

A General Framework for Transfer Learning

総合研究大学院大学 南 俊匠

統計数理研究所 吉田 亮

1. はじめに

人間の学習過程において、すでに獲得された知識を新しい学習タスクに再利用することはごく自然に行われている。この知識の再利用という考え方を機械学習に取り入れるためのアプローチとして転移学習と呼ばれる解析技術に注目が集まっている。転移学習の手法として、ニューラルネットワークに基づくものなど多くのものが存在するが、それらは転移元タスクのデータ取得状況や特定の機械学習モデルに限定したものであることが多く、活用機会が限られる。本研究では転移元タスクのデータ取得状況や特定の機械学習モデルに限定されない、より一般的な転移学習の方法論的フレームワークを構築することを目指す。

2. 関連研究

Liu and Fukumizu[1]は転移先(ターゲットタスク)の確率分布 $p_t(y|x)$ を転移元(ソースタスク)の確率分布 $p_s(y|x)$ を用いて以下のように分解することで、密度比推定という方法論を起点に確率論的な転移学習フレームワークを提案した。

$$p_t(y|x) = \frac{p_t(y|x)}{p_s(y|x)} p_s(y|x).$$

ここで $p_t(y|x)/p_s(y|x)$ はソースとターゲットの確率密度の比である。この密度比を $g(x, y; \theta)$ とモデル化し、真の分布 $p_t(y|x)$ と $g(x, y; \theta)p_s(y|x)$ との Kullback-Leibler 情報量の上限を最小化することにより、ソースからターゲットへの転移関数 $g(x, y; \hat{\theta})$ を構築する。結果として得られた $g(x, y; \hat{\theta})$ をソースの確率密度と合成することでターゲットの確率密度を得る。ここで推定する密度比 $g(x, y; \theta)$ はソースとターゲットの違いを表しているとみなすことができる。この手法では、タスクそのものは複雑であっても別のタスクとの違いは単純であるという仮定のもと、タスク間の差分のみを推定することで、効率的な転移を可能にしている。

3. 提案手法の概要

本研究では Liu and Fukumizu[1]の方法を以下の形で拡張する。

$$\hat{\theta} = \operatorname{argmin}_{\theta} \frac{1}{n_t} \sum_{i=1}^{n_t} \left[-\log g(x_i^t, y_i^t; \theta) + \lambda \log \int g(x_i^t, u; \theta) p_s(u|x_i^t; \beta_s) du \right].$$

ここで、 $\{(x_i^t, y_i^t)\}_{i=1}^{n_t}$ はターゲットタスクの観測値であり、 λ はハイパーパラメータである。 $\lambda = 1$ のとき Liu and Fukumizu[1]と一致する。本フレームワークは以下のような特徴がある。

- 過去の知識をデータではなく機械学習モデルを保存しておけばよい。
- 元のモデルがどのような機械学習モデルでも適用できる。
- 転移モデルにも一般性がある。
- いくつかの転移学習の考え方を包括したアルゴリズムになっている。

提案手法の性質の詳細や適用例については当日報告する。

参考文献

- [1] Liu, S and Fukumizu, K. (2016). Estimating posterior ratio for classification: transfer learning from probabilistic perspective. *Proceedings of the 2016 SIAM International Conference on Data Mining* 747-755.