

運用中の予測器を使って未知のクラスを分類する方法

An Approach to Unseen Classs Classification with In-Service Predictors

坂井 智哉 十河 泰弘

Tomoya Sakai Yasuhiro Sogawa

NEC データサイエンス研究所

NEC Data Science Research Laboratories

The goal of zero-shot learning is to recognize a novel class that did not appear in training. In this talk, we introduce a novel approach to zero-shot learning. Our approach reuses in-service predictors which are often available in practice. Unlike most of the existing methods, our method does not require to replace in-service predictors with new predictors specifically designed for zero-shot learning.

1. はじめに

機械学習技術が一般的になるにつれ、様々なデータ分析ツールが利用可能になっている。これにより、従来の課題の多くが容易に解決されるようになりつつあるが、一方で、これまでの機械学習手法を単純に適用するだけでは解けない問題も認識されるようになった。その一つの例として、訓練データには存在しない未知のクラスがテスト時に現れるゼロショット学習 [1] が挙げられる。

ゼロショット学習では、既知と未知のクラスにまたがる属性と呼ばれる共通の意味情報が与えられると仮定することで、未知クラスを含めた分類を行う [1]。これまでに様々なゼロショット学習法が提案され、その有用性が示されてきた [2-6]。

一方で、従来のゼロショット学習法の多くが、ゼロショット学習を導入する以前に既知クラスに対する予測器が運用されている状況を考慮していなかった。そのため従来の方法を利用すると、既に運用中の予測器をゼロショット学習のための新しい予測器と置き換えることになり、多くの費用と時間がかかることになる。また、運用中の予測器に依存した他のシステムがあれば、その更新費用も必要となる。

本研究では、モデル再利用法に基づいたゼロショット学習法を提案する。提案法により、運用中の予測器を置き換えることなく、クラス属性を準備するだけで未知クラスを含む予測が可能となる。計算機実験により、提案法はゼロショット学習専用の予測器を一から構築しないにも関わらず、既存のゼロショット学習手法の性能に匹敵する性能が得られることを示した。

2. 予備知識

2.1 問題設定

入力を d 次元の特徴ベクトル $\mathbf{x} \in \mathbb{R}^d$, 対応するクラスラベルを $y \in \mathcal{Y}$ とする。クラス t に対する予測器を $f^{(t)}: \mathbb{R}^d \rightarrow \mathbb{R}$ とし、テストデータ点 \mathbf{x}' に対する予測ラベルを $\hat{y} = \arg\max_{t' \in \mathcal{Y}} f^{(t')}(\mathbf{x}')$ で得る。

訓練およびテスト時におけるクラスラベルのドメインを、それぞれ $\mathcal{Y}_S = \{1, \dots, k_S\}$ および $\mathcal{Y}_U = \{k_S + 1, \dots, k_S + k_U\}$ とする。ここで、 k_S と k_U は、それぞれ既知および未知クラスのクラス数であり、 $\mathcal{Y}_S \cup \mathcal{Y}_U = \mathcal{Y}$ および $\mathcal{Y}_S \cap \mathcal{Y}_U = \emptyset$ である。ゼロショット学習の目標は、訓練時にあたえられる既知クラスの教師情報から、テストデータ点が既知クラスと未知クラス

を含むクラスのうち、どのクラスに属するかを予測することである。したがって、如何にして未知クラスに対する予測器の出力を得るかが鍵となる。

2.2 属性を用いた予測

ゼロショット学習を可能にする一つの方法が、属性と呼ばれる既知および未知クラスすべてに共通する意味情報を用いることである [1]。

クラス t における属性を m 次元の属性ベクトル $\mathbf{a}^{(t)} \in \mathbb{R}^m$ で表す。既知クラスおよび未知クラスに対する属性ベクトルの集合を、それぞれ $\mathcal{A}_S := \{\mathbf{a}^{(t)}\}_{t=1}^{k_S}$ と $\mathcal{A}_U := \{\mathbf{a}^{(t')}\}_{t'=k_S+1}^{k_S+k_U}$ で表す。

