

# 学習済みモデルの特徴ベクトルに基づく 未知個体への対応を考慮した地域猫の個体分類

永尾 浩太<sup>†</sup> 服部 峻<sup>††</sup> 宮城 茂幸<sup>††</sup>

<sup>†</sup> 滋賀県立大学大学院工学研究科電子システム工学専攻 〒 522-8533 滋賀県彦根市八坂町 2500

<sup>††</sup> 滋賀県立大学先端工学研究院 〒 522-8533 滋賀県彦根市八坂町 2500

E-mail: <sup>†</sup>to23knagao@ec.usp.ac.jp, <sup>††</sup>{hattori.s,miyagi.s}@e.usp.ac.jp

**あらまし** 不幸な猫の発生を防ぐ取り組みとして、地域猫活動が行われている。活動を円滑に進めるためには各個体を正確に把握する必要があるが、首輪やタグの装着が難しい場合も多い。そこで地域住民が日常的に撮影する画像を用いて個体識別ができれば、負担の少ない有効な把握手法となる。機械学習による猫の個体識別の研究の多くは学習時に想定した既知個体のみを識別の対象としている。しかし、実際の地域環境においては未知個体が存在する可能性を考慮する必要がある。本稿では、地域猫を対象とし、既知個体の識別に加えて未知個体の判別を同時に行うことを目指す。まず既知個体を学習したモデルを作成し、それを特徴抽出器として用いることにより既知個体画像および未知個体画像の特徴ベクトルを抽出する。その後、特徴ベクトル間の類似度を算出し、設定した閾値により既知個体と未知個体の分類を行う。

**キーワード** 地域猫, 機械学習, 個体識別, 分類, オープンセット認識

## 1 はじめに

現代社会において、引き取り手が見つからず行き場がなくなり殺処分されてしまう猫が存在する。環境省の統計 [1] によると、日本国内における猫の殺処分数は平成 16 年度には 238,929 匹、令和 5 年度には 6,899 匹が殺処分されており、年々減っているものの依然として多くの命が失われている。

そのような不幸な猫を生まない・減らすための活動として地域猫活動が行われている。地域猫活動とは、地域住民が主体となって不妊去勢手術 (TNR) や適切な餌やり、糞尿の管理、見守りなどを行うことで、飼い主のいない猫を増やさないことや、人と猫が共生できる社会をつくることを目的とする活動である。一方で猫によるトラブルも発生しており、地域猫活動を快く思わない住民もいる。地域猫活動を円滑に進めることや、地域住民の理解を得るためには猫の適切な管理が必要である。

猫の管理には各個体の把握が重要であるが、首輪やタグなどの物理的な装置の装着が難しい場合もある。そこで、地域住民がスマートフォン等のカメラを用いて日常的に撮影するような画像を用いて個体識別ができれば、負担の少ない有効な管理手法となる。

野生の猫や飼い猫を対象とした画像を用いた機械学習による個体識別の研究は行われているが、多くは学習時に想定した個体のみを対象として再識別を行っており、学習していない猫への対応は十分に検討されていない。地域においてはこのような未知の猫がいるという可能性が考えられる。

そこで本研究では、地域猫を対象として猫の個体分類を行い、既知の猫の個体識別を行うと同時に、未知の猫を未知として判別することを目指す。アプローチとしては、学習済みモデルによって抽出された特徴ベクトル間の類似度に基づいて分類を行

う。具体的には、まず初めに既知の猫についての学習済みモデルを作成する。次にそのモデルを特徴抽出器として用いて、学習で使用した画像の特徴ベクトルを得た後、各個体を表すベクトルとして個体ごとに平均ベクトルを求める。識別対象の画像も同様に、特徴抽出器を用いて特徴ベクトルを求める。そして、そのベクトル間で類似度を求める。類似度について閾値を設定し、それにより既知個体と未知個体の分類を行う。なお、対象とする画像は、スマートフォン等のカメラで撮った画像に対し物体検出モデルを用いて猫を検出したものとし、可能ならば背景の削除を行ったものを想定とする。

