

# 基于自步学习多元回归分析

甘江璋<sup>1</sup>, 钟智<sup>2+</sup>, 余浩<sup>1</sup>, 雷聪<sup>1</sup>, 赵树之<sup>1</sup>

(1. 广西师范大学 广西多源信息挖掘与安全重点实验室, 广西 桂林 541004;

2. 广西师范学院 计算机与信息工程学院, 广西 南宁 530023)

**摘要:** 针对现有多元回归模型没有充分考虑离群训练样本的影响而导致模型泛化能力差的问题, 提出一种结合自步学习和稀疏属性选择的多元回归分析方法。通过自步学习理论优先选择高置信度的样本来训练初始属性选择模型, 依次加入次高置信度的训练样本增加初始选择模型的泛化能力, 直至增加的训练样本使泛化能力减弱或者所有训练样本被用完。用选择的属性进行多元回归分析, 提高算法效率和效果。6个公开的数据集上的实验结果表明, 该算法在回归分析中得到的结果优于对比算法。

**关键词:** 自步学习; 属性选择; 稀疏学习; 回归分析; 有监督学习

中图法分类号: TP181 文献标识号: A 文章编号: 1000-7024 (2018) 12-3835-05

doi: 10.16208/j.issn1000-7024.2018.12.040

## Multi-output regression based on self-paced learning

GAN Jiang-zhang<sup>1</sup>, ZHONG Zhi<sup>2+</sup>, YU Hao<sup>1</sup>, LEI Cong<sup>1</sup>, ZHAO Shu-zhi<sup>1</sup>

(1. Guangxi Key Lab of Multi-Source Information Mining and Security, Guangxi Normal University, Guilin 541004, China;

2. College of Computer and Information Engineering, Guangxi Teachers Education

University, Nanning 530023, China)

**Abstract:** To solve the problem that existing multi-output regression model does not consider the influence of outliers and thus leading to the poor generalization ability of the model, a multi-output regression method combining self-paced learning with sparse feature selection was proposed. The feature selection model was trained using the most high-confidence samples based on the self-paced learning theory, and more high-confidence training samples were added in the remaining samples to increase the generalization ability of the initial feature selection model until the generalization ability of the feature selection model stopped improving or all training samples were used up. As a result, the selected features may improve the efficiency and effectiveness of the multi-output regression. Experimental results on six datasets show that the proposed method is superior to the comparison algorithms.

**Key words:** self-paced learning; feature selection; sparse learning; regression analysis; supervised learning

## 0 引言

多元回归问题在现实应用中普遍存在, 而且常用高维特征数据进行描述, 但离群样本和高维属性都会影响多元回归分析的准确度和效率<sup>[1-3]</sup>。所以, 如何处理离群样本和高维数据对于建立有效可靠多元回归模型具有重要的研

究价值。

现有处理高维数据的方法有子空间学习<sup>[4]</sup>和属性选择两种<sup>[5]</sup>。属性选择方法既可以保持数据的原有功能, 又提高了算法的效率<sup>[6]</sup>。而处理离群样本的方法主要有基于距离方法<sup>[7]</sup>和基于聚类的方法<sup>[8]</sup>等, 基于聚类的方法主要通过将远离类簇的少数样本判定为离群样本。基于距离的方

收稿日期: 2017-11-13; 修订日期: 2018-06-04

基金项目: 国家自然科学基金项目 (61672177、61573270); 国家 973 重点基础研究发展计划基金项目 (2013CB329404); 广西自然科学基金项目 (2015GXNSFCB139011、2015GXNSFAA139306); 广西研究生教育创新计划基金项目 (YCSW2018093)

作者简介: 甘江璋 (1994-), 男, 湖南衡阳人, 硕士研究生, 研究方向为数据挖掘、机器学习; +通讯作者: 钟智 (1963-), 男, 广西梧州人, 教授, 研究方向为机器学习、数据挖掘; 余浩 (1994-), 男, 江西上饶人, 硕士研究生, 研究方向为数据挖掘、机器学习; 雷聪 (1991-), 男, 湖北大冶人, 硕士研究生, 研究方向为机器学习和数据挖掘; 赵树之 (1992-), 男, 湖南郴州人, 硕士研究生, 研究方向为机器学习和数据挖掘。E-mail: ganjzgxnu@163.com

