一种面向多源领域的实例迁移学习

张 倩 [1] 李 明 [1] 王雪松 [1] 程玉虎 [1] 朱美强 [1]

摘 要 在迁移学习最大的特点就是利用相关领域的知识来帮助完成目标领域中的学习任务, 它能够有效地在相似的领域或任务之间进行信息的共享和迁移, 使传统的从零开始的学习变成可积累的学习, 具有成本低、效率高等优点. 针对源领域数据和目标领域数据分布类似的情况, 提出一种基于多源动态 TrAdaBoost 的实例迁移学习方法. 该方法考虑多个源领域知识, 使得目标任务的学习可以充分利用所有源领域信息, 每次训练候选分类器时, 所有源领域样本都参与学习, 可以获得有利于目标任务学习的有用信息, 从而避免负迁移的产生. 理论分析验证了所提算法较单源迁移的优势, 以及加入动态因子改善了源权重收敛导致的权重熵由源样本转移到目标样本的问题. 实验结果验证了此算法在提高识别率方面的优势.

关键词 多源, TrAdaBoost, 实例迁移, 迁移学习

引用格式 张倩, 李明, 王雪松, 程玉虎, 朱美强. 一种面向多源领域的实例迁移学习. 自动化学报, 2014, **40**(6): 1176−1183

DOI 10.3724/SP.J.1004.2014.01176

Instance-based Transfer Learning for Multi-source Domains

ZHANG Qian[1] LI Ming[1] WANG Xue-Song[1] CHENG Yu-Hu[1] ZHU Mei-Qiang[1]

Abstract The most remarkable characteristic of transfer learning is that it can employ the knowledge in relative domains to help perform the learning tasks in the domain of the target. With the use of different fields of knowledge for target task learning, transfer learning can transfer and share the information between similar domains or tasks, making the traditional learning from scratch an addable one, which implies that the learning efficiency is higher and the cost is lower. For the specific situation that the shared knowledge in the domains of the source and the target are sample data with similar distribution, an instance transfer learning method based on multi-sources dynamic TrAdaBoost is put forward. Integrated with the knowledge in multiple source domains, this method makes the target task learning the one that is able to make good use of the information of all source domains. Whenever candidate classifiers are trained, all the samples in all source domains are involved in learning, and the information conducive to target task learning can be obtained, so that negative transfer can be avoided. The theoretical analysis suggests that the given algorithm is better than the single source transfer. By means of adding the dynamic factor, this algorithm improves the defect that weight entropy drifts from source to target instances. The experimental results support that the given algorithm has the advantage of improving the recognition rate.

Key words Multi-source, TrAdaBoost, instance transfer, transfer learning

Citation Zhang Qian, Li Ming, Wang Xue-Song, Cheng Yu-Hu, Zhu Mei-Qiang. Instance-based transfer learning for multi-source domains. *Acta Automatica Sinica*, 2014, **40**(6): 1176−1183

迁移学习在上世纪 90 年代被引入机器学习领域[1], 它根据不同任务间的相似性, 将源领域数据向目标领域迁移, 实现对已有知识的利用, 使传统的从零开始学习变得可积累, 从而显著提高了学习效率[2−3].

但是, 迁移的引入也为机器学习带来了难题, 相关领域知识的表达方式可根据知识的不同类型分为样本实例、特征映射、模型参数和关联规则, 针对不同的知识表达方式需要采取不同的迁移学习方法, 如果方法选择不恰当, 会极大地影响目标领域中的学习效果[4]. 本文选择样本实例作为相关领域知识的表达方式, 来确定采用何种迁移方法, 以提高目标领域的学习效率.

1 相关工作

通常而言, 目标领域和源领域中的训练样本可能会有所不同, 但还是会存在部分训练样本比较适合用来训练出有效的分类模型, 并且适应测试样本.

收稿日期 2013-05-02 录用日期 2013-10-01
Manuscript received May 2, 2013; accepted October 1, 2013
国家自然科学基金 (61072094, 61273143), 江苏省自然科学基金 (BK 20130207), 教育部新世纪优秀人才支持计划 (NCET-10-0765), 教育部高等学校博士学科点专项科研基金 (20110095110016, 20120095110025) 资助
Supported by National Natural Science Foundation of China (61072094, 61273143), Natural Science Foundation of Jiangsu Province (BK20130207), Program for New Century Excellent Talents in University (NCET-10-0765), and Specialized Research Fund for the Doctoral Program of Higher Education of China (20110095110016, 20120095110025)
本文责任编委 封举富
Recommended by Associate Editor FENG Ju-Fu
1. 中国矿业大学信息与电气工程学院 徐州 221116
1. School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou 221116

这一类迁移学习方法被称为基于实例的迁移[3], 其目标就是通过一定的策略对源数据进行评估, 从中选择出一部分合适的数据, 并将这些用实例表达的数据迁移到目标任务的学习中. 其中关键的技术就是如何对这部分训练数据进行权重计算[5].

Dai 等[6] 提出了一个扩展的 AdaBoost[7] 算法 TrAdaBoost, 用于解决归纳迁移学习问题. TrAdaBoost 假设源领域和目标领域的数据使用同样的特征集合和标记集合, 但是两个领域上数据的分布不同. 这样就可能导致一些源领域数据有益于目标领域的学习效果, 另外一些数据损害目标领域的学习. TrAdaBoost 通过一种迭代重加权的方式, 不断减少坏数据的影响, 同时不断放大好数据对目标领域的帮助. 在每一次迭代中, 基于加权后的源和目标领域数据, 训练一个基准分类器, 并计算该分类器在目标领域数据上的误差.

