

基于跨域结构保持投影的异构在线 多源迁移学习方法

蒋晓玲, 吴映波, 陈 蒙, 瞿祥谋
(重庆大学大数据与软件学院, 重庆 400000)

摘 要: 异构在线迁移学习使用异构源域的离线数据弥补目标域在线学习数据不足, 从而提高目标域在线学习性能. 现有方法通常假定源域是目标域特征空间子集或依赖特定的辅助数据. 本文提出一种基于跨域结构保持投影的异构在线多源迁移学习方法. 通过跨域结构保持投影, 同时将每个源域与目标域的特征空间映射到公共子空间, 并基于公共子空间中的跨域离线混合数据和目标域在线数据分别进行离线学习和在线学习, 提出采用一种双层差异导向对冲集成策略, 实现源域离线学习模型与目标域在线学习模型的两层集成融合和在线演化更新. 基于本文方法设计实现了一种异构在线多源迁移多分类算法, 且理论分析了该算法的分类错误上界. 实验结果表明, 本文方法能有效实现异构在线多源迁移学习并降低目标域在线多分类错误率, 且优于同类的在线多源迁移学习方法.

关键词: 异构迁移学习; 在线学习; 跨域结构保持投影; 特征空间; 多分类

基金项目: 国家重点研发计划 (No.2019YFB1706101); 重庆市技术创新与应用发展专项重点项目 (No.cstc2019jcsx-mbdxX0047); 中央高校基本业务费项目 (No.2020CDCGRJ50)

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112(2023)08-1983-12

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20210935

Heterogeneous Online Multi-Source Transfer Learning with Cross-Domain Structure Preserving Projection

JIANG Xiao-ling, WU Ying-bo, CHEN Meng, QU Xiang-mou
(School of Big-data and software, Chongqing University, Chongqing 400000, China)

Abstract: Heterogeneous online transfer learning aims to improve the online learning performance on target domain by making use of offline labeled instances from heterogeneous source domains to make up for the lack of online labeled data from target domain, where the feature space of source and target domains are different. Most existing approaches usually assume that the feature space of a source domain is a subset of that of the target domain, or rely on other auxiliary data. This paper proposes a new method called heterogeneous online multi-source transfer learning with cross-domain structure preserving projection. First, the original features of the data from every source and target domains are projected into a common subspace by the cross domain structure preserving projection algorithm, then we leverage the cross-domain offline hybrid data in the common subspace and online data from target domain to perform offline learning and online learning respectively. Furthermore, we propose the double-level mistake-driven hedge ensemble strategies to combine source and target learners by two-layer ensemble method and keep updating the combination method. Finally, we design and implement a heterogeneous online transfer learning algorithm for multi-class classification, and analyze the mistake bounds of the proposed algorithm theoretically. Experiment results show that our approach can reduce the mistake rate of online learning method on target domain, and outperforms the comparable online multi-source transfer learning approaches.

Key words: heterogeneous transfer learning; online learning; cross-domain structure preserving projection; feature space; multi-class classification

Foundation Item(s): National Key Research and Development Program of China (No.2019YFB1706101); Special Key Project for Technological Innovation and Application Development in Chongqing (No. cstc2019jcsx-mbdxX0047); Central University Basic Business Fee Project (No.2020CDCGRJ50)

1 引言

随着移动互联网和物联网的快速发展,在线流式数据处理应用不断涌现.在线学习用于解决在线数据不断产生的动态环境下的学习问题.但当在线数据样本较少时,在线学习准确率较低.在线迁移学习可把从相关源域数据中提取的知识迁移到目标域,以解决目标域在线学习之初因训练数据稀缺而导致学习性能不佳的问题.但从源域到目标域的知识迁移会因源域与目标域数据的特征表示及维度不一致等异构性问题,而无法将从源域学到的知识直接应用到目标域上^[1].

现有异构在线迁移学习方法可分为两类.(1)假设源域特征空间是目标域特征空间的子集,共同正则化在线迁移学习(Co-regularized Online Transfer Learning, COTL)^[2]、异构在线迁移学习(Heterogeneous Online Transfer Learning, HetOTL)^[3]、多源异构在线迁移学习(Heterogeneous Online Transfer Learning with Multiple Source domains, HetOTLMS)^[4]和异构集成在线迁移学习(Heterogeneous Ensembled Online Transfer Learning, HetEOTL)^[5]将每个目标域在线数据分为与源域特征表示相同与不同的两个样本分别输入源域分类器和在线学习目标域分类器.此类方法虽然将目标域分类器与源域分类器进行组合以弥补目标域分类器因利用不完全目标域样本学习而导致分类准确率不高的问题,但却忽略了对目标域特征属性整体的学习,制约着目标域在线学习性能的提高.(2)假设源域与目标域中存在未标记的辅助数据,对冲集成的在线异构迁移(Online Heterogeneous Transfer by Hedge Ensemble, OHTHE)^[1]和在线异构知识过渡(Online Heterogeneous Knowledge Transition, OHKT)^[6]利用源域中存在的未标记的辅助共现数据(Auxiliary Co-occurrence Data)建立源域和目标域的特征空间关联.在线异构迁移度量学习(Online Heterogeneous Transfer Metric Learning, OHTML)^[7]则使用具有源域与目标域中相同数据特征表示的未标记通信数据(corresponding data)作为辅助训练样本,以保持每对样本在源域与目标域中的距离一致为目标,学习目标域的距离度量.此类迁移学习方法仅适用于存在辅助数据的场景,且由于增加了对未标记辅助样本的标签学习时间,降低了将源域离线学习的知识在线迁移到目标域的时效性.

跨域结构保持投影(Cross-Domain Structure Preserving Projection, CDSPP)^[8]是一种可利用少量标记样本学习特征投影矩阵,实现异构域特征映射迁移的域适应方法,且计算复杂度较低.本文提出一种基于跨域结构保持投影的异构在线多源迁移学习方法(Heterogeneous Online Multi-source Transfer Learning with Cross-Domain Structure Preserving Projection, HetOMTL-

CDSPP).该方法通过跨域结构保持投影将多个源域离线数据与目标域初始少量离线数据的特征空间同时映射到同一个公共子空间以实现特征空间对齐,无须限定源域特征空间是目标域特征空间的子集,也不依赖任何特定的辅助数据.该方法基于公共子空间的跨域离线混合数据进行离线学习,利用目标域在线数据进行在线学习.针对源域与目标域学习模型组合,本文设计提出一种双层差异导向对冲集成策略,通过离线与在线学习模型的双层集成,以及源域与目标域组合权重的差异导向对冲(mistake-driven hedge),以实现源域离线学习模型与目标域在线学习模型的集成融合和在线演化更新,从而不断提升在线学习效果.

本文的主要贡献包括以下3个方面:(1)基于跨域结构保持投影,提出了一种实现多个异构源域与目标域特征空间统一表征的跨域在线多源迁移方法;并基于统一的特征公共子空间、跨域离线混合数据以及目标域在线数据,解决多个异构源域到目标域的知识迁移和在线学习样本稀缺问题.(2)提出了一种双层差异导向对冲集成策略,实现源域离线学习模型与目标域在线学习模型的两层集成融合和在线演化更新.(3)基于本文方法设计实现了一种异构在线多源迁移多分类算法 HetOMTL-CDSPP,并理论分析了该算法的分类错误上界.大量实验表明,该算法能有效降低目标域在线多分类的错误率,且优于同类在线多源迁移学习多分类方法.

2 基于跨域结构保持投影的异构在线多源迁移学习

2.1 问题描述

定义 n 个异构源域 $S = \{S_1, S_2, \dots, S_n\}$ 和目标域 T , 第 i 个源域 S_i 由离线数据集 $D_{S_i} = \left\{ \left(\mathbf{x}_j^{S_i}, y_j^{S_i} \right), j = 1, 2, \dots, n_{S_i} \right\}$ 组成, 包含 n_{S_i} 个样本 $\mathbf{x}_j^{S_i} \in \mathbb{R}^{d_{S_i}}$, $y_j^{S_i}$ 是样本 $\mathbf{x}_j^{S_i}$ 对应的类别标签, d_{S_i} 是源域特征空间的维度. 目标域 T 由一个含少量标记样本的离线数据集 $D_{T_{\text{off}}} = \left\{ \left(\mathbf{x}_j^T, y_j^T \right), j = 1, 2, \dots, n_T \right\}$ 和一个在线数据流 $D_{T_{\text{on}}} = \left\{ \left(\mathbf{x}_j, y_j \right), j = 1, 2, \dots, n_t, \dots \right\}$ 组成. \mathbf{x}_j^T 和 $\mathbf{x}_j \in \mathbb{R}^{d_T}$ 分别表示为目标域离线数据集和在线数据集中的第 j 个样本, y_j^T 和 y_j 分别为它们各自对应的类别标签, d_T 是目标域特征空间的维度, n_T 为目标域离线样本个数, n_t 表示为经过 t 轮后所有在线接收到的目标域样本个数. 若每一轮只依次接收一个样本 \mathbf{x}_j 和一个标签 y_j , 则有 $n_t = t$. 把目标域的所有离线数据按列向量合并形成矩阵 $\mathbf{X}_{T_{\text{off}}} \in \mathbb{R}^{d_T \times n_T}$, 把源域的所有离线数据按列向量合并形成矩阵 $\mathbf{X}_S \in \mathbb{R}^{d_S \times n_S}$, 则 D_{S_i} 和 $D_{T_{\text{off}}}$ 的数据空间可分别表示为 $\mathbf{X}_S \times Y$ 和 $\mathbf{X}_{T_{\text{off}}} \times Y$. 其中, $Y = \{1, 2, \dots, K\}$