以下、本稿の構成について述べる。2 章では本研究に関連する研究や技術について述べる。次に、3 章で提案手法の詳細について述べる。そして、4 章において提案手法の評価実験を行い、最後に 5 章で結論および本研究の今後の展望について述べる。

## 2 関連研究・技術

本章では、本研究の関連研究と関連技術について述べる。

### 2.1 関連研究

Trein らの研究 [2] では、中国の都市部に生息する野良猫を対象とした個体識別の自動化を目的に、Siamese Networks を用いて個体識別を行った。Siamese Networks は、2 つの同一のネットワークを用いて入力データの類似性を学習するネットワークで、この研究では EfficientNetB0, MobileNet, VGG16 などをバックボーンとして利用し比較検討している。またライブ配信映像から個体画像を抽出し、猫の正面と上部の 2 つの視点を含むデータセットを構築している。

Li らの研究 [3] では、ペットショップでの猫の管理や野生の猫

の監視の改善のため、深層学習を用いた猫の個体識別における様々なニューラルネットワークモデルの比較を行った。この研究では ImageNet 学習済みの ResNet や、DenseNet, EfficientNet, ConvNeXt, Siamese Networks といったモデルに対して体系的に比較しており、転移学習を行ったモデルとの比較も行っている。

Yang らの研究 [4] では、オーストラリアの外来種である野生猫のモニタリングや生態系保護のため、YOLOv5 を用いてカメラトラップ画像から得られた不均衡なデータを使用して個体識別を行った。この研究では個体ごとの画像が不均衡な問題に対し、データ増強や転移学習を用いることでモデルの汎化性を高めている。

Caquilpan の研究 [5] では、不規則な姿勢や向きの変化などが伴うカメラトラップ画像において、多様な条件下においても野良猫を正確に識別するため姿勢情報を活用し、猫の体の部位パーツに基づいて個体識別を行った。この研究では、Liu らの研究 [6] で提案されたアムールトラの再識別のためのアムールトラの身体パーツに基づいて作られた PPGNet と呼ばれるネットワークを参考にしており、猫の画像の特徴に合わせて改良した PPGNet-Cat という猫の再識別のためのネットワークモデルを提案している。

これらの研究は、猫の個体識別のため様々なニューラルネットワークモデルの比較や検証、追求などを行っている。しかしこれらの研究を含めた多くの研究は、モデルに対して学習を行った猫のみを想定しており、学習を行っていない猫への対応は十分に考慮できていない。本研究では学習を行った既知の猫に加え、学習を行っていない未知の猫にも対応するため、未知の猫を既知の猫に分類せず未知として判別する。

## 2.2 関連技術

### 2.2.1 YOLO

YOLO (You Only Look Once) [8] は Redmon らによって提案された、リアルタイム性に優れた物体検出モデルである。YOLO は画像全体に対して、物体の検出とクラス予想を同時に行うことができるため高速に動作する。Ultralytics 社 [7] がライブラリとして提供しており、YOLOv5, YOLOv8, YOLO11 は同社が開発したバージョンである。本研究では、この中で最も新しく性能が向上されたモデルである YOLO11 を、猫の検出やセグメンテーションによる背景削除などのデータ作成の際に用いた。

### 2.2.2 ResNet

ResNet [9] は He らによって提案された、深い層を持つ CNN (畳み込みニューラルネットワーク) の一種である。従来の CNN モデルが抱えていた、層を深くしても学習が進まなくなる勾配消失問題を解決することで、ネットワークの深層化を可能にした。ResNet は標準的な CNN モデルで、コンピュータビジョンのタスクに広く使用されており、他のモデルや技術と比較する際によく用いられる。また、ResNet には層の数に応じて ResNet-18, 34, 50, 101, 152 など様々なバリエーションが存在する。本研究では学習のための CNN として速度と精度のバラ