TrAdaBoost 是第一种使用 Boosting 作为归纳迁移学习器的迁移学习方法, 应用非常广泛. 但它也有一些缺点, 主要包括: 权重不匹配; 分类器集合的前半部分被忽略; 引用不平衡以及源领域权重的下降速度过快. 一些学者分别提出了相应的解决方案. 针对权重不匹配的问题, 文献 [8] 中指出, 如果给目标样本分配较多的初始权重, 这个问题可以得到缓解; 针对分类器集合的前半部分被忽略的问题, 文献 [9] 给出解决方案, 只保留了分类器集合中针对较难分类样本的后半部分分类器, 而丢弃了适用于大多数样本的前半部分分类器; 针对引用不平衡的问题, 文献 [10] 在每一步中对数据进行重新采样以平衡这些等级.

源领域权重的下降速度过快是 TrAdaBoost 方法最严重的问题, 即使源样本表达了目标概念, 它们的权重也会快速地降低. 文献 [9] 验证了这种快速收敛性, 在 TrAdaBoost 方法重新确定权重的策略中, 源样本和目标样本权重的差异性逐渐增加, 并且在随后的迭代中, 即使源样本变得对目标领域学习有利, 其权重也没有办法恢复. 本文的研究重点就是有效解决这种权重转移现象, 并在提高学习效率的同时抑制负迁移的产生.

2 多源动态 TrAdaBoost 算法

文献 [11] 在充分考虑源领域样本类信息基础上, 基于结构风险最小化模型, 提出了基于类分布的领域自适应支持向量机 (CDASVM), 并扩展到多源领域. 文献 [12] 中提出了一种多源实例迁移方法 (MS-TrAdaBoost), 它假设源训练数据来自不同的源领域, 在每次迭代中, 选择与目标领域最相关的源领域训练弱分类器, 最后得到强分类器. 这种方法可以保证迁移的知识与目标任务最相关, 但它却忽略了其他源任务对目标任务学习的影响.

为了解决上述问题, 本文在文献 [12] 的基础上, 提出了一种多源动态 TrAdaBoost 方法 (MSD-TrAdaBoost), 使得与目标领域相关性不大的源领域样本的权重不至于收敛过快, 共同帮助学习目标任务, 达到对所有源领域知识的充分利用.

假设有 N 个源领域训练数据 $D_{a_1},\cdots,D_{a_N}$, 利用它们提高目标分类器函数 $f'_b: X\to Y$ 的学习性能. 调用传统弱分类器模型在每一个训练集训练得到一个弱分类器, 将所有弱分类器组成弱分类器集, 分别计算每个弱分类器在目标训练集上的误差并加相应的权重; 将加权后的弱分类器集成得到当前迭代的候选分类器, 然后计算候选分类器在目标训练集和不同源领域训练集上的误差, 更新源领域样本的权重. 将更新权重后的样本重新训练, 依次循环, 直到最大迭代次数 M.

算法的详细描述如下:

步骤 1. 初始化权矢量 $(\omega_{a_1},\cdots,\omega_{a_N},\omega_b)$, 其中 $\omega_{a_k}=(\omega^1_{a_k},\cdots,\omega^{n_{a_k}}_{a_k})$ 为第 k 个源领域训练样本的权重矢量, $\omega_b=(\omega^1_b,\cdots,\omega^{n_b}_b)$ 为目标领域训练样本的权重矢量;

步骤 2. 设 $\beta_a=\frac{1}{1+\sqrt{2*\ln(n_a)/M}}$, 其中 $n_a=\sum_k n_{a_k}$ 为全部源领域训练样本个数, n_{a_k} 为第 k 个源领域训练集包含样本数量;

步骤 3. 清空候选弱分类器集合, 并将矢量归一化;

步骤 4. 在合并数据集 $D_{a_k}\cup D_b$ 上调用基分类器, 得到候选弱分类器 $(f^t_b)^k$, 计算 $(f^t_b)^k$ 在目标领域 D_b 上的误差

$$\left(\varepsilon^t_b\right)^k=\sum_{j=1}^{n_b}\frac{\omega^j_b\sum\limits_{k=1}^{N}\left[y^j_b\neq\left(f^t_b\right)^k\cdot x^j_b\right]}{\sum\limits_{i=1}^{n_b}\omega^i_b}$$

并更新弱分类器 $(f^t_b)^k$ 的权重

$$\left(\omega^t_b\right)^k=\frac{\mathrm{e}^{1-(\varepsilon^t_b)^k}}{\mathrm{e}^{(\varepsilon^t_b)^k}}$$

循环往复, 直到遍历 N 个源领域;

步骤 5. 得到第 t 次迭代的分类器

$$f^t_b=\sum_k\frac{\left(\omega^t_b\right)^k}{\sum\limits_k\left(\omega^t_b\right)^k}(f^t_b)^k$$

计算 f^t_b 在 D_b 上的误差

$$\varepsilon^t_b=\sum_{j=1}^{n_b}\frac{\omega^j_b\sum\limits_{t=1}^{M}\left[y^j_b\neq f^t_b\cdot x^j_b\right]}{\sum\limits_{i=1}^{n_b}\omega^i_b}$$

步骤 6. 设 $\beta_b^t = \varepsilon_b^t/(1-\varepsilon_b^t)$, $C_t = 2\,(1-\varepsilon_b^t)$, 其中 $0 \le \varepsilon_b^t \le 1/2$;

步骤 7. 更新源样本权矢量 $\omega_{a_k}^{(t+1)\cdot i} = C_t \cdot \omega_{a_k}^{t\cdot i} \cdot (\beta_a)^{\sum_{t=1}^{M}[y_b^j \ne f_b^t \cdot x_b^j]}$, 其中 $i \in D_{a_k}$; 更新目标样本权矢量 $\omega_b^{(t+1)\cdot i} = \omega_b^{t\cdot i} \cdot (\beta_b^t)^{\sum_{t=1}^{M}[y_b^j \ne f_b^t \cdot x_b^j]}$, 其中 $i \in D_b$;