法将与数据集中大部分样本距离大于阈值的样本判为离群样本，从而达到处理离群样本的目的。

然而，现有的回归分析算法只是单一考虑其中一种因素的影响（离群样本或高维大数据），因此在本文提出了一种基于自步学习多元回归分析算法（multiple regression analysis based on self-paced learning, SPM\_RS）来同时处理高维大数据和离群样本，以此来获得更好的效果。具体地，首先利用自步学习方法对数据中的训练样本进行选择，有效避免离群样本带来的影响，然后引入稀疏学习理论，使用可以导致行稀疏的  $\ell_{2,1}$  范数进行属性选择。经实验验证，结合了自步学习和稀疏属性选择的多元回归分析方法在应用中各项评价指标均优于对比算法。

### 1 相关理论背景

#### 1.1 多元分析

多元回归分析是研究多个变量之间相关关系的一种重要统计分析方法，因其坚实的内在理论基础被广泛应用于自然科学，社会科学和应用技术中等领域<sup>[9]</sup>。

假设样本  $x_i$  由  $d$  个属性来描述，回归分析的本质就是试图学到一个模型尽可能的预测出样本标签  $y_i$ ，使用最小二乘法对样本标签  $y_i$  进行线性回归拟合，这样可以得到模型

$$f(x_i) = x_i W + b \tag{1}$$

其中， $W$  表示回归模型参数， $b$  表示模型偏差项。

在实际任务中，为了使模型尽可能更好拟合原始数据，需要模型的拟合误差尽可能的小。但是在多元回归问题中，高维大数据普遍存在，会使回归模型出现过拟合的问题。为了缓解模型的过拟合，常在多元回归模型中引入稀疏学习理论<sup>[10]</sup>。

在稀疏学习的基本理论中，通过稀疏正则化项对回归模型参数  $W$  进行稀疏假设，并使用训练数据对  $W$  进行拟合，则可以得到模型

$$\min_W \sum_{i=1}^n (y_i - f(x_i))^2 + \alpha \phi(W) \tag{2}$$

其中， $\phi(W)$  为稀疏正则化项， $\alpha$  表示调节参数用来平衡拟合损失函数项和稀疏正则化项， $n$  为样本数。

在稀疏学习中，正则化项通常选择能够凸优化求解的范数<sup>[14]</sup>。其中  $\ell_1$  范数具有较强的稀疏性， $\ell_2$  范数具有防止损失函数过度拟合。而  $\ell_{2,1}$  范数融合了两者之间优点，既有  $\ell_1$  范数稀疏性的特点又有  $\ell_2$  范数防止过度拟合的特点。因此本文采用  $\ell_{2,1}$  范数作为稀疏正则化项进行对  $W$  行稀疏处理，排除冗余信息和不相关的属性，从而提升算法效率。

#### 1.2 自步学习简介

自步学习<sup>[11]</sup>是一种模拟人的认知机理的机器学习方法，人类对事物的认识都是从简单的知识过度到复杂知识。我们在机器学习的模型中引入这一机制，利用自步学习的

方法首先学习简单样本再逐步将复杂的样本纳入训练当中。

给定一个数据集  $E(x_i, y_i)$  有  $n$  个样本， $x_i$  表示一个样本， $y_i$  表示与该样本对应的类标签， $W$  表示模型需要优化的参数， $r(W)$  为参数的正则化项。用损失函数  $L(x_i, y_i, W)$  来表示样本的“难易”程度，则可以得到传统的机器学习目标函数

$$\min_W (W) + \sum_{i=1}^n L(x_i, y_i, W) \tag{3}$$

自步学习的核心思想在于每一次的迭代都倾向于选择“简单”的样本来更新模型参数<sup>[12]</sup>。每次迭代选择的样本数量由自步学习参数来确定，通过逐次增加自步学习参数将更多的训练样本纳入训练当中。因此，自步学习在传统的机器学习目标函数中引入一个变量  $v$  用以表征样本是否被选择的程度，则自步学习的目标函数为

$$\min_{W, v} (W) + \sum_{i=1}^n v_i L(x_i, y_i, W) + f(v, \lambda) \tag{4}$$

其中， $f(v, \lambda)$  为自步正则化项， $\lambda$  为自步正则化参数，用于控制哪些样本被选择，如果  $\lambda$  的值较小，目标函数的优化过程就倾向于选择  $L(\cdot)$  较小的样本。随着迭代次数的增加，逐步增大  $\lambda$  的值，将更多的样本纳入训练。

