

基于敏感度方差重要性的RBF神经网络结构优化算法

杨 一, 高社生, 胡高歌

(西北工业大学 自动化学院, 西安 710072)

摘要: 针对RBF神经网络的结构设计问题, 提出一种基于输出敏感度方差重要性的结构优化算法. 首先, 检验网络隐层节点的输出敏感度在样本集上的方差是否与零有显著差异, 以此作为依据增加或删除相应的隐层节点; 然后, 对调整后的网络参数进行修正, 使网络具有更好的拟合精度和收敛性; 最后, 对所提出的优化算法进行仿真实验, 结果表明, 所提出的算法可根据研究对象自适应地调整RBF的网络结构, 具有良好的逼近能力和泛化能力.

关键词: 径向基函数神经网络; 输出敏感度; 方差重要性; 结构优化算法

中图分类号: TP273

文献标志码: A

Optimal algorithm for RBF neural network structure based on variance significance in output sensitivity

YANG Yi, GAO She-sheng, HU Gao-ge

(School of Automation, Northwestern Polytechnical University, Xi'an 710072, China. Correspondent: YANG Yi, E-mail: yangyi19850315@163.com)

Abstract: Aiming at the problem of design of the RBF neural network structure, an optimal algorithm based on variance significance in output sensitivity is proposed. Firstly, it is tested whether the variance in output sensitivity for the different patterns is significantly different from zero. If the variance in output sensitivities is significantly different from zero or not, the hidden units corresponding can be inserted or pruned. Then, the gradient descent method for the parameter adjusting ensures the fitting precision of the network. Finally, the proposed optimal algorithm is applied to the simulation experiment. Simulation results show that the proposed optimal algorithm can adjust network structure adaptive and possess good approximation and generalization ability.

Keywords: radial basis function(RBF) neural network; output sensitivity; variance significance; structure optimal algorithm

0 引言

径向基函数(RBF)神经网络因其简单的拓扑结构和全局逼近能力, 在时间序列预测、非线性系统建模与控制等方面得到了广泛的应用^[1-2]. RBF网络是一种三层前馈式神经网络, 其中输入层和输出层由线性神经元组成, 隐含层神经元是径向基函数, 一般取高斯核函数^[3-4].

RBF网络应用的关键是其结构设计问题^[5]. 为了实现RBF网络的自适应设计, Platt^[6]提出了一种著名的增长型学习算法: 资源分配网络(RAN). 该算法可以根据实际研究对象的复杂度, 以输入样本的“新颖性”作为依据为隐含层分配新节点, 满足RBF网络的

学习精度. 然而, RAN只能增加节点, 对于网络中不重要的节点不能删减, 在处理大型复杂问题时, 网络结构会出现冗余. 为了解决这一问题, Lu等^[7]提出了一种基于RAN的改进算法: 最小资源神经网络(M-RAN). M-RAN利用剪枝策略删除那些对网络输出的影响持续不明显的隐层节点, 并结合MAN的增长策略确保神经元数量的平滑过渡, 最终获得较为紧凑的RBF网络结构. 但是, 对网络输出影响程度的判定需要依据详尽的仿真研究实验, 增加了M-RAN的复杂度. Huang等^[8]提出了一种适用于RBF网络结构调整的在线学习算法: 广义增长修剪网络(GGAP-RBF). GGAP-RBF将所需的学习精度与神经元的重要性相

收稿日期: 2014-05-23; 修回日期: 2014-09-09.

基金项目: 国家自然科学基金项目(61174193); 航天科技创新基金项目(CASC201102).

作者简介: 杨一(1985—), 男, 博士生, 从事导航、制导与控制的研究; 高社生(1956—), 男, 教授, 博士生导师, 从事导航、制导与控制等研究.