步骤 8. 如果没有达到最大迭代次数 M, 则转步骤 3; 如果达到, 则转步骤 9;

步骤 9. 最终强分类器

$$f_b' = \mathrm{sgn}\left\{\prod_{t=1}^{M}\left[(\beta_b^t)^{-f_b^t}\right] - \prod_{t=1}^{M}\left[(\beta_b^t)^{-\frac{1}{2}}\right]\right\}$$

其中, 为了满足 $|\beta_b^t| \le 1$, ε_b^t 的值必须小于 0.5, 但是, 为了避免算法停止, 当其值超过 0.5 时, 设置 $\varepsilon_b^t = 0.5$. MSD-TrAdaBoost 算法在每一步对源样本和目标样本的组合集训练的过程中都利用集成学习的概念. 源样本权矢量的更新使用加权多数算法 (Weighted majority algorithm, WMA), 通过迭代降低错误分类源样本的权重来调整源数据集的权重, 并保存正确分类源样本的当前权重值.

步骤 4 中的 $(\varepsilon_b^t)^k$ 表示第 k 个源领域的候选分类器在目标领域的错误率; $y_b^j \ne (f_b^t)^k \cdot x_b^j$ 表示候选弱分类器分类错误; $\sum_{k=1}^{N}$ 表示对 N 个源领域求和; 权重更新策略 $(\omega_b^t)^k = (\mathrm{e}^{1-(\varepsilon_b^t)^k})/\mathrm{e}^{(\varepsilon_b^t)^k}$ 表示根据测试误差对每个弱分类器加相应的权重, 误差大的分类器设置权重小, 误差小的分类器设置权重大, 可以理解为正确率高的分类器对应的源领域包含对目标任务有用的信息多, 对目标任务的学习帮助大, 正确率低的分类器对应的源领域包含对目标任务有用的信息相对少, 对目标任务的学习帮助也小. 步骤 5 中的 ε_b^t 表示第 t 次迭代的分类器在目标领域的误差率, 将加权后的弱分类器集成得到当前迭代的候选分类器, 然后计算候选分类器在目标训练集和不同源领域训练集上的误差. 步骤 6 中给出了更新源样本权矢量中的动态因子的表达式, 定理 1 中将会给出这个动态因子的推导过程. 步骤 7 中源样本权重更新的收敛率由 β_a 和动态因子 C_t 计算得到; 目标样本的权重更新利用 β_b^t 的值计算, 只需要知道步骤 6 中的目标误差率 ε_b^t 的值即可.

MSD-TrAdaBoost 对分类器的权重计算公式为 $\beta_b^t = \varepsilon_b^t/(1-\varepsilon_b^t)$, ε_b^t 越小, 则目标分类误差越小, 表明与目标领域的相关度越高, 将多次迭代的基分类器组合成目标分类器, 源领域中的有用知识就会逐渐迁移到目标领域中. 更新源领域样本的权重, 对于分类正确的源领域样本权重不变, 分类错误的样本权重减小, 减小分类错误样本的权重表示此样本对目标任务的学习没有帮助, 降低此样本对目标学习的影响. 在每个迁移学习模型中, 源样本分布都是相关的, 目标样本可以从合并的相关源样本中获得知识.

由算法可以看出, 所有源领域训练样本都参与了每次迭代的训练, 各源领域中训练样本在训练中的权重不同, 对目标学习有帮助的样本权重大, 阻碍目标学习的样本权重低, 经过多次迭代, 可筛选出对目标学习帮助大的源领域, 充分利用多个源领域所有有用知识, 最大化帮助目标领域的学习.

3 理论分析

上一节给出了实例迁移学习框架 MSD-TrAdaBoost, 利用多个源领域数据帮助目标领域学习. 这一节中, 将要根据文献 [13] 中对 DTrAdaBoost 算法做出的理论分析, 从理论上对这一多源学习框架的性质进行详细分析.

首先, 定理 1 和定理 2 将会证明在源权重中加入动态因子对源权重和目标权重的影响.

定理 1. 将动态因子 $C_t = 2\,(1-\varepsilon_b^t)$ 加入源权重, 可以防止权重转移, 并得到源样本权矢量更新机制.

证明. 首先令 A 是第 $t+1$ 步迭代正确分类目标权重的总和, B 是第 $t+1$ 步迭代错误分类目标权重的总和, 其表达式如下:

当 $\sum_{t=1}^{M}\left[y_b^j = f_b^t \cdot x_b^j\right] = 0$ 时,

$$A = n_b \cdot \omega_b^t \cdot \left(1-\varepsilon_b^t\right) \cdot \left(\frac{\varepsilon_b^t}{1-\varepsilon_b^t}\right)^{\sum\limits_{t=1}^{M}\left[y_b^i = f_b^i \cdot x_b^i\right]} = n_b \cdot \omega_b^t \cdot \left(1-\varepsilon_b^t\right) \tag{1}$$

当 $\sum_{t=1}^{M}\left[y_b^j \ne f_b^t \cdot x_b^j\right] = 1$ 时,

$$B = n_b \cdot \omega_b^t \cdot \varepsilon_b^t \cdot \left(\frac{\varepsilon_b^t}{1-\varepsilon_b^t}\right)^{\sum\limits_{t=1}^{M}\left[y_b^i = f_b^i \cdot x_b^i\right]} = n_b \cdot \omega_b^t \cdot \left(1-\varepsilon_b^t\right) \tag{2}$$

则算法源权重的值更新为

$$\omega_{a_k}^{t+1} = \frac{\omega_{a_k}^t}{n_a \cdot \omega_{a_k}^t + A + B} = \frac{\omega_{a_k}^t}{n_a \cdot \omega_{a_k}^t + 2n_b \cdot \omega_b^t\,(1-\varepsilon_b^t)} \tag{3}$$

