

具有协同约束的共生迁移学习算法研究

张景祥^{1,2}, 王士同¹, 邓赵红¹, 李 奕¹, 蒋亦樟¹

(1. 江南大学数字媒体学院, 江苏无锡 214122; 2. 江南大学理学院, 江苏无锡 214122)

摘 要: 传统迁移学习方法通常直接利用相关领域中的数据来辅助完成当前领域的学习任务, 而忽略了领域间互相学习的能力. 针对此类问题, 提出了一种具有协同约束的共生迁移学习方法 (Collaborative Constraints based Symbiosis Transfer Learning, CCSTL). 在协同约束的基础上, 引入共生迁移机制实现领域间的交替互动学习, 进而实现源领域和目标领域间的知识迁移, 从而提高受训分类器的分类性能. 在模拟数据和真实数据集上的实验结果表明了新算法的有效性.

关键词: 协同约束; 共生迁移学习; 分类; 支持向量机

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2014)03-0556-05

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2014.03.020

Symbiosis Transfer Learning Method with Collaborative Constraints

ZHANG Jing-xiang^{1,2}, WANG Shi-tong¹, DENG Zhao-hong¹, LI Yi¹, JIANG Yi-zhang¹

(1. School of Digital Media, Jiangnan University, Wuxi, Jiangsu 214122, China;

2. School of Science, Jiangnan University, Wuxi, Jiangsu 214122, China)

Abstract: Transfer learning algorithms usually focus on reusing data of related domains to help solving the learning tasks in the target domain. However, these methods ignore the ability of mutual learning between domains. In this paper, a collaborative constraint based symbiosis transfer learning method (CCSTL) is proposed. Symbiotic transfer mechanism is used to implement mutual learning among domains along with the collaborative constraint. With the help of the iterative optimizations, the proposed method can realize knowledge transfer between the source and target domains. Experimental results on synthetic and real world datasets show the superior or comparable performance of the proposed algorithm compared with existing algorithms.

Key words: collaborative constraints; symbiosis transfer learning; classification; support vector machine

1 引言

迁移学习方法的提出在机器学习领域产生了巨大的影响^[1~3]. 根据领域和任务的不同设置, 迁移学习通常被分成三类: 归纳式迁移学习、直推式迁移学习和无监督迁移学习. 为了提高迁移学习的效率, 学者们从不同角度提出很多策略, 大致分为两类: 一类是选取源领域相关的训练样本, 直接应用到目标领域的学习任务中, 并通过在学习过程添加适当约束条件和样本加权来强化样本的选择和使用, 从而提高目标领域模型的可靠度. 具有代表性的工作有: LP-SVM^[4], LWL^[5]等方法; 另外一类是寻找训练样本新的特征表示或局部特征, 使得在新特征表示下, 减小不同领域的分布差异, 将源领域知识迁移到目标领域. 代表性的工作有: LMPROJ^[6], DASVM^[7], TCA^[8]等方法.

上述方法虽然都取得了一定的效果, 但也面临一些

不足之处: 不论是基于源领域数据选择和加权的迁移学习, 还是基于共同特征表示的迁移学习, 都强调目标领域对源领域信息的提取和学习, 而没有考虑领域间互相学习的问题, 即忽略了源领域和目标领域间的互动学习. 由于不同域之间的互动在学习中是很有意义的, 因此在迁移学习过程适度地考虑不同领域之间的互动是有必要的.

因此, 本文提出了一种具有协同约束的共生迁移学习 (Collaborative Constraints based Symbiosis Transfer Learning, CCSTL) 算法. CCSTL 是一个交替迭代迁移学习的过程, 首先利用源领域数据训练得到的分类器对目标领域中未标记的数据进行“辅助”标记, 在协同约束的条件下, 将有标签的源领域数据和带有“辅助标签”的目标领域数据统一嵌入到支持向量机 (SVM) 的训练过程中, 得到目标领域的分类器; 再运用共生迁移学习的策略, 以新得到的目标领域分类器信息为主导, 重新训练得到源

领域新的分类器,以此作为源领域知识再重新指导目标领域的学习,最终通过迭代实现源领域和目标领域互相迁移学习.CCSTL方法强化了相似领域间分类器的分类协同性,并在不断的交替迭代优化过程中获取最终一致性较好的分类模型.较现有相关方法,本文方法的特色之处在于:(1)提出了领域协同约束的策略.(2)提出了共生迁移学习策略,在交替迭代共生迁移学习过程中,不断通过目标领域和源领域的交互学习,提高所训分类器的性能.