结合, 给出增长与删减神经元的规则. 该算法仅对增加的神元或距离删减神元最近的节点进行参数调整, 有效提高了算法的实时性. 然而, GGAP-RBF 需要依据全局样本数据设定网络初值, 这一要求对于在线学习算法往往难以实现. Gonzales 等^[9]提出了一种基于多目标进化算法的 RBF 神经网络优化算法, 该算法在进化过程中加入新的遗传算子来改进网络的全局搜索能力. 然而, 进化算法的计算复杂, 不利于数据处理的实时性. Feng^[10]将粒子群优化 (PSO) 学习算法与 RBF 神经网络相结合, 解决复杂的全局优化问题. PSO 算法可以自动调整每个径向基函数的中心、宽度以及连接权, 达到提高网络性能的目的. 然而, PSO 算法在训练过程中需要进行全局搜索, 因此仍然需要较长的调整时间. Zhang^[11]利用在线减法聚类算法跟踪实时工况的特性以及 RBF 神经网络隐含层神经元的物理意义, 确定要增加或删除的隐节点. 由于只考虑距离实时工况数据最近的隐含层神元, 该算法不仅能够根据实时特性在线调整网络结构, 而且网络参数的调整速度较快. 然而, 该算法在删除阶段需要依据经验判断隐节点未被工况数据激活的时间, 易对隐节点的删除产生不确定性.

针对 RBF 神经网络的结构设计问题, 本文提出一种基于输出敏感度方差重要性的 RBF 神经网络 (VS-RBF) 结构优化算法. 该算法将基于输出敏感度方差重要性的度量方法与 RBF 神经网络有机结合, 能够根据实际问题的需要增加或删除网络隐含层神元, 使网络具有良好的自适应能力, 并利用梯度下降算法对优化后的网络结构参数进行修正. 将提出的优化算法应用于非线性函数逼近和组合导航位置误差估计, 仿真结果验证了该算法的有效性和可行性.

1 RBF 神经网络

RBF 神经网络是包含一个隐含层的三层前馈神经网络, 从输入层到隐含层的权值固定为 1, 偏差项固定为 0. 设网络的输入向量为 $x = (x_1, x_2, \dots, x_I)^T$, 则隐含层第 j 个节点的输出为

$$h_j(x) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma_j^2}\right). \quad (1)$$

其中: $h_j(x)$ 为高斯径向基函数; $\|\cdot\|$ 为欧氏范数; $c_j = (c_{j1}, c_{j2}, \dots, c_{jI})^T$ 为径向基函数的中心向量; σ_j 为第 j 个基函数的扩展常数或宽度 (可以自由选择参数), 宽度越小, 基函数的选择性越大.

隐含层第 j 个节点到输出层第 k 个节点的连接权重为 w_{kj} ($k = 1, 2, \dots, K, j = 1, 2, \dots, J$), 则高斯径向基函数神经网络输出层第 k 个节点关于向量 x 的输出 y_k 为

$$y_k(x) = \sum_{j=1}^J w_{kj} h_j(x) + w_{k0}, \quad (2)$$

其中 w_{k0} 为输出层第 k 个节点的偏差项.

另外, 定义输出层第 k 个节点的误差函数为

$$E_k = \frac{1}{2P} \sum_{p=1}^P (y_k - y_{dk})^2. \quad (3)$$

其中: P 为训练样本数, y_{dk} 为输出层第 k 个节点的期望输出.

网络总误差函数为

$$E = \sum_{k=1}^K E_k. \quad (4)$$

根据误差目标函数 (4) 调整神经网络的隐含层神元输出权值、中心值以及函数宽度如下 (利用梯度下降算法^[12]):

$$w_j(t+1) = w_j(t) - \eta_1 \frac{\partial E}{\partial w_j(t)}, \quad (5)$$

$$\mu_j(t+1) = \mu_j(t) - \eta_2 \frac{\partial E}{\partial \mu_j(t)}, \quad (6)$$

$$\sigma_j(t+1) = \sigma_j(t) - \eta_3 \frac{\partial E}{\partial \sigma_j(t)}, \quad (7)$$

其中 η_1, η_2, η_3 均为学习步长.

2 方差重要性 RBF 神经网络优化算法

方差重要性的基本思想是检验网络输出敏感度在所有样本上的方差是否与零有显著差异^[13]. 如果输出敏感度的方差与零有显著性差异, 且平均敏感度较大, 则表明相应的隐节点对网络输出影响较大, 反之表明相应的隐节点对网络输出影响较小或毫无影响^[14]. 以此增加或者删除隐含层神元, 达到神经网络结构优化的目的.

方差重要性: RBF 神经网络的隐节点 j 在样本 p ($p = 1, 2, \dots, P$) 上输出敏感度的方差统计重要性定义为

$$\gamma_{z_j} = \frac{(P-1)\sigma_{z_j}^2}{\sigma_0^2}. \quad (8)$$

其中: $\sigma_{z_j}^2$ 是网络输出对隐节点 j 中扰动的敏感度方差, σ_0^2 是接近 0 的值.