在每个 WMA 迭代中引入动态因子, 由于有等式 $\omega_{a_k}^{t+1} = \omega_{a_k}^t$, 有公式:

$$\omega_{a_k}^t = \frac{C_t \cdot \omega_{a_k}^t}{C_t \cdot n_a \cdot \omega_{a_k}^t + 2n_b \cdot \omega_b^t\,(1-\varepsilon_b^t)} \tag{4}$$

进而可以计算出动态因子的值

$$C_t = \frac{2n_b \cdot \omega_b^t (1-\varepsilon_b^t)}{1 - n_a \cdot \omega_{a_k}^t} = \frac{2n_b \cdot \omega_b^t (1-\varepsilon_b^t)}{n_b \cdot \omega_b^t} = 2\left(1-\varepsilon_b^t\right) \tag{5}$$

□

定理 2. 将动态因子 $C_t = 2(1-\varepsilon_b^t)$ 加入源权重, 可以利用 TrAdaBoost 算法得到目标样本权矢量的更新机制[14].

证明. 在 TrAdaBoost 算法中, 没有任何源样本的情况下, 即 $n_a = 0$, 正确分类样本的目标权重可以更新为

$$\omega_b^{t+1} = \frac{\omega_b^t}{\sum\limits_{j=1}^{n_b} \omega_b^t \cdot \left(\frac{\varepsilon_b^t}{1-\varepsilon_b^t}\right)^{\sum\limits_{t=1}^{M}\left[y_b^i \neq f_b^i \cdot x_b^i\right]}} = \frac{\omega_b^t}{A+B} = \frac{\omega_b^t}{2n_b \cdot \omega_b^t (1-\varepsilon_b^t)} = \frac{\omega_b^t}{2(1)(1-\varepsilon_b^t)} \tag{6}$$

将动态因子应用到源样本权重更新, 可以根据 MSD-TrAdaBoost 计算出目标样本权重更新机制.

$$\omega_b^{t+1} = \frac{\omega_b^t}{n_a \cdot \omega_{a_k}^t + 2n_b \cdot \omega_b^t (1-\varepsilon_b^t)} = \frac{\omega_b^t}{C_t \cdot n_a \cdot \omega_{a_k}^t + 2n_b \cdot \omega_b^t (1-\varepsilon_b^t)} = \frac{\omega_b^t}{2(1-\varepsilon_b^t)\left(n_a \cdot \omega_{a_k}^t + n_b \cdot \omega_b^t\right)} = \frac{\omega_b^t}{2(1-\varepsilon_b^t)(1)} \tag{7}$$

□

下面, 给出 MSD-TrAdaBoost 算法在目标领域的性能.

定理 3. 目标领域训练集上最终测试误差为

$$\varepsilon \leq 2^M \cdot \prod_{t=1}^{M} \sqrt{\varepsilon_b^t (1-\varepsilon_b^t)} \tag{8}$$

证明. 令在目标领域训练集上最终测试错误样本集合为 T, 则最终测试误差 $\varepsilon = \mid T \mid / n_b$, 其中 n_b 为目标领域训练样本数目.

每次迭代得到的测试误差为

$$\varepsilon_b^t = \sum_k \frac{(\omega_b^t)^k}{\sum\limits_k (\omega_b^t)^k} (\varepsilon_b^t)^k = \frac{\sum\limits_k \mathrm{e}^{1-2(\varepsilon_b^t)^k} (\varepsilon_b^t)^k}{\sum\limits_k \mathrm{e}^{1-2(\varepsilon_b^t)^k}} \tag{9}$$

其中, $0 \leq (\varepsilon_b^t)^k \leq 1/2$.

当 $\varepsilon_b^t = 0$ 时, 表明目标领域训练样本测试误差为 0, 训练样本权重无需更新, 设置 $\omega_b^{(t+1)\cdot i} = \omega_b^{t\cdot i}$, 此时 $\varepsilon = \varepsilon_b^t = 0$.

当 $\varepsilon_b^t \neq 0$ 时, $\beta_b^t = \varepsilon_b^t/(1-\varepsilon_b^t) \neq 0$, 目标领域训练样本最终的权重计算公式为

$$\sum_{i=1}^{n_b} \omega_b^{(t+1)\cdot i} = \sum_{i=1}^{n_b} \omega_b^{t\cdot i} (\beta_b^t)^{1-\varepsilon_b^t} \leq \sum_{i=1}^{n_b} \omega_b^{t\cdot i} (1-(1-\varepsilon_b^t)\beta_b^t) \tag{10}$$

于是:

$$\sum_{i=1}^{n_b} \omega_b^{(M+1)\cdot i} = \sum_{i=1}^{n_b} \omega_b^{t\cdot i} (\beta_b^t)^{1-\varepsilon_b^t} \leq \sum_{i=1}^{n_b} \omega_b^i \prod_{t=1}^{M} (1-(1-\varepsilon_b^t)\beta_b^t) = \prod_{t=1}^{M} (1-(1-\varepsilon_b^t)\beta_b^t) \tag{11}$$

又有:

$$\sum_{i=1}^{n_b} \omega_b^{(M+1)\cdot i} \geq \sum_{i\in S} \omega_b^i (\prod_{t=1}^{M} \beta_b^t)^{\frac{1}{2}} = \varepsilon (\prod_{t=1}^{M} \beta_b^t)^{\frac{1}{2}} \tag{12}$$

合并式 (11) 和 (12), 得:

$$\varepsilon (\prod_{t=1}^{M} \beta_b^t)^{\frac{1}{2}} \leq \prod_{t=1}^{M} (1-(1-\varepsilon_b^t)\beta_b^t) \tag{13}$$

将 $\beta_b^t = \varepsilon_b^t/(1-\varepsilon_b^t)$ 代入式 (13), 可得:

$$\varepsilon \leq 2^M \cdot \prod_{t=1}^{M} \sqrt{\varepsilon_b^t (1-\varepsilon_b^t)}$$

□

由定理 3 可知, 当 $\varepsilon_b^t < 0.5$ 时, 最终目标训练数据 D_b 中的分类误差将会随着迭代次数的增加而不断减小, 当迭代次数无穷大时, 误差接近于 0.

