

# 控制与决策

Control and Decision

## 基于DLSR的归纳式迁移学习

姜志彬, 潘兴广, 周洁, 张远鹏, 王士同

引用本文:

姜志彬, 潘兴广, 周洁, 等. 基于DLSR的归纳式迁移学习[J]. 控制与决策, 2021, 36(12): 2982–2990.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0703>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 基于数据分布特性的代价敏感宽度学习系统

Data distribution-based cost-sensitive broad learning system

控制与决策. 2021, 36(7): 1686–1692 <https://doi.org/10.13195/j.kzyjc.2019.1484>

### 基于深度时序特征迁移的轴承剩余寿命预测方法

Remaining useful life prediction of bearing based on deep temporal feature transfer

控制与决策. 2021, 36(7): 1699–1706 <https://doi.org/10.13195/j.kzyjc.2019.1809>

### 基于共享隐空间的多视角SVM

Multi view SVM based on common hidden space

控制与决策. 2021, 36(3): 534–542 <https://doi.org/10.13195/j.kzyjc.2019.0829>

### 基于迁移学习灰支持向量回归机的交互式进化计算

Interactive evolutionary computation based on transfer learning grey support vector regression

控制与决策. 2021, 36(10): 2399–2408 <https://doi.org/10.13195/j.kzyjc.2020.0420>

### 迁移学习引导的变源域长短时记忆网络建筑负荷预测

Load forecasting of buildings using LSTM based on transfer learning with variable source domain

控制与决策. 2021, 36(10): 2328–2338 <https://doi.org/10.13195/j.kzyjc.2020.0215>

# 基于DLSR的归纳式迁移学习

姜志彬<sup>1,2†</sup>, 潘兴广<sup>1,2</sup>, 周洁<sup>1,2</sup>, 张远鹏<sup>3</sup>, 王士同<sup>1,2</sup>

(1. 江南大学 人工智能与计算机学院, 江苏 无锡 214122; 2. 江南大学 江苏省媒体设计与软件技术重点实验室, 江苏 无锡 214122; 3. 南通大学 医学信息学系, 江苏 南通 226019)

**摘要:** 传统机器学习方法的有效性依赖于大量的有效训练数据,而这难以满足,因此迁移学习被广泛研究并成为近年来的研究热门. 针对由于训练数据严重不足导致多分类场景下分类性能降低的挑战,提出一种基于DLSR(discriminative least squares regressions)的归纳式迁移学习方法(TDLSR). 该方法从归纳式迁移学习出发,通过知识杠杆机制,将源域知识迁移到目标域并同目标域数据同时进行模型学习,在提升分类性能的同时保证源域数据的安全性. TDLSR继承了DLSR在多分类任务中扩大类别间间隔的优势,为DLSR注入了迁移能力以适应数据不足的挑战,更加适用于复杂的多分类任务. 通过在12个真实UCI数据集上进行实验,验证了所提出方法的有效性.

**关键词:** 多分类; DLSR; 归纳式迁移学习; 知识杠杆机制; 安全性

中图分类号: TP391

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0703

开放科学(资源服务)标识码(OSID):



引用格式: 姜志彬,潘兴广,周洁,等. 基于DLSR的归纳式迁移学习[J]. 控制与决策, 2021, 36(12): 2982-2990.

## DLSR based inductive transfer learning method

JIANG Zhi-bin<sup>1,2†</sup>, PAN Xing-guang<sup>1,2</sup>, ZHOU Jie<sup>1,2</sup>, ZHANG Yuan-peng<sup>3</sup>, WANG Shi-tong<sup>1,2</sup>

(1. School of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi 214122, China; 2. Jiangsu Key Laboratory of Digital Design and Software Technology, Jiangnan University, Wuxi 214122, China; 3. Department of Medical Informatics, Nantong University, Nantong 226019, China)

**Abstract:** Since the effectiveness of traditional machine learning methods depends on a large amount of effective training data and it is difficult to satisfy, transfer learning has been widely studied and become a hot research in recent years. In order to meet the challenge that the classification performance is degraded due to the serious shortage of training data in current multiclass classification scenarios, a discriminative least squares regressions (DLSR) based inductive transfer learning method (TDLSR) is proposed. The proposed method starts with inductive transfer learning, and transfers knowledge from source domain to target domain through knowledge leverage mechanism. It combines the knowledge of source domain and data in target domain for model learning, which improves classification performance and ensures the security of source domain data. The TDLSR inherits the advantage of the DLSR, which is better applicable to multiclass classification tasks by enlarging the distance between different classes, and injects transfer ability for the DLSR to adapt to the challenge of training data shortage. It can be well applied to various complex multiclass classification tasks. Experiments on 12 real UCI datasets verify the effectiveness of the proposed method.

**Keywords:** multiclass classification; DLSR; inductive transfer learning; knowledge leverage mechanism; security

## 0 引言

传统机器学习方法的有效性通常建立在有效训练数据充足的基础上. 然而在实际应用中,训练数据的采集往往存在巨大困难,因此许多场景无法保证大量的有效训练数据. 鉴于此,迁移学习<sup>[1-2]</sup>应运而生. 由于其有效性,一直受到广大学者的持续关注,并就此成为了机器学习领域的重要分支之一<sup>[3-4]</sup>. 迁移

学习是一种新颖的学习策略,主要应用于训练数据不足或信息不充分的场景,通过对相关领域知识的学习并迁移至当前领域,从而构建学习模型,以弥补当前场景训练数据不足对构建高质量模型的阻碍. 迁移学习在新生事物的诞生初期尤其能够展现出对模型精度和泛化性能上的独特优势.

近年来,机器学习领域不断涌现出关于迁移学

收稿日期: 2020-06-04; 修回日期: 2020-10-18.

基金项目: 国家自然科学基金项目(61772198, 61772239, 81701793).

责任编辑: 胡清华.

†通讯作者. E-mail: jnuszmtjzb@163.com.