隐节点 j 的方差 $\sigma_{z_j}^2$ 由下式给出:

$$\sigma_{z_j}^2 = \frac{\sum_{p=1}^P (N_{z_j}^{(p)} - \bar{N}_{z_j})^2}{P-1}. \quad (9)$$

其中

$$N_{z_j}^{(p)} = \frac{\sum_{k=1}^K S_{y_k, z_j}^{(p)}}{K}, \quad (10)$$

且 \bar{N}_{z_j} 为平均敏感度, 其定义形式为

$$\bar{N}_{z_j} = \frac{\sum_{p=1}^P N_{z_j}^{(p)}}{P}. \quad (11)$$

$S_{y_k, z_j}^{(p)}$ 为网络输出 y_k 对于隐节点 j 在第 p 个样本上的敏感度, 由下式计算:

$$S_{y_k, z_j}^{(p)} = \frac{\partial y_k}{\partial z_j} = \sum_{j=1}^J w_{kj} \cdot h'_j(x). \quad (12)$$

在使用敏感度方差重要性时, 需要对隐节点 j 敏感度方差近似为零加以检验, 即对每个隐含层节点 j 定义零假设

$$H_0: \sigma_{z_j}^2 = \sigma_0^2. \quad (13)$$

然而, 由式(8)可知 $\sigma_0^2 \neq 0$, 所以不能假设所有样本上隐含层节点敏感度的方差严格为零, 即 $\sigma_{z_j}^2 \neq 0$. 因此, 赋给 σ_0^2 接近于零的值并使用备选假设

$$H_1: \sigma_{z_j}^2 < \sigma_0^2. \quad (14)$$

在零假设的条件下, 方差重要性度量满足 $\chi^2(P-1)$ 分布, 且 γ_C 可以从 χ^2 分布表中查询

$$\gamma_C = \chi_{v; 1-\alpha}^2. \quad (15)$$

其中: $v = P - 1$ 为自由度, α 为显著性水平.

本文采用梯度下降算法对参数进行调整, 因此网络对初始值很敏感, 不同的初值使网络的收敛速度差异很大. 若初始值离极小点很近, 则收敛速度较快; 反之, 收敛速度较慢. 当初始值选择不合适时, 训练起始阶段甚至会出现振荡. 基于上述分析, 本文采用 k -均值动态聚类法确定网络的初始中心, 找出有代表性的数据点作为网络隐节点的中心, 提高网络收敛速度, 并随机初始化函数宽度和权重.

根据以上计算过程, 得到基于敏感度方差重要性的RBF神经网络结构优化算法如下.

Step 1: 假设隐含层节点的初始值为较小数, 采用 k -均值动态聚类法确定基函数中心, 并随机初始化基函数宽度和连接权.

Step 2: 利用式(9)~(12)计算每个隐节点 j 在样本 p 上的输出敏感度方差 $\sigma_{z_j}^2$, 令 $\sigma_0^2 = 0.0001$.

Step 3: 采用式(8)计算检验变量 γ_{z_j} , 并按照升序排列每个检验变量的大小.

Step 4: 使用式(15)计算 γ_C . 对于每个隐含层节点 j , 如果统计重要性 $\gamma_{z_j} > 1.5\gamma_C$ 成立, 则分裂节点 j . 假设分裂前隐含层神经元数为 J , 运行时刻为 t , 统计重要性 $\gamma_{z_j} > 1.5\gamma_C$ 的隐含层神经元为 j , 则新增神经元 $J+1$ 的初始参数和神经元 j 的参数为

$$w_{J+1}(t) = \lambda \cdot w_j(t), \quad (16)$$

$$\mu_{J+1}(t) = \mu_j(t), \quad (17)$$

$$\sigma_{J+1}(t) = \sigma_j(t), \quad (18)$$

$$w'_j(t) = (1 - \lambda) \cdot w_j(t), \quad (19)$$

$$\mu'_j(t) = \mu_j(t), \quad (20)$$

$$\sigma'_j(t) = \sigma_j(t), \quad (21)$$

其中 λ 为 $(0, 0.5)$ 范围内的任意常数, 根据实际研究对象而定. 其他神经元的参数仍然按式(5)~(7)调整.

