

文章编号: 1001-0920(2011)11-1659-06

一种功能分区的BP神经网络结构设计方法

张昭昭^{1,2}, 乔俊飞¹, 杨刚¹

(1. 北京工业大学 电子信息与控制工程学院, 北京 100124;

2. 辽宁工程技术大学 电子与信息工程学院, 辽宁 葫芦岛 125105)

摘要: 针对全连接BP网络在解决大规模复杂问题时存在的收敛速度缓慢等问题, 提出一种功能分区的BP网络结构模式. 利用RBF神经元的物理特性对输入样本空间进行分解, 并将分解后的样本送给不同的子BP网络学习. 与全连接BP网络相比, 降低了网络在学习过程中的权值搜索空间, 提高了学习速度, 改善了网络泛化性能, 体现了人脑在学习过程中的知识积累特征. 对三维墨西哥草帽函数逼近和双螺旋分类的实验结果表明, 该网络能够解决全连接BP网络不能有效解决的问题.

关键词: BP神经网络; 功能分区; 权值搜索空间; 知识积累

中图分类号: TP273

文献标识码: A

Structure model of function-dividing design for BP neural network

ZHANG Zhao-zhao^{1,2}, QIAO Jun-fei¹, YANG Gang¹

(1. College of Electronic Information and Control Engineering, Beijing University of Technology, Beijing 100124, China; 2. Institute of Electronic and Information Engineering, Liaoning Technical University, Huludao 125105, China.

Correspondent: ZHANG Zhao-zhao, E-mail: zzzhao123@126.com)

Abstract: For the problem that the fully coupled BP neural network suffers the slow convergence rate to solve the large scale complex problems, a structure model of function-dividing BP neural network architecture is presented. By using the physical characteristics of the RBF neurons, the input sample space is decomposed, and different sub-samples space is sent to different sub-module of BP neural network to learn automatically. Compared with the fully coupled BP neural network, the searching space of weight in the learning process of neural network is reduced, the learning speed and network's generalization performance are improved, and the characteristics of the human brain in the learning process of knowledge accumulation are reflected. Experiments of 3D Mexican hat function approximation and two-spiral classification show that the neural network of function-dividing BP neural network can solve the problem that the fully coupled BP neural network can not solve perfectly.

Key words: BP neural network; function-dividing; weight search space; knowledge accumulation

1 引言

BP神经网络是前馈神经网络中应用最广泛的网络之一. 理论上, 当BP神经网络隐层节点足够多时, 可以逼近任意复杂系统的动力学行为. 然而, 由于神经网络规模巨大以及数据饱和等原因, 使网络难以收敛到全局最小点, 或收敛速度异常缓慢, 为实际应用带来许多具体的难以克服的困难^[1]. 人们提出了很多改进的学习算法, 并极大地改善了收敛速度^[2-6]. 但是, 对于复杂的问题, BP神经网络规模巨大以及收敛

速度缓慢的问题到目前为止依然没有得到有效解决. 实质上, 导致BP神经网络收敛缓慢的原因不仅仅是由于BP神经网络所采用的梯度学习算法, 而且也与BP神经网络全连接对称的网络结构有关. 全连接对称结构的BP神经网络应用梯度下降法进行权值修正时, 网络中的每个隐节点都各自为政, 并力图使自己在总体计算中发挥主要作用. 每个隐节点都只看到其输入信号和输出端反传给它的误差信号, 误差信号给出了每个隐节点需要完成的任务, 但输入信号和输出信号一直在变化, 因此隐节点要完成的任务也一

收稿日期: 2010-06-05; 修回日期: 2010-09-06.

基金项目: 国家自然科学基金项目(60873043); 国家“863”计划项目(2009AA04Z155); 北京市自然科学基金项目(4092010); 教育部博士点基金项目(200800050004); 北京市高等学校人才强教计划项目(PHR201006103).

作者简介: 张昭昭(1973-), 男, 博士生, 从事智能信息处理、神经网络结构与优化的研究; 乔俊飞(1968-), 男, 教授, 博士生导师, 从事智能控制与智能信息处理等研究.