4 实验结果与分析

上一节理论上分析了本文算法的优越性, 本节将通过对物体种类的识别来验证方法的有效性, 假设拥有少量的目标领域的训练样本和大量的源领域的训练样本, 给定一个测试样本, 证明它是否属于目标领域.

4.1 实验设置

对于物体种类识别, 利用 Caltech256 数据集[15], 包含了 256 个物体种类, 最少一类的图像至少有 80 幅. 指定目标领域并随机地从目标数据中配置样本. 其中包含 50 幅图像作为目标领域测试样本, 用于训练的样本数记为 n_b, 限制在 1 到 50 之间. 此外, 为了说明文中方法不依赖于数据集, 我们从

Google 图像搜索引擎中收集来的数据作为辅助数据集, 用于验证方法的有效性和鲁棒性. 从 1 到 10 改变源领域的数量 N, 来观察源领域数量的变化对分类器性能的影响. 一个源领域样本的数量为 100, 对每一个目标物体种类, 分类器的性能由 N 个源领域的随机组合来评价. 给定目标种类和源种类之后, 通过计算 20 次实验, 对其结果取平均值就能得到分类器的总体性能. 在数据集上比较几种不同算法, 样本都含有相同数量的标记. 基分类器选用支持向量机, 实验中迭代次数设为 50 次.

4.2 误差分析

由于目标数据集的数量很大, 不需要迁移学习来获得好的分类效果, 所以这里不采用标准的交叉验证方法. 利用目标数据集中的一小部分用于训练, 剩下的大多数样本用于测试. 图 1 针对不同数量的目标训练样本 ($n_b = \{1, 10, 20, 30, 40, 50\}$) 和不同数量的源领域 ($N = \{1, 4, 6, 8, 10\}$) 进行实验, 每个实验用接收者操作特性曲线 (Receiver operating characteristic curve, ROC) 作为分类器输出性能的比较[16], 同时计算该曲线下面积 $A_{\rm ROC}$ 作为定量的性能评价指标, 如图 1 所示.

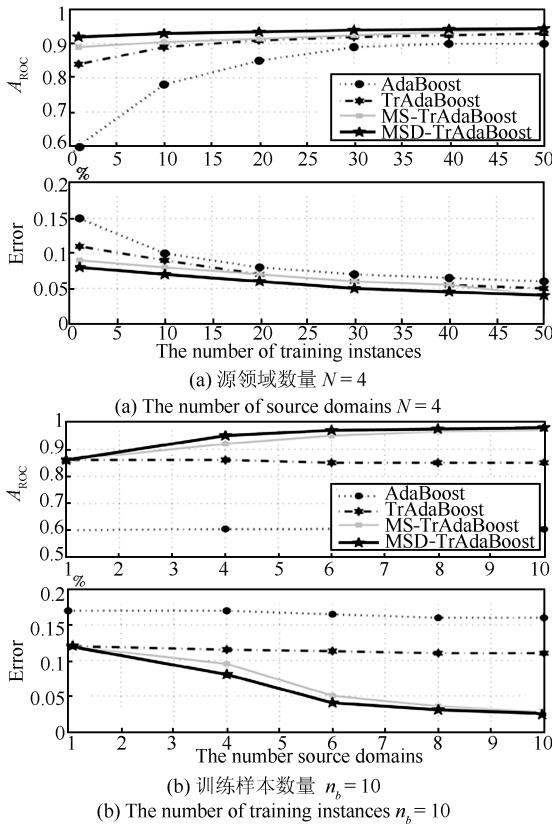

(a) 源领域数量 $N = 4$

(a) The number of source domains $N = 4$

(b) 训练样本数量 $n_b = 10$

(b) The number of training instances $n_b = 10$

图 1 性能比较

Fig. 1 Performance comparisons

图 1 (a) 显示了假设有 4 个源领域, 即 $N = 4$, 系统性能随着训练样本数量 n_b 增加时 4 种算法的比较结果. 由于 AdaBoost 没有从源领域中迁移任何知识, 它对 n_b 的依赖性很大. 如果 n_b 很小, 从 $A_{\rm ROC}$ 可以看出, 它仅仅比随机选择要好一点. TrAdaBoost 由于有迁移学习机制的影响, 它的性能比 AdaBoost 有所提高. 通过合并从多个个体领域迁移知识的能力, 即使在 n_b 很小的情况下, MS-TrAdaBoost 和 MSD-TrAdaBoost 在识别的精确度上有很大提高, 且后者略有优势. 另外, AdaBoost 和 TrAdaBoost 在很大程度上依赖于源领域和目标样本的选择, 而 MS-TrAdaBoost 和 MSD-TrAdaBoost 却可以得到一个很小的误差. 并且, 由于给定数据集限制了测试样本的总数, 所有算法的差异随着 n_b 的增加而减少.

图 1 (b) 假设训练样本数量 $n_b = 10$, 从图中看出, 随着源领域数量的增加, MS-TrAdaBoost 和 MSD-TrAdaBoost 的 $A_{\rm ROC}$ 也增加, 相应的误差减小, 在精确度和一致性上都有所提高, 后者的优势更加明显. 由于 TrAdaBoost 不能探索多源领域分离的决策范围, 导致不论源数据数量如何改变, 其性能依旧保持不变.

