

基于深度玻尔兹曼机的文本特征提取研究

张立民, 刘 凯

(海军航空工程学院 电子信息工程系, 山东 烟台 264001)

摘 要: 鉴于深度学习模型在进行知识推理相关研究时提取抽象概念的优势, 在目前对文本特征提取性能较好的浅层结构 RSM 的基础上构建以 RSM 为特征抽取器的深度玻尔兹曼机模型. 通过新模型的能量函数和网络连接关系, 对模型组成单元的后验概率进行推导, 并结合新的交叉熵稀疏惩罚因子, 给出模型的详细学习算法. 经 20-new-groups 文档集上测试证明, 经过交叉熵稀疏惩罚因子影响后的新模型提取出的特征在对文本表征上性能较好, 相比于浅层模型 RSM, 其分类准确度更高, 概念更加抽象, 在处理大规模文本分析上具有良好的可行性.

关键词: 文本特征; 多重 softmax 模型; 深度学习; 深度玻尔兹曼机; 稀疏表示

中图分类号: TP393

文献标识码: A

文章编号: 1000-7180(2015)02-0142-06

Document Features Extraction Based on DBM

ZHANG Li-min, LIU Kai

(Department of Electronic and Information Engineering, Naval Aeronautical and Astronautical University, Yantai 264001, China)

Abstract: According to the advantages of deep learning model in the extraction of abstract concept, a new Deep Boltzmann Machine is designed based on the outperform model-Replicate Softmax Model. Based on Replicate Softmax Model and structure of the new Deep Boltzmann Machine, energy function of this model is proposed and the detail learning algorithm is introduced. The learning can be made more efficient by using a layer-by-layer “pre-training” phase that allows variational inference to be initialized with a single bottom up pass. The values of the latent variables in the deepest layer are easy to infer and give a much better representation of each document than low learning. The 20-newsgroups document sets experiment results illustrated that the novel algorithm learn good generative models, get the better competence of a shallow model-Replicate Softmax Model in handling with an extract abstract concept and has good feasibility in large scale document analysis.

Key words: document features; replicate softmax models; deep learning; deep boltzmann machines; sparse representation

1 引言

文本分析目的都是在于如何准确、高效地提取文档信息和分析文本语义. 概率主题模型^[1,2,3]是目前主要的分析和提取文本语义的方法, 很多存在的语义模型都是基于每一个文档是多个主题组合的假设上进行的. 从模型连接方式来讲, 这些模型均为有向图, 但有向图存在难以推断的问题, 很难计算基于主题的后验概率.

2006 年 Hinton 在^[4]中构建了第一个具有标志

性意义的深度学习机制—深度信念网络 (Deep Belief Net, DBN), 提出了深度学习 (Deep Learning) 的概念. 已经被广泛应用到各种领域, 如数据降维^[5]、语音识别^[6]、网络态势感知^[7]、图像转换^[8]、以及高维时间序列建模^[9]等.

鉴于深度学习模型, 并利用基于多项分布的文本分析模型—RSM (Replicated Softmax Model, RSM), 本文设计了以其为基础的深度玻尔兹曼机 (Deep Boltzmann Machine, DBM), 用于对文本特征进行提取, 并针对 RBM 训练过程中出现的特征

同质化问题引入新的稀疏惩罚因子,以更好地表征文本特征.

2 受限玻尔兹曼机模型

2.1 受限玻尔兹曼机

受限玻尔兹曼机(RBM)^[10]是在玻尔兹曼机的基础上增加了限定条件形成的双向连接马尔科夫随机场(MRF),其中层内单元无连接、层间单元全连接,模型结构如图 1 所示.




图 1 RBM 单元连接图

对于包含 N 个二值可见单元和 M 个二值隐单元的 RBM, 设定 v_i 表示第 i 个可见单元的状态, h_j 表示第 j 个隐单元状态. 那么, 给定状态 (v, h) 所具备的能量定义如式(1) 所示^[11].

$$E(v, h) = - \sum_{i=1}^N v_i b_i - \sum_{j=1}^M h_j c_j - \sum_{i=1}^N \sum_{j=1}^M W_{ij} v_i h_j \quad (1)$$

式中, W_{ij} 表示可视单元 i 与隐单元 j 之间的连接权值, b_i 表示可视单元 i 的偏置, c_j 表示隐单元 j 的偏置, 则 RBM 处于状态 (v, h) 的概率如式(2) 所示.

$$P(v, h) = \frac{1}{Z} \exp(-E(v, h)) \quad (2)$$

式中, $Z = \sum_{v, h} \exp(-E(v, h))$ 为归一化因子(剖分函数).

