

广义 RBF 神经网络在煤矿冲击地压预测上的应用

李 焱^{1,2} 马尽文¹

(1. 北京大学数学科学学院信息科学系和数学及其应用教育部重点实验室 北京 100871;
2. 黑龙江科技大学理学院 哈尔滨 150027)

摘 要: 本文将广义径向基函数(RBF)神经网络应用于华丰煤矿实测的煤矿中冲击地压数据的建模和短期预报。在网络设计上,本文采用了贝叶斯阴阳(BYY)和谐学习算法进行网络隐单元个数的确定和参数初始值的选取,而在参数学习上,本文则采用了同步 LMS 学习算法。实验结果表明,这种基于广义 RBF 神经网络的预测方法在精度和速度上有了显著的优势,能够满足在工程应用中的实际要求。

关键词: RBF 神经网络; 贝叶斯阴阳和谐学习; 矿山冲击地压; 预测

中图分类号: TP183 **文献标识码:** A **文章编号:** 1003-0530(2013)12-1689-07

The Application of Generalized RBF Neural Network to Mine Rockburst Prediction

LI Yan^{1,2} MA Jin-wen¹

(1. Department of Information Science, School of Mathematical Sciences and LMAM, Peking University, Beijing 100871;
2. College of Science, Heilongjiang University of Science and Technology, Harbin, 150027)

Abstract: In this paper, the generalized Radial Basis Function (RBF) neural network is applied to the short-term prediction of mine rockburst on a real-world dataset recorded by Huafeng Mine Company. For its network design and parameter learning, the Bayesian Ying-Yang (BYY) harmony learning algorithm and the synchronous LMS learning algorithm are utilized, respectively. It is demonstrated by the experimental results that this generalized RBF neural network based mine rockburst prediction method has obvious advantages of both prediction accuracy and convergence speed, and can satisfy the practical requirements of engineering application.

Key words: RBF neural network; BYY harmony learning; mine rockburst; prediction

1 引言

煤矿中冲击地压是由于井巷和采场周围的煤岩体中所聚积的弹性变形势能在一定条件下的突然猛烈释放,导致岩石爆裂并弹射出来的现象。作为煤矿开采中发生的主要灾害之一,它会对地下硐室、人员、设备以及地面建筑物造成强烈的破坏。随着我国煤矿开采深度逐年增加,冲击地压显现日

趋频繁,严重威胁着煤炭的安全生产,因此如何根据煤矿的实际地质和采矿的技术条件进行针对性的冲击地压的预测与防治是保证矿井安全生产的重要措施^[1-5]。近年来随着多学科在矿山灾害预测领域的应用增强及大量微震设备和技术引入煤矿,对于冲击地压预测的探索也不断地发展并逐步趋于成熟^[6-10]。

目前,神经网络模型和方法已经被广泛地应用

到工程技术领域中。很自然,不少学者试图将神经网络方法应用到冲击地压预测上,其中典型的预测方法包括:利用多层感知机和BP算法与主成分分析相结合的方法^[11]、基于异步迭代算法的神经网络方法^[12]和神经网络与灰色理论相结合的方法^[13]。这些神经网络方法在冲击地压的预测上提高了精度,其显著特点和优势在于能够直接通过对实际数据的学习建立预测模型,无需了解复杂的地质构造和力学机制,这无疑给冲击地压的预测带了新的活力。然而,这些神经网络方法也存在着收敛速度慢、受样本限制较大、结果不够稳定、容易陷入局部极小解等问题^[14]。因此,人们还在努力寻求能够更为有效地进行冲击地压预测的神经网络模型和学习算法,以克服这些缺点和不足。