図1 提案手法のシステム概略図

ンスのとれた ResNet-50 を用いた。

### 2.2.3 オープンセット認識

オープンセット認識 (OSR: Open Set Recognition) は機械学習において、モデルが学習時に与えられた既知クラスを正しく分類するとともに、学習時には存在しなかった未知クラスのデータを「未知」と検出し識別・拒否することを目的とする。従来のクローズドな集合 (closed-set) では、推論時に与えられるデータは全て既知クラスに属すると仮定されるが、オープンセット認識では未知のクラスが混在する状況を想定する。

未知クラスを検知する手法の1つとして、閾値を設定し既知クラスに対する予測確率や信頼度が、その閾値以下の場合未知と判断する方法が挙げられる。OpenMax [10] は Bendale らによって提案された手法で、未知クラスへの対応を目的として、ネットワークの最終層の SoftMax を拡張している。Weibull 分布を用いた処理を行い、入力を単に既知クラスの中で予測するのではなく、未知クラスに属する可能性を考慮して評価を行う。

## 3 提案手法

本章では、本研究の提案手法について述べる。図1にシステムの流れを示す。システムは主に、猫の検出と画像処理、特徴抽出器の作成、画像のベクトル抽出、類似度評価の段階に分かれている。各節でその詳細について述べる。

### 3.1 猫の検出と画像処理

入力された猫画像に対して、物体検出モデル YOLO11 を用いてバウンディングボックスを作成し猫の検出を行う。検出後、バウンディングボックスが画像の中心に来るように配置。背景情報を少しでも減らすためバウンディングボックス部分以外を黒くなるようにし、画像全体を正方形に加工する。その後、可能な画像は更に背景の影響を減らすため、セグメンテーションにより猫以外の部分が黒くなるように加工する。図2にその処




図 2 猫の検出と画像処理の例

理例を示す。

### 3.2 特徴抽出器の作成

各猫画像をその特徴を捉えたベクトルへと変換するため、既知の猫とした画像を用いて CNN を学習させ特徴抽出器を作成する。なお、未知の猫とする画像は CNN には学習させずテスト時のみ用いる。ここで学習を行った CNN は直接画像を分類するためには用いず、特徴抽出のために用いる。

### 3.3 画像のベクトル抽出

3.2 節で作成した特徴抽出器を用いて、各個体のベクトル抽出と識別対象画像のベクトル抽出を行う。各個体のベクトル抽出では、まず初めに学習に用いた全画像を特徴抽出器に再度入力し画像のベクトル化を行う。次に各個体ごとに特徴ベクトルの平均を求め、そのベクトルを各個体の代表ベクトルとする。識別対象画像も同様に、識別対象としたい画像を作成した特徴抽出器に 1 度入力し画像のベクトル化を行う。

### 3.4 類似度評価

3.3 節で求めた各個体のベクトルと識別対象画像のベクトルを用いて類似度を求め、既知個体や未知個体の分類を行う。まず初めに、既知猫である各個体のベクトルと、判別を行いたい識別対象画像のベクトル間でそれぞれ  $\cos$  類似度を計算する。次に、求めた各  $\cos$  類似度の中での最大値を求める。その後、既知・未知の判別のための閾値を設定し、これを用いて以下のように分類や行う。

- 最大  $\cos$  類似度が閾値以上の場合、既知猫として  $\cos$  類似度をとったベクトルに該当する猫へと分類する。
- 最大  $\cos$  類似度が閾値未満の場合、既知猫へ分類せず未知猫と分類する。

## 4 評価実験

本章では、本研究の評価実験における実験方法と実験結果について述べる。

### 4.1 実験方法

本実験の準備としてまず初めにデータセットの作成を行った。画像は野外の猫をカメラで撮ったものを想定し、今回はデータ収集の効率のため、猫の動画を撮った後、動画から画像を切り出し集めた。その後、3 章で述べた猫の検出と画像処理を行った。最終的にデータセットとして猫画像を 6 個体（各個体約

