

# 基于进化深度学习的特征提取算法

陈 珍 夏靖波 柏 骏 徐 敏

(空军工程大学信息与导航学院 西安 710077)

**摘 要** 信息全面与维数灾难的矛盾是大数据时代网络态势感知需要解决的首要难题。特征提取一直是主流的降维方法,但现有算法对高维非线性数据效果不佳;深度学习是一类具有多层非线性映射的学习算法,可以完成复杂函数的逼近,但对隐层相关参数十分敏感。针对上述问题,将进化算法的思想引入深度学习,提出了一种基于进化深度学习的特征提取算法。该算法利用遗传算法及进化策略实现全局搜索及优化的特点,并对深度学习结构及相关参数进行了优化。理论分析及实验结果都证明了该算法的有效性。

**关键词** 网络态势感知,特征提取,进化算法,深度学习,波尔兹曼机

**中图分类号** TP393 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.11.059

## Feature Extraction Algorithm Based on Evolutionary Deep Learning

CHEN Zhen XIA Jing-bo BAI Jun XU Min

(Institute of Information and Navigation, Air Force Engineering University, Xi'an 710077, China)

**Abstract** The contradiction of comprehensive information and dimension curse is the preliminary problem of network situation awareness in the times of big data. Feature extraction is a mainstream method to dimensionality reduction, but performs not well when solving high-dimension and nonlinear data. Deep learning is a multi-layer and nonlinear algorithm which can realize the approximation of complicated function, however, it is sensitive to parameters related to hidden layer. Based on above analysis, a feature extraction algorithm based on evolutionary deep learning was proposed. The algorithm combines evolutionary algorithm (EA) and deep learning, takes advantage of the characteristics of GA and ES, and optimizes the learning structure and relevant parameters. Theoretical analysis and simulation results both prove the effectiveness of this algorithm.

**Keywords** Network situation awareness, Feature extraction, Evolution algorithm, Deep learning, RBM

## 1 引言

大数据时代的到来对大规模复杂网络的态势感知既是机遇又是挑战。一方面,纷繁多样的信息使得全面体现网络的运行态势成为可能;另一方面,海量、异构的数据则增加了数据处理的负担,大大制约着网络态势感知效益的发挥。为解决信息全面与维数灾难的矛盾,需要降低数据空间的维度。特征提取是通过合并特征,而不是删除特征,来减少特征维度,这种方法可以有效精简特征空间。常用的线性特征提取方法有主成分分析法(PCA)、基于 Fisher 准则的线性判别分析(LDA)和多位放缩(MDS)<sup>[1]</sup>。然而,高维数据空间的样本往往具有非线性结构,线性方法难以完全提取信息;当前各种具有浅层结构的非线性学习算法由于计算单元有限,其对复杂函数的表示能力也受到一定的制约。

理论分析指出,与浅层结构相比,由多层非线性映射层组成的深度结构更加高效<sup>[1-3]</sup>。深度学习是一类新兴的多层神经网络学习算法,通过组合低层特征形成更加抽象的高层表

示(属性类别或特征),以发现数据的分布式特征表示<sup>[4]</sup>。但是,深度学习层数以及隐层单元数的确定目前没有严格的理论指导,设置不当就可能带来处理时间过长或精度不够的问题。

进化算法(Evolutionary Algorithm, EA)是基于自然选择和自然遗传等生物进化机制的一种全局搜索和优化算法,主要包括遗传算法(Genetic Algorithm, GA)、遗传规划(Genetic Programming, GP)、进化策略(Evolutionary Strategies, ES)和进化规划(Evolutionary Programming, EP) 4 种典型方法。不同于普通搜索算法,进化算法具有以下优点:1)非线性,不需要函数梯度信息,也不需要函数的连续性;2)全局寻优;3)并行性,从多个点开始寻优,容易获得最优解。这些特点可以解决深度学习中遇到的问题。

基于以上分析,本文利用进化算法思想对深度学习算法进行了改进,提出基于进化深度学习的特征提取算法 EDL (Evolutionary Deep Learning)。该方法通过优化重建误差函数来构建性能良好的学习结构,提高处理效率,以期在不影响

