

# 安全迁移支持向量机

周国华 巢海鲸 申燕萍

(常州轻工职业技术学院信息工程系 常州 213164)

**摘要** 迁移学习方法是一种新的机器学习框架,它将源领域数据通过学习迁移到相似的目标领域中,减弱了对已标记数据的依赖。但迁移学习方法中一个重大问题是使用目标领域数据与源领域数据得到的分类器很可能比仅利用目标领域数据得到的分类器的效果更差,从而造成一种“负迁移”现象。针对此问题,提出一种基于目标领域已标记数据知识的安全控制机制,并通过结合近年出现的一种迁移学习分类器(TL-SVM)提出了一种安全迁移支持向量机(SATL-SVM),从理论上解决了 TL-SVM 的负迁移问题,在人工数据集和真实数据集上的实验结果表明了所提方法的有效性。

**关键词** 迁移学习,支持向量机,分类

**中图分类号** TP391.4 **文献标识码** A

## Safety-aware Transfer Learning Support Vector Machine

ZHOU Guo-hua CHAO Hai-jing SHEN Yan-ping

(Department of Information Engineering, Changzhou Institute of Light Industry Technology, Changzhou 213164, China)

**Abstract** Transfer learning method is a new machine learning framework, which aims at realizing an effective learning for target domain by efficiently transferring the existing knowledge from source domain to target domain. It would be nice to reduce the need and effort to recollect the training data. However, the classifier trained by the data of source domain and target domain often put in a worse performance than the classifier only trained by the data of target domain, which leads to the appearance of “negative transfer”. To address this problem, a safety-control mechanism with the knowledge of the labeled data of target domain was proposed for safe transfer leaning. Furthermore, in implementation, based on a recent transfer learning method (TL-SVM), a safety-aware transfer learning support vector machine (SATL-SVM) was proposed, which avoids the appearance of “negative transfer” of TL-SVM theoretically. Experiment results on artificial datasets and real-world datasets show the effectiveness of the proposed method.

**Keywords** Transfer learning, Support vector machine, Classification

## 1 引言

模式分类的复杂性主要依赖于所研究的应用领域以及可用的先验知识。传统的模式分类方法若要获得较好的分类结果,则必须保证训练数据与测试数据满足独立同分布(Identically and Independently Distributed, IID)<sup>[1-2]</sup>。然而,在现今的很多新兴应用领域,如微信和 WiFi 数据的学习领域,并不能保证所有数据分布完全一致。另外,新数据的标记工作费时费力,而像博客、论坛帖子等与微信这类新兴领域相似的数据却可以较容易地得到,抛弃这些数据是不明智的选择。迁移学习<sup>[3-6]</sup>旨在研究如何利用这些相关领域的已标记的源领域数据或知识,对目标问题领域中的学习任务进行辅助,使得对目标领域中新实例的学习更快速有效。迁移学习已在一些领域的研究和应用中获得了广泛关注,如 Opbroek 等人<sup>[7]</sup>将根据图像属性间的关联获得的迁移知识用于不同领域图像的分割;Yang 等人<sup>[8]</sup>将迁移学习用于多种表现形式的癫痫脑电信号的识别;Cheng 等人<sup>[9]</sup>使用知识的迁移进行轻度认知障碍和阿兹海默症的预测;Mei 等人<sup>[10]</sup>将迁移学习用于多种类

型的大规模膜蛋白数据的识别;Ugent 等人<sup>[11]</sup>则将迁移问题应用到四足机器人上转移步态的学习上。现有的迁移学习技术主要发展为 3 个分支,即归纳式迁移学习、直推式迁移学习和无监督迁移学习<sup>[1,3]</sup>。其中关于归纳式迁移学习的研究最为广泛,因为在归纳式迁移学习中已知目标领域中少量的已标记数据与大量的源领域已标记数据,目标领域与源领域较容易进行知识的迁移,也比较符合实际情况。关于归纳式迁移学习的研究很多,例如 Gao 等人<sup>[12]</sup>提出了局部加权嵌入学习算法(LWE),其根据不同领域训练样本和待测领域样本间的联系设置不同的权重,进而实现领域间知识的迁移。洪佳明等人<sup>[13]</sup>定义了领域弱相似性的概念,而后将其与支持向量机(SVM)联系起来,提出了基于领域相似性的迁移学习方法(TrSVM),以达到有效迁移学习的目的。许敏等人<sup>[14]</sup>提出了迁移支持向量机 TL-SVM,该算法在训练目标领域模型时参考了源领域分类面参数这一知识,在构造目标函数时加入使得源领域和目标领域分类面参数最接近的迁移学习项,完成了由源领域知识到目标领域学习的有效迁移学习。虽然归纳式迁移学习取得了巨大的成功,但其也存在迁移学习的一个