表 1 使用した画像の内訳

個体名	画像数
mike1	206
saba	204
mike2	200
tora1	207
tora2	209
siro	202
合計	1228




図 3 使用した猫画像の例

200 枚) 計 1228 枚用意した。内訳を表 1 に示す。この 6 個体を既知 5 体未知 1 体に分け、学習: 検証: テスト = 6:2:2 に分割して使用した。使用した猫画像の例を図 3 に示す。

学習では CNN として ImageNet 学習済みの ResNet-50 を用いた。CNN への入力の際、画像の画素は  $224 \times 224$  ピクセルとした。バッチサイズ 32, エポック数 10, 学習率 0.001, 損失関数は交差エントロピー誤差を用いた。また、特徴抽出器として用いる際の特徴ベクトルの次元は 2048 次元とした。

実験は、初めに未知個体を想定せずに既知猫 5 体で学習した時の分類、既知猫 6 体で学習した時の分類を行った。次に既知猫 5 体を学習したモデルを特徴抽出器として用い、提案手法に基づき、 $\cos$  類似度の閾値を変化させ既知猫の分類と未知猫の判定を行った。

また、提案手法以外に、SoftMax, OpenMax, マハラノビス距離を用いて、各々閾値を活用し同様に実験を行った。なおマハラノビス距離は、ユークリッド距離とは異なり各変数の相関を考慮した距離のことを言う。

### 4.2 実験結果

#### 4.2.1 提案手法の実験結果

使用した画像のうち、siro を未知個体として扱い実験を行った。未知個体を想定せずに既知猫 5 体で学習した時の検証時の正解率は 99.51%, テスト時の正解率は 97.10% であり、分類結果は表 2 に示す通りとなった。同様に、既知猫 6 体で学習した時の検証時の正解率は 99.18%, テスト時の正解率は 97.60% であり、分類結果は表 3 に示す通りとなった。正解率はどちらも 97% 以上となり高い正解率を出した。これは事前の処理により、モデルが画像の特徴表現を上手く捉えることができたから

だと考えた。なお、tora1 や tora2 など誤分類された場合もあり、これは対象画像の猫の毛色が似ていたためだと考えた。ただ、モデルの正解率は高く、特徴抽出器として用いるには十分な性能だと考えた。

次に既知猫 5 体を学習したモデルを用いて、提案手法により閾値を様々変えて既知猫の分類と未知猫の判定を行った時の結果を表 4 に示す。最大 cos 類似度の閾値が 0.60 の時、既知個体正解率は 97.61% を記録したが未知個体正解率は 0% であり、全体正解率は 81.60% となった。閾値を大きくすると、閾値 0.90 の時、既知個体正解率が 97.13%、未知個体正解率が 100%、全体正解率が 97.60% となった。既知個体正解率は低くなったが、未知個体正解率は高くなり、全体正解率が最も高くなった。更に閾値を大きくし、閾値 0.95 の時、既知個体正解率が 94.26%、未知個体正解率が 100%、全体正解率が 95.20% となった。未知個体正解率は 100% のまま変わらなかったが既知個体正解率が低くなり、全体正解率も低くなった。これより、閾値を大きくすると既知個体正解率は低くなるが、未知個体正解率は高くなり、どちらかの正解率を高くしようとすると、もう一方の値が低くなるため、閾値を上手く設定することが重要だと考えた。

全体正解率が最も高い、閾値 0.90 の時の分類結果を表 5 に示す。これを見ると、本来既知個体だった画像が一部未知個体へと分類されてしまっていることが確認できる。ただ全体正解率は 97.60% を記録しており、誤分類はあるものの精度が高く分類することができた。これは未知個体が他個体と類似しておらず、類似度の分布が閾値の前後でよく分かれていたからだと考えた。