图 2 中比较了不同方法在目标领域的分类性能. 由图 2 可以看出: AdaBoost 算法没有迁移源领域知识, 因此得到较低的分类精度; DTrAdaBoost 算法由于只使用一个源领域训练样本集, 从源领域获得的有用知识最少, 因而测试结果相对较差; CDASVM 算法基于结构风险最小化模型, 可以充分考虑源领域样本类信息, 因而得出的分类精确度有所提高; MS-TrAdaBoost 和 MSD-TrAdaBoost 分别使用 4 个不同源领域训练样本集, 包含的有用信息量多, 得到的测试准确率也高. 在各组实验中, MS-TrAdaBoost 只选取每次迭代中准确率最高的

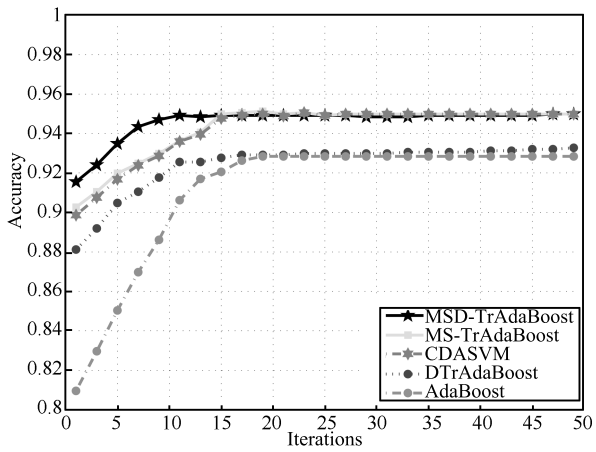

图 2 目标领域的分类性能

Fig. 2 The classification performance on the target domain

分类器, 忽略了其他源领域对目标任务的影响, 而 MSD-TrAdaBoost 由于引入了动态因子和加权机制, 更好地利用所有源领域中有用知识, 消除源领域训练集中无关样本对目标任务的影响, 结果比 MS-TrAdaBoost 算法更有效.

为了更科学地比较不同方法的有效性, 采用数理统计的假设检验对实验结果进行分析. 设随机变量 X_1, X_2, X_3, X_4 和 X_5 分别表示 MSD-TrAdaBoost, MS-TrAdaBoost, CDASVM, DTrAdaBoost 以及 AdaBoost 方法的分类误差率. 由于 X_1, X_2, X_3, X_4 和 X_5 的值受很多随机因素的影响, 因此, 可以假定它们都服从正态分布. 设 $X_i \sim \mathrm{N}(\mu_i, \sigma_i^2)$, $i = 1, 2, 3, 4, 5$. 现在, 比较不同方法对应的随机变量均值, 即 μ_i $(i = 1, 2, 3, 4, 5)$ 的大小. μ_i 的值越小, 说明该方法需要的分类误差率期望值越低, 其效率就越高. 因为样本方差是总体方差的无偏估计, 因此, 用样本方差的值作为总体方差的估计值. 显著性水平 α 的值取为 0.01. μ_1 和其他参数的比较过程如表 1 所列.

从表 1 可以看出, 对所有程序的检验, 本文方法的分类误差率期望值远远低于其他 4 种方法.

4.3　时间复杂度

由于多个源领域共同参与目标任务的学习, 算法的时间复杂度要大于单源领域算法. 假设训练一个分类器的复杂度为 C_h, 更新一个训练样本的复杂度为 C_w, 则对于 AdaBoost, DTrAdaBoost, MS-TrAdaBoost 和 MSD-TrAdaBoost 4 种算法而言, 它们的时间复杂度分别可以近似为 $C_h\mathrm{O}(M) + C_w\mathrm{O}(n_bM)$, $C_h\mathrm{O}(M)+C_w\mathrm{O}(n_aM)$, $C_h\mathrm{O}(NM)+C_w\mathrm{O}(n_aNM)$ 和 $C_h\mathrm{O}(NM)+C_w\mathrm{O}(n_aM)$. 图 3 中绘制了 5 种算法在分别固定 N, n_b 时平均训练时间.

4.4　动态因子

下面的实验将要证明动态因子对源权重和目标权重的影响, 这里先不考虑多个源领域的情况, 假设源领域数量 $N = 1$. 在图 4 (a) 中, 设定两个领域样本的数量 $n_a = 1\,000$, $n_b = 200$, 源领域误差率设置为 0. 依据 WMA, 由于 $\varepsilon_{a_k}^t = 0$, 本文算法的权重保持不变 $\omega_{a_k}^{t+1} = \omega_{a_k}^t$. 图中描绘了 MS-TrAdaBoost 算法权重和 MSD-TrAdaBoost 算法权重的比值随着迭代次数的增加在不同目标域上的分类误差 $\varepsilon_b^t = \{10\,\%, 20\,\%, 30\,\%, 40\,\%\}$ 下的曲线.

图 4 (a) 的仿真结果可以得到如下结论: 1) 在 MS-TrAdaBoost 中, 即使能正确分类, 源权重也会收敛; 2) MSD-TrAdaBoost 算法和 WMA 的思想匹配; 3) 如果不采用动态因子, ε_b^t 越小, 源权重收敛越快.

从图中还可以看出, 如果弱分类器目标域上的分类误差为 $\varepsilon_b^t = 10\,\%$, 即使源领域数量增加到 30, 即便在没有错误分类的情况下, MS-TrAdaBoost 算法在源样本超过 1 000 的时候效果也不好.

4.5　收敛率

在图 4 (b) 中, 源样本数量设置为 1 000, 绘制出随着目标域的分类误差 $\varepsilon_b^t \in \{10\,\% \sim 50\,\%\}$ 的增加, 在不同的目标样本数量 $n_b \in \{10, 20, 50\}$ 下的曲线. 可以看出, 在一次迭代之后, 正确分类源样本的权重随着目标域的分类误差 ε_b^t 的变化而变化.