2 相关概念及问题描述

为了便于描述提出的迁移学习算法,首先对一些相关概念和符号进行相关说明.

定义 1 样本集:样本集常用 $D = \{(x_i, y_i) | x_i \in \mathbf{R}^d, y_i \in \{1, -1\}, 1 \leq i \leq N\}$, 其中 d 为样本特征维数, N 为样本容量.

定义 2 协同分类:设源领域和目标领域是两个数据分布不同但相似的同维数据域,若源领域分类决策函数 $f_s(x)$ 和目标领域分类器决策函数 $f_t(x)$ 对目标领域所有样本都具有相近的分类决策结果,则称这两个领域的分类器具有协同分类性.

对于迁移学习中不同领域的分类器而言,协同的结果是使分类器双方(或多方)分类效果在迁移过程中向同一方向积极发展,以促进迁移学习更为和谐有效.

定义 3 共生迁移学习:迁移学习大都是利用源领域的历史知识为目标领域提供有利于学习的信息,反之,若目标领域的判别信息也能有效指导源领域的学习,那么两个不同领域之间能通过相互学习,最终形成紧密互利的迁移关系.本文称此类迁移过程为共生迁移学习.

3 具有协同约束的共生迁移学习机

3.1 协同约束共生迁移策略及学习框架

针对上述分析,本节给出具有协同约束共生迁移机制学习机的学习框架,如图 1 所示.其学习策略可概括为以下几点:(1)利用有标记的源领域数据训练得到的初始分类器对目标领域数据进行辅助标记.(2)根据




图1 本文提出的协同约束共生迁移迭代学习框架图

协同约束,利用源领域主导的协同约束共生迁移学习优化当前目标领域的分类器.(3)根据共生迁移的策略,利用目标领域主导的协同约束共生迁移重新优化源领域分类器.(4)交替迭代执行(2)和(3),直到满足给定的终止条件,例如目标领域前后两次学习得到的分类器参数变化小于给定阈值.

3.2 源领域主导的协同约束共生迁移学习

源领域主导的协同约束共生迁移是本文提出的协同共生迁移方法重要组成部分.其学习思路如下:首先假设源领域已经得到一个初始分类器,以 SVM 分类器为例得到 $f_s(x) = \mathbf{w}_s^T \mathbf{x} + b_s$, 然后以 $f_s(x)$ 为主导,给出如下的源领域主导的协同约束共生迁移学习目标函数:

$$\min_{\mathbf{w}_t, b_t, \xi} \frac{1}{2} \mathbf{w}_t^T \mathbf{w}_t + \frac{\lambda}{2} (\mathbf{w}_s - \mathbf{w}_t)^T (\mathbf{w}_s - \mathbf{w}_t) + \frac{\lambda}{2} (b_s - b_t)^2 + C \sum_{j=1}^{N_t} \xi_j^2 \quad (1)$$

$$\text{s.t. } (\mathbf{w}_s^T \mathbf{x}_j + b_s) (\mathbf{w}_t^T \mathbf{x}_j + b_t) \geq 0 - \xi_j^2 \quad (2)$$

$$\xi_j^2 \geq 0, j = 1, 2, \dots, N_t$$

对于上述目标函数说明如下:(1) \mathbf{w}_t, b_t 为待求解的目标领域分类器参数; C 表示正则化参数; ξ_j^2 表示对目标领域错分的程度; N_t 表示目标领域的样本数;(2) 由定义 2 可知,式(2)即为协同约束项.其使得目标领域和源领域能在学习过程中协同一致;(3) 目标函数中,除了传统的 SVM 优化项之外,还增加了目标领域和源领域的共生迁移项,即 $\|\mathbf{w}_s - \mathbf{w}_t\|^2$ 和 $\|b_s - b_t\|^2$, 这两项使得目标领域在某种程度上能有效地从源领域中获得知识.对于式(1)的优化问题,可以利用拉格朗日乘子法转化为下面的定理求解.