直在变动,于是各隐节点在很长一段时间内处于混沌状态,需要很长时间才能够稳定下来^[7].因此,要改善BP神经网络的性能,需在网络结构上改变其全连接的形式,降低网络参数搜索空间.人工神经网络建立在大脑生理研究的基础上,是对生物神经网络若干基本特性的抽象和模拟.人脑在处理复杂事件时,会将事件分解成若干子事件,然后分配给大脑的相应处理机构,协调完成事件的处理工作,同时人脑对知识具有积累特性,在获得新知识的同时不会破坏原来已学好的知识.而全连接神经网络却不具备这些特性,它在学习新样本时,会破坏全部原来已经学好的旧样本.因此,近年来许多学者试图从仿生学和拟人脑的角度研究神经网络结构设计理论及应用^[8-9].

本文针对BP神经网络在应用中存在的问题,依照脑系统在宏观和微观角度上的结构和功能模块化的特点,提出一种功能分区的BP神经网络结构连接模式以及相应的结构设计算法.该神经网络的连接模式,能用RBF神经元感受野的物理特性对学习样本空间进行划分,并将相应子样本空间的数据自动分配给不同的子BP神经网络学习,实现复杂任务的分解.结构设计算法能够根据任务自适应调整对应于神经网络的网络结构,以保证各子神经网络对各自任务的逼近性能和泛化性能.采用该方法设计出的神经网络不仅训练时间短、收敛速度快,而且能体现出人脑在学习过程中的知识累积特性.本文最后通过仿真实验验证了所提出神经网络的性能.

2 功能分区的BP神经网络

2.1 功能分区的BP神经网络连接机制和工作机制

图1为功能分区的BP神经网络结构框图.图中第1层为RBF神经元,其激活函数为高斯径向基函数,即

$$\Phi_i(x) = e^{-\frac{\|x - c_i\|^2}{\delta_i^2}}. \quad (1)$$

其中: c_i 为第 i 个RBF神经元的数据中心, δ_i 为核函数的扩展宽度.




图1 功能分区的BP神经网络结构

在功能分区的BP神经网络结构中, $\Phi_i(x)$ 被定义为硬限幅函数,即

$$\Phi_i(x) = \begin{cases} 1, & \|x - c_i\| \leq \delta; \\ 0, & \|x - c_i\| > \delta. \end{cases} \quad (2)$$

RBF神经元是在输入样本空间中以核心 c_i 为球心,以 δ_i 为半径作一个超球面.当输入点在此超球面内时输出为1,在超球面以外时输出为0.该神经元的作用如下:1)对输入样本空间进行划分,实现对复杂任务的分解;2)起开关函数的作用,自动分配相应的学习样本到与其对应的子BP神经网络模块进行学习.在神经网络的学习过程中,输入样本 X 同时送给前层的RBF神经元和后层的各BP神经网络子模块,而每个子BP神经网络是否学习该输入样本则由前面的RBF神经元的输出决定.

2.2 功能分区的BP神经网络任意逼近性能

以单输出神经网络为例,由图1知功能分区的BP神经网络的输出为

$$y(x) = \sum_{i \in S} (w_i^2 f(w_i^1 x + b_i^1) + b^2) \cdot \Phi_i(x) = \sum_{i \in \rho} (w_i^2 f(w_i^1 x + b_i^1) + b^2). \quad (3)$$

其中: S 为BP网络中所有子模块的隐节点集合, w_i^1 为第 i 个隐节点与输入节点的连接权, w_i^2 为第 i 个隐节点与输出节点的连接权, b_i^1 为第 i 个隐节点的偏置, b^2 为输出节点偏置, ρ 为神经网络被学习样本 x 激活的隐节点集合.由于 $\Phi_i(x)$ 为硬限幅函数,此时 $\Phi_i(x) = 1$.因此,在学习任务的过程中,对于该神经网络,其实质上是BP网络,而三层BP网络已被证明具有任意逼近能力,所以功能分区的BP神经网络也具有任意逼近能力.