#### 4.2.2 他手法の実験結果

提案手法以外に、SoftMax と閾値、OpenMax、マハラノビス距離と閾値を用いた方法で実験を行った。各手法で最良時の結果を表 6 に示す。提案手法を用いた場合、全体正解率 97.60%、SoftMax と閾値を用いた場合、全体正解率 88.00%、OpenMax を用いた場合、全体正解率 93.20%、マハラノビス距離と閾値を用いた場合、全体正解率 94.80% となった。SoftMax を用いた時に正解率が最も低くなったが、データが既知クラスにも当てはまらない場合でも確率の合計は 1.0 であるため、未知の場合でも高い確率が割り当てられることがあるからだと考えた。他手法について、提案手法では特徴ベクトル同士で類似度を求め分類していたが、OpenMax は Weibull 分布、マハラノビス距離は変数の相関を用いており、これらの手法は統計分布を考慮している。今回の地域猫データはデータ数が多くなく、単純なモデルでは表せなかったことや、既知個体に未知個体に類似した個体がいなかったため、統計に基づく手法より類似度に基づく提案手法の方が安定したのではないかと考えた。

#### 4.2.3 各個体を未知として扱った時の実験結果

次に、siro 以外の個体も同様に未知個体として扱い、全個体に対し実験を行った。各個体を未知として扱った時の全体正解率の結果を表 7 に示す。提案手法の全体正解率は、saba, siro を未知個体とした時、それぞれ 96.40%、97.60% と他個体、他手法と比べ高い値を記録した。一方、mike1, mike2, tora1, tora2 を未知個体とした時、提案手法の正解率はそれぞれ

表 2 既知猫 5 体の分類結果 (siro 以外)

予測 正解	mike1	saba	mike2	tora1	tora2	正解率
mike1	42	0	0	0	0	1.0000
saba	0	42	0	0	0	1.0000
mike2	0	0	40	0	0	1.0000
tora1	0	0	0	39	3	0.9290
tora2	0	2	0	1	40	0.9300
全体正解率	-	-	-	-	-	0.9710

表 3 既知猫 6 体の分類結果

予測 正解	mike1	saba	mike2	tora1	tora2	siro	正解率
mike1	42	0	0	0	0	0	1.0000
saba	0	42	0	0	0	0	1.0000
mike2	0	0	38	2	0	0	0.9500
tora1	0	0	0	41	1	0	0.9762
tora2	0	0	0	3	40	0	0.9302
siro	0	0	0	0	0	41	1.0000
全体正解率	-	-	-	-	-	-	0.9760

表 4 提案手法の閾値ごとの分類結果 (siro)

閾値	既知個体正解率	未知個体正解率	全体正解率
0.60	0.9761	0.0000	0.8160
0.65	0.9761	0.0244	0.8200
0.70	0.9761	0.1463	0.8400
0.75	0.9761	0.2439	0.8560
0.80	0.9713	0.3415	0.8680
0.85	0.9713	0.5366	0.9000
0.95	0.9426	1.0000	0.9520
1.00	0.0000	1.0000	0.1640

88.80%、92.40%、84.40%、86.80% となり、saba や siro といった個体に比べ低い値となった。また、他手法と比べるとこれらの個体の場合、SoftMax やマハラノビス距離を用いた時の値が提案手法以上の値となった。

これらより、saba や siro といった未知個体がユニークな特徴を持つ場合、特徴空間上で未知個体が独立しているため、類似度を用いる提案手法が優位となったと考えた。一方、mike1, mike2 や tora1, tora2 といった未知個体が既知個体に類似している場合、特徴空間上で未知個体が既知個体と近い位置になるため、境界や分布を重視する他手法の方が優位となったと考えた。

また、saba のマハラノビス距離による正解率は 84.00%、siro の SoftMax による正解率は 88.00% であり、各個体の中で他の全手法と比べ 5% 以上の差をつけて低くなった。提案手法や OpenMax を用いたときの正解率は、各個体の中で他の全手法と比べここまでの差はなく、提案手法や OpenMax は平均を用いているため、安定した正解率を記録したと考えた。