习的研究,其中包含很多适用不同场景的迁移学习方法<sup>[5-12]</sup>,例如:迁移SVM(support vector machine)算法<sup>[6-7]</sup>,迁移Adaboost算法<sup>[8-9]</sup>,以及基于流形结构的MMD(maximum mean discrepancy)算法<sup>[10-11]</sup>等.根据文献[5],迁移学习方法大致可以分为3大类:归纳式(inductive)迁移方法<sup>[13]</sup>、直推式(transductive)迁移方法<sup>[14]</sup>和无监督(unsupervised)迁移方法<sup>[15]</sup>.当然,也可以根据迁移内容将上述3大类方法分为如下4类:基于样本(instance-based)迁移方法<sup>[16]</sup>、基于特征(feature-based)迁移方法<sup>[17]</sup>、基于参数(parameter-based)迁移方法<sup>[18]</sup>和基于关系-知识(relation-knowledge-based)迁移方法<sup>[19]</sup>.本文主要关注归纳式迁移学习方法,并受Deng等<sup>[20]</sup>的启发,利用一种知识杠杆机制,从源域中迁移知识并结合目标域的数据用于学习模型,从而在保证性能的基础上更好地保护源域数据的安全性.由于基于知识杠杆的归纳式迁移学习方法使用的是源域获得的知识(如相应的模型参数),而不是直接使用源域的数据,所提出的方法在保护源域数据的安全性方面具有独特的优势,尤其是涉及数据隐私保护的场景(如医学辅助诊断等)<sup>[13]</sup>.众所周知,多分类任务在分类领域一直是十分重要的研究方向,被广泛关注.然而关于迁移学习在多分类任务上的研究依然不够充分,无法满足实际需要.因此,本文针对多分类任务进行归纳式迁移学习研究.

LSR(least squares regression)因其对数据分析的有效性以及相关统计理论的完整性,成为机器学习和模式识别领域的一个典型方法,已被广泛研究及应用<sup>[21]</sup>.目前已有很多基于LSR的方法被提出,包括WLSR(weight least squares regressions)<sup>[22]</sup>、DLSR(discriminative least squares regressions)<sup>[21]</sup>和RLR(regularized linear regression)<sup>[23]</sup>等,这些方法在半监督学习、多任务学习、多分类学习等机器学习任务上得到了广泛的应用<sup>[21]</sup>,并展现出较好的适应性.其中,在多分类学习领域,DLSR通过增大不同类之间的间隔得到更好的适应性和泛化性,因此被广泛关注.然而,当前场景训练数据严重不足,会导致DLSR无法得到有效模型,无法保证分类性能.本文注意到DLSR在常规场景中的有效性,在其基础上提出了基于DLSR的归纳式迁移学习方法(DLSR based inductive transfer learning method, TDLSR),以应对训练数据严重不足带来的挑战.通过在12个真实UCI数据集上进行的实验验证该方法的有效性,表明其能够适用训练数据不足的场景.本文的贡献主要体现在

在以下几个方面:

1) 本文方法基于归纳式迁移学习的框架提出,且利用知识杠杆机制,将从源域迁移的知识与目标域数据相结合进行模型学习.它并非直接从源域利用样本或特征到目标域进行迁移学习,因而在保证性能的基础上能很好地保护源域数据的安全性.

2) 本文方法以DLSR为基础探讨迁移学习,将能够适用于多分类任务的DLSR拓展成具有一定迁移学习能力的新方法,不仅继承了DLSR的特性,而且能够很好地适用于训练数据严重不足等更加复杂的多分类场景.

### 1 方法实现

基于知识杠杆的归纳式迁移学习的基本原理如图1所示.

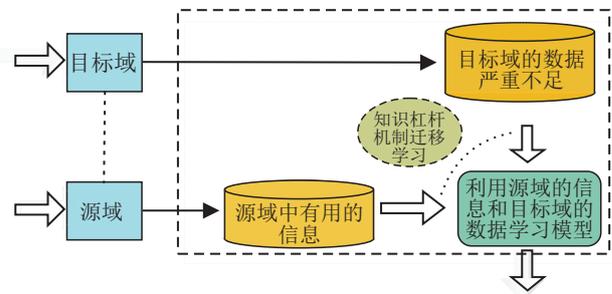


图1 基于知识杠杆的归纳式迁移学习基本原理

#### 1.1 discriminative least squares regressions (DLSR)

对于多分类任务,定义 $n$ 个 $d$ 维样本及其类标(即 $\{(x_i, y_i)\}_{i=1}^n$ ,其中 $x_i \in \mathbf{R}^d, y_i \in \{1, 2, \dots, c\}$ ),可根据类别信息构造对应的二进制标签矩阵 $Y$ .以具有4个类的数据集的5个样本为例,假设5个样本的类标分别为4, 2, 3, 1, 2,则二进制标签矩阵 $Y$ 定义如下:

$$Y = \begin{bmatrix} 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}. \quad (1)$$

$Y$ 中第 $i$ 行表示第 $i$ 个样本,第 $j$ 列对应第 $j$ 类.当第 $i$ 个样本属于第 $j$ 类时,该位置元素为1,其余位置元素均为0.

对于上述二进制类标矩阵 $Y$ ,任意两类之间的间隔均为 $\sqrt{2}$ .为了扩大类别间的间隔,文献[21]所提出的DLSR,将 $\varepsilon$ 松弛引入LSR,并考虑多类情况,提供了一种针对多分类任务的紧凑优化模型.具体做法是构建一个指示矩阵 $B$ ,每个元素 $B_{ij}$ 被定义如下:

$$B_{ij} = \begin{cases} 1, & y_i = j; \\ -1, & \text{otherwise.} \end{cases} \quad (2)$$

矩阵  $B$  的每一个元素表示该样本  $i$  对应的类标偏移方向。

根据指示矩阵,对  $Y$  的每一个元素进行  $\varepsilon$  松弛,并将松弛量  $\varepsilon$  存储在矩阵  $M$  中.由此,得出 DLSR 的目标函数

$$\begin{aligned} \min_{A,t} \|XA + e_n t^T - (Y + B \odot M)\|_F^2 + \lambda \|A\|_F^2; \\ \text{s.t. } M \geq 0. \end{aligned} \quad (3)$$

其中:  $X$  为训练数据集,  $Y$  为对应二进制标签矩阵;  $A$  为映射矩阵,  $t$  为映射偏移矢量,  $B$  和  $M$  分别为指示矩阵和松弛量矩阵;  $e_n = [1, 1, \dots, 1]^T \in \mathbf{R}^n$  为全是 1 的向量,  $\odot$  为 Hadamard 运算符,  $\lambda$  为正则化参数.

