

オンライン転移学習における能動学習法

Active Learning via Online Transfer Learning

成田敦博*¹ 佐藤一誠*² 中川裕志*²
Atsuhiko Narita Issei Sato Hiroshi Nakagawa

*¹東京大学大学院情報理工学系研究科数理情報学専攻

Department of Mathematical Informatics, Graduate school of Information Science and Technology, the University of Tokyo

*²東京大学情報基盤センター

Information Technology Center, the University of Tokyo

機械学習では、教師データ作成コストが問題となる場合があるため、少量のデータから効率的に学習する枠組みが重視されている。少量のデータからの学習として、能動学習および転移学習が提案されている。能動学習は、教師データの作成コストが大きい場合、一部のデータだけに選択的にラベルを付ける方法である。転移学習は、教師データが少ない場合、データの豊富な他のタスクの情報も利用して学習を行う枠組みである。本研究では、逐次的な転移学習に能動学習の考え方をとりいれ、すでに存在する資源を利用しつつ、学習に効果的なデータを選択することで、低コストな学習が行えることを示す。

1. はじめに

機械学習においては、データの少なさやモデルの複雑さといった問題から、少量のデータからよいモデルを学習するための手法が重要である。これに対応するために、本研究では転移学習と能動学習の2つのアプローチを扱う。また、利用できるメモリが限られている場合に対応するため、すべてのデータをメモリに乗せることなく1つずつ処理するオンライン学習の枠組みで考える。

転移学習とは、あるドメインについて学習モデルを作ろうとする際にデータが足りない場合、十分なデータがある別のドメインでの情報をうまく役立てるための手法の総称である。さまざまな問題設定において転移学習は長く研究されてきた。オンライン学習における転移学習に関する研究はZhaoらによるもの[6]があげられるが、問題設定の難しさなどからまだ深い研究が行われているとは言えない。

また、データへのラベル付けは人力に頼ることが多く、そのためコストが無視できない場合も多い。能動学習とはこのような場合において、可能な限り学習に寄与しそうな少数のデータのみを選択してラベル付けすることで、なるべく少ないラベル付きデータで高い精度のモデルを学習するためのフレームワークである。

本研究では、まず従来のモデルの結合に基づくオンライン転移学習の問題点を解決するためのアルゴリズムを提案し、次にこの枠組の中で能動学習を行うための手法と、そのために今後解決されるべき課題を示す。

2. オンライン転移学習

この節では、オンライン学習での転移学習法を提案する。

2.1 予測器の結合

簡単のために二値分類の場合を考える。つまり、ラベル y について $y \in \mathcal{Y} = \{0, 1\}$ のような場合である。学習に用いるモデルとしては、データ x が与えられた時のラベルが正例であ

る確率

$$\xi = f(x) = p(y = 1|x)$$

が定義されているようなものを仮定する。確率モデルであれば十分だが、そうでなくても、 x と y が与えられた時に 0, 1 間の値を返す関数さえ定義されていればよい。たとえば線形識別器 $\text{sign}(yw^T x)$ を考えると、シグモイド関数 $\frac{1}{1+\exp(-x)}$ のような単調増加な関数 $\Pi(x)$ を用いて $\xi = f(x) = \Pi(w^T x)$ のように予測関数を作ることができる。

さて、元ドメインの情報を目標ドメインでの学習に取り入れるため、2つの予測器の出力の加重平均をとるという方法を用いる。 $f_{0,t}, f_{1,t}$ をそれぞれ、 t ステップ目における目標ドメインと元ドメインの予測器だとすると、重み $w_{0,t}$ と $w_{1,t}$ を用いて