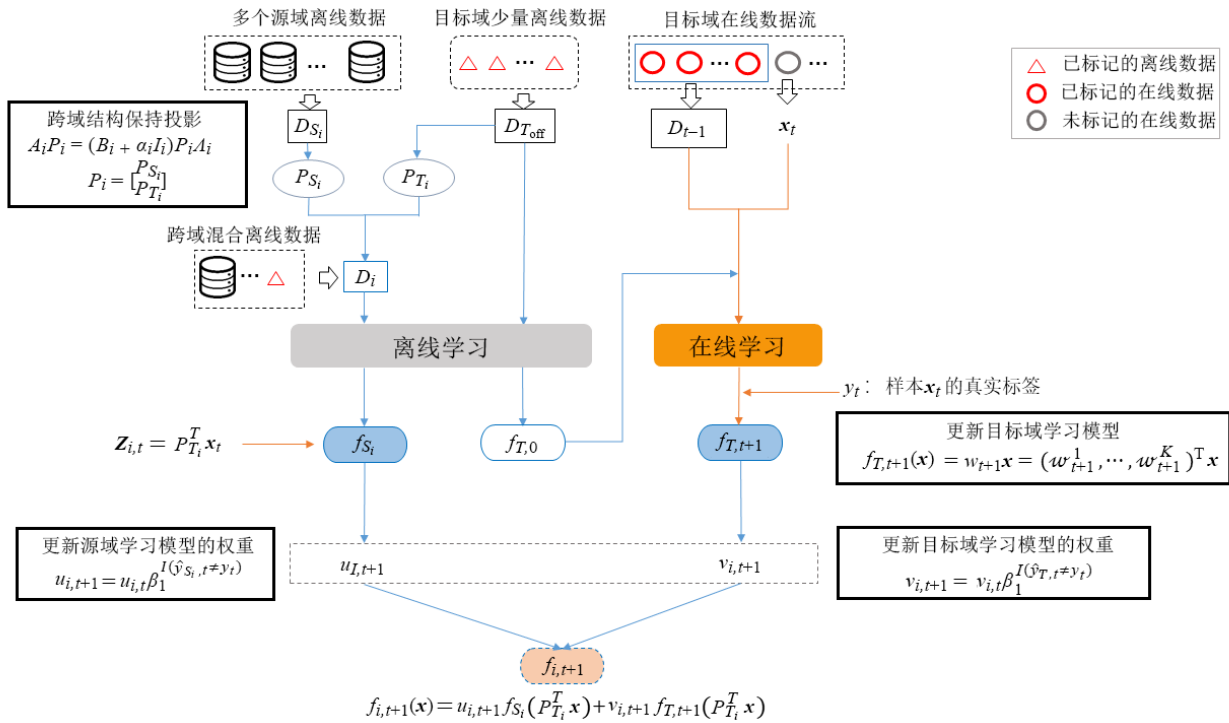
为源域与目标域的标签域,表示源域与目标域的样本均可分为 K 个不同的标签.

本文所研究的异构在线多源迁移学习问题可简要描述为:利用从多个异构源域离线数据与目标域初始少量的标记离线数据上学到的知识,以及 t 轮中所有在线接收到的目标域数据集 $D_t = \{(x_j, y_j), j = 1, 2, \dots, t\}$, 经过 t 轮在线学习训练以构建 $t+1$ 轮中的学习模型来预测目标域在线数据的标签.

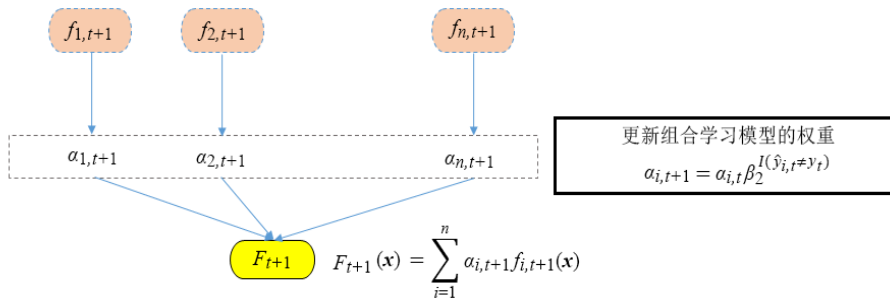
2.2 总体框架

本文提出的基于跨域结构保持投影的异构在线多源迁移学习方法总体框架可分为两个过程,即离线阶段和在线阶段,如图 1 所示. 在离线阶段,将目标域初始离线标记数据集 $D_{T_{off}}$ 分别与 n 个源域的离线标记数

据集 D_{S_i} 合并,再通过跨域结构保持投影组合矩阵 $P_i = [P_{S_i} P_{T_i}]$ 映射到 n 个潜在子空间以得到新特征空间中的跨域离线混合数据集 D_i . 利用跨域离线混合数据集 D_i 学习得到 n 个源域学习模型 f_{S_i} , 利用目标域初始离线数据集 $D_{T_{off}}$ 学习得到一个目标域初始学习模型 f_{T_1} ; 在线阶段,首先用离线阶段所求 P_i 中的目标域投影矩阵 P_{T_i} 将目标域样本 x 映射到新特征空间中,得到 $z_{T_i} = P_{T_i}^T x$, 并将其输入对应源域学习模型 f_{S_i} , 然后以 f_{T_1} 作为初始学习模型,在线学习得到目标域学习模型 $f_{T_{t+1}}$. 为有效集成融合源域离线学习模型和目标域在线学习模型,提升目标域组合学习模型性能,本文提出一种双层差异导向对冲集成策略,将源域和目标域的学习模型分



(a) 离线与在线学习及其第一层集成



(b) 学习模型的第二层集成

图 1 基于跨域结构保持投影的异构在线多源迁移学习方法总体框架

两层集成得到组合学习模型,第一层集成和第二层集成分别如图 1(a)和 1(b)所示,先将每个源域学习模型 f_{S_i} 分别与目标域学习模型 $f_{T,t+1}$ 配对,并给定不同权重 $u_{i,t+1}$ 和 $v_{i,t+1}$,进而得到组合学习模型 $f_{i,t+1}$;再给组合学习模型分配不同权重 $\alpha_{i,t+1}$ 以组成 $t+1$ 轮的组合学习模型 F_{t+1} . 其中, $u_{i,t+1}$, $v_{i,t+1}$ 和 $\alpha_{i,t+1}$ 是根据各学习模型的预测结果准确与否,将 t 轮中的各分类器权重 $u_{i,t}$, $v_{i,t}$ 和 $\alpha_{i,t}$ 分别与 Hedge(β) 值 β_1 和 β_2 相乘得到的,实现了权重的差异导向对冲(Mistake-driven Hedge)更新.

2.3 离线阶段

利用 n 个源域的离线标记数据集 D_{S_i} 和一个含有少量标记样本的目标域初始离线数据集 $D_{T_{off}}$,使用跨域结构保持投影将每对源-目标域的数据集 $(D_{S_i}, D_{T_{off}})$ 映射到 n 个公共子空间上. 通过求解式(1)中的广义特征值问题计算出第 i 个源域与目标域的投影矩阵的组合矩阵:

$$\begin{aligned} A_i P_i &= (B_i + \alpha_i I_i) P_i A_i \\ P_i &= [P_{S_i} P_{T_i}] (i=1, 2, \dots, n) \end{aligned} \quad (1)$$

其中,利用源域特征转换矩阵 $P_{S_i} \in \mathbb{R}^{d_s \times d}$ 与目标域特征转换矩阵 $P_{T_i} \in \mathbb{R}^{d_t \times d}$ 可分别将 D_{S_i} 和 $D_{T_{off}}$ 映射到 d 维的特征子空间,以得到新特征空间下的跨域离线混合数据集 D_i . $I_i \in \mathbb{R}^{(n_s+n_t) \times (n_s+n_t)}$ 是单位矩阵, α_i 是正则化的超参数, A_i 是对角特征矩阵:

$$A_i = \begin{bmatrix} 0 & X_{S_i} W^C_i (X_{T_{off}})^T \\ X_{T_{off}} (W^C_i)^T (X_{S_i})^T & 0 \end{bmatrix} \quad (2)$$

$$B_i = \begin{bmatrix} X_{S_i} L_{S_i} (X_{S_i})^T & 0 \\ 0 & X_{T_{off}} L_{T_{off}} (X_{T_{off}})^T \end{bmatrix} \quad (3)$$

其中, $W^C_i \in \mathbb{R}^{n_s \times n_t}$ 为跨域相似性矩阵,如果 $y_j^S = y_k^T$, 则 $W_{jk}^C_i = 1$; 反之,则为 0. $L_{S_i} = D_{S_i} - W_{S_i}^S + \frac{1}{2} D^{CS_i}$, $L_{T_{off}} = D^{T_{off}} - W^{T_{off}} + \frac{1}{2} D^{CT_{off}}$. $W_{S_i}^S \in \mathbb{R}^{n_s \times n_s}$ 为源域离线样本的相似性矩阵,如果 $y_j^S = y_k^S$, 则 $W_{jk}^S_i = 1$; 反之,则为 0. $W^{T_{off}} \in \mathbb{R}^{n_t \times n_t}$ 为目标域离线样本的相似性矩阵,如果 $y_j^T = y_k^T$, 则 $W_{jk}^{T_{off}} = 1$; 反之,则为 0. $D^{S_i}, D^{CS_i} \in \mathbb{R}^{n_s \times n_s}$ 且 $D^{T_{off}}, D^{CT_{off}} \in \mathbb{R}^{n_t \times n_t}$, 它们均为对角线矩阵, $D_{jj}^{S_i} = \sum_k W_{jk}^{S_i}$, $D_{jj}^{CS_i} = \sum_k W_{jk}^C_i$, $D_{jj}^{T_{off}} = \sum_k W_{jk}^{T_{off}}$, $D_{kk}^{CT_{off}} = \sum_j W_{jk}^C_i$.

