

基于流形结构的多源自适应迁移学习算法及应用研究

史玉皓¹, 田建艳^{1†}, 刘军军², 杨胜强³

(1. 太原理工大学电气与动力工程学院, 山西太原 030024;

2. 太原理工大学数学学院, 山西太原 030024;

3. 太原理工大学机械与运载工程学院, 山西太原 030024)

摘要: 迁移学习是将源域的知识迁移解决目标域问题的方法, 能有效解决数据分布不一致问题. 针对多源域迁移时传统方法缺乏对多源域的可迁移性的合理分析和迁移效果的有效处理问题, 本文提出了一种基于流形结构的多源自适应迁移学习的方法, 旨在提高单源域迁移效果的同时实现多源域的有效迁移. 首先, 对多源域进行可迁移性分析, 选择可迁移的源域; 然后, 适配边缘分布和条件分布并引入均衡因子得到均衡分布适配, 同时利用流形正则化约束数据结构, 使单源域的信息使用最大化; 最后, 通过加权因子对不同源域分类器进行自适应加权, 充分利用多源域的信息求解目标域问题. 将该算法应用于滚磨光整加工中滚抛磨块的优选, 通过建立滚抛磨块的相似度匹配方法, 构建基于流形结构的多源自适应迁移学习的滚抛磨块优选模型. 大量对比实验表明该方法表现更佳, 准确率最高至 73.44%, 可以为滚磨光整中滚抛磨块的选择提供更有效的决策指导.

关键词: 迁移学习; 多源域迁移; 可迁移性分析; 自适应; 流形正则化; 滚磨光整; 滚抛磨块优选

中图分类号: TP29

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1367

开放科学 (资源服务) 标识码 (OSID):



Research on Multi Domain Adaptation-Manifold Regularization and Application

Shi Yuhao¹, Tian Jianyan^{1†}, Liu Junjun², Yang Shengqiang³

(1. College of Electrical and Power Engineering, Taiyuan University of Technology, Taiyuan 030024, China;

2. College of Mathematics, Taiyuan University of Technology, Taiyuan 030024, China;

3. College of Mechanical and Vehicle Engineering, Taiyuan University of Technology, Taiyuan 030024, China)

Abstract: Transfer learning is a method of transferring knowledge from source domain to solve the problem of the target domain, which can effectively solve the problem of inconsistent data distribution. Aiming at the problem that traditional methods lack a reasonable analysis of the transferability of multi domain and the effective treatment of transfer effects in multi domain transfer, the Multi Domain Adaptation-Manifold Regularization transfer learning algorithm is proposed to improve the effect of single source domain transfer while realizing effective transfer of multi domain. Firstly, the transferability of multi domain is analysed to select the source domains that can be transferred; then, the marginal distribution and the conditional distribution is adapted and the balance factor is introduced to obtain the balanced distribution adaptation, as well as the manifold regularization is used to constrain the data structure to maximize the use of information in the single source domain; finally, different domain classifiers are adaptively weighted by weighting factors, and the information of multi domain is fully utilized to solve the target domain problem. This algorithm is applied to the optimization of the abrasive media in the mass finishing. By establishing the similarity matching method of the abrasive media, the Multi Domain Adaptation-Manifold Regularization of the abrasive media optimization model is constructed. A large number of comparative experiments show that this method performs better, with an accuracy rate of up to 73.44%, which can provide more effective decision-making guidance for the optimization of the abrasive media in the mass finishing.

Keywords: transfer learning; multi domain transfer; analysis of the transferability; self-adaptive; manifold regularization; mass finishing; optimization of the abrasive media

收稿日期: 2021-08-05; 录用日期: 2021-11-26.

基金项目: 山西省重点研发计划项目 (201903D121057); 山西省自然科学基金重点项目 (201801D111002); 山西省研究生教育创新计划项目 (2021Y229).

†通讯作者. E-mail: tut_tianjy@163.com

0 引言

迁移学习是一类热门的机器学习方法,与传统的机器学习相比,它具有较少的数据依赖和较少的标签依赖等优点^[1]. 迁移学习克服了传统机器学习中数据特征服从同一分布的设定^[2]. 其中,新数据所在的领域称为目标域,而相关历史数据所在的领域称为源域^[3]. 基于特征的迁移学习旨在构建一个共同子空间,并在其中最小化源域和目标域之间的差异来提高分类器的性能^[4]. 国内外迁移学习研究团队在特征迁移学习算法领域依次提出了 TCA^[5]、JDA^[6]、BDA^[7] 等算法,旨在缩小最小化源域和目标域之间的边缘分布距离和条件分布距离. 基于特征迁移学习的实际应用是近年来众多学者的研究热点. 阎高伟^[8] 等将特征迁移学习应用于湿式球磨机负荷参数预测,提出了一种 MMD-JDA 特征迁移学习算法,并通过实验可知验证该方法可以使测量结果更加准确且可信. 陈佳鲜^[9] 等针对不同工况下轴承退化数据分布不一致问题,提出了一种基于深度时序特征迁移的轴承剩余寿命预测方法. 结果表明所提出方法构建的健康指标可更有效地反映退化趋势. Xue B^[10] 等针对不同情绪识别的学习问题,提出了一种基于 EEG 的情绪识别的特征分析算法,该算法通过 TCA 了缩小源域和目标域的距离. Li H B^[11] 等提出了一种 MA-JDA 特征迁移学习算法并应用于船舶识别问题,并通过实验证明该方法在船舶识别问题上表现更优.