对于此类式 (3) 的优化过程一般采用 ACS (alternative convex search) 策略<sup>[13,14]</sup>，这是一种双凸优化迭代方法，通过固定一个变量块，优化另一个变量块。用固定的  $W$ ，得到  $v$  的全局最优解  $v^* = [v_1^*, v_2^* \dots, v_n^*]$ 。

这种迭代优化的策略在当使用固定的  $W$  更新  $v$  的时候，将损失小于阈值  $\lambda$  的样本作为“简单”样本，并选择这些“简单”样本进行训练。当用固定的  $v$  来更新  $W$  的时候，只对所选择的“简单”样本进行训练，得到模型参数  $W$ 。其中  $\lambda$  也相当于模型的“年龄参数”，随着  $\lambda$  值的增加，那些“复杂”的样本也会被选择，这样模型也会变得更加成熟，泛化能力更强。

### 2 算法描述和优化

#### 2.1 算法描述

给定一个训练数据集  $X = [x_1, x_2, \dots, x_n] \in R^{n \times d}$ ， $n$  表示样本数量， $d$  表示属性维度。 $Y \in R^{n \times c}$  表示样本类标签， $c$  表示样本对应的类数。使用最小二乘法来拟合模型参数和数据，得到如下模型

$$\min_W \|Y - XW\|_F^2 \tag{5}$$

其中， $\|\cdot\|_F$  表示 Frobenius 范数<sup>[15]</sup>。模型输出的系数矩阵  $W \in R^{d \times c}$  代表着训练样本和测试样本之间的重构系数矩阵。

大部分数据中普遍存在不相关信息和离群值，会对实验结果造成一定影响。所以，找到一个合适的规则化项对于提高算法性能有很大的作用。 $\ell_{2,1}$  范数既有良好的行稀疏性，又能防止模型的过拟合，对于去除一些冗余信息有很好的效果。本文采用  $\ell_{2,1}$  范数对重构系数矩阵进行稀疏，得

到的模型为

$$\min_w \|Y - XW\|_F^2 + \alpha \|W\|_{2,1} \quad (6)$$

其中,  $\alpha$  为稀疏正则化参数,  $\alpha$  越大则矩阵越稀疏。

在传统的机器学习模型训练过程中通常会将所有样本一次加入到训练中, 这样的学习方式没有充分考虑到噪声给模型训练带来的影响, 因此在本文中采用自步学习的方法有意义的对样本进行选择, 这样得到的目标函数如下所示

$$\min_{w, v} \sum_{i=1}^n v_i \|y_i - x_i W\|_F^2 + \alpha \|W\|_{2,1} - \lambda \|v\|_1 \quad (7)$$

其中,  $\lambda$  为自步正则化参数, 用于控制样本的选择。  $-\lambda \|v\|_1$  为权重自步正则项,  $v_i = 0$  时样本为“复杂”样本不被选择,  $v_i = 1$  为“简单”样本被选中加入训练。随着  $\lambda$  值的增大, 更多的样本被选中。自步学习实现了一种由易到难的学习方式, 有顺序的对样本进行训练, 提高了模型的精准度。

SPM\_RS 算法的伪代码如下:

算法 1: SPM\_RS 算法伪代码

输入: 训练样本  $X \in R^{n \times d}$ ,  $Y \in R^{n \times c}$  控制参数  $\alpha, \lambda$ 。

输出: aCC

- (1) 初始化  $t=1$ 。
- (2) 初始化矩阵  $D \in R^{d \times d}$ ,  $v \in R^{1 \times n}$ 。
- (3) 通过式(13)求解  $W$ 。
- (4) 根据得到的  $W$ , 更新  $D$ , 计算  $\lambda$ 。
- (5) 根据  $\lambda$  值, 更新  $v$ 。
- (6)  $t=t+1$ , 重复步骤(3)~(6)。
- (7) 直到式(8)收敛。
- (8) 最后, 对新的属性集构成的样本使用 SVR 进行回归分析。