本文受江苏省大学生创新项目(201513101015Y),江苏省卫生计生委信息化科研课题(X201510)基金资助。

周国华(1977—),男,硕士,讲师,主要研究领域为智能学习、模式识别,E-mail:tiddyddd@sina.com;巢海鲸(1981—),女,讲师,主要研究领域为人工智能、模式识别;申燕萍(1979—),女,讲师,主要研究领域为机器学习。

通病,即该方法存在负迁移问题。迁移学习中负迁移(Negative Transfer)就是指源领域数据或知识降低了目标领域的学习效果<sup>[1]</sup>。针对归纳式迁移学习,“负迁移”是指最后的迁移分类器的效果比仅使用目标领域已标记数据的有监督分类器的效果更差。

针对上述问题,本文在文献[14]提出的 TL-SVM 的基础上提出了一种具备安全迁移能力的迁移学习方法(Safety Transfer Learning Support Vector Machine, STL-SVM)。该方法的主要思想是将安全迁移机制引入到迁移学习框架中,以 TL-SVM 方法为研究对象,通过引入安全迁移学习机制,构造一种新的安全迁移优化目标学习准则,并通过相关的理论得证新分类器的求解过程依然是一个二次规划(Quadratic Programming, QP)问题。由于本文方法在原理上保证了目标领域模型的分类效果不差于在目标领域内的有监督学习,因此相较于现有的相关方法,本文工作具有较大的优势。

### 2 TL-SVM 方法

为引出所提分类器方法,本节简单介绍与所提方法紧密相关的迁移学习方法——TL-SVM 方法<sup>[14]</sup>。以二分类为例,支持向量机的判别函数为  $f(x) = w^T x + b$ ,其中包含两个参数  $w$  和  $b$ 。TL-SVM 算法的核心思想是:若两领域相关,则各自分类器的  $w$  值应相近。通过在软间隔 SVM<sup>[15]</sup> 目标式中增加迁移项  $\mu \|w_t - w_s\|^2$ , TL-SVM 实现了领域间参数的迁移,其优化目标函数的表达式如下:

$$\min_{w_t, b_t} \frac{1}{2} \|w_t\|^2 + C_t \sum_{i=1}^n \xi_i + \mu \|w_t - w_s\|^2$$

$$\text{s. t. } y_i^t (w_t^T x_i + b_t) \geq 1 - \xi_i, \xi_i \geq 0, i = 1, 2, \dots, n \quad (1)$$

### 3 安全迁移学习支持向量机

参考 TL-SVM 算法的模型,本文给出安全迁移学习支持向量机模型,其原理如图 1 所示。由图 1 可知,为了解决因目标领域数据不足可能带来的分类学习效果不佳的问题,所提方法利用了源领域中学习的知识来辅助学习。值得一提的是,为了保证迁移学习不产生负迁移,利用在目标领域上学习的决策值来保证所提方法最终所得分类器的学习性能。这既有效地进行了迁移学习,又同时保证了最终分类器一定会优于不采用迁移的方法。

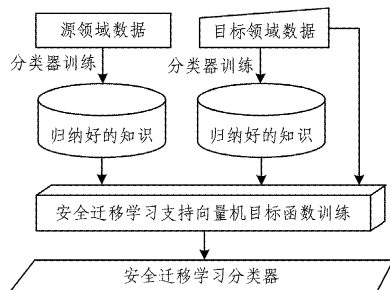


图 1 安全迁移学习支持向量机的原理结构图

#### 3.1 融合历史知识与当前知识的安全迁移学习机目标函数的构造

从源领域和目标领域的分类器得到的知识都可以辅助新分类器的构造,针对支持向量机的分类学习模型,其中可以利用的知识有分类面的参数  $w$  和最终的决策值  $f(x)$  等。本文分类器的特点是既利用源领域受训的 SVM 分类模型的参数来进行有效的迁移学习,又利用对于目标领域已标定数据受

