

一种基于CRO的高阶神经网络多示例学习方法

邓波¹ 陆颖隽² 王如志³

(邵阳学院信息工程系 邵阳 422000)¹ (武汉大学信息管理学院 武汉 430072)²

(北京工业大学材料科学与工程学院 北京 100124)³

摘要 在多示例学习(MIL)中,包是含有多个示例的集合,训练样本只给出包的标记,而没有给出单个示例的标记。提出一种基于示例标记强度的MIL方法(ILI-MIL),其允许示例标记强度为任何实数。考虑到基于梯度训练神经网络方法的计算复杂性和ILI-MIL目标函数的复杂性,利用基于化学反应优化的高阶神经网络来实现ILI-MIL,学习方法具有较强的非线性表达能力和较高的计算效率。实验结果表明,该算法比已有算法具有更加有效的分类能力,且适应范围更广。

关键词 多示例学习,化学反应优化,高阶神经网络,分类器

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.03.054

Multiple-instance Learning Method Based on CRO High Order Neural Networks

DENG Bo¹ LU Ying-jun² WANG Ru-zhi³

(Department of Information Engineering, College of Shaoyang, Shaoyang 422000, China)¹

(School of Information Management, Wuhan University, Wuhan 430072, China)²

(College of Materials Science and Engineering, Beijing University of Technology, Beijing 100124, China)³

Abstract Multi-instance learning (MIL) is a variant of inductive machine learning developed recently, in which each learning example contains a bag of instances instead of a single feature vector. In this paper, we presented a novel MIL method based on the concept of instance label intensity (ILI) called ILI-MIL. Considering the complexity of the object function and the complexity of the gradient descent based training method in neural networks, we used a chemical reaction optimization (CRO) algorithm for training a high-order neural network (HONN) to implement the presented ILI-MIL method, which has more powerful nonlinear fitting capacity and high computation efficiency. The experiment results show that our ILI-MIL method have more effective ability of classification than the state-of-the-art methods.

Keywords MIL, CRO, HONN, Classifier

1 引言

多示例学习(MIL)^[1]是近年发展起来的一种新的机器学习方法,在诸如药物行为预测^[2]、图像分类^[3]、Web知识挖掘^[4]等方面得到了广泛的应用。

在MIL中,每个学习样本包括一组(包)示例,只有包层次上有训练标记,而不对每个属性向量提供标记,因而不能直接利用有监督的学习方法来解决。为弥补信息的不足,MIL方法往往通过附加包标记和示例标记之间的某种假设关系来进行学习^[5]。因此,人们提出了各种假设及其MIL模型和算法,如基于支持向量机的MIL^[2]和基于神经网络的MIL^[1,6-8]等。但这些假设模型往往只适合于某一类数据集,不对所有的MIL问题通用。因此研究一些适用面更广的假设模型将有利于MIL的应用。

本文提出基于标记强度的标记方法,假设每个示例对包

标记都有一定的贡献,而且标记强度可以为负值,以表示对负标记的贡献强度或对正标记包的负贡献,从而构建出一种新的MIL假设模型。新的假设模型涵盖了许多现有假设模型,使得多示例学习的应用范围更广。基于MIL问题的非线性性,本文采用基于化学反应优化(CRO)的高阶神经网络算法实现新的MIL方法,即在高阶神经网络上应用化学反应优化算法进行训练。高阶神经网络的非线性分类能力强,化学反应优化算法训练速度快,使得提出的分类器具有较强的分类能力和较快的计算速度。实验结果表明,该算法比已有算法能更有效地进行分类。

2 基于示例标记强度的MIL方法(ILI-MIL)

2.1 多示例学习(MIL)

多示例学习中每个包是一组示例的集合,对每个包给出了训练标记,但对包中的示例没有给出标记。标记分为

到稿日期:2016-03-28 返修日期:2016-09-23 本文受国家自然科学基金项目(61373132),湖南省教育厅科研基金资助项目(13C845)资助。