従来のゼロショット学習のほとんどは、特徴および属性ベクトルを入力とする予測器 $G(\mathbf{x}, \mathbf{a}): \mathbb{R}^d \times \mathbb{R}^m \rightarrow \mathbb{R}$ を、属性ベクトルと既知クラスに関するラベル付きデータを用いて訓練する。予測器 G に入力する属性ベクトル $\mathbf{a}^{(t)}$ を固定すれば、 $g_{\mathbf{a}^{(t)}}(\mathbf{x}) := G(\mathbf{x}, \mathbf{a}^{(t)})$ はクラス t に対する予測器

$$f^{(t)}(\mathbf{x}) \approx g_{\mathbf{a}^{(t)}}(\mathbf{x})$$

とみなせる。ここで、 $g_{\mathbf{a}^{(t)}}$ を属性固定予測モデルと呼ぶ。

未知クラスの属性を用いることで、未知クラスに対する予測器の出力が得られるため、未知クラスを含めた分類が

$$\hat{y} = \arg\max_{t' \in \mathcal{Y}_S \cup \mathcal{Y}_U} g_{\mathbf{a}^{(t')}}(\mathbf{x}')$$

により可能となる。

2.3 運用中の予測器

本論文では、従来のゼロショット学習法と異なり、既知クラスに対する予測器

$$\{h^{(t)}: \mathbb{R}^d \rightarrow \mathbb{R}\}_{t=1}^{k_S}$$

が得られることを仮定する。

運用中の予測器が利用可能という仮定は現実においてしばしば満たされる。例えば、データ分析者が教師付き学習を用いて用意した予測器が運用されていることが十分考えられる。これらの運用中の予測器を新たなゼロショット学習用の予測器に置き換えるには、関連するシステムの更新費用や時間など多くのコストがかかるため、置き換えなしに未知クラスを含めた予測ができることが望ましい。本研究の目的は、この運用中の予測器 $\{h^{(t)}\}_{t=1}^{k_S}$ を再利用しながらゼロショット学習法を構築することである。

連絡先: {t-sakai,y-sogawa}@ah.jp.nec.com

3. 提案手法

3.1 特徴固定予測モデル

従来法の多くは、属性ベクトルを固定することで予測モデル $G(\mathbf{x}, \mathbf{a})$ を対応するクラスに対する予測器とみなした。それに対して我々は、特徴ベクトルを固定した特徴固定予測モデル $\eta_{\mathbf{x}'_j}(\mathbf{a})$ を考える。ここで、 \mathbf{x}'_j は予測対象となるデータ点であり、予測ラベルは

$$\hat{y}_j = \operatorname{argmax}_{t' \in \mathcal{Y}_S \cup \mathcal{Y}_U} \eta_{\mathbf{x}'_j}(\mathbf{a}^{(t')})$$

により得られる。

3.2 モデル再利用予測

次に特徴固定予測モデルの推定法について説明する。テストデータ点には様々なパターンがあり得るため、あり得るすべてのテストデータ点に対して特徴固定予測モデルを準備することは現実的ではない。そこで、提案法は特定のテスト点に対する予測モデルをテスト時に学習する。

まず、テストデータ点 \mathbf{x}'_j に対する運用中の予測器の出力 $s_j^{(t)} = h^{(t)}(\mathbf{x}'_j)$ を得る。鍵となるアイデアは、特徴固定予測モデル $\eta_{\mathbf{x}'_j}(\mathbf{a}^{(t)})$ を、その出力が運用中の予測器の出力に近くなるように訓練することである：

$$s_j^{(t)} \approx \eta_{\mathbf{x}'_j}(\mathbf{a}^{(t)}).$$

そのような $\eta_{\mathbf{x}'_j}(\mathbf{a}^{(t)})$ は、 $\{(\mathbf{a}^{(t)}, s_j^{(t)})\}_{t=1}^{k_S}$ を訓練データとして既製の回帰用ソフト（例えばリッジ回帰を行う関数）を利用することで容易に得られる。得られた予測器 $\hat{\eta}_{\mathbf{x}'_j}$ を用いることで、予測ラベル $\hat{y}_j = \operatorname{argmax}_{t' \in \mathcal{Y}_S \cup \mathcal{Y}_U} \hat{\eta}_{\mathbf{x}'_j}(\mathbf{a}^{(t')})$ が得られる。