训的 SVM 分类模型的决策值来进行约束。基于上述分析,以 TL-SVM 为基础框架,构造一种引入安全迁移机制的 SATL-SVM 的新学习目标函数:

$$\min_{w_t, b_t} \frac{1}{2} \|w_t\|^2 + C \sum_{i=1}^l \xi_i + \frac{\lambda}{2} \|w_t - w_s\|^2$$

$$\text{s. t. } y_i (w_t^T x_i + b_t) \geq 1 - \xi_i, y_i (w_t^T x_i + b_t - \tilde{w}_t^T x_i - \tilde{b}_t) \geq 0,$$

$$\xi_i \geq 0, i = 1, 2, \dots, l \quad (2)$$

其中,  $\{(x_i, y_i)\}_{i=1}^l$  为目标领域中已标定样本及其所属类别;  $\xi = [\xi_1, \dots, \xi_l]^T$  为松弛变量;  $C$  为目标领域正则化参数;  $w_s$  为历史领域知识中归纳学习的知识;  $f(x_i) = \tilde{w}_t^T x_i - \tilde{b}_t$  为目标领域中 SVM 分类器的决策结果。

对于式(2)所示的优化目标函数,本文给出如下说明:

- 1)  $\frac{1}{2} \|w_t\|^2 + C \sum_{i=1}^l \xi_i$  分别表示目标领域数据的结构风险项和经验风险项;
- 2)  $\|w_t - w_s\|^2$  反映了目标领域和历史领域分类器的差异程度,其值越大,则反映的分类器差异越大,反之则表示二者越相似,  $\lambda$  为协调系数;
- 3) 约束条件  $y_i (w_t^T x_i + b_t) \geq 1 - \xi_i (i = 1, \dots, n)$  确保在目标领域中分类器尽可能正确分类;
- 4) 约束条件  $y_i (w_t^T x_i + b_t - \tilde{w}_t^T x_i - \tilde{b}_t) \geq 0$  确保最终的迁移效果不差于仅在目标领域中已标定数据上的 SVM 分类学习效果,也决定了 SATL-SVM 在理论上不存在负迁移,即迁移学习效果比不迁移的效果更好。

从式(2)所示的目标函数表达式可以知道, SATL-SVM 的特点在于,其在分类模型的训练过程中在理论上保证了最终结果要优于非迁移分类器的效果,因而从根本上消除了产生负迁移的可能性。因为在实际应用中,我们无法保证目标领域与源领域一定具有可以迁移的相似知识或数据,所以极易产生负迁移现象,因此较其他迁移方法如 TL-SVM, 本文所提 SATL-SVM 方法具有一定的优势。

式(2)所示的安全迁移支持向量机可转化为如下对偶问题形式进行求解:

$$L(w_t, b_t, \xi, \alpha, \beta, r) =$$

$$\frac{1}{2} \|w_t\|^2 + C \sum_{i=1}^l \xi_i + \frac{\lambda}{2} \|w_t - w_s\|^2 - \sum_{i=1}^l \alpha_i (y_i (w_t^T x_i + b_t) - 1 + \xi_i) - \sum_{i=1}^l \beta_i y_i (w_t^T x_i + b_t - \tilde{w}_t^T x_i - \tilde{b}_t) - \sum_{i=1}^l r_i \xi_i \quad (3)$$

其中,  $\alpha = [\alpha_1, \dots, \alpha_l]^T, \beta = [\beta_1, \dots, \beta_l]^T, r = [r_1, \dots, r_l]^T, \xi = [\xi_1, \dots, \xi_l]^T$  是拉格朗日系数。

根据 Karush-Kuhn-Tucker (KKT)<sup>[16]</sup> 条件,有如下等式成立:

$$\frac{\partial L}{\partial \xi_i} = 0 \Rightarrow C = \alpha_i + r_i \Rightarrow 0 \leq \alpha_i \leq C \quad (4)$$

$$\frac{\partial L}{\partial b_t} = 0 \Rightarrow \sum_{i=1}^l y_i (\alpha_i + \beta_i) = 0 \quad (5)$$

$$\frac{\partial L}{\partial w_t} = 0 \Rightarrow w_t + 2\lambda (w_t - w_s) - \sum_{i=1}^l y_i (\alpha_i + \beta_i) x_i = 0$$

$$\Rightarrow w_t = \frac{1}{2\lambda + 1} \left( \sum_{i=1}^l y_i (\alpha_i + \beta_i) x_i + 2\lambda w_s \right) \quad (6)$$