邓波(1973—),男,硕士,讲师,主要研究方向为信息处理与虚拟现实技术,E-mail:190091882@qq.com;陆颖隽(1963—),男,博士,副教授,主要研究方向为数字图书馆原理与技术、虚拟现实技术;王如志(1973—),男,教授,博士生导师,主要研究方向为材料科学与信息处理技术。

正(+)、负(-)两种标记。MIL 算法获得一个分类器,通过对已知包标记的训练求得未知包的正确标记。

2.2 MIL 的假设模型

假设有 n 个包 $\{B_1, B_2, \dots, B_n\}$, 第 i 个包有 n_i 个示例, 即 $B_i = \{B_{i1}, B_{i2}, \dots, B_{in_i}\}$, 示例 $B_{ij} = (B_{ij1}, B_{ij2}, \dots, B_{ijK})$ 是一个 K 维属性向量, 包对应的训练标记为 $\{L_1, L_2, \dots, L_n\}$, $L_i \in \{1, -1\}$, 其中 1 代表正标记, -1 代表负标记。

在设计 MIL 算法时,往往需要假设包标记和示例标记存在某种关系。一个标准的假设^[1]是:如果包标记为负,则认为包中所有示例都是负标记;如果包标记为正,则认为包中至少包含一个正标记示例。因此,包层的分类由示例层的分类来确定,很多分类算法采用了这个标准的假设,如文献[2]中的支持向量机的分类方法。这个假设虽然在 Musk 药物行为预测和某些问题是合适的,但对其他问题却并不一定合适。为此人们提出了许多可选的模型假设及算法^[5],如基于计数的假设模型要求包中具备某些特征的示例数必须在某个范围内,才能认为该包为正标记;又如基于几何特征的假设模型设定 k 个目标点,当包中含有的示例与至少 r 个目标点充分接近时,才认为该包为正标记;收集假设模型则假设所有的示例对包的标记有相同的作用,并定义出每个包的标记概率来确定包的最终标记结果;当对不同的示例选择不同作用权值时,就是基于加权概率的假设模型,该模型假设可以得到每个示例的标记概率,包层的标记概率则由该包中所有示例的标记概率加权得到,若包的标记概率大于阈值(一般为 0.5),则确定其为正标记。基于这些模型的假设,人们进一步提出了一些推广和改进模型,以适应不同的应用环境,从而使得 MIL 的假设模型逐步一般化,适应面更广。在这些假设模型中,基于概率模型的假设适应面最广,但其参数最多,参数的确定具有一定的主观性,因而难以确定。本文提出示例标记的强度概念,在保持适应性的基础上简化了参数的设计。

2.3 基于示例标记强度的 MIL 方法(ILM-MIL)

上述对 MIL 的概率假设模型中,若对示例的标记概率的估计采取简单方式,很多情况下并不能反映真实情况,而权值的选择则更加灵活,需要更多的额外信息,因此合理估计示例标记概率和选取权值都是十分困难的。本文提出一种标记强度 $I(x_i)$ 的概念来取代 MIL 概率假设模型中的示例标记概率和相关的权值,并用高阶神经网络学习每个示例的标记强度,预测出包的标记,从而避免了构建概率模型的困难。

设对于每个包 B 中的示例 x_i , 定义其示例的标记强度为 $I(x_i)$, 取值为实数,若 $I(x_i)$ 为正,则表示该示例对包的正标记具有贡献;若 $I(x_i)$ 为负,则表示该示例对包的负标记具有贡献。这个定义对示例的意义做了扩充:对于属于负标记包中的示例,并不一定所有示例对包的正标记都没有贡献,而只是示例贡献之和不足以达到让包成为正标记所需的强度,或是被其他负标记示例的贡献所抵消;同样对于正标记包中的示例,也可能存在标记贡献为负的示例,只是示例的正标记总贡献高于负标记的总贡献,并达到某个阈值。