Step 5: 对于每个隐含层节点 j , 如果统计重要性 $\gamma_{z_j} \leq \gamma_C$ 成立, 则删除节点 j . 假设运行时刻为 t , 此时与被删除节点欧氏距离最近的神经元为 j_n , 其相关参数调整为

$$w'_{j_n} = w_{j_n}(t) + w_j(t) \frac{h_j(x)}{h_{j_n}(x)}, \quad (22)$$

$$\mu'_{j_n}(t) = \mu_{j_n}(t), \quad (23)$$

$$\sigma'_{j_n}(t) = \sigma_{j_n}(t). \quad (24)$$

其他神经元的参数仍按照式(5)~(7)调整.

Step 6: 直至没有神经元分裂或删除时, 得到最终优化后的网络.

该优化算法将隐节点的敏感度方差统计重要性与RBF网络参数学习有机地结合. 通过计算网络输出对隐节点中扰动的敏感度方差, 判断该节点对网络的重要性. 对于影响较大的神经元进行分裂, 删除影响较小或毫无影响的隐含层神经元, 达到神经网络结构优化的目的, 最终获得结构较为合理的RBF神经网络.

3 仿真分析

VS-RBF网络能够在线调整隐含层神经元, 得到与研究对象相适应的网络结构, 提高RBF神经网络的性能. 本节利用非线性函数逼近以及组合导航误差估计为研究对象, 通过仿真实验表明该算法的有效性, 并与几种常用的神经网络算法进行比较, 以验证该算法的高效性.

3.1 非线性函数逼近

选取二维不同频率的三角函数为学习样本, 即

$$y_d = \cos(2\pi k_1 x_1 + 2\pi k_2 x_2) \times \sin(2\pi k_2 x_2). \quad (25)$$

其中: y_d 为期望输出, k_1 取 0.05, k_2 取 0.02, 输入样本满足 $0 < x_1 < 36, 0 < x_2 < 36$. 对式(25)进行训练, 训练前随机产生 500 个训练样本对 $((x_1, x_2), y)$, 期望误差选为 0.003.

在三角函数逼近过程中, VS-RBF网络逼近效果和误差曲面如图1所示, 网络的隐含层神经元变化状态如图2所示.

图1给出了VS-RBF神经网络对非线性函数的逼近结果以及对函数逼近的误差曲面, 其均方误差达到 0.0031, 说明该网络有较强的逼近能力; 图2给出了训练结束后网络最终的隐含层神经元个数, 训练后

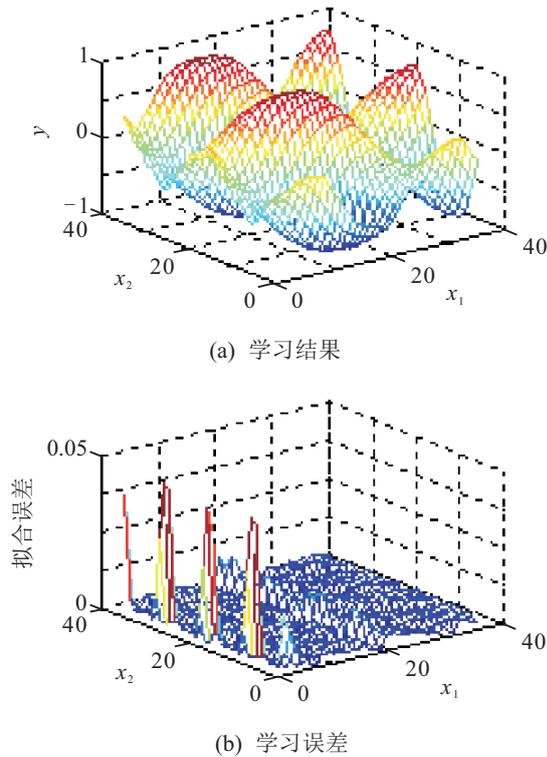


图1 VS-RBF对函数的逼近效果和误差曲面

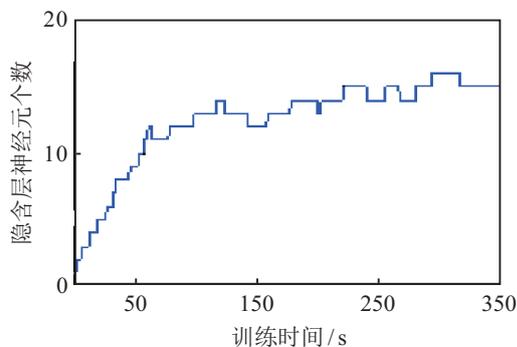


图2 网络训练中隐含层神经元变化情况

的网络结构为2-15-1.