通过源域投影矩阵 P_{S_i} 和目标域投影矩阵 P_{T_i} 矩阵可将源域和目标域的每个离线标记样本映射到同一公共特征子空间,得到新特征空间中的源域离线样本 $\mathbf{z}_{S_i} = P_{S_i}^T \mathbf{x}_{S_i}$ 和目标域离线样本 $\mathbf{z}_{T_i} = P_{T_i}^T \mathbf{x}_t$, 再由新特征空间中的源域离线样本和目标域离线样本构成跨域离线混

合数据集 D_i . 其中,每个样本可统一表示为 $\mathbf{z}_{i,j} \in \mathbb{R}^d$, 则有 $D_i = \{(\mathbf{z}_{i,j}, y_{i,j}), j=1, 2, \dots, n_{S_i} + n_{T_i}\}$.

采用多类被动-主动算法 (Multi-class Passive-Aggressive, MPA) [9] 并利用 n 个跨域离线混合数据集 D_i 和目标域原始离线标记数据集 $D_{T_{off}}$ 分别训练得到 n 个源域分类器 $f_{S_1}, f_{S_2}, \dots, f_{S_n}$ 和一个目标域分类器 $f_{T,1}$.

每个源域分类器 f_{S_i} 和目标域分类器 $f_{T,1}$ 分别以 $f_{S_i,1}$ 和 $f_{T_{off},1}$ 作为初始分类器经过 $(n_{S_i} + n_{T_i})$ 轮和 n_{T_i} 轮计算得到. 其中,

$$\begin{aligned} f_{S_i,1} &= (f_{S_i,1}^1, f_{S_i,1}^2, \dots, f_{S_i,1}^K)^T \\ &= (\mathbf{w}_{S_i,1}^1, \mathbf{w}_{S_i,1}^2, \dots, \mathbf{w}_{S_i,1}^K)^T \mathbf{x} \\ &= \mathbf{w}_{S_i,1} \mathbf{x} \end{aligned} \quad (4)$$

$$\begin{aligned} f_{T_{off},1} &= (f_{T_{off},1}^1, f_{T_{off},1}^2, \dots, f_{T_{off},1}^K)^T \\ &= (\mathbf{w}_{T_{off},1}^1, \mathbf{w}_{T_{off},1}^2, \dots, \mathbf{w}_{T_{off},1}^K)^T \mathbf{x} \\ &= \mathbf{w}_{T_{off},1} \mathbf{x} \end{aligned} \quad (5)$$

故有 $f_{S_i} = f_{S_i, (n_{S_i} + n_{T_i})} = \mathbf{w}_{S_i, (n_{S_i} + n_{T_i})} \mathbf{x}$, $f_{T,1} = f_{T_{off}, n_{T_i}} = \mathbf{w}_{T_{off}, n_{T_i}} \mathbf{x}$, 且可知每个源域分类器 f_{S_i} 和目标域分类器 $f_{T,1}$ 均由 K 个支持向量组成. 其中, $f_{S_i,1}^k = f_{T_{off},1}^k = \emptyset, k \in Y = \{1, 2, \dots, K\}$, K 为源域和目标域样本的标签类别数.

在第 j 轮中依次接收到跨域离线混合样本 $\mathbf{z}_{i,j}$ 和目标域离线样本 \mathbf{x}_j^T , 以及它们所对应的真实标签 $y_{i,j}$ 和 y_j^T . 首先根据式(6)和式(7)计算出 $f_{S_i,j}$ 和 $f_{T_{off},j}$ 中排名最高的无关标签 $r_{i,j}$ 和 r_j :

$$r_{i,j} = \arg \max_{k \in Y \text{ and } k \neq y_{i,j}} f_{S_i,j}^k(\mathbf{z}_{i,j}) \quad (6)$$

$$r_j = \arg \max_{k \in Y \text{ and } k \neq y_j^T} f_{T_{off},j}^k(\mathbf{x}_j^T) \quad (7)$$

然后将式(6)和式(7)中解得的标签 $r_{i,j}$ 和 r_j 分别代入式(8)和式(9), 计算出分类器 $f_{S_i,j}$ 和 $f_{T_{off},j}$ 的损失 $l_{S_i,j}$ 和 l_j :

$$l_{S_i,j} = \max \left(0, 1 - \left(f_{S_i,j}^{y_{i,j}}(\mathbf{z}_{i,j}) - f_{S_i,j}^{r_{i,j}}(\mathbf{z}_{i,j}) \right) \right) \quad (8)$$

$$l_j = \max \left(0, 1 - \left(f_{T_{off},j}^{y_j^T}(\mathbf{x}_j^T) - f_{T_{off},j}^{r_j}(\mathbf{x}_j^T) \right) \right) \quad (9)$$

其中, $f_{S_i,j} = [f_{S_i,j}^1, f_{S_i,j}^2, \dots, f_{S_i,j}^K]^T = \mathbf{w}_{S_i,j} \mathbf{x}$ 和 $f_{T_{off},j} = [f_{T_{off},j}^1, f_{T_{off},j}^2, \dots, f_{T_{off},j}^K]^T = \mathbf{w}_{T_{off},j} \mathbf{x}$ 分别利用前 $j-1$ 轮接收到的跨域离线混合样本和目标域离线样本得到.

最后通过优化目标式(10)解得向量矩阵 $\mathbf{w}_{S_i,j+1}$, 从而得到下一轮的源域分类器 $f_{S_i,j+1} = \mathbf{w}_{S_i,j+1} \mathbf{x}$.

$$\begin{cases} \mathbf{w}_{S_i,j+1} = \arg \min_{\mathbf{w} \in \mathbb{R}^{K \times d}} \frac{1}{2} \|\mathbf{w} - \mathbf{w}_{S_i,j}\|^2 + C\xi \\ \text{s.t. } l_{S_i,j} \leq \xi \text{ 和 } \xi \geq 0 \end{cases} \quad (10)$$

如果 $l_{S_i,j} = 0$, 则不更新向量矩阵 \mathbf{w} , 即 $\mathbf{w}_{S_i,j+1} = \mathbf{w}_{S_i,j}$;

如果 $l_{S,j} > 0$, 则可将优化目标式 (10) 转换为拉格朗日函数即式 (11):

$$\begin{aligned} \mathcal{L}(\mathbf{w}, \xi, \tau, \lambda) &= \frac{1}{2} \|\mathbf{w} - \mathbf{w}_{S,j}\|^2 + C\xi \\ &\quad + \tau \left(1 - \xi - \left(f_{S,j}^{y_{i,j}}(\mathbf{z}_{i,j}) - f_{S,j}^{r_{i,j}}(\mathbf{z}_{i,j}) \right) \right) - \lambda \xi \\ &= \frac{1}{2} \|\mathbf{w} - \mathbf{w}_{S,j}\|^2 + \xi(C - \tau - \lambda) \\ &\quad + \tau \left(1 - \left(f_{S,j}^{y_{i,j}}(\mathbf{z}_{i,j}) - f_{S,j}^{r_{i,j}}(\mathbf{z}_{i,j}) \right) \right) \end{aligned} \quad (11)$$

其中, $\lambda \geq 0$ 和 $\tau \geq 0$ 是拉格朗日乘数, 通过求解拉格朗日函数式 (11) 关于变量 \mathbf{w} 和非负松弛变量 ξ 的最小值, 计算出下一轮中向量矩阵 $\mathbf{w}_{S,j+1} = (\mathbf{w}_{S,j+1}^1, \mathbf{w}_{S,j+1}^2, \dots, \mathbf{w}_{S,j+1}^K)^T$ 的更新方式即式 (12) 以及对应的学习率 $\tau_{i,j}$:

$$\mathbf{w}_{S,j+1}^k = \begin{cases} \mathbf{w}_{S,j}^k + \tau_{i,j} \mathbf{z}_{i,j}, & k = y_{i,j} \\ \mathbf{w}_{S,j}^k - \tau_{i,j} \mathbf{z}_{i,j}, & k = r_{i,j} \\ \mathbf{w}_{S,j}^k, & k \in Y \text{ 且 } k \neq \{y_{i,j}, r_{i,j}\} \end{cases} \quad (12)$$

$$\tau_{i,j} = \min \left(C, \frac{l_{S,j}}{\|f_{S,j}^{y_{i,j}}(\mathbf{z}_{i,j}) - f_{S,j}^{r_{i,j}}(\mathbf{z}_{i,j})\|^2} \right) \quad (13)$$