在标记强度的定义下,本文设计的对包的标记方法如下:设 B 中有 n_b 个示例,示例 x_i 的标记强度为 $I(x_i)$, 定义包 B 的标记强度 $I(B)$ 为:

$$I(B) = \frac{1}{n_b} \sum_{i=1}^{n_b} I(x_i) \quad (1)$$

若标记强度 $I(B)$ 大于某一阈值 γ , 则标记该包为正标记,反之标记该包为负标记, γ 一般可设为 0。包 B 的标记由式(3)给出:

$$I(B) = \begin{cases} 1, & I(B) \geq \gamma \\ -1, & I(B) < \gamma \end{cases} \quad (2)$$

本文提出的基于示例标记强度的模型具有较强的适应性。模型设定每个标记具有一定的标记强度,从而使得包中每个标记对整个包的标记都具有一定的贡献;模型假设示例标记强度可以为实数,从而保证在包的标记贡献上可以反映一种负的作用;示例的标记强度反映了示例的性质,因此能细微刻画包的结构。

本模型能涵盖许多已有模型,例如在标准的 MIL 模型中,包的标记定义为:

$$I(B) = \begin{cases} 1, & B \text{ 中含正标记示例} \\ -1, & B \text{ 中不含正标记示例} \end{cases} \quad (3)$$

在本模型中,定义负标记示例的标记强度为 0, 正标记的标记强度为 1, 阈值 γ 设为 1, 则本假设模型即为标准的 MIL 模型。

又如基于概率假设的模型^[5]中,定义示例 x_i (标记为 c) 的概率为 $p(c|x_i)$, 并由此定义包的标记为:

$$P(c|b) = \left(\sum_{i=1}^{n_b} w(x_i) \right)^{-1} \sum_{i=1}^{n_b} w(x_i) P(c|x_i) \quad (4)$$

其中 $w(x_i)$ 为示例 x_i 的权值, 则包标记为:

$$I(B) = 1, p(c|b) > 0.5$$

该模型虽然细化了每个标记的作用,但是权值参数和概率参数如何选择是个很难确定的问题。在本模型中,若将权值与概率的积作为标记强度,即定义:

$$I(x_i) = \left(\sum_{i=1}^{n_b} w(x_i) \right)^{-1} w(x_i) P(c|x_i) \quad (5)$$

本模型即为基于概率的模型,但不需要设置权值参数和标记概率参数。

基于示例强度的 MIL 模型要解决的问题是学习出每个示例标记强度并预测出 $I(B)$ 。本文采用基于化学反应的高阶神经网络来学习每个示例的标记强度,并预测包的标记。

3 基于化学反应优化的高阶神经网络

3.1 高阶神经网络

高阶神经网络(HONNN)在人工神经网络中增加高阶连接权值以加强其函数逼近能力和存储能力, HONNN 神经元中的求积器使该网络本质上具有了非线性,从而提了高神经网络的非线性能力。此外,高阶神经网络具有更强的函数逼近能力、更快的收敛速度、更强的存储能力和容错能力。Pi-Sigma 神经网络^[9](PSNN)是一种结构相对固定的多输入单输出网络的 HONNN。PSNN 的结构如图 1 所示,网络由三层节点组成,只包含一个隐层,隐层节点是求和层,输出层节点则为求积层,单元激活函数为 Sigmoid 函数或双曲正切函数。PSNN 的隐层到输出层节点间的权值为固定常数 1, 因此只有第一层权值需要训练,从而大大降低了训练的计算量。PSNN 不仅保持了多层高阶神经网络强大的学习能力和非线性

性映射能力,又具有单隐层神经网络收敛速度快的特点,能避免权值数目随输入维数增加而呈组合性增加的弱点。




图1 Pi-Sigma神经网络

3.2 化学反应优化算法

化学反应优化(CRO)算法是近年来发展起来的一种新型优化技术^[10],其通过模拟化学反应中分子碰撞容器壁以及分子间的相互作用来达到稳定状态,即最小系统势能的过程。CRO具有群体规模动态变化、个体之间信息交换手段丰富等独有特征,因此在许多工程问题上都有良好的应用,如求解挖掘分类规则、组合优化问题^[11]等。