## 5 結論および今後の展望

本稿では、地域猫を対象として猫の個体分類を行い、既知の猫の個体識別を行うと同時に、未知の猫を未知として判別することを目的とした。手法としては、既知個体を学習したモデルを作成し、それを特徴抽出器として用いることにより既知個体

表 5 最良閾値の時の分類結果 (siro)

予測 正解	mike1	saba	mike2	tora1	tora2	un- known	正解率
mike1	42	0	0	0	0	0	1.0000
saba	0	42	0	0	0	0	1.0000
mike2	0	0	40	0	0	0	1.0000
tora1	0	0	0	39	2	1	0.9286
tora2	0	0	0	0	40	3	0.9302
unknown	0	0	0	0	0	41	1.0000
全体正解率	-	-	-	-	-	-	0.9760

表 6 他手法との比較 (siro)

方法	既知個体正解率	未知個体正解率	全体正解率
提案手法	0.9713	1.0000	0.9760
SoftMax	0.9330	0.6098	0.8800
OpenMax	0.9187	1.0000	0.9320
マハラノビス距離	0.9474	0.9512	0.9480

表 7 各個体を未知として扱った時の全体正解率

方法	mike1	saba	mike2	tora1	tora2	siro
提案手法	0.8880	0.9640	0.9240	0.8440	0.8680	0.9760
SoftMax	0.8880	0.9560	0.9320	0.8440	0.8640	0.8800
OpenMax	0.9160	0.9560	0.9240	0.8240	0.8640	0.9320
マハラノビス距離	0.9320	0.8400	0.9280	0.8440	0.8960	0.9480

画像および未知個体画像の特徴ベクトルを抽出した後、特徴ベクトル間の類似度を求め、設定した閾値により既知個体と未知個体の分類を行った。実験の結果、ユニークな特徴を持つ個体の場合、提案手法は高い正解率を記録し、最大で 97.60% となった。一方、類似個体を持つ場合、提案手法に比べ他手法の方が優れた結果を記録した。以上より、他手法の方が優れる場合があるものの、本手法により概ね既知個体と未知個体の分類を行うことができることが分かった。

課題としては、個体が類似している場合明確な分類が難しく、既知個体に類似した未知個体をいかに精度良く未知と分類するかが、性能改善の上で今後重要となる。また、このような閾値を活用する手法を用いる場合、既知個体正解率か未知個体正解率どちらかを上げようとする、もう一方が下がるため、全体正解率を高くするために手動で適切に閾値を設定しないといけないという問題がある。

今後の展望としては、各個体をより識別できるように特定の体の特徴や猫の向きといった情報を用いることや、特徴抽出器の改善の為、Triplet loss や ArcFace 等の距離学習手法を検討したい。また、現在はデータセットの中で特定の 1 個体のみ未知個体として扱っているため、未知個体を複数個体に設定しての実験を行いたい。加えて、実用化としてリアルタイムで動くアプリケーションの開発を目指したい。

## 文 献

- [1] 環境省統計資料「犬・猫の引取り及び負傷動物等の収容並びに処分の状況」、[https://www.env.go.jp/nature/dobutsu/aigo/2\\_data/statistics/dog-cat.html](https://www.env.go.jp/nature/dobutsu/aigo/2_data/statistics/dog-cat.html) (参照 2025/12/9)
- [2] Tobias Trein, Luan Fonseca Garcia, “Siamese Networks for Cat Re-Identification: Exploring Neural Models for Cat Instance Recognition,” arXiv:2501.02112 (2025)