到稿日期:2014-11-21 返修日期:2015-04-24 本文受陕西省自然科学基金项目(2012JZ8005)资助。

陈 珍(1990—),女,硕士生,主要研究方向为网络态势感知,E-mail:cz10184527@163.com;夏靖波(1963—),男,博士后,教授,主要研究方向为信息栅格网络、网络管理;柏 骏(1985—),男,博士生,主要研究方向为信息栅格、网络态势感知;徐 敏(1990—),女,硕士生,主要研究方向为网络流量测量。

精度的前提下,精简隐层结构,进而实现对原始数据的有效降维。

## 2 基本概念

### 2.1 遗传算法与进化策略

遗传算法(GA)是不需要求导的随机优化方法,以自然选择和演变过程为基础,在适应控制、数据库查询优化、机器学习等领域已成功应用。用遗传算法进行优化主要包括以下步骤<sup>[10]</sup>。

1) 编码方案和初始化:编码是对优化对象的编码;初始化是对各相关参数的初始化。

2) 适应度设计:适应度是衡量个体优劣的标志,通常是所研究问题的目标函数。

3) 选择:确定哪个父代参加下一代繁殖,体现“优胜劣汰”原则。

4) 交叉:利用当前基因库的潜能,产生新个体,保留良好特征。

5) 突变:在当前基因库没有需要的编码信息时,自发突变产生新个体。

进化策略(ES)是由德国柏林工业大学的 I. Rechenberg 等人于 1963 年提出的,是一类模仿自然进化原理以求解参数优化问题的算法。进化策略中应用比较广泛的是 $(\mu+\lambda)$ -ES 算法。 $(\mu+\lambda)$ -ES 算法的种群概念如下。

搜索开始时,建立一个初始种群 PA,包含个体数为  $\mu$ ,从初始种群开始,迭代计算一系列种群。每一次迭代中,从当前代 PA 产生  $\lambda$  个子代。在每种情况下,用 3 步计算产生一个子代:

1) 从当前代 PA 中无偏地选择两个个体作为父代用于重组;

2) 通过所选父代的重组,产生一个新个体;

3) 对新个体施行变异和评估。

迭代结束后,计算子代和父代的误差,通过对误差的排序,从  $\lambda$  个子代和  $\mu$  个 PA 代个体组成的集合中选择那些拥有最小误差的矢量作为下一代 PA+1,重复以上过程,直至达到精度要求。

### 2.2 深度学习

2006 年 Hinton 等人<sup>[5]</sup>在《科学》上发表的一篇文章开启了深度学习在机器学习领域的浪潮。深度学习源于传统的人工神经网络,其实质是通过构建具有多隐层的机器学习模型和海量的训练数据来学习更有用的特征,从而最终提升分类或预测的准确性。因此,“深度模型”是手段,“特征学习”是目的。区别于传统的浅层学习,深度学习的特点<sup>[6]</sup>在于:

1) 强调了模型结构的深度,通常有五、六层,甚至十多层的隐层节点;

2) 明确突出了特征学习的重要性,即通过逐层特征变换,将样本在原始空间的特征映射到一个新的特征空间,从而使分类或预测更加容易。

与人工规则构造特征的方法相比,利用大数据来学习特征,更能够挖掘数据丰富而全面的内在信息。

### 2.3 深度学习模型及方法

深度信任网络(Deep Belief Network, DBN)是目前研究和应用比较广泛的深度学习结构,由一系列的受限波尔兹曼

机(RBM)单元组成。RBM 是一种双向概率图模型,为了研究方便,一般假设所有可视层和隐层节点都是随机二值变量节点(只取 0 或 1),同时假设全概率分布  $p(v, h)$  满足 Boltzmann 分布。如图 1 所示,可见层与隐层之间双向全连接,而可见层与可见层、隐层与隐层之间无连接。




图 1 RBM 结构示意图

可见层向量  $V=\{0,1\}$  由输入节点和输出节点组成,是网络和环境之间的接触面,表示可观察的数据;隐单元向量  $h=\{0,1\}$  由隐节点组成,不与外界环境直接接触,主要作用是从数据中提取特征。