与BP网络、RBF网络以及MRAN(网络初始结构与VS-RBF网络相同)的性能比较如表1所示.

表1 神经网络训练算法的性能比较

| 训练算法 | VS-RBF | MRAN | RBF | BP |
|--------|--------|--------|--------|--------|
| 均方误差 | 0.0031 | 0.0037 | 0.0082 | 0.0127 |
| 隐节点个数 | 15 | 19 | 28 | 33 |
| 训练时间/s | 316.5 | 633.2 | 231.7 | 185.4 |

表1给出了VS-RBF网络与MRAN、RBF、BP网络比较的详细结果,由此可以得到以下结论:

1) 在相同的初始条件下,VS-RBF网络所需的训练时间远远小于MRAN,且逼近精度略高于MRAN,说明所提出的网络优化算法有效提高了网络的实时性;

2) 训练后的RBF和BP网络的复杂度远远大于VS-RBF,存储空间相应增加,所以它们的逼近精度远

小于VS-RBF.因此,VS-RBF神经网络不仅具有较强的非线性函数逼近能力,而且可以有效提高神经网络计算的实时性.

3.2 组合导航误差估计

将所提出的VS-RBF算法应用于GPS/DR车辆组合导航系统中,并与传统BP算法进行仿真比较.

假设车辆东向和北向初始位置真值均为0,车辆以15 m/s的速度沿45°航向角匀速直线运动,东向和北向的初始加速度为0 m/s²,GPS东向和北向量测噪声方差为(15 m)²,里程计量测噪声方差为(1 m)²,相关时间 $\tau_e = \tau_n = 300$ s,里程计标定系数 $\psi = 0.5$,仿真时间取2 000 s.组合导航系统的状态变量为

$$X = [v_e, v_n, a_e, a_n, x_e, x_n].$$

其中: v_e, v_n 分别表示车辆东向和北向的速度分量; a_e, a_n 分别表示东向和北向的加速度分量,且 $a_e = a_n = 1$ m/s²; x_e, x_n 分别表示东向和北向的位置分量.量测量取 $Z = [e, n, w, s]$, e, n, w 分别表示GPS输出的东向、北向位置信息和角速率陀螺的输出, s 表示里程计输出距离.组合导航状态方程和观测方程见文献[15].

采用GPS/DR组合导航系统扩展卡尔曼滤波器(EKF)为神经网络提供仿真实验所需的训练样本,随机选取500对输入输出数据作为训练样本.设计三层VS-RBF网络模型,网络的输入为组合导航模型的量测量,输出为组合导航模型的状态量^[16].由GPS/DR组合导航系统的动力学模型可知,量测量包含4个变量,状态量包含6个变量,初始阶段隐含层神经元个数选为较小的自然数.训练过程中,VS-RBF网络隐含层神经元个数变化如图3所示.根据多次实验对比,将BP神经网络的结构选为4-60-6.

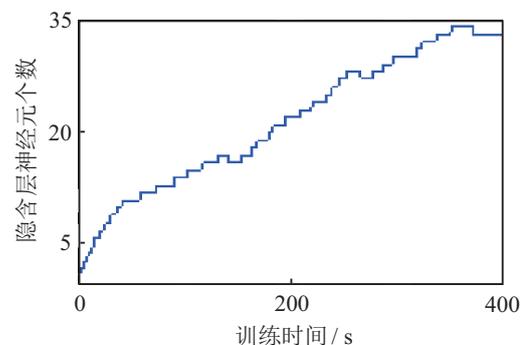


图3 网络训练中隐含层神经元变化情况

东向和北向定位误差的仿真结果如图4和图5所示.从图中可以看出,采用传统BP算法得到的东、北向定位误差曲线波动较大,约在[-9 m, 9 m]之间波动,其峰值甚至超过了±10 m.而采用本文提出的VS-RBF神经网络算法得到的东、北向定位误差大约控制在[-5.5 m, 5.5 m]之内,估计效果较好.