同样地, 通过优化目标式 (14) 解得向量矩阵 $\mathbf{w}_{T_{\text{off}},j+1}$, 从而得到下一轮的目标域分类器 $f_{T_{\text{off}},j+1} = \mathbf{w}_{T_{\text{off}},j+1} \mathbf{x}$.

$$\begin{cases} \mathbf{w}_{T_{\text{off}},j+1} = \arg \min_{\mathbf{w} \in \mathbb{R}^{K \times d_r}} \frac{1}{2} \|\mathbf{w} - \mathbf{w}_{T_{\text{off}},j}\|^2 + C\xi \\ \text{s.t. } l_j \leq \xi \text{ 和 } \xi \geq 0 \end{cases} \quad (14)$$

如果 $l_j = 0$, 则不更新向量矩阵 \mathbf{w} , 即 $\mathbf{w}_{T_{\text{off}},j+1} = \mathbf{w}_{T_{\text{off}},j}$; 如果 $l_j > 0$, 则可将优化目标式 (14) 转换为拉格朗日函数式 (15):

$$\begin{aligned} \mathcal{L}(\mathbf{w}, \xi, \tau, \lambda) &= \frac{1}{2} \|\mathbf{w} - \mathbf{w}_{T_{\text{off}},j}\|^2 \\ &\quad + C\xi + \tau \left(1 - \xi - \left(f_{T_{\text{off}},j}^{y_j^T}(\mathbf{x}_j^T) - f_{T_{\text{off}},j}^{r_j^T}(\mathbf{x}_j^T) \right) \right) - \lambda \xi \\ &= \frac{1}{2} \|\mathbf{w} - \mathbf{w}_{T_{\text{off}},j}\|^2 + \xi(C - \tau - \lambda) \\ &\quad + \tau \left(1 - \left(f_{T_{\text{off}},j}^{y_j^T}(\mathbf{x}_j^T) - f_{T_{\text{off}},j}^{r_j^T}(\mathbf{x}_j^T) \right) \right) \end{aligned} \quad (15)$$

其中, $\lambda \geq 0$ 和 $\tau \geq 0$ 是拉格朗日乘数, 通过求解拉格朗日函数式 (15) 关于变量 \mathbf{w} 和非负松弛变量 ξ 的最小值, 计算出下一轮中向量矩阵 $\mathbf{w}_{T_{\text{off}},j+1} = (\mathbf{w}_{T_{\text{off}},j+1}^1, \mathbf{w}_{T_{\text{off}},j+1}^2, \dots, \mathbf{w}_{T_{\text{off}},j+1}^K)^T$ 的更新方式即式 (16) 以及对应的学习率 τ_j :

$$\mathbf{w}_{T_{\text{off}},j+1}^k = \begin{cases} \mathbf{w}_{T_{\text{off}},j}^k + \tau_j \mathbf{x}_j^T, & k = y_j^T \\ \mathbf{w}_{T_{\text{off}},j}^k - \tau_j \mathbf{x}_j^T, & k = r_j \\ \mathbf{w}_{T_{\text{off}},j}^k, & k \in Y \text{ 且 } k \neq \{y_j^T, r_j\} \end{cases} \quad (16)$$

$$\tau_j = \min \left(C, \frac{l_j}{\|f_{T_{\text{off}},j}^{y_j^T}(\mathbf{x}_j^T) - f_{T_{\text{off}},j}^{r_j^T}(\mathbf{x}_j^T)\|^2} \right) \quad (17)$$

2.4 在线阶段

首先采用 MPA 算法, 以离线阶段得到的 $f_{T,1}$ 作为初始分类器, 利用前 $t-1$ 轮的目标域样本训练得到一个目标域分类器 $f_{T,t}$. 其中, 目标域的多分类器 $f_{T,t} = [f_{T,t}^1, f_{T,t}^2, \dots, f_{T,t}^K]^T = (\mathbf{w}_t^1, \mathbf{w}_t^2, \dots, \mathbf{w}_t^K)^T \mathbf{x} = \mathbf{w}_t \mathbf{x}$ 由 K 个支持向量组成, K 为目标域样本的标签类别数.

然后接收第 t 轮的目标域样本 \mathbf{x}_t , 用离线阶段得到的 n 个投影矩阵 \mathbf{P}_{T_i} 将样本 \mathbf{x}_t 分别映射到 n 个新特征空间, 得到 $\mathbf{z}_t^i = \mathbf{P}_{T_i}^T \mathbf{x}_t (i=1, 2, \dots, n)$, 将其分别输入对应的源域分类器 f_{S_i} . 给源域分类器 f_{S_i} 与目标域分类器 $f_{T,t}$ 以不同权重 $u_{i,t}$ 和 $v_{i,t}$ 进行第一层集成, 得到 n 个组合分类器 $f_{i,t}$:

$$f_{i,t}(\mathbf{x}_t) = u_{i,t} f_{S_i}(\mathbf{P}_{T_i}^T \mathbf{x}_t) + v_{i,t} f_{T,t}(\mathbf{x}_t) \quad (18)$$

其中, $u_{i,t}, v_{i,t} \in [0, 1]$ 且满足 $u_{i,t} + v_{i,t} = 1$. 对这 n 个组合分类器 $f_{i,t}$ 给定不同权重 $\alpha_{i,t}$ 进行第二层集成, 得到第 t 轮的最终分类器:

$$F_t(\mathbf{x}_t) = \sum_{i=1}^n \alpha_{i,t} f_{i,t}(\mathbf{x}_t) \quad (19)$$

因有 $F_t(\mathbf{x}_t) = [F_t^1(\mathbf{x}_t), F_t^2(\mathbf{x}_t), \dots, F_t^K(\mathbf{x}_t)]^T$, 则预测标签为

$$\hat{y}_t = \arg \max_{k \in Y} F_t^k(\mathbf{x}_t) \quad (20)$$

根据目标域样本 \mathbf{x}_t 的真实标签 y_t 解得 $f_{T,t}$ 中排名最高的无关标签 s_t :

$$s_t = \arg \max_{k \in Y \text{ 且 } k \neq y_t} f_{T,t}^k(\mathbf{x}_t) \quad (21)$$

将式 (21) 中解得的标签 s_t 代入式 (22) 计算出目标域分类器 $f_{T,t}$ 的损失 l_t :

$$l_t = \max \left(0, 1 - \left(f_{T,t}^{y_t}(\mathbf{x}_t) - f_{T,t}^{s_t}(\mathbf{x}_t) \right) \right) \quad (22)$$

通过优化目标式 (23) 解得向量矩阵 \mathbf{w}_{t+1} , 从而得到下一轮的目标域分类器 $f_{T,t+1} = \mathbf{w}_{t+1} \mathbf{x}$.

$$\begin{cases} \mathbf{w}_{t+1} = \arg \min_{\mathbf{w} \in \mathbb{R}^{K \times d_r}} \frac{1}{2} \|\mathbf{w} - \mathbf{w}_t\|^2 + C\xi \\ \text{s.t. } l_t \leq \xi \text{ 和 } \xi \geq 0 \end{cases} \quad (23)$$

如果 $l_t = 0$, 则不更新向量矩阵 \mathbf{w} , 即 $\mathbf{w}_{t+1} = \mathbf{w}_t$; 如果 $l_t > 0$, 则可将优化目标式 (23) 转换为拉格朗日函数式 (24):

$$\begin{aligned} \mathcal{L}(\mathbf{w}, \xi, \tau, \lambda) &= \frac{1}{2} \|\mathbf{w} - \mathbf{w}_t\|^2 + C\xi \\ &\quad + \tau \left(1 - \xi - \left(f_{T,t}^{y_t}(\mathbf{x}_t) - f_{T,t}^{s_t}(\mathbf{x}_t) \right) \right) - \lambda \xi \\ &= \frac{1}{2} \|\mathbf{w} - \mathbf{w}_t\|^2 + \xi(C - \tau - \lambda) \\ &\quad + \tau \left(1 - \left(f_{T,t}^{y_t}(\mathbf{x}_t) - f_{T,t}^{s_t}(\mathbf{x}_t) \right) \right) \end{aligned} \quad (24)$$

其中, $\lambda \geq 0$ 和 $\tau \geq 0$ 是拉格朗日乘数. 通过求解拉格朗日函数式 (24) 关于变量 \mathbf{w} 和非负松弛变量 ξ 的最小值, 计算出下一轮中向量矩阵 $\mathbf{w}_{t+1} = (\mathbf{w}_{t+1}^1, \mathbf{w}_{t+1}^2, \dots, \mathbf{w}_{t+1}^K)^T$ 的更

新方式即式(25)以及对应的学习率 τ_t :

$$\mathbf{w}_{t+1}^k = \begin{cases} \mathbf{w}_t^k + \tau_t \mathbf{x}_t, & k = y_t \\ \mathbf{w}_t^k - \tau_t \mathbf{x}_t, & k = s_t \\ \mathbf{w}_t^k, & k \in Y \text{ 且 } k \neq \{y_t, s_t\} \end{cases} \quad (25)$$

$$\tau_t = \min \left(C, \frac{L_t}{\|f_{T,t}^{y_t}(\mathbf{x}_t) - f_{T,t}^{s_t}(\mathbf{x}_t)\|^2} \right) \quad (26)$$

将 $\mathbf{z}_t^i = \mathbf{P}_{T_i}^T \mathbf{x}_t$ 输入源域分类器 f_{S_i} , 得到源域分类器 f_{S_i} 的预测标签:

$$\hat{y}_{S_i,t} = \arg \max_{k \in Y} f_{S_i}^k(\mathbf{z}_t^i) \quad (27)$$

将 \mathbf{x}_t 输入目标域分类器 $f_{T,t}$ 与组合分类器 $f_{i,t}$, 得到各分类器的预测标签:

$$\hat{y}_{T,t} = \arg \max_{k \in Y} f_{T,t}^k(\mathbf{x}_t) \quad (28)$$

$$\hat{y}_{i,t} = \arg \max_{k \in Y} f_{i,t}^k(\mathbf{x}_t) \quad (29)$$

最后, 根据样本 \mathbf{x}_t 的真实标签 y_t 与各分类器预测标签的差异和 Hedge(β) 值, 更新权重:

$$u_{i,t+1} = u_{i,t} \beta_1^{I(\hat{y}_{S_i,t} \neq y_t)} \quad (30)$$

$$v_{i,t+1} = v_{i,t} \beta_1^{I(\hat{y}_{T,t} \neq y_t)} \quad (31)$$

$$\alpha_{i,t+1} = \alpha_{i,t} \beta_2^{I(\hat{y}_{i,t} \neq y_t)} \quad (32)$$

其中, I 是指示函数, 若括号内的条件满足则为 1, 反之则为 0.