2.3 功能分区的BP神经网络参数搜索空间

神经网络对任务的学习,实质上是在神经网络权值空间的一个寻优过程^[7].因此,对于全连接BP神经网络,其输出为

$$y(x) = \sum_{i \in \rho} (w_i^2 f(w_i^1 x + b_i^1) + b^2) = \sum_{i \in \rho} f(w_i, x). \quad (4)$$

其中: ρ 为神经网络中所有隐节点集合, w_i 为第 i 个隐节点的连接权参数, $f(w_i, x)$ 为第 i 个隐节点的输出.设学习任务有 p 个学习样本,为 (x_i, y_i) , $i = 1, 2, \dots, p$.则神经网络对任务的学习可表示为

$$\begin{cases} y_1 = f(w_1, x_1) + f(w_2, x_1) + \dots + f(w_n, x_1), \\ y_2 = f(w_1, x_2) + f(w_2, x_2) + \dots + f(w_n, x_2), \\ \vdots \\ y_p = f(w_1, x_p) + f(w_2, x_p) + \dots + f(w_n, x_p). \end{cases} \quad (5)$$

其中: n 为完成学习任务时(达到要求的精度)神经网络中的最少隐节点数, $f(w_i, x_j)$ 为第 i 个隐节点对第 j 个学习样本的输出.设 w_i 为 k (表示第 i 个隐节点共有 k 个连接权),则 n 个隐节点的全连接BP神经网络的权值寻优空间维数不小于 $(n-1)k$.

对于功能分区的BP神经网络,由式(3)和神经网络的连接特性可知,任意一个学习样本 x_i 只能激活一个或几个子BP神经网络模块中的隐节点(当前层RBF神经元的核函数有重叠显现,且该学习样本正好落在多个核函数的重叠区域时,该学习样本便会激活多个子BP神经网络模块),而并不是激活BP神经网络中的全部隐节点.如前所述,因为功能分区的BP神经网络具有任意逼近性能,所以对于任意给定的学习样本序列 $(x_i, y_i), i=1, 2, \dots, p$,存在一个最小神经网络结构(达到要求的精度),且神经网络对任务的学习可表示为

$$\begin{cases} y_1 = f_1(W_{11}, x_1), \\ y_2 = f_{21}(W_{2o}, x_2) + f_{22}(W_{2n}, x_2), \\ y_3 = f_{31}(W_{3o}, x_3) + f_{32}(W_{3n}, x_3), \\ \vdots \\ y_p = f_{p1}(W_{po}, x_p) + f_{p2}(W_{pn}, x_p). \end{cases} \quad (6)$$

其中: W_i 表示BP网络中被学习样本 x_i 所激活的隐节点集合, $W_{io} = (W_1 \cup W_2 \cup \dots \cup W_{i-1}) \cap W_i$, $W_{in} = W_i - W_{io}$, $f_1(W_1, x_1)$ 为隐节点集合 W_1 中所有隐节点对学习样本 x_1 的输出和, $f_{i1}(W_{io}, x_i)$ 为隐节点集合 W_{io} 中所有隐节点对学习样本 x_i 的输出和, $f_{i2}(W_{in}, x_i)$ 为隐节点集合 W_{in} 中所有隐节点对学习样本 x_i 的输出和.则功能分区的BP神经网络学习任务时的神经网络权值寻优空间 Ω 可表示为

$$\Omega \subseteq \Omega_1 + \sum_{i=2}^p \Psi_{i-1} \times \Omega_i. \quad (7)$$

其中: Ω_1 表示 $f_1(W_1, x_1)$ 中隐节点集合 W_1 中所有隐节点的权值空间, Ψ_{i-1} 表示 $f_{i1}(W_{io}, x_i)$ 中隐节点集合 W_{io} 中所有隐节点的权值空间, Ω_i 表示 $f_{i2}(W_{in}, x_i)$ 中隐节点集合 W_{in} 中所有隐节点的权值空间.

因为功能分区的BP神经网络具有局部激活特性,所以设 q 为所有学习样本中一个样本所能激活的整个BP神经网络的最大隐节点数,且每个隐节点有 k 个连接权,则 $\Omega_1 \leq qk$, $\Psi_{i-1} \times \Omega_i \leq qk$.显然,功能分区的BP神经网络在学习任务的过程中,神经网络权值寻优空间不大于 qk .在功能分区的BP神经网络中, q 远小于BP神经网络中总的隐节点数 n ,所以功能分区的BP神经网络在学习一个样本时的权值搜索空间远小于全连接BP神经网络.因此,功能分区的BP神经网络相对于全连接BP神经网络,不仅学习速度快,而且能体现出人脑在学习过程中所表现出的知识积累特性.

