

# 基于流形正则化框架和 MMD 的域自适应 BLS 模型

赵慧敏<sup>1</sup> 郑建杰<sup>2</sup> 郭晨<sup>3</sup> 邓武<sup>1</sup>

**摘要** 宽度学习系统 (Broad learning system, BLS) 作为一种基于随机向量函数型网络 (Random vector functional-link network, RVFLN) 的高效增量学习系统, 具有快速自适应模型结构选择能力和高精度的特点. 但针对目标分类任务中有标签数据匮乏问题, 传统的 BLS 难以借助相关领域知识来提升目标域的分类效果, 为此提出一种基于流形正则化框架和最大均值差异 (Maximum mean discrepancy, MMD) 的域自适应 BLS (Domain adaptive BLS, DABLS) 模型, 实现目标域无标签条件下的跨域图像分类. DABLS 模型首先构造 BLS 的特征节点和增强节点, 从源域和目标域数据中有效提取特征; 再利用流形正则化框架构造拉普拉斯矩阵, 以探索目标域数据中的流形特性, 挖掘目标域数据的潜在信息. 然后基于迁移学习方法构建源域数据与目标域数据之间的 MMD 惩罚项, 以匹配源域和目标域之间的投影均值; 将特征节点、增强节点、MMD 惩罚项和拉普拉斯矩阵相结合, 构造目标函数, 并采用岭回归分析法对其求解, 获得输出系数, 从而提高模型的跨域分类性能. 最后在不同图像数据集上进行大量的验证与对比实验, 结果表明 DABLS 在不同图像数据集上均能获得较好的跨域分类性能, 具有较强的泛化能力和较好的稳定性.

**关键词** 宽度学习系统, 流形正则化框架, 最大均值差异, 域自适应, 图像分类

**引用格式** 赵慧敏, 郑建杰, 郭晨, 邓武. 基于流形正则化框架和 MMD 的域自适应 BLS 模型. 自动化学报, 2024, 50(7): 1458–1471

**DOI** 10.16383/j.aas.c210009

## Domain Adaptive BLS Model Based on Manifold Regularization Framework and MMD

ZHAO Hui-Min<sup>1</sup> ZHENG Jian-Jie<sup>2</sup> GUO Chen<sup>3</sup> DENG Wu<sup>1</sup>

**Abstract** As an efficient incremental learning system based on random vector function-link network (RVFLN), broad learning system (BLS) has the characteristics of fast adaptive model structure selection and high precision. However, due to the lack of label data in target classification, the traditional BLS is difficult to improve the classification effect of target domain by using relevant domain knowledge. Therefore, a domain adaptive BLS (DABLS) model based on manifold regularization framework and maximum mean discrepancy (MMD) is developed to achieve cross-domain image classification of target domain under unlabeled condition. Firstly, the feature nodes and enhancement nodes of BLS are constructed to effectively extract features from the data of source domain and target domain. The manifold regularization framework is used to construct Laplacian matrix in order to explore the manifold characteristics of the target domain data and mine the potential information of the target domain data. Then the transfer learning method is used to construct the MMD penalty term between the source domain data and the target domain data to match the projection mean between the source domain and the target domain. The feature nodes, enhancement nodes, MMD penalty term and Laplacian matrix are combined to construct the objective function. Ridge regression analysis is used to solve the objective function to obtain the output coefficients, so as to improve the cross-domain classification performance. Finally, a large number of validation and comparative experiments are carried out on different image data sets, and the experiment results show that the DABLS can better achieve cross-domain classification on different image data sets, and has strong generalization ability and better stability.

**Key words** Broad learning system (BLS), manifold regularization framework, maximum mean discrepancy (MMD), domain adaptation, image classification

**Citation** Zhao Hui-Min, Zheng Jian-Jie, Guo Chen, Deng Wu. Domain adaptive BLS model based on manifold regularization framework and MMD. *Acta Automatica Sinica*, 2024, 50(7): 1458–1471

收稿日期 2021-01-04 录用日期 2021-05-12

Manuscript received January 4, 2021; accepted May 12, 2021

国家自然科学基金 (61771087, 51879027), 中国民航大学科研启动基金 (2020KYQD123) 资助

Supported by National Natural Science Foundation of China (61771087, 51879027) and Research Foundation for Civil Aviation University of China (2020KYQD123)

本文责任编辑 杨健

Recommended by Associate Editor YANG Jian

1. 中国民航大学电子信息与自动化学院 天津 300300 2. 首都师范大学心理学院 北京 100048 3. 大连海事大学船舶电气工程学院 大连 116023

1. College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300 2. School of Psychology, Capital Normal University, Beijing 100048 3. School of Marine Electrical Engineering, Dalian Maritime University, Dalian 116023

神经网络的快速发展为准确、快速处理数据提供了方法. 目前, 神经网络已在图像处理、语音识别、故障诊断等众多领域获得广泛的应用, 尤其是反向传播网络 (Back propagation, BP) 以及深度玻尔兹曼机 (Deep Boltzmann machine, DBM)<sup>[1]</sup>、卷积神经网络 (Convolutional neural network, CNN)<sup>[2]</sup>、深度置信网络 (Deep belief network, DBN)<sup>[3]</sup>、生成对抗网络 (Generative adversarial network, GAN)<sup>[4]</sup>、递归神经网络 (Recursive neural network, RNN)<sup>[5]</sup> 等取得了很好的应用效果.

反向传播神经网络结构较简单, 但存在迭代求解速度较慢且容易陷入局部极小值的问题; 深度神经网络作为多层神经网络, 具有精度高、超参数数量多且结构复杂的特点, 通常训练过程耗时过长. 为解决这一问题, Chen 等<sup>[6]</sup> 提出一种基于随机向量函数型网络 (Random vector functional-link network, RVFLN) 的宽度学习系统 (Broad learning system, BLS), 继承 RVFLN 在线增量学习算法的优点并增加了映射层, 非常适合处理大数据, 并具有通用的逼近能力. 宽度学习首先将原始的输入数据经过一系列的随机映射, 形成特征节点矩阵; 然后在特征节点矩阵的基础上, 经过一系列的随机增强变换, 形成增强节点矩阵. 不同于深度学习, 该方法致力于神经网络的宽度拓展而非深度拓展来解决复杂问题, 不仅克服了深度学习训练过程耗时长长的缺点, 还可快速增量构建网络模型. 因此, 宽度学习已得到学术界和工业界的广泛关注. Chen 等<sup>[7]</sup> 分析证明了宽度学习系统的通用逼近性能. Jin 等<sup>[8]</sup> 提出一种正则化鲁棒宽度学习系统, 实现了不确定数据建模, 提高了面向噪声数据的模型鲁棒性. 杨刚等<sup>[9]</sup> 结合回声状态网络的储备池结构, 提出一种基于池计算的宽度学习系统, 提高了 BLS 的泛化能力和稳定性. 邹伟东等<sup>[10]</sup> 构建基于压缩因子的宽度学习系统, 加快了收敛速度, 提高了泛化性能. Kong 等<sup>[11]</sup> 引入类概率结构, 设计了一种半监督宽度学习系统, 提高了模型的分类精度. 郑云飞等<sup>[12]</sup> 引入  $p$ -范数作为损失函数, 提出一种基于最小  $p$ -范数的宽度学习系统, 增强了在复杂噪声情况下的抗干扰能力. Lin 等<sup>[13]</sup> 提出一种四元数宽度学习系统, 提高了系统的回归能力. 同时, 结构化流行宽度学习系统<sup>[14]</sup>、增量式 Wishart 宽度学习系统<sup>[15]</sup>、模糊宽度学习系统<sup>[16]</sup>、递归广义宽度学习系统<sup>[17]</sup>、加权宽度学习系统<sup>[18]</sup>、增量式贝叶斯框架宽度学习系统<sup>[19]</sup>、多视图宽度学习系统<sup>[20]</sup> 等相继提出, 从不同角度提高了宽度学习系统的泛化性、收敛性和鲁棒性. 此外, Zhao 等<sup>[21]</sup> 提出一种基于流形正则化的半监督宽度学习系统, 扩展了宽度学习在半监督领域的应用.

由于宽度学习系统具有通用逼近能力、良好的泛化性和较强的鲁棒性, 且具有时间记忆性与灵活重构性, BLS 被普遍认为是一种极具前途的深度学习替代方法. 然而, 实际应用中的许多分类问题面临着目标分类中有标签数据匮乏的问题, 传统宽度学习系统难以借助相关领域知识来提升目标域分类效果. 针对这些问题, 本文充分利用基于流形正则化框架的半监督学习方法和基于最大均值差异的迁移学习方法的各自优势, 提出一种新的域自适应宽度学习系统, 旨在实现一种简单、高效的跨域分类模式, 提高模型在快速收敛、良好泛化能力基础上的跨域分类性能, 并通过图像分类来验证域自适应宽度学习模型的有效性.