滚磨光整加工技术是机械加工领域的一类基础性制造工艺技术,属于精密和超精密加工的范畴^[12]. 滚抛磨块是影响其加工效果的关键因素之一^[13]. 闫瑞斌^[14] 等针对案例推理 (Case-based reasoning, CBR)^[15] 技术在滚磨光整加工中难以解决的数据分布不一致问题,引入特征迁移学习算法,提出了条件分布适配-流形正则化 (Conditional Distribution Adaptation-Manifold Regularization, CDA-MR) 的迁移学习方法,经过对比实验表明该方法可以为数据分布不一致时滚抛磨块的选择提供建议.

随着案例的大量收集,对多源域进行可迁移分析以及信息的有效利用成为限制决策的关键因素. 本文针对多源域迁移学习中 CDA-MR 等传统迁移学习缺乏对多源域的可迁移性的合理分析和迁移效果的有效处理问题,提出了基于流形结构的多源自适应迁移学习 (Multi Domain Adaptation-Manifold Regularization, MDA-MR) 方法,并将该方法应用于滚抛磨块的优选. 步骤: 对多源域案例集进行可迁移性分析,选择可迁移的源域案例集; 结合边缘分布适

配和条件分布适配并引入均衡因子得到均衡分布适配,同时利用流形正则化保持数据结构,使单源域案例集的信息使用最大化,得到基于均衡分布适配-流形正则化 (Balanced Distribution Adaptation-Manifold Regularization, BDA-MR) 的迁移学习方法; 通过加权因子对多源域案例集分类器进行自适应加权,充分利用多源域案例集的信息用于目标域案例集的求解; 建立滚抛磨块的相似度匹配方法,最终构建起 MDA-MR 的滚抛磨块优选模型. 本文在课题组已搭建的面向用户的滚磨光整加工数据库平台^[16] 上将该方法与 CDA-MR 等方法进行对比实验,来验证本文针对多源域迁移问题改进的必要性.

1 基于 MDA-MR 的迁移学习算法

基于 MDA-MR 的迁移学习算法旨在分析不同领域的可迁移性,选择可迁移的源域; 结合边缘分布适配和条件分布适配并引入均衡因子得到均衡分布适配,同时利用流形正则化约束数据结构,使单源域案例集的信息使用最大化; 通过加权因子对多源域分类器进行自适应加权,充分利用多源域案例集的信息用于目标域案例集的求解. 其算法流程如下:

算法: 基于 MDA-MR 的迁移学习算法

输入: 各源域案例集特征信息 $\sum_{i=1}^p \mathbf{X}_i^s$ 和标签特征信息 $\sum_{i=1}^p \mathbf{Y}_i^s$ ($1 \leq l \leq p, p$ 表示有 p 个源域案例集), 目标域案例集特征信息 $\mathbf{X}^t$, 均衡因子 μ , 正则项系数 λ

输出: 空间变换矩阵 $\mathbf{A}$, 分类器 f , 预测的目标域案例集标签特征信息 $\mathbf{Y}$, 修正后的目标域案例集预测标签

Step1: 最优优化式 (10) 的同时采用式 (8) 和式 (9) 进行约束

Step2: 根据式 (14) 得到空间变换矩阵 $\mathbf{A}$

Step3: 源域案例集特征信息投影到公共子空间为 $\sum_{i=1}^p \mathbf{Z}_i^s = \mathbf{A}^T \sum_{i=1}^p \mathbf{X}_i^s$

Step4: 目标域案例集特征信息投影到公共子空间为 $\mathbf{Z}^t = \mathbf{A}^T \mathbf{X}^t$

Step5: 构建起基于 BDA-MR 的单源域案例集分类器

Step6: 根据式 (17) 对分类器自适应加权, 得到多源域案例集分类器 f

Step7: 根据式 (18) 将目标域案例集特征信息 $\mathbf{X}^t$ 输入至分类器 f 得到预测的目标域案例集标签特征信息 $\mathbf{Y}$

1.1 最大均值差异

迁移学习的主要目标是减少源域案例集和目标域案例集的分布差异, 所以量化领域案例集之间的数据分布差异是迁移学习中基础且重要的问题. 最大均值差异 (Maximum Mean Discrepancy, MMD)^[1] 可以度量两种案例集数据分布的距离, 被广泛应用于迁移学习领域. 假设存在两个特征信息分布不一致的源域案例集 $\mathbf{D}_s$ 和目标域案例集 $\mathbf{D}_t$, 则两个领域案例集数据分布的距离定义为:

$$f(\mathbf{D}_s, \mathbf{D}_t) = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \psi(x_i^s) - \frac{1}{n_t} \sum_{j=1}^{n_t} \psi(x_j^t) \right\|^2. \quad (1)$$

式中, $\psi(\cdot)$ 表示映射函数, 该函数将原始数据变换至再生核希尔伯特空间; $x_i^s \in \mathbf{D}_s$ 表示为源域案例集样本集的第 i 个样本, $i = 1, 2, \dots, n_s$; $x_j^t \in \mathbf{D}_t$ 表示为目标域案例集样本集的第 j 个样本, $j = 1, 2, \dots, n_t$.

1.2 数据适配

1.2.1 边缘分布距离

边缘分布距离表征源域案例集和目标域案例集间的特征信息差异, 本文采用 MMD 来度量的源域案例集与目标域案例集的边缘分布距离:

$$\left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \mathbf{A}^T x_i^s - \frac{1}{n_t} \sum_{j=1}^{n_t} \mathbf{A}^T x_j^t \right\|^2 = \text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{M}_0 \mathbf{X}^T \mathbf{A}). \quad (2)$$