虽然 DLSR 是凸优化问题,但是却无法直接优化求解.文献[21]提供了一种求解思路,利用交替优化策略,并保证每一步都得到一个闭式解,具体如下:

1) 先固定  $M$ , 然后求解  $t$  和  $A$ . 给定  $M$ , 令  $D = Y + B \odot M$ , 式(3)可以重写为

$$J(A, t) = \arg \min_{A,t} \|XA + e_n t^T - D\|_F^2 + \lambda \|A\|_F^2. \quad (4)$$

根据最优化理论,对  $t$  求偏导,有

$$\begin{aligned} \frac{\partial J(A, t)}{\partial t} = 0 \Rightarrow \\ A^T X^T e_n + t e_n^T e_n - D^T e_n = 0 \Rightarrow \\ t = \frac{(D^T e_n - A^T X^T e_n)}{n}. \end{aligned} \quad (5)$$

进而,类似地,有

$$\begin{aligned} \frac{\partial J(A)}{\partial A} = 0 \Rightarrow \\ 2X^T X A - 2X^T (e_n t^T - D) + 2\lambda A = 0 \Rightarrow \\ X^T X A - X^T \left( e_n \frac{(e_n^T D - e_n^T X A)}{n} - D \right) + \lambda A = 0 \Rightarrow \\ X^T \left( I_n - \frac{e_n e_n^T}{n} \right) X A - X^T \left( I_n - \frac{e_n e_n^T}{n} \right) D + \lambda A = 0 \Rightarrow \\ A = (X^T H X + \lambda I_d)^{-1} X^T H D. \end{aligned} \quad (6)$$

2) 固定  $A$  和  $t$ , 然后求解  $M$ . 给定  $A$  和  $t$ , 令  $P = XA + e_n t^T - Y$ ,  $M$  可以从以下优化问题中求解得到:

$$\begin{aligned} \arg \min_M \|P - B \odot M\|_F^2; \\ \text{s.t. } M \geq 0. \end{aligned} \quad (7)$$

由于矩阵的  $F$ -范数元素可以逐个进行求解,式(7)可以看作求解  $n \times c$  个子问题,每一个子问题为求解元素  $M_{ij}$ , 即

$$\begin{aligned} \min_{M_{ij}} (P_{ij} - B_{ij} M_{ij})^2; \\ \text{s.t. } M_{ij} \geq 0. \end{aligned} \quad (8)$$

其中:  $P_{ij}$  和  $B_{ij}$  分别为矩阵  $P$  和  $B$  的第  $i$  行的第  $j$  个元素,  $B_{ij}^2 = 1$ . 因此有

$$(P_{ij} - B_{ij} M_{ij})^2 = (B_{ij} P_{ij} - M_{ij})^2. \quad (9)$$

又因为  $M$  的每一个元素  $M_{ij} \geq 0$ , 所以由式(9)可得

$$M_{ij} = \max(B_{ij} P_{ij}, 0). \quad (10)$$

式(7)中的  $M$  最终可以通过下式求解:

$$M = \max(B \odot P, 0). \quad (11)$$

### 算法1 DLSR算法.

输入: 训练样本  $X = [x_1, x_2, \dots, x_n] \in \mathbf{R}^{n \times d}$  及其对应的类标  $y_i \in \{1, 2, \dots, c\}, i = 1, 2, \dots, n$ , 其中  $x_i \in \mathbf{R}^d (i = 1, 2, \dots, n)$ , 最大迭代次数  $S$ .

输出: 映射矩阵  $A$  和映射偏移向量  $t$ .

step 1: 根据式(1)和(2)分别构建类标矩阵  $Y$  和相应的指示矩阵  $B$ ;

step 2: 初始化  $A' = 0, t = 0, M = 0$ , 设置参数  $\lambda, s = 1$ ;

step 3: 计算  $R = (X^T H X + \lambda I_d)^{-1} X^T H$ ;

循环:

step 4: 计算类标矩阵  $D = Y + B \odot M$ ;

step 5: 根据式(5)和(6)分别计算  $t$  和  $A$ ;

step 6: 计算  $P = XA + e_n t^T - Y$ ;

step 7: 根据式(11)计算类标松弛矩阵  $M$ ;

step 8: 更新  $A' = A$  和  $s = s + 1$ , 直到  $\|A' - A\|_F^2 \leq 10^{-4}$  或  $s > S$ .

## 1.2 基于DLSR的归纳式迁移学习方法

大多数归纳式迁移学习方法均直接从源域数据中学习. Deng 等<sup>[20]</sup>采用了一种特别的方法,即利用知识的迁移来替代原始数据以实现归纳式迁移学习.这种方法能够实现目标域数据和源域知识的结合,共同构建目标域的模型.受其启发,本文针对多类分类任务面临的挑战,结合 DLSR 和迁移学习,提出了一种基于 DLSR 的归纳式迁移学习方法 (TDLSR).

### 1.2.1 TDLSR的目标函数

根据基于知识的归纳式迁移学习框架以及前述 DLSR, 可以得到 TDLSR 的目标函数如下:

$$\begin{aligned} \min_{A_T, t_T} \|X_T A_T + e_{N_T} t_T^T - (Y_T + B_T \odot M_T)\|_F^2 + \\ \lambda \|A_T\|_F^2 + \beta \|A_T - A_S\|_F^2; \\ \text{s.t. } M_T \geq 0. \end{aligned} \quad (12)$$

其中:  $X_T \in \mathbf{R}^{N_T \times d}$  和  $Y_T$  分别为目标域的训练数据集和对应的二进制标签矩阵,  $A_T$  和  $t_T$  分别表示目标域的映射矩阵和映射偏移矢量, 而  $B_T$  和  $M_T$  分

别表示目标域的指示矩阵和松弛量矩阵,  $A_S$  是利用 DLSR 从源域中求得的映射矩阵,  $e_{N_T} = [1, 1, \dots, 1]^T$  是对应目标域训练集全为 1 的列向量,  $\lambda$  和  $\beta$  是给定的正则化参数.

从 TDLSR 的目标函数可以看出, 前两项是利用 DLSR 思想, 对目标域样本进行映射和学习, 第 3 项用于源域知识  $A_S$  从源域到目标域的迁移. 由此可以看出, TDLSR 是一种利用源域知识而非直接利用源域数据的归纳式迁移学习方法, 且能够同时利用目标域数据和源域知识构建目标域模型.

比较式 (3) 和 (12), 可以看出式 (3) 是 (12) 的一个特例 (当  $\beta = 0$  时), 此时, TDLSR (即式 (12)) 退化为 DLSR (即式 (3)). 因而, TDLSR 是一种基于 DLSR 的知识归纳式迁移学习方法, 它在 DLSR 的基础上增加了对源域知识的迁移和利用, 较 DLSR 具有更好的适用性.

对于参数  $\beta$ , 当  $\beta \neq 0$  时, TDLSR 可以从源域获取知识用于模型学习. 如果迁移的知识是负迁移, 则可以调节  $\beta$  无限接近 0 以避免负迁移; 如果迁移的知识是正迁移, 则可以适当调大  $\beta$  以增加迁移的知识对目标函数的作用. 因此, 通过适当调节正则化参数  $\beta$ , 能够保证 TDLSR 从源域中迁移有用的知识用于目标学习, 保证迁移学习的可行性.