5　结论

本文针对源领域数据和目标领域数据分布类似的情况, 提出一种新的迁移学习算法, 在 TrAdaBoost 算法基础上, 加入多个源领域, 并考虑多个源领域与目标领域相关性不同, 使得目标领域的学习能充分利用所有源领域信息. 每次训练候选分类器时, 所有源样本都参与学习, 既可获得有利于目标任务学习的有用信息, 又可避免负迁移的产生. 理论分析验证了所提算法较单源迁移的优势, 以及加入动态因子改善了源权重收敛导致的权重熵由源样本转移到目标样本的问题. 物体种类识别实验验证了算法在提高识别率方面的优势.

表 1　实验结果的假设检验

Table 1　Hypothesis testing for experimental results

假设	$H_0: \mu_1 \geq \mu_2$	$H_0: \mu_1 \geq \mu_3$	$H_0: \mu_1 \geq \mu_4$	$H_0: \mu_1 \geq \mu_5$
	$H_1: \mu_1 < \mu_2$	$H_1: \mu_1 < \mu_3$	$H_1: \mu_1 < \mu_4$	$H_1: \mu_1 < \mu_5$
统计量	$U_1 = \frac{\overline{x}_1 - \overline{x}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$	$U_2 = \frac{\overline{x}_1 - \overline{x}_3}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_3^2}{n_3}}}$	$U_3 = \frac{\overline{x}_1 - \overline{x}_4}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_4^2}{n_4}}}$	$U_4 = \frac{\overline{x}_1 - \overline{x}_5}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_5^2}{n_5}}}$
拒绝域	$U_1 \leq -Z_\alpha = -2.325$	$U_2 \leq -Z_\alpha = -2.325$	$U_3 \leq -Z_\alpha = -2.325$	$U_4 \leq -Z_\alpha = -2.325$
统计量的值	$U_1 = -58.67$	$U_2 = -114.56$	$U_3 = -136.59$	$U_4 = -158.23$
结论	$H_1: \mu_1 < \mu_2$	$H_1: \mu_1 < \mu_3$	$H_1: \mu_1 < \mu_4$	$H_1: \mu_1 < \mu_5$

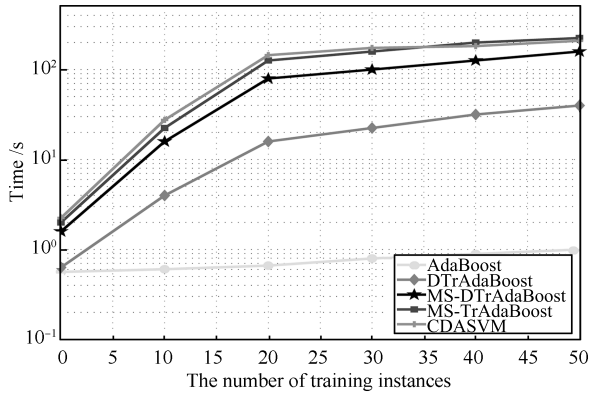

(a) 源领域数量级 $N = 4$

(a) The number of source domains $N = 4$

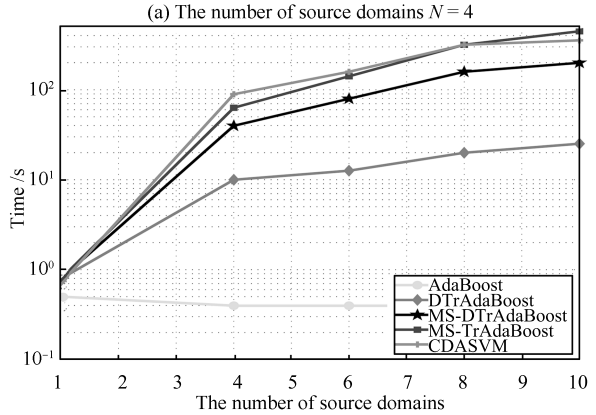

(b) 训练样本量 $n_b = 10$

(b) The number of training instances $n_b = 10$

图 3 不同方法的时间代价比较

Fig. 3 Time cost comparison on different methods

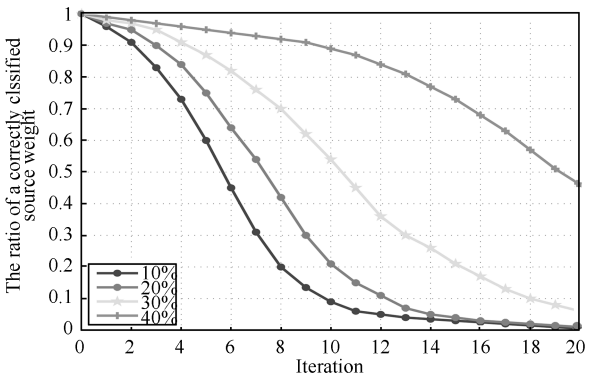

(a) 不同目标误差率经过20步迭代的结果

(a) Results for 20 iterations with different target error rates

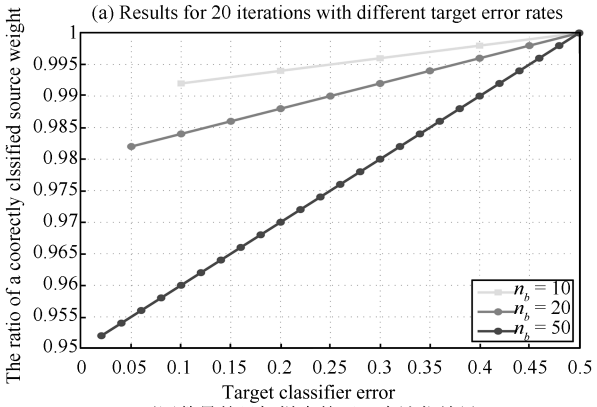

(b) 不同数量的目标样本的下一步迭代结果

(b) Results after a single iteration with different numbers of target instances

图 4 正确分类源权重的比率

Fig. 4 The ratio of a correctly classified source weight

References

1 Wang Hao, Gao Yang, Chen Xing-Guo. Transfer of reinforcement learning: the state of the art. *Acta Electronica Sinica*, 2008, **36**(12): 39−43
(王皓, 高阳, 陈兴国. 强化学习中的迁移: 方法和进展. 电子学报, 2008, **36**(12): 39−43)