## 1 基础知识

### 1.1 流形正则化框架

流形正则化框架是一种基于图的半监督学习方法, 能够将大量无标签样本和少量有标签样本共同引入模型训练中, 从而避免模型在有标签样本不足时出现的性能退化问题. 此外, 流形正则化框架还能够探索数据中的流形特性, 进而揭示数据的潜在信息, 提升模型的适应能力, 可表达为如式 (1) 描述的损失函数

$$L_m = \frac{1}{2} \sum_{i=1}^{l+u} \sum_{j=1}^{l+u} w_{ij} \|P(y|x_i) - P(y|x_j)\|^2 \quad (1)$$

式中,  $w_{ij}$  表示样本  $x_i$  和  $x_j$  之间的成对相似性,  $i = 1, \dots, l+u$ ;  $j = 1, \dots, l+u$ ,  $l$  表示有标签样本个数,  $u$  表示无标签样本个数,  $l+u$  表示所有样本个数.

由于很难计算条件概率, 将式 (1) 用式 (2) 来近似表示, 即

$$\hat{L}_m = \frac{1}{2} \sum_{i=1}^{l+u} \sum_{j=1}^{l+u} w_{ij} \|\hat{y}_i - \hat{y}_j\|^2 \quad (2)$$

式中,  $\hat{y}_i$  和  $\hat{y}_j$  分别表示样本  $x_i$  和  $x_j$  的输出.

式 (1) 和式 (2) 中任意两样本之间的成对相似性可用高斯核函数求解:

$$w_{ij} = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right), & x_i \in N_k(x_j) \text{ 或} \\ & x_j \in N_k(x_i) \\ 0, & \text{其他} \end{cases} \quad (3)$$

式中,  $\sigma$  表示高斯核的宽度,  $N_k(x)$  表示  $x$  的  $k$  个近邻集合, 所有样本产生的  $w_{ij}$  可构成邻接矩阵  $W$ , 将邻接矩阵的每列求和, 可得到对角元素, 即

$$D_{ii} = \sum_{j=1}^{l+u} w_{ij} \quad (4)$$

式中, 所有对角元素  $D_{ii}$  可构成度矩阵  $D$ .

拉普拉斯矩阵  $L$  可用式 (4) 产生的度矩阵  $D$  获得, 即

$$L = D - W \quad (5)$$

此外, 还可以通过  $D^{-\frac{1}{2}}(D - W)D^{-\frac{1}{2}}$  对  $L$  进行标准化.

利用式 (3) ~ (5) 对式 (2) 以矩阵形式进行简化, 得到流行正则化框架的表达形式, 即

$$\hat{L}_m = \text{tr}(\hat{Y}^T L \hat{Y}) \quad (6)$$

式中,  $\text{tr}(\cdot)$  表示矩阵的迹,  $\hat{Y}$  表示样本的输出.

## 1.2 最大均值差异

迁移学习能够在训练数据和测试数据特征分布不同时, 将源域中学习到的知识迁移到目标域. 领域自适应是迁移学习方法的重要分支, 其目标是充分利用有标签的源域数据和无标签的目标域数据构建目标域的分类模型. 而构建跨域分类模型的关键在于找到一种良好的度量手段来度量源域与目标域之间的距离并使之最小. 本文采用迁移学习中的度量手段——最大均值差异 (Maximum mean discrepancy, MMD) 来度量源域和目标域的距离, MMD 可表示为

$$MMD^2(\mathcal{F}, p, q) = \sup_{f \in \mathcal{F}} \|\mathbb{E}_{x \sim p}[f(x)] - \mathbb{E}_{z \sim q}[f(z)]\|^2 \quad (7)$$

式中,  $\mathbb{E}_{x \sim p}[f(x)]$  表示在概率分布  $p$  下, 函数  $f(\cdot)$  对数据集  $x$  的期望值,  $\mathbb{E}_{z \sim q}[f(z)]$  表示在概率分布  $q$  下, 函数  $f(\cdot)$  对数据集  $z$  的期望值,  $\mathcal{F}$  表示给定的函数集. 当且仅当  $MMD^2(\mathcal{F}, p, q) = 0$  时,  $p$  和  $q$  表示相同的分布. 因此,  $MMD^2(\mathcal{F}, p, q)$  的值越趋近于 0,  $p$  和  $q$  的相似程度越高.

为解决域自适应问题, 现有大部分方法都将数据变换到再生核希尔伯特空间后计算两数据源分布之间的相似程度. 上述计算 MMD 的方式, 并不能作为惩罚项融入 BLS 架构中, 但 MMD 可以在给定的投影矢量下进行投影, 从而作为惩罚项, 其计算式为

$$MMD^2[D_S, D_T] = \left\| \frac{1}{s} \sum_{i=1}^s f(x_i) - \frac{1}{t} \sum_{j=1}^t f(x_j) \right\|^2 \quad (8)$$

式中,  $D_S$  表示源域数据集,  $D_T$  表示目标域数据集,  $s$  和  $t$  分别表示源域数据集和目标域数据集的样本个数,  $f(\cdot)$  表示映射函数.

## 1.3 宽度学习系统

BLS 是一种不需要深度结构的高效增量学习系统, 能够为解决分类问题提供一种有效的方法. 在该方法中, 原始数据通过随机权重变换为映射特征, 并储存在特征节点中; 然后特征节点通过非线性函数变换为增强节点; 最后利用岭回归优化最小二乘问题, 以获得最终的输出系数. BLS 的具体训练过程如下:

对输入数据  $X$ , 利用线性变换函数映射产生第  $i$  组映射特征  $Z_i$ , 即

$$Z_i = \phi_i(XW_{ei} + \beta_{ei}), \quad i = 1, \dots, n \quad (9)$$

式中,  $W_{ei}$  和  $\beta_{ei}$  是具有适当维度的随机权重和偏置,  $n$  为特征节点的组数, 每组特征节点的个数为  $k$ ,  $\phi(\cdot)$  表示线性变换.

将所有特征节点组合并记作  $Z^n$ , 即

$$Z^n = [Z_1, \dots, Z_n] \quad (10)$$

式中,  $Z^n \in \mathbf{R}^{N \times nk}$ ,  $N$  为样本的个数,  $nk$  为所有特征节点的个数.

利用式 (10) 产生的所有特征节点组  $Z^n$  经过非线性函数变换产生增强节点  $H_j$ , 即

$$H_j = \xi_j(Z^n W_{h_j} + \beta_{h_j}) \quad (11)$$

式中,  $W_{h_j}$  和  $\beta_{h_j}$  是具有适当维度的随机权重和偏置,  $j = 1, \dots, m$ ,  $m$  为增强节点的总数,  $\xi(\cdot)$  表示进行非线性函数变换.

将所有的增强节点记作  $H^m$ , 即

$$H^m = [H_1, \dots, H_m] \quad (12)$$

式中,  $H^m \in \mathbf{R}^{N \times m}$ .

将式 (10) 和式 (12) 产生的特征节点和增强节点合并, 得到  $A$ , 即

$$A = [Z^n | H^m] \quad (13)$$

式中,  $A \in \mathbf{R}^{N \times nk+m}$  是大小为  $N \times nk + m$  的矩阵.

BLS 旨在通过最小化预测误差的平方损失之和来求解输出权重, 即

$$\arg \min_{\beta} \theta \|\beta\|^2 + \|A\beta - Y\|^2 \quad (14)$$

式中,  $Y$  为数据  $X$  对应的标签,  $\beta$  为输出系数,  $\theta$  为正则化参数, 用来平衡误差和模型复杂度.

通过将式 (14) 中相对于  $\beta$  的梯度置为 0, 可得

$$\beta = ((A^T A) + \theta I)^{-1} A^T Y \quad (15)$$

式中,  $I$  为单位矩阵. 如果  $\theta = 0$ ,  $\beta$  的求解就会变成最小二乘问题; 如果  $\theta \rightarrow \infty$ ,  $\beta$  的值就会受到限制并且接近于 0. 因此, 通常设置  $\theta \rightarrow 0$ .

BLS 的结构如图 1 所示.