将式(4)一式(6)代入式(3)并化简后可得到形如式(7)所示的对偶问题形式:

$$\min_{\alpha, \beta} \frac{1}{2(2\lambda + 1)} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i + \beta_i) (\alpha_j + \beta_j) y_i y_j x_i^T x_j +$$

$$\frac{2\lambda}{2\lambda+1}(\alpha_i+\beta_i)y_i\mathbf{x}_i^T\mathbf{w}_i+\sum_{i=1}^l\beta_i(\tilde{\mathbf{w}}_i^T\mathbf{x}_i+\tilde{b}_i)-\sum_{i=1}^l\alpha_i$$

$$\text{s. t. } \alpha_i \in [0, C], \sum_{i=1}^l y_i(\alpha_i + \beta_i) = 0, i=1, 2, \dots, l \quad (7)$$

则式(7)可表示为式(8)所示的二次规划矩阵形式<sup>[17]</sup>:

$$\min_{\boldsymbol{\gamma}} \frac{1}{2} \boldsymbol{\gamma}^T \tilde{\mathbf{K}} \boldsymbol{\gamma} + \tilde{\mathbf{e}}^T \boldsymbol{\gamma} \quad (8)$$

$$\text{s. t. } \mathbf{f}^T \boldsymbol{\gamma} = 0$$

其中:

$$\tilde{\mathbf{K}} = \frac{1}{2(1+\lambda)} \begin{bmatrix} \mathbf{K}_{1,1} & \mathbf{K}_{1,2} & -\mathbf{K}_{1,2} \\ \mathbf{K}_{1,2}^T & \mathbf{K}_{2,2} & -\mathbf{K}_{2,2} \\ -\mathbf{K}_{1,2} & -\mathbf{K}_{2,2} & \mathbf{K}_{2,2} \end{bmatrix}$$

$$\mathbf{K}_{1,1} = (y_i y_j \mathbf{x}_i^T \mathbf{x}_j)_{i,j=1,\dots,m}$$

$$\mathbf{K}_{1,2} = (\mathbf{x}_i^T \mathbf{x}_j y_j)_{i=1,\dots,l, j=1,\dots,m}$$

$$\mathbf{K}_{2,2} = (\mathbf{x}_i^T \mathbf{x}_j)_{i,j=1,\dots,n}$$

$$\boldsymbol{\gamma} = [\alpha_1, \dots, \alpha_l, \beta_1, \dots, \beta_l]^T = [\boldsymbol{\alpha}^T, \boldsymbol{\beta}^T]^T$$

$$\mathbf{f}^T = [y_1, \dots, y_l, y_1, \dots, y_l]$$

$$\tilde{\mathbf{e}} = [\tilde{\mathbf{w}}_1^T \mathbf{x}_1 + b_1, \dots, \tilde{\mathbf{w}}_l^T \mathbf{x}_l + b_l, \underbrace{-1, \dots, -1}_l]^T$$

$$\mathbf{z} = [\mathbf{z}_i]^T = [\mathbf{x}_1, \dots, \mathbf{x}_l, \mathbf{x}_1, \dots, \mathbf{x}_l]^T$$

设  $\boldsymbol{\gamma}^* = [\alpha_1^*, \dots, \alpha_l^*, \beta_1^*, \dots, \beta_l^*]^T$  是对偶问题(8)的解, 参照文献[17], 原始问题(3)关于  $\mathbf{w}_i$  和  $b_i$  的解为:

$$\mathbf{w}_i = \frac{1}{2\lambda+1} \left( \sum_{i=1}^l y_i (\alpha_i + \beta_i) \mathbf{x}_i + 2\lambda \mathbf{w}_s \right) \quad (9)$$

$$b_i = \frac{1}{l} \sum_{i=1}^l \left( y_i - \frac{1}{2\lambda+1} \left( \sum_{j=1}^l y_j (\alpha_j + \beta_j) \mathbf{x}_j^T \mathbf{x}_i + 2\lambda \mathbf{w}_s^T \mathbf{x}_i \right) \right) \quad (10)$$

### 3.2 算法描述

根据上述 SATL-SVM 方法的推导和结论, 本小节给出所提安全迁移学习方法的步骤, 如算法 1 所示。

#### 算法 1 SATL-SVM 方法

Input:  $n$  个有标号的源领域样本  $\{(\tilde{\mathbf{x}}_i, \tilde{y}_i)\}_{i=1}^n$ ,  $l$  个有标号的目标领域样本  $\{(\mathbf{x}_i, y_i)\}_{i=1}^l$