定理 1 对于式(1)所示的优化问题,其对偶优化问题可表示为:

$$\min_{\alpha} \frac{1}{2} \alpha^T \mathbf{H} \alpha - \mathbf{f}^T \alpha \quad (3)$$

$$\text{s.t. } 0 \leq \alpha_i \leq C, i = 1, 2, \dots, N_t$$

其中, α 为拉格朗日乘子向量; $\mathbf{H} = [k_{ij}]_{N_t \times N_t}$ 为核矩阵.

$\mathbf{f} = (\frac{\lambda}{1+\lambda} \sum_{j=1}^{N_t} h_j^s \mathbf{w}_s^T \mathbf{x}_j - h_j^s b_s)$, $h_j^s = (\mathbf{w}_s^T \mathbf{x}_j + b_s)$ 为线性项系数; \mathbf{H} 定义如下:

$$k_{ij} = (1 + \frac{1}{2(1+\lambda)} \mathbf{x}_i^T \mathbf{x}_j) \quad (4)$$

对于式(3)的二次规划,通常需核矩阵 \mathbf{H} 正定半正定,则需其满足 Mercer 核条件,才能保证式(3)为凸二次规划,进而满足了 KKT 条件,使得式(3)的二次规划的解为全局最小解.为了验证这一条件,给出如下定理:

引理 1^[9] 设 X 是 \mathbf{R}^n 上的一个紧集,若 $\mathbf{K}(x_i, x_j)$

是 $\mathbf{X} \times \mathbf{X}$ 上的连续对称函数且关于任意 $\mathbf{x}_i \in \mathbf{X}$ 的 Gram 矩阵半正定, 则 $\mathbf{K}(\mathbf{x}_i, \mathbf{x}_j)$ 是 Mercer 核.

定理 2 形如式(4)所表达的核函数是 Mercer 核.

证明: 首先, 根据式(4)的定义有 $\mathbf{H} = [k_{ij}]_{N_i \times N_i}$, k_{ij}

$= (1 + \frac{1}{2(1+\lambda)} \mathbf{x}_i^T \mathbf{x}_j)$, $\lambda > 0$. 由于 $\mathbf{x}_i^T \mathbf{x}_j$ 为实对称阵, 因此

\mathbf{H} 矩阵也是一个对称矩阵. 其次, 对任意的 α_i , 有

$$\begin{aligned} \sum_{i,j} \alpha_i \alpha_j k_{ij} &= \sum_{i,j} \alpha_i \alpha_j (1 + \frac{1}{2(1+\lambda)} \mathbf{x}_i^T \mathbf{x}_j) \\ &= \frac{1}{2(1+\lambda)} \left(\sum_{i=1}^{N_i} \alpha_i \mathbf{x}_i \right)^T \left(\sum_{j=1}^{N_i} \alpha_j \mathbf{x}_j \right) + \zeta \\ &= \frac{1}{2(1+\lambda)} \left(\sum_{i=1}^{N_i} \alpha_i \mathbf{x}_i \right)^2 + \zeta, \text{ 其中 } \zeta = \sum_{i,j} \alpha_i \alpha_j. \end{aligned}$$

因为 $\frac{1}{2(1+\lambda)} \left(\sum_{i=1}^{N_i} \alpha_i \mathbf{x}_i \right)^2 \geq 0$ 且 $\mathbf{x}_i^T \mathbf{x}_j$ 为 $\mathbf{X} \times \mathbf{X}$ 上的连续

对称函数, 因此 $(1 + \frac{1}{2(1+\lambda)} \mathbf{x}_i^T \mathbf{x}_j)$ 为半正定矩阵, 另外 $\zeta > 0$, 由引理 1 可知, 核 $\mathbf{H} = [k_{ij}]_{N_i \times N_i}$ 为 Mercer 核矩阵.