因为 RBM 是双向概率模型图,所以在已知  $v$  的情况下,所有的隐层节点之间是条件独立的(因为节点间无连接),即  $p(h|v)=p(h_1|v)p(h_2|v)\cdots p(h_n|v)$ 。同理,在已知  $h$  的情况下,所有可视层节点也是条件独立的。又因为所有的  $v$  和  $h$  节点都服从 Boltzmann 分布,当输入  $v$  时,通过  $p(h|v)$  可以得到隐层  $h$ ,而得到  $h$  之后,又可以通过  $p(v|h)$  得到新的可视层  $v_1$ 。特征学习就是通过调整连接权值使新得到的可视层  $v_1$  与原来的可视层  $v$  一样,如果一样或逼近一样,那么就可以将隐层看作是可视层输入数据的特征。图 2 是波尔兹曼机的学习过程。




图 2 波尔兹曼机学习过程示意图

由波尔兹曼机的能量函数表达式<sup>[7]</sup>可以推导出 RBM 结构中可视层与隐层节点之间的能量函数为:

$$E(v, h; \psi) = -v^T W h - v^T B - h^T A$$

$$= -\sum_{i=1}^D \sum_{j=1}^K w_{ij} v_i h_j - \sum_{i=1}^D b_i v_i - \sum_{j=1}^K a_j h_j \quad (1)$$

其中,  $\psi = \{W, a, b\}$  为模型参数。

将能量函数指数化并正则化,通过 Boltzmann 分布,就可以得出可视节点与隐层节点的联合概率分布:

$$p_{\psi}(v, h; \psi) = \frac{1}{Z(\psi)} \exp(-E(v, h; \psi))$$

$$= \frac{1}{Z(\psi)} \prod_{ij} e^{w_{ij} v_i h_j} \prod_i e^{b_i v_i} \prod_j e^{a_j h_j} \quad (2)$$

其中,  $Z(\psi) = \sum_{h,v} \exp(-E(v, h; \psi))$  为配分函数。

上文已知,  $p(h|v) = \prod_j p(h_j|v)$ , 在给定可视层  $v$  的基础上,对此式进行因式分解,可以得到隐层节点  $j$  为 0 或 1 的概率为:

$$p(h_j = 1 | v) = \frac{1}{1 + \exp(-\sum_i W_{ij} v_i - a_j)} \quad (3)$$

同理,在给定隐层  $h$  的基础上,可视层节点  $i$  为 0 或 1 的概率为:

$$p(v_i = 1 | h) = \frac{1}{1 + \exp(-\sum_j W_{ij} h_j - b_i)} \quad (4)$$

通过  $p(v|h) = \prod_i p(v_i|h)$  就可重构得到新的可视层  $v_1$ , 那么  $p(v_1 = 1 | h)$  也可以得到。

通过自底向上组合多个 RBM, 就可以得到 DBN。为了获取连接权值,一般采用贪婪无监督逐层预训练算法<sup>[11]</sup>来实

现:首先采用无监督学习算法对深度结构神经网络的底层进行训练,生成第一层的初始参数值;然后将第一层的输出作为第二层的输入,同样采用无监督学习算法对该层参数进行初始化;以此类推,这个过程被称为预训练。预训练之后,在最后一层,DBN就利用带标签样本用BP算法对最后的判别性能作调整。算法过程如图3所示。

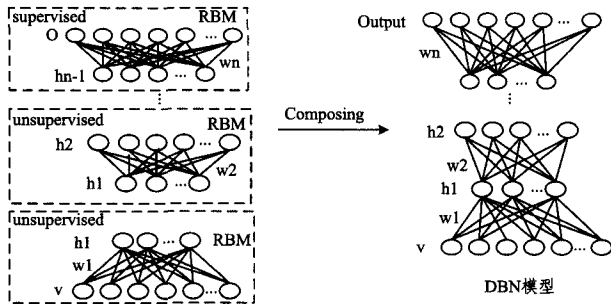


图3 贪婪无监督逐层训练算法示意图

### 3 EDL 算法

EDL算法是将进化算法的核心思想融入到深度学习的全过程,以达到最小化重建误差、优化学习模型结构的效果。

#### 3.1 学习结构编码及初始化

学习结构主要是指隐层层数、隐层节点数,这里对隐层节点数及相应的网络参数进行编码。所谓的网络参数,即式(1)中涉及的参数: $W$ 代表可视层与隐层之间的连接权值; $b, a$ 分别代表可视层与隐层的偏置值。但因为不同隐层的节点数不同,对应参数的维数也不相同,所以编码后形成的码串长度不一,这样就无法进行后面的交叉运算。这一问题可以使用MATLAB中的元胞数组解决,表1是对各参数的编码(每一列代表元胞数组中的一个元素)。

