学習基準から導かれる差分最大相互情報量 (dMMI: differenced Maximum Mutual Information) 基準を用いた線形回帰適応学習の有用性も明らかにした[論文(5)]．


(5) 最適化用ハイパーパラメータを必要としない MCE 学習法の開発

利用可能な標本群の分割が最小分類誤り確率状態の推定に及ぼす (否定的な) 影響の

精査を通し、ハイパーパラメータの設定に必須と考えられてきた検証用標本の利用そのものを避ける、新しいアプローチからこの根源的な問題に迫るべきであろうと、発想を転換した[発表(9)等]。そして、その延長として「ハイパーパラメータのみならずパラメータに関しても、それらの学習の真の目標は、分類誤り確率の最小値の推定にあるのではなく、その最小値状態に対応するクラス境界（ベイズ境界）が満たすべき必要十分条件、即ち『ベイズ境界は、その境界上の全ての点において境界を構成する2つのクラスの事後確率が等しく（分類判断における曖昧性が最大であり）、非ベイズ境界においては、その均衡が成り立たない』の成否を直接評価することにある。」との理解を得るに至った[発表(2)]。

本手法を用いて得た評価結果を図3に示す。用いたパターンは16次元の固定次元特徴ベクトルであり、分類器は2クラス用SVM、最適化対象のハイパーパラメータはSVMにおけるガウスクERNELのカーネル幅（図中の横軸）である。図中、緑の曲線は慎重に推定した分類誤り確率の推定値であり、その最小値が理想的な最小分類誤り確率状態に対応する。また、図中の青の曲線は、本手法による「ベイズ境界らしさ」の指標値であり、その値が小さいほど大きなベイズ境界らしさを示す。図から、これらの2つの曲線が優れた類似を示し、提案した指標が、カーネル幅の適切な設定（青の曲線の底部に対応するカーネル幅）を通してベイズ境界状態を正確に推定し得ることがわかる。

図3 パターン特徴空間においてベイズ境界らしさを評価するアルゴリズムの動作例。



5. 主な発表論文等

（研究代表者、研究分担者及び連携研究者には下線）

〔雑誌論文〕(計 6 件)

- (1) Marc Delcroix (第1著者), Atsunori Ogawa (第3著者), 他3名; “Context Adaptive Neural Network Based Acoustic Models for Rapid Adaptation,” IEEE/ACM Transactions on Audio, Speech, and Language Processing, 査読有り, 26巻, 5号, 2018, 895-908, DOI: 10.1109/TASLP.2018.2798821.
- (2) 松廣達也 (第1著者), 渡辺秀行 (第6著者), 片桐滋 (第7著者), 他5名; “可変長時系列パターン分類のための大幾何マージン最

小分類誤り学習法の提案とその実験の評価,” 情報処理学会論文誌, 査読有り, 59巻, 4号, 2018年, 1295-1308.

- (3) Atsunori Ogawa (第1著者), Atsushi Nakamura (第3著者), 他1名; “Estimating Speech Recognition Accuracy Based on Error Type Classification,” IEEE/ACM Transactions on Audio, Speech, and Language Processing, 査読有り, 24巻, 2016年, 2400-2413, DOI: 10.1109/TASLP.2016.2603599.
- (4) Tsubasa Ohiai (第1著者), Hideyuki Watanabe (第3著者), Shigeru Katagiri (第7著者), 他5名; “Speaker Adaptive Training Localizing Speaker Modules in DNN for Hybrid DNN-HMM Speech Recognizers,” IEICE Transactions on Information & Systems, 査読有り, E99-D巻, 10号, 2016年, 2431-2443, DOI: 10.1587/transinf.2016SLP0010.
- (5) Marc Delcroix (第1著者), Atsunori Ogawa (第2著者), Atsushi Nakamura (第5著者), 他2名; “Differenced Maximum Mutual Information Criterion for Robust Unsupervised Acoustic Model Adaptation,” Computer Speech and Language, 査読有り, 36巻, 2016年, 24-41, DOI: 10.1016/j.csl.2015.08.001

〔学会発表〕(計 39 件)