$$\hat{y} = \frac{w_{0,t}f_{0,t} + w_{1,t}f_{1,t}}{w_{0,t} + w_{1,t}}$$

のように2つの関数を結合する。これを用いて、 \hat{y} が $\frac{1}{2}$ を上回っているかどうかで分類を行うことができる。

また、元ドメインを2つ以上利用場合への拡張は簡単なので、本論文では元ドメインは一つだけの場合のみを扱う。

2.2 結合重みの決定

さて、データを1つずつしか受け取れない場合に、逐次的に結合重み $w_{0,t}, w_{1,t}$ を決定しなければならない。

まず、アルゴリズムの評価基準が必要になる。今回はオンライン学習を想定しているので、誤識別回数

$$\sum_{t=0}^T M_t \quad (1)$$

がなるべく小さくなるように学習を行いたい。ここで M_t は、時刻 t において識別を誤った時に 1、正しく分類できた時には 0 をとる変数である。ただ、重みの最適化において誤識別回数を直接扱うのは困難であるので、予測 \hat{y} と正解ラベル y_t の差を測るための下に凸な損失関数 $L(\hat{y}, y_t)$ を用い、(1) の凸緩和を行った

$$\sum_{t=0}^T L(\hat{y}, y_t)$$

連絡先: 成田敦博, 東京大学大学院情報理工学系研究科数理情報学専攻 中川研究室, 03-5841-2729, 東京都文京区本郷 7-3-1 総合図書館, Atsuhiko_Narita@mist.i.u-tokyo.ac.jp

を用いる。

これを最適化するためには、Prediction with Expert Advice [1] と呼ばれるオンライン学習の枠組みが利用できる。Zhao らが提案したオンライン転移学習のための手法 [6] ではこの考え方を応用されており、時刻 t においてラベルとデータの組 (y_t, \mathbf{x}_t) をあらたに受け取るごとに、重みを

$$w_{i,t+1} = w_{i,t} (\log 2)^{L(\hat{y}_t, y_t)} \quad (2)$$

のように更新するという方法が提案されている。

理想的には、学習の初めのうちは目標ドメインの予測器はあまり精度が高くないため、元ドメインに大きな重みを付けておいて、学習が進むに従って徐々に目標ドメインの予測器に対する重み $w_{0,t}$ を大きくしていく、ということが必要となる。式 (2) による方法には強い理論的保証があるが、一方で学習の初期段階では $f_{0,t}$ の精度が悪いため、目標ドメインに対する重み $w_{0,t}$ が小さくなりすぎてしまい、後に $f_{0,t}$ の学習が進んでも、重みが回復するのが遅れるという問題がある。結果としてほとんど元ドメインの予測器のみを使ったモデルが作られてしまい、最終的な累積誤識別回数はそれほど良くなる。

これは、目標ドメインでのモデルの学習が進むに従って予測器の性質が変化するためであり、このような状況で愚直に Prediction with Expert Advice のための手法を適用したために発生する問題である。逐次的に学習を行う際、データの分布が途中で変化する状況は一般に“コンセプトドリフト”と呼ばれる。今回の状況ではデータそのものが変化するわけではないが、モデルによる予測結果の変化という意味ではこれに近い状況だと考えられる。

Prediction with Expert Advice の状況でコンセプトドリフトを扱うためのアルゴリズムが Kolter らによって提案されている [4] が、今回オンライン転移学習においてこの問題に対応するため、重み $w_{0,t}, w_{1,t}$ の更新式を

$$w_{i,t+1} = w_{i,t} \beta^{L(\hat{y}_t, y_t)} + \gamma (w_{0,t} + w_{1,t}) L(\hat{y}_t, y_t)$$

のように改良したアルゴリズムを提案する (Algorithm 1)。第二項によって、予測器の重みが小さくなった場合でも将来重みが回復する可能性を考慮しており、重みが小さくなりすぎるのを防いでいる。これによって 2 つのモデルの結合をより適応的に行うことができる。