由于层间单元是无连接的, 可以推导出隐单元和可见单元的后验激活概率, 分别如式(3)、(4) 所示^[12].

$$P(v_i = 1 | h) = \text{sigm} \left(\sum_{j=1}^m W_{ij} h_j + b_i \right) v \quad (3)$$

$$P(h_j = 1 | v) = \text{sigm} \left(\sum_{i=1}^n W_{ij} v_i + c_j \right) \quad (4)$$

式中, $\text{sigm}(x) = 1 / (1 + \exp(-x))$.

2.2 RSM 模型

Salakhutdinov 在^[13] 中提出了 RSM, 是在 RBM 的基础上将可见单元看作为多项分布变量, 以实现了文本表示. RSM 中, 对于一个文本样本, 设定每一个词汇 $v \in \{1, \dots, K\}^D$, 其中 K 是词汇字典容量, D 是该文本词汇数量; 隐单元 $h \in \{0, 1\}^F$ 代表潜在语义, 故 RSM 中可见单元为一个 $K \times D$ 的二值矩阵

($v_i^k = 1$ 表示在可见单元 i 的位置上出现的是第 k 个词汇), 并且在 RSM 中, 设定同一个词汇的偏置 b_i^k 和 W_{ij}^k 是相同的, 因此其能量形式如式(5) 所示.

$$E(V, H) = - \sum_{j=1}^F \sum_{k=1}^K W_{ij}^k h_j \hat{v}^k - \sum_{k=1}^K \hat{v}^k b^k - D \sum_{j=1}^F h_j c_j \quad (5)$$

式中, $\hat{v}^k = \sum_{i=1}^D v_i^k$ 表示文档中第 k 个词汇出现的个数; 通过式(5), 将得到可见单元和隐单元的后验激活概率分别如式(6)、(7) 所示.

$$p(v_i^k = 1 | h) = \frac{\exp(b_i^k + \sum_{j=1}^F h_j W_{ij}^k)}{\sum_{q=1}^K \exp(b_i^q + \sum_{j=1}^F h_j W_{ij}^q)} \quad (6)$$

$$p(h_j = 1 | V) = \text{sigm} \left(c_j + \sum_{i=1}^D \sum_{k=1}^K v_i^k W_{ij}^k \right) \quad (7)$$

3 深度玻尔兹曼机

深度学习是一种建立、模拟人脑进行分析学习的神经网络. 其特点是具有多隐藏层的多层感知器结构.

3.1 基于 RSM 的 DBM

深度玻尔兹曼机(Deep Boltzmann Machine, DBM)^[14]是由多层 RBM 叠加而成的, 不同于 Hinton 提出的 DBN 模型之处在于其中间层与相邻层是双向连接的. 以包含两层隐单元的 DBM 为例, 其能量形式如式(8) 所示(为方便显示, 忽略掉模型中各单元的偏置).

$$E(v, h; \theta) = -v^T W^{(1)} h^{(1)T} - h^{(1)T} W^{(2)} h^{(2)} \quad (8)$$

式中, $v \in \{0, 1\}^N$ 为可见单元, $h^{(1)} \in \{0, 1\}^{M_1}$ 为第一层隐单元, $W^{(1)}$ 为第一组单元连接权值, $h^{(2)} \in \{0, 1\}^{M_2}$ 为第二层隐单元, $W^{(2)}$ 为第二组单元连接权值, 整个模型的结构如图 2 所示.




图 2 DBM 单元连接图

通过对 RSM 的介绍和 DBM 构造机制的分析, 将图 2 最底层单元换为 RSM 中的可见单元, 即构成了基于 RSM 的深度玻尔兹曼机模型, 其模型的

工作机制原理如下:将底层的输出数据特征作为顶层 RBM 的输入,通过微调参数和权值偏置来增强 DBM 的特征抽取能力,以达到自动特征提取的目的.在给定某个样本 $\{v^1, v^2, \dots, v^K\}$ 下,整个模型的概率如式(9)所示.

$$P(v; \theta) = \sum_{h^{(1)}, h^{(2)}} P(h^{(1)}, h^{(2)}) \left(\sum_{h^{(1)}} P(v, h^{(1)}) \right) \quad (9)$$

由于底层单元与上层单元只与中间层单元连接,故其后验激活概率可参照式(3)(4)得出.因此只列出模型中间层单元的后验激活概率如式(10)所示.