由定理 1 二次规划求得对偶问题的最优解 α 后, 根据对偶理论可求得原优化问题的最优解, 分别表示如下:

$$\mathbf{w}_t = \frac{1}{(1+\lambda)} \left(\sum_{j=1}^{N_i} a_j h_j^t \mathbf{x}_j + \lambda \mathbf{w}_s \right) \quad (5)$$

$$b_t = \sum_{j=1}^{N_i} a_j h_j^s + b_s \quad (6)$$

通过式(5)和式(6), 可得到目标领域的分类器 (\mathbf{w}_t, b_t) , 其在学习过程中借助了源领域已有的知识 (\mathbf{w}_s, b_s) 以及协同约束项, 使得目标领域的分类器学习的信息量增大, 从而对目标领域的分类性能将某种程度地得到提升.

3.3 目标领域主导的协同约束共生迁移学习

本部分利用和前节类似的策略, 以前节学习得到的目标领域分类器为主导, 进行目标领域主导的协同约束共生迁移学习. 为此, 给出如下优化目标函数:

$$\begin{aligned} \min_{\mathbf{w}_s, b_s, \xi} \quad & \frac{1}{2} \mathbf{w}_s^T \mathbf{w}_s + C \sum_{i=1}^{N_i} \xi_i^s + \frac{\lambda}{2} (\mathbf{w}_s - \mathbf{w}_t)^T (\mathbf{w}_s - \mathbf{w}_t) \\ & + \frac{\lambda}{2} (b_s - b_t)^2 + C \sum_{j=1}^{N_i} \xi_j^t \quad (7) \end{aligned}$$

s. t. $\mathbf{y}_i^s (\mathbf{w}_s^T \mathbf{x}_i + b_s) \geq 1 - \xi_i^s$, $\xi_i^s \geq 0$, $i = 1, 2, \dots, N_s$

$(\mathbf{w}_t^T \mathbf{x}_j + b_t) (\mathbf{w}_s^T \mathbf{x}_j + b_s) \geq 1 - \xi_j^t$, $\xi_j^t \geq 0$, $j = 1, 2, \dots, N_t$

为了与式(1)中的变量 \mathbf{w}_s 和 b_s 区别, 式(7)中 \mathbf{w}_s 和 b_s 表示在目标领域的有用信息指导下, 源领域得到的新的分类器之参数. 较之式(1), 式(7)多了约束项 $\mathbf{y}_i^s (\mathbf{w}_s^T \mathbf{x}_i + b_s) \geq 1 - \xi_i^s$, 这是因为源领域较之目标领域有更多的知识和信息可用. 对于式(7)的优化问题, 可以利用拉格朗日乘子法得到转化为下面的定理求解.

定理 3 对于式(7)所示优化问题, 其对偶问题可表示为如下的二次规划优化形式:

$$\begin{aligned} \min_{\boldsymbol{\tau}} \quad & \frac{1}{2} \boldsymbol{\tau}^T \hat{\mathbf{H}} \boldsymbol{\tau} - \hat{\mathbf{f}}^T \boldsymbol{\tau} \quad (8) \\ \text{s. t.} \quad & 0 \leq \tau_i \leq C \end{aligned}$$

这里, $\boldsymbol{\tau} = [\alpha_1, \dots, \alpha_{N_s}, \beta_1, \dots, \beta_{N_t}]$; $\hat{\mathbf{H}} = [\hat{k}_{ij}] \in$

$\mathbf{R}^{(N_s + N_t) \times (N_s + N_t)}$, $\hat{k}_{ij} = (1 + \frac{1}{2(1+\lambda)} \mathbf{x}_{n_i}^T \mathbf{x}_{n_j})$, 根据定理 2, $\hat{\mathbf{H}}$ 为一个 Mercer 核矩阵; $\hat{\mathbf{f}} = \sum_{i=1}^{N_s + N_t} \left(1 + m_i - \frac{\lambda}{1+\lambda} m_i \mathbf{w}_t^T \mathbf{x}_{n_i} \right)$, $\mathbf{m}_i = [y_1, \dots, y_{N_s}, y_{N_s+1}, \dots, y_{N_s+N_t}]$.

3.4 算法描述

本节根据前面理论推导, 我们给出如下的算法描述.

CCSTL 算法

Input: 带有标签的源领域数据集和未标记的目标领域数据集.

Output: 目标领域分类决策函数 $f_t(\mathbf{x})$.