2.5 算法描述

根据上文描述, 可将异构在线多源迁移学习多分类算法 HetOMTL-CDSPP 总结如下. 其中, T 表示在线学习总轮次, 假设每一轮只接受一个目标域在线样本, 那么 T 与目标域在线样本数量相等.

算法 1 HetOMTL-CDSPP 算法

输入: 给定的 n 个源域的离线标记数据集 $D_{S_j} = \{(\mathbf{x}_j^S, y_j^S), j = 1, 2, \dots, n_S\}$ ($i = 1, 2, \dots, n$) 和目标域的初始离线标记数据集 $D_{T_{\text{off}}} = \{(\mathbf{x}_j^T, y_j^T), j = 1, 2, \dots, n_T\}$; 正则化参数 C 及权重衰减因子 $\beta_1, \beta_2 \in (0, 1)$.

输出: $F_t(\mathbf{x}) = \sum_{i=1}^n \alpha_{i,t} (u_{i,t} f_{S_i}(\mathbf{P}_{T_i}^T \mathbf{x}) + v_{i,t} f_{T,t}(\mathbf{x}))$.

1. 初始化: $f_{S_i,1}^k = f_{T_{\text{off}},1}^k = \emptyset, k \in Y = \{1, \dots, K\}, i = 1, \dots, n$

$$\alpha_{i,1} = \frac{1}{n} \quad (i = \{1, 2, \dots, n\});$$

$$u_{i,1} = v_{i,1} = \frac{1}{2} \quad (i = \{1, 2, \dots, n\}).$$

2. FOR $i = 1, 2, \dots, n$:

3. 利用离线标记数据集 $D_{S_i} \cup D_{T_{\text{off}}}$ 通过求解式(1)中的广义特征值问题计算出投影矩阵 \mathbf{P}_{S_i} 和 \mathbf{P}_{T_i} ;

4. 通过源域投影矩阵 \mathbf{P}_{S_i} 和目标域投影矩阵 \mathbf{P}_{T_i} 矩阵将离线标记数据集 $D_{S_i} \cup D_{T_{\text{off}}}$ 映射为跨域离线混合数据集 $D_i = \{(\mathbf{z}_{i,j}, y_{i,j}), j = 1, 2, \dots, n_{S_i} + n_T\}$;

5. 利用跨域离线混合数据集 D_i 离线学习源域分类器 f_{S_i} , 其中,

$$f_{S_i} = f_{S_i(n_{S_i} + n_T)} = \mathbf{w}_{S_i(n_{S_i} + n_T)}^T \mathbf{x};$$

6. FOR $j = 1, 2, \dots, (n_{S_i} + n_T)$:

7. 接收跨域离线混合样本: $\mathbf{z}_{i,j} \in \mathbb{R}^d$

8. 根据式(6)求解得到标签 $r_{i,j}$

9. 根据式(8)计算源域分类器 f_{S_i} 的损失 $l_{S_i,j}$

10. IF $l_{S_i,j} > 0$, THEN

11. 根据式(13)计算出学习率 $\tau_{i,j}$

12. 根据式(12)更新得到 $\mathbf{w}_{S_i,j+1}$

13. END IF

14. END FOR

15. END FOR

16. 离线学习目标域分类器 $f_{T_{\text{off}},n_T} = \mathbf{w}_{T_{\text{off}},n_T}^T \mathbf{x}$:

17. FOR $j = 1, 2, \dots, n_T$:

18. 接收目标域离线样本: $\mathbf{x}_j^T \in \mathbb{R}^{d_T}$

19. 根据式(7)求解得到标签 r_j

20. 根据式(9)计算目标域分类器 $f_{T_{\text{off}},j}$ 的损失 l_j

21. IF $l_j > 0$, THEN

22. 根据式(17)计算出学习率 τ_j

23. 根据式(16)更新得到 $\mathbf{w}_{T_{\text{off}},j+1}$

24. END IF

25. END FOR

26. 初始化目标域分类器 $f_{T,1} = f_{T_{\text{off}},n_T}$

27. FOR $t = 1$ to T :

28. 接收目标域在线样本: $\mathbf{x}_t \in \mathbb{R}^{d_T}$

29. 计算得到目标分类器: $f_{T,t} = \mathbf{w}_t^T \mathbf{x}_t$

30. 将 \mathbf{x}_t 映射到对应的 n 个新特征空间

$$\mathbf{z}_t^i = \mathbf{P}_{T_i}^T \mathbf{x}_t \quad (i = 1, 2, \dots, n)$$

31. 根据式(20)得到样本 \mathbf{x}_t 的预测标签 \hat{y}_t

32. 接收 \mathbf{x}_t 的真实标签 $y_t \in \{1, 2, \dots, K\}$

33. FOR $i = 1, 2, \dots, n$:

34. 根据式(21)求解得到标签 s_i

35. 根据式(22)计算目标域分类器 $f_{T,t}$ 的损失 l_t

36. IF $l_t > 0$, THEN

37. 根据式(26)计算出学习率 τ_t

38. 根据式(25)更新得到 \mathbf{w}_{t+1}

39. END IF

40. 根据式(27)至式(29)计算 $\hat{y}_{S_i,t}, \hat{y}_{T,t}, \hat{y}_{i,t}$

41. 根据式(30)至式(32)更新 $u_{i,t+1}, v_{i,t+1}, \alpha_{i,t+1}$

42. END FOR

43. 归一化权重

$$u_{i,t+1} = u_{i,t} / z_{i,t+1}, v_{i,t+1} = v_{i,t} / z_{i,t+1}, \alpha_{i,t} = \alpha_{i,t} / \sum_{i=1}^n \alpha_{i,t}$$

$$\text{其中 } z_{i,t+1} = u_{i,t+1} + v_{i,t+1}$$

44. END FOR

HetOMTL-CDSPP 算法复杂度计算主要包括离线阶段和在线阶段的计算复杂度.

假定 m_S, m_T, m 分别为源域特征空间的维度、目标域特征空间的维度、公共子空间的维度, $n_S = \max \{n_{S_i}\}, m_S = \max \{d_{S_i}\}, i \in \{1, 2, \dots, n\}$.

离线阶段: 式(2)和式(3)的矩阵相乘计算复杂度为 $\mathcal{O}((n_S + n_T)m_S m_T)$, 式(1)中特征值分解的计算复杂度为 $\mathcal{O}((m_S + m_T)^3)$, 源域学习模型的计算复杂度为 $\mathcal{O}((n_S + n_T)m)$. 因离线阶段需要学习 n 个源域上的知

识,故离线阶段总体计算复杂度为 $\mathcal{O}(n[(n_S+n_T)m_S m_T+(m_S+m_T)^3])$.

在线阶段:学习目标域学习模型的计算复杂度为 $\mathcal{O}(m_T)$,更新最终学习模型的计算复杂度为 $\mathcal{O}(1)$.

故 HetOMTL-CDSPP 算法的计算复杂度为 $\mathcal{O}(n[(n_S+n_T)m_S m_T+(m_S+m_T)^3+(n_S+n_T)m]+m_T)$.

2.6 理论分析

HetOMTL-CDSPP 算法的预测错误理论上界证明如下.

定理 1 假设 M 为 HetOMTL-CDSPP 算法在线分类错误的个数. 若假设

$$\beta_2 = \frac{\sqrt{\min\{M_i\}}}{\sqrt{\min\{M_i\}} + \sqrt{\ln n}} \quad (33)$$

则有

$$M \leq \min\{M_i\} + \frac{3}{2} \sqrt{\ln n + \min\{M_i\}} + \ln n \quad (34)$$

其中,

$$M_i = \sum_{i=1}^T I(\hat{y}_{i,t} \neq y_t) \quad (35)$$

证明 从文献[10]中的定理2可知,若将每个组合分类器 f_i 的权重统一初始化为 $\frac{1}{n}$,则可由以下式子解得在线分类错误的个数 M 的边界:

$$M \leq \frac{\sqrt{\min\{M_i\}} \ln(1/\beta_2) + \ln n}{1 - \beta_2} \quad (36)$$

又因为,当 $\beta_2 \in (0, 1]$ 时,有

$$-\ln \beta_2 \leq \frac{1 - \beta_2^2}{2\beta_2} \quad (37)$$

若将式(37)代入到式(36),则可解得

$$M \leq \frac{\min\{M_i\}(1 + \beta_2)}{2\beta_2} + \frac{\ln n}{1 - \beta_2} \quad (38)$$

用式(33)替代式(38)中的 β_2 即可证得式(34).