在化学反应优化算法中,每一个分子由若干个原子组成,并赋予焓(最小化问题)或熵(最大化问题)来评价其能量状态。分子的反应包括单分子反应或多分子反应,多分子反应可以给分子带来多样性,而单分子反应则有助于强化分子的某一特性。

3.3 改进的化学反应优化算法

本文采用一种简化的改进的CRO算法,只考虑单分子反应和双分子反应,并在生成新分子时充分利用较好分子的特性,从而简化了反应过程并加快了收敛速度。设反应物分子由 D 个原子组成, N_p 为分子个数,第 j 个反应物分子为 $R_j = (w_{j1}, w_{j2}, \dots, w_{jD})$,其中, w_{jx} 为第 j 个分子的第 x 个原子,每个原子的取值范围为区间 $[L, U]$ 。本文考虑的基本反应为:单分子无效碰撞和分解反应、双分子无效碰撞和合成反应。在本文的改进算法中,为加快收敛速度,在双分子合成反应中取较好的分子进行双分子的碰撞和合成反应及置换反应,以提高反应的优化速度。

在每次化学反应后,都将通过一个贪心过程来更新反应物分子。在单分子反应中,如果产生出来的新分子比原分子更好,则新分子取代了原分子;在双分子反应中,如果产生的两个新分子比原分子更好,将产生的新分子以一定的概率取代对应的分子;如果只有一个更好的新分子,则取代其中一个反应分子。这个更新规则保证了反应物的数量一致,不仅简化了算法实现,而且比化学反应有更快的收敛速度。

3.4 基于化学反应优化的高阶神经网络训练方法

在高层神经网络中,设输入样本向量为 $\{X_i \in R^k, i=1, 2, \dots, n\}$,目标值为 $\{y_i \in R, i=1, 2, \dots, n\}$,样本的个数为 n 。因此输入层的节点数为 K ,设隐含层的节点数为 H ,则需要训练的权值向量 W 为 $K * H$ 的权值向量 $W = \{w_{11}, w_{12}, \dots, w_{1H}, w_{21}, \dots, w_{KH}\}$,其中, w_{ij} ($w_{ij} \in R, i=1, 2, \dots, K, j=1, \dots, H$)为第 i 个输入节点到第 j 个隐含层节点的连接权值。

对应到化学反应优化训练算法中,一个权值向量 W 对应一个反应物分子。化学反应优化算法的目标就是经过权值向

量的调整,使得神经网络的输出值 $\{d_i \in R, i=1, 2, \dots, n\}$ 尽可能接近目标值,因此可以定义化学反应算法的能量函数为预测值的均方误差MSE,即