Step1 选择参数 C , 高斯核函数的窗宽参数 γ , 设迭代次数 $m = 1$, 最大迭代次数 m_{\max} 和阈值 ϵ . 使用传统的分类方法 SVM 对源领域有标签样本进行初始学习, 得到初始分类器 (\mathbf{w}_s, b_s) .

Step2 利用式(1)和定理 1, 得到当前的目标领域分类器参数 (\mathbf{w}_m, b_m) ; 令 $m = m + 1$;

Step3 利用式(6)和定理 2, 更新源领域分类器 (\mathbf{w}_s, b_s) ;

Step4 如果 $\|\mathbf{w}_s - \mathbf{w}_{s,m-1}\| < \epsilon$ 或 $m > m_{\max}$, 则算法结束, 输出最终两个领域分类判别函数, 否则, 返回 Step2;

Step5 利用目标领域决策函数 $f_t(\mathbf{x})$ 进行测试验证.

4 实验分析

为了验证文本所提算法 CCSTL 的有效性, 在不同类型数据集上对其性能进行了评估. 所采用的数据集主要包括如下两大类: (1) 模拟数据集; (2) 真实数据集 (包括 20Newsgroups 文本分类数据集和汾酒荧光光谱数据集).

实验部分采用了如下的相关方法进行比较: (1) 最大间隔支持向量机 v -SVM; (2) 直推式支持向量机 (Transductive Support Vector Machines, TSVM); (3) 迁移学习算法 LWE 算法; (4) 迁移学习算法 LMPROJ 算法. 实验中, 比较算法的各参数采用 5 折交叉验证获得.

CCSTL 算法各参数设置采用了与文献相同的方法. 在实验中采用高斯函数 $\mathbf{K}(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{1}{\gamma} \|\mathbf{x} - \mathbf{y}\|^2\right)$ 作为核函数, 其窗宽参数 γ 值是通过网格搜索选取 $\gamma \in \{\sigma^2/64, \sigma^2/16, \sigma^2/8, \sigma^2/4, \sigma^2/2, \sigma^2, 2\sigma^2, 4\sigma^2, 8\sigma^2, 16\sigma^2, 64\sigma^2\}$, σ 为训练样本平均范数的

平方根;平衡参数 λ 在 $\{10^{-6}, 10^{-5}, 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 1, 10, 10^2, 10^3, 10^4, 10^5, 10^6\}$ 中搜索选取;正则化参数 C 在区间 $\{10^{-5}, 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 1, 10, 10^2, 10^3, 10^4, 10^5\}$ 中搜索选取. 实验环境: WinXP, CPU Intel T4300 2.1GHz, RAM 3G, MATLAB R2010a 等.

4.1 模拟数据集

4.1.1 模拟数据集设置

模拟生成一个样本容量为 600 的香蕉形二维样本集作为源领域数据集, 正类和负类样本各包含 300 个. 然后, 通过将源领域数据分别按逆时针旋转 10° 和 30° 即可获得 2 个模拟目标领域数据集, 见图 2. 为了描述简便, 将图 2 中右侧数据定义为负类, 右侧数据为正类.

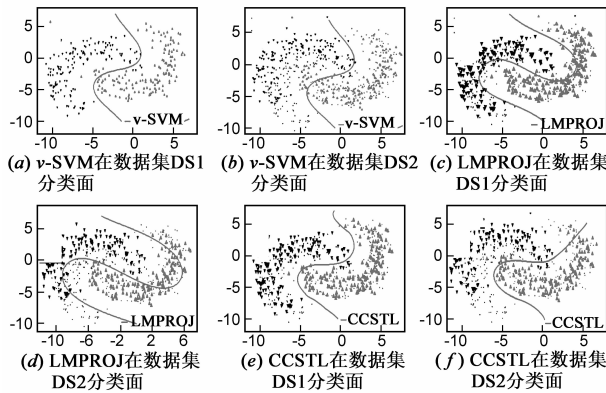


图2 各方法得到的香蕉数据集分类面

4.1.2 实验结果及分析

本部分实验选择 v -SVM, TSVM, LMPROJ 和本文算法对模拟数据集进行性能测试. 这里使用分类精度作为性能指标. 测试精度的结果如表 1 所示, 图 2 给出不同方法得到的分类效果.