- (1) 山田浩嗣 (第1著者), 渡辺秀行 (第3著者), 片桐滋 (第5著者), 他2名; “時系列パターンの時間長正規化を伴うカーネル最小分類誤り学習法,” 2018年電子情報通信学会総合大会, 2018年3月20日, 東京電機大学 東京千住キャンパス (東京都, 足立区)。
- (2) David Ha (第1著者), Hideyuki Watanabe (第4著者), Shigeru Katagiri (第5著者), 他3名; “A Classification-Uncertainty-Based Criterion for Classification Boundary Selection,” IEICE Technical Report PRMU2017, 2018年2月20日, 和歌山大学 (和歌山県, 和歌山市)。
- (3) Tsubasa Ochiai (第1著者), Shigeru Katagiri (第3著者), 他1名; “Does Speech Enhancement Work with End-To-End ASR Objectives?: Experimental Analysis of Multichannel End-To-End ASR,” 27th IEEE International Workshop on Machine Learning for Signal Processing, 2017年9月28日, 国際文化会館 (東京都, 港区) DOI: 10.1109/MLSP.2017.8168188.
- (4) Ryoma Tani (第1著者), Hideyuki Watanabe (第2著者), Shigeru Katagiri (第3著者), 他1名; “Compact Kernel Classifiers Trained with Minimum Classification Error Criterion,” 27th IEEE International Workshop on Machine

Learning for Signal Processing, 2017 年 9 月 27 日, 国際文化会館 (東京都, 港区) DOI: 10.1109/MLSP.2017.8168184.

- (5) Tsubasa Ochiai (第 1 著者), Hideyuki Watanabe (第 3 著者), Shigeru Katagiri (第 4 著者), 他 1 名; "Automatic Node Selection for Deep Neural Networks Using Group Lasso Regularization," 2017 IEEE International Conference on Acoustics, Speech and Signal Processing, 2017 年 3 月 8 日, Hilton New Orleans Riverside (米国, ニューオーリンズ市).
- (6) Takuya Yoshioka (第 1 著者), 他 3 名; "Noise Robust Speech Recognition Using Recent Developments in Neural Networks for Computer Vision," 2016 IEEE International Conference on Acoustics, Speech and Signal Processing, 2016 年 3 月 24 日, Shanghai International Convention Center/Oriental Riverside Hotel (中国, 上海市).
- (7) Tsubasa Ochiai (第 1 著者), Hideyuki Watanabe (第 3 著者), Shigeru Katagiri (第 6 著者), 他 3 名; "Bottleneck Linear Transformation Network Adaptation for Speaker Adaptive Training-Based Hybrid DNN-HMM Speech Recognizer," 2016 IEEE International Conference on Acoustics, Speech and Signal Processing, 2016 年 3 月 23 日, Shanghai International Convention Center/Oriental Riverside Hotel (中国, 上海市).
- (8) Tsubasa Ochiai (第 1 著者), Hideyuki Watanabe (第 3 著者), Shigeru Katagiri (第 6 著者), 他 3 名; "Speaker Adaptive Training for Deep Neural Networks Embedding Linear Transformation Networks," 2015 IEEE International Conference on Acoustics, Speech and Signal Processing, 2015 年 4 月 21 日, Brisbane Convention & Exhibition Centre (豪州, ブリスベーン市).
- (9) 白石裕之 (第 1 著者), 渡辺秀行 (第 2 著者), 片桐滋 (第 3 著者), 他 3 名; "大幾何マージン最小分類誤り学習法におけるデータ分割法と未知標本耐性の関係について," 電子情報通信学会「パターン認識・メディア理解」研究会, 2015 年 1 月 23 日, 奈良先端科学技術大学院大学 (奈良県, 生駒市).
- (10) Yotaro Kubo (第 1 著者), Atsushi Nakamura (第 4 著者), 他 2 名; "Restructuring Output Layers of Deep Neural Networks using Minimum Risk Parameter Clustering," 15th Annual Conference of ISCA (INTERSPEECH2014), 2014 年 9 月

14 日, MAX Atria@ Singapore EXPO (シンガポール共和国, シンガポール).

6. 研究組織

(1) 研究代表者

片桐 滋 (KATAGIRI SHIGERU)
同志社大学・理工学部・教授
研究者番号: 40396114

(2) 研究分担者

渡辺 秀行 (WATANABE HIDEYUKI)
株式会社国際電気通信基礎技術研究所・脳情報通信総合研究所・連携研究員
研究者番号: 40395091

中村 篤 (NAKAMURA ATSUSHI)
名古屋市立大学・大学院システム自然科学研究科・教授
研究者番号: 50396206

堀 貴明 (HORI TAKAAKI)
日本電信電話株式会社 NTT コミュニケーション科学基礎研究所・メディア情報研究部・主任研究員
研究者番号: 20396211

小川 厚徳 (OGAWA ATSUNORI)
日本電信電話株式会社 NTT コミュニケーション科学基礎研究所・メディア情報研究部・主任研究員
研究者番号: 90527516

吉岡 拓也 (YOSHIOKA TAKUYA)
日本電信電話株式会社 NTT コミュニケーション科学基礎研究所・メディア情報研究部・研究主任
研究者番号: 40466404

デルクロア マーク (DELCROIX MARC)
日本電信電話株式会社 NTT コミュニケーション科学基礎研究所・協創情報研究部・主任研究員
研究者番号: 70793339