径向基函数(Radial Basis Function, RBF)神经网络是一种仅有单个隐层的前馈型神经网络,能够以任意精度逼近一个任意给定的连续函数。相比BP神经网络,它结构更为简单,学习速度有了大大的提高,并能够有效地避免局部极小解^[15]。因此,它在灾害预测、故障诊断等方面已经得到了广泛的应用^[16-18]。为了提高RBF神经网络的学习和推广能力,一种新型的广义RBF神经网络^[19-22]被提了出来。实际上,在广义RBF神经网络中,高斯(即正态)概率密度函数被用于取代了原来的高斯核函数,打破了传统基函数所要求的径向对称性的限制,或者说将其推广到了按马氏距离满足径向对称性,从而获得了更强大的表达能力。另一方面,我们也通过贝叶斯阴阳(BYY)和谐学习型的自动模型选择算法^{[23]-[25]}更为合理地选择网络中隐单元个数而达到优化网络设计,然后再对这一优化的网络结构采用同步的LMS参数学习,便可提高了网络的学习和预测能力。

本文将这种广义RBF神经网络应用于煤矿冲击压力的预测,采用BYY自适应梯度和谐学习算法^[24]进行隐层单元个数的确定和参数初始值的选取,而进一步采用LMS学习算法进行参数的学习和估计。在华丰煤矿的现场实测数据上的实验结果表明,这种基于广义RBF神经网络和学习方法能够对于未来10日内冲击地压最大震级进行了有效的预测。

2 预测模型与学习算法

2.1 RBF神经网络模型

RBF神经网络由三层组成,其结构如图1所示。输入层由一些感知单元组成,它们将网络与外界环境连接起来;第二层是网络中仅有的一个隐层,其作用是对输入信号进行非线性变换。在一般情况下,隐层包含着较多的单元,所形成的中间数据具有较高的维数。输出层是由一组线性单元组成,它对于网络的输入模式做出响应或输出决策结果。由于RBF神经网络模拟了人脑局部调整、相互覆盖接受域等神经网络结构和特点,因此它具有良好的逼近或学习能力。从理论上讲,它能够以任意精度来逼近任何一个连续函数。




图1 RBF神经网络结构模型

Fig. 1 The structural model of RBF neural network

在RBF神经网络中,人们最常用的径向基函数为高斯核函数:

$$R_j(x) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma_j^2}\right), j = 1, \dots, m \quad (1)$$

其中 x 是 n 维输入向量, c_j 和 σ_j 分别是第 j 个径向基函数的中心和宽度,且 m 是径向基函数或者说隐单元的个数。这里, $\|x - c_j\|$ 是指向量 $x - c_j$ 的范数,通常表示 x 和 c_j 之间的欧氏距离。 $R_j(x)$ 在 c_j 处达到最大值,并随着 $\|x - c_j\|$ 的增大而迅速衰减到零。实际上,对于一般的输入 $x \in R^n$,只有靠近中心 c_j 的那部分被显著地激活了。

从图1可以看出,从输入层到任一隐层单元则实现了一个非线性映射: $x \rightarrow R_j(x)$,而从隐层到输出层则实现了一个线性映射:

$$[R_1(x), R_2(x), \dots, R_m(x)]^T \rightarrow y, \text{ 即}$$

$$y_k = \sum_{j=1}^m w_{jk} R_j(x), k = 1, 2, \dots, p \quad (2)$$

其中 p 是输出节点个数, w_{jk} 则是第 j 个隐单元到第 k 个输出单元的连接权值。

2.2 广义 RBF 神经网络

在实际应用中,RBF 神经网络主要存在着两点不足。首先,在参数学习中,隐层单元个数是需要事先给定的,但在实际应用中,如何确定隐层单元的个数却是一个非常复杂的问题,传统的先确定一个可能的范围再逐一取值试验的方法需要花费很大的计算代价。其次,两步走的学习算法,即将神经网络的参数分割成两部分分别进行学习,无法达到全局上的最优,必然会降低神经网络的推广或预测能力。

为了克服上述不足,我们可对传统 RBF 神经网络进行一定的改进和推广。首先,可采用高斯概率密度函数来代替高斯核函数来作为基函数,即

$$R_j(x) = \frac{1}{(\pi)^{\frac{1}{2}} |\Sigma_j|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} (x - m_j)^T \Sigma_j^{-1} (x - m_j) \right\} \quad (3)$$