$$P(h_j^{(1)} = 1 | v, h^{(2)}) = \text{sigm} \left(\sum_{i=1}^D \sum_{k=1}^K v_i^k W_{ij}^k + \sum_m W_{jm}^{(2)} h_j^{(2)} \right) \quad (10)$$

3.2 基于交叉熵的稀疏惩罚因子

在 RBM 对网络连接权值进行学习的过程中,存在的一个主要问题是特征学习的同质化:由于所有隐单元都是在相互独立的基础上对训练数据进行学习的,因此当训练数据中存在某种共有特征时,隐单元极有可能均会受到影响,其表现在于 RBM 学习到的连接权值(也就是数据特征模式)之间的列(对应于每个隐单元)相似度过高,而解决这一问题的方法就是调节隐单元的稀疏性.在信号理论中,所谓变量稀疏意味着该随机变量在大多数情况下的值为 0,并且在很少的时候取值为非零,而且其值偏离 0 较远.隐单元稀疏化就是使大多数隐单元处于不激活状态,而仅仅使部分隐单元来表征训练数据;对于某一个特定的隐单元来说,整体稀疏化也就是使该隐单元仅被用来表示很小的一部分训练数据,从而就可以避免隐单元特征同质化问题.

Lee 在文献[15]中通过对 RBM 训练的最大似然目标函数增加稀疏惩罚因子—隐单元的期望与稀疏度之间的误差平方和,来抑制隐单元的激活概率(由于隐单元为二进制单元,其期望即为激活概率),以得到稀疏受限玻尔兹曼机(Sparse RBM).但该方法存在的问题是:惩罚因子只对隐单元偏置进行了影响,没有考虑连接权值,并且惩罚因子对于隐单元的稀疏化力度随着隐单元平均激活概率的下降而减弱.为了克服这一问题,需要提出一种新的稀疏惩罚因子.

两个随机分布 $q(x)$ 与 $p(x)$ 之间的交叉熵(cross entropy)等价于 $p(x)$ 与 $q(x)$ 之间的 Kullback-Leiber 距离与 $p(x)$ 的熵之和,定义如式

(11) 所示.

$$\text{CrossEntropy} = - \int p(x) \ln q(x) dx \quad (11)$$

当 $q(x)$ 等于 $p(x)$ 时,交叉熵最小,即 Kullback-Leiber 距离最小;相比于误差平方和,交叉熵在估计小概率值时更为合理.

利用交叉熵的概念,将 $p(x)$ 作为隐单元稀疏度系数 p , $q(x)$ 作为隐单元激活概率分布,设定 RBM 隐单元个数为 M , L 为训练样本集 V 的个数,提出新的稀疏惩罚因子—交叉熵稀疏惩罚因子,如式(12)所示.

$$P_{\text{cross-entropy}} = \sum_{j=1}^M \left[p \log \left(\frac{1}{L} \sum_{l=1}^L P(h_j^{(1)} | V) \right) + (1-p) \log \left(1 - \frac{1}{L} \sum_{l=1}^L P(h_j^{(1)} | V) \right) \right] \quad (12)$$

在给定训练集 $V = \{v^{(1)}, \dots, v^{(m)}\}$ 之后,对于 RBM 的训练,就是处理式(13)的优化问题:

$$\begin{aligned} \text{minimize}_{\{w_{ij}, c_i, b_j\}} = & - \sum_{l=1}^m \log \sum_h P(v^{(l)}, h^{(1)}) + \\ & \lambda \sum_{j=1}^M \left[p \log \left(\frac{1}{L} \sum_{l=1}^L P(h_j^{(1)} | V) \right) + \right. \\ & \left. (1-p) \log \left(1 - \frac{1}{L} \sum_{l=1}^L P(h_j^{(1)} | V) \right) \right] \end{aligned} \quad (13)$$

式中 λ 为稀疏正则化常数, p 用于控制隐单元的稀疏程度,即通过稀疏惩罚因子鼓励隐单元在学习过程中的平均激活概率与 p 之间的 Kullback-Leiber 距离达到最小,使隐单元具备稀疏性.

3.3 学习算法

作为包含多层隐单元层的深度结构,对网络参数进行全局优化是难以处理的,因此 Hinton 提出了贪婪逐层训练,并提供了深度学习模型的训练方法.由于 DBM 的训练是基于 RBM 训练进行的,因此,需要首先设计在基于交叉熵稀疏惩罚因子下的 RBM 训练,其次介绍 DBM 的训练方法.

