

属性ごとの観測確率を考慮した転移学習

Transfer Learning Based on the Observation Probability of Attributes

鈴木 雅大 *1 佐藤 晴彦 *1 小山 聡 *1 栗原 正仁 *1
Masahiro Suzuki Haruhiko Sato Satoshi Oyama Masahito Kurihara

*1北海道大学大学院情報科学研究科

Graduate School of Information Science and Technology, Hokkaido University

Machine learning is the basis of important advances in artificial intelligence. Unlike general machine learning, which uses the same task for training and testing, transfer learning uses the results trained by other tasks to learn a new task. Among the various transfer learning algorithms have been proposed, we focus on attribute-based transfer learning. This algorithm realizes transfer learning by introducing attributes and transferring the results of training. However, the existing algorithm does not consider the extent which each attribute can learn correctly (called the observation probability). Here, we devised the generative model which introduced the observation probability. We confirmed that the accuracy rate of the proposed technique was higher than that of the preceding work.

1. はじめに

転移学習 [1][2] は同一タスク内のみで訓練とテストを行う一般的な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、全てのタスク内の各クラスの定義として属性を導入し、さらに属性ごとに分類器を用意して全タスクで用いることで転移学習を実現している。しかし既存研究では、各属性が入力データからの程度正しく学習できるか（観測確率）を考慮していない。また、転移元のタスクについてしか訓練できないため、転移元の知識を新規タスクの学習に利用する追加学習ができないという問題があった。

本稿では、提案手法として属性ごとの観測確率を考慮した生成モデルを考案し、既存研究との比較実験をした。

2. 関連研究

属性ベースクラス分類 (Attribute-based Classification) 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。

$(x_1, l_1), \dots, (x_n, l_n) \in X \times Y$ 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。以後、転移元のタスクのことを元タスク、転移先のタスクを目標タスクと呼称する。

従来の機械学習では、 $X \rightarrow Y$ の分類を学習しても、目標タスクについては学習していないため $X \rightarrow Z$ の分類はできない。属性ベース転移学習では属性 (attribute) を導入することで、この問題を解決している。属性はクラスによって $\{0, 1\}$ の 2 値をとり、全タスク内のクラスで共有している。

クラス y とそれに対応する属性 a の値が予めわかっているな

らば、各入力に対する属性 a_m の値が分かるので、入力 x を特徴ベクトル、対応する属性 a_m の値をラベルとして訓練する。

テストの際は、目標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 についても属性との関係が予めわかっているとし、元タスクで訓練した分類器でテストをすると、各属性について分類確率 $p(a_m = 1|x)$ を得る。また入力が x のとき出力するクラスが z である確率は、 $p(z|x)$ なので、分類する z は MAP (最大事後確率) 推定より

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

となる。式変形によって、結局 z は式 (2) で求まる。

$$\arg \max_z \prod_{m=1}^M \frac{p(a_m^z|x)}{p(a_m^z)} \quad (2)$$

式 (2) の $p(a_m^z|x)$ は $p(a_m = a_m^z|x)$ の意味である。また、 $p(a_m^z)$ は元タスクの属性の分布 $p(a_m = 1) = \frac{1}{K} \sum_{k=1}^K a_m^{y_k}$ から求めることができる。

3. 提案手法

それぞれの属性には、入力への現れやすさに違いがある。例えば、動物画像には「黒」という属性は現れやすいが、「肉食」という属性を得ることは困難である。そこで、本稿では入力への属性の現れやすさを観測確率と定義し、観測確率を事前分布として異なるタスクで用いることで転移学習を実現するような生成モデルを提案する。

図 1 が提案するモデルである。このモデルでは、観測確率は $\mu_{m\lambda}$ で定義される。 λ は $\{0, 1\}$ をとり、 $\lambda = 1$ は属性をもち、 $\lambda = 0$ は属性をもたない状態を意味する。よって μ_{m1} と μ_{m0} はそれぞれ「属性 m の真値が 1 のとき、正しく 1 と観測される確率」と「属性 m の真値が 0 のとき、誤って 1 と観測される確率」を表す。また $\mu_{m\lambda}$ はパラメータ α のベータ分布 (事前分布) によって生成されるとし、観測確率から属性 a_{mn} が生成される確率をベルヌーイ分布とする。また、 c_{mn} はクラス z_n に対応する真の属性値であり、既存研究と同様に予め決まるものとする。元タスクのテストデータ集合 X_{source} が与