$$f = MSE = \sum_{i=1}^n (d_i - y_i)^2 \quad (6)$$

将化学反应优化算法应用到PSNN的训练过程中,运用改进的CRO和更新过程更新PSNN权值向量,得到算法1。

算法1 基于化学反应优化的HONN训练算法

- Step 1 初始化:设定神经网络输入节点数 K 、中间节点数 H ,反应物分子种群大小 N_p ;初始化反应物种群中的分子,即权值向量,初始分子群记作 $P^0 = \{R_1^0, R_2^0, \dots, R_{N_p}^0\}$,其中 $R_i^0 = (w_{i1}^0, w_{i2}^0, \dots, w_{iD}^0)$ 为第 i ($i=1, 2, \dots, N_p$)个初始反应物分子,初始权值的随机生成服从 $[L, U]$ 上的均匀分布。设定终止条件迭代总数 NI ,终止迭代精度 ϵ ,化学反应优化的更新参数 p_1, p_2, p_3, p_4 。
- Step 2 设置迭代计数器 $i=0$ 。
- Step 3 计算各分子的能量函数值 $f(R_j^0)$ ($j=1, \dots, N_p$),并求出 $\min f = \min\{f(R_j^0), j=1, \dots, N_p\}$ 。
- Step 4 如果 $\min f < \epsilon$ 或 $i \leq NI$,转Step 5,否则转Step 8。
- Step 5 对每个 R_j^i ,执行:
- Step 5.1 在区间 $[0, 1]$ 中取随机值 r_1 ,若 $r_1 \leq p_1$,转Step 5.2;否则转Step 5.3。
- Step 5.2 在区间 $[0, 1]$ 中取随机值 r_2 ,若 $r_2 \leq p_2$,进行单分子分解反应,反之执行单分子无效碰撞反应,转Step 6。
- Step 5.3 在区间 $[0, 1]$ 中取随机值 r_3 ,若 $r_3 \leq p_3$,选择最好的反应物 R_k^i ($R_k^i \neq R_j^i$)与 R_j^i 进行双分子合成反应,转Step 6;否则转Step 5.4。
- Step 5.4 若 $r_3 \leq p_4$,随机选择分子 R_k^i ($R_k^i \neq R_j^i$),进行双分子置换反应,转Step 6。
- Step 5.5 随机选择另一分子 R_k^i ($R_k^i \neq R_j^i$),执行双分子无效碰撞反应。
- Step 6 更新反应分子,计算能量函数 $f(R_j^i)$ ($j=1, \dots, N_p$),求 $\min f = \min\{f(R_j^i), j=1, \dots, N_p\}$ 。
- Step 7 $i=i+1$,转Step 4。
- Step 8 求 $j^* = \operatorname{argmin}\{f(R_j^i), j=1, \dots, N_p\}$,将 $R_{j^*}^i$ 作为最优PSNN权值。

4 基于化学反应优化的高阶神经网络多示例学习方法

本文利用上述化学反应优化的高阶神经网络对提出的基于示例标记强度的MIL模型进行学习。

设每个示例是 K 维属性向量,HONN的输入节点数为 K ,隐含层节点数为 H ,因此权值向量的维数为 $D=K * H$,输出为单一实数,用来表示该示例的标记强度 $I(x_i)$,因为示例标记强度允许为负数,激活函数采用双曲正切函数 $\sigma(x) = \tanh(x)$ 。定义全局误差为:

$$MSE = \sum_{i=1}^n MSE_i \quad (7)$$

其中, MSE_i 是第 i 个包的均方误差。由于本模型的特殊性,均方误差的定义采用式(8)的函数来计算:

$$MSE_i = \begin{cases} 0, & L_i = 1, f(O_i) > \alpha \\ 0, & L_i = -1, f(O_i) < \beta \\ (\alpha - f(O_i))^2, & L_i = 1, f(O_i) > \alpha \\ (\beta - f(O_i))^2, & L_i = -1, f(O_i) < \beta \end{cases} \quad (8)$$

其中, $\alpha > 0$ 为正标记目标阈值, $\beta < 0$ 为负标记目标阈值, $O_i = (o_{i1}, o_{i2}, \dots, o_{ij})$ 为包 B_i 中示例的神经网络输出向量, $o_{ij} (j = 1, \dots, n_i)$ 为示例 B_{ij} 的输出, $f(O_i)$ 为预测包标记强度的函数,

这里定义 $f(O_i) = \sum_j^{n_i} o_{ij}$ 。在目标函数(8)的计算中,引入正和负标记目标阈值 α 和 β 的目的在于训练时尽量扩大正、负标记包之间的差别,而当输出包的标记强度符号与包标记相同且超过阈值时,均方误差定义为零,迫使预测包的标记强度正确反映包的标记情况。由均方误差函数(7)和(8)可以看到,采用梯度下降训练的方法并不合适,而化学反应优化则能方便地进行训练。