## 2.2 算法优化

本节对文中提出的目标函数进行优化

$$\min_{w, v} \sum_{i=1}^n v_i \|y_i - x_i W\|_F^2 + \alpha \|W\|_{2,1} - \lambda \sum_{i=1}^n v_i \quad (8)$$

目标函数存在两个变量, 所以本文采用交替优化方法。

定义一个对角矩阵  $D$

$$D^i = \frac{1}{2 \|W^i\|_2} \quad (9)$$

- (1) 固定  $v$ , 优化  $W$ : 固定  $v$  后, 目标函数变为

$$\min_w \sum_{i=1}^n v_i \|y_i - x_i W\|_F^2 + \alpha \|W\|_{2,1} \quad (10)$$

为方便优化将式(10)写成如下所示

$$\min_w \|Q - GW\|_F^2 + \alpha \|W\|_{2,1} \quad (11)$$

其中,  $Q = UY, G = UX, U = \text{diag}(\sqrt{v})$ 。

对式(11)中  $W$  求导可得

$$\begin{aligned} & \|Q - GW\|_F^2 + \alpha \|W\|_{2,1} \\ & (Q - GW)^T (Q - GW) + \alpha W^T DW = 0 \\ & -Q^T G + G^T GW + \alpha DW = 0 \end{aligned} \quad (12)$$

最终求出的结果为

$$W = (G^T G + \alpha D)^{-1} G^T Q \quad (13)$$

- (2) 固定  $W$ , 优化  $v$  问题变成

$$\min_v \sum_{i=1}^n v_i \|y_i - x_i W\|_F^2 - \lambda \sum_{i=1}^n v_i \quad (14)$$

令  $L(x_i, y_i, W) = \|y_i - x_i W\|_F^2$  可得

$$\min_v \sum_{i=1}^n v_i L(x_i, y_i, W) - \lambda \sum_{i=1}^n v_i \quad (15)$$

对式(15)求导可得最优解

$$v_i^* = \begin{cases} 1 & L(x_i, y_i, W) < \lambda, \\ 0 & otherwise. \end{cases} \quad (16)$$

## 2.3 算法收敛性证明

根据算法 2 可得第  $t$  次迭代的  $W^{(t+1)}$

$$\min_w \|Q' - G'W'\|_F^2 + \alpha \text{tr}(W'^T D'W') \quad (17)$$

由式(17)可得

$$\begin{aligned} & \|Q^{(t)} - G^{(t)}W^{(t+1)}\|_F^2 + \alpha \text{tr}(W^{(t+1)T} D'W^{(t+1)}) \leq \\ & \|Q^{(t)} - G^{(t)}W^t\|_F^2 + \alpha \text{tr}(W^t T D'W^t) \end{aligned} \quad (18)$$

将对角矩阵  $D$  代入式(18)可得

$$\begin{aligned} & \|Q^{(t)} - G^{(t)}W^{(t+1)}\|_F^2 + \alpha \sum_{i=1}^d \frac{\|W^{(t+1)}\|_2^2}{2 \|W^{(t)}\|_2^2} \leq \\ & \|Q^{(t)} - G^{(t)}W^{(t)}\|_F^2 + \alpha \sum_{i=1}^d \frac{\|W^{(t)}\|_2^2}{2 \|W^{(t)}\|_2^2} \end{aligned} \quad (19)$$

对于  $W^{(t)}$  和  $W^{(t+1)}$  的每一行, 可以得到下列不等式

$$\begin{aligned} & \|W^{(t+1)}\|_2 - \frac{\|W^{(t+1)}\|_2^2}{2 \|W^{(t)}\|_2^2} \leq \\ & \|W^{(t)}\|_2 - \frac{\|W^{(t)}\|_2^2}{2 \|W^{(t)}\|_2^2} \end{aligned} \quad (20)$$

对上述不等式乘以控制参数  $\alpha$ , 并累加得到

$$\begin{aligned} & \alpha \sum_{i=1}^d \|W^{(t+1)}\|_2 - \frac{\|W^{(t+1)}\|_2^2}{2 \|W^{(t)}\|_2^2} \leq \\ & \alpha \sum_{i=1}^d \|W^{(t)}\|_2 - \frac{\|W^{(t)}\|_2^2}{2 \|W^{(t)}\|_2^2} \end{aligned} \quad (21)$$