式中, $\mathbf{A} \in \mathbb{R}^{m \times k}$ 为空间变换矩阵, m 为源域案例集与目标域案例集的公共特征数, k 为子空间的基数; $\mathbf{A}^T$ 为矩阵 $\mathbf{A}$ 的转置; $\mathbf{X} \in \mathbb{R}^{m \times n}$ 为源域案例集特征信息 $\mathbf{X}^s$ 和目标域案例集的特征信息 $\mathbf{X}^t$ 的并集, $n = n_s + n_t$; $\mathbf{M}_0 \in \mathbb{R}^{n \times n}$ 为边缘分布的 MMD 矩阵:

$$(\mathbf{M}_0)_{ij} = \begin{cases} \frac{1}{n_s n_s}, & x_i, x_j \in \mathbf{D}_s; \\ \frac{1}{n_t n_t}, & x_i, x_j \in \mathbf{D}_t; \\ \frac{-1}{n_s n_t}, & \text{Otherwise.} \end{cases} \quad (3)$$

1.2.2 条件分布距离

目标域案例集往往存在少标签甚至存在无标签的情况, 使得条件分布 $Q_s(y^s | x^s)$ 和 $Q_t(y^t | x^t)$ 难以直接进行建模. 源域案例集建立的模型可以为目标域案例集的构建出案例伪标签, 根据伪标签继续建模, 近似匹配每一标签的条件分布. 同样采用 MMD 计算条件分布距离为:

$$\sum_{c=1}^C \left\| \frac{1}{n_s^{(c)}} \sum_{x_i^s \in \mathbf{D}_s^{(c)}} \mathbf{A}^T x_i^s - \frac{1}{n_t^{(c)}} \sum_{x_j^t \in \mathbf{D}_t^{(c)}} \mathbf{A}^T x_j^t \right\|^2 = \sum_{c=1}^C \text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{M}_c \mathbf{X}^T \mathbf{A}). \quad (4)$$

式中, 标签 $c = 1, 2, \dots, C$; $n_s^{(c)}$ 和 $n_t^{(c)}$ 分别为 $\mathbf{D}_s$ 和 $\mathbf{D}_t$ 中属于第 c 个标签的案例个数; $\mathbf{D}_s^{(c)}$ 和 $\mathbf{D}_t^{(c)}$ 表示属于第 c 个标签的源域案例集和目标域案例集; $\mathbf{M}_c$ 为 c 条件分布的 MMD 矩阵:

$$(\mathbf{M}_c)_{ij} = \begin{cases} \frac{1}{n_s^{(c)} n_s^{(c)}}, & x_i, x_j \in \mathbf{D}_s^{(c)}; \\ \frac{1}{n_t^{(c)} n_t^{(c)}}, & x_i, x_j \in \mathbf{D}_t^{(c)}; \\ \frac{-1}{n_s^{(c)} n_t^{(c)}}, & \begin{cases} x_i \in \mathbf{D}_s^{(c)}, x_j \in \mathbf{D}_t^{(c)}; \\ x_j \in \mathbf{D}_s^{(c)}, x_i \in \mathbf{D}_t^{(c)}; \end{cases} \\ 0, & \text{Otherwise.} \end{cases} \quad (5)$$

1.2.3 流形正则化

流形正则化 (Manifold regularization, MR)^[17] 旨在分析数据间的局部流形结构关系, 并在迁移学习的空间变换过程中保持这种流形结构来提升学习效率同时提高模型的鲁棒性, 其目标函数为:

$$\min \left(\sum_{g,h} \|z_g - z_h\|^2 W_{gh} \right). \quad (6)$$

式中, z_g 和 z_h 为 $\mathbf{D}_s$ 中第 g 个数据 x_g 和第 h 个数据 x_h 投影后样本, $g \neq h$; W_{gh} 为样本相似度矩阵 $\mathbf{W}$ 中的元素, $\mathbf{W}$ 计算公式如式 (7) 所示.

$$\mathbf{W} = \{W_{gh}\} = \begin{cases} \cos(x_g, x_h), & \|x_g - x_h\|^2 < \varepsilon \\ 0, & \text{Otherwise.} \end{cases} \quad (7)$$

式中, ε 为局部近邻半径.

式 (6) 可等价:

$$\min \left(\sum_{g,h} \|z_g - z_h\|^2 W_{gh} \right) = \min \left(\text{tr}(\mathbf{A}^T \mathbf{X}^s \mathbf{L} (\mathbf{X}^s)^T \mathbf{A}) \right). \quad (8)$$

式中, $\mathbf{L} \in \mathbb{R}^{n_s \times n_s}$ 为 Laplacian 矩阵, $\mathbf{L} = \mathbf{D} - \mathbf{W}$; $\mathbf{D}$ 为对角矩阵, 其对角线元素为 $D_{hh} = \sum_{g=1}^{n_s} W_{gh}$.

数据适配的核心在于缩小源域案例集和目标域案例集间的边缘分布距离和条件分布距离. 为使适配过程中单源域案例集的信息使用最大化, 用 MR 约束适配过程的同时引入均衡因子^[7], 旨在调节边缘分布和条件分布在适配过程中的作用占比, 来提高单源域迁移学习的学习效率, 计算公式如式 (9) 所示:

$$\mu \text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{M}_0 \mathbf{X}^T \mathbf{A}) + (1 - \mu) \sum_{c=1}^C \text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{M}_c \mathbf{X}^T \mathbf{A}) + \lambda \text{tr}(\mathbf{A}^T \mathbf{X}^s \mathbf{L} (\mathbf{X}^s)^T \mathbf{A}). \quad (9)$$

式中, μ 为均衡因子, $\mu \in [0, 1]$; λ 为正则项系数.

1.3 最优化问题

为了提高迁移学习模型的有效性和鲁棒性, 最大程度保留对目标域案例集标签有用的特征信息, 采用最大方差^[18]来去除噪声影响, 使映射后数据保留最多有用信息, 其目标函数为:

$$\max (\text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{H} \mathbf{X}^T \mathbf{A})) \quad (10)$$

式中, $\mathbf{H} = \mathbf{I}_{n_s+n_t} - 1/(n_s + n_t) \mathbf{u} \mathbf{u}^T$; $\mathbf{I}_{n_s+n_t}$ 为单位向量; $\mathbf{u} \in \mathbb{R}^n$ 表示内部元素为 1 的列向量.