由第 2 节可知,每个示例 x_i 对应一个标记强度 $I(x_i)$,但示例标记强度未知,因此只能从包的层次来训练 HONN。以包为单位的化学反应优化训练过程如下:给定一个分子(权值向量) $R = (w_1, w_2, \dots, w_D)$,依次输入包 $B_i (i = 1, 2, \dots, n)$ 中的示例,计算出对应的 PSNN 输出 $o_{ij} (j = 1, \dots, n_i)$,得到该包的输出向量 $O_i = (o_{i1}, o_{i2}, \dots, o_{i, n_i})$,按照式(8)计算对应的 MSE_i ;将所有包的示例输入,得到该分子的能量函数: $f(R) = MSE = \sum_{i=1}^n MSE_i$ 。采用算法 1 训练出最好的分子,得到 PSNN 的最终权值。

当训练出神经网络的权值之后,包标记的预测就相当简单:输入包 B 的所有示例,当输出包的强度大于 0 时,则标记为正标记,否则标记为负标记。

5 实验结果与分析

为测试算法的有效性,本文采用文献[1-2,5]等所用的多示例测试 Musk 数据集。该数据分为 Musk1 和 Musk2 两种数据,如表 1 所列。从表中可以看到,Musk1 含有 47 个正包和 45 个负包,每个包的示例数量在 2 到 40 之间变化;而 Musk2 含有 39 个麝香分子和 63 个非麝香分子。Musk2 中的数量是 Musk1 的 13.8 倍,而包只多了 10 个,因此 Musk2 的学习难度更大。

表 1 Musk 测试数据集

	属性维数	示例数	正/负标记包数	包平均示例数
Musk1	166	476	47/45	5.17
Musk2	166	6598	39/63	64.69

对于 Musk 数据集,每个示例有一个 166 维的属性向量描述,因此设计的神经网络有 166 个输入单元,对应 166 个属性,而每一个属性输出为实数,隐含层节点数取为 3,因此权值向量的维数为 498,其他参数如表 2 所列。

表 2 HONN 运行参数

N_p	NI	ϵ	p_1	p_2	p_3	p_4	L	U	α	β
200	100	10E-6	0.7	0.5	0.33	0.66	-0.5	0.5	0.5	-0.5

本文训练的代数为 100,取 50 次的性能平均值与其他方法进行对比,如表 3 所列。从表中可以看到,本文提出的 ILI-MIL 方法在两个数据集上所得结果都比其他方案要好,特别是在 Musk2 的集合上表现更好。原因是本文的 ILI-MIL 方法在训练时同等看待正负标记包中的示例,从而可挖掘到更多的信息。本文的实验证明,当进一步增加迭代次数到 300 时,两个数据集的正确率可以增加至 93% 和 91% 以上,超过

了文献[2]中提到的特殊算法 IAPR 的 92.4% 和 39.2%。实验数据充分反映了 ILI-MIL 方法强大的表示能力和 HONN 网络的强大存储能力。

表 3 Musk 数据集上的分类正确率对比/%

算法	Musk1	Musk2
BP ^[1]	75.0	67.7
MI-NN ^[5]	88.9	82.5
BP-MIP ^[6]	83.8	80.4
mi-SVM ^[2]	87.4	83.6
ILI-MIL	89.6	86.4

为说明本文提出的模型的分​​类能力,对 Musk1 和 Musk2 的测试数据分别做 ROC 曲线分析,得到的 ROC 曲线如图 2 所示。从图 2 中可以看到,本分类器对 2 个数据集都具有很好的分类能力,分类器对 Musk2 数据集的分类能力略低于对 Musk1 数据集的分类能力,这也说明了 Musk2 数据集的分类较难,与事实相符。




图 2 Musk1 和 Musk2 数据集的 ROC 曲线

同时,本文也对文献[2]中的 3 个图像识别数据集(elephant, fox, tiger)进行了实验,每个数据集有 100 个正标记和 100 个负标记。因为有限的图像分割和较少的区域描述,训练集比较小,所以比上述 Musk 数据集更难分类。采用同样的参数,通过本文算法所得的分类准确率如表 4 所列,可以看到与传统方法^[2]相比本算法所得的分类准确性有显著的提高。当提高迭代次数到 300 时,准确率分别可以达到 93%, 78% 和 91%,明显高于其他算法。