最后, 结合不等式(18)和式(20)就可以得到

$$\begin{aligned} & \|Q^{(t+1)} - G^{(t+1)}W^{(t+1)}\|_F^2 + \alpha \|W^{(t+1)}\|_{2,1} \leq \\ & \|Q^{(t)} - G^{(t)}W^t\|_F^2 + \alpha \|W^{(t)}\|_{2,1} \end{aligned} \quad (22)$$

根据上述不等式可以得出, 目标函数的值在迭代的过程中是单调递减的, 所以 SPM\_RS 算法可以收敛到当前选择样本下的最优解。

## 3 实验结果和分析

### 3.1 实验数据集和对比算法

本文使用 6 个数据集来测试算法在回归分析上的性能。数据集来源于 UCI<sup>[16]</sup>, 信息统计见表 1。

本文通过与 4 种优秀对比算法的实验结果比较来评估提出的算法: LSG21<sup>[17]</sup>方法, CSFS<sup>[18]</sup>, SLRR<sup>[6]</sup>和 RSR<sup>[19]</sup>方法。在实验中使用平均相关系数 (average correlation coefficient, aCC) 来评估回归的准确性。

表 1 数据集信息统计

数据集	样本数	属性数	响应变量
EDM	154	16	2
ATP1d	337	411	6
ATP7d	296	411	6
OES10	403	298	16
sf1	323	10	3
OES97	334	263	16

3.2 实验结果和分析

实验中的对比算法和 SPM\_RS 算法均采用十折交叉验证来对比算法性能，在每一折中再进行 5 折交叉验证，并且使用 SVR 学习训练得到回归模型。

SPM\_RS 算法与对比算法在 6 个数据集上每一折的 aCC 对比如图 1~图 6 所示。由于十折交叉验证的随机性，所以 SPM\_RS 算法并不是在每一折上都是最好的，但是 10 次实验结果大部分都高于对比算法，最后的平均 aCC 也优于对比算法。

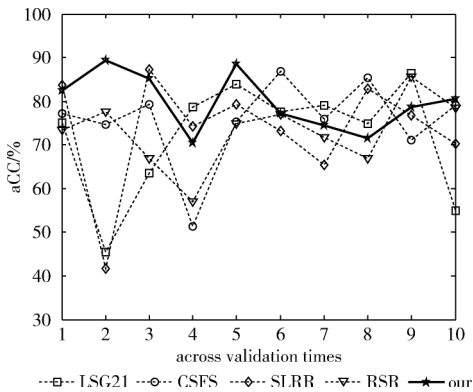


图 1 数据集 EDM




图 2 数据集 ATP1d

在表 2 中的数据可以看出，SPM\_RS 算法的平均 aCC 在 6 个数据集上与另外的 4 种对比算法的平均 aCC 进行了




图 3 数据集 ATP7d




图 4 数据集 OES10

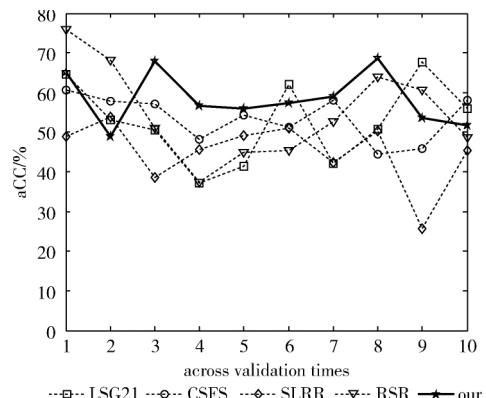


图 5 数据集 sf1

比较。在 6 个数据集上 SPM\_RS 算法获得了最高的 aCC。具体的，在 EDM 数据集上 SPM\_RS 算法取得了最好的 79.83%，比 LSG21 高出了 7.85%，比 CSFS, SLRR, RSR 分别高出 4.2%、6.38%、6.88%。在数据集 ATP7d 上 SPM\_RS 算法的 aCC 是 87.13%，相对于其它对比算法分别高出 8.29%、10.13%、7.22%、11.39%。在 sf1 数据集上 SPM\_RS 算法比对比算法提高了 5.92%、4.9%、13.38%、3.61%。其中在 OES97 上提高的最多，高出了