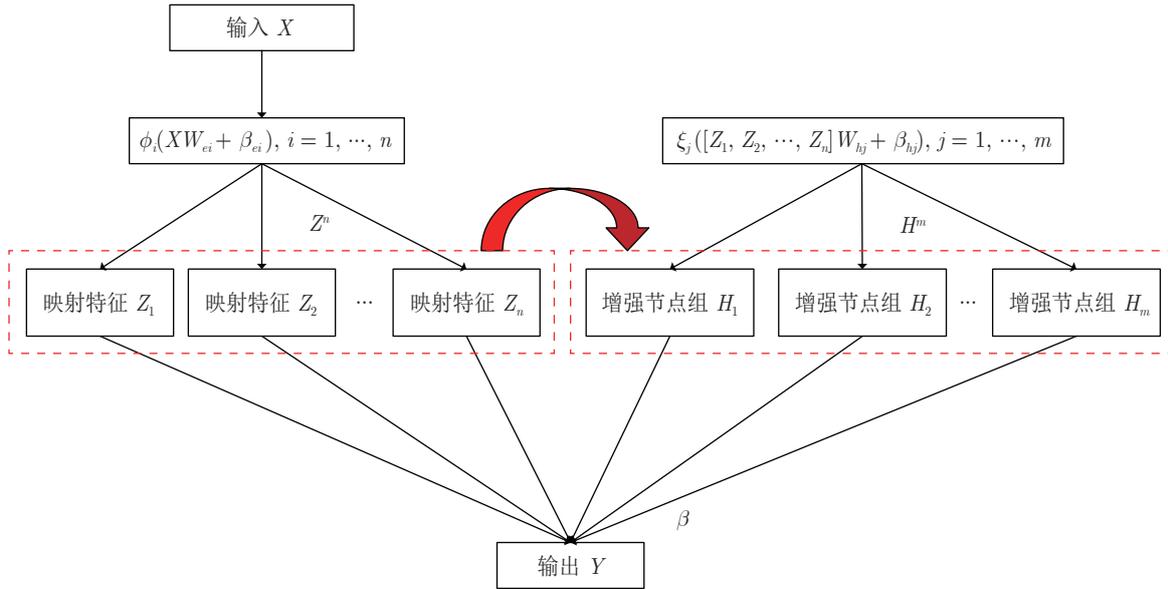


图 1 BLS 的结构示意图

Fig.1 Structure diagram of BLS

## 2 域自适应 BLS 模型的理论推导

本文针对目标分类任务中有标签数据匮乏以及传统 BLS 难以借助相关领域知识来提升目标域分类效果的问题, 基于宽度学习、半监督学习和迁移学习理论, 提出域自适应 BLS 模型. 首先, 通过构造特征节点和增强节点, 从源域和目标域数据中提取特征; 再利用流形正则化框架构造拉普拉斯矩阵, 以探索目标域数据中的流形特性, 揭示目标域数据的潜在信息; 接着对源域数据与目标域数据之间的 MMD 进行投影, 构建惩罚项; 然后结合特征节点、增强节点、MMD 惩罚项和拉普拉斯矩阵, 构建目标函数; 最后通过岭回归求解该目标函数, 获得输出系数. 域自适应 BLS 模型的理论推导过程如下.

在训练过程中, 将数据分为两部分, 有标签源域数据集  $D_S = \{X_s, Y_s\} = \{x_i, y_i\}_{i=1}^s$  和无标签目标域数据集  $D_T = \{X_t\} = \{x_j\}_{j=1}^t$ , 其中  $s$  和  $t$  分别是源域数据和目标域数据的长度.  $X_s, X_t \in X$ ,  $Y_s \in Y$ ,  $X$  表示特征空间,  $Y$  表示标签空间.  $P_s(X_s)$  和  $P_t(X_t)$  分别表示源域数据和目标域数据的边缘概率分布,  $Q_s(Y_s|X_s)$  和  $Q_t(Y_t|X_t)$  分别表示源域数据和目标域数据的条件概率分布. 一般来说, 由于源域和目标域不同, 它们可能具有不同的边缘或条件分布, 即  $P_s(X_s) \neq P_t(X_t)$  或  $Q_s(Y_s|X_s) \neq Q_t(Y_t|X_t)$ .

对于输入数据  $X$ , 采用线性变换函数映射产生第  $i$  组映射特征  $Z_i$ , 即

$$Z_i = \phi_i(XW_{ei} + \beta_{ei}) \quad (16)$$

式中,  $X = \{X_s, X_t\}$  表示所有样本, 其余变量的含义均同式 (9).

将所有特征节点组合并记作  $Z^n$ , 即

$$Z^n = [Z_1, \dots, Z_n] \quad (17)$$

式中,  $Z^n$  为  $(s+t) \times nk$  的矩阵,  $s+t$  为样本个数.

利用式 (17) 产生的所有特征节点组  $Z^n$  经过非线性函数变换产生增强节点  $H_j$ , 即

$$H_j = \xi_j(Z^n W_{hj} + \beta_{hj}) \quad (18)$$

式中,  $W_{hj}$  和  $\beta_{hj}$  是具有适当维度的随机权重和偏置,  $m$  为增强节点总数,  $j = 1, \dots, m$ ,  $\xi(\cdot)$  表示进行非线性函数变换.

将所有的增强节点记作  $H^m$ , 即

$$H^m = [H_1, \dots, H_m] \quad (19)$$

式中,  $H^m$  为  $(s+t) \times m$  的矩阵.

将式 (17) 和式 (19) 产生的特征节点和增强节点进行合并, 得到  $A$ , 即

$$A = [Z^n | H^m] \quad (20)$$

式中,  $A$  为  $(s+t) \times (nk+m)$  的矩阵,  $s+t$  为样本个数,  $nk+m$  为所有节点个数.

将  $A$  重新表达为

$$A = [a^T(x_1), \dots, a^T(x_i), \dots, a^T(x_{s+t})]^T \quad (21)$$

式中,  $a^T(x_i)$  是第  $i$  个样本通过式 (17) 和式 (18) 变换后所得.

式 (21) 可用于生成网络的输出, 即

$$f_i = a(x_i)\beta^* \quad (22)$$

$$F = [f_1^T, \dots, f_i^T, \dots, f_{s+t}^T]^T \quad (23)$$

根据式 (22), 可以得到式 (24), 即

$$e_i^T = a(x_i)\beta^* - y_i^T \quad (24)$$

式中,  $y_i^T$  表示样本的期望输出.

根据式 (22) 和式 (23) 可对式 (8) 进行如下修改:

$$MMD^2[D_S, D_T] = \left\| \frac{1}{s} \sum_{i=1}^s a(x_i)\beta^* - \frac{1}{t} \sum_{j=1}^t a(x_j)\beta^* \right\|^2 \quad (25)$$

式中,  $D_S$  表示源域数据集,  $D_T$  表示目标域数据集,  $s$  和  $t$  分别表示源域数据集和目标域数据集的样本个数,  $i = 1, \dots, s, j = 1, \dots, t$ .

式 (25) 又可改写为

$$MMD^2[D_S, D_T] = \text{tr}(\beta^{*T} A^T V_M A \beta^*) \quad (26)$$

式中,  $A = [A_s^T, A_t^T]^T$  表示源域数据和目标域数据生成的节点,  $V_M$  为  $(s+t) \times (s+t)$  的 MMD 矩阵, 可由式 (27) 计算, 即

$$V_M = \begin{bmatrix} \frac{1}{s^2} \mathbf{1}_{s \times s} & -\frac{1}{s \times t} \mathbf{1}_{s \times t} \\ -\frac{1}{t \times s} \mathbf{1}_{t \times s} & \frac{1}{t^2} \mathbf{1}_{t \times t} \end{bmatrix} \quad (27)$$

式中,  $s$  表示源域数据个数,  $t$  表示目标域数据个数,  $\mathbf{1}_{s \times t}$  表示元素全为 1 且大小为  $s \times t$  的矩阵,  $\mathbf{1}_{t \times s}$  表示元素全为 1 且大小为  $t \times s$  的矩阵.

将流形正则化框架、MMD 融入 BLS 框架中, 构建域自适应宽度学习框架 (Domain adaptive broad learning system, DABLS), 其目标函数可描述为

$$\begin{aligned} \min_{\beta \in \mathbf{R}^{n_h \times n_o}} & \frac{\theta}{2} \|\beta^*\|^2 + \frac{C}{2} \sum_{i=1}^s \|e_i\|^2 + \\ & \frac{\gamma}{2} \text{tr}(F_t^T L_t F_t) + \frac{\lambda}{2} \text{tr}(\beta^{*T} A^T V_M A \beta^*) \\ \text{s.t.} & \begin{cases} e_i^T = a(x_i)\beta^* - y_i^T, & i = 1, \dots, s \\ f_i = a(x_i)\beta^*, & i = 1, \dots, s+t \end{cases} \end{aligned} \quad (28)$$

式中,  $n_h$  为增强节点和特征节点数的总和,  $\theta$  表示正则化参数,  $C$ 、 $\lambda$  和  $\gamma$  表示惩罚因子,  $L_t$  是由目标域数据产生的拉普拉斯矩阵,  $F_t$  由式 (23) 获得.

根据式 (21) ~ (24), 式 (28) 可以转换为如下的目标函数:

$$\begin{aligned} \min_{\beta \in \mathbf{R}^{n_h \times n_o}} & \frac{\theta}{2} \|\beta^*\|^2 + \frac{1}{2} \sum_{i=1}^{s+t} \|C^{*\frac{1}{2}}(A\beta^* - \tilde{Y})\|^2 + \\ & \frac{\gamma}{2} \text{tr}(\beta^{*T} A^T L A \beta^*) + \frac{\lambda}{2} \text{tr}(\beta^{*T} A^T V_M A \beta^*) \end{aligned} \quad (29)$$

式中,  $C^*$  是  $(s+t) \times (s+t)$  的对角矩阵, 其前  $s$  个对角元素为  $C$ , 其余对角元素为 0,  $\tilde{Y}$  为  $(s+t) \times n_o$  的矩阵, 是训练的目标, 它的前  $s$  行等于  $Y_s$ , 其余为 0,  $L = \begin{bmatrix} \mathbf{0}_{s \times s} & \mathbf{0}_{s \times t} \\ \mathbf{0}_{t \times s} & L_t \end{bmatrix}$ ,  $L_t$  表示由目标域数据构成的拉普拉斯矩阵,  $\mathbf{0}_{t \times s}$  表示元素全为 0 的  $t \times s$  矩阵.