Algorithm 1 提案手法 1: オンライン転移学習

```

重みを初期化する:  $w_{0,0} = 0, w_{0,1} = 1$ 
for  $t = 0 \dots T - 1$  do
  ラベルとデータの組  $(y_t, \mathbf{x}_t)$  を受け取る。
   $\hat{y}_t = \frac{w_{0,t} f_{0,t} + w_{1,t} f_{1,t}}{w_{0,t} + w_{1,t}}$ 
   $\xi_{0,t} = f_{0,t}(y_t, \mathbf{x}_t)$   $\xi_{1,t} = f_{1,t}(y_t, \mathbf{x}_t)$ 
   $w_{0,t+1} = w_{0,t} \beta^{L(\xi_{0,t}, y_t)} + \gamma L(\xi_{0,t}, y_t)$ 
   $w_{1,t+1} = w_{1,t} \beta^{L(\xi_{1,t}, y_t)} + \gamma L(\xi_{1,t}, y_t)$ 
  受信したデータ  $(y_t, \mathbf{x}_t)$  を使って、予測器  $f_{0,t}$  を更新する。
end for

```

3. 能動学習

次に、このオンライン転移学習の枠組みで能動学習を行い、ラベルコストを減らす方法について論ずる。データは 1 つずつしか受け取れないため、ストリームベースでの能動学習を考えることになる。ストリームベースでの能動学習においては、

データ x を受け取った時に、ある確率 $q(x)$ でラベル y を要求して (y, x) を学習に使い、残りの確率 $1 - q(x)$ でそのデータは捨てるというやり方が一般的である。

この設定では、本質的に二種類の問題を同時に解くことになることを考えることができる。

- 目標ドメインでの予測器 $f_{0,t}$ をオンラインで更新する。
- 2 つの識別器の結合重み $w_{0,t}, w_{1,t}$ を適切に定める。

学習に用いるラベル付きデータをなるべく減らしながら、上の 2 つのタスクを扱う必要があるため、問題設定としては通常の能動学習より難しくなる。

たとえばオンライン転移学習の場合でも、目標ドメインの予測器 $f_{0,t}$ を学習するために通常のストリームベースの能動学習法をそのまま用いることができる。しかし多くの場合、目標タスクの識別面の近くからデータをサンプルすることになり、 $f_{0,t}$ による誤差 $L(\xi_{0,t}, y_t)$ と、誤識別の回数が増える。結果として目標ドメインへの重み $w_{0,t}$ には本来より小さい値しか割り当てられず、性能が悪化するという問題がおこる。

3.1 提案手法 1

能動学習のなかでラベルをつけるデータを選ぶにあたって、Uncertainty Sampling [5] と呼ばれる手法では、何らかの基準に従って、なるべく学習に大きく寄与しそうなデータにラベルを要求する。ラベル付けの基準 $q(x)$ の作り方には、識別面からの距離によるものなどいくつかの方法があるが、今回はエントロピーによる基準を利用する。

データ x を受け取った時のラベルの予測確率 $p(y|x)$ を用いて、そのエントロピー

$$q(x) \equiv H(x) = - \sum_y p(y|x) \log p(y|x) \quad (3)$$

を計算し、この値が大きいデータにラベル付けしやすくするのが、エントロピー基準と呼ばれる方法である。

この基準をそのまま用いることも可能だが、転移学習を行う場合には目標ドメインと元ドメインによる予測として $p_0(y|x), p_1(y|x)$ の 2 つのラベル確率を考えることができるため、これら 2 つの情報をうまく取り入れる形で能動学習のための基準を作ることが望ましい。

エントロピー基準は $H(x) = E[-\log p(y|x)]$ であるので、ラベル確率 $p(y|x)$ の負の対数尤度の期待値と考えることができる。尤度の小さいと期待されるデータが優先的にラベル付けされることになり、モデルにとって識別に自信のないデータを積極的に学習に組み入れていることになる。本研究の設定において学習を行うのはもっぱら目標ドメインでの識別関数なので、 $-\log p_0(y|x)$ が期待的になるべく大きなデータにラベル付けて学習に用いたい。

この期待値を計算するにあたって y の分布が必要だが、ここに元ドメインの情報を組み入れて $p_{0+1}(y|x) \equiv w_0 p_0(y|x) + w_1 p_1(y|x)$ を用いる。すると、 $p_{0+1}(y|x)$ から $p_0(y|x)$ へのクロスエントロピー

$$q(x) = - \sum_y p_{0+1}(y|x) \log p_0(y|x) \quad (4)$$

を基準に用いればよいということが分かる。

3.2 提案手法 2

能動学習では学習に用いるデータがもともとのデータと異なる分布を持つことになるので、作られるモデルが真のモデルからずれてしまうという問題が起こるので、重点サンプリングの考え方を取り入れ、重みの推定に普遍性を持たせる。