表1 编码方案

	可视层到隐层	隐层到隐层的	隐层到输出层	可视层与隐层
$n$	的权值矩阵:	权值矩阵:	的权值矩阵:	的阈值矩阵:
	$v \times n$	$n_i \times n_j$	$n \times o$	$1 \times n$

其中, $n$ 表示隐层的初始节点数; $v$ 和 $o$ 分别表示输入、输出节点数。区别于神经网络的随机初始化,深度学习中参数的初始化是采用无监督学习完成的,即逐层通过对输入数据的无监督预训练来学习初始参数,这样可以减小初值对整个学习过程的影响,提高学习效率。

#### 3.2 适合度函数设计

将进化思想引入深度学习的主要目的是使学习模型在满足一定精度要求的前提下具有最简单的网络结构。本文中学习模型的构建及优化主要是通过最小化重建误差完成的,因此,将重建误差作为优化对象。本文采用的重建误差是通过对比初始可视层节点 $i$ 的状态概率与模型重建后新可视层对应节点 $i'$ 的状态概率而得到的。通常情况下,采用K-L离差(Kullback-Leibler divergence)度量这两个概率的相近度<sup>[7]</sup>:

$$G = \sum_{i=1}^D p(v=i) \ln \left( \frac{p(v=i)}{p(v1=i')} \right) \quad (5)$$

其中, $D$ 是输入数据的维数,当且仅当 $p(v=i) = p(v1=i')$ 时, $G=0$ 。式(5)就是所需的适合度函数。

#### 3.3 选择

这个阶段的任务是利用式(5)给出的离差函数计算出各点的离差值(即适应度值),从而根据适应度值的大小选择性能较好的隐层节点产生新群体。节点被选的概率应该与该节点的适应度值成反比,即“择优录取”<sup>[8]</sup>。实现这种方案最常见的方式是按照式(6)设定选择概率 $p$ (以其中一层为例):

$$p_i = \frac{g_i}{\sum_{j=1}^n g_j} \quad (6)$$

式中, $n$ 是隐层节点数量, $g_i$ 是第 $i$ 个节点的离差值(适应度值)。这种选择方法利于父代的优良基因继续传承下去。计算出各节点的适应度值后,对适应度值进行排序,设定一个适应度阈值 $\epsilon$ ,选出 $g < \epsilon$ 的节点作为新一代隐层节点。

#### 3.4 变异

这一阶段主要是针对精度不够的问题实施操作。原始数据是海量且高维的,如果适应度值符合要求的节点数量有限,就有可能出现欠拟合即特征无法充分挖掘的情况。所以,必要的时候可以以一定的概率更新不符合要求的节点的相关参数,即可看作是不符合要求的节点发生了变异,直至达到精度要求。

各参数可以按照以下公式进行变异:

$$\Delta w = a \Delta w + \beta \frac{\partial G}{\partial w_{ij}} \quad (7)$$

$$\Delta b = a \Delta b + \beta \frac{\partial G}{\partial b_i} \quad (8)$$

$$\Delta a = a \Delta a + \beta \frac{\partial G}{\partial a_j} \quad (9)$$

$$w1 = w + \Delta w \quad (10)$$

$$b1 = b + \Delta b \quad (11)$$

$$a1 = a + \Delta a \quad (12)$$

其中, $a$ 为动力常数,可以使参数的变化更为平滑,取值范围是 $[0.1, 1]$ ,通常设定为 $0.5$ <sup>[10]</sup>; $\beta$ 为学习率,调整参数变化的大小,取值范围 $[0, 1]$ ,学习率的选取很重要,过大可能会导致系统的不稳定,过小则会使训练时间过长,收敛慢,达不到要求的误差。经反复实验得出,当 $\beta=0.1$ 时,网络的稳定性及收敛速度均在可接受范围内,所以本文取 $\beta$ 为 $0.1$ ; $\Delta w, \Delta b$ 及 $\Delta a$ 的初始值均为 $0$ 。