3 功能分区的BP神经网络学习及结构设计

3.1 前层RBF神经网络结构设计

对于前层RBF神经元,用经典K-means聚类算法实现对输入样本空间的分类,并确定各个RBF神经

元的数据中心 c_i 和扩展宽度 δ_i .具体算法描述如下:

Step 1: 初始化.从输入样本中随机选择 h 个不同的初始聚类中心,并令 $k=1$.

Step 2: 计算所有输入样本与聚类中心的距离 $\|x_j - c_i(k)\|, i=1, 2, \dots, h, j=1, 2, \dots, p$.

Step 3: 对于输入样本 x_j ,按最小距离原则对其进行分类,即当 $i(x_j) = \min_i \|x_j - c_i(k)\|$ 时, x_j 被归为第 i 类,即 $x_j \in s_i(k)$.

Step 4: 重新计算各类新的聚类中心

$$c_i(k+1) = \frac{1}{N_i} \sum_{x \in s_i(k)} x, i=1, 2, \dots, h,$$

其中 N_i 为第 i 个聚类域 $s_i(k)$ 中包含的样本数.

Step 5: 如果 $c_i(k+1) \neq c_i(k)$,则转到Step 2;否则,聚类结束,转到Step 6.

Step 6: 根据聚类中心间的距离确定各RBF神经元的扩展常数.扩展常数取 $\delta_i = \kappa d_i$, d_i 为第 i 个数据中心与其他最近的数据中心之间距离,即 $d_i = \min_j \|c_j - c_i(k)\|$, κ 为重叠系数.

3.2 功能分区的BP神经网络学习和子BP网络结构

训练开始前,先由前层RBF神经元的个数决定子BP神经网络模块的个数;训练开始时,每个子BP神经网络中的隐层神经元个数为1.神经网络的学习采用增量学习方法,则功能分区的BP神经网络学习过程和子BP网络结构设计方法如下:

Step 1: 对所有输入样本采用K-means聚类算法,产生前层RBF神经网络的数据中心和扩展宽度;采用批学习方式,产生前层RBF神经网络输出矩阵 O .RBF(O -RBF $\in R^{M \times N}$, M 为RBF神经元个数, N 为总的学习样本数).令矩阵 O -RBF中不等于0的项为1,则 O -RBF列中为1的项即为每个学习样本所激活的子BP神经网络模块.

Step 2: 对学习样本 (x_i, y_i) 检索矩阵 O -RBF第 i 列中为1的项,从BP网络全连接矩阵中提取出对应的子BP网络的权值连接矩阵,采用梯度下降法对该样本进行学习.学习完成后,将修改后的权值连接矩阵重新放回BP神经网络全连接矩阵中.每训练20步进行一次检查,若输出误差已达到要求,则算法停止;否则,若训练步数大于100,则转Step 4;若训练步数 ≤ 100 ,则转Step 3.

Step 3: 设误差下降趋势

$$PE(k) = (E(k) - E(k-1))/E(k) \times 100\%,$$

其中 $E(K)$ 为第 k 步期望输出与实际输出的均方差.若输出误差未达到要求,但 $PE(k) > 0.2$,则继续训练,转Step 2;若 $PE(k) < 0.2$ (即误差下降趋于平坦),表示

训练可能陷入局部极小点, 此时应跳出极小点, 设已训练了 k 步, 则第 $k+1$ 步的权向量为

$$W_i(k+1) = -W_i(k),$$

其中 $i = 1, 2, \dots, m$ 为此时参与训练的子 BP 网络的隐节点数, 转 Step 2.

Step 4: 在隐层增加一个隐节点, 因为一个样本有可能激活多个子 BP 神经网络模块, 所以采用分裂隐节点的方法增加隐节点, 调整网络结构. 即从当前参与学习的隐节点中选择输出贡献最大的隐节点 h_a , 将其分裂为 2 个隐节点 h_b 和 h_c , 新隐节点 h_b 和 h_c 的连接权为

$$w_b = (1 + \alpha)w_a, w_c = -\alpha w_a,$$

其中 α 为变异系数, 是一个很小的随机数.