データ x が $p(x)$ という分布に従って発生していると考えたと、ラベル付けされるデータ x は、 $p(x)q(x)$ という確率密度を持っている。ここで、重みの更新に用いる損失関数 $L(\hat{y}, y_t)$ を考える。 \hat{y} は x の関数であるので、他の変数を無視すると、損失関数は x の関数 $L(x)$ とみなすことができる。能動学習においてデータの分布が偏っている状況でこの損失をそのまま重みの推定に用いるのは問題があるため、なるべく偏っていない損失の値を得たい。データがオリジナルの分布 $p(x)$ に従っている時の損失関数の期待値 $E_{\sim p}[L(x)]$ を考えると

$$\begin{aligned} E_{\sim p}[L(x)] &= \int Lp(x)dx \\ &= \int \frac{p(x)}{p(x)q(x)}Lp(x)q(x)dx = E_{\sim pq}\left[\frac{1}{q}L(x)\right] \end{aligned}$$

となるので、損失関数として $L(x)$ の代わりに $\frac{1}{q}L(x)$ を用いることで期待値を一致させることができることが分かる。今回提案するオンライン転移学習における能動学習では、この値を予測に対する損失関数として使い、結合重み $w_{0,t}, w_{1,t}$ の調整を適切に行う。

4. 実験

この節では数値実験の結果を示す。

まず、単純な二値分類ではなく 0-1 値の出力を得るための方法として、今回我々は高性能なオンライン識別器である Confidence Weighted [3] アルゴリズムを用いた。 $\text{sign}(y \cdot w^T x)$ のように識別を行う線形識別器はパラメータ w を持つが、Confidence Weighted では w はある正規分布 $\mathcal{N}(\mu, \Sigma)$ に従っていると仮定されている。パラメータの分布を保持することによってそれぞれの素性のスケールや出現頻度を考慮に入れることができ、少ないデータ数で高精度な分類が可能になっている。これを使って、ラベルの予測確率 $p(y|x)$ を

$$p(y|x) = \int p(y|xw)p(w)dw = \Phi\left(\frac{yw^T x}{\sqrt{x^T \Sigma x}}\right) \quad (5)$$

と定義できる。ここで、 $\Phi(x) = \int_{-\infty}^x \mathcal{N}(0, 1) dt$ である。

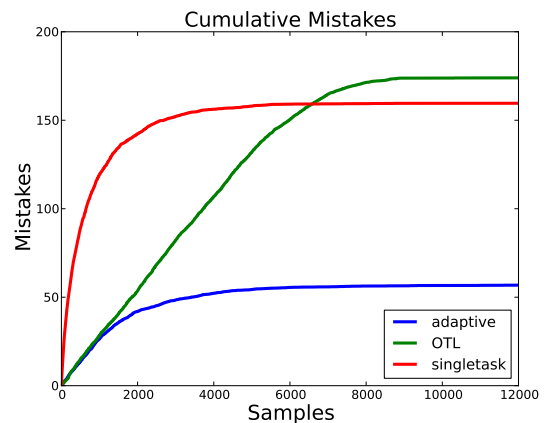
4.1 人工データ

線形分離できるデータを仮定し、目標ドメインと元ドメインでの真のパラメータ w_0, w_1 を適当に決める。次に、データ x を $\mathcal{N}(0, 1)$ に従って発生させ $\text{sign}(w^T x)$ の値に従ってラベルを付ける。