通过 BDA 将特征信息投射到公共子空间来减小源域案例集和目标域案例集之间的特征信息分布差异, 并采用 MR 保持数据的结构关系, 同时采用最大方差的来去除噪声, 最大程度保留特征变换后数据的有效性, 得出最优化问题为:

$$\begin{aligned} \min & \left(\mu \operatorname{tr}(\mathbf{A}^T \mathbf{X} \mathbf{M}_0 \mathbf{X}^T \mathbf{A}) + (1 - \mu) \sum_{c=1}^C \right. \\ & \left. \operatorname{tr}(\mathbf{A}^T \mathbf{X} \mathbf{M}_c \mathbf{X}^T \mathbf{A}) + \lambda \operatorname{tr}(\mathbf{A}^T \mathbf{X}^s \mathbf{L} (\mathbf{X}^s)^T \mathbf{A}) \right) \\ \text{s.t.} & \quad \mathbf{A}^T \mathbf{X} \mathbf{H} \mathbf{X}^T \mathbf{A} = \mathbf{I}, \quad 0 \leq \mu \leq 1. \end{aligned} \quad (11)$$

等价于

$$\begin{aligned} \min & \left(\frac{\mu \operatorname{tr}(\mathbf{A}^T \mathbf{X} \mathbf{M}_0 \mathbf{X}^T \mathbf{A}) + (1 - \mu) \sum_{c=1}^C \operatorname{tr}(\mathbf{A}^T \mathbf{X} \mathbf{M}_c \mathbf{X}^T \mathbf{A})}{\operatorname{tr}(\mathbf{A}^T \mathbf{X} \mathbf{H} \mathbf{X}^T \mathbf{A})} \right. \\ & \left. + \lambda \frac{\operatorname{tr}(\mathbf{A}^T \mathbf{X}^s \mathbf{L} (\mathbf{X}^s)^T \mathbf{A})}{\operatorname{tr}(\mathbf{A}^T \mathbf{X} \mathbf{H} \mathbf{X}^T \mathbf{A})} \right) \\ \text{s.t.} & \quad 0 \leq \mu \leq 1. \end{aligned} \quad (12)$$

采用 Laplacian 乘子法, 取 Laplacian 乘子为 $\Phi = \operatorname{diag}(\Phi_1, \dots, \Phi_k) \in \mathbb{R}^{k \times k}$, 则

$$\begin{aligned} \mathbf{F} = \operatorname{tr} & \left(\mathbf{A}^T \left(\mu \mathbf{X} \mathbf{M}_0 \mathbf{X}^T + (1 - \mu) \mathbf{X} \sum_{c=1}^C \mathbf{M}_c \mathbf{X}^T + \right. \right. \\ & \left. \left. \lambda \mathbf{X}^s \mathbf{L} (\mathbf{X}^s)^T \right) \mathbf{A} \right) + \operatorname{tr}((\mathbf{I} - \mathbf{A}^T \mathbf{X} \mathbf{H} \mathbf{X}^T \mathbf{A}) \Phi). \end{aligned} \quad (13)$$

通过对 $\mathbf{A}$ 求导后得到广义特征分解:

$$\begin{aligned} & \left(\mu \mathbf{X} \mathbf{M}_0 \mathbf{X}^T + (1 - \mu) \mathbf{X} \sum_{c=1}^C \mathbf{M}_c \mathbf{X}^T + \right. \\ & \left. \lambda \mathbf{X}^s \mathbf{L} (\mathbf{X}^s)^T \right) \mathbf{A} = \mathbf{X} \mathbf{H} \mathbf{X}^T \mathbf{A} \Phi. \end{aligned} \quad (14)$$

联立方程求解式 (14) 得到了 $\mathbf{A}$, 变换后的源域案例集特征信息 $\mathbf{Z} = \mathbf{A}^T \mathbf{X}$, 再采用机器分类方法构建基于 BDA-MR 的迁移学习算法并得到预测的目标域案例集特征信息 $\mathbf{Y}$.

1.4 分类器加权

挖掘并利用领域间的相似性, 不仅可以提高迁移学习算法的学习效率, 还可以提高目标域的分类效率^[19]. 可迁移性分析可以有效挖掘领域之间的相似性. 为了对多源域案例集进行可迁移性分析、评价和合理处理, 本文将分类器加权引入至 BDA-MR 模型中. 首先采用 BDA-MR 缩小全部源域案例集特征信息和目标域案例集特征信息的分布差异:

$$\left(\sum_{l=1}^p \mathbf{Z}_l^s, \mathbf{Z}^t \right) = \mathbf{G} \left(\sum_{l=1}^p \mathbf{X}_l^s, \sum_{l=1}^p \mathbf{Y}_l^s, \mathbf{X}^t \right). \quad (15)$$

式中, $\mathbf{Z}_l^s$ 为第 l 个源域案例集适配后的源域案例集特征信息, $l \in [1, p]$, p 表示共有 p 个源域案例集; $\mathbf{Z}^t$ 为适配后的目标域案例集特征信息; $\mathbf{G}(\cdot)$ 为 BDA-MR 适配过程; $\mathbf{X}_l^s$ 和 $\mathbf{Y}_l^s$ 为第 l 个源域案例集适配前的特征信息及磨块特征信息; $\mathbf{X}^t$ 为适配前的目标域案例集特征信息.