表 4 图像数据集上的分类准确率对比

数据集	Elephant	Fox	Tiger
示例数	1391	1320	1220
特征数	230	230	230
EM-DD ^[2] /%	78.3	56.1	72.1
MI-SVM ^[2] /%	82.2	58.2	78.4
MI-SVM ^[2] /%	81.4	57.8	84.0
ILI-MIL/%	88.6	74.4	87.2

结束语 本文引入示例标记强度的概念,提出 ILI-MIL 方法,该方法同时考虑正、负标记示例的强度,充分体现了正负标记示例的共同作用,能反映现实世界中的真实情况。利用 PSNN 超常的非线性表达能力和计算高效的优势,采用高效快速的化学反应优化方法实现训练过程,简化了 ILI-MIL 方法的实现。实验结果表明,相较于其他类似的模型和方法,本文方法在分类准确性上有明显优势。

参考文献

[1] DIETTERICH T G, LATHROP R H, LOZANO-PEREZ T. Solving the multiple instance problem with axis-parallel rectangles[J]. Artificial Intelligence, 1997, 89(1/2): 31-71.

- 于沛东,李静,彭华.一种利用软判决的信道编码识别新算法[J].电子学报,2013,41(2):301-306.
- [5] XIE H, WANG F H, HUANG Z T. Blind recognition of $(n, 1, m)$ convolutional code based on maximum likelihood detection [J]. Journal of Electronics & Information Technology, 2013, 35(7):1671-1676. (in Chinese)
解辉,王风华,黄知涛.基于最大似然检测的 $(n, 1, m)$ 卷积码盲识别方法[J].电子与信息学报,2013,35(7):1671-1676.
- [6] CHEN J J, JI T Z, YANG J A. Blind recognition of linear block code under high error rate condition[J]. Journal of Applied Science, 2013, 31(5):459-467. (in Chinese)
陈金杰,计同钟,杨俊安.高误码条件下线性分组码的盲识别[J].应用科学学报,2013,31(5):459-467.
- [7] ZHU L X, LI L. Improved blind recognition method for binary cyclic code[J]. Journal of Computer Applications, 2013, 33(33):2762-2764, 2768. (in Chinese)
朱联祥,李荔.改进的二进制循环码盲识别方法[J].计算机应用,2013,33(33):2762-2764, 2768.
- [8] ZHENG R R, WANG L X. Recognition method of cyclic codes based on code weight distribution probability variance[J]. Journal of Terahertz Science and Electronic Information Technology, 2013, 11(5):792-796. (in Chinese)
郑瑞瑞,汪立新.基于码重分布概率方差的循环码识别方法[J].太赫兹科学与电子信息学报,2013,11(5):792-796.
- [9] CLUZEAU M, FINIASZ M. Recovering a code's length and synchronisation from a noisy intercepted bitstream [C]// Proceedings of the 2009 IEEE International Symposium on Information Theory (ISIT09). Seoul, Coree, Juillet, 2009:1-5.
- [10] YANG X W, GAN L. Blind estimation Algorithm of the linear lock codes parameters based on WHT[J]. Journal of Electronics & Information Technology, 2012, 34(7):1642-1646. (in Chinese)
杨晓炜,甘露.基于Walsh-Hadamard变换的线性分组码参数盲估计算法[J].电子与信息学报,2012,34(7):1642-1646.
- [11] WANG L X, LI D F. A new method for BCH codes of blind recognition[C]//2012 2nd International Conference on Materials Engineering for Advanced Technologies(ICMEAT). 2012:1403-1408.
- [12] KUO Y H, ZENG W T, CHEN J. Blind identification of primitive BCH codes parameters based on probability Approximation [J]. Journal of Electronics & Information Technology, 2014, 36(2):332-339. (in Chinese)
阔永红,曾伟涛,陈健.基于概率逼近的本原 BCH 码编码参数的盲识别方法[J].电子与信息学报,2014,36(2):332-339.
- [13] REN Y B, ZHANG J, LIU Y N, et al. Blind recognition of BCH codes under error conditions[J]. Journal of Computer Applications, 2014, 34(12):3618-3620, 3623. (in Chinese)
任亚博,张健,刘以农,等.误码条件下 BCH 码的盲识别方法[J].计算机应用,2014,34(12):3618-3620, 3623.
- [14] 王新梅,肖国镇.纠错码—原理与方法(修订版)[M].西安:西安电子科技大学出版社,2001.
- [15] YANG F Z. Research on technologies for high dimensional data mining[M]. Fujian: Southeast University Press, 2007. (in Chinese)
杨风召.高维数据挖掘技术研究[M].福建:东南大学出版社,2007.
- [16] SHU P. Life cycle cost model sensitivity analysis in power transformer[J]. Sichuan Electric Power Technology, 2013, 36(5):59-63. (in Chinese)
舒萍.电力变压器全寿命周期成本模型参量的敏感性分析[J].四川电力技术,2013,36(5):59-63.
- [17] LV X Z, HUANG Z P, SU S J. Fast recognition method for generator polynomial of BCH codes[J]. Journal of Xi'an University of electronic science and technology, 2011, 38(6):159-172. (in Chinese)
吕喜在,黄芝平,苏绍瓌. BCH 码生成多项式快速识别方法[J].西安电子科技大学学报,2011,38(6):159-172.
- [18] XIE H, WANG F H, HUANG Z T, et al. Blind detection and recognition of RS code based on spectral preprocessing[J]. Journal of Astronautics, 2013, 34(1):128-132. (in Chinese)
解辉,王丰华,黄知涛,等.基于频谱预处理的 RS 码盲检测识别方法[J].宇航学报,2013,34(1):128-132.

