

属性ごとの予測能力に基づく属性ベース転移学習

Attribute-based Transfer Learning
Based on the Predictive Ability of Each Attribute鈴木 雅大[†]佐藤 晴彦[†]小山 聡[†]栗原 正仁[†]

Masahiro Suzuki

Haruhiko Sato

Satoshi Oyama

Masahito Kurihara

1. はじめに

今日、インターネット上などで大量のデータを容易に入手することができるが、それらを直接機械学習に利用することは難しい。何故なら、それらのデータは教師情報がない、解こうとしているタスクとは異なるといった可能性が高いからである。このような問題を解決する手法として、近年転移学習 [1][2] が注目されている。

転移学習は同一タスク内で学習とテストを行う一般の機械学習とは異なり、新規タスクにおいて別のタスクで学習した結果を利用するという手法である。転移学習を実現するアルゴリズムは様々考案されているが、我々はその一つである属性ベース転移学習 [3] に着目した。属性ベース転移学習は、各クラスの定義として属性という概念を導入し、学習結果を転移することで転移学習を実現している。しかし先行研究では、各属性がテスト段階でどのくらい目標クラスの分類予測に貢献するか（予測能力）について考慮していない。

本研究では、提案手法として目標クラスを予測する際に用いる評価値に、各属性の予測能力に基づき重み付けを行うことで、クラス分類性能の向上を試みた。

2. 関連研究

2.1. 転移学習

転移学習 (transfer learning) は、一般的な機械学習が同一タスク内でしか学習・予測のプロセスができないのに対し、他のタスクの学習結果を利用（転移）することで問題を解決しようという手法である。転移学習という言葉は、幅広い枠組みに対して用いられているために統一的な定義や議論は難しいが、Pan ら [2] や神島 [1] などによる転移学習のサーベイがある。

2.2. 属性ベース転移学習

属性ベースクラス分類 (Attribute-based Classification) による転移学習は、Lampert らによって提案された手法である [3]。本稿では、転移学習であることを強調するため属性ベース転移学習 (Attribute-based Transfer Learning) と呼称する。

$(x_1, l_1), \dots, (x_n, l_n) \subset X \times Y$ を訓練集合とする。このとき、 X は任意の特徴空間であり、 $Y = \{y_1, \dots, y_K\}$ は K 個のクラスから構成されている。この手法の目標は、 Y とは異なる未知のタスクのクラス集合 $Z = \{z_1, \dots, z_L\}$ において $X \rightarrow Z$ の分類を得ることである。

図 1(a) のように従来の方法では、 $X \rightarrow Y$ の分類のため訓練クラス $y_1, \dots, y_K$ ごとの分類 $\alpha_1, \dots, \alpha_K$ を学習しても、 $X \rightarrow Z$ 間は学習していないため $X \rightarrow Z$ の分類はできない。知識を転移するためには、異なるタ




図 1: 一般の機械学習 (a) と属性ベース転移学習 (b)

スク間で変換する必要がある。この先行研究ではその方法として属性 (attribute) を用いる。属性はクラスによって 0,1 の二値をとる。また全てのタスク内のクラスで共有しているため、属性を介して知識を転移することができる。

図 1(b) がこの手法の概要図である。先行研究では Direct attribute prediction (DAP) モデルと呼ばれている。図 1(a) と比較すると、間に属性 $A = \{a_1, \dots, a_M\}$ の層が導入されている。クラス y とそれに対応する属性 a の値は $a^y = (a_1^y, \dots, a_M^y)$ と予めわかっているとすると、 $X \rightarrow Y$ の分類は入力 x と対応する属性 a_m の値を教師情報として分類 β_m を学習することで求まる。

テストの際は、学習したデータとは異なるタスク内のクラス集合 Z に属するデータを入力データとする。またクラス z に対しても $a^z = (a_1^z, \dots, a_M^z)$ と予めわかっているとすると、入力 x のとき出力するクラスが z である確率は、 $p(z|x)$ である。MAP (最大事後確率) 推定より分類する z は

$$\arg \max_z p(z|x) \quad (1)$$

となる。確率部分は式変形によって

$$p(z|x) = \sum_{a \in \{0,1\}^M} p(z|a)p(a|x) = p(z) \prod_{m=1}^M \frac{p(a_m^z|x)}{p(a_m^z)} \quad (2)$$

となる。ここで、 $p(z)$ は z を推定する際に無視することができるので、結局 z は式 (3) で求まる。

$$\arg \max_z \prod_{m=1}^M \frac{p(a_m^z|x)}{p(a_m^z)} \quad (3)$$

式 (3) 中の $p(a_m^z|x)$ は分類 β_m として学習した確率的分類器であり、 $p(a_m^z)$ はテストクラスの属性の分布なので $p(a_m^z) = \frac{1}{L} \sum_{l=1}^L a_m^z$ で求めることができる。