将式 (29) 中关于  $\beta^*$  的梯度设置为 0, 即

$$\begin{aligned} L_{\text{DABLS}} &= \theta\beta^* + A^T C^* (A\beta^* - \tilde{Y}) + \\ & \lambda A^T V_M A \beta^* + \gamma A^T L A \beta^* = 0 \end{aligned} \quad (30)$$

通过式 (30) 可求解出 DABLS 的输出系数

$$\beta^* = (\theta I_{n_h} + A^T (C^* + \lambda V_M + \gamma L) A)^{-1} A^T C^* \tilde{Y} \quad (31)$$

式中,  $I_{n_h}$  是维度为  $n_h$  的单位矩阵.

当训练样本数少于节点数时,  $A$  的列数多于行数, 这样通常会导致欠定最小二乘问题. 在这种情况下,  $\beta^*$  可能会有无穷多个解, 传统的 BLS 采用伪逆算法来解决这一问题. 然而, 式 (31) 含有拉普拉斯矩阵和 3 个不同的惩罚参数, 导致伪逆算法不适合求解式 (31).

因此, 将  $\beta^*$  限制为  $A$  的行线性组合, 即

$$\beta^* = A^T \alpha \quad (32)$$

式中,  $\alpha \in \mathbf{R}^{N \times n_o}$ ,  $n_o$  为权重的节点数, 因为  $A$  的列数多于行数, 所以  $AA^T$  可逆.

式 (30) 两边都乘以  $(AA^T)^{-1}A$ , 可以获得 DABLS 的输出系数  $\beta^*$ :

$$\begin{aligned} \beta^* &= A^T \alpha = A^T (\theta I_{s+t} + \\ & (C^* + \lambda V_M + \gamma L) H H^T)^{-1} C^* \tilde{Y} \end{aligned} \quad (33)$$

式 (33) 中,  $I_{s+t}$  是维度为  $s+t$  的单位矩阵.

综上, 当节点数少于训练样本数时, DABLS 的输出系数可用式 (31) 来计算; 当节点数多于训练样本数时, DABLS 的输出系数可用式 (33) 来计算.

### 3 DABLS 模型的算法流程及步骤

本文所提出的 DABLS 模型的算法流程, 如图 2 所示.

DABLS 模型的详细步骤, 描述如下:

**步骤 1.** 获取有标签的源域数据样本和无标签的目标域数据样本;

**步骤 2.** 初始化 DABLS 模型的参数, 包括正则化参数  $\theta$ , 惩罚因子  $C$  和  $\gamma$  等;

**步骤 3.** 对目标域数据集利用流形正则化框架构造拉普拉斯矩阵;

**步骤 4.** 采用映射函数对源域数据与目标域数据之间的 MMD 进行投影, 构建惩罚项;

步骤 5. 利用源域数据集和目标域数据集构建特征节点和增强节点;

步骤 6. 通过特征节点、增强节点、拉普拉斯矩阵、MMD 惩罚项和 BLS 框架构建 DABLS 的目标函数;

步骤 7. 求解 DABLS 的目标函数, 获得 DABLS 的输出系数  $\beta^*$ : 若节点数少于样本个数, 则利用式 (31) 计算输出系数; 若节点数多于样本个数, 则利用式 (33) 计算输出系数;

步骤 8. 获取有标签的目标域测试样本;

步骤 9. 将测试样本输入 DABLS 模型进行测试, 输出分类结果.

### 4 DABLS 模型在图像分类中的应用

针对图像分类中获取人工标注训练样本困难的问题, 本文将 DABLS 应用于跨域图像分类, 建立基于 DABLS 的跨域图像分类模型, 有效实现目标域无标签状态下的图像分类, 提升跨域图像分类的精度及效率.

#### 4.1 实验数据与环境

##### 4.1.1 数据集

本文采用 USPS、MNIST、COIL20、Office、Caltech256、ImageNet 和 VOC2007 公共数据集来验证 DABLS 模型的性能. USPS 和 MNIST 是两个不同的灰度手写数字数据集, 具有 10 个数字类

别. 本文从 USPS 和 MNIST 数据集中分别抽取 1800 和 2000 幅图像数据, 并通过编码灰度像素值的方式将所有图像均匀地缩放至  $16 \times 16$  像素. 因此两种不同的数据可具有相同的特征空间. COIL20 是一个由 20 个灰度对象组成的数据库, 其中包含 1440 幅图像. 当物体在转盘上盘旋时, 每个物体的图像被分开  $5^\circ$ , 每个物体有 72 幅图像. 每幅图像的大小为  $32 \times 32$  像素. 实验中将其划分为 CO1 和 CO2 两个子集, CO1 包含在  $[0^\circ \cup 85^\circ] \cup [180^\circ \cup 265^\circ]$  (象限 1 和象限 3) 方向拍摄的 720 幅图像, CO2 包含在  $[90^\circ \cup 175^\circ] \cup [270^\circ \cup 355^\circ]$  (象限 2 和象限 4) 方向拍摄的 720 幅图像. Office 是一个标准的视觉领域基准数据集, 包含 Amazon (从网上商家下载的图像)、Webcam (通过网络摄像机拍摄的低分辨率图像) 和 DSLR (Digital single lens reflex) (通过数字单反相机拍摄的高分辨率图像) 三个真实世界的对象域. Caltech256 是一个标准的对象识别数据集. 分别从 Office 和 Caltech256 数据集中提取 1410 幅和 1123 幅图像, 在 Office 中, A 子集含有 958 幅图像, W 子集含有 295 幅图像, D 子集含有 157 幅图像, 每幅图像被提取 SURF 特征并量化成 800 维的向量, 因此两种不同的数据可以具有相同的特征空间. ImageNet 和 VOC2007 是大型标准图像数据集, 每个数据集都可视为一个域, 来自同一类而不同域的图像遵循不同的数据分布. 实验中提取这两个数据集的子数据集来构造跨域分类任务, 每个子

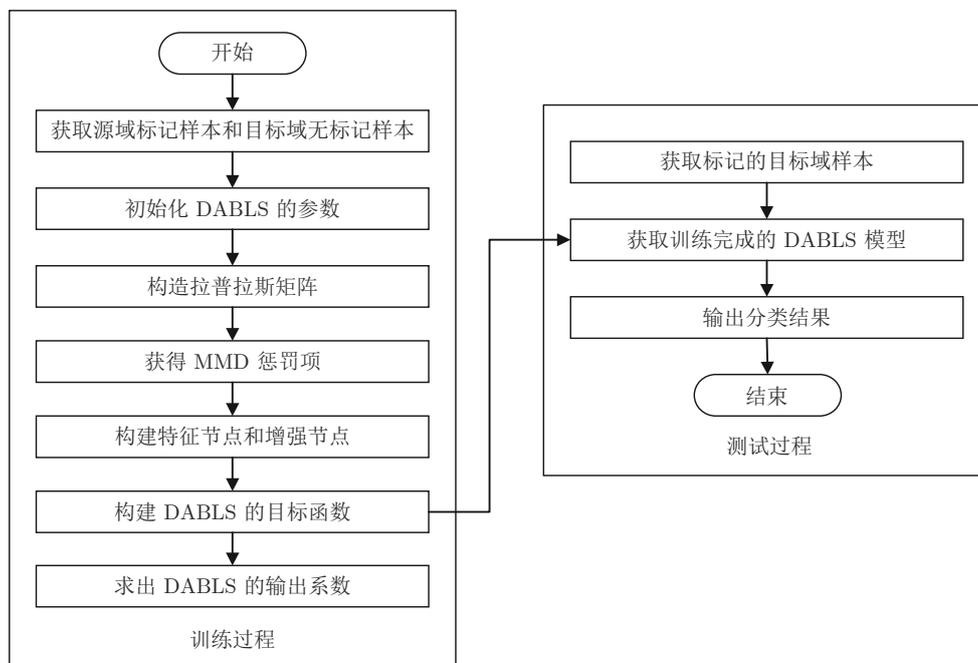


图 2 DABLS 模型的算法流程  
Fig.2 Algorithm flow of DABLS model

数据集分别包含鸟、猫、狗、人以及摩托车, 共 5 个类别。

7 种图像数据集样本分别如图 3 和图 4 所示, 7 种数据集的详细情况如表 1 所示。

#### 4.1.2 比较方法的选择

本文将 BLS、SS-BLS、TCA (Transfer component analysis)、CDELM (Cross-domain extreme learning machine) 和 CD-CDBN (Cross-domain convolutional deep belief network) 与 DABLS 进行实验对比, 以验证 DABLS 的有效性。

1) BLS<sup>[6]</sup>: 采用源域数据测试训练 BLS 模型, 目标域样本数据训练完成的 BLS 模型。BLS 的正则化参数  $\theta$  选取经验值。

2) SS-BLS<sup>[21]</sup>: 采用有标签源域数据 and 无标签目标域数据共同训练 SS-BLS 模型, 再利用目标域样本测试训练完成的 SS-BLS 模型。SS-BLS 的参数  $\lambda$ 、 $C_0$  和  $\theta$  都是从  $[10^{-6}, 10^{-5}, \dots, 10^2, 10^3]$  中选取。