证毕

定理 2 若假设

$$\beta_1 = \frac{\sqrt{\min\{M_S, M_T\}}}{\sqrt{\min\{M_S, M_T\}} + \sqrt{\ln 2}} \quad (39)$$

则有

$$M_i \leq \min\{M_S, M_T\} + \frac{3}{2} \sqrt{\ln 2 \times \min\{M_S, M_T\}} + \ln 2 \quad (40)$$

其中,

$$M_S = \sum_{i=1}^T I(\hat{y}_{S,t} \neq y_t) \quad (41)$$

$$M_T = \sum_{i=1}^T I(\hat{y}_{T,t} \neq y_t) \quad (42)$$

证明 因每个组合分类器 f_i 均由源域分类器 f_S 和目标域分类器 f_T 组成,且它们的初始权重均为 $\frac{1}{n}$,则可根据文献[10]中的定理2,由以下式子解得组合分类器的在线分类错误个数 M_i 的边界为

$$M_i \leq \frac{\sqrt{\min\{M_S, M_T\}} \ln(1/\beta_1) + \ln 2}{1 - \beta_1} \quad (43)$$

与定理1同理,可解得

$$M_i \leq \frac{\min\{M_S, M_T\}(1 + \beta_1)}{2\beta_1} + \frac{\ln 2}{1 - \beta_1} \quad (44)$$

用式(39)去替代(44)中的 β_1 即可证得式(40).

证毕

3 实验结果与分析

3.1 数据集

本文使用以下3个公开数据集作为实验数据集:

Office-Caltech^[11]是一个图片数据集,包含了4个子集,即 Amazon(A), Webcam(W), DSLR(D)和 Caltech(C),具有4 096维的Decaf₆、800维的SURF这两种可用于跨域自适应的图片特征.实验分别从这两种特征中选择其中一种特征中的全部子集作为源域,从另一种特征中选择任意一个子集作为目标域,排列组合产生8组异构在线迁移学习分类任务.

Office-Home^[12]包含了4个子集: Art(A), Clipart(C), Product(P)和 Real-world(R).分别用VGG16^[13]和 ResNet50^[14]模型进行预训练,提取得到4 096维和2 048维的两组特征.实验选择任意一组特征中的4个子集作为源域,另一组特征中的一个子集作为目标域,排列组合产生8组异构在线迁移学习分类任务.

NUS-WIDE^[15]和 ImageNet^[16],实验用具有64维标签特征的NUS-WIDE作为源域,用具有4 096维图片特征Decaf₆的ImageNet作为目标域,产生1组异构在线迁移学习分类任务.

实验中所用数据的更多细节如表1所示.

表1 数据集的描述

数据集	类别	源域标记数量/类	目标域标记数量/类	目标域(子集)	目标域测试
Office-Caltech	10	20	3	A	928
				W	265
				D	127
				C	1 093
Office-Home	65	20	3	A	2 232
				C	4 170
				P	4 244
				R	4 162
NUS-ImageNet	8	100	3	ImageNet	800

3.2 实验设置

为验证本文所提出的 HetOMTL-CDSPP 算法的有效性,选择在线多分类算法 MPA 和同构在线多源迁移学习多分类算法 OMTL-MC^[17] (Online Multi-source Transfer Learning for Multi-class Classification) 进行实验对比. 因 OMTL-MC 算法只适用于同构领域间的知识迁移,实验中先用 CDSPP 将源域与目标域的特征空间映射到同一公共子空间再执行该算法,下文用 OMTLMC-CDSPP 表示. 实验以异构在线迁移学习任务在目标域上的分类错误率作为算法性能的评价标准,每种算法均复执行 30 次,计算出目标域在线分类的平均错误率和平均在线累计错误率. 错误率及在线累计错误率的计算如下:

$$\text{mistake rate} = \frac{|\mathbf{x}_j: \mathbf{x}_j \in D_{T_m} \wedge \hat{y}_j \neq y_j|}{|\mathbf{x}_j: \mathbf{x}_j \in D_{T_m}|}$$

$$\text{online cumulative mistake rate} = \frac{|\mathbf{x}_j: \mathbf{x}_j \in D_l \wedge \hat{y}_j \neq y_j|}{|\mathbf{x}_j: \mathbf{x}_j \in D_l|}$$

为保证公平性,本文参照文献[10]中 OMTL-MC 算法的参数设置,将参数统一设置为: $C=1$, $\beta_1 = \frac{\sqrt{T}}{\sqrt{T} + \sqrt{\ln 2}}$, $\beta_2 = \frac{\sqrt{T}}{\sqrt{T} + \sqrt{\ln n}}$, $w_{i,1} = \frac{1}{n}$, $u_{i,1} = v_{i,1} = \frac{1}{2}$ ($i=1, 2, \dots, n$).

3.3 实验结果

本文在 3 个数据集上的实验结果分别如表 2 至表 6 所示. 错误率为 30 次实验的平均值,括号内为标准差,时间则是预测单个目标域样本标签所需的平均时间. 实验结果的具体细节如图 2 至图 4 所示,图 2 和图 3 表示的是数据集 Office-Caltech 与 Office-Home 上,不同目标域上两组异构在线迁移学习任务执行 30 次的平均在线累计错误率随目标域样本数增加而变化的情况. 图 2 (a) 描绘了 2 种情况:①将具有 Decaf₆ 特征的源域 A, W, D, C 上学到的知识迁移到具有 SURF 特征的目标域 A; ②将具有 SURF 特征的源域 A, W, D, C 上学到的知识迁移到具有 Decaf₆ 特征的目标域 A. 这 2 组异构在线迁移学习任务执行 30 次的平均在线累计错误率随目标域 Amazon (A) 样本数增加而变化的情况. 图 4 表示的是 NUS-ImageNet 数据集中以 NUS-WIDE 为源域、ImageNet 为目标域的异构在线迁移任务.

执行 30 次的平均在线累计错误率随目标 ImageNet 样本数增加而变化的情况.

由表 2 至表 6 可知, HetOMTL-CDSPP 算法几乎在所有任务上都能获得最优的分类结果;由图 2 至图 4 可知, HetOMTL-CDSPP 算法在 3 个数据集上的平均在线累计错误率均随着目标域样本数的增加而逐渐降低.

表 2 Office-Caltech 数据集上 SURF 特征 → Decaf₆ 特征

方法	A,W,D,C → A		A,W,D,C → W		A,W,D,C → D		A,W,D,C → C	
	Mistake/%	Time/ms	Mistake/%	Time/ms	Mistake/%	Time/ms	Mistake/%	Time/ms
MPA	7.539 5 (0.499 4)	0.063	4.327 0 (0.797 3)	0.057	6.640 4 (1.427 9)	0.052	13.296 7 (0.624 9)	0.066
OMTLMC-CDSPP	11.756 5 (1.861 8)	0.428	10.088 1 (3.465 5)	0.387	8.897 6 (3.116 5)	0.363	22.348 3 (2.184 8)	0.459
HetOMTL-CDSPP	6.724 1 (0.463 8)	0.711	3.308 2 (0.928 0)	0.703	4.566 9 (1.247 6)	0.685	12.320 8 (0.710 5)	0.774

表 3 Office-Caltech 数据集上 Decaf₆ 特征 → SURF 特征

方法	A,W,D,C → A		A,W,D,C → W		A,W,D,C → D		A,W,D,C → C	
	Mistake/%	Time/ms	Mistake/%	Time/ms	Mistake/%	Time/ms	Mistake/%	Time/ms
MPA	37.252 2 (0.822 2)	0.014	30.251 6 (1.972 3)	0.014	41.994 8 (3.138 3)	0.014	53.491 9 (1.467 1)	0.015
OMTLMC-CDSPP	58.811 1 (2.284 4)	0.131	40.717 0 (3.843 7)	0.138	44.698 2 (3.464 3)	0.126	70.006 1 (2.777 3)	0.130
HetOMTL-CDSPP	36.734 9 (0.911 0)	0.205	28.188 7 (2.153 3)	0.206	38.923 9 (3.029 8)	0.211	53.141 2 (1.466 4)	0.209

分析以上实验结果,由于 MPA 算法没有采用迁移学习,只利用目标域数据来进行在线学习,计算复杂度较低,所以错误率较高,平均预测时间也最短. OMTLMC-CDSPP 算法虽然采用了迁移学习,但在源域与目标域分类器的权重更新策略上,只是通过比较这

两种分类器的损失值大小来更新权重,更新后的权重并不能完全反映出这两种分类器的分类精度,因此错误率也比较高;且相比 MPA 算法, OMTLMC-CDSPP 算法的计算复杂度相对更高,平均预测时间更长. 本文提出的 HetOMTL-CDSPP 算法将跨域结构保持投影引入