2 Yang Q. An introduction to transfer learning. In: Proceedings of the 4th International Advanced Data Mining and Applications Conference. Berlin, Heidelberg: Springer-Verlag, 2008. 1

3 Taylor M E, Stone P. Transfer learning for reinforcement learning domains: a survey. *Journal of Machine Learning*, 2009, **10**: 1633−1685

4 Meng Jia-Na. Research on the Application of Transfer Learning on Text Classification [Ph. D. dissertation], Dalian University of Technology, China, 2011
(孟佳娜. 迁移学习在文本分类中的应用 [博士学位论文]. 大连理工大学, 中国, 2011)

5 Gao Jun, Huang Li-Li, Sun Chang-Yin. A local weighted mean based domain adaptation learning framework. *Acta Automatica Sinica*, 2013, **39**(7): 1037−1052
(皋军, 黄丽莉, 孙长银. 一种基于局部加权均值的领域适应学习框架. 自动化学报, 2013, **39**(7): 1037−1052)

6 Dai W Y, Yang Q, Xue G R, Yu Y. Boosting for transfer learning. In: Proceedings of the 24th International Conference on Machine Learning. New York, USA: ACM, 2007. 193−200

7 Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, 1997, **55**(1): 119−139

8 Pardoe D, Stone P. Boosting for regression transfer. In: Proceedings of the 27th International Conference on Machine Learning (ICML-10). Haifa, Israel, 2010. 863−870

9 Eaton E, des Jardins M. Set-based boosting for instance-level transfer. In: Proceedings of the 2009 IEEE International Conference on Data Mining Workshops. Miami, FL: IEEE, 2009. 422−428

10 Eaton E. Selective Knowledge Transfer for Machine Learning [Ph. D. dissertation], University of Maryland Baltimore County, USA, 2009

11 Ying Wen-Hao, Wang Shi-Tong, Deng Zhao-Hong, Wang Jun. Support vector machine for domain adaptation based on class distributiond. *Acta Automatica Sinica*, 2012, **39**(8): 1273−1288
(应文豪, 王士同, 邓赵红, 王骏. 基于类分布的领域自适应支持向量机. 自动化学报, 2012, **39**(8): 1273−1288)

12 Al-Samir S, Reddy C K. Adaptive boosting for transfer learning using dynamic updates. In: Proceedings of the 2011 European Conference on Machine Learning and Knowledge Discovery in Databases. Berlin, Heidelberg, Springer-Verlag, 2011. 60−75

13 Eaton E, des Jardins M. Set-based boosting for instance-level transfer. In: Proceedings of the 2009 IEEE International Conference on Data Mining Workshops. Miami, FL: IEEE, 2009. 422−428

14 Zhang Qian, Li Hai-Gang, Li Ming, Cheng Yu-Hu. Instance-based transfer learning method with multi-source dynamic TrAdaBoost. *Journal of China University of Mining and Technology*, 2014, **43**(4): 701−708
(张倩, 李海港, 李明, 程玉虎. 基于多源动态 TrAdaBoost 的实例迁移学习方法. 中国矿业大学学报, 2014, **43**(4): 701−708)

15 Griffin G, Holub A, Perona P. Caltech-256 Object Category Dataset, Technical Report 7694, California Institute of Technology, USA, 2007

16 Li Qiu-Jie, Mao Yao-Bin. AUC optimization boosting based on data rebalance. *Acta Automatica Sinica*, 2012, **38**(9): 1467−1475
(李秋洁, 茅耀斌. 基于数据重平衡的 AUC 优化 Boosting 算法. 自动化学报, 2012, **38**(9): 1467−1475)

张 倩 博士, 中国矿业大学讲师. 主要研究方向为机器学习, 迁移学习. 本文通信作者.
E-mail: zhangqian374@126.com
(**ZHANG Qian** Ph. D., lecturer at China University of Mining and Technology. Her research interest covers machine learning and transfer learning. Corresponding author of this paper.)

李 明 中国矿业大学教授. 主要研究方向为智能控制和模式识别.
E-mail: liming@cumt.edu.cn
(**LI Ming** Professor at China University of Mining and Technology. His research interest covers intelligent control and pattern recognition.)

王雪松 中国矿业大学教授. 主要研究方向为机器学习和生物信息学.
E-mail: wangxuesongcumt@163.com
(**WANG Xue-Song** Professor at China University of Mining and Technology. Her research interest covers machine learning and bioinformatics.)

程玉虎 中国矿业大学教授. 主要研究方向为机器学习, 智能优化与控制.
E-mail: chengyuhu@163.com
(**CHENG Yu-Hu** Professor at China University of Mining and Technology. His research interest covers machine learning, intelligent optimization and control.)

朱美强 博士, 中国矿业大学讲师. 主要研究方向为机器学习, 智能优化与控制.
E-mail: zhumeiqiang@cumt.edu.cn
(**ZHU Mei-Qiang** Ph. D., lecturer at China University of Mining and Technology. His research interest covers machine learning, intelligent optimization and control.)