3) TCA<sup>[22]</sup>: 迁移成分分析是一种基于数据分布自适应的迁移学习方法, 旨在最小化源域和目标域

边缘概率分布的距离, 从而完成迁移学习。TCA 的惩罚因子选取经验值, 子空间维数从  $[100, 200, 300, \dots, 800]$  中选取。

4) CDELM<sup>[23]</sup>: 跨域极限学习机是基于流形正则化框架、极限学习机和 MMD 惩罚项的跨域分类模型。采用有标签源域数据和无标签目标域数据共同训练 CDELM, 再利用目标域测试样本测试 CDELM 模型。CDELM 的三个参数  $\lambda$ 、 $\gamma$  和  $C$  都是从  $[10^{-6}, 10^{-5}, \dots, 10^2, 10^3]$  中选取的。

5) CD-CDBN: 卷积置信深度网络是一种常见的深度学习方法<sup>[24]</sup>, 本文结合特征域自适应思想构建 CD-CDBN 模型进行对比实验。先通过特征映射函数最小化 MMD 函数, 缩小源域与目标域数据之间的分布差异, 接着采用处理后的源域数据训练 CD-CDBN, 最后采用处理后的目标域数据测试 CD-CDBN 模型。相关参数如学习率、稀疏化等参数分别从  $[10^{-5}, 10^{-4}, \dots, 10^4, 10^5]$  中选取。

6) DABLS: 实验采用有标签源域数据和无标签目标域数据共同训练 DABLS, 再利用目标域测

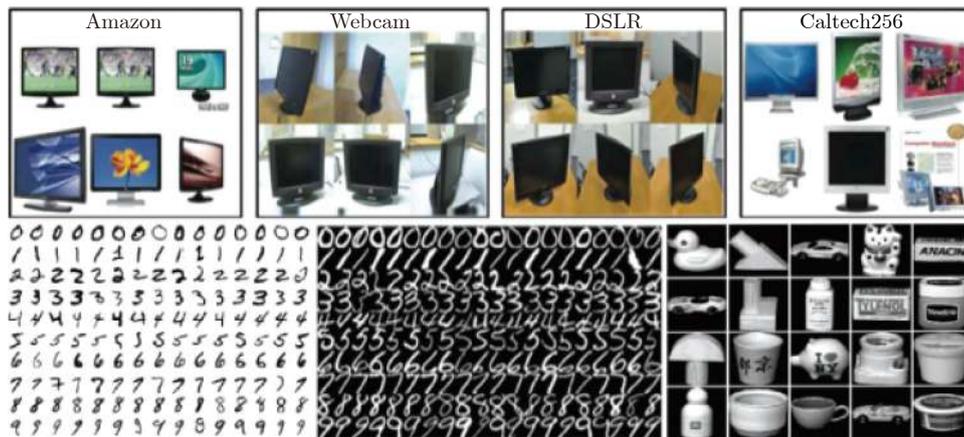


图 3 5 种图像数据集样本 (第 1 行显示 Office 和 Caltech256 数据集, 第 2 行显示 MNIST, USPS 和 COIL20 数据集 (从左到右))

Fig.3 Samples from five image datasets (The first row shows Office and Caltech256 datasets, and the second row shows MNIST, USPS and COIL20 datasets (from left to right))



图 4 ImageNet 和 VOC2007 数据集样本  
Fig.4 Samples from display ImageNet and VOC2007 datasets

表 1 数据集的详细描述

Table 1 Detailed description of datasets

数据集	样本数目	特征维数	类别	子集
USPS	1800	256	10	U
MNIST	2000	256	10	M
COIL20	1440	1024	20	CO1, CO2
Office	1410	800	10	A, W, D
Caltech256	1123	800	10	C
ImageNet	7341	4096	5	I
VOC2007	3376	4096	5	V

试样本测试 DABLS 模型. DABLS 的四个参数都从  $[10^{-6}, 10^{-5}, \dots, 10^2, 10^3]$  中选取.

#### 4.1.3 实验环境

所有实验都是基于 MATLAB 2018b 软件平台, 设备配置为 Intel-i5、2.4 GHz CPU 和 8 GB 内存, 每种方法都独立运行 10 次并对结果取平均值进行比较分析.

### 4.2 MNIST 和 USPS 实验结果与比较

针对经典的 MNIST 和 USPS 数据集, 根据经验: BLS 的正则化参数设为  $2^{-30}$ , 节点数为 10-10-2000; SS-BLS 的正则化参数设为  $10^{-4}$ ,  $10^0$  和  $10^{-4}$ , 节点数为 10-10-2 000; CDELM 的正则化参数设为  $10^{-2}$  和  $10^{-3}$ , 惩罚因子为  $10^{-2}$ , 节点数为 3 000; TCA 的惩罚因子设为 0.1, 子空间维数为 100; CD-CDBN 的学习率为  $10^{-3}$ , 稀疏化参数为  $10^{-2}$ , 迭代次数为  $10^1$ ; DABLS 的正则化参数设为  $10^{-5}$ , 惩罚因子为  $10^{-1}$ ,  $10^0$  和  $10^0$ .

不同节点数下 DABLS 模型在数据集 MNIST 和 USPS 之间的跨域分类结果, 如表 2 所示.

由表 2 可知, 在迁移任务  $M \rightarrow U$  中, 若要求 DABLS 保持一定的分类精度和训练时间, 则选择 100 个特征节点和 2 000 个增强节点; 若要求 DABLS 的分类精度最高且不考虑训练时间, 则选择 100 个特征节点和 3 500 个增强节点. 随着增强节点数的增加, DABLS 的分类精度会呈现出先增加后降低的现象. 在迁移任务  $U \rightarrow M$  中, 若分类精度要求高, 则选择 100 个特征节点和 3 000 个增强节点; 若要求 DABLS 的训练时间较短, 则选择 100 个特

征节点和 500 个增强节点. 结果表明, 特征节点和增强节点都会影响 DABLS 的训练时间、分类精度和模型稳定性. 增强节点对训练时间、分类精度和模型稳定性的影响大于特征节点. 在实验中, 综合两种迁移任务中增强节点和特征节点对分类结果的影响, 将 DABLS 的结构设为 100 个特征节点和 2 000 个增强节点, 即 10-10-2000.

在相同数据集下比较 DABLS 与 BLS、SS-BLS、TCA、CDELM 和 CD-CDBN 的性能. 选取平均分类精度和平均训练时间两个指标进行比较, 比较结果如表 3 和表 4 所示.

从表 3 和表 4 可知, 在迁移任务  $M \rightarrow U$  中, BLS、SS-BLS、TCA、CDELM、CD-CDBN 和 DABLS 的分类精度分别为 25.34%、59.67%、54.28%、53.27%、50.27% 和 68.54%. 在迁移任务  $U \rightarrow M$  中, DABLS 的分类精度为 50.13%, 略低于 TCA, 但要优于 BLS、SS-BLS、CDELM 和 CD-CDBN. 实验结果表明, DABLS 能够有效缩小源域数据和目标域数据之间的差异, 建立一个分类精度较高的跨域分类模型. DABLS 的平均分类精度为 59.33%, 这要优于 BLS、SS-BLS、TCA 和 CDELM. CD-CDBN 的平均训练时间最长, 达到 542.71 s, 这要远高于其他方法. DABLS 的平均训练时间为 23.13 s, 这要快于 TCA 和 CDELM. 因此, DABLS 对 MNIST 和 USPS 组成的迁移任务具有较好的分类精度和较高的效率.

### 4.3 COIL20 实验结果与比较

COIL20 数据集分为两个子集合 CO1 和 CO2.

表 2 不同节点数下 DABLS 的实验结果

Table 2 Experimental results of DABLS with different numbers of nodes

特征节点	增强节点	M→U			U→M		
		精度 (%)	时间 (s)	标准差	精度 (%)	时间 (s)	标准差
100	500	60.41	19.01	1.25	45.25	20.50	1.84
100	1000	63.94	19.59	1.61	47.57	22.46	2.14
100	1500	66.98	21.56	1.49	48.05	26.16	2.27
100	2000	68.54	23.98	1.67	50.13	27.27	1.53
100	2500	68.77	27.15	1.72	50.25	29.27	1.64
100	3000	69.22	33.12	1.81	50.37	32.83	1.78
100	3500	69.31	37.26	1.89	49.91	36.25	1.92
100	4000	68.95	40.96	1.75	49.63	41.17	1.82
150	2000	68.36	25.03	1.87	49.49	27.92	1.72
200	2000	67.53	25.91	2.01	50.08	28.72	1.79
300	2000	66.57	26.41	2.03	49.92	29.62	1.87
400	2000	64.35	26.97	3.37	48.59	30.58	1.95
500	2000	62.96	27.49	4.61	49.38	31.41	1.64

表 3 从源域到目标域的平均分类精度 (%)  
Table 3 Average classification accuracy from source domain to target domain (%)

任务	BLS	SS-BLS	TCA	CDELM	CD-CDBN	DABLS
M→U	25.34	59.67	54.28	53.27	50.27	68.54
U→M	20.25	29.84	52.00	39.80	41.65	50.13
平均值	22.79	44.75	53.14	46.53	45.96	59.33

表 4 从源域到目标域的平均训练时间 (s)  
Table 4 Average training time from source domain to target domain (s)

任务/方法	BLS	SS-BLS	TCA	CDELM	CD-CDBN	DABLS
M→U	0.69	12.75	27.14	24.77	548.47	23.98
U→M	0.58	13.18	22.36	23.63	536.95	22.27
平均值	0.64	12.97	24.75	24.20	542.71	23.13

根据经验: BLS 的正则化参数设为  $2^{-30}$ , 节点数为 10-10-3 000; SS-BLS 的正则化参数分别为  $10^4$ ,  $10^{-5}$  和  $10^{-4}$ , 节点数为 10-10-3 000; CDELM 的正则化参数为  $10^{-1}$  和  $10^{-5}$ , 惩罚因子为  $10^2$ , 节点数为 3 500; TCA 的惩罚因子为 0.1, 子空间维数为 100; CD-CDBN 的学习率为 0.01, 稀疏化参数为 0.01, 迭代次数为 10; DABLS 的正则化参数为  $10^{-5}$ , 惩罚因子为  $10^{-4}$ ,  $10^3$  和  $10^3$ .