### 1.2.2 优化求解

显然, TDLSR 也是一个凸优化问题且无法直接优化求解. 因此, 本文采用类似 DLSR 的交替优化方法进行求解. 具体如下:

1) 先固定  $M_T$ , 然后求解  $t_T$  和  $A_T$ . 给定  $M_T$ , 并令  $D_T = Y_T + B_T \odot M_T$ , 则式 (12) 可以重写为

$$J(A_T, t_T) = \arg \min_{A_T, t_T} \|X_T A_T + e_{N_T} t_T^T - D_T\|_F^2 + \lambda \|A_T\|_F^2 + \beta \|A_T - A_S\|_F^2. \quad (13)$$

根据最优化理论, 对  $t_T$  求偏导, 即

$$\begin{aligned} \frac{\partial J(A_T, t_T)}{\partial t_T} = 0 &\Rightarrow \\ A_T^T X_T^T e_{N_T} + t_T e_{N_T}^T e_{N_T} - D_T^T e_{N_T} = 0 &\Rightarrow \\ t_T = \frac{(D_T^T e_{N_T} - A_T^T X_T^T e_{N_T})}{N_T}. &\quad (14) \end{aligned}$$

进而, 类似地, 有

$$\begin{aligned} \frac{\partial J(A_T)}{\partial A_T} = 0 &\Rightarrow \\ 2X_T^T X_T A_T - 2X_T^T (e_{N_T} t_T^T - D_T) + 2\lambda A_T + & \\ 2\beta(A_T - A_S) = 0 &\Rightarrow \\ X_T^T X_T A_T - X_T^T \left( e_{N_T} \frac{(e_{N_T}^T D_T - e_{N_T}^T X_T A_T)}{N_T} - D_T \right) + & \end{aligned}$$

$$\begin{aligned} \lambda A_T + \beta(A_T - A_S) = 0 &\Rightarrow \\ X_T^T \left( I_{N_T} - \frac{e_{N_T} e_{N_T}^T}{N_T} \right) X_T A_T + (\lambda + \beta) A_T - & \\ \beta A_S - X_T^T \left( I_{N_T} - \frac{e_{N_T} e_{N_T}^T}{N_T} \right) D_T = 0 &\Rightarrow \\ A_T = (X_T^T H_T X_T + (\lambda + \beta) I_d)^{-1} (X_T^T H_T D_T + \beta A_S). &\quad (15) \end{aligned}$$

2) 再固定  $A_T$  和  $t_T$ , 求解  $M_T$ . 给定  $A_T$  和  $t_T$ , 令  $P_T = X_T A_T + e_{N_T} t_T^T - Y_T$ , 则  $M_T$  可以从以下优化问题中求解得到:

$$\begin{aligned} \arg \min_{M_T} \|P_T - B_T \odot M_T\|_F^2; \\ \text{s.t. } M_T \geq 0. \end{aligned} \quad (16)$$

类似 DLSR 中  $M$  的求解方式, 式 (16) 中的  $M_T$  最终可以根据下式求解:

$$M_T = \max(B_T \odot P_T, 0). \quad (17)$$

### 1.2.3 算法描述

根据上一节的推导, 本小节给出 TDLSR 的算法描述.

输入: 根据算法 1 从源域中得到的知识  $A_S$ ; 目标域训练样本  $X_T = [x_1, x_2, \dots, x_{N_T}] \in \mathbf{R}^{N_T \times d}$ , 及其对应类标  $y_i \in \{1, 2, \dots, c\}$ ,  $i = 1, 2, \dots, N_T$ , 其中  $x_i \in \mathbf{R}^d$ ,  $i = 1, 2, \dots, N_T$ ; 最大迭代次数  $S$ .

输出: 目标域的映射矩阵  $A_T$  和映射偏移向量  $t_T$ .

step 1: 根据式 (1) 和 (2) 分别构建类标矩阵  $Y_T$  和相应的指示矩阵  $B_T$ ;

step 2: 初始化目标域的  $A'_T = 0$ ,  $t'_T = 0$  和  $M_T = 0$ . 设置参数  $\lambda$ ,  $\beta$  和  $s = 1$ ;

step 3: 分别计算

$$\begin{aligned} R &= (X_T^T H_T X_T + (\lambda + \beta) I_d)^{-1} X_T^T H_T, \\ U &= \beta (X_T^T H_T X_T + (\lambda + \beta) I_d)^{-1} A_S. \end{aligned}$$

循环:

step 4: 计算类标矩阵  $D_T = Y_T + B_T \odot M_T$ ;

step 5: 根据式 (14) 和 (15) 分别计算  $t_T$  和  $A_T$ ;

step 6: 计算  $P_T = X_T A_T + e_{N_T} t_T^T - Y_T$ ;

step 7: 根据式 (17) 计算类标松弛矩阵  $M_T$ ;

step 8: 更新  $A'_T = A_T$  和  $s = s + 1$ , 直到  $\|A'_T - A_T\|_F^2 \leq 10^{-4}$  或  $s > S$ .

## 2 实验研究

本文使用了 12 个真实 UCI 数据集对 TDLSR 进行实验以验证其算法性能, 并将 TDLSR 算法与 SVM<sup>[24]</sup>、KNN<sup>[25]</sup>、LSR<sup>[26]</sup>、DLSR<sup>[21]</sup>、RLR<sup>[23]</sup> 和 TrAdaboost<sup>[8]</sup> 方法进行比较, 给出实验结果和分析.

2.1 实验设置

2.1.1 实验数据

本节采用了12个UCI真实数据集<sup>[27]</sup>,表1中列出了其详细信息.

表1 所有数据集的详细信息

| 数据集       | 特征数 | 类别数 | 样本个数  |
|-----------|-----|-----|-------|
| Ecoli1    | 7   | 5   | 327   |
| Glass     | 9   | 6   | 216   |
| Iris      | 4   | 3   | 150   |
| Landsat   | 36  | 6   | 2000  |
| Led24     | 24  | 10  | 3200  |
| Letter    | 16  | 26  | 5000  |
| Penbased  | 16  | 10  | 10000 |
| Pendigits | 16  | 10  | 7494  |
| Segment   | 18  | 7   | 2310  |
| Texture   | 40  | 11  | 5500  |
| Vowel     | 10  | 11  | 528   |
| Wine      | 13  | 3   | 178   |

为了对TDLSR在多分类问题不同场景下的适应性进行探究,在本节的实验设置中对真实数据集进行了不同的处理,以构建更多场景对TDLSR及对比方法进行实验.首先,将所有数据集按照70%为源域、30%为目标域的比例划分,并对源域数据进行旋转或加噪处理,以构建与目标域不同的数据分布.然后,按照样本个数是否超过3000将数据集划分为两

组并分别设置目标域数据用于实验.具体为:第1组为样本个数小于3000的Ecoli1、Glass、Iris、Landsat、Segment、Vowel和Wine数据集,将目标域数据按照20%训练集和80%测试集进行划分用于实验;第2组为样本个数大于3000的Led24、Letter、Penbased、Pendigits和Texture数据集,随机从目标域的每个类别分别选取5、10和15个样本作为训练集,其余样本作为测试集用于实验.