这种形式的基函数具有更强大的表达能力,尤其是在输入样本数据服从高斯混合模型的时候,它表现的更为突出。其次,当隐层单元个数确定后,我们对于神经网络的所有参数可以进行同步学习,即不再需要像传统算法那样先确定各个隐单元的参数,再对后面的连接权值进行学习,而是可以同步地对隐单元均值向量 m_j 、协方差阵 Σ_j 和连接权值 w_j 同时进行学习(注意,在冲击低压预测问题中,网络的输出单元只需要一个,即 $p=1$,这样则可令 $w_{j1}=w_j$,网络模型更为简单)。

通过对 RBF 神经网络进行上述改进和推广,其学习和推广能力有显著提高,并称其为广义 RBF 神经网络^{[20]-[21]}。进一步,为了提高其推广能力,我们还可限制协方差阵 Σ_j 为对角矩阵,即令

$$\Sigma_j = \text{diag}(\sigma_{j1}, \dots, \sigma_{jn}) \quad (\sigma_{ji} > 0) \quad (4)$$

这样所得到的 RBF 神经网络则是一种结构受限制(或子空间形式)的广义 RBF 神经网络,被称之为对角型广义 RBF 神经网络^[22]。实际上,对角型广义 RBF 神经网络较之一般广义 RBF 神经网络有着两个比较明显的优势:首先,对角型广义 RBF 网络的形式更为简单,与传统的 RBF 神经网络更为接近,对角矩阵的运算法也相对简单,运算量大大降低,

即算法的速度会有显著提高。其次,对角型广义 RBF 神经网络的基函数的参数个数明显变少。根据统计计算学习理论,一个模型的参数越多,其拟合性能就越好,但是作为代价,其泛化推广能力一般也就越差。尤其是当训练样本量较小的时候,参数较多的模型虽然可以在训练集上有很好的表现,但在测试集上的预测表现会相当弱。因此,在构建神经网络的时候,权衡网络的表达能力与泛化能力是至关重要的。而对角型广义 RBF 神经网络的基函数参数数目正好介于传统 RBF 神经网络和广义 RBF 神经网络之间,既能打破传统 RBF 网络径向对称性的限制,获得更广泛的表达能力,又能尽量避免一般广义 RBF 网络参数过多导致过学习的风险,拥有较好的泛化能力。

综上所述,对角型广义 RBF 神经网络较好地调和了传统 RBF 神经网络学习能力弱和一般广义 RBF 神经网络推广能力差之间的矛盾,而综合了二者的优点,在算法的简洁性、效率、拟合能力和泛化能力等多个方面能达到较好的平衡。因此,我们针对煤矿冲击地压预测所采用的广义 RBF 神经网络便是对角型的。

2.3 学习算法

对于广义 RBF 神经网络,我们先采用 BYY 自适应梯度和谐学习算法^[24]对输入样本数据进行学习来确定隐单元(即 RBF)个数和相应参数的初始值。从理论上,我们可以认为输入样本空间是由若干个高斯分布混合而成,即服从高斯混合模型,而仅仅当隐单元个数与这些高斯分量的个数相匹配时,广义 RBF 神经网络才能最好地刻画出数据的输入输出映射关系。基于这一原理,我们可以采用自适应梯度 BYY 和谐学习算法对于输入样本数据进行学习。在实际实施时,我们总可以将数据中高斯分量个数设计的大一些,通过 BYY 和谐学习,那些多余的高斯分量会被自动地清除掉(即其混合比例衰减为零,自动消失),所保留的高斯分量正是输入样本数据中真实的分量。这样就自动地确定了输入样本空间中高斯分量个数,并令其为广义 RBF 神经网络中的隐单元个数。同时,算法所

获得的这些高斯分量的参数估计值则可作为广义 RBF 神经网络的相关参数的最为合理的初始值。注意当协方差矩阵限制为对角矩阵后, 高斯混合模型的自适应梯度 BYY 和谐学习算法则转变为一种简化的形式了。

当广义 RBF 神经网络的结构确定以后, 我们则可根据给定的完整样本 $S = \{(x_i, \hat{y}_i)\}_{i=1}^N$ 来建立对所有参数同步的最小均方误差(LMS)学习算法。这时, 广义 RBF 神经网络($p=1$)的均方误差函数则为:

$$E = \frac{1}{2} \sum_{i=1}^N (\hat{y}_i - y_i)^2 = \frac{1}{2} \sum_{i=1}^N [\hat{y}_i - \sum_{j=1}^k w_j R_j(x_i)]^2 \tag{5}$$