連絡先: 鈴木雅大, 北海道大学大学院情報科学研究科, 060-0814 札幌市北区北 14 条西 9 丁目, masa@complex.ist.hokudai.ac.jp




図 1: 提案手法のグラフィカルモデル

えられたとき、観測確率の推定値 $\hat{\mu}_{m\lambda}$ は MAP 推定

$$\hat{\mu}_{m\lambda} = \arg \max_{\mu_{m\lambda}} p(\mu_{m\lambda} | X_{\text{source}}) \quad (3)$$

によって求めることができ、計算すると

$$\hat{\mu}_{m\lambda} = \frac{\sum_{n: c_{mn}=\lambda} p(a_{mn} = 1 | x_n) + \alpha - 1}{N_{m\lambda} + 2(\alpha - 1)} \quad (4)$$

となる。ここで $p(a_{mn} = 1 | x_n)$ は、元タスクにおいて確率的分類器で訓練・テストした結果を用いる。また、 $N_{m\lambda}$ は $c_m = \lambda$ となるテストデータの数である。

次に目標タスクで訓練・テストを行い、目標タスクのテストデータ集合 X_{target} について $p(a_{mn} = 1 | x_n)$ を得る。この確率と元タスクで求めた観測確率 $\mu_{m\lambda}$ を使って目標タスクでのクラス分類を行う。

図 1 の同時分布は

$$p(X, A, C, Z; \mu) = \prod_n p(z_n) \prod_m p(c_{mn} | z_n) p(a_{mn} | c_{mn}, \mu_{m\lambda}) p(x_n | a_{mn}) \quad (5)$$

となる。入力 x に対するクラス z は式 (1) と同様に MAP 推定によって求める。MAP 推定は式 (5) を式変形して

$$\arg \max_z p(z | x) = \arg \max_z \prod_m \sum_a \frac{p(a_m | \mu_{c_m^z}) p(a_m | x)}{p(a_m)} \quad (6)$$

と求めることができる。このとき c_m^z はクラス z に対応する真の属性値であり、 $\mu_{c_m^z}$ は $\lambda = c_m^z$ における $\mu_{m\lambda}$ である。

既存手法では、共通の分類器で元タスクでは訓練、目標タスクではテストを行う必要があった。しかし本稿の提案手法では観測確率によって転移することができるので、異なるタスクのそれぞれで訓練・テストができる。ただし、観測確率は分類器に依存するため、用いる分類器やパラメータは元タスク及び目標タスクで同一にすべきと考えられる。

4. 実験

本実験では、データセットに Attributes with animals (AwA)*¹ 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 種類であり、本実験ではそのうち 40 種類を元タスク、残りの 10 種類を目標タスクとして、多クラス分類問題に取り組んだ。既存研究と比較するため、目標タスクのデータは訓練せずに全てテストデータとした。また提案手法では訓練データの各クラスの画像 10% を観測確率を求めるためのテストデータとした。

*1 <http://attributes.kyb.tuebingen.mpg.de/>




図 2: 既存手法と提案手法の正解率の比較

AwA では 6 種類の手法で画像から特徴量を抽出しているが、本実験では最近傍法での正解率が高い [4] SURF と RGB color histograms の 2 種類の特徴量を用いた。また分類器には特徴量が複数なので、特徴量それぞれにサブカーネルを用意して線形結合した Multiple Kernel Learning (MKL)-SVM を用いた。さらに SVM から確率 $p(a_{mn} = 1 | x_n)$ を近似する手法として、シグモイド関数を用いた [5]。なお、式 (4) のハイパーパラメータ α の値は 2、シグモイド関数のゲインは 10 とした。

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向上したことがわかる。

また本稿には載せていないが、既存手法ではできなかった追加学習についても実験を行い、本稿の手法が有効であることを確認している。

5. まとめ

本稿では、提案手法によって既存手法よりも分類性能が向上したことを示した。今後は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] 神島敏弘. 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] Sandra Ebert, Diane Larlus, and Bernt Schiele. In Kostas Daniilidis, Petros Maragos, and Nikos Paragios, editors, *ECCV (1)*, Lecture Notes in Computer Science, pp. 720-733. Springer.
- [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.