4. 評価実験

4.1 人工データ

人工データを [3] に従い生成し、提案法の性能を評価した。我々の実験では、 $d = 10$, $m = 20$, $n^{(t)} = 50$, $k_U = 100$ とした。

運用中の予測器として、ロジスティック回帰 (LR) とサポートベクトル分類器 (SVC) を検討し、予測器の違いによる提案法の性能への影響も調査した。提案法における、特徴固定予測モデルの推定には ℓ_2 -正則化最小二乗法を利用した。

既知クラス数 k_S を変化したときの提案法の分類精度の変化を図 1 に示す。 $k_S < 50$ では、既知クラス数の増加に伴い分類精度が増加し、 $k_S \geq 50$ であれば、分類精度に大きな変化は見られなかった。運用中の予測器に用いられる予測モデルに関しては、LR を利用の方が平均的に少し高い分類精度が得られた。

4.2 ベンチマークデータ

次に、4 つのベンチマークデータを用いて提案手法の性能を評価した。ベンチマークデータとして、Attribute Pascal and Yahoo (aPY) [7], Animals with Attributes (AWA) [1], Caltech-UCSD-Birds 200-2011 (CUB) [8], SUN [9] を利用した。画像特徴量として、101 層の ResNet [10] から得られた 2048 次元ベクトル [6] を利用した。

表 1 に平均 Top-1 分類精度を示す。提案法はゼロショット学習に特化した分類器を一から構築しないにも関わらず、従来のゼロショット学習専用の分類器の分類精度に匹敵する精度が得られた。




図 1: 既知クラス数 k_S を変化させたときの平均精度と標準誤差（試行回数 5 回）。

表 1: 平均 Top-1 分類精度。既存手法の結果は、既存研究 [6] より結果を引用した。

手法	aPY	AWA	SUN	CUB
ALE [2]	39.7	59.9	58.1	54.9
ESZSL [3]	38.3	58.2	54.5	53.9
SynC [4]	23.9	54.0	56.3	55.6
LatEm [5]	35.2	55.1	55.3	49.3
提案法	38.7	54.5	55.4	53.4

5. おわりに

本研究では、モデル再利用に基づいたゼロショット学習法を提案した。多くの従来法と異なり、提案法は運用中の予測器を活用して未知クラスを含めた予測ができる。実験により、提案法はゼロショット学習に特化した分類器を一から構築しないにも関わらず、従来法に匹敵する性能が得られることを確認した。

謝辞

原稿にコメントをくれた大坂直人さんに感謝します。

参考文献

- [1] Christoph H Lampert, Hannes Nickisch, and Stefan Harmeling. Learning to detect unseen object classes by between-class attribute transfer. In *CVPR*, 2009.
- [2] Zeynep Akata, Florent Perronnin, Zaid Harchaoui, and Cordelia Schmid. Label-embedding for attribute-based classification. In *CVPR*, 2013.
- [3] Bernardino Romera-Paredes and Philip Torr. An embarrassingly simple approach to zero-shot learning. In *ICML*, 2015.
- [4] Soravit Changpinyo, Wei-Lun Chao, Boqing Gong, and Fei Sha. Synthesized classifiers for zero-shot learning. In *CVPR*, 2016.
- [5] Yongqin Xian, Zeynep Akata, Gaurav Sharma, Quynh Nguyen, Matthias Hein, and Bernt Schiele. Latent embeddings for zero-shot classification. In *CVPR*, 2016.
- [6] Yongqin Xian, Bernt Schiele, and Zeynep Akata. Zero-shot learning - the good, the bad and the ugly. In *CVPR*, 2017.
- [7] Ali Farhadi, Ian Endres, Derek Hoiem, and David Forsyth. Describing objects by their attributes. In *CVPR*, 2009.
- [8] P. Welinder, S. Branson, T. Mita, C. Wah, F. Schroff, S. Belongie, and P. Perona. Caltech-UCSD Birds 200. Technical report, California Institute of Technology, 2010.
- [9] Genevieve Patterson and James Hays. SUN attribute database: Discovering, annotating, and recognizing scene attributes. In *CVPR*, 2012.
- [10] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *CVPR*, 2016.