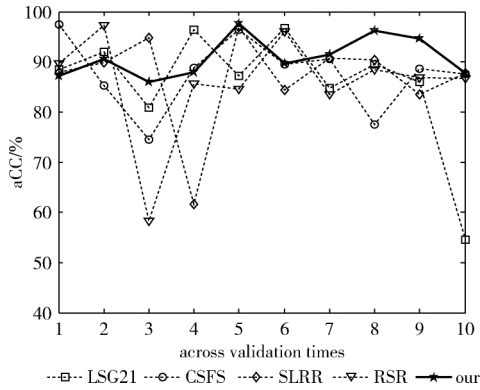


图 6 数据集 OES97

13.38%。在所有的数据集中, SPM\_RS 算法也比对比算法高出 7.21%, 7.11%, 5.79%, 5.88%。可见 SPM\_RS 算法在回归实验上取得了明显的效果。

表 2 aCC 统计结果/%

数据集	LSG21	CSFS	SLRR	RSR	SPM_RS
EDM	71.98	75.63	73.45	72.95	<b>79.83</b>
ATP1d	84.89	83.42	90.05	87.05	<b>92.73</b>
ATP7d	78.74	77.00	79.91	75.74	<b>87.13</b>
OES10	87.11	83.09	94.15	92.68	<b>95.13</b>
sf1	52.55	53.57	45.09	54.86	<b>58.47</b>
OES97	85.64	87.62	86.78	85.67	<b>90.90</b>
Average	76.82	76.72	78.24	78.15	<b>84.03</b>

实验结果表明 SPM\_RS 算法在性能上优于 4 个对比算法。与 SPM\_RS 相比, 4 个对比算法都没有采取有效的方法对样本进行选择, 无法避免噪声和离群样本对回归模型的影响, 从而影响模型的稳定性和准确性。本文算法不仅有效避免了噪声样本的影响, 还保留了提取后的重要属性, 使得算法拥有更好的性能。

#### 4 结束语

本文提出了一种结合了基于自步学习多元回归分析算法 (SPM\_RS 算法) 用于回归分析。基于基本线性回归模型, 利用自步学习选择训练样本, 再结合稀疏属性选择理论对样本的重要属性进行选取。因此算法融合了自步学习和稀疏学习, 既考虑了高维大数据对多元回归模型的影响, 同时又有效避免了离群样本对模型训练带来的干扰。实验结果表明 SPM\_RS 算法在回归分析中取得了较好的效果。在今后的研究中, 我们尝试将自步学习引入其它的机器学习模型中来扩展自步需学习的应用范围。

#### 参考文献:

[1] Zhang S, Jin Z, Zhu X. Missing data imputation by utilizing

information within incomplete instances [J]. Journal of Systems and Software, 2011, 84 (3): 452-459.

[2] Zhang Shichao. Decision tree classifiers sensitive to heterogeneous costs [J]. Journal of Systems and Software, 2012, 85 (4): 771-779.

[3] Zhu X, Suk H I, Shen D. Matrix-similarity based loss function and feature selection for alzheimer's disease diagnosis [C] //IEEE Conference on Computer Vision and Pattern Recognition. 2014: 3089-3096.

[4] Zhu X, Huang Z, Shen H T, et al. Dimensionality reduction by mixed kernel canonical correlation analysis [J]. Pattern Recognition, 2012, 45 (8): 3003-3016.

[5] Zhu X, Li X, Zhang S, et al. Robust joint graph sparse coding for unsupervised spectral feature selection [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28 (6): 1263-1275.

[6] Zhang S, Yang L, Deng Z, et al. Leverage triple relational structures via low-rank feature reduction for multi-output regression [J]. Multimedia Tools & Applications, 2016, 76 (16): 17461-17477.

[7] Purkait P, Chin T J, Ackermann H, et al. Clustering with hypergraphs: The case for large hyper-edges [C] //European Conference on Computer Vision, 2014: 672-687.

[8] Zhu X, He W, Li Y, et al. One-step spectral clustering via dynamically learning affinity matrix and subspace [C] //Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, 2017: 2963-2969.