采用 MMD 对领域案例集进行度量. 两个领域案

例集之间的 MMD 距离越大表示两个领域案例集联系越小, 故需减小其作用占比; 反之, 则需增大其作用占比. 因此本文采用式 (16) 表征两个领域案例集之间的相似度:

$$\begin{aligned} d_l &= \frac{1}{\operatorname{MMD}(\mathbf{Z}_l^s, \mathbf{Z}^t)}. \\ \text{s.t.} & \quad l \in [1, p]. \end{aligned} \quad (16)$$

式中, $\operatorname{MMD}(\cdot)$ 为两个领域案例集间的最大均值差异值. 根据各源域案例集与目标域案例集之间的相似度得到各分类器的加权因子:

$$w_l = \frac{d_l}{\sum_{l=1}^p d_l}. \quad (17)$$

根据加权因子 w_l 对不同源域案例集分类器进行自适应加权, 最终预测得到目标域案例集的标签特征信息:

$$\mathbf{Y} = \sum_{l=1}^p w_l \mathbf{M}(\mathbf{Z}_l^s, \mathbf{Z}^t, \mathbf{Y}_l^s) = f(\mathbf{X}^t). \quad (18)$$

式中, $\mathbf{M}(\cdot)$ 为机器分类算法; f 为基于 MDA-MR 的多源域案例集分类器.

2 基于 MDA-MR 的滚抛磨块优选模型

首先, 分析大量滚磨光整加工生产实例选取零件特征和磨块特征制作滚抛磨块案例库和磨块库; 其次, 采用归一化方法对案例库特征信息进行预处理, 通过 MDA-MR 将处理后的特征信息投射到公共子空间; 然后, 使用机器分类方法对磨块特征进行预测; 最后, 将预测结果与磨块库进行相似度计算最终输出优选的滚抛磨块. 基于 MDA-MR 的滚抛磨块优选模型流程图如图 1 所示.




图 1 基于 MDA-MR 的滚抛磨块优选模型的流程图

2.1 案例特征选取

在滚磨光整加工中, 待加工零件的特征信息和客户的加工要求是影响滚抛磨块选择的关键因素, 表征并描述各实体间的联系是案例特征选取的必要手段. 实体-联系图^[20] 是一种能够表征实体联系、类型和属性的表示方法. 通过对实验报告、专家经验和文献手册数据的研究, 本文选取待加工零件的特征有关键零件尺寸 (以轴类零件为例: 长度 F1、轴径 F2) 和零件加工前特征 (粗糙度 F3、光亮度 F4、毛刺 F5、硬度 F6); 加工要求为加工后零件特征 (粗糙度 F7、光亮度 F8、毛刺 F9、硬度 F10、残余应力改善 F11); 磨块特征信息有形状 L1、尺寸 L2、材质 L3 和类型 L4. 其中 F4、F8 按国家标准分为四种等级: 光亮度非常高、较低且没有磨纹、无光亮度、可辨加工痕迹方向, 分别赋值为 4、3、2、1^[15]; F9 表示加工后毛刺是否存在, 1 表示毛刺被去除, 0 表示毛刺仍存在^[21]. 根据零件特征参数和加工要求构建零件特征训练数据 $\mathbf{X}$ 和源域案例集磨块特征解集 $\mathbf{Y}^s$.

2.2 基于相似度计算的滚抛磨块匹配

针对存在预测结果与磨块库里磨块都不匹配的问题, 本文设计了基于相似度计算的滚抛磨块匹配方法, 将预测的每组目标域案例集磨块特征信息 $Y_i (Y_i \in \mathbf{Y}, i = 1, 2, \dots, n_t)$ 逐一与磨块库的磨块特征信息 $T_p (T_p \in \mathbf{T}, p = 1, 2, \dots, M)$ 进行相似度计算, 其中磨块库常用磨块有 8 种, 故选择 $M = 8$. 将相似度最大值对应的磨块作为输出结果来完成对每组目标域案例集磨块特征信息 Y_i 的修正, 进而完成对 $\mathbf{Y}$ 的修正, 公式如式 (19) 所示.

$$Y_i = \text{MAX}(\text{SIM}(T_1, Y_i), \text{SIM}(T_2, Y_i), \dots, \text{SIM}(T_8, Y_i)). \quad (19)$$

式中, $\text{MAX}(\cdot)$ 为修正函数, 将匹配相似度最高的磨块来修正 Y_i ; $\text{SIM}(T_p, Y_i)$ 为 T_p 与 Y_i 的整体相似度, 计算公式如式 (20) 所示:

$$\text{SIM}(T_p, Y_i) = \frac{1}{n} \sum_{j=1}^n \text{sim}(T_{pj}, Y_{ij}). \quad (20)$$

s.t. $p = 1, 2, \dots, 8, j = 1, 2, 3, 4.$

式中, Y_{ij} 为 Y_i 的第 j 个磨块特征信息; T_{pj} 为 T_p 的第 j 个磨块特征信息; n 为磨块特征信息数, 本文中 $n=4$; $\text{sim}(T_{pj}, Y_{ij})$ 为 T_{pj} 和 Y_{ij} 的第 j 个磨块特征信息的相似度, 需根据具体的磨块特征信息数据类型选择不同的相似度计算公式, 磨块库常见的滚抛磨块及特征信息^[14] 如表 1 所示, 滚抛磨块特征信息相似度计算公式如式 (21)~ 式 (23) 所示.