2.1.2 评价指标

采用两种常用的多分类指标对实验结果进行评价,分别定义如下:

$$Accuracy = \frac{\text{分类正确的样本个数}}{\text{测试样本总数}} \times 100\%, \quad (18)$$

$$MacroF\text{-score} = \frac{\sum_{i=1}^C F\text{-score}_i}{C} \times 100\%. \quad (19)$$

其中: $C$ 代表类别数; $F\text{-score}_i$ 代表第 $i$ 个类的 $F\text{-score}$ .

2.1.3 参数设置

TDLSR算法与6种对比方法均进行了参数设置.其中SVM和TrAdaboost采用高斯核( $K(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / 2\sigma^2)$ )进行实验.所有方法均采用网格搜索策略以确定最优参数,具体的参数及范围在表2中给出.

表2 各方法的参数及范围

| 方法         | 参数及范围   |
|------------|---|
| SVM        | 正则化参数 $C \in \{2^{-6}, 2^{-5}, \dots, 2^0, 2^1, \dots, 2^5, 2^6\}$ ; 高斯核宽 $\sigma \in \{2^{-6}, 2^{-5}, \dots, 2^0, 2^1, \dots, 2^5, 2^6\}$ |
| KNN        | 正则化参数 $k \in \{2, 3, 4, 5, 6, 7, 8, 9, 10\}$  |
| LSR        | 正则化参数 $\lambda \in \{0.0001, 0.001, 0.01, 0.1, 1.0, 10.0, 100.0\}$  |
| DLSR       | 正则化参数 $\lambda \in \{0.0001, 0.001, 0.01, 0.1, 1.0, 10.0, 100.0\}$  |
| RLR        | 正则化参数 $\lambda \in \{0.0001, 0.001, 0.01, 0.1, 1\}$ , $\sigma \in \{2^{-6}, 2^{-5}, \dots, 2^0, 2^1, \dots, 2^5, 2^6\}$                     |
| TrAdaboost | 正则化参数 $C \in \{2^{-6}, 2^{-5}, \dots, 2^0, 2^1, \dots, 2^5, 2^6\}$ , 高斯核宽 $\sigma \in \{2^{-6}, 2^{-5}, \dots, 2^0, 2^1, \dots, 2^5, 2^6\}$ |
| TDLSR      | 正则化参数 $\lambda \in \{0.0001, 0.001, 0.01, 0.1, 1.0, 10.0, 100.0\}$ , $\beta \in \{0.0001, 0.001, 0.01, 0.1, 1.0, 10.0, 100.0\}$             |

2.2 实验结果与分析

为了使实验结果公正,所有实验均重复20次,并将实验结果按照分好的两组进行分别展示.对于第1组数据集的Accuracy和Macro  $F\text{-score}$ 以图像的形式直接展示,如图2和图3所示.对于另一组的实验,给出所有方法在各数据集上对应指标的均值和标准差,并且将最好的结果加粗显示,结果如表3和表4所示.

根据图2和图3,可以得出如下的观察:

1)整体上看,无论是Accuracy还是Macro  $F\text{-score}$ ,在第1组数据集上,TDLSR的表现最优,而KNN的效

果最差.这是由于迁移能够弥补样本不足的劣势,通过对源域知识的迁移能够提升目标域的分类性能.

2)具体分析第1组中每个数据集的结果时,在指标Accuracy上,TDLSR除在Vowel、Landsat数据集的表现稍逊色于TrAdaboost,其余均表现最佳;而在指标Macro  $F\text{-score}$ 上,TDLSR除在Ecoli1、Vowel上结果为次优外,均为最优结果.这表明TDLSR分类性能好,尤其是较LSR的相关方法具有更优的性能表现.

3)对比TDLSR和DLSR的结果指标可以看出,其性能比DLSR有很大提高.这是由于迁移学习的引

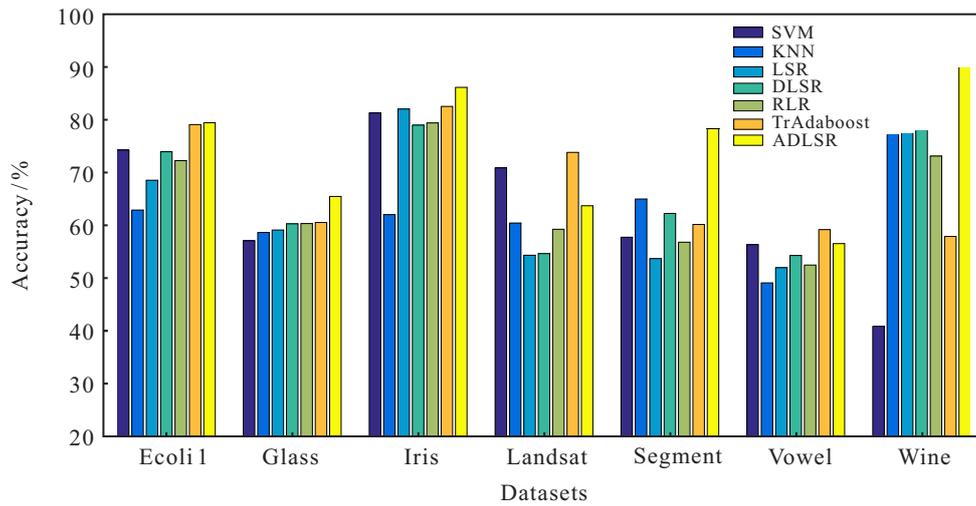


图2 所有方法在第1组数据集上的实验结果 (accuracy)

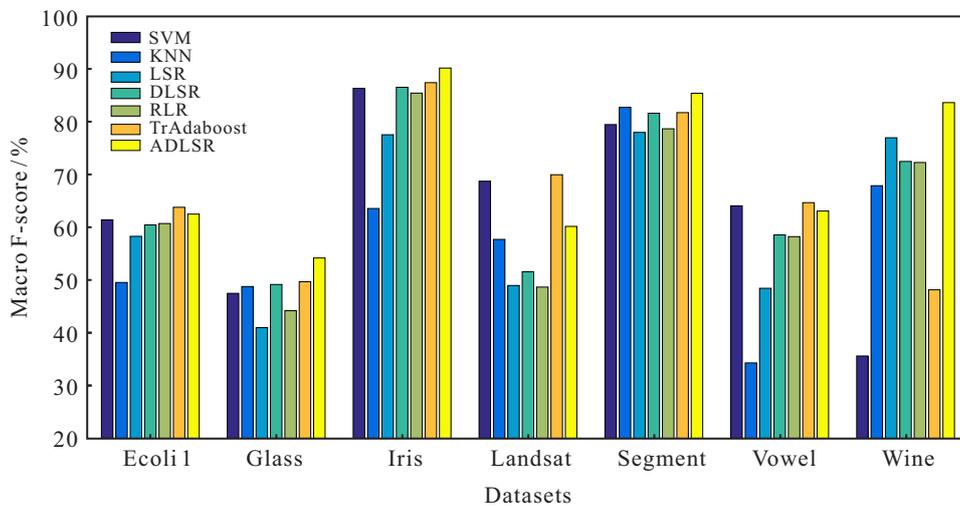


图3 所有方法在第1组数据集上的实验结果 (Macro F-score)