从图 2 和表 1 可得如下几点结论: (1) 从图 2(a)、(c) 和 (e) 上看出, 对于模拟数据集, 相比之下传统的 v -SVM 方法的分类性能明显逊于其它 3 种方法, 这也说明传统的基于最大间隔的学习方法不适于需要迁移学习的应用场景; TSVM 使用少量目标领域信息, 因而其算法性能较 v -SVM 方法有所提高; LMPROJ 方法考虑了源领域和目标领域的局部特征, 从而有效降低了分布之间的差异, 较好的实现知识迁移, 因而分类精度有所提高; CCSTL 方法通过将协同共生过程嵌入 SVM 框架中, 不但兼顾了最大间隔原则, 同时充分考虑了目标领域和源领域的协同共生学习, 因此, 在分类精度上优于其它三种方法. (2) 从图 2(b)、(d) 和 (f) 上可以看出: 当香蕉数据集的源领域的旋转角度达到 30° 时, 源领域和目标领域分布差异性变大. 从表 1 可看出所有方法的学习性能都随香蕉数据集旋转角度的增大均呈下降趋势, 这是因为当两个领域间差异性上升到一定程度时, 源领域与目标领域间的相关性变弱, 从而使得迁移算

法迁移能力下降. (3) 对于旋转角度增加, 相较于 v -SVM, TSVM 和 LMPROJ 方法, CCSTL 方法的分类性更高, 且更能反映数据的分布特征, 体现了协同约束共生迁移学习更好的适应能力.

表 1 模拟数据集分类精度

Method	v -SVM	TSVM	LMPROJ	CCSTL
数据集 1 (DS1)	93.36%	94.16%	96.54%	98.50%
数据集 2 (DS2)	85.33%	86.33%	87.67%	89.31%

4.2 真实数据集实验与分析

4.2.1 数据集设置

本节以经典的 20Newsgroups 文本数据为例来进一步验证本文算法的性能, 该数据集也是一个经典的用于迁移学习算法测试的基准数据集. 通过对文本数据集中的大类中的小类进行分割和组合, 构造出 comp vs. rec (DS3), comp vs. sci (DS4), comp vs. talk (DS5), rec vs. sci (DS6), rec vs. talk (DS7) 和 sci vs. talk (DS8) 等 6 个用于迁移学习的数据集用以评估算法的性能.

4.2.2 实验结果及分析

各种方法在文本数据集上的分类结果如表 2 所示. 从表 2 可以得到如下观察: (1) 对于文本数据集, 三种迁移学习算法 LWE, LMPROJ 和 CCSTL 的分类性能明显优于 v -SVM 和 TSVM 两种非迁移学习算法. (2) 比较三种迁移学习方法, 可以看出 LWE 和 LMPROJ 性能相当, 但总体上都弱于本文提出的 CCSTL 算法. 这也进一步体现了本文提出的基于协同约束共生迁移学习机制的有效性和更好的适应能力.

表 2 不同方法在 20 Newsgroups 精度比较

数据集	v -SVM	TSVM	LWE	LMPROJ	CCSTL
DS3	65.76%	69.80%	83.06%	82.22%	83.43%
DS4	73.53%	77.75%	80.50%	82.45%	81.17%
DS5	70.70%	73.60%	91.95%	93.08%	94.12%
DS6	73.40%	74.90%	79.58%	86.23%	89.52%
DS7	78.30%	81.20%	82.54%	82.56%	85.81%
DS8	77.70%	78.74%	80.78%	85.82%	87.62%

4.3 汾酒光谱分类

为了进一步验证本文算法在真实数据集上的分类器性能, 本章节采用真实的汾酒数据集对各种方法进行了性能比较.