#### 3.5 编程方案

EDL算法流程如图4所示。

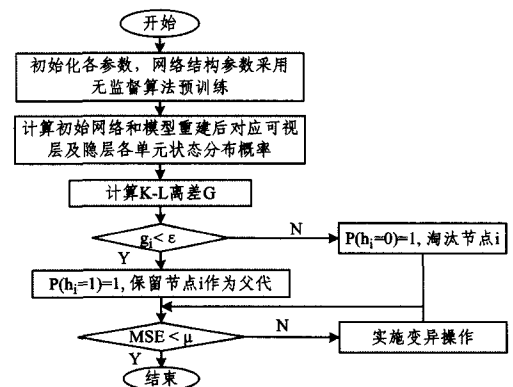


图4 EDL算法流程

### 4 仿真实验

本实验是在Deep Learning Toolbox基础上,对其中相关程序按照EDL算法思想进行了改进。为了验证本算法的性能,从运算时间、误差精度等方面与原深度学习算法进行了MATLAB仿真对比,实验数据来自Deep Learning Toolbox

和 UCI 数据集。实验中初始隐层节点数设为 200, 经训练、优化后最终构成含 3 隐层的深度网络结构, 维度分别为 150、100 和 50, 即 150-100-50。实验结果如表 2 所列。

表 2  $\alpha=0(0.5), \beta=(0.1), rbm. epoch=3, dbn. epoch=3$

迭代次数	Average reconstruction error	Mean squared error	Elapsed time(s)
1/3	67.6224 (52.594)		
2/3	55.9225 (48.4813)		
3/3	48.0629 (44.5173)		
1/3	64.5237 (45.0857)	0.17025	18.215153
2/3	47.6489 (40.194)	(0.14389)	(13.628748)
3/3	43.5532 (32.1023)		
1/3	15.2766 (24.0399)		
2/3	11.204 (20.7395)		
3/3	10.56 (13.3915)		

其中, *rbm. epoch* 表示波尔兹曼机训练时的迭代次数, *dbn. epoch* 表示深度信任网络的迭代次数, 括号中是算法改进后相应的性能参数。

通过实验数据对比可以发现, 虽然平均均方误差降低的幅度很小, 只降低了 0.026, 但是重建误差的变化平滑了许多, 这说明网络结构的稳定性得到了提高; 耗时方面可以看到, 改进后的算法时间缩短将近 5s, 即时间效率提高了 25%。因此, EDL 算法与原有深度学习相比, 在性能上得到了明显的提升。

图 5—图 7 是网络结构优化过程中, 各隐层结构下图像的识别性能对比(直方图横坐标表示图像的灰度值, 纵坐标表示相应灰度的个数)。




图 5 隐层节点为 200 时的图像特征提取




图 6 隐层结构为 150-100-50 时的图像特征提取




图 7 隐层结构为 150-125-100 时的图像特征提取

由 3 幅图的对比可以发现, 随着隐层深度及节点数的增加, 图像的识别度越来越高, 当达到 150-100-50 时已经在人眼可识别范围, 结构为 150-125-100 时识别度有所提高, 但耗时也相应地增加。所以, 综合识别度和耗时量最终确定深度学习模型的最佳结构为 150-100-50。

**结束语** 本文针对现有特征提取方法的局限性, 利用进化算法可以全局寻优的特点, 对深度学习进行了改进, 优化了深度学习的模型结构及相关参数的设定机制。实验结果表明, 该算法在时间和精度上都取得了不错的效果, 但是随着时间的推进, 性能呈下降趋势。因此, 算法稳定性是下一步解决的重点。如果改进得当, 这将为基于模式识别的网络态势感知提供一种新的解决方案。