入,对目标域添加了源域迁移的知识,对目标域分类器构建有正面作用.类似地,TrAdaboost作为一种基于SVM的归纳式迁移学习方法,其性能相比SVM也有较大提高.

4)观察LSR、DLSR、RLR和TDLSR的结果可以发现,后3种方法较LSR的性能都有不同程度的提高.这是由于,这3种方法均从LSR出发并作出改进,增大了不同类之间的间隔,从而获得了更好的性能.而TDLSR效果在这4种方法中最优,其原因是它不仅增大了类间间隔而且引入了对源域的知识迁移.

根据表3和表4的实验结果,可以得出如下的观察:

1)总体来看,从两个指标的平均值和标准差可以发现,在第2组数据集上,TDLSR的性能依然是最好的,而SVM的效果最差.这表明在较大数据集上,当遭遇训练样本严重不足时,传统分类器性能普遍变差.但TDLSR具有迁移学习的优点,能够利用源域迁移的知识弥补训练数据不足的劣势.

2)TDLSR在5个实验数据集的不同个数目标域训练样本的实验中均能获得不错效果.逐个分析每一个数据集,TDLSR在数据集(Led 24, Penbased和Texture)上的部分Accuracy结果略逊色于TrAdaboost或KNN;而在数据集Led 24、Penbased、Pendigits和Texture上的部分Macro F-score指标未达到最优结果,尽管如此,TDLSR在这些数据集上的性能比其他方法都好.

3)对于第2组数据集,本文通过设置目标域每个类的不同个数训练样本来构建不同的场景进行实验,以观察不同个数的目标域训练样本对各种方法性能的影响.显然,在同一数据集上,随着目标域训练样本的增多,各个方法的性能均有不同程度的提升.由此可以看出,训练样本个数对方法性能影响巨大,且体现了在样本不足时迁移学习的重要性.其中TDLSR由于其具有迁移学习的优势,在样本个数很少时,性能表现仍旧不错.

表3 所有方法在第2组数据集上的实验结果(Accuracy)

%

| 数据集       |    | SVM        | KNN               | LSR        | DLSR       | RLR        | TrAdaboost        | TDLSR               |
|-----------|----|------------|-------------------|------------|------------|------------|-------------------|---------------------|
| Led 24    | 5  | 56.45±0.60 | 53.27±0.34        | 44.57±0.53 | 48.36±0.19 | 48.93±0.13 | <b>57.89±0.55</b> | 53.28±0.33          |
|           | 10 | 67.53±0.47 | 62.72±0.38        | 66.71±0.38 | 69.35±0.28 | 68.90±0.20 | 71.58±0.46        | <b>77.9415±0.31</b> |
|           | 15 | 69.67±0.50 | 64.61±0.31        | 79.73±0.27 | 80.15±0.20 | 81.73±0.17 | 72.20±0.43        | <b>85.48±0.31</b>   |
| Letter    | 5  | 60.29±0.70 | 59.99±0.91        | 65.74±0.23 | 68.66±0.12 | 69.16±0.33 | 64.13±1.28        | <b>71.62±0.28</b>   |
|           | 10 | 63.12±0.64 | 64.98±0.80        | 79.84±0.55 | 80.79±0.59 | 80.13±0.56 | 68.74±0.77        | <b>81.80±0.42</b>   |
|           | 15 | 70.03±0.34 | 69.34±0.82        | 80.79±0.43 | 81.79±0.23 | 81.39±0.48 | 71.80±0.87        | <b>89.98±0.29</b>   |
| Penbased  | 5  | 14.42±0.72 | <b>90.41±0.79</b> | 83.93±0.70 | 86.33±0.82 | 85.87±0.86 | 31.14±1.08        | 87.69±0.88          |
|           | 10 | 16.76±0.97 | <b>92.35±0.42</b> | 87.50±0.67 | 87.32±0.98 | 87.06±0.64 | 35.95±0.56        | 89.71±0.52          |
|           | 15 | 20.03±0.53 | <b>93.06±0.94</b> | 88.68±0.78 | 89.12±0.73 | 90.29±0.38 | 37.83±0.63        | 90.29±0.44          |
| Pendigits | 5  | 17.05±0.65 | 85.14±0.43        | 85.89±0.70 | 84.71±0.39 | 83.95±0.46 | 17.52±0.69        | <b>88.89±0.44</b>   |
|           | 10 | 21.46±1.04 | 91.37±0.71        | 87.28±0.67 | 87.83±0.62 | 87.48±0.98 | 29.48±1.15        | <b>91.79±0.53</b>   |
|           | 15 | 21.59±0.82 | 91.35±1.02        | 90.10±0.54 | 91.90±0.65 | 91.53±0.86 | 31.72±1.08        | <b>92.98±0.46</b>   |
| Texture   | 5  | 85.62±0.69 | 68.20±0.26        | 81.17±0.42 | 84.80±0.38 | 83.75±0.67 | 89.92±0.68        | <b>90.21±0.27</b>   |
|           | 10 | 88.67±0.82 | 71.22±0.59        | 83.88±0.98 | 86.77±0.58 | 85.15±1.90 | <b>91.87±1.43</b> | 91.33±0.15          |
|           | 15 | 90.27±0.53 | 73.03±0.23        | 84.62±0.30 | 88.17±0.25 | 86.04±0.37 | <b>94.05±1.04</b> | 93.94±0.28          |
| Ave.Acc   |    | 50.86      | 75.4              | 79.36      | 81.07      | 80.76      | 57.72             | <b>85.13</b>        |
| Ave.Std   |    | 0.67       | 0.6               | 0.54       | 0.47       | 0.6        | 0.85              | <b>0.39</b>         |

表4 所有方法在第2组数据集上的实验结果(MacroF-score)