RBM 的训练是依据极大似然法则最大化训练数据出现概率进行的.假设训练样本个数为 K ,则训练 RBM 即为最大化以下目标函数,如式(14)所示.

$$L(W) = \sum_{k=1}^K \log \sum_h P(v^{(k)}, h; W) \quad (14)$$

利用随机梯度下降法,目标函数(14)对于各个

参数的偏导如式(15)所示(以连接权重 W 为例).

$$\frac{\partial L(W)}{\partial W_{ij}} = -\frac{1}{d} \sum_{k=1}^d v_i^{(k)} P(h_j | \mathbf{v}^{(k)}) + \langle v_i h_j \rangle_{P(\mathbf{v}, \mathbf{h}; W)} \quad (15)$$

对于式(15)等号右侧多项式中的第一个项(positive phase),可以直接计算出来;但是对于第二个项(negative phase),由于 $P(\mathbf{v}, \mathbf{h})$ 无法直接通过数学推导出来的,故难以计算. Hinton 于 2002 年提出了对比散度(Contrastive Divergence, CD)算法^[16],通过执行 block Gibbs 采样—分别以各个训练数据作为初始状态,进行几次状态转移,然后以转移后的状态作为样本对 negative phase 估算均值. Hinton 通过实验证明,在实际应用中,甚至只需要一次状态转移就能保证良好的学习效果. 由于新引入的交叉熵稀疏惩罚因子,因此需要对 CD 算法进行改进,以保证惩罚因子对隐单元的稀疏化.

参照文献[15]中的训练,利用随机梯度下降法,得到交叉熵稀疏惩罚因子对 RBM 参数的影响,如式(16)、(17)所示.

$$\Delta_1 W_{.k} = \frac{\partial P_{\text{cross-entropy}}}{\partial W} = \frac{p-q}{q(1-q)} \cdot \frac{\partial q}{\partial W} = \frac{p-q}{q(1-q)} \cdot q(1-q) \mathbf{V}^T = (p-q) \cdot \mathbf{V}^T \quad (16)$$

$$\Delta_1 b_k = \frac{\partial P_{\text{cross-entropy}}}{\partial b} = \frac{p-q}{q(1-q)} \times \frac{\partial q}{\partial b} = p-q \quad (17)$$

式中, $q = \frac{1}{m} \sum_{l=1}^m P(h_k^{(l)} | \mathbf{V})$ 为隐单元 k 在训练样本集 V 中的平均激活概率;式(16)和(17)作为 D 算法更新参数的补充项,用于 RBM 的训练中.

在介绍完基于交叉熵稀疏惩罚因子的 RBM 训练以后,下面对深度玻尔兹曼机的训练进行介绍;该部分的训练分为两部分:

(1)通过贪婪算法(Greedy Layerwise Pretraining)逐层训练深度网络中的 RBM 模型;计算时,每一层各自根据输入数据,通过 RBM 的学习方法学习到此层的 RBM 参数,包括连接权值以及隐藏层节点值;在进行上层 RBM 训练,将底层 RBM 的输出层作为第二个 RBM 的输入,并继续单独调整当前 RBM 参数;需要注意的是,参照式(10)得出中间层单元的激活概率均会受到上下两层的影响,因此在进行 RBM 训练时,对应于深度网络中间层的隐单元激活概率在计算时应当将底层可见单元的激活

概率 $\times 2$,以补偿实际模型中其余层的缺失;

(2)采用 back propagation 的方法,运用梯度下降法对整个 DBM 进行精调,通过微调参数和权重偏置来增强 DBM 的抽取性能.

4 20-newgroups 测试

实验采用 20-newgroups 文档集作为训练集. 20-newgroups 文档集包含 18 845 篇文章,整个文档集被分为 20 个不同主题的新闻组. 为了对模型的文本表示进行性能,随机挑选 11 314 个样本进行训练,剩余的 7 531 个样本以供测试.

4.1 学习过程

实验准备步骤为:首先去除文本中的停用词和无用词;然后提取信息增益最大的前 5 000 个词汇并将其整合为词典库;最后根据词典库中的词汇,将每个文本转变为一维向量的形式.