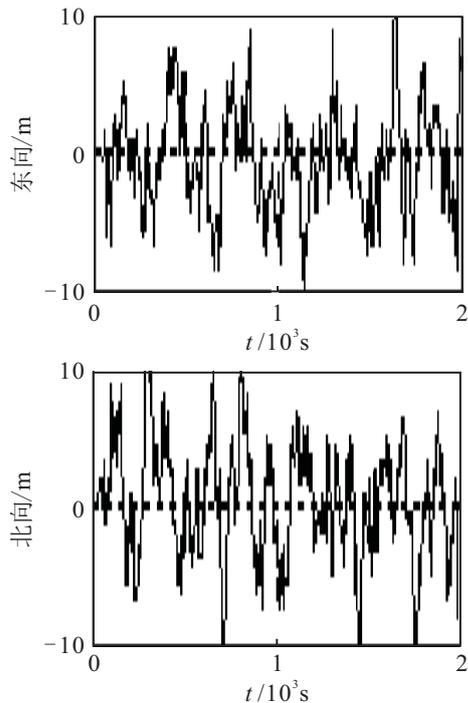


图 4 BP 算法得到的位置误差

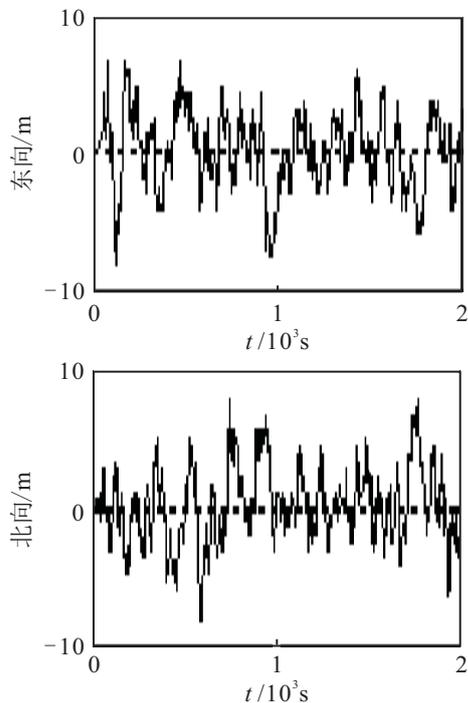


图 5 VS-RBF 算法得到的位置误差

表 2 给出了两种算法的训练结果和平均位置误差.

表 2 两种训练算法的性能比较

| 训练算法 | 位置平均误差 | 隐节点数 | 训练时间/s |
|--------|-----------------|------|--------|
| BP | [-7.3 m, 7.5 m] | 60 | 280.8 |
| VS-RBF | [-4.8 m, 4.4 m] | 33 | 372.3 |

可以看出, 本文提出的 VS-RBF 神经网络算法得到的东、北向平均误差小于 BP 算法得到的东、北向平均误差. 表明所提出的 VS-RBF 网络的估计性能优

于 BP 网络, 能够减小导航定位误差, 有效逼近组合导航系统的位置信息. 这是因为 BP 网络隐含层节点个数的选择尚无理论指导, 一般根据经验选取, 在训练阶段网络结构不能变化, 不利于网络的适用性; 而 VS-RBF 网络可以在训练阶段自适应地调整隐含层节点, 动态确定网络结构, 从而减少相应的存储空间, 使网络有更紧凑的结构以及更好的估计精度.

4 结 论

本文针对 RBF 神经网络的结构设计问题, 提出了一种基于输出敏感度方差重要性的 RBF 神经网络结构优化算法. 首先, 以隐含层节点的输出敏感度在样本集上的方差作为重要性度量, 并给出方差统计重要性的计算方法; 然后, 对比方差统计的计算结果与检验变量的关系, 利用假设检验确定隐含层节点的重要性, 从而判定是否对节点进行分裂或删除操作; 最后, 对调整后的网络参数进行修正, 使网络具有更好的收敛性. 通过对非线性函数的逼近以及组合导航误差的估计, 并与其他常用的神经网络结构进行比较, 可以得到以下结论:

1) VS-RBF 神经网络可以根据研究目标的不同自适应地调整隐含层节点的个数, 获得紧凑的 RBF 神经网络结构.

2) 与其他改进的 RBF 网络相比, 经过该算法优化的 RBF 网络具有较强的非线性逼近能力以及较好的收敛速度.

3) 相较于其他神经网络结构, VS-RBF 神经网络表现出较好的训练结果和测试结果, 说明在处理组合导航这样的复杂系统时, VS-RBF 神经网络具有较好的泛化能力.