根据均方误差函数对于 w_j, m_j 和 σ_{ji} 的导数, 我们可以得到下列 LMS 学习准则:

$$\Delta w_j = \eta \sum_{i=1}^N (\hat{y}_i - y_i) R_j(x_i) \tag{6}$$

$$\Delta m_j = \eta \sum_{i=1}^N (\hat{y}_i - y_i) w_j R_j(x_i) \Sigma_j^{-1}(x_i - m_j) \tag{7}$$

$$\Delta \sigma_{ji} = \frac{\eta}{2} \sum_{i=1}^N \sum_{u=1}^p (y_{iu} - \hat{y}_{iu}) w_{ji} R_j(x_i) \left[\frac{1}{\sigma_{ji}} - \frac{(x_{iu} - m_{ji})^2}{\sigma_{ji}^2} \right] \tag{8}$$

在上述参数学习准则(1)-(3)中, $\eta (>0)$ 为学习率, 可取一个比较小的正数, 或从一个相对大的初始值随时间逐步衰减为零。当迭代所带来的误差绝对变化量 $|\Delta E| = |E(\Theta^{(k+1)}) - E(\Theta^{(k)})|$ 小于给定的误差精度 $\varepsilon (>0)$ 后, 算法则终止, 并获得了 对角型广义 RBF 神经网络的所有参数值。

3 实验结果与分析

3.1 数据的归一化处理

我们采用华丰煤矿提供的一组冲击地压的现场监测数据。如表 1 所示, 每组数据包括冲击地压的能量、产生波的幅值、频次和最大震级, 并按采样时间先后对其编号(采样周期为 10 天)。从表 1 可以清楚地看出, 这些实际数据属于不同量纲, 并且数据之间相差较大。如果我们直接使用它们, 将会使得神经网络对小量纲的数据的变化不够敏感, 直

接影响神经网络学习的精度。因此, 我们需要对数据进行归一化处理。

表 1 华丰煤矿对冲击地压的监测数据
Tab. 1 The monitoring data of mine rockburst from Huafeng Mine Company

编号	能量值 (万焦)	波幅值	十日内地震 频次	最大震级 (里氏)
1	46.95	14.2	14	1.2
2	44.77	17.3	15	1
3	10.5	5.1	7	0.9
4	17.77	6.7	4	1.1
5	22.42	10.1	10	1
6	28.71	11	8	1.1
7	54.92	11.3	5	1.5
8	17.35	10.5	10	0.9
9	98.9	22	15	1.6
10	66.59	18.1	13	1.4
11	139.4	25.3	13	1.6
12	28.96	11.2	12	1.6
13	30.7	15.9	15	0.9
14	83.06	26.4	25	1.2
15	117.22	24.9	15	1.6
16	247.5	26.4	12	1.9
17	145.32	26.3	22	1.6
18	90.94	26.6	24	1.2
19	113.65	23.6	14	1.6
20	41.6	17.1	17	1
21	59.9	23.7	21	1.2
22	52.3	24.4	20	0.9
23	101.79	21.62	19	1.4
24	107.88	29.22	24	1.4
25	229.06	40.7	26	1.5
26	1350.78	113.7	81	1.8
27	223.23	46	59	1.3
28	131.91	34	40	1.2
29	213.02	28.3	14	1.8

续表

编号	能量值 (万焦)	波幅值	十日内地震 频次	最大震级 (里氏)
30	39.46	17	15	1
31	78.71	21.8	16	1.4
32	34.41	14.7	23	1
33	312.81	46.4	70	1.6
34	144.14	35.2	59	1.2
35	312.65	52.1	88	1.3
36	548.05	72.1	121	1.5
37	1733.63	135.8	162	1.7
38	739.56	82.8	128	1.6
39	286.27	51.7	116	1.3
40	478.51	655	110	1.7
41	603.53	54.6	84	1.7