Step 5: 重新开始训练, 转 Step 2.

由算法可见: 每个学习样本只激活一个或几个子 BP 神经网络模块, 降低了神经网络在学习过程中的权值搜索空间, 同时每个子 BP 神经网络模块所学习的样本空间远远小于原学习样本空间, 因此在学习过程中可大大提高整个网络系统的学习速度; 各子 BP 神经网络模块的结构在学习过程中可根据学习状况灵活改变; 另外, 聚类时设置合适的重叠系数 κ 可以控制各子样本空间之间有平滑过渡, 减小各子样本空间边界的误差.

4 仿真实验

为检验功能分区的 BP 网络的性能, 下面用 2 个仿真实验与全连接 BP 神经网络的实验结果进行比较. BP 网络训练均采用 Levenberg-Marquardt 算法, 该算法是一种改进的 BP 算法(具有训练速度快的特点). 函数逼近时, 隐层和输出层的传递函数分别为 sigmoid 函数和线性函数; 分类时, 隐层和输出层的传递函数均为 sigmoid 函数. 因为功能分区的 BP 神经网络结构采用空间超球面实现对已有训练样本空间的划分, 所以可能会有极个别测试样本不能激活任何子 BP 神经网络模块. 仿真时, 对于这些样本点, 可分配一个欧氏距离距该样本点最近的子 BP 神经网络模块学习该样本.

4.1 三维墨西哥草帽函数逼近

三维墨西哥草帽函数问题是难度非常大的回归估计问题. 文献[10]提出的 FART 3 算法应用于此问题的近似效果很不理想, 为此有些学者利用支持向量机才获得了较好的解.

本文用功能分区的 BP 神经网络对形如

$$F(x_1, x_2) = \sin(\sqrt{x_1^2 + x_2^2}) / \sqrt{x_1^2 + x_2^2} \quad (8)$$

的三维墨西哥草帽函数在 $x_1, x_2 \in [-2\pi, 2\pi]$ 区间上的

取值进行逼近.

仿真时, 在 $[-2\pi, 2\pi]$ 区间随机产生均匀分布的学习样本 600 个, 设前层 RBF 神经元个数为 10 (即设定子 BP 神经网络模块数), 重叠系数 κ 为 0.15, 用 K-means 聚类法确定各 RBF 神经元的数据中心和扩展宽度, 并生成 600 个学习样本的子 BP 网络模块索引矩阵. 测试样本为 $-2\pi : 0.6 : 2\pi$, 共 441 个. 学习率为 0.03.

图 2 所示为采用全连接 BP 神经网络逼近墨西哥草帽函数时的输出. 从图 2 可以看出, 全连接 BP 神经网络对墨西哥草帽函数的拟合效果很不理想. 图 3 所示为用功能分区的 BP 神经网络将墨西哥草帽函数的输入样本空间划分为 10 个子样本空间时神经网络的输出. 从图 3 可以看出, 虽然有个别子空间之间的过渡不够平滑, 但拟合曲面相对于全连接 BP 神经网络还是能够更好地逼近期望输出, 且逼近效果比较理想.




图 2 全连接 BP 神经网络输出




图 3 功能分区的 BP 神经网络输出

表 1 给出了分别采用 5 个、10 个和 15 个子 BP 神经网络模块的实验结果与全连接 BP 神经网络的实验结果的对比.

表 1 三维墨西哥草帽函数实验结果

网络类型	样本空间	网络结构	目标误差	训练时间/s	检测误差
功能分区的 BP	15	2-51-1	0.05	75.287	0.1107
	10	2-49-1	0.05	73.853	0.0991
	5	2-46-1	0.05	80.952	0.1012
全连接 BP	1	2-60-1	0.1	387.882	0.1309

从表 1 可以看出, 对于同样的任务采用同样的算法, 功能分区的 BP 神经网络的结构相对于全连接 BP

神经网络隐节点数少,其训练时间远小于全连接BP神经网络;功能分区的BP神经网络的检测误差相对于训练误差要大很多,这是由于测试样本中有极个别输入样本点不能激活任何子BP神经网络模块,但相对于全连接BP网络,功能分区的BP神经网络的泛化性能较优.为保证功能分区的BP神经网络的泛化性能,要求训练样本足够多且在样本输入空间均匀分布.