不同节点数下 DABLS 模型在数据子集 CO1 和 CO2 之间的迁移分类结果, 如表 5 所示.

从表 5 中可知, 在迁移任务 CO1→CO2 中, 若对分类精度要求高, 则选择 100 个特征节点和 3 500 个增强节点. 若要求训练时间最短, 则选择 100 个特征节点和 500 个增强节点. 在迁移任务 CO2→CO1 中, 若要求模型最稳定, 则选择 100 个特征节点和

4 000 个增强节点. 若对分类精度、训练时间和模型稳定性都有一定要求, 则选择 100 个特征节点和 3 000 个增强节点. 在 CO1→CO2 和 CO2→CO1 的迁移任务中, 无论增加特征节点或增强节点都会导致模型训练时间的增加. 此外, 增强节点数目对 DABLS 模型分类精度影响大于特征节点. 综合上述分析, 实验将 DABLS 的结构设为 100 个特征节点和 3 000 个增强节点, 即 10-10-3 000.

在相同数据集下比较 DABLS 与 BLS、SS-BLS、TCA、CDELM 和 CD-CDBN 的性能. 选取平均分类精度和平均训练时间两个指标进行比较, 比较结果如表 6 和表 7 所示.

从表 6 和表 7 中可知, 在 CO1→CO2 的迁移任务中, CDELM 的分类精度最低, 为 81.66%, TCA 的分类精度为 88.61%, 这要高于其他分类模

表 5 不同节点数下 DABLS 的实验结果  
Table 5 Experimental results of DABLS with different numbers of nodes

特征节点	增强节点	CO1→CO2			CO2→CO1		
		精度 (%)	时间 (s)	标准差	精度 (%)	时间 (s)	标准差
100	500	85.43	2.59	1.82	82.70	2.83	1.61
100	1000	86.40	3.17	1.80	83.29	3.35	1.71
100	1500	86.83	3.65	1.32	83.83	3.76	1.52
100	2000	87.33	4.50	1.27	84.04	4.02	1.46
100	2500	87.69	4.93	1.30	84.41	4.85	1.32
100	3000	88.18	5.85	1.12	84.72	5.02	1.28
100	3500	88.26	6.54	1.13	84.16	5.81	1.21
100	4000	87.55	7.61	1.17	83.76	6.10	1.06
150	3000	87.55	6.02	1.15	83.61	6.21	1.21
200	3000	87.09	6.15	1.16	82.95	6.38	1.63
300	3000	85.92	6.64	1.15	81.52	6.62	1.18
400	3000	84.08	7.24	1.20	80.48	6.79	1.20
500	3000	82.29	7.42	1.02	79.51	7.04	1.11

表 6 从源域到目标域的平均分类精度 (%)  
Table 6 Average classification accuracy from source domain to target domain (%)

任务/方法	BLS	SS-BLS	TCA	CDELM	CD-CDBN	DABLS
CO1→CO2	82.25	83.75	88.61	81.66	84.67	88.12
CO2→CO1	80.63	81.17	86.33	80.19	80.74	84.72
平均值	81.44	82.46	87.47	80.93	82.70	86.42

表 7 从源域到目标域的平均训练时间 (s)  
Table 7 Average training time from source domain to target domain (s)

任务/方法	BLS	SS-BLS	TCA	CDELM	CD-CDBN	DABLS
CO1→CO2	1.38	3.22	19.98	5.87	125.33	5.35
CO2→CO1	0.85	2.95	14.67	5.48	136.78	5.33
平均值	1.12	3.09	17.32	5.68	131.05	5.34

型. 在 CO2→CO1 的迁移任务中, DABLS 的分类精度为 84.72%, 这要优于 BLS、SS-BLS 和 CDELM. BLS 的训练时间最短, 仅为 0.85 s. CD-CDBN 的训练时间最长, 达到 136.78 s. 从平均分类精度上分析, DABLS 的平均分类精度为 86.42%, 这要优于 BLS、SS-BLS、CDELM 和 CD-CDBN, 略低于 TCA. 从平均分类时间上分析, DABLS 的平均分类时间为 5.34 s, 这要远优于 TCA 的 17.32 s. 因此, DABLS 能够以较好的分类精度、较快的分类效率实现 COIL20 数据集的跨域分类.

#### 4.4 Office 和 Caltech256 实验结果与比较

选择 Office 和 Caltech256 数据集进一步验证 DABLS 的有效性. 根据经验: BLS 的正则化参数设为  $2^{-30}$ , 节点数为 50-10-100; SS-BLS 的正则化参数分别为  $10^{-3}$ ,  $10^{-5}$  和  $10^{-4}$ , 节点数为 50-10-100; CDELM 的正则化参数为  $10^{-2}$  和  $10^{-3}$ , 惩罚因子为  $10^{-2}$ , 节点数为 2000; TCA 的惩罚因子为 0.1, 子空间维数为 100; CD-CDBN 的学习率为  $10^{-2}$ , 稀疏化参数为  $10^{-1}$ , 迭代次数为  $10^1$ ; DABLS 的正则化参数为  $10^{-1}$ , 惩罚因子为  $10^{-5}$ ,  $10^{-1}$  和  $10^0$ , 节点数为 50-10-100.

不同节点数下 DABLS 模型在数据集 Office 和 Caltech256 之间的跨域分类结果, 如表 8 所示.

从表 8 不难发现, 在迁移任务 A→C 和 W→C 中, 当特征节点不变时, 随着增强节点增加, DABLS 的训练时间都会随之增加, 而分类精度会出现先增加后减少的现象. 在迁移任务 A→C 中, 若要求分类精度最高且不考虑训练时间, 则选择 500 个特征节点和 500 个增强节点. 若对训练时间要求高, 则选择 100 个特征节点和 500 个增强节点. 在迁移任务 W→C 中, 若对模型稳定性要求高, 则选择 500 个特征节点和 50 个增强节点. 若对分类精度、训练

时间和模型稳定性都有一定要求, 则选择 500 个特征节点和 500 个增强节点. 综合特征节点和增强节点对实验结果的影响, 本节实验中的 DABLS 选取 500 个特征节点和 500 个增强节点, 即 50-10-500.

在相同数据集下比较 DABLS 与 BLS、SS-BLS、TCA、CDELM 和 CD-CDBN 的性能. 取平均分类精度和平均训练时间两个指标进行比较, 比较结果如表 9 和表 10 所示.

从表 9 和表 10 可知, 从分类精度的角度上分析, SS-BLS 的平均分类精度为 46.69%, 比 BLS 高 11.50%. DABLS 的平均分类精度为 48.52%, 分别比 SS-BLS、CDELM 和 CD-CDBN 高 1.83%, 7.02% 和 13.31%. TCA 在迁移任务 W→D 和 D→W 上的分类效果最好, 分别达到 90.45% 和 87.12%. 在其余的迁移分类任务中, DABLS 都能以最优的分类精度完成跨域分类任务. 从训练时间的角度分析, 相比于其他迁移分类任务, 各模型在 A→C 上分类时间最长, 在 D→W 上分类时间最短. BLS 的平均训练时间最短, 为 0.62 s. CD-CDBN 的平均训练时间最长, 达到 30.08 s, 这比 DABLS 多 25.12 s. 因此, 对于 Office 和 Caltech256 数据集, DABLS 可以获得较好的跨域分类结果.

#### 4.5 ImageNet 和 VOC2007 实验结果与比较

选择 ImageNet 和 VOC2007 图像数据集验证 DABLS 的有效性. 根据经验: BLS 的正则化参数设为  $2^{-30}$ , 节点数为 25-10-600; SS-BLS 的正则化参数设为  $10^{-2}$ ,  $10^{-5}$  和  $10^{-4}$ , 节点数为 25-10-600; CDELM 的正则化参数设为  $10^2$  和  $10^{-3}$ , 惩罚因子为  $10^{-5}$ , 节点数为 1500; TCA 的惩罚因子设为 0.1, 子空间维数为 100; CD-CDBN 的学习率为  $10^{-2}$ , 稀疏化参数为  $10^{-3}$ , 迭代次数为  $10^1$ ; DABLS 的正则化参数设为  $10^{-4}$ , 惩罚因子为  $10^{-3}$ ,  $10^3$  和  $10^1$ .