[9] Lai H, Pan Y, Liu C, et al. Sparse learning-to-rank via an efficient primal-dual algorithm [J]. IEEE Transactions on Computers, 2013, 62 (6): 1221-1233.

[10] Zhu X, Li X, Zhang S, et al. Robust joint graph sparse coding for unsupervised spectral feature selection [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28 (6): 1263-1275.

[11] Jiang L, Meng D, Zhao Q, et al. Self-paced curriculum learning [C] //Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence, 2015: 2694-2700.

[12] Kumar MP, Packer B, Koller D. Self-paced learning for latent variable models [C] //Proceedings of the 23rd International Conference on Neural Information Processing Systems, 2010: 1189-1197.

[13] Zhang D, Meng D, Li C, et al. A self-paced multiple-instance learning framework for co-saliency detection [C] //IEEE International Conference on Computer Vision, 2015: 594-602.

[14] Jeyakumar V, Li G. A new class of alternative theorems for SOS-convex inequalities and robust optimization [J]. Applicable Analysis, 2015, 94 (1): 56-74.

(下转第 3852 页)

- 体计算中用户主题感知的任务分配 [J]. 计算机研究与发展, 2015, 52 (2): 309-317.]
- [4] Srinivasan K, Agrawal P, Arya R, et al. Context-aware, QoE-driven adaptation of multimedia services [M] //Mobile Wireless Middleware, Operating Systems, and Applications. Berlin: Springer, 2013: 236-249.
- [5] Tekin C, Schaar M V D. Contextual online learning for multimedia content aggregation [J]. IEEE Transactions on Multimedia, 2015, 17 (4): 549-561.
- [6] Bulterman DCA, Cesar P, Guimaraes RL. Socially-aware multimedia authoring: Past, present, and future [C] //ACM Transactions on Multimedia Computing, Communications and Applications. United States: ACM, 2013.
- [7] Chang CK. Situation analytics: A foundation for a new software engineering paradigm [J]. Computer, 2016, 49 (1): 24-33.
- [8] Zhang Z, Sun R, Wang X, et al. A situational analytic method for user behavior pattern in multimedia social networks [C] //IEEE Transactions on Big Data, 2017.
- [9] Zhang Z, Sun R, Zhao C, et al. CyVOD: A novel trinity multimedia social network scheme [J]. Multimedia Tools & Applications, 2016, 76 (18): 18513-18529.
- [10] Zhang Z, Wen J, Wang X, et al. A novel crowd evaluation method for security and trustworthiness of online social networks platforms based on signaling theory [J]. Journal of Computational Science, 2017, 26: 468-477.
- [11] ZHANG Lu, CAI Wandong, PENG Dong. Social network seed node search algorithm [J]. Computer Engineering and Design, 2013, 34 (12): 4114-4119 (in Chinese). [张璐, 蔡皖东, 彭冬. 社交网络种子节点搜索算法 [J]. 计算机工程与设计, 2013, 34 (12): 4114-4119.]
- [12] HUANG Jun, WANG Qingfeng, LIU Zhiqin, et al. Cloud task scheduling based on resource state ant colony optimization [J]. Computer Engineering and Design, 2014, 35 (9): 3305-3309 (in Chinese). [黄俊, 王庆风, 刘志勤, 等. 基于资源状态蚁群算法的云计算任务分配 [J]. 计算机工程与设计, 2014, 35 (9): 3305-3309.]

---

(上接第 3839 页)

- [15] Sun H, Wu Q. Least square regression with indefinite kernels and coefficient regularization [J]. Applied & Computational Harmonic Analysis, 2011, 30 (1): 96-109.
- [16] UCI repository of machine learning datasets [EB/OL]. [2016-05-27]. <http://archive.ics.uci.edu/ml/>.
- [17] Cai X, Nie F, Cai W, et al. New graph structured sparsity model for multi-label image annotations [C] //IEEE International Conference on Computer Vision. IEEE, 2013: 801-808.
- [18] Hu R, Zhu X, Cheng D, et al. Graph self-representation method for unsupervised feature selection [J]. Neurocomputing, 2016, 220 (12): 130-137.
- [19] Zhu P, Zuo W, Zhang L, et al. Unsupervised feature selection by regularized self-representation [J]. Pattern Recognition, 2015, 48 (2): 438-446.