## 参考文献

- [1] 孙志军, 薛磊, 许阳明. 基于深度学习的边缘 Fisher 分析特征提取算法[J]. 电子与信息学报, 2013, 35(4): 805-811  
Sun Zhi-jun, Xue Lei, Xu Yang-ming. Marginal Fisher Feature Extraction Algorithm Based on Deep Learning[J]. Journal of Electronics & Information Technology, 2013, 35(4): 805-811
- [2] Bengio Y, Delalleau O. On the expressive power of deep architecture [M]// Algorithmic Learning Theory. Springer, 2011: 18-36
- [3] Bengio Y. Deep Learning of representations for unsupervised and transfer learning[C]// JMLR. Washington, USA, 2012: 17-36
- [4] 孙志军, 薛磊, 许阳明, 等. 深度学习研究综述[J]. 计算机应用研究, 2012, 29(8): 2806-2810  
Sun Zhi-jun, Xue Lei, Xu Yang-ming, et al. Overview of deep learning[J]. Application Research of Computers, 2012, 29(8): 2806-2810
- [5] Hinton G, Salakhutdinov R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507
- [6] 余凯, 贾磊, 陈雨强, 等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799-1804  
Yu Kai, Jia Lei, Chen Yu-qiang, et al. Deep learning: Yesterday, Today, and Tomorrow[J]. Journal of Computer Research and Development, 2013, 50(9): 1799-1804
- [7] 刘建伟, 刘媛, 罗雄麟. 波尔兹曼机研究进展[J]. 计算机研究与发展, 2014, 51(1): 1-16  
Liu Jian-wei, Liu Yuan, Luo Xiong-lin. Research and Development of Boltzmann Machine[J]. Journal of Computer Research and Development, 2014, 51(1): 1-16
- [8] 徐敏, 夏靖波, 申健, 等. 基于 LEAST 的高速网络大流检测算法[J]. 空军工程大学学报, 2015, 8: 25-30  
Xu min, Xia Jing-bo, Shen Jian, et al. Based on LESET High-Speed Network Traffic Measurement Method[J]. Journal of Air Force Engineering University, 2015, 8: 25-30
- [9] Hinton, Salakhutdinov R. Training a deep auto-encoder or a classifier on MNIST digits[OL]. [http://www.cs.toronto.edu/Hinton/Matlab For Science Paper. html](http://www.cs.toronto.edu/Hinton/Matlab%20For%20Science%20Paper.html)
- [10] Kantardzic M. Data Mining: Conception, Model, and Algorithm (Edition 2)[M]. Beijing: Tsinghua University press, 2013
- [11] Bengio Y, Lamblin P, Popovici D, et al. Greedy layer-wise training of deep networks [C]// Proc of the 12th Annual Conference on Neural Information Processing System. 2006: 153-160
- [12] Hinton G, Osindero S, Teh Y. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554
- [13] 方敏, 王宝树. 基于进化策略的多传感器雷达辐射源目标识别方