表 4 Office-Home 数据集上 VGG16 特征→ResNet50 特征

方法	A,C,P,R → A		A,C,P,R → C		A,C,P,R → P		A,C,P,R → R	
	Mistake/%	Time/ms	Mistake/%	Time/ms	Mistake/%	Time/ms	Mistake/%	Time/ms
MPA	49.729 7 (0.842 8)	0.166	52.799 4 (0.524 4)	0.184	26.793 9 (0.460 8)	0.168	32.349 8 (0.503 2)	0.168
OMTLMC-CDSPP	47.037 0 (1.017 4)	1.232	56.555 6 (1.378 6)	1.296	28.376 5 (1.503 3)	1.256	33.287 7 (1.408 5)	1.287
HetOMTL-CDSPP	47.431 3 (0.824 1)	2.525	51.527 6 (0.571 8)	2.770	24.146 2 (0.437 4)	2.600	30.012 8 (0.562 2)	2.571

表 5 Office-Home 数据集上 ResNet50 特征→VGG16 特征

方法	A,C,P,R → A		A,C,P,R → C		A,C,P,R → P		A,C,P,R → R	
	Mistake/%	Time/ms	Mistake/%	Time/ms	Mistake/%	Time/ms	Mistake/%	Time/ms
MPA	53.151 1 (0.655 9)	0.930	60.557 2 (0.487 2)	0.954	31.633 7 (0.474 9)	0.938	37.317 0 (0.498 0)	0.952
OMTLMC-CDSPP	59.787 9 (1.565 2)	6.696	67.360 5 (1.507 3)	6.747	37.405 7 (1.419 8)	7.505	43.724 2 (1.895 0)	7.707
HetOMTL-CDSPP	52.113 2 (0.567 7)	14.272	59.916 1 (0.486 4)	14.720	29.869 6 (0.471 6)	14.415	35.970 7 (0.520 1)	14.716

表 6 NUS-ImageNet 数据集 Tag 特征→Image 特征

方法	NUS-WIDE → ImageNet	
	Mistake/%	Time/ms
MPA	27.350 0 (0.851 8)	0.083
OMTLMC-CDSPP	36.658 3 (3.502 3)	0.176
HetOMTL-CDSPP	24.800 0 (1.010 0)	0.269

在线学习. 相比 MPA 算法, HetOMTL-CDSPP 算法将异构的源域与目标域的特征空间通过投影矩阵映射到同一公共子空间, 同时利用源域与目标域的离线数据来辅助目标域在线数据分类任务, 从而提高了分类准确性; 相比 OMTLMC-CDSPP 算法, HetOMTL-CDSPP 算法采用双层差异导向对冲集成策略, 优化源域分类器与

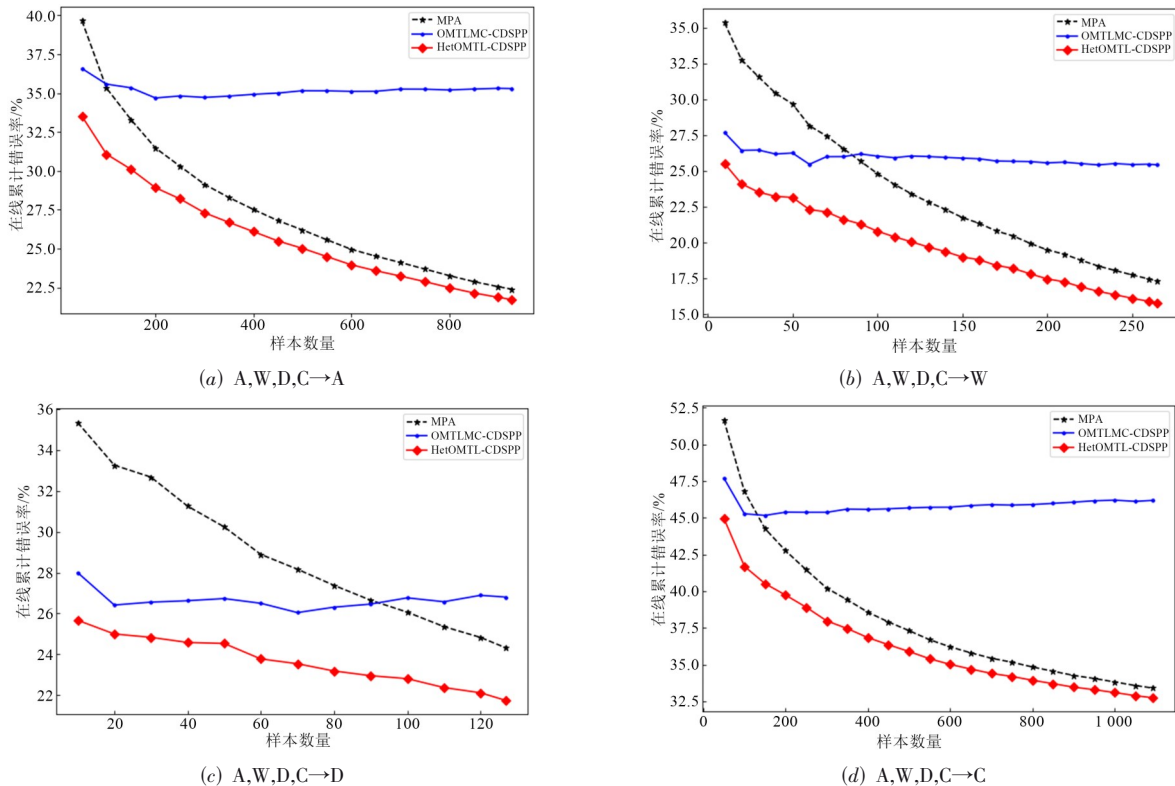


图 2 Office-Caltech 数据集的平均在线累计错误率

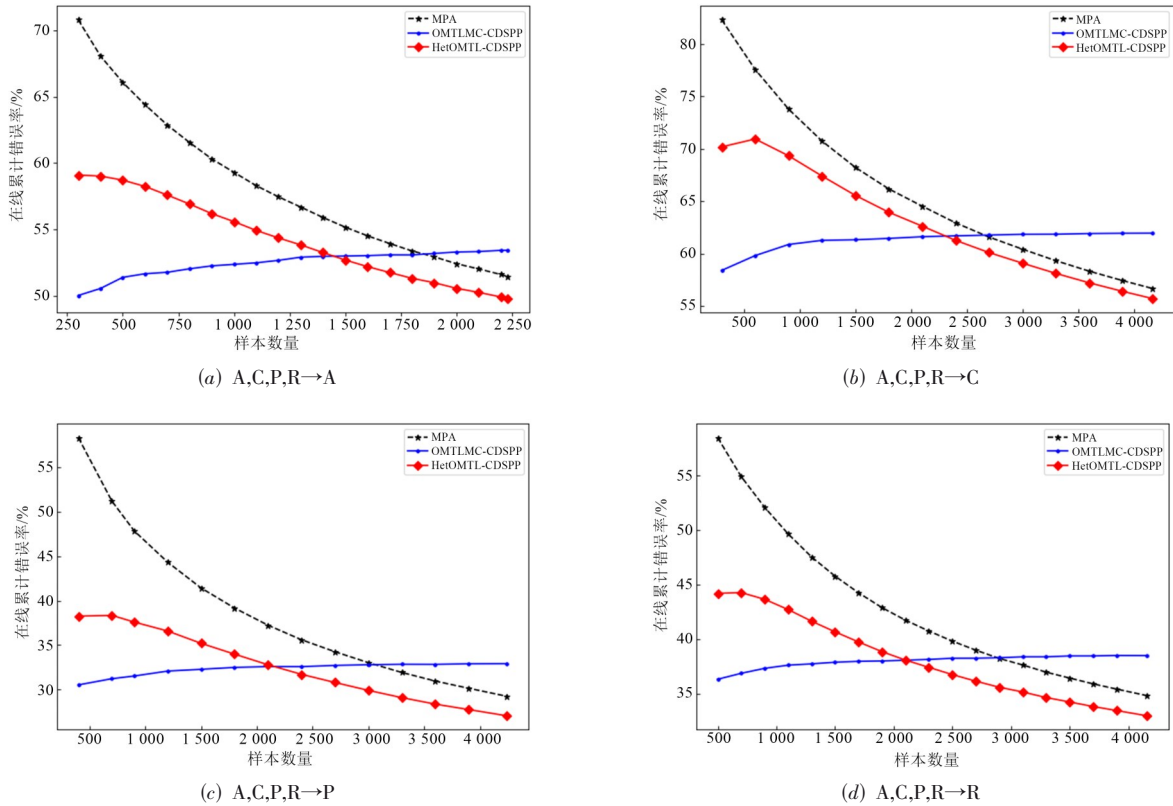


图3 Office-Home 数据集上的平均在线累计错误率

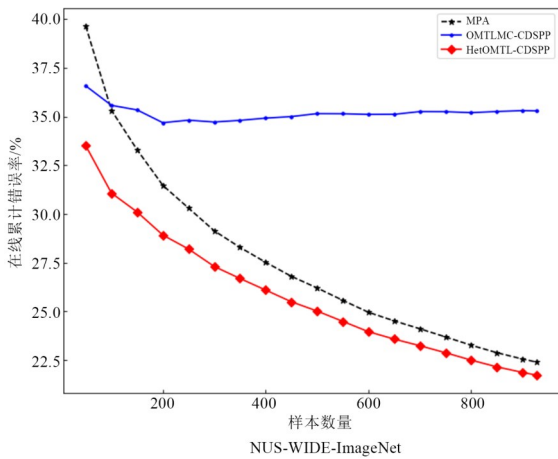


图4 NUS-ImageNet 数据集的平均在线累计错误率

目标域分类器的权重配比,降低了目标域在线数据的分类错误率,且在单个样本的预测时间上,HetOMTL-CDSPP 算法牺牲了少量时间成本以降低目标域在线数据的分类错误率.