表 1 磨块库常见的滚抛磨块及特征信息

滚抛磨块	尺寸	形状	材质	类型
2 号三角磨块	2#	三角形 (T)	刚玉 (C)	粗磨 (R)
2 号粗磨磨块	2#	球形 (S)	刚玉 (C)	粗磨 (R)
2 号中磨磨块	2#	球形 (S)	刚玉 (C)	中磨 (M)
2 号精磨磨块	2#	球形 (S)	氧化铝 (A)	精磨 (F)
3 号三角磨块	3#	三角形 (T)	刚玉 (C)	粗磨 (R)
3 号粗磨磨块	3#	球形 (S)	刚玉 (C)	粗磨 (R)
3 号中磨磨块	3#	球形 (S)	刚玉 (C)	中磨 (M)
3 号精磨磨块	3#	球形 (S)	氧化铝 (A)	精磨 (F)

(1) 磨块尺寸为数值型, 采用式 (21) 计算.

$$\text{sim}(T_{p1}, Y_{i1}) = \exp \left[-\frac{T_{p1} - Y_{i1}}{\sqrt{2}} \right]. \quad (21)$$

(2) 磨块形状和磨块材质为二值型, 采用式 (22) 计算.

$$\text{sim}(T_{pj}, Y_{ij}) = \begin{cases} 1, & T_{pj} = Y_{ij}, j = 2, 3 \\ 0, & T_{pj} \neq Y_{ij} \end{cases} \quad (22)$$

(3) 磨块类型为模糊逻辑型, 采用式 (23) 计算

$$\text{sim}(T_{p4}, Y_{i4}) = 1 - \frac{|T_{p4} - Y_{i4}|}{M}. \quad (23)$$

式中, M 为磨块类型数.

将基于相似度计算的滚抛磨块匹配方法引至迁移学习中, 构建基于 MDA-MR 的滚抛磨块优选模型.

3 实验与结果分析

在机械装备领域中, 轴类零件是最为常见的典型零件之一, 轴类零件在使用过程中往往会发生磨损、腐蚀等现象, 进而影响工作系统的使用^[22]. 常见的轴类零件包括齿轮轴零件、凸轮轴零件和曲轴零件等, 本文基于数据库平台中已有成功案例结果, 选择齿轮轴案例集、凸轮轴案例集、曲轴案例集进行对比验证, 并采用非轴类的齿轮案例集对可迁移进行研究. 同时为验证本论文提出理论的有效性, 采用 TCA^[5]、JDA^[6]、BDA^[7]、MMD-JDA^[8]、CDA-MR^[14] 与 BDA-MR 和 MDA-MR 进行验证实验. 常见轴类零件及齿轮零件如图 2 所示.



(a) 齿轮轴 (b) 凸轮轴 (c) 曲轴 (d) 齿轮

图 2 常见轴类零件及齿轮零件

3.1 数据预处理

为消除案例中各特征信息数量级及量纲的作用, 需要对其行归一化处理, 公式如式 (24):

$$x_i^{k'} = \frac{x_i^k - x_{\min}^k}{x_{\max}^k - x_{\min}^k}. \quad (24)$$

式中, x_i^k 为第 i 组数据的第 k 个特征信息; $x_i^{k'}$ 为 x_i^k 的归一化后的数据; $x_{\max}^k$ 和 $x_{\min}^k$ 为案例中第 k 个特征的数据峰值以及数据最小值.

3.2 可迁移性分析

目标域受迁移知识的负面影响的现象被称为负迁移^[23]. 对源域知识的可迁移性进行分析以及避免负迁移是当下迁移学习领域的重点问题^[1]. 通过可迁移分析选择合理的数据源域, 同时对源域信息合理加权是解决负迁移的有效手段^[24]. 本文采用最大均值差异对多种处理方法后的数据进行度量与分析, 进而对源域案例集知识的可迁移性进行判断, 度量结果如表 2 所示. 同时以齿轮轴案例集对凸轮轴案例集迁移为例, 分别引入同类的曲轴案例集和非轴类的齿轮案例集, 来验证可迁移分析以及非负迁移和有效迁移的合理性, 结果如图 3 所示.

表 2 不同领域案例集在多种处理方法下的最大均值差异度量值

方法 \ 案例集	齿轮轴: 齿轮轴: 齿轮轴: 凸轮轴: 凸轮轴: 曲轴:					
	凸轮轴	曲轴	齿轮	曲轴	齿轮	齿轮
原始	0.6956	0.3520	0.8808	0.6302	0.3733	0.8035
预处理	0.0168	0.0132	0.0224	0.0076	0.0146	0.0156
TCA	0.0018	0.0031	0.0069	0.0023	0.0063	0.0067
JDA	0.0024	0.0039	0.0062	0.0024	0.0055	0.0062
CDA-MR	0.0012	0.0004	0.0053	0.0011	0.0056	0.0049




图 3 可迁移性分析验证实验下基于不同方法的滚抛磨块优选模型准确率

由表 2 可知, 在不同处理方法下, 非轴类的齿轮案例集和任一轴类案例集的最大均值差异度量值普遍高于同方法下轴类案例集之间的最大均值差异度量值, 在迁移学习适配后差异最高可达 14 倍. 由图 3 可知, 在实际迁移中, 当引入非轴类的齿轮案例集进行多源域案例集迁移时, 各模型准确率降低, 可知不合理引入源域案例集数据导致迁移过程中出现了负迁移; 当引入同类的曲轴案例集进行多源域案例集迁移时, 各模型迁移效果提升, 故判断合理引入源

域案例集数据有利于多源域案例集迁移时的有效迁移. 综上可知, 当领域案例集之间属于不同类时最大均值差异度量值高, 表示领域案例集之间特征信息差异过大, 不合理引入会造成负迁移; 领域案例集之间属于同一类时最大均值差异度量值低, 表示领域案例集之间特征信息相近, 可抑制负迁移同时增加正迁移的迁移效率, 最终在多源域案例集迁移时实现有效迁移.

3.3 模型参数调优

为保证对比实验的有效性, 需要对每个模型进行参数调优. 以本文提出 MDA-MR 模型为例, 对式 (9) 中的均衡因子 μ 和正则化系数 λ 进行参数调优, 调优如表 3 和表 4 所示.