- 法[J]. 控制理论与应用, 2004, 21(2): 165-168
- Fang Min, Wang Bao-shu. Multi-sensor radar radiation source target recognition based on evolution strategy method[J]. Control Theory and Application, 2004, 21(2): 165-168
- [14] 李鸿儒, 王晓楠, 高全. 基于免疫进化策略的神经网络优化方法[J]. 东北大学学报(自然科学版), 2008, 29(6): 794-797
- Li Hong-ru, Wang Xiao-nan, Gao Tong. Optimization Algorithm Based on Immune Evolutionary Strategy of Neural Network[J]. Journal of Northeast University(Natural Science), 2008, 29(6): 794-797
- 
- (上接第 278 页)
- [3] Greco S, Matarazzo B, Slowinski R. Rough sets theory for multi-criteria decision analysis[J]. European Journal of Operational Research, 2001, 129(1): 1-47
- [4] Greco S, Matarazzo B, Slowinski R. Rough sets methodology for sorting problems in presence of multiple attributes and criteria[J]. European Journal of Operational Research, 2002, 138(2): 247-259
- [5] 苟光磊, 王国胤, 利节, 等. 基于置信优势关系的粗糙集近似模型[J]. 控制与决策, 2014, 29(7): 1325-1329
- Gou Guang-lei, Wang Guo-yin, Li jie, et al. Confidential dominance relation based rough approximation model[J]. Control and Decision, 2014, 29(7): 1325-1329
- [6] Liu Jian, Xue Li, Liu Si-feng, et al. Research on multiple-attribute decision making problems based on the superiority index[J]. Control and Decision, 2010, 25(7): 1079-1087
- [7] 陈万翠, 吕跃进, 翁世洲. 基于容差优势关系的排序方法及其应用[J]. 计算机应用, 2014, 34(8): 2170-2174
- Chen Wan-cui, Lv Yue-jin, Weng Shi-zhou. Sorting method and its application based on tolerance dominance relation[J]. Journal of Computer Applications, 2014, 34(8): 2170-2174
- [8] 王利东, 田晓娟, 杨艳冰. 基于熵权与优势关系的教学效果评价方案[J]. 数学的实践与认识, 2014, 44(10): 8-12
- Wang Li-dong, Tian Xiao-juan, Yang Yan-bing. The comprehensive evaluation of teaching based on entropy weight and dominance relation[J]. Journal of Mathematics in Practice and Theory, 2014, 44(10): 8-12
- [9] 李金鹏, 岳超源, 李武. 一类基于优势关系的不完全信息多属性决策方法[J]. 控制与决策, 2013, 28(2): 229-234
- Li Jin-peng, Yue Chao-yuan, Li Wu. A dominance relation-based decision making approach for multi-attribute decision making problems with incomplete information[J]. Control and Decision, 2013, 28(2): 229-234
- [10] 邱涤珊, 贺川, 朱晓敏. 基于概率可信度的区间数排序方法[J]. 控制与决策, 2012, 27(12): 1894-1898
- Qiu Di-shan, He Chuan, Zhu Xiao-min. Ranking method research of interval numbers based on probability[J]. Control and Decision, 2012, 27(12): 1894-1898
- [11] 徐智明, 刘宏, 马琳, 等. 基于可能度优势关系的区间序粗糙集模型[J]. 舰船电子工程, 2012, 32(9): 40-42
- Xu Zhi-ming, Liu Hong, Ma Lin, et al. Interval ordered rough set model based on possible degree dominance relation[J]. Ship Electronic Engineering, 2012, 32(9): 40-42
- [12] Hu Ming-li, Li Lin-li. A novel dominance relation and application in interval grey number decision model[J]. Journal of Grey System, 2014, 26(1): 91-98
- [13] Qian Yu-hua, Liang Ji-ye, Dang Chuang-yin. Interval ordered information systems[J]. Computers and Mathematics with Applications, 2008, 56(8): 1994-2009
- [14] 王晓妍. 不完备信息系统中优势关系粗糙集决策方法研究[D]. 哈尔滨: 哈尔滨理工大学, 2014
- Wang Xiao-yan. Study on decision-making approaches based on dominance relation rough sets in incomplete information system [D]. Harbin: Harbin University of Science and Technology, 2014
- [15] 王斌, 邵明文, 王金鹤, 等. 基于改进的优势关系下的不完备区间值信息系统评估模型[J]. 计算机科学, 2014, 41(2): 253-256
- Wang Bin, Shao Ming-wen, Wang Jin-he, et al. New evaluation model for incomplete interval-valued information system based on improved dominance relations[J]. Computer Science, 2014, 41(2): 253-256
- [16] 杨青山, 王国胤, 张清华, 等. 基于优势关系的区间值粗糙集扩充模型[J]. 山东大学学报(理学版), 2010, 45(9): 7-13
- Yang Qing-shan, Wang Guo-yin, Zhang Qing-hua, et al. The interval-valued rough set extended model based on the dominance relation[J]. Journal of Shandong University(Natural Science), 2010, 45(9): 7-13
- [17] 刘学生. 基于粗糙的不确定多属性决策排序法的研究[D]. 大连: 大连理工大学, 2009
- Liu Xue-sheng. Research on uncertain multiple attribute decision ranking based on rough sets[D]. Dalian: Dalian University of Technology, 2009
- [18] 翁世洲, 吕跃进, 莫京兰. 基于优势关系的排序模型及其保序性约简理论[J]. 广西师范大学学报(自然科学版), 2013, 31(3): 37-44
- Weng Shi-zhou, Lv Yue-jin, Mo Jing-lan. Ranking model and preserving reduction based on dominance relation[J]. Journal of Guangxi Normal University(Natural Science Edition), 2013, 31(3): 37-44
- [19] 郭金维, 蒲绪强, 高祥, 等. 一种改进的多目标决策指标权重计算方法[J]. 西安电子科技大学学报, 2014, 41(6): 118-125
- Guo Jin-wei, Pu Xu-qiang, Gao Xiang, et al. Improved method on weights determination of indexes in multi-objective decision[J]. Journal of Xidian University, 2014, 41(6): 118-125