4.2 双螺旋模式分类问题

双螺旋分类问题是评估神经网络分类复杂边界样本能力的基准问题^[11],也是最困难的模式分类问题之一.如图4所示,双螺旋线由2条相互缠绕的螺旋线构成,每条螺旋线上的点对应于一类,双螺旋线问题的任务是判断输入样本属于相互缠绕的2条螺旋线中的哪一条.由于2条螺旋线之间相互缠绕,即它们所对应的类之间是重叠的,这样便加大了模式分类的难度.有些学者试图利用BP网络求解双螺旋分类问题,但没有成功;文献[12]提出“生成-收缩”法来求解双螺旋问题,但正确率只有89.6%.




图4 双螺旋分类图

双螺旋分类问题训练样本产生方式如下:

$$\begin{cases} \theta = i \times \pi/16, \\ r = 6.5 \times (104 - i)/104, \\ x = r \times \sin \theta, \\ y = r \times \cos \theta, \end{cases} \quad (9)$$

其中 $i=0, 1, \dots, 96$. 则 (x, y) 和 $(-x, -y)$ 便可以构成2类样本,共194个样本点,分别属于2个点集.测试样本为 $x=-7:0.1:7$ 和 $y=-7:0.1:7$, 即 x 和 y 各141个,测试样本对为19881个.

图5为采用全连接BP神经网络,网络结构为2-90-1时对双螺旋问题的分类效果,网络学习结束后对19881个测试样本分类正确率为76.908%.图6为采用功能分区的BP神经网络(共有30个子BP神经网络模块)对双螺旋问题的分类效果,网络学习结束后对19881个测试样本的分类正确率为95.183%.

采用功能分区的BP神经网络对于双螺旋的分类结果,没有100%识别测试样本中的所有样本,这是由于学习样本相对于测试样本太少,导致前层RBF神经




图5 全连接BP神经网络对双螺旋分类效果




图6 功能分区的BP神经网络对双螺旋分类效果

元未能有效覆盖整个样本空间.因此,测试样本中有较多的测试样本未能激活任何子BP网络模块,导致识别率下降.但是,与全连接BP神经网络相比,还是大大提高了识别的正确率,表明采用功能分区的BP神经网络可以有效解决该问题.

5 结 论

本文依据脑系统在宏观和微观角度上的结构和功能模块化的特点以及人脑在学习过程中所表现出的知识积累特性的事实,利用RBF神经元的几何意义提出了一种功能分区的BP神经网络连接模式.该神经网络使用了2种不同结构的神经元来构造网络,突破了使用单一结构神经元构造神经网络的局限,有效地克服了传统BP神经网络在处理复杂任务时训练时间长、收敛速度慢的问题,同时考虑了神经网络规模的优化问题,给出了子BP神经网络自适应结构调整算法.分别对墨西哥草帽函数逼近和双螺旋分类进行实验,均取得了令人满意的结果.这与传统的全连接BP神经网络相比具有明显的优势.

本文提出的功能分区的BP神经网络结构只是一种尝试性研究,虽然在BP神经网络前面引入RBF神经元,能够实现输入样本划分和对每个学习样本自动分配子网络的功能,但仍需从以下2个方面进行进一步的研究和探讨:1)需要寻找一种能自动确定RBF神经元个数的自适应聚类算法;2)寻找一种对样本空间划分边界进行处理的方法,如模糊化处理,使得各子空间之间能平滑过渡.

参考文献(References)