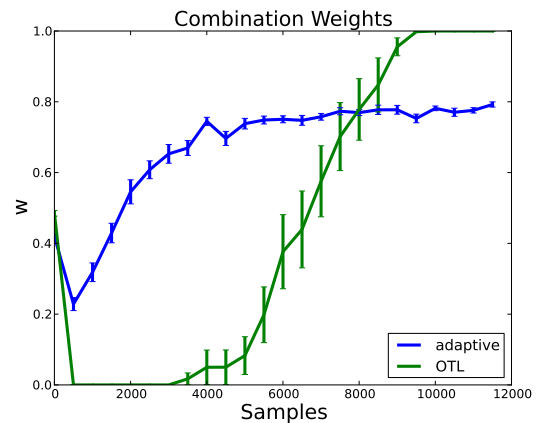
4.2 オンライン転移学習

- singletask 転移を行わない、confidence weighted を用いた通常のオンライン学習である。
- OTL Zhao らによるオンライン転移学習 [6]。識別器の更新には confidence weighted を利用している。
- adaptive 今回の提案手法。

元ドメインと目標ドメインでデータの分布が同じ場合について実験を行う。つまり、 $w_0 = w_1$ である。



(a) 累積誤識別回数の推移



(b) 目標ドメインに対する重み $w_{0,t}$ の変化

図 1: オンライン転移学習

元ドメインで 2000 個のデータを使って学習し、そのモデルを基に目標ドメインでの学習を行った。この時の累積誤識別回数と、目標ドメインに割り当てられた重み $w_{0,t}$ の推移を図 1 に示す。

累積誤識別回数のグラフの傾きは、ある時刻における誤識別率となり、どのアルゴリズムの場合でも学習が進むに従って徐々に精度が向上し、誤識別率が 0 に近づいていく。転移をしない通常のオンライン学習と比べて、転移学習を行う手法 (adaptive, OTL) は学習開始直後の傾きが緩やかである。これは元ドメインにおいて 2000 個のデータで学習した識別器が有効になっているためである。

しかし、学習が進むにつれて、既存の転移学習法 (OTL) は精度が向上せず、同じ割合で誤識別を重ねてしまっている。これは、2つの識別器の結合重み $w_{0,t}, w_{1,t}$ の調整方法が、学習が進むに従って予測器の性質が変化するという状況に対応していないためである。このため重みが小さくなりすぎ、目標ドメインでの予測器が十分信頼できるようになってもしばらく $w_{0,t}$ が大きくならない。一方、提案手法 (adaptive) は目標ドメインでの学習が進むに従って緩やかに重みを変化させ、精度の悪

化を防いでいる。重みは適切に調整されており、 $w_{0,t}$ が $\frac{1}{2}$ を上回るのが、ちょうど元ドメインの学習に用いたサンプル数である $t = 2000$ 個付近となっている。最終的に、提案手法が最も累積誤識別回数が少なく済み、少ないデータで良い学習をすることが達成されていると言える。

4.3 能動学習

次に、能動学習についての評価を行う。目標ドメインの学習方法については次の5種類を考える。

- passive 能動学習しないもの。ベースラインとして用いる。
- entropy (biased) 単純なエントロピー基準による能動学習。基本的に文献 [2] による。
- entropy (unbiased) エントロピー基準に提案手法 2 を利用したもの。
- cross entropy (unbiased) 提案手法 1 による、クロスエントロピーをラベル付けの基準に用いるもの。
- cross entropy (unbiased) 提案手法 1 と提案手法 2 を組み合わせたもの。

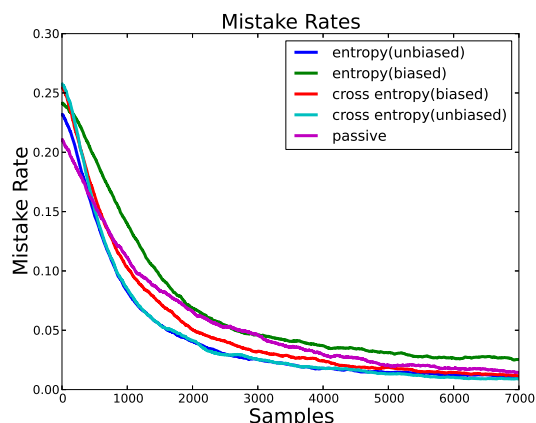
これらの能動学習法と、今回提案したオンライン転移学習を組み合わせる。前項の転移学習での設定と同じ状況に対する結果を、図 2 に示す。オンライン能動学習では一部のデータしか学習に使用されないため、累積誤識別回数の推移という形で評価することは難しい。そこで、ラベルをつけたデータの数を横軸に取り、縦軸をそのデータ数で学習した時の誤識別率という形で評価している。