表 8 不同节点数下 DABLS 的实验结果  
Table 8 Experimental results of DABLS with different numbers of nodes

特征节点	增强节点	A→C			W→C		
		精度 (%)	时间 (s)	标准差	精度 (%)	时间 (s)	标准差
500	50	43.63	8.81	0.75	34.69	6.01	0.35
500	100	43.73	8.86	0.53	35.24	6.24	0.91
500	150	43.82	8.92	0.77	35.53	6.50	0.65
500	200	43.92	9.01	0.62	35.61	6.78	0.71
500	300	43.98	9.18	0.85	35.93	6.93	0.92
500	400	44.02	9.53	0.87	36.27	7.21	0.77
500	500	44.29	9.77	0.44	36.50	7.43	0.70
500	600	43.50	9.98	0.61	36.52	7.72	0.93
500	800	43.36	10.52	0.59	36.21	8.01	0.64
500	1000	43.18	10.90	0.82	36.04	8.39	0.33
100	500	42.01	8.72	0.76	32.39	6.48	0.91
200	500	42.36	9.02	0.83	33.95	6.66	0.99
300	500	42.83	9.30	0.65	34.27	6.87	0.92
400	500	43.59	9.53	0.69	36.11	7.12	0.77
600	500	44.25	10.44	0.78	36.17	7.85	0.82
800	500	43.43	10.75	0.65	35.77	8.03	0.69

表 9 从源域到目标域的平均分类精度 (%)  
Table 9 Average classification accuracy from source domain to target domain (%)

任务/方法	BLS	SS-BLS	TCA	CDELM	CD-CDBN	DABLS
A→C	20.82	42.16	40.78	31.67	35.56	44.29
A→D	17.83	39.40	31.85	32.48	33.79	42.06
A→W	19.61	40.61	37.63	31.47	27.46	42.09
C→A	29.16	49.67	44.89	44.99	38.78	51.68
C→D	24.84	44.20	45.84	35.37	36.94	45.85
C→W	20.46	45.74	36.61	38.92	35.54	47.79
D→A	32.42	35.57	31.52	30.61	28.34	36.73
D→C	30.03	30.19	32.50	28.96	26.79	32.47
D→W	79.98	79.11	87.12	76.95	50.78	80.06
W→A	34.61	37.51	30.69	35.55	30.89	40.01
W→C	31.73	35.29	27.16	32.03	27.26	36.50
W→D	80.81	80.89	90.45	78.99	50.42	82.73
平均值	35.19	46.69	45.38	41.50	35.21	48.52

不同节点数下 DABLS 模型在数据集 ImageNet 和 VOC2007 之间的跨域分类结果, 如表 11 所示。

从表 11 可知, 在迁移任务 V→I 中, 若要求 DABLS 的训练时间最短, 则选择 250 个特征节点和 200 个增强节点. 当增强节点保持不变时, DABLS 的分类精度会随着特征节点的增加而呈现先提升后降低的现象. 在迁移任务 I→V 中, 若对模型稳定性要求高, 则可选择 250 个特征节点和 2500 个增强节点. 若对精度和时间、稳定性方面都有要求, 则

可选择 250 个特征节点和增强节点. 综合两种迁移任务结果, 本节实验中的 DABLS 选取 250 个特征节点和 600 个增强节点, 即 10-25-600.

在相同数据集下比较 DABLS 与 BLS、SS-BLS、TCA、CDELM 和 CD-CDBN 的性能. 取平均分类精度和平均训练时间两个指标进行比较, 比较结果如表 12 和表 13 所示.

从表 12 和表 13 可知, 在迁移任务 V→I 中, DABLS 分类精度最高, 达到 77.87%. BLS、SS-

表 10 从源域到目标域的平均训练时间 (s)  
Table 10 Average training time from source domain to target domain (s)

任务/方法	BLS	SS-BLS	TCA	CDELM	CD-CDBN	DABLS
A→C	0.78	5.39	36.69	6.83	46.36	9.77
A→D	0.67	0.83	11.73	1.29	33.28	2.76
A→W	0.64	0.99	13.65	1.52	34.23	2.91
C→A	0.68	3.86	35.71	5.74	41.44	8.18
C→D	0.71	0.93	15.05	1.58	35.86	3.71
C→W	0.67	1.09	16.75	1.59	38.37	3.63
D→A	0.59	3.58	11.82	4.14	20.12	5.50
D→C	0.54	5.19	16.21	6.14	26.63	7.45
D→W	0.55	0.79	3.53	0.73	20.48	1.17
W→A	0.58	3.43	14.29	4.33	45.53	5.93
W→C	0.57	5.17	19.05	6.12	56.28	7.43
W→D	0.52	0.69	3.22	0.66	12.40	1.02
平均值	0.62	2.66	16.48	3.39	30.08	4.96

表 11 不同节点数下 DABLS 的实验结果  
Table 11 Experimental results of DABLS with different numbers of nodes

特征节点	增强节点	V→I			I→V		
		精度 (%)	时间 (s)	标准差	精度 (%)	时间 (s)	标准差
100	600	74.13	35.25	1.05	66.61	16.62	1.31
150	600	75.94	37.99	0.75	66.83	19.24	0.77
200	600	76.53	42.29	0.59	67.51	22.42	0.62
250	600	77.87	44.51	0.33	67.83	26.03	0.41
300	600	77.65	47.64	0.29	67.81	28.96	0.43
400	600	76.87	53.89	0.36	67.24	31.62	0.45
500	600	75.67	57.13	0.19	67.02	35.37	0.39
600	600	75.20	61.29	0.27	66.86	38.69	0.37
250	200	74.29	26.56	0.73	66.32	14.73	0.87
250	400	77.21	31.59	0.67	67.13	17.33	0.54
250	800	77.23	46.21	0.56	67.69	24.09	0.42
250	1000	76.83	52.68	0.65	67.52	27.55	0.34
250	1500	74.93	65.71	0.46	67.42	36.43	0.31
250	2000	73.86	83.61	0.36	67.33	43.53	0.33
250	2500	71.77	103.38	0.31	66.73	50.92	0.26

BLS、TCA、CDELM、CD-CDBN 和 DABLS 的训练时间分别为 6.37 s、37.69 s、52.15 s、55.04 s、1 039.03 s 和 44.51 s。在迁移任务 I→V 中, BLS、SS-BLS、TCA、CDELM、CD-CDBN 和 DABLS 的分类精度分别为 66.32%、67.13%、64.34%、66.85%、67.19% 和 67.83%。CD-CDBN 的训练时间为 823.35 s, 要远高于其他几种方法。从平均分类精度上分析, DABLS 的精度为 72.85%, 这要优于 BLS、SS-BLS、TCA、CDELM 和 CD-CDBN。DABLS 的训练时间为 35.27 s, 要快于 TCA、CDE-

LM 和 CD-CDBN。因此, DABLS 对于 ImageNet 和 VOC2007 数据集组成的迁移任务具有较好的分类效果与较高的效率。

#### 4.6 实验结果分析

从 MNIST、USPS、COIL20、Office、Caltech256、ImageNet 和 VOC2007 数据集的实验结果可知, 增加特征节点或增强节点都会影响 DABLS 分类精度、训练时间和模型稳定性。因此, 在实际应用中, 可根据具体需求灵活地选取特征节点和增强节点数目, 以达

表 12 从源域到目标域的平均分类精度 (%)

Table 12 Average classification accuracy from source domain to target domain (%)

任务/方法	BLS	SS-BLS	TCA	CDELM	CD-CDBN	DABLS
V→I	76.22	77.03	73.79	76.82	76.02	77.87
I→V	66.32	67.13	64.34	66.85	67.19	67.83
平均值	71.27	72.08	69.06	71.83	71.60	72.85

表 13 从源域到目标域的平均训练时间 (s)

Table 13 Average training time from source domain to target domain (s)

任务/方法	BLS	SS-BLS	TCA	CDELM	CD-CDBN	DABLS
V→I	6.37	37.69	52.15	55.04	1039.03	44.51
I→V	3.62	17.32	30.42	33.39	823.35	26.03
平均值	4.96	27.50	41.28	44.25	931.19	35.27

到理想的跨域分类效果. 无论由上述哪种数据组成的迁移环境下, DABLS 都能够获得较好的分类效果和较高的效率, 这说明 DABLS 具有良好的适应性.

从表 3、表 6、表 9 和表 12 中可知, 与 BLS 相比, SS-BLS 的分类精度较高, 这是因为 SS-BLS 能够构造目标域拉普拉斯矩阵来揭示目标域潜在信息, 使模型对目标域具有更强的适应性; 与 SS-BLS 相比, DABLS 能获得更优的分类精度, 这是因为 DABLS 能够构造 MMD 惩罚项, 匹配源域与目标域之间的投影均值, 缩小两域之间的数据分布差异, 提升模型的跨域应用能力; 与 CDELM 相比, DABLS 能够以较好的分类精度完成分类任务, 这是因为 DABLS 能够通过构建特征节点与增强节点提取数据特征, 提升模型的分类能力; 与 TCA 相比, DABLS 仅在 COIL20 数据集上的分类精度略低, 而在其他数据集组成的分类任务下效果都较好. 主要原因是 COIL20 数据集中的图像是相同相机在不同角度对同一物体拍摄形成的, TCA 能够更好地拉近该数据集下两域之间的概率分布差异, 进而更好地完成跨域分类任务; CD-CDBN 因受限于数据集样本数目, 且无法进一步缩小源域数据与目标域数据的差异, 导致分类效果不如 DABLS 模型.