综上所述, 本文所提出的方差重要性度量算法可以有效解决 RBF 神经网络的结构设计问题, 并且提高神经网络的逼近能力和泛化能力, 具有理论可行性和实际应用潜力.

参考文献(References)

[1] 张琨, 崔胜民, 王剑锋. 基于自适应 RBF 网络补偿的智能车辆循迹控制[J]. 控制与决策, 2014, 29(4): 627-637. (Zhang K, Cui S M, Wang J F. Intelligent vehicle's path tracking control based on self-adaptive RBF network compensation[J]. Control and Decision, 2014, 29(4): 627-637.)

[2] Luengo J, Garcia S, Herrera F. A study on the use of imputation methods for experimentation with radial basis function network classifiers handling missing attribute values: The good synergy between RBFNs and EventCovering method[J]. Neural Networks, 2010, 23(3): 406-418.

- [3] Ferrari S, Bellocchio F, Puri V, et al. A hierarchical RBF online learning algorithm for real-time 3-D scanner[J]. *IEEE Trans on Neural Networks*, 2010, 21(2): 275-285.
- [4] Illya K, Antonio P B. An effective multi-objective learning algorithm for RBF network learning[J]. *Neurocomputing*, 2010, 73: 2799-2808.
- [5] 韩红桂, 乔俊飞, 薄迎春. 基于信息强度的RBF神经网络结构设计研究[J]. *自动化学报*, 2012, 38(7): 1083-1090.
(Han H G, Qiao J F, Bo Y C. On structure design for RBF neural network based on information strength[J]. *Acta Automatica Sinica*, 2012, 38(7): 1083-1090.)
- [6] Platt J. A resource-allocating network for function interpolation[J]. *Neural Computation*, 1991, 3(2): 213-225.
- [7] Lu Y W, Sundararajan N, Saratchandran P. A sequential learning scheme for function approximation using minimal radial basis function neural networks[J]. *Neural Computation*, 1997, 9(2): 461-478.
- [8] Huang G B, Saratchandran P, Sundararajan N. A generalized growing and pruning RBF(GGAP-RBF) neural network for function approximation[J]. *IEEE Trans on Neural Networks*, 2005, 16(1): 57-67.
- [9] Gonzales J, Rojas I, Ortega J. Multi-objective evolutionary optimization of the size, shape, and position parameters of radial basis function networks for function approximation[J]. *IEEE Trans on Neural Networks*, 2003, 14(6): 1478-1495.
- [10] Feng H M. Self-generation RBFNs using evolutionary PSO learning[J]. *Neurocomputing*, 2006, 70(1/2/3): 241-251.
- [11] 张昭昭, 乔俊飞. 基于在线减法聚类的RBF神经网络结构设计[J]. *控制与决策*, 2012, 27(7): 997-1002.
(Zhang Z Z, Qiao J F. Design RBF neural network architecture based on online subtractive clustering[J]. *Control and Decision*, 2012, 27(7): 997-1002.)
- [12] Buzzi C, Grippo L, Sciandrone M. Convergent decomposition techniques for training RBF neural networks[J]. *Neural Computation*, 2001, 13(8): 1897-1920.
- [13] Zeng X, Yeung D S. Hidden neuron pruning of multilayer perceptrons using a quantified sensitivity measure[J]. *Neurocomputing*, 2006, 69(7): 825-837.
- [14] Engelbrecht A P. A new pruning heuristics based on variance analysis of sensitivity information[J]. *IEEE Trans on Neural Networks*, 2001, 12(6): 1386-1399.
- [15] 薛丽, 高社生, 赵岩. 权值自适应调整Unscented粒子滤波及其在组合导航中的应用[J]. *中国惯性技术学报*, 2012, 20(4): 459-463.
(Xue L, Gao S S, Zhao Y. Unscented particle filtering with adaptive adjusted weight and its application in integrated navigation[J]. *J of Chinese Inertial Technology*, 2012, 20(4): 459-463.)
- [16] 杨一, 高社生, 吴佳鹏, 等. 模型预测前向神经网络算法及其在组合导航中的应用[J]. *中国惯性技术学报*, 2014, 22(2): 221-226.
(Yang Y, Gao S S, Wu J P, et al. Feed-forward neural network algorithm based on model predictive filtering and its application in integrated navigation[J]. *J of Chinese Inertial Technology*, 2014, 22(2): 221-226.)

(责任编辑: 齐 霖)