単純なエントロピー基準による手法 (entropy (biased)) は能動学習を行わないもの (passive) に比べてあまり精度の向上が見られない一方、提案手法 1 と提案手法 2 をそれぞれ独立に用いた “entropy (unbiased)”, “cross entropy (biased)” が誤識別が少なく、精度が最も高くなっており、学習に必要なラベル付きデータを 4 割程度減らすことができている。しかし、2つの提案手法を組み合わせた “cross entropy (unbiased)” でさらに良い学習が行えるわけではいということがわかる。図 2(b) では重み $w_{0,t}$ の変化が示されているが、目標ドメインの重みの上昇が早すぎても遅すぎても、学習の質は下がってしまう。

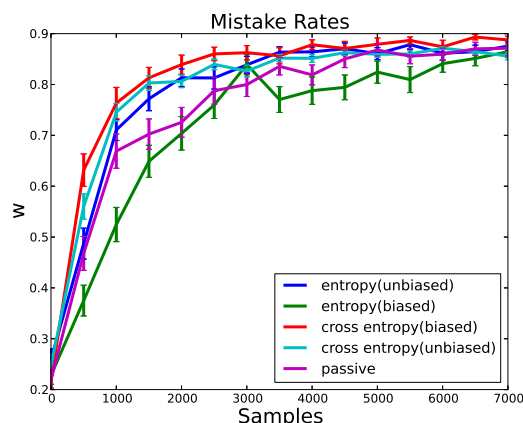
先に言及したとおり、オンライン転移学習における能動学習では、目標ドメインにおける学習と、適切な結合重みの調整という2つのタスクを同時に解いているということになる。相互に悪影響を及ぼさないように、両方を最適化できるように適切なデータを選んでラベルを要求しなければならず、難しい問題となる。しかし、提案手法の実験結果も示す通り、オンライン転移学習を行いながら能動学習を上手く行うことが出来れば、省メモリかつきわめて低コストで、効果的な学習を行うことができるため、この手法についてはさらなる分析が求められる。

参考文献

- [1] Nicolo Cesa-Bianchi and Gabor Lugosi. *Prediction, Learning, and Games*. Cambridge University Press, New York, NY, USA, 2006.
- [2] Wei Chu, Martin Zinkevich, Lihong Li, Achint Thomas, and Belle L. Tseng. Unbiased online active learning in data streams. In Chid Apté, Joydeep Ghosh, and Padhraic Smyth, editors, *KDD*, pages 195–203. ACM, 2011.



(a) 能動学習による誤識別率の変化



(b) 目標ドメインに対する重み $w_{0,t}$ の変化

図 2: 能動学習

- [3] Mark Dredze, Koby Crammer, and Fernando Pereira. Confidence-weighted linear classification. In William W. Cohen, Andrew McCallum, and Sam T. Roweis, editors, *ICML*, volume 307 of *ACM International Conference Proceeding Series*, pages 264–271. ACM, 2008.
- [4] Jeremy Z. Kolter and Marcus A. Maloof. Using additive expert ensembles to cope with concept drift. In Luc De Raedt and Stefan Wrobel, editors, *ICML*, volume 119 of *ACM International Conference Proceeding Series*, pages 449–456. ACM, 2005.
- [5] B. Settles. Active learning literature survey. Computer Sciences Technical Report 1648, University of Wisconsin–Madison, 2009.
- [6] Peilin Zhao and Steven C. H. Hoi. Otl: A framework of online transfer learning. In Johannes Fürnkranz and Thorsten Joachims, editors, *ICML*, pages 1231–1238. Omnipress, 2010.