- [3] Mingxuan Li, Kai Zhou, “The Comparison of Individual Cat Recognition Using Neural Networks,” arXiv:2410.02305 (2024)
- [4] Zihan Yang, Richard Sinnott, Qijuhong Ke, James Bailey, “Individual Feral Cat Identification through Deep Learning,” BDCAT’21: 2021 IEEE/ACM 8th International Conference on Big Data Computing, Applications and Technologies, pp.101-110 (2021)
- [5] Victor Caquilpan, “What cat is that? A re-id model for feral cats,” arXiv:2507.11575 (2025)
- [6] Cen Liu, Rong Zhang, Lijun Guo, “Part-Pose Guided Amur Tiger Re-Identification,” 2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW) (2019)
- [7] Ultralytics YOLO Docs, <https://docs.ultralytics.com> (参照 2025-12-30)
- [8] Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.779-788 (2016)
- [9] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun, “Deep Residual Learning for Image Recognition,” 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.770-778 (2016)
- [10] Abhijit Bendale, Terrance E. Boult, “Towards Open Set Deep Networks,” 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.1563-1572 (2016)

表 8 提案手法の閾値ごとの分類結果 (mike1)

閾値	既知個体正解率	未知個体正解率	全体正解率
0.60	0.9615	0.0000	0.8000
0.65	0.9615	0.0000	0.8000
0.70	0.9615	0.0000	0.8000
0.75	0.9615	0.0952	0.8160
0.80	0.9615	0.1905	0.8320
0.85	0.9567	0.3571	0.8560
0.88	0.9471	0.5952	0.8880
0.90	0.9327	0.6667	0.8880
0.95	0.8894	0.8095	0.8760
1.00	0.0000	1.0000	0.1680

表 9 最良閾値の時の分類結果 (mike1)

予測 正解	un- known	saba	mike2	tora1	tora2	siro	正解率
unknown	25	0	6	0	0	11	0.5952
saba	0	42	0	0	0	0	1.0000
mike2	0	0	40	0	0	0	1.0000
tora1	5	0	1	36	0	0	0.8571
tora2	3	0	0	1	39	0	0.9070
siro	1	0	0	0	0	40	0.9756
全体正解率	-	-	-	-	-	-	0.8880

表 10 他手法との比較 (mike1)

方法	既知個体正解率	未知個体正解率	全体正解率
提案手法	0.9471	0.5952	0.8880
SoftMax	0.8990	0.8333	0.8880
OpenMax	0.9087	0.9524	0.9160
マハラノビス距離	0.9471	0.8571	0.9320

表 11 提案手法の閾値ごとの分類結果 (saba)

閾値	既知個体正解率	未知個体正解率	全体正解率
0.60	0.9904	0.0000	0.8240
0.65	0.9904	0.0000	0.8240
0.70	0.9904	0.0238	0.8280
0.75	0.9904	0.1190	0.8440
0.80	0.9904	0.2619	0.8680
0.85	0.9808	0.5952	0.9160
0.90	0.9760	0.7857	0.9440
0.93	0.9615	0.9762	0.9640
0.95	0.9519	1.0000	0.9600
1.00	0.0000	1.0000	0.1680

表 17 提案手法の閾値ごとの分類結果 (tora1)

閾値	既知個体正解率	未知個体正解率	全体正解率
0.60	1.0000	0.0000	0.8320
0.65	1.0000	0.0000	0.8320
0.70	1.0000	0.0000	0.8320
0.75	1.0000	0.0000	0.8320
0.80	1.0000	0.0238	0.8360
0.82	1.0000	0.0714	0.8440
0.85	1.0000	0.0714	0.8440
0.90	1.0000	0.0714	0.8440
0.95	0.9808	0.1190	0.8360
1.00	0.0000	1.0000	0.1680

表 12 最良閾値の時の分類結果 (saba)

予測 正解	mike1	un- known	mike2	tora1	tora2	siro	正解率
mike1	42	0	0	0	0	0	1.0000
unknown	0	41	0	0	1	0	0.9762
mike2	0	1	39	0	0	0	0.9750
tora1	0	4	0	38	1	0	0.8837
tora2	0	3	0	0	40	0	0.9302
siro	0	0	0	0	0	41	1.0000
全体正解率	-	-	-	-	-	-	0.9602

表 18 最良閾値の時の分類結果 (tora1)