Output: 分类决策函数  $g(\mathbf{x})$

源领域知识归纳阶段:

Step1 设置核函数带宽  $\sigma_s$  和正则参数  $C_s$ ;

Step2 利用 SVM 得到源领域数据的分类模型;

Step3 利用二次规划原理求解源领域拉格朗日向量  $\boldsymbol{\alpha}^s$ ;

Step4 归纳源领域知识  $\mathbf{w}_s = \sum_{i=1}^s \alpha_i^s \tilde{y}_i \tilde{\mathbf{x}}_i$ ;

当前分类标准得出阶段:

Step1 设置核函数带宽  $\sigma_t$  和正则参数  $C_t$ ;

Step2 利用 SVM 得到源领域数据的分类模型;

Step3 利用二次规划原理求解源领域拉格朗日向量  $\boldsymbol{\alpha}^t$ ;

Step4 归纳领域分类参数,  $\tilde{\mathbf{w}}_i = \sum_{i=1}^l \alpha_i^t y_i \mathbf{x}_i$ ,  $\tilde{b}_i = \frac{1}{l} \sum_{j=1}^l (y_j - \sum_{i=1}^l \alpha_i^t k(\mathbf{x}_i, \mathbf{x}_j))$ ;

迁移学习阶段:

Step5 根据式(9)计算决策超平面法向量  $\mathbf{w}_i$ ;

Step6 根据式(10)计算偏移量  $b_i$ ;

Step7 输出分类决策函数  $f(\mathbf{x}) = \mathbf{w}_i^T \varphi(\mathbf{x}) + b_i$ 。

## 4 实验与分析

为了综合评价 SATL-SVM 的性能, 选用了人工二维双月型数据集以及文本分类数据集 20Newsgroup 和 Reuters<sup>[18-19]</sup> 这两类不同类型的数据集。实验主要从非迁移、迁移和安全迁移 3 个角度来组织, 以评价所提分类器的优势。实验使用源域已标签样本集, 目标域已标签样本集、源域与目

标域已标签样本集合并 3 种情况下的样本集作为 SVM 的训练集进行训练, 分别记为 SVM-S, SVM-T 和 SVM-ST, 这些方法将与迁移学习方法比较, 以说明迁移学习的必要性。在迁移学习方面, 本文所提方法与 TL-SVM 方法进行比较, 用以说明安全迁移学习的必要性。

本文选用了分类算法普遍使用的分类精确度作为评价算法性能的指标:  $Accuracy = \frac{|\{x | x_c \in D_c \cap f(x_c) = y_c\}|}{|\{x | x_c \in D_c\}|}$ , 其中  $D_c$

表示目标领域数据集,  $y_c$  表示  $x_c$  的真实标签类别,  $f(\mathbf{x})$  为使用学习所得分类器对  $\mathbf{x}_c$  进行分类的结果。

本文实验中所有算法的最优参数均通过网格搜索的方式来确定。核函数均采用高斯核函数, 核宽度参数  $2\sigma^2$  以源领域样本的平均 2 范数的平方  $s$  为基准, 并在网格  $\{s/64, s/32, s/16, s/8, s/4, s/2, s, 2s, 4s, 8s, 16s, 32s, 64s\}$  中搜索最优值; TL-SVM 方法采用与文献[14]相同的策略。SATL-SVM 的正则化参数  $C_s$  和  $C_t$  在网格  $\{2^{-5}, 2^{-4}, \dots, 2^5\}$  中搜索最优值; 平衡参数  $\lambda$  在区间  $\{2^{-5}, 2^{-4}, \dots, 2^8\}$  中搜索最优值。所有实验均在 Intel Core2, 2.6GHz 主频、8GB RAM、Windows 7 系统下执行, SVM 算法由 Libsvm 软件<sup>[20]</sup> 实现, 其他算法均在 Matlab R2009A 环境下实现。对于实验中所有的数据集, 历史领域和目标领域的样本均具有标签信息, 但目标领域样本的标签信息仅用于评价各算法的分类性能。