表 3 $\lambda=0.1$, 不同 μ 值下 MDA-MR 的准确率结果

μ	准确率	μ	准确率
0.1	62.50%	0.6	71.88%
0.2	64.06%	0.7	73.44%
0.3	67.19%	0.8	71.88%
0.4	68.75%	0.9	68.75%
0.5	70.31%	1.0	67.19%

表 4 $\mu=0.7$, 不同 λ 值下 MDA-MR 的准确率结果

λ	准确率	λ	准确率
0.01	68.75%	0.1	73.44%
0.02	65.63%	0.2	70.31%
0.03	56.25%	0.3	68.75%
0.04	57.81%	0.4	70.31%
0.05	57.81%	0.5	70.31%
0.06	65.63%	0.6	70.31%
0.07	56.25%	0.7	70.31%
0.08	71.88%	0.8	65.63%
0.09	56.25%	0.9	70.31%
0.10	73.44%	1.0	67.19%


由表 3 和表 4 可知, 本文采取固定参数法进行各参数调优. 固定 $\lambda=0.1$,MDA-MR 在 $\mu=0.7$ 时边缘分适配和条件分布适配作用比例最佳; 当 $\mu=0.7$ 时, λ 分别对 (0.01,0.1) 和 (0.1,1) 区间进行等距调参, 结果表明, 在当 $\lambda=0.1$ 、 $\mu=0.7$ 时 MDA-MR 模型参数最优, 准确率可达最高值. 为保证对比实验的有效性, 本文实验对其他模型同样采用该方法对其关键参数进行了调优.

3.4 对比实验验证


在满足可迁移性的基础上, 本文选取齿轮轴案例集、凸轮轴案例集、曲轴案例集作为验证案例集进行对比实验, 具体对比实验验证结果如表 5 和图 4 所示.

表 5 对比实验验证下基于不同方法的滚抛磨块优选模型准确率

方法			TCA	JDA	BDA	MMD-JDA	CDA-MR	BDA-MR	MDA-MR
案例集									
源域案例集		目标域案例集							
单源域	齿轮轴	曲轴	40.00%	43.33%	43.33%	43.33%	46.67%	50.00%	50.00%
	齿轮轴	凸轮轴	39.06%	48.44%	51.56%	48.44%	57.81%	67.19%	67.19%
多源域	齿轮轴和凸轮轴		36.67%	40.00%	43.33%	40.00%	46.67%	53.33%	56.67%
	齿轮轴和曲轴		51.56%	56.25%	56.25%	57.81%	60.93%	67.19%	73.44%



(a) 单源域仿真



(b) 多源域仿真

图 4 对比实验验证下基于不同方法的滚抛磨块优选模型对比图

由表 5 和图 4 可知, 在单源域案例集仿真中 BDA-MR 与 MDA-MR 较其他方法有着更高的准确率, 验证了引入均衡因子以及基于相似度计算的滚抛磨块匹配算法的有效性, 同时证明了在单源域案例集仿真中 MDA-MR 可以达到与 BDA-MR 相同的效果; 在多源域案例集仿真中, MDA-MR 与其他方法对比更为准确, 最高可达 73.44%, 验证了引入分类器加权的必要性。综上可知, 基于 MDA-MR 的滚抛磨块优选模型更充分的利用了每个源域案例集的知识, 为滚抛磨块的选择提供更准确且可信的决策建议。

4 结论

针对多源域迁移学习中传统迁移学习缺乏对多源域的可迁移性的合理分析和迁移效果的有效处理问题, 本文提出了基于流形结构的多源自适应迁移学习方法。通过引入均衡因子和流形正则化提高单源域案例集的适配效率, 并通过对可迁移性进行分析引入分类器加权的思想, 该方法能自适应调节不同源域的迁移水平, 进而提高多源域案例集的迁移效果。通过课题组已搭建的面向用户的滚磨光整加工数据库平台进行对比实验表明该方法迁移效果优于其他算法, 准确率最高可达 73.44%, 能够更好地为滚抛磨块的选择提供有效的建议。

参考文献 (References)

- [1] Zhuang F Z, Qi Z Y, Duan K Y, et al. A Comprehensive Survey on Transfer Learning[J]. Proceedings of the IEEE, 2021, 109(1): 43-76.
- [2] 庄福振, 罗平, 何清, 等. 迁移学习研究进展 [J]. 软件学报, 2015, 26(1): 26-39.
(Zhuang F Z, Luo P, He Q, et al. Survey on transfer learning research[J]. Journal of Software, 2015, 26(1): 26-39.)
- [3] 王洪元, 耿磊, 倪彤光, 等. 知识嵌入的迁移孪生支持向量机 [J]. 控制与决策, 2019, 034(3): 519-526.
(Wang H Y, Geng L, Ni T G, et al. Knowledge embedded transfer twin support vector machine[J]. Control and Decision, 2019, 034(3): 519-526.)
- [4] Nguyen B H, Bing X, Andreae P. A particle swarm optimization based feature selection approach to transfer learning in classification[C]. the Genetic and Evolutionary Computation Conference. 2018: 37-44.
- [5] Pan S J, Tsang I W, Kwok J T, et al. Domain Adaptation via Transfer Component Analysis[J]. IEEE Transactions on Neural Networks, 2011, 22(2): 199-210.
- [6] Long M S, Wang J M, Ding G G, et al. Transfer feature learning with joint distribution adaptation[C]. Int Conf on Computer Vision. New York: IEEE, 2013: 2200-2207.
- [7] Wang J D, Chen Y Q, Hao S J, et al. Balanced distribution adaptation for transfer learning[C]. IEEE International Conference on Data Mining, 2017, 1129-1134.
- [8] 阎高伟, 贺敏, 汤健, 等. 基于最大均值差异多源域迁移学习的湿式球磨机负荷参数软测量 [J]. 控制与决