在实验中,DBM 由两级 RBM 组成,分别为:提取中间隐单元的 RSM 和提取更抽象概念的 RBM. 根据实验准备步骤,设定字典词汇量 $K=5\ 000$,所有 RBM 的学习速率 $\eta=0.01$,循环次数不超过 2 000,设置稀疏惩罚因子中的稀疏度 $p=0.05$;在完成对文本的特征进行提取后,采取常用的文本检索指标—查全—查准曲线(RPC)作为对文档特征有效性的考察度量.

4.2 实验结果分析

实验平台采用安装 Matlab(2013a)的主频为 2.4 GHz 的台式机. 为有效测试本文所设计的基于深度玻尔兹曼机的文本特征提取机制优势,进行以下两种测试.

(1)稀疏惩罚因子实验对比

该部分实验从两方面进行对比,一是对比稀疏惩罚因子是否能够有效地解决 RBM 在训练过程中出现的特征同质化问题;二是对比交叉熵稀疏惩罚因子相比于以往稀疏惩罚因子,对隐单元的稀疏程度是否增强,该部分实验进行的步骤如下:

①训练无稀疏惩罚因子的 RSM,结构为 5 000—200;

②训练基于交叉熵稀疏惩罚因子的 RSM,结构为 5 000—200;

③训练基于误差平方和稀疏惩罚因子的 RSM,结构为 5 000—200.

从图 3 中可以看出,采用交叉熵稀疏惩罚因子产生的 RSM 特征能够更好地表征文本,其 RPC 曲线较好.




图3 单层 RSM 的 RPC

为了量化在不同稀疏惩罚因子下的隐单元稀疏程度,采用 Hoyer 提出的稀疏度量^[17]. 对于 D 维向量 v , 其 Hoyer 稀疏度如式(18)所示.

$$Sparseness(v) = \frac{\sqrt{D} - \frac{\sum_{i=1}^D |v_i|}{\sqrt{\sum_{i=1}^D v_i^2}}}{\sqrt{D} - 1} \quad (18)$$

该稀疏度量区间范围为 $[0, 1]$, 其值越接近 1 代表向量 v 越稀疏. 分别计算基于选取 3 种不同的稀疏惩罚因子的条件下, RSM 在 20-newgroups 测试集提取出的特征向量稀疏度, 结果如表 1 所示.

表1 Hoyer 稀疏度值

稀疏惩罚因子	稀疏度区间	稀疏度均值
误差平方和	[0.57, 0.79]	0.65
交叉熵	[0.64, 0.82]	0.71
无	[0.40, 0.62]	0.44

从表 1 中的数据可以得出, 采用交叉熵稀疏惩罚因子的 RSM 特征向量激活概率低, 整体稀疏性要优于采用误差平方和稀疏惩罚因子的模型.

(2) 深度结构与浅层结构实验对比

该部分实验对比 DBM 与 RSM 进行文本特征提取的有效性, 进行的步骤如下:

- ①训练在交叉熵稀疏惩罚因子影响下的 DBM, 其结构为 5 000-200-100, 特征维数为 300;
- ②训练在无交叉熵稀疏惩罚因子影响下的 DBM, 其结构为 5 000-200-100, 特征维数为 300;
- ③训练在交叉熵稀疏惩罚因子影响下的 RSM, 其结构为 5 000-300, 特征维数为 300;
- ④训练在无交叉熵稀疏惩罚因子影响下的 RSM, 其结构为 5 000-300, 特征维数为 300.

从图 4 中可以得出, 通过 DBM 提取出的文本特征, 对于文本的描述较为准确, 反映在 RCP 曲线上要好于浅层模型 RSM; 而采用交叉熵稀疏惩罚因子均能够提高模型特征表达能力, 无论是在深度模型还是浅层模型; 同时, 可以从与图 4 进行对比发




图4 多种模型 RPC 曲线对比

现: 隐单元个数越大, 对于文本特征提取更准确, 表现在 RSM 中隐单元个数为 300 时, RCP 曲线要优于隐单元个数为 200 的情况.

5 结束语

本文提出了一种基于交叉熵稀疏惩罚因子的深度玻尔兹曼机文本特征提取方式, 并对其效果进行了文本分类实验. 通过与浅层模型—RSM 在 20-newgroups 文档集上的测试证明, 新的惩罚因子更为有效, 而基于交叉熵惩罚因子构成的深度玻尔兹曼机不仅能够提高特征表示的准确度, 而且更加抽象, 可以适合于大规模文本分析、分类研究. 今后的工作继续研究如何提高深度学习模型的训练效率, 并尝试将深度学习模型应用到更多的方面.