(上接第 267 页)

- [2] ANDRDWS S, TSOCHANTARIDIS I, HOFMANN T. Support vector machines for multiple-instance learning[M]// Advances in Neural Information Processing Systems. 2002:561-568.
- [3] XU Y Y, SHIH C H. Image Classification via Multiple-Instance Decision-Based Neural Networks[C]// 2013 Seventh International Conference on Image and Graphics (ICIG). IEEE, 2013:394-399.
- [4] TARRAG D S, CORNELIS C, BELLO R, et al. A multi-instance learning wrapper based on the Rocchio classifier for web index recommendation[J]. Knowledge-Based Systems, 2014, 59:173-181.
- [5] FOULDS J, FRANK E. A review of multi-instance learning assumptions[J]. The Knowledge Engineering Review, 2010, 25(1):1-25.
- [6] RAMON J, DE RAEDT L. Multi instance neural networks [C]// Proceedings of the ICML-2000 Workshop on Attribute-value and Relational Learning. 2000:53-60.
- [7] ZHOU Z H, ZHANG M L. Neural networks for multi-instance learning[C]// Proceedings of the International Conference on Intelligent Information Technology. Beijing, China, 2002:455-459.
- [8] XU Y Y, SHIH C H. Multiple-instance learning via decision based neural networks [M] // Intelligent Decision Technologies. Springer Berlin Heidelberg, 2011:885-895.
- [9] GHOSH J, SHIN Y. Efficient higher-order neural networks for classification and function approximation[J]. Int J Neural Syst, 1992, 3:323-350.
- [10] LAM A Y S, LI V O K. Chemical-reaction-inspired metaheuristic for optimization [J]. IEEE Transactions on Evolutionary Computation, 2010, 14(3):381-399.
- [11] LAM A Y S, LI V O K, XU J. On the convergence of chemical reaction optimization for combinatorial optimization[J]. IEEE Transactions on Evolutionary Computation, 2013, 17(5):605-620.