- 策, 2018, 33(10): 70-75.
(YAN G W, HE M, TANG J, et al. Soft sensor of wet ball mill load based on maximum mean discrepancy multi-source domain transfer learning[J]. Control and Decision, 2018, 33(10): 70-75.)
- [9] 陈佳鲜, 毛文涛, 刘京, 等. 基于深度时序特征迁移的轴承剩余寿命预测方法 [J]. 控制与决策, 2021, 36(07):1699-1706.
(Chen J X, Mao W T, Liu J, et al. Remaining useful life prediction of bearing based on deep temporal feature transfer [J]. Control and Decision, 2021, 36(07):1699-1706.)
- [10] Xue B, Lv Z, Xue J Y. Feature Transfer Learning in EEG-based Emotion Recognition[C]. 2020 Chinese Automation Congress, 2020:3608-3611.
- [11] Li H B, Guo B, Gao T, et al. A Transfer Learning Method of Ship Identification Based on Weighted Hog Features[C]. IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium, 2019: 1302-1305.
- [12] 杨胜强, 李文辉, 李秀红, 等. 高性能零件滚磨光整加工的研究进展 [J]. 表面技术, 2019, 48(10): 13-24.
(Yang S Q, Li W H, Li X H, et al. Research development of mass finishing for high-performance parts[J]. Surface technology, 2019, 48(10): 13-24.)
- [13] 谢盼新, 李文辉, 杨胜强, 等. 齿轮卧式滚磨光整加工方案设计及理论研究 [J]. 现代制造工程, 2017(11): 125-129.
(Xie P X, Li W H, Yang S Q, et al. Technical solution and theoretic research on barrel finishing of gears[J]. Modern manufacturing engineering, 2017(11): 125-129.)
- [14] 闫瑞斌, 田建艳, 杨胜强, 等. 基于迁移学习的滚抛磨块优选模型 [J]. 现代制造工程, 2021(1):75-80.
(Yan R B, Tian J Y, Yang S Q, et al. Optimal model of the abrasive media based on transfer learning[J]. Modern manufacturing engineering, 2021(1):75-80.)
- [15] 杨炎, 高炜, 杨胜强, 等. 基于模糊聚类和案例推理的滚抛磨块优选模型 [J]. 表面技术, 2019, 48(9): 315-320+335.
(Yang Y, Gao W, Yang S Q, et al. Optimal model of the abrasive blocks based on fuzzy clustering and case-based reasoning[J]. Surface technology, 2019, 48(9): 315-320+335.)
- [16] 高炜, 杨胜强, 田建艳, 等. 面向用户的滚磨光整加工数据库平台构建及工序模板设计 [J]. 太原理工大学学报, 2020, 51(2): 234-241.
(Gao W, Yang S Q, Tian J Y, et al. Database System Construction and Process Temperate Design of Barrel Finishing Technology for User Application[J]. Journal of Taiyuan University of Technology, 2020, 51(2): 234-241.)
- [17] Ma J, Wu J, Zhao J, et al. Nonrigid Point Set Registration With Robust Transformation Learning Under Manifold Regularization[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(12):3584-3597.
- [18] 杜永贵, 李思思, 阎高伟, 等. 基于流形正则化域适应湿式球磨机负荷参数软测量 [J]. 化工学报, 2018, 69(3): 1244-1251.
(Du Y G, Li S S, Yan G W, et al. Soft sensor of wet ball mill load parameter based on domain adaptation with manifold regularization[J]. Journal of Chemical Industry and Engineering, 2018, 69(3): 1244-1251.)
- [19] 卞则康, 王士同. 基于相似度学习的多源迁移算法 [J]. 控制与决策, 2017, 32(11): 1941-1948.
(Bian Z K, Wang S T. Similarity-learning based multi-source transfer learning algorithm[J]. Control and Decision, 2017, 32(11): 1941-1948.)
- [20] 任丽红, 赵丽芳. B/S 模式下博物馆馆藏数据库管理系统设计 [J]. 现代电子技术, 2019, 42(15): 157-159, 164.
(Ren L H, Zhao L F. Design of database management system for cultural relics collected in museum under B/S mode[J]. Modern Electronic Technology, 2019, 42(15): 157-159, 164.)
- [21] 范晓建, 田建艳, 杨英波, 等. 基于改进 D-S 证据理论的滚抛磨块融合决策模型 [J]. 表面技术, 2021, 50(4): 393-401.
(Fan X J, Tian J Y, Yang Y B, et al. Fusion Decision Model of Abrasive Media Based on Improved D-S Evidence Theory[J]. Surface Technology, 2021, 50(4): 393-401.)
- [22] 王争强, 李文戈, 杜旭, 等. 激光熔覆技术在轴类零件再制造过程中的应用现状 [J]. 机械工程材料, 2020, 44(11): 35-40.
(Wang Z Q, Li W G, Du X, et al. Applications of Laser Cladding Technique in Remanufacturing of Shaft Part[J]. Materials for Mechanical Engineering, 2020, 44(11): 35-40.)
- [23] Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [24] S. Niu, Y. Liu, J. Wang, H. Song, et al. A Decade Survey of Transfer Learning (2010-2020)[J]. IEEE Transactions on Artificial Intelligence, 2020, 1(2): 151-166.

作者简介

史玉皓(1998—), 男, 硕士生, 从事复杂系统建模与智能监控等研究, E-mail: tyut_shiyuhao@163.com;

田建艳(1966—), 女, 教授, 博士生导师, 从事复杂系统建模与智能监控等研究, E-mail: tut_tianjy@163.com;

刘军军(1984—), 男, 副教授, 硕士生导师, 从事分布参数系统控制等研究, E-mail: liujunjun@tyut.edu.cn;

杨胜强(1964—), 男, 教授, 博士生导师, 从事精密表面光整加工技术等研究, E-mail: tutysq@263.net.cn.