予測 正解	mike1	saba	mike2	un- known	tora2	siro	正解率
mike1	42	0	0	0	0	0	1.0000
saba	0	42	0	0	0	0	1.0000
mike2	0	0	40	0	1	0	0.9756
unknown	0	0	2	3	37	0	0.0714
tora2	0	0	0	0	43	0	1.0000
siro	0	0	0	0	0	41	1.0000
全体正解率	-	-	-	-	-	-	0.8406

表 13 他手法との比較 (saba)

方法	既知個体正解率	未知個体正解率	全体正解率
提案手法	0.9615	0.9762	0.9640
SoftMax	0.9615	0.9286	0.9560
OpenMax	0.9471	1.0000	0.9560
マハラノビス距離	0.9615	0.2381	0.8400

表 19 他手法との比較 (tora1)

方法	既知個体正解率	未知個体正解率	全体正解率
提案手法	1.0000	0.0714	0.8440
SoftMax	1.0000	0.0714	0.8440
OpenMax	0.9327	0.2857	0.8240
マハラノビス距離	0.9760	0.1905	0.8440

表 14 提案手法の閾値ごとの分類結果 (mike2)

閾値	既知個体正解率	未知個体正解率	全体正解率
0.60	0.9905	0.0000	0.8320
0.65	0.9905	0.0000	0.8320
0.70	0.9905	0.0000	0.8320
0.75	0.9905	0.0250	0.8360
0.80	0.9857	0.1000	0.8440
0.85	0.9762	0.2750	0.8640
0.90	0.9619	0.5500	0.8960
0.95	0.9524	0.7500	0.9200
0.97	0.9238	0.9250	0.9240
1.00	0.0000	1.0000	0.1600

表 20 提案手法の閾値ごとの分類結果 (tora2)

閾値	既知個体正解率	未知個体正解率	全体正解率
0.60	0.9952	0.0000	0.8240
0.65	0.9952	0.0698	0.8360
0.70	0.9952	0.0698	0.8360
0.75	0.9952	0.1163	0.8440
0.80	0.9903	0.1860	0.8520
0.85	0.9855	0.2326	0.8560
0.90	0.9807	0.2558	0.8560
0.94	0.9662	0.3953	0.8680
0.95	0.9614	0.4186	0.8680
1.00	0.0000	1.0000	0.1720

表 15 最良閾値の時の分類結果 (mike2)

予測 正解	mike1	saba	un- known	tora1	tora2	siro	正解率
mike1	42	0	0	0	0	0	1.0000
saba	0	42	0	0	0	0	1.0000
unknown	0	0	37	2	0	1	0.9250
tora1	0	0	4	38	0	0	0.9048
tora2	0	0	10	0	33	0	0.7674
siro	0	0	2	0	0	39	0.9512
全体正解率	-	-	-	-	-	-	0.9240

表 21 最良閾値の時の分類結果 (tora2)

予測 正解	mike1	saba	mike2	tora1	un- known	siro	正解率
mike1	42	0	0	0	0	0	1.0000
saba	0	42	0	0	0	0	1.0000
mike2	0	0	36	4	1	0	0.8780
tora1	0	0	0	41	1	0	0.9762
unknown	0	0	1	25	17	0	0.3953
siro	0	0	0	2	0	39	0.9512
全体正解率	-	-	-	-	-	-	0.8645

表 16 他手法との比較 (mike2)

方法	既知個体正解率	未知個体正解率	全体正解率
提案手法	0.9238	0.9250	0.9240
SoftMax	0.9571	0.8000	0.9320
OpenMax	0.9095	1.0000	0.9240
マハラノビス距離	0.9714	0.7000	0.9280

表 22 他手法との比較 (tora2)

方法	既知個体正解率	未知個体正解率	全体正解率
提案手法	0.9662	0.3953	0.8680
SoftMax	0.9662	0.3721	0.8640
OpenMax	0.9130	0.6279	0.8640
マハラノビス距離	0.9614	0.5814	0.8960