在实际应用中,我们可以利用下述最大最小值公式来进行数据归一化处理:

$$x'_{il} = \frac{x_{il} - \min_{1 \leq j \leq 41} \{x_{jl}\}}{\max_{1 \leq j \leq 41} \{x_{jl}\} - \min_{1 \leq j \leq 41} \{x_{jl}\}}, l = 1, 2, 3 \quad (9)$$

其中 x'_{il} 为归一化后的数据, $\min_{1 \leq j \leq 41} \{x_{jl}\}$ 为 l 列中最小数据,而 $\max_{1 \leq j \leq 41} \{x_{jl}\}$ 为 l 列中最大数据。

3.2 预测结果分析与比较

我们将归一化的数据用于对角型广义 RBF 神经网络的设计和参数学习。我们希望使用前一时刻数据中的地震产生的能量值、波的幅值(曲线值)、10 日内产生的冲击地压的次数作为输入数据来预测出下一时刻的冲击地压的最大震级,并通过对角型广义 RBF 神经网络来实现这种预测或映射关系。实际上,华丰监测数据共有 40 组输入输出对应值。为了检测广义 RBF 神经网络的预测性能,我们采用交叉检验的方法。具体地说,我们将 40 组数据随机地分成 4 单元,每个单元包含 10 组数据。在实验时,我们取每个单元的数据为检验集,而其余 3 个单元的数据为训练集,对于广义 RBF 神经网络进行训练和检验。网络的输入单元个数为 3(即 $n = 3$),输出节点数为 1,交叉检验对每对训练和检验集根据初始参数的随机进行 10 次实验,并得到冲击地压预测的平均误差。然后,我们再根据 4 组实验结

果进一步计算出冲击地压预测的总体平均误差 \hat{e} 和标准差 σ ,其中 $\hat{e} = \frac{1}{4} \sum_{i=1}^4 e_i, \sigma = \frac{1}{2} \sqrt{\sum_{i=1}^4 (e_i - \hat{e})^2}$ 。




图 2 训练集中输入样本点及其对应的预测值
Fig.2 The input sample points and their corresponding prediction values in a training set

实际上,如图 2 所示,这里是一组随机选取的用于交叉检验的训练样本及其预测值的数据点分布图,图中各点上所标数字为广义 RBF 神经网络(即学习系统)所给出的预测或输出值。从此可以看出,在 30 个训练样本点中,有将近 20 个输入样本密集在一个很小的范围内。这就给实际预测带来了极大的困难。然后,采用新型学习算法的对角型广义 RBF 神经网络却取得了很好的冲击地压预测效果。从表 2 可以看出,通过交叉检验所得到的广义 RBF 神经网络的平均预测误差仅为 0.0026,这已经充分地小了,足以满足实际要求。另外,广义 RBF 神经网络预测性能也很稳定。实际上,交叉检验中预测误差的标准差也仅仅为 0.0022。从表 2 还可以看出,两种 RBF 神经网络方法比基于 BP 算法的多层感知机神经网络方法在预测性能上有了大的提高,显示出很强的优势。更进一步,广义 RBF 神经网络方法比传统 RBF 神经网络方法在预测的准确性和稳定系也有了显著的提高,其主要原因在于广义 RBF 神经网络有效地优化了网络的隐单元个数和学习方式。另外,从计算复杂性上,对于广义 RBF 神经网络,新型学习算法自然要花费更多的时间,比传统的 RBF 神经网络的学习增加了一定的计算量,但相对于基于多层感知机的 BP 算法还是要快的多。从运行时间来,基于广义 RBF 神经网络的新型学习算法的执行时间仅仅是基于多层感知机

的BP算法的执行时间的四分之一左右。因此,基于新学习算法的广义RBF神经网络是一种很有效的煤矿冲击地压预测模型和方法,优于传统的神经网络模型和方法。

表2 预测误差结果及其比较

Tab.2 The prediction error and comparisons

神经网络与算法	误差($\hat{e} \pm \sigma$)
多层感知机与BP算法	0.0244±0.0173
RBF神经网络与两步算法	0.0035±0.0066
广义RBF神经网络与BYY和谐学习算法及同步LMS学习算法	0.0026±0.0022