### 4.1 人造双月型数据集

构造均值为 0、标准差为 1、正负类样本各 150 个的双月型目标领域数据集。实验随机抽取 20 个点作为目标领域中已标记的点, 其他点为未标记点。如图 2(a) 所示, 将该源领域数据集围绕所有样本的中心顺时针方向旋转 6 次, 每次旋转  $10^\circ$ , 从而得到 6 个源领域数据集。图 2(b) 描述了目标领域数据集在顺时针旋转  $60^\circ$  后得到的源领域数据集。由图 2 可见, 旋转角度越大, 目标领域和源领域的分布差异越大, 越容易产生负迁移情况。SVM-T 为使用目标领域中已标记点进行训练得到的分离器。TL-SVM 为使用目标领域已标记点和源领域分类知识的迁移学习分类器, SATL-SVM 为使用目标领域已标记点和源领域分类知识的安全迁移学习分类器。图 3 比较了 SVM-T, TL-SVM 和 SATL-SVM 算法的分类性能。

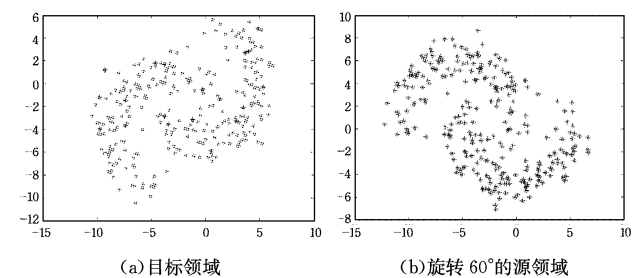


图 2 目标领域和旋转  $60^\circ$  得到的源领域双月数据集




图 3 各种算法在旋转不同角度的双月数据集上的分类精度变化趋势

由图2和图3可知:

1) 由于SVM-T仅使用目标领域中已标记点进行训练,因此旋转不同角度的源领域对其没有影响。还可以看出,因为目标领域的已标记点较少,所以分类器的效果一般。

2) TL-SVM训练时使用目标领域已标记点和源领域分类知识,在旋转角度不大时,源领域的分布与目标领域比较相近,所以源领域得到的分类超平面知识为有用知识,TL-SVM得到了非常高的分类精确度;但随着源领域旋转角度的增大,源领域得到的分类超平面知识对最终的分类结果起到了负迁移作用,在旋转30°附近,TL-SVM的分类效果已经差于SVM-T,并且随着旋转角度的增大持续变差。

3) 对于本文所提SATL-SVM,其由于采用了安全迁移机

制,使得在源领域旋转角度较大时避免了负迁移效果的产生,进而使得所提方法的效果始终好于TL-SVM。

#### 4.2 真实数据集20Newsgroups和Reuters

本节将抽取常用的文本分类数据集20Newsgroups和Reuter来评价所提方法。对于20Newsgroups文本数据集,实验中分别从顶层大类中抽取6个大类以构建学习数据集,其中每2个大类分别选作正类和负类,数据基于子类进行分割,不同的子类被认为是不同的领域。具体的抽取情况如表1所列。实验构造的20Newsgroups文本数据集各学习任务的详细信息如表1所列。在目标领域选取数量为源领域数据规模的1%的数据为已标记数据,构成迁移学习任务。5种对比方法在9个学习任务上的分类性能如表2所列。

表1 不同领域真实数据集的详细描述

序号	学习任务	源领域	目标领域	特征
T1	comp vs. rec	comp. {graphics,os} rec. {autos,motorcycles}	com. sys. {ibm,mac} rec. sport. {baseball,hokey}	26214
T2	comp vs. sci	comp. {graphics,os} sci. {crypt,med}	comp. sys. {ibm,mac} sci. {electronic,space}	26214
T3	comp vs. talk	comp. {graphics,os} politics. {guns,mideast}	comp. sys. {ibm,mac} talk. {politics, misc,religion}	26214
T4	rec vs. sci	rec. {autos,motorcycles} sci. {crypt,med}	rec. sport. {baseball,hokey} sci. {electronic,space}	26214
T5	rec vs. talk	rec. {autos,motorcycles} politics. {guns,mideast}	rec. sport. {baseball,hokey} talk. {politics, misc,religion}	26214
T6	sci vs. talk	sci. {crypt,med} politics. {guns,mideast}	sci. {electronic,space} talk. {politics, misc,religion}	26214
T7	orgs vs. people	orgs. {...},people. {...}	orgs. {...},people. {...}	4771
T8	orgs vs. place	orgs. {...},place. {...}	orgs. {...},place. {...}	4415
T9	people vs. place	people. {...},place. {...}	people. {...},place. {...}	4562