参考文献:

- [1] Andriy Mnih, Hinton G E. A scalable hierarchical distributed language model, vancouver[C]// Advances in Neural Information Processing System, Vancouver: IEEE, 2008: 1081-1088.
- [2] Sungjin Ahn, Anoop Korattikara, Max Welling. Bayesian posterior sampling via stochastic gradient fisher scoring[C]// Proceedings of the 29th International Conference on Machine Learning, Toronto: IEEE, 2012: 1552-1560.
- [3] R Salakhutdinov, G E Hinton. Semantic hashing[J]. International Journal of Approximate Reasoning, 2009, 50(7): 969-978.
- [4] G E Hinton, R Salakhutdinov. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-508.
- [5] 陈宇, 郑德权, 赵铁军. 基于 Deep Belief Nets 的中文名实体关系抽取[J]. 软件学报, 2012, 23(10): 2572-2585.
- [6] Mohamed G E Dahl, G E Hinton. Acoustic modeling

- using deep belief networks[J]. IEEE Transactions on Audio, Speech and Language Processing, 2012, 20(1): 14-22.
- [7] 周长建, 司震宇, 邢金阁. 基于 Deep Learning 网络态势感知建模方法研究[J]. 东北农业大学学报, 2013, 44(5): 144-149.
- [8] 杨奎元. 基于深层结构的图像内容分析及其应用[D]. 合肥: 中国科技大学计算机学院, 2012.
- [9] Taylor G W, Sigal L, Fleet D J, et al.. Dynamical binary latent variable models for 3D human pose tracking [C]// IEEE Conference on Computer Vision and Pattern Recognition. San Francisco: IEEE, 2010: 631-638.
- [10] 刘建伟, 刘媛, 罗雄麟. 玻尔兹曼机研究进展[J]. 计算机研究与发展, 2014, 51(1): 1-16.
- [11] 林妙真. 基于深度学习的人脸识别研究[D]. 大连: 大连理工大学计算机学院, 2013.
- [12] G E Hinton. A practical guide to training restricted boltzmann machines[R]. Toronto: Machine Learning Group University of Toronto, 2010, 129-136.
- [13] Ruslan Salakhutdinov, G E Hinton. Replicated Softmax: an undirected topic model[C]// Advances in neural information processing systems. Vancouver: IEEE, 2009: 1607-1614.
- [14] R Salakhutdinov, G E Hinton. Deep boltzmann machines[C]// Proceeding of the International Conference on Artificial Intelligence and Statistics. Vancouver: IEEE, 2009: 448-455.
- [15] Lee H, Ekanadham C, Ng A. Sparse deep belief net model for visual area V2[C]// Advances in neural information processing systems. Vancouver: IEEE, 2007: 873-880.
- [16] G. E. Hinton. Training products of experts by minimizing contrastive divergence[J]. Neural Computation, 2002, 14(8): 1711-1800.
- [17] Hoyer P. Non-negative matrix factorization with sparseness constraints[J]. Journal of Machine Learning Research, 2004, 5(12): 1457-1469.

作者简介:

张立民 男,(1966-),博士,教授.研究方向为盲信号处理、军用仿真技术.

刘凯 男,(1986-),博士研究生.研究方向为智能信息处理、军用仿真技术. E-mail:848297582@qq.com

(上接第 141 页)

- [6] Aminian M, Aminian F. A modular fault-diagnostic system for analog electronic circuits using neural networks with wavelet transform as a preprocessor[J]. IEEE Transactions on Instrumentation and Measurement, 2007, 56(5): 1546-1554.
- [7] Wang A, Liu J. A novel fault diagnosis of analog circuit algorithm based on incomplete wavelet packet transform and improved balanced binary-tree SVM [J]. Bio-Inspired Computational Intelligence and Applications, 2007(1):482-493.
- [8] 马超, 陈西宏, 邓均明,等. 模拟电路故障诊断的信息融合新方法[J]. 微电子学与计算机, 2011, 28(4): 9-17.
- [9] 连可, 王厚军, 龙兵. 基于 SVM 的模拟电子系统多故障诊断研究 [J]. 仪器仪表学报, 2007, 28(6): 1029-1034.
- [10] 李云红, 谭阳红. 基于小波包与量子神经网络的容差模拟电路的软故障诊断 [J]. 微电子学与计算机, 2009, 26(5): 187-192.

作者简介:

许军 女,(1961-),博士,教授.研究方向为模拟电路故障诊断、信号检测与估计等. E-mail:xj719222@sohu.com