%

| 数据集              |    | SVM               | KNN               | LSR        | DLSR       | RLR        | TrAdaboost | TDLSR             |
|------------------|----|-------------------|-------------------|------------|------------|------------|------------|-------------------|
| Led 24           | 5  | <b>35.39±0.22</b> | 33.20±0.28        | 32.01±0.33 | 32.54±0.26 | 31.84±0.25 | 35.30±0.43 | 33.35±0.27        |
|                  | 10 | 50.15±0.36        | 50.62±0.35        | 51.15±0.32 | 52.47±0.39 | 52.19±0.47 | 52.04±0.79 | <b>57.89±0.42</b> |
|                  | 15 | 53.68±0.29        | 52.93±0.14        | 63.66±0.16 | 63.54±0.17 | 63.81±0.17 | 54.09±0.25 | <b>64.15±0.32</b> |
| Letter           | 5  | 51.13±0.88        | 50.61±0.78        | 51.82±0.49 | 53.57±0.31 | 58.31±0.95 | 51.58±0.91 | <b>58.38±0.43</b> |
|                  | 10 | 52.36±0.50        | 52.30±0.63        | 61.05±0.42 | 63.07±0.22 | 63.10±0.84 | 53.60±0.63 | <b>63.13±0.51</b> |
|                  | 15 | 53.65±0.51        | 53.97±0.34        | 62.40±0.36 | 63.41±0.29 | 63.23±0.67 | 54.78±0.74 | <b>64.70±0.24</b> |
| Penbased         | 5  | 16.05±0.95        | <b>73.17±0.85</b> | 62.61±0.53 | 64.02±0.75 | 63.84±0.66 | 32.36±0.59 | 68.60±0.90        |
|                  | 10 | 20.11±1.09        | <b>75.47±0.84</b> | 68.23±0.78 | 67.69±0.90 | 67.62±0.83 | 38.45±1.07 | 69.50±0.67        |
|                  | 15 | 22.66±0.69        | <b>76.79±0.70</b> | 68.65±0.92 | 71.96±0.93 | 71.87±1.03 | 39.67±0.78 | 71.81±0.69        |
| Pendigits        | 5  | 18.45±0.16        | 63.56±0.13        | 63.21±0.16 | 63.48±0.18 | 63.06±0.16 | 20.75±0.57 | <b>68.18±0.15</b> |
|                  | 10 | 20.11±0.24        | <b>76.39±0.33</b> | 68.50±0.25 | 68.61±0.22 | 68.44±0.23 | 30.81±0.68 | 76.09±0.29        |
|                  | 15 | 21.17±0.14        | <b>76.33±0.27</b> | 74.21±0.17 | 76.91±0.49 | 76.84±0.14 | 32.82±0.75 | 76.69±0.24        |
| Texture          | 5  | 70.60±0.70        | 54.90±0.62        | 62.42±0.46 | 63.43±0.47 | 62.82±0.59 | 70.89±0.80 | <b>71.83±0.30</b> |
|                  | 10 | <b>73.58±0.90</b> | 57.68±0.54        | 63.36±0.44 | 67.41±0.69 | 65.96±0.64 | 71.56±1.02 | 72.02±0.22        |
|                  | 15 | <b>75.32±0.46</b> | 60.77±0.62        | 65.00±0.44 | 71.69±0.59 | 69.86±0.47 | 73.23±0.92 | 73.36±0.23        |
| Ave.MacroF-score |    | 42.29             | 60.58             | 61.22      | 62.92      | 62.85      | 47.46      | <b>65.98</b>      |
| Ave.Std          |    | 0.54              | 0.49              | 0.42       | 0.46       | 0.54       | 0.73       | <b>0.39</b>       |

### 2.3 统计分析

为了进一步分析实验中所有方法的性能,本节对所有方法进行非参数统计分析。

本文利用 Friedman test<sup>[28]</sup>对所有方法在所有数据集上的实验结果进行了统计分析。Friedman test是一种非参数检验方法,能够用来分析多个方法的性

能之间是否存在显著差异。其具体做法是先比较所有方法在所有数据集上性能的平均排名,如图4所示,可以看出TDLSR具有最优性能,而SVM的性能最差(平均排名越小,方法的性能越好)。这表明所有方法的性能存在显著差异。因此需要利用Post hoc假设检验来具体分析两种方法的性能是否存在显著差

异. 这里主要分析本文方法TDLR与其他对比方法的性能是否存在显著差异.

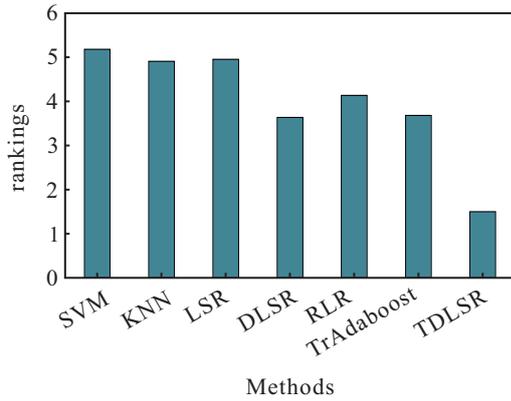


图4 所有方法的排名

表5展示了置信度为 $\alpha_{F_{ri}} = 0.05$ 的Post hoc假设检验结果, 并按照图4中的平均排名降序排列(不含TDLSR). 由表5可以看出, 当 $p_{F_{ri}} \leq 0.05$ 时, 拒绝“TDLSR与其他对比方法的性能没有显著性差异”这一假设, 因此可以得出TDLSR的性能显著优于其他对比方法.

表5 置信度 $\alpha_{F_{ri}} = 0.05$ 的Post hoc假设检验结果

| <i>i</i> | 方法         | <i>z</i>  | $p_{F_{ri}}$ | Holm      | hypothesis |
|----------|------------|-----------|--------------|-----------|------------|
| 6        | SVM        | 5.652 692 | 0            | 0.008 333 | rejected   |
| 5        | LSR        | 5.303 76  | 0            | 0.01      | rejected   |
| 4        | KNN        | 5.233 974 | 0            | 0.012 5   | rejected   |
| 3        | RLR        | 4.047 606 | 0.000 052    | 0.016 667 | rejected   |
| 2        | TrAdaboost | 3.349 743 | 0.000 809    | 0.025     | rejected   |
| 1        | DLSR       | 3.279 957 | 0.001 038    | 0.05      | rejected   |

### 3 结论

本文针对由于训练数据严重不足导致多分类场景下分类性能降低的挑战, 提出一种基于DLSR的归纳式迁移学习方法(TDLSR). 该方法通过知识杠杆机制, 将源域知识迁移到目标域并与目标域数据同时进行模型学习. 在提升分类性能的同时保证源域数据安全性. TDLSR继承DLSR在多分类任务中扩大类别间隔的优势, 且为DLSR注入了迁移能力, 使之更能适应目标域数据不足的情况. UCI数据集上的实验验证了TDLSR在复杂多分类任务上的有效性. 然而, 本文仅仅关注基于DLSR的迁移学习方法, 对于未来的研究将着眼于设计更有效的具备迁移能力的多分类算法.