4 结论

本文将广义RBF神经网络成功地应用于煤矿冲击地压的预测中,并通过BYY和谐学习算法进行网络中隐单元个数和参数初始值设的合理选择,且利用同步的LMS学习算法进行参数学习和估计。通过在华丰煤矿冲击地压的检测数据上的交叉检验,我们验证了基于新型学习算法的广义RBF神经网络能够有效地预测煤矿冲击地压,对于短期最大震级预报可达到很高精度,并且优于传统的神经网络模型及学习算法。在运行时间上,该方法也远优于基于多层感知机的BP学习方法。实际上,由于煤矿冲击地压问题具有相当复杂的背景和机理,为避免重大损失,在实际应用中可结合地质构造、煤柱分布等信息,以及微地震监测和电磁辐射、钻屑量等数据进行更为合理的综合预报。

参考文献

[1] 吴中立. 矿井通风与安全[M]. 徐州: 中国矿业大学出版社, 1992.
Z. L. Wu. Ventilation and Security of Mine [M]. Xuzhou: The Publishing House of China Mining University, 1992. (in Chinese)

[2] 窦林名, 何学秋. 冲击地压防治理论与技术[M]. 徐州: 中国矿业大学出版社, 2001.
L. M. Dou, X. Q. He. Protection Theory and Technology of Rockburst [M]. Xuzhou: The Publishing House of China Mining University, 2001. (in Chinese)

[3] 窦林名, 赵从国, 杨思光等. 煤矿开采冲击矿压灾害防治[M]. 徐州: 中国矿业大学出版社, 2006.
L. M. Dou, C. G. Zhao, S. G. Yang, et al. Rockburst Dis-

ter Prevention and Control on Coal Mining [M]. Xuzhou: The Publishing House of China Mining University, 2006. (in Chinese)

- [4] 陈忠辉等. 矿山压力与控制[M]. 徐州: 中国矿业大学, 2007.
Z. H. Chen, et al. Mine Ground Pressure and Control [M]. Xuzhou: The Publishing House of China Mining University, 2007. (in Chinese)
- [5] 姜福兴, 王同旭, 潘立友等. 矿山压力与岩层控制[M]. 北京: 煤炭工业出版社, 2004.
F. X. Jiang, T. X. Wang, L. Y. Pan, et al. Mine Pressure and Ground Control [M]. Beijing: Coal Industry Publishing House, 2004. (in Chinese)
- [6] 桂兵, 张广文, 张士斌等. 冲击地压实时监测预警技术及其应用[J]. 煤炭科学技术, 2010, 38(8): 22-29.
B. Gui, G. W. Zhang, S. B. Zhang. Warning technology and its application of the impact pressure real-time monitoring and early [J]. Coal Science and Technology, 2010, 38(8): 22-29. (in Chinese)
- [7] 李铁, 王维, 谢俊文等. 基于采动顶、底板岩层损伤的冲击地压预测[J]. 岩石力学与工程学报, 2012, 31(12): 2438-2444.
T. Li, W. Wang, X. W. Xie, et al. Rockbursts prediction based on rock damage of roof and floor induced by mining [J]. Chinese Journal of Rock Mechanics and Engineering, 2012, 31(12): 2438-2444. (in Chinese)
- [8] 王应启, 马良, 游卫勇. 复杂地质条件下高冲击危险工作面冲击地压防治技术[J]. 煤炭工程, 2010, 8: 46-48.
Y. Q. Wang, L. Ma, W. Y. You. Strata bump prevention and control technology of coal mining face with high strata bump danger in potential under complicated geological condition [J]. Coal Engineering, 2010, 8: 46-48. (in Chinese)
- [9] 王存文, 姜福兴, 孙庆国等. 基于覆岩空间结构理论的冲击地压预测技术及应用[J]. 煤炭学报, 2009, 34(2): 150-155.
C. W. Wang, F. X. Jiang, Q. G. Sun, et al. The forecasting method of rock burst and the application based on overlying multi-strata spatial structure theory [J]. Journal of China Coal Society, 2009, 34(2): 150-155. (in Chinese)
- [10] V. Frid. Rockburst hazard forecast by electromagnetic radiation excited by rock fracture [J]. Rock Mechanics and Rock Engineering, 1997, 30(4): 229-236.
- [11] 杨凯, 陈建宏. 基于主成分分析与BP神经网络的冲击地压预测[J]. 广西大学学报(自然科学版), 2012, 37(5): 997-1003.