4.3.1 汾酒光谱数据集设置

汾酒光谱数据集由不同年份不同度数的汾酒酒样荧光光谱组成(下文中简称光谱数据), 光谱数据按时间批次测得. 实验中, 构造如下两个数据集: (1) DS9: 选择 42 度汾酒 10 年和 20 年各 300 个光谱数据作为源领域数据的正负类; 选择 45 度汾酒 10 年和 20 年各 100 个光谱数据作为目标领域数据集的正负类. (2) DS10:

选择 45 度汾酒 10 年和 20 年各 300 个光谱数据作为源领域数据的正负类;选择 53 度汾酒 10 年和 20 年各 100 个光谱数据作为目标领域数据集的正负类。

4.3.2 实验分析

表 3 给出不同方法在汾酒数据集的分类性能,从中我们可以得到和前面文本数据集上类似的实验结论。同样在该数据集上有效地体现了本文协同约束共生迁移学习机制的有效性。

表 3 不同方法汾酒数据的精度

数据集	v -SVM	TSVM	LMPROJ	CCSTL
DS9	86.90%	87.13%	92.67%	96.43%
DS10	89.18%	91.83%	95.17%	98.54%

5 结论

针对经典迁移学习方法中直接利用相关领域中的知识来协助完成当前领域的学习任务时,没有充分考虑领域间互相学习的问题,本文提出了一种具有协同约束的共生迁移学习方法 CCSTL。通过在相关领域间进行协同约束与共生交替迭代互动学习,强化了源领域和目标领域间的知识迁移。实验分析验证了所提方法在分类问题上的良好适应性。虽然本文方法展现出了较好的有效性,其依然面临一些进一步需要探讨的问题。例如:如何针对不同特征的领域研究其共生迁移学习策略将是一个非常有意义的工作,我们将在未来的工作中作更深入地研究。

参考文献

- [1] Sinno Pan J L, Yang Q. A survey on transfer learning[J]. IEEE Trans, 2009, KDE-22(10): 1345 - 1359.
- [2] 于重重, 田蕊, 谭励, 等. 非平衡样本分类的集成迁移学习算法[J]. 电子学报, 2012, 40(7): 1358 - 1363.
YU Chong-chong, TIAN Rui, TAN Li, et al. Integrated transfer learning algorithmic for unbalanced samples classification[J]. Acta Electronica Sinica, 2012, 40(7): 1358 - 1363. (in Chinese)
- [3] 胡文军, 王士同. 隐私保护的 SVM 快速分类方法[J]. 电子学报, 2012, 40(2): 280 - 286.
HU Wen-Jun, WANG Shi-tong. Fast classification approach of support vector machine with privacy preservation [J]. Acta Electronica Sinica, 2012, 40(2): 280 - 286. (in Chinese)

- [4] Wu P, Dietterich T G. Improving SVM accuracy by training on auxiliary data sources [A]. Proc ICML[C]. New York: ACM Press, 2004. 110 - 117.
- [5] Gao J, Fan W, Jiang J, Han J W. Knowledge transfer via multiple model local structure mapping[A]. Proc SIGKDD[C]. New York: ACM Press, 2008. 312 - 324.
- [6] Quanz B, Huan J. Large margin transductive transfer learning [A]. Proc CIKM[C]. New York: ACM Press, 2009. 1327 - 1336.
- [7] Bruzzone L, Marconcini M. Domain adaptation problems: a DASVM classification technique and a circular validation strategy [J]. IEEE Trans, 2010, PAMI-32(5): 770 - 787.
- [8] Pan S J L, Tsang I W, Kwok J T, et al. Domain adaptation via transfer component analysis [J]. IEEE Trans, 2011, NN-22(2): 199 - 210.
- [9] 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. 4 - 19.
DENG Nai-yang, TIAN Ying-jie. New Method in Data Mining: Support Vector Machine[M]. Beijing: Science Press, 2004. 4 - 19. (in Chinese)

作者简介



张景祥 男, 1977 年生于吉林通化。2002 年、2007 年分别在重庆大学、江南大学获得理学学士、工学硕士学位, 2011 年进入江南大学攻读博士学位。主要从事模式识别、人工智能和生物信息学等方面的研究。
E-mail: zjx145@163.com



王士同 男, 1964 年生于江苏扬州。教授、博士生导师、中国计算机学会高级会员。1984 年、1987 年在南京航空航天大学获得工学学士、硕士学位。主要从事人工智能、模式识别、模糊系统、医学图像处理和生物信息学等方面的研究工作。



邓赵红 男, 1981 年生于安徽蒙城。副教授、硕士生导师。主要从事人工智能、模式识别、模糊系统、医学图像处理等方面的研究工作。