#### 参考文献(References)

[1] Pan S, Yang Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.

[2] Tan C, Sun F, Kong T, et al. A survey on deep transfer learning[C]. Proceedings of the International Conference on Artificial Neural Networks. Rhodes, 2018: 270-279.

[3] 蒋亦樟, 邓赵红, 王士同. ML型迁移学习模糊系统[J]. 自动化学报, 2012, 38(9): 1393-1409. (Jiang Y Z, Deng Z H, Wang S T. Mamdani-Larsen type transfer learning fuzzy system[J]. Acta Automatica Sinica, 2012, 38(9): 1393-1409.)

[4] Xie L X, Deng Z H, Xu P, et al. Generalized hidden-mapping transductive transfer learning for recognition of epileptic electroencephalogram signals[J]. IEEE Transactions on Cybernetics, 2019, 49(16): 2200-2214.

[5] Deng Z H, Xu P, Xie L X, et al. Transductive joint-knowledge-transfer TSK FS for recognition of epileptic EEG signals[J]. IEEE Transactions on Neural, Systems, and Rehabilitation Engineering, 2018, 26(8): 1481-1494.

[6] Wang G J, Liu J, Choi K S, et al. A transfer-based additive LS-SVM classifier for handling missing data[J]. IEEE Transactions on Cybernetics, 2020, 50(2): 739-752.

[7] 毕安琪, 王士同. 基于SVC和SVR约束组合的迁移学习分类算法[J]. 控制与决策, 2014, 29(6): 1021-1026. (Bi A Q, Wang S T. Transfer classification learning based on combination of both SVC and SVR's constraints[J]. Control and Decision, 2014, 29(6): 1021-1026.)

[8] Dai W, Yang Q, Xue G, et al. Boosting for transfer learning[C]. Proceedings of the 24th International Conference on Machine Learning. Corvallis, 2007: 193-200.

[9] Du Y T, Qian C, Lu H Y, et al. Online single homogeneous source transfer learning based on AdaBoost[C]. Proceedings of the IEEE 30th International Conference on Tools with Artificial Intelligence (ICTAI). Volos, 2018: 344-349.

[10] Pan S J L, Kwok J T, Yang Q. Transfer learning via dimensionality reduction[C]. Proceedings of the 23rd International Conference on Artificial Intelligence. Chicago, 2008: 677-682.

[11] Jiang M, Huang Z Q, Qiu L M, et al. Transfer learning-based dynamic multiobjective optimization algorithms[J]. IEEE Transactions on Evolutionary Computation, 2018, 22(4): 501-514.

[12] 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.)

[13] Deng Z H, Jiang Y Z, Ishibuchi H, et al. Enhanced

- knowledge-leverage-based TSK fuzzy system modeling for inductive transfer learning[J]. *ACM Transactions on Intelligent, Systems, and Technology (TIST)*, 2016, 8(1): 1-21.
- [14] Gui L, Xu R F, Lu Q, et al. Negative transfer detection in transductive transfer learning[J]. *International Journal of Machine Learning and Cybernetics*, 2018, 9(2): 185-197.
- [15] Chang H, Han J, Zhong C, et al. Unsupervised transfer learning via multi-scale convolutional sparse coding for biomedical applications[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(5): 1182-1194.
- [16] Tan B, Yu Z, Pan S J, et al. Distant domain transfer learning[C]. *Proceedings of the 31st AAAI Conference on Artificial Intelligence*. San Francisco, 2017: 2604-2610.
- [17] Long M S, Wang J M, Cao Y, et al. Deep learning of transferable representation for scalable domain adaptation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2016, 28(8): 2027-2040.
- [18] Wei Y, Zhu Y, Cane Wing-ki Leung, et al. Instilling social to physical: Co-regularized heterogeneous transfer learning[C]. *Proceedings of the 30th AAAI Conference on Artificial Intelligence*. Phoenix, 2016: 1338-1344.
- [19] Mihalkova L, Huynh T, Mooney R J. Mapping and revising markov logic networks for transfer learning[C]. *Proceedings of the 22nd AAAI Conference Artificial Intelligence*. Vancouver, 2007: 608-614.
- [20] Deng Z H, Choi K S, Jiang Y Z, et al. Generalized hidden-mapping ridge regression, knowledge-leveraged inductive transfer learning for neural networks, fuzzy systems and kernel methods[J]. *IEEE Transactions on Cybernetics*, 2014, 44(12): 2585-2599.
- [21] Xiang S M, Nie F P, Meng G F, et al. Discriminative least squares regression for multiclass classification and feature selection[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2012, 23(11): 1738-1754.
- [22] Chatterjee S, Mächler M. Robust regression: A weighted least squares approach[J]. *Communications in Statistics-Theory and Methods*, 1997, 26(6): 1381-1394.
- [23] Fang X Z, Xu Y, Li X L, et al. Regularized label relaxation linear regression[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(4): 1006-1018.
- [24] Halldorsson G H, Benediktsson J A, Sveinsson J R. Support vector machines in multisource classification[C]. *Proceedings of the IGARSS*. Toulouse, 2003: 2054-2056.
- [25] Liu Q, Liu C. A novel locally linear KNN method with applications to visual recognition[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(9): 2010-2021.
- [26] Naseem I M, Togneri R, Bennamoun M. Linear regression for face recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 32(11): 2106-2112.
- [27] Bache K, Lichman M. UCI machine learning repository[DB/OL]. [2020-06-04]. <http://archive.ics.uci.edu/ml>.
- [28] Sheldon M R, Fillyaw M J, Thompson W D. The use and interpretation of the Friedman test in the analysis of ordinalscale data in repeated measures designs[J]. *Physiotherapy Research International*, 1996, 1(4): 221-228.

### 作者简介

姜志彬(1991—), 男, 博士生, 从事人工智能与模式识别、机器学习的研究, E-mail: jnuszmtjzb@163.com;

潘兴广(1979—), 男, 博士生, 从事机器学习、数据挖掘的研究, E-mail: 408206387@qq.com;

周洁(1992—), 女, 博士生, 从事人工智能与模式识别、机器学习的研究, E-mail: 799489588@qq.com;

张远鹏(1984—), 男, 讲师, 博士生, 从事人工智能与模式识别的研究, E-mail: 155297131@qq.com;

王士同(1964—), 男, 教授, 博士生导师, 从事模式识别、人工智能等研究, E-mail: wxwangst@jiangnan.edu.cn.

(责任编辑: 孙艺红)