- K. Yang, J. H. Chen. Percussive ground pressure prediction based on principal component analysis and BP neural network[J]. Journal of Guangxi University (Natural Science Edition), 2012, 37(5): 997-1003. (in Chinese)
- [12] 陈刚, 潘一山. 基于异步迭代算法的冲击地压预测[J]. 岩土力学, 2004, 25(3): 446-450.
G. Chen, Y. S. Pan. Rockburst forecast based on asynchronous iterative algorithm[J]. Rock and Soil Mechanics, 2004, 25(3): 446-450. (in Chinese)
- [13] 郭德勇, 李念友, 裴大文等. 煤与瓦斯突出预测灰色理论-神经网络方法[J]. 北京科技大学学报, 2007, 29(4): 354-357.
D. Y. Guo, N. Y. Liu, D. W. Pei, et al. Prediction method of coal and gas outburst using the grey theory and neural network[J]. Journal of university of science and technology Beijing, 2007, 29(4): 354-357. (in Chinese)
- [14] 韩立. 人工神经网络教程[M]. 北京: 北京邮电大学出版社, 2006.
L. Han, A Course in Artificial Neural Networks[M]. Beijing: The Publishing House of Beijing University of Post & Telecommunication, 2006. (in Chinese)
- [15] 朱大奇, 史慧. 人工神经网络原理及应用[M]. 北京: 科学出版社, 2006.
D. Q. Zhu, H. Shi. Principles and Applications of Artificial Neural Networks [M]. Beijing: Science Press. 2006. (in Chinese)
- [16] 王涛, 王洋洋, 郭长娜等. 基于径向基的瓦斯涌出量灰色预测模型[J]. 计算机测量与控制, 2012, 20(5): 1218-1221.
T. Wang, Y. Y. Wang, C. N. Guo, et al. The grey prediction model based on radial basis gas emission [J]. Computer Measurement and Control, 2012, 20(5): 1218-1221.
- [17] 潘玉民, 邓永红, 张全柱等. 基于 QPSO-RBF 的瓦斯涌出量预测模型[J]. 中国安全科学学报, 2012, 22(12): 29-34.
Y. M. Pan, Y. H. Deng, Q. Z. Zhang, et al. Gas Emission Prediction Model Based on QPSO-RBF[J]. China Safety Science Journal, 2012, 22(12): 29-34. (in Chinese)
- [18] 张晓莹, 吴占超, 陈鹿民等. 基于 RBF 网络与自适应遗传算法的旋转机械故障诊断方法[J]. 煤矿机械, 2010, 31(1): 241-244.
X. Y. Zhang, Z. C. Wu, L. M. Chen, et al. Method of rotating machinery fault diagnosis based on RBF networks and adaptive genetic algorithms [J]. Coal Mine Machinery, 2010, 31(1): 241-244. (in Chinese)
- [19] K. Huang, L. Wang, J. Ma. Efficient training of RBF networks via the BYY automated model selection learning algorithms [J]. Lecture Notes in Computer Science, 2007, 4491: 1183-1192.
- [20] 王乐. 自适应 BYY 和谐学习与广义 RBF 网络的训练[D]. 北京: 北京大学数学科学学院硕士研究生学位论文, 2007.
L. Wang. Adaptive BYY Harmony Learning and Generalized RBF Network's Training[D]. Beijing: Master Thesis, School of Mathematical Sciences, Peking University, 2007. (in Chinese)
- [21] L. Wang, J. Ma. Efficient training of RBF networks via the kurtosis and skewness minimization learning algorithm [J]. Journal of Theoretical and Applied Information Technology, 2013, 48(1): 496