表2 不同方法在各个数据集上的精度比较结果

序号	SVM-S	SVM-T	SVM-ST	TL-SVM	SATL-SVM
T1	0.8433	0.5632	0.8508	0.9111	<b>0.9412</b>
T2	0.8112	0.5480	0.8651	<b>0.8921</b>	0.8911
T3	0.8921	0.6908	0.9055	0.9524	<b>0.9631</b>
T4	0.6668	0.5298	0.7800	<b>0.7768</b>	<b>0.7768</b>
T5	0.8321	0.5689	0.8779	0.9049	<b>0.9443</b>
T6	0.5555	0.6209	0.6733	0.7206	<b>0.7513</b>
T7	0.6800	0.6479	0.6899	0.7229	<b>0.7631</b>
T8	0.6610	0.6788	0.7077	0.7255	<b>0.7462</b>
T9	0.5971	0.6422	0.5746	0.6144	<b>0.6612</b>

根据表2的实验结果,我们可得出如下结论:

1) 由于源领域数据与目标领域数据在数据分布上存在差异,因此SVM-S的分类效果不理想;由于目标领域已标记数据较少,分类器学习不充分,因此SVM-T的分类效果也不理想;而将源领域数据与目标领域数据通过简单相加作为训练集的方法也不能够很好地利用数据信息;虽然SVM-ST的分类效果依旧不理想,但其单分类精度都超过了前两种分类器。这说明了目标领域数据对于分类器训练的重要性。

2) 两种迁移学习方法TL-SVM和SATL-SVM由于不仅利用了目标领域的已标记数据,还充分考虑了源领域数据和的辅助信息,因此都取得了不错的分类效果。这说明在领域相似的分类问题上,迁移学习比其他传统方法具有明显的优势。

3) 同为迁移学习方法,TL-SVM和SATL-SVM方法的精度在源领域和目标领域相似度较高的数据集上相差无几,

但在相关度低的数据集(比如people vs. place)上,TL-SVM的精确度不升反降,这充分说明了TL-SVM不具备处理负迁移的能力;而本文所提方法则在优化目标函数的构造上就杜绝了这种情况的发生,因此取得了较高的精确度。随着数据获取难度的降低,我们未来将获得更多的相似数据集,而在大多数情况下并不知道它们的相关性如何,因此本文所提方法将会有更大的应用前景。

**结束语** 本文针对归纳式迁移学习,提出了SATL-SVM方法,其继承了迁移学习通过融合源领域和目标领域知识从而可以获得较好分类器的优点,从原理上克服了迁移学习中负迁移情况的发生,在源领域和目标领域相似性较低的情况下依然有不错的学习效果。在人工数据和真实数据集上进行了仿真实验,结果亦表明了本文所提方法在迁移学习问题上的有效性。下一步的研究方向是如何将提出的SATL-SVM方法拓展到多分类情况下,并探索在大数据环境下的有效实际应用。

#### 参考文献

- [1] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge & Data Engineering, 2010, 22(10): 1345-1359.
- [2] 庄福振,罗平,何清等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1): 26-39.

**结束语** 本文将半结构化 XML 文件作为桥梁将网上爬虫的非结构化数据转化成了结构化数据。转换过程利用了 SAX 技术对 XML 文件进行解析,并通过实验对比证实了在 DOM 解析的基础上 SAX 方法较好地提高了解析效率。但本文还有不足之处,只对文档类文件的处理进行了研究,缺少对其他类型文件的研究,在以后的学习中会加强这方面的研究。