3.4 参数敏感度分析

为研究参数对算法性能的影响,本文在3个数据集上进行了不同的实验,分析正则化参数 C 和衰减因子 β_1, β_2 对不同算法的影响.

首先,观察正则化参数 C . 固定衰减因子 $\beta_1 = \frac{\sqrt{T}}{\sqrt{T} + \sqrt{\ln 2}} \approx 0.9754, \beta_2 = \frac{\sqrt{T}}{\sqrt{T} + \sqrt{\ln n}} \approx 0.9656$, 调节正则化参数 C 的值. 观察参数 C 的取值与不同算法在3个数据集上17个异构在线多源迁移学习多分类任务的平均错误率的变化情况.

从图5可以看出:①无论 C 值如何变化,HetOMTL-CDSPP 算法的平均错误率始终低于另外两种算法的平均错误率;②对于同一任务,不同的算法在不同的 C 值上实现了最佳性能,如 MPA 算法的平均错误率在 $C=1$ 时达到最低;③当 $2^{-5} < C < 2^{-1}$ 时, HetOMTL-CDSPP 算法的平均错误率随 C 值的增大而不断降低,且当 $2^{-1} < C < 2^3$ 时, HetOMTL-CDSPP 算法的平均错误率随 C 值的增大而不断升高,可得 HetOMTL-CDSPP 算法的平均错误率的最低点在 $C=2^{-1}$ 时;④HetOMTL-CDSPP 算法的平均错误率总是低于 OMTLMC-CDSPP 算法的平均错误率,则证明本文提出的双层差异导向对冲集成策略能提升在线迁移学习效果;⑤MPA 算法与 HetOMTL-CDSPP 算法的平均错误率的变化趋势虽然比较相似,但 MPA 算法的平均错误率总是高于 HetOMTL-CDSPP 算法的平均错误率,可推测是因为 MPA 算法没有利用源域上学到的知识.




图5 参数 C 对平均错误率的影响

其次,观察衰减因子 β_1 和 β_2 . 选择数据集 Office-Caltech 中具有 800 维 SURF 特征的 4 个子集作为源域, 具有 4 096 维 Decaf6 特征子集 Caltech (测试集样本共有 1 093 个, $T=1 093$) 作为目标域, 组成 1 个异构在线多源迁移学习任务. 先固定正则化参数 $C=1$ 与衰减因子

$$\beta_2 = \frac{\sqrt{T}}{\sqrt{T} + \sqrt{\ln n}} \approx 0.965 6, \text{ 调节衰减因子 } \beta_1 \text{ 的值以}$$

观察参数 β_1 的取值与不同算法在该任务上的错误率的变化情况; 再固定正则化参数 $C=1$ 与衰减因子 $\beta_1 =$

$$\frac{\sqrt{T}}{\sqrt{T} + \sqrt{\ln 2}} \approx 0.975 4, \text{ 调节衰减因子 } \beta_2 \text{ 的值以观察参}$$

数 β_2 的取值与不同算法在该任务上的错误率的变化情况.

从图 6 和图 7 可以看出, 对于同一任务, 参数 β_1 与 β_2 的取值对 MPA 算法没有任何影响; OMTLMC-CDSPP 算法的错误率在 $0 < \beta_1, \beta_2 < 0.9$ 时均无明显变化, 但在 $0.9 < \beta_1, \beta_2 < 1$ 时却呈现急速降低的趋势, 并分别在 $\beta_1 =$




图6 参数 β_1 对错误率的影响

1 和 $\beta_2 = 1$ 时达到最低点; HetOMTL-CDSPP 算法的错误率在 $0 < \beta_1 < 0.9$ 与 $0 \leq \beta_2 \leq 1$ 时均无明显变化, 只在 $0.9 < \beta_1 < 1$ 时才呈现先降低再升高的变化趋势, 且不论 β_1 与 β_2 的取值如何变化, HetOMTL-CDSPP 算法的错误率始终是最低的.




图7 参数 β_2 对错误率的影响

4 总结

现有异构在线迁移方法或因假定源域特征空间是目标域特征空间的子集而忽略了对于目标域特征属性整体的学习, 或因依赖特定的辅助数据而增加了对辅助数据的学习成本. 本文提出了一种基于跨域结构保持投影的异构在线多源迁移学习方法. 该方法通过跨域结构保持投影算法实现了源域与目标域的特征空间对齐, 既不限定源域特征空间是目标域特征空间子集, 也不依赖特定的辅助数据, 实现了多个异构源域到目标域的知识迁移. 此外, 该方法采用一种双层差异导向对冲集成策略, 可合理设置源域离线学习模型与目标域在线学习模型的两层集成形式和在线优化权重配比, 从而持续提高目标域的在线学习性能. 基于公开数据集和与其他同类方法的实验对比分析, 充分验证了本文方法的有效性和优越性.

参考文献

[1] YAN Y, WU Q, TAN M, et al. Online heterogeneous transfer by hedge ensemble of offline and online decisions[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(7): 3252-3263.

[2] ZHAO P L, HOI S C H. OTL: A framework of online transfer learning[C]//Proceedings of the 27th International Conference on International Conference on Machine Learning. New York: ACM, 2010: 1231-1238.

- [3] ZHAO P L, HOI S C H, WANG J L, et al. Online transfer learning[J]. *Artificial Intelligence*, 2014, 216: 76-102.
- [4] WU Q Y, WU H R, ZHOU X M, et al. Online transfer learning with multiple homogeneous or heterogeneous sources[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2017, 29(7): 1494-1507.
- [5] CHEN Q, DU Y T, XU M, et al. HetEOTL: an algorithm for heterogeneous online transfer learning[C]//2018 IEEE 30th International Conference on Tools with Artificial Intelligence (ICTAI). Piscataway: IEEE, 2018: 350-357.
- [6] WU H R, YAN Y G, YE Y Z, et al. Online Heterogeneous Transfer Learning by Knowledge Transaction[J]. *ACM Transaction on Intelligent Systems and Technology*, 2019, 10(3): 26, 1-19.
- [7] LUO Y, LIU T L, WEN Y G, et al. Online heterogeneous transfer metric learning[C]//Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. California: International Joint Conferences on Artificial Intelligence Organization, 2018: 2525-2531.
- [8] WANG Q, BRECKON T P. Cross-domain structure preserving projection for heterogeneous domain adaptation [EB/OL]. (2020-04-26)[2021-07-16]. <https://arxiv.org/abs/2004.12427>.
- [9] CRAMMER K, DEKEL O, KESHET J, et al. Online passive-aggressive algorithms[J]. *Journal of Machine Learning Research*, 2006, 7: 551-585.
- [10] YOAV, FREUND, et al. A decision-theoretic generalization of on-line learning and an application to boosting[J]. *Journal of Computer and System Sciences*, 1997, 55(1): 119-139.
- [12] GONG B Q, SHI Y, SHA F, et al. Geodesic flow kernel for unsupervised domain adaptation[C]//2012 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2012: 2066-2073.
- VENKATESWARA H, EUSEBIO J, CHAKRABORTY S, et al. Deep hashing network for unsupervised domain adaptation[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2017: 5385-5394.
- [13] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2014-09-04) [2021-07-16]. <https://arxiv.org/abs/1409.1556>.
- [14] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 770-778.
- [15] CHUA T S, TANG J H, HONG R C, et al. NUS-WIDE: A real-world web image database from National University of Singapore[C]//Proceedings of the ACM International Conference on Image and Video Retrieval. New York: ACM, 2009: 1-9.
- [16] DENG J, DONG W, SOCHER R, et al. ImageNet: A large-scale hierarchical image database[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2009: 248-255.
- [17] KANG Z, YANG B, YANG S, et al. Online transfer learning with multiple source domains for multi-class classification[J]. *Knowledge-Based Systems*, 2020, 190: 105149.
- [18] WU Q Y, ZHOU X M, YAN Y G, et al. Online transfer learning by leveraging multiple source domains[J]. *Knowledge and Information Systems*, 2017, 52(3): 687-707.
- [19] 季鼎承, 蒋亦樟, 王士同. 基于域与样例平衡的多源迁移学习方法[J]. *电子学报*, 2019, 47(3): 692-699.
- JI D C, JIANG Y Z, WANG S T. Multi-source transfer learning method by balancing both the domains and instances[J]. *Acta Electronica Sinica*, 2019, 47(3): 692-699. (in Chinese)
- [20] 赵鹏, 王美玉, 纪霞, 等. 基于张量表示的域适配的迁移学习中特征表示方法[J]. *电子学报*, 2020, 48(2): 359-368.
- ZHAO P, WANG M Y, JI X, et al. A novel feature representation based on tensor and domain adaption for transfer learning[J]. *Acta Electronica Sinica*, 2020, 48(2): 359-368. (in Chinese)

作者简介



蒋晓玲 女, 1993年生, 重庆人. 现为重庆大学大数据与软件学院在读硕士研究生. 主要研究方向为在线迁移学习.
E-mail: 201924021010@cqu.edu.cn



吴映波(通讯作者) 男, 1978年生, 湖北通城人. 现为重庆大学大数据与软件学院教授. 主要研究方向为分布式智能计算、分布式智能决策与优化.
E-mail: wyb@cqu.edu.cn