从表 4、表 7、表 10 和表 13 可知, 与 BLS 相比, SS-BLS 的训练时间更长, 原因是构建拉普拉斯矩阵需要耗费大量时间; 与 SS-BLS 相比, DABLS 需要更多的训练时间, 这是因为 DABLS 需要构建 MMD 惩罚项; 综合 BLS, SS-BLS, DABLS 的实验结果可知, 构建拉普拉斯矩阵所需耗费的时间比构建 MMD 惩罚项的时间长; TCA 的训练时间比 BLS, SS-BLS 和 DABLS 长, 这是因为其在跨域分类中需要多次迭代以寻求最优值; CD-CDBN 在上述迁移任务中, 所需的训练时间是最长的, 这是因为 CD-CDBN 结构复杂且训练过程需要多次迭代, 而 DABLS 结构简单且仅需一次迭代就能完成训练.

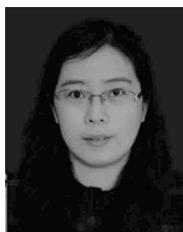
## 5 结束语

本文针对实际分类问题面临的有标签数据匮乏及传统宽度学习系统难以借助相关领域知识提升目标域分类精度问题, 将 MMD 惩罚项和流形正则化框架融入到 BLS 目标函数中, 提出一种域自适应 BLS 模型, 实现了 BLS 跨域分类能力的提升, 拓宽了 BLS 的应用领域. 采用 MMD 惩罚项能够匹配两域之间的投影均值来缩小两域数据之间的分布差异, 以提升模型泛化能力; 采用流形正则化框架揭示目标域的潜在信息, 提升模型对目标域的适应性. 选取 USPS, MNIST, COIL20, Office, Caltech256, ImageNet 和 VOC2007 公共数据集验证 DABLS 模型的性能, 实验结果表明, 无论在简单或复杂的迁移条件下, DABLS 都能利用源域数据知识来提升模型在目标域下的分类效果, 并以较高的精度和效率实现图像的跨域分类, 表现出泛化能力强、计算效率高的特点. 与 BLS、SS-BLS、TCA、CDELM 和 CD-CDBN 模型的实验结果比较表明, DABLS 模型具有较高的分类效率和较强的分类能力. 因此, DABLS 为实现高精度和高效率的跨域图像分类提供一种新方法.

## References

- Salakhutdinov R, Hinton G. An efficient learning procedure for deep boltzmann machine. *Neural Computation*, 2014, **24**(8): 1967–2006
- Lin Jing-Dong, Wu Xin-Yi, Chai Yi, Yin Hong-Peng. Structure optimization of convolutional neural networks: A survey. *Acta Automatica Sinica*, 2020, **46**(1): 24–37 (林景栋, 吴欣怡, 柴毅, 尹宏鹏. 卷积神经网络结构优化综述. *自动化学报*, 2020, **46**(1): 24–37)
- Hinton G E, Osindero T Y W. A fast learning algorithm for deep belief nets. *Neural Computation*, 2006, **18**(7): 1527–1554
- Liu Jian-Wei, Xie Hao-Jie, Luo Xiong-Lin. Research progress on application of generative adversarial networks in various fields. *Acta Automatica Sinica*, 2020, **46**(12): 2500–2536 (刘建伟, 谢浩杰, 罗雄麟. 生成对抗网络在各领域应用研究进展. *自动化学报*, 2020, **46**(12): 2500–2536)

- 5 Feng L, Chen Z, Jie W. Video image target monitoring based on RNN-LSTM. *Multimedia Tools Applications*, 2018, **78**(2): 1–18
- 6 Chen C L P, Liu Z. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, **29**(1): 10–24
- 7 Chen C L P, Liu Z, Feng S. Universal approximation capability of broad learning system and its structural variations. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, **30**(4): 1191–1204
- 8 Jin J W, Chen C L P. Regularized robust broad learning system for uncertain data modeling. *Neurocomputing*, 2018, **322**(1): 58–69
- 9 Yang Gang, Chen Peng, Dai Li-Zhen, Yang Hui. A broad learning system based on reservoir computing. *Control and Decision*, 2021, **36**(9): 2203–2210  
(杨刚, 陈鹏, 戴丽珍, 杨辉. 一种基于池计算的宽度学习系统. 控制与决策, 2021, **36**(9): 2203–2210)
- 10 Zou Wei-Dong, Xia Yuan-Qing. Virtual machine performance prediction using broad learning system based on compression factor. *Acta Automatica Sinica*, 2022, **48**(3): 724–734  
(邹伟东, 夏元清. 基于压缩因子的宽度学习系统的虚拟机性能预测. 自动化学报, 2022, **48**(3): 724–734)
- 11 Kong Y, Wang X, Cheng Y, Chen C. Hyperspectral imagery classification based on semi-supervised broad learning system. *Remote Sensing*, 2018, **10**(5): Article No. 685
- 12 Zheng Yun-Fei, Chen Ba-Dong. Least  $p$ -norm based broad learning system. *Pattern Recognition and Artificial Intelligence*, 2019, **32**(1): 51–57  
(郑云飞, 陈霸东. 基于最小  $p$ -范数的宽度学习系统. 模式识别与人工智能, 2019, **32**(1): 51–57)
- 13 Lin J, Liu Z, Chen C L P, Zhang Y. Quaternion broad learning system: A novel multi-dimensional filter for estimation and elimination tremor in teleoperation. *Neurocomputing*, 2020, **380**: 78–86
- 14 Han M, Feng S B, Chen C L P, Xu M L, Qiu T. Structured manifold broad learning system: A manifold perspective for large-scale chaotic time series analysis and prediction. *IEEE Transactions on Knowledge and Data Engineering*, 2019, **31**(9): 1809–1821
- 15 Fan J H, Wang X, Wang X X, Zhao J H, Liu X X. Incremental wishart broad learning system for fast polsar image classification. *IEEE Geoscience and Remote Sensing Letters*, 2019, **16**(12): 1854–1858
- 16 Feng S, Chen C L P. Fuzzy broad learning system: A novel neuro-fuzzy model for regression and classification. *IEEE Transactions on Cybernetics*, 2020, **50**(2): 414–424
- 17 Xu M L, Han M, Chen C L P, Qiu T. Recurrent broad learning systems for time series prediction. *IEEE Transactions on Cybernetics*, 2020, **50**(4): 1405–1417
- 18 Chu F, Liang T, Chen C L P, Wang X S, Ma X P. Weighted broad learning system and its application in nonlinear industrial process modeling. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, **31**(8): 3017–3031
- 19 Liu Y, Wang Y F, Chen L, Zhao J, Wang W, Liu Q L. Incremental Bayesian broad learning system and its industrial application. *Artificial Intelligence Review*, 2020, **54**: 3517–3537
- 20 Shi Z H, Chen X M, Zhao C M, He H, Stuphorn V, Wu D R. Multi-view broad learning system for primate oculomotor decision decoding. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, **28**(9): 1908–1920
- 21 Zhao H M, Zheng J J, Deng W, Song Y J. Semi-supervised broad learning system based on manifold regularization and broad network. *IEEE Transactions on Circuits and Systems— I: Regular Papers*, 2020, **67**(3): 983–994
- 22 Pan S J, Tsang I W, Kwok J T, Yang Q. Domain adaptation via transfer component analysis. *IEEE Transactions on Neural Networks*, 2021, **22**(2): 199–210
- 23 Li S, Song S J, Huang G, Wu C. Cross-domain extreme learning machines for domain adaptation. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2019, **49**(6): 1194–1207
- 24 Huang G B. Learning hierarchical representations for face verification with convolutional deep belief networks. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Providence, USA: IEEE, 2012. 2518–2525



**赵慧敏** 中国民航大学电子信息与自动化学院教授. 主要研究方向为智能控制与信息处理, 深度学习与智能优化, 智能诊断与性能评估.

E-mail: hm\_zhao1977@126.com

**(ZHAO Hui-Min** Professor at the College of Electronic Information and Automation, Civil Aviation University of China. Her research interest covers intelligent control and information processing, deep learning and intelligent optimization, intelligent diagnosis, and performance evaluation.)



**郑建杰** 首都师范大学心理学院博士研究生. 主要研究方向为宽度学习系统与图像处理, 人类脑图谱的构建和应用.

E-mail: zheng853796151@126.com

**(ZHENG Jian-Jie** Ph.D. candidate at the School of Psychology, Capital Normal University. His research interest covers broad learning system and image processing, and construction and application of human brain atlas.)



**郭晨** 大连海事大学船舶电气工程学院教授. 主要研究方向为船舶自动控制系统, 智能控制理论与应用, 虚拟现实技术及应用.

E-mail: dmuguoc@126.com

**(GUO Chen** Professor at the School of Marine Electrical Engineering, Dalian Maritime University. His research interest covers ship automatic control system, intelligent control theory and application, and virtual reality technology and application.)



**邓武** 中国民航大学电子信息与自动化学院教授. 主要研究方向为智能优化与资源调度, 深度学习与智能诊断. 本文通信作者.

E-mail: dw7689@163.com

**(DENG Wu** Professor at the College of Electronic Information and Automation, Civil Aviation University of China. His research interest covers intelligent optimization and resource scheduling, deep learning, and intelligent diagnosis. Corresponding author of this paper.)