### 参 考 文 献

- [1] 万里鹏. 非结构化到结构化数据转换的研究与实现[D]. 成都: 西南交通大学, 2013.
- [2] CHIEW W S, HAW S C, SUBRAMANIAM S, et al. Labeling Schemes for Xml Dynamic Updates; a Survey and Open Discussions[C]//Proceedings of the 2014 International Conference on E-commerce, e-business and E-service. 2014; 79-83.
- [3] 施伟斌, 孙未未, 施伯乐. XML 数据的结构化处理方法[J]. 计算机研究与发展, 2002, 39(7): 819-826.
- [4] 李爱民, 谭献海. 基于 XML 技术的非结构化数据到结构化数据转换的研究[J]. 铁路计算机应用, 2012, 21(10): 12-15.
- [5] MARTENS W, NEVEN F, SCHWENTICK T, et al. Expressiveness and complexity of XML Schema[J]. ACM Transactions on Database Systems, 2006, 31(3): 770-813.
- [6] SHANMUGASUNDARAM J, SHEKITA E, BARR R, et al. Efficiently publishing relational data as XML documents[J]. The VLDB Journal, 2001, 10(2): 133-154.
- [7] 鉴保瑞, 宋余庆, 陈健美, 等. 一种基于关系的 XML 文档模型映射方法[J]. 计算机应用研究, 2011(12): 4621-4624.
- [8] 冯进, 丁博, 史殿习, 等. XML 解析技术研究[J]. 计算机工程与科学, 2009, 31(2): 120-124.
- [9] 贾福林, 王国仁, 于戈. 基于 DOM 的 XML 数据库的索引技术研究[J]. 计算机研究与发展, 2004, 41(1): 175-186.
- [10] 赵俊岚. XML 编程中的 DOM 与 SAX 技术[J]. 计算机工程, 2004, 30(24): 70-72.
- [11] 杨治, 鞠时光. 基于 SAX 的 XML 数据结构聚簇存储方法[J]. 计算机工程, 2008, 34(18): 72-74.
- [12] COLLADO E M, SOTO M A C, DELAMER I M, et al. Embedded XML DOM parser: an approach for XML data processing on networked embedded systems with real-time requirements[J]. EURASIP Journal on Embedded Systems, 2007, 2008(1): 163864.
- [13] 戴维. POI 实现 Excel 的数据导入导出的研究[J]. 科技信息, 2013(1): 107.
- (上接第 384 页)
- [3] WEISS K, TAGHI M K, WANG D D. A survey of transfer learning[J]. Journey of Big Data, 2016, 3(9): 1-40.
- [4] LU J, BEHBOOD V, HAO P, et al. Transfer learning using computational intelligence: a survey[J]. Knowledge-Based Systems, 2015, 80(5): 14-23.
- [5] BIONDI G O, PRATI R C. Setting parameters for support vector machines using transfer learning[J]. Journal of Intelligent & Robotic Systems, 2015, 80(12): 295-311.
- [6] YING L, LIU B. Application of transfer learning in task recommendation system[J]. Procedia Engineering, 2017, 174(2): 518-523.
- [7] OPBROEK V, IKRAM A. Transfer learning improves supervised image segmentation across imaging protocols[J]. IEEE Transactions on Medical Imaging, 2015, 34(5): 1018-1030.
- [8] YANG C J, DENG Z H, CHOI K S, et al. Takagi-Sugeno-Kang transfer learning fuzzy logic system for the adaptive recognition of epileptic electroencephalogram signals[J]. IEEE Transactions on Fuzzy Systems, 2016, 24(5): 1079-1094.
- [9] CHENG B, LIU M X, ZHANG D Q, et al. Domain transfer learning for MCI conversion prediction[J]. IEEE Transactions on Biomedical Engineering, 2015, 62(7): 1805-1817.
- [10] MEI S Y. SVM ensemble based transfer learning for large-scale membrane proteins discrimination[J]. Journal of Theoretical Biology, 2014, 340(1): 105-110.
- [11] UGENT J D, BURM M, KINDERMANS P J. Transfer learning of gaits on a quadrupedal robot[J]. Adaptive Behavior, 2015, 23(2): 69-82.
- [12] GAO J, FAN W, JIANG J, et al. Knowledge transfer via multiple model local structure mapping[C]//ACM the 14th SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: ACM, 2008: 283-291.
- [13] 洪佳明, 印鉴, 黄云, 等. 一种基于领域相似性的迁移学习算法[J]. 计算机研究与发展, 2011, 48(10): 1823-1830.
- [14] 许敏, 王士同, 顾鑫. TL-SVM: 一种迁移学习新算法[J]. 控制与决策, 2014, 29(1): 141-146.
- [15] VAPNIK V. Statistical Learning Theory[M]. John Wiley and Sons, 1998.
- [16] ARGYRIOU A, MICCHELLI C A, PONTIL M. When is there a representer theorem? vector versus matrix regularizers[J]. Journal of Machine Learning Research, 2009, 10(12): 2507-2529.
- [17] 邓乃杨, 田英杰. 数据挖掘的新方法——支持向量机[M]. 北京: 科学出版社, 2004.
- [18] XIANG E W, CAO B, HU D H, et al. Bridging domains using world wide knowledge for transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(6): 770-783.
- [19] BRUZZONE L, MARCONCINI M. Domain adaptation problems: A DASVM classification technique and a circular validation strategy[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(5): 770-787.
- [20] CHANG C C, LIN C J. LIBSVM: a library for support vector machines[J/OL]. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, 2001.