- [1] 张昭昭, 乔俊飞, 韩红桂. 一种基于神经网络复杂度的修剪算法[J]. 控制与决策, 2010, 25(6): 821-824.
(Zhang Z Z, Qiao J F, Han H G. A pruning algorithm based on neural complexity[J]. Control and Decision, 2010, 25(6): 821-824.)
- [2] Liu J, Feng D, Zhang W. Adaptive improved natural gradient algorithm for blind source separation[J]. Neural Computation, 2009, 21(3): 872-889.
- [3] Man Z, Wu H, Liu X. A new adaptive backpropagation algorithm based on Lyapunov stability theory for neural networks[J]. IEEE Trans on Neural Networks, 2006, 17(6): 1580-1591.
- [4] 乔俊飞, 张颖. 一种多层前馈神经网络的快速修剪算法[J]. 智能系统学报, 2008, 3(2): 173-176.
(Qiao J F, Zhang Y. Fast unit pruning algorithm for multilayer[J]. CAAI Trans on Intelligent Systems, 2008, 3(2): 173-176.)
- [5] Siu S, Yang S, Lee C, et al. Improving the back-propagation algorithm using evolutionary strategy[J]. IEEE Trans on Circuits and Systems-II: Express Briefs, 2007, 54(2): 171-175.
- [6] Zweiri Y H. Optimization of a three-term backpropagation algorithm used for neural network learning[J]. Int J of Computational Intelligence, 2007, 3(4): 322-327.
- [7] Jianye Sun. Local coupled feedforward neural network[J]. Neural Networks, 2010, 23(1): 108-113.
- [8] Seiichi Ozawa, Asim Roy, Dmitri Roussinov. A multitask learning model for online pattern recognition[J]. IEEE Trans on Neural Networks, 2009, 20(3): 430-445.
- [9] 王宪保, 周德龙, 王守觉. 基于仿生模式识别的构造型神经网络分类方法[J]. 计算机学报, 2007, 30(12): 2109-2114.
(Wang X B, Zhou D L, Wang S J. Constructive neuron networks classification algorithm based on biomimetic pattern recognition[J]. Chinese J of Computers, 2007, 30(12): 2109-2114.)
- [10] 周志华, 陈兆乾, 邵栋, 等. 一种新型自适应神经网络回归估计算法[J]. 计算机学报, 2000, 23(6): 654-659.
(Zhou Z H, Chen Z Q, Shao D, et al. A novel adaptive neural network regression estimate algorithm[J]. Chinese J of Computers, 2000, 23(6): 654-659.)
- [11] Ridella A, Rovetta S, Zunino R. Circular back propagation for classification[J]. IEEE Trans on Neural Networks, 1997, 8(1): 84-97.
- [12] Yan Qiu Chen, David W Thomas, Mark S Nixon. Generating shrinking algorithm for learning arbitrary classification[J]. Neural Networks, 1994, 5(7): 1477-1489.

(上接第1658页)

- [4] Yue D, Tian E G, Zhang Y J. Delay-distribution-dependent robust stability of uncertain systems with time-varying delay[J]. Int J of Robust and Nonlinear Control, 2009, 19(4): 377-393.
- [5] Yue D, Tian E G, Wang Z D, et al. Stabilization of systems with probabilistic interval input delays and its applications to networked control systems[J]. IEEE Trans on Systems, Man and Cybernetics, Part A: Systems and Humans, 2009, 39(4): 939-945.
- [6] Song H B, Yu L, Zhang W A. H_∞ filtering of network-based systems with random delay[J]. Signal Processing, 2009, 89(4): 615-622.
- [7] Liu M, Ho D, Niu Y. Stabilization of Markovian jump linear system over networks with random communication delay[J]. Automatica, 2009, 45(2): 416-421.
- [8] Yue D, Peng C, Yang T C. Guaranteed cost control of linear systems over networks with state and input quantizations[J]. IEE Proceedings: Control Theory and Applications, 2006, 153(6): 658-664.
- [9] Peng C, Tian Y C. Networked control of linear systems with state quantization[J]. Information Sciences, 2007, 177(24): 5763-5774.
- [10] Tian E G, Yue D, Peng C. Quantized output feedback control for networked control systems[J]. Information Sciences, 2008, 178(12): 2734-2749.
- [11] Niu Y, Jia T, Wang X, et al. Output-feedback control design for NCSs subject to quantization and dropout[J]. Information Sciences, 2009, 179(21): 3804-3813.
- [12] Mao Z H, Jiang B, Shi P. Fault detection filter design for networked control systems modelled by discrete Markovian jump systems[J]. IET Control Theory Application, 2007, 1(5): 1336-1343.
- [13] 冯宜伟, 郭戈. 一种新的量化反馈控制系统稳定性分析方法[J]. 控制与决策, 2009, 24(5): 785-793.
(Feng Y W, Guo G. A new stability analysis approach for quantized feedback control system[J]. Control and Decision, 2009, 24(5): 785-793.)