3. 提案手法

先行研究の問題点として、それぞれの属性がどの程度学習と分類予測に有効かを考慮していないことが挙

[†]北海道大学大学院情報科学研究科

げられる。この「属性がどの程度学習と分類予測に有効か」ということを、本稿では属性の「予測能力」と呼ぶ。つまり予測能力が高い属性とは、未知の入力に対して精度が高い予測をすることができ、反対に予測能力の低い属性は、上手く予測することができないことを意味する。

予測能力は主に二つの要因によって影響を受けると考えられる。一つ目は、その属性が入力から学習しやすいかどうかである。上手く学習できる属性は予測能力が高く、学習が困難な属性は予測能力が低いと考えられる。もう一つの要因は、データセット内の属性の偏りである。特に訓練時のそれぞれの属性 a_m^y の値の偏りは予測能力に大きく影響する。なぜなら分類 β_m は属性ごとに学習するため、属性値の偏りは不均衡データとなって未知の入力に対して属性値を予測しにくくなってしまふからである。

予測能力の低い属性は分類の際の影響をなるべく小さくしたいので、分類の評価値に属性ごとの予測能力に応じた重みをつけることを考える。上記の一つ目の要因の度合いを表す重みを v_m 、二つ目の要因を w_m とし、各属性ごとに重み付けをすることを踏まえて式 (3) を次のように変更する。

$$\arg \max_z \sum_{m=1}^M v_m w_m \log \frac{p(a_m^z | x)}{p(a_m^z)} \quad (4)$$

一つ目の要因については、属性の正解率によって表すことができる。よって v_m は

$$v_m = E(\delta(p_m^x, a_m^x)) \quad (5)$$

となる。ただし

$$x = y : \delta(x, y) = 1 \quad (6)$$

$$x \neq y : \delta(x, y) = 0 \quad (7)$$

E は期待値で、 p_m^x は入力 x に対する属性 a_m^x の予測値である。

もう一つの要因は属性 a_m^y の偏りであるが、学習した後未知のデータを分類した結果の偏りの方が、より属性の予測能力が反映されると考えられる。このとき重み w_m は分類予測の平均が 0 と 1 で最小、0.5 で最大になるようにしたい。よって属性 a_m に対し次のような重み w_m を提案する。

$$w_m = 1 - 2|E(p_m^x) - \frac{1}{2}| \quad (8)$$

以上により重み v_m , w_m が定まった。

4. 実験

本実験では、データセットに Attributes with animals(AwA)[4]を使用する。このデータセットは動物の画像とそれに対応する属性が用意されている。動物のクラスは 50 種類であるが、本実験では元タスク、つまり訓練データとしてそのうちの 40 種類を用いて、残りの 10 種類を目標タスク、テストデータとして、多クラス分類問題に取り組んだ。また訓練データの各クラスの画像 10%を重み v_m と w_m を求めるためのテスト




図 2: 先行研究と提案手法

データとした。

また AwA では 6 種類の手法で画像から特徴量を抽出しているため、MKL-SVM を用いた。さらに線形分類器である SVM から確率的分類器を求める手法には platt-scaling[5] を使った。

実験結果が図 2 である。横軸は訓練データ及びテストデータのクラスごとの枚数で、縦軸は分類の正解率を表す。提案手法によって正解率がおおむね向上したことがわかる。

5. まとめ

本稿では、提案手法によって従来の手法よりも分類性能が向上したことを示した。今後はさらなる改良の他、別の問題設定においても本手法が有効か検証したい。

参考文献

- [1] 神畠敏弘. 転移学習. 人工知能学会誌, vol.25, no.4, pp.572-580 (2010).
- [2] S.J. Pan and Q. Yang. A survey on transfer learning. *Knowledge and Data Engineering, IEEE Transactions on*, Vol. 22, No. 10, pp. 1345–1359, 2010.
- [3] C.H. Lampert, H. Nickisch, and S. Harmeling. Learning to detect unseen object classes by between-class attribute transfer. In *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, pp. 951–958. IEEE, 2009.
- [4] Stefan Harmeling Jens Weidmann Christoph H. Lampert, Hannes Nickisch. animals with attributes a dataset for attribute based classification. <http://attributes.kyb.tuebingen.mpg.de>.
- [5] John C. Platt. Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods. In *Advances in Large Margin Classifiers*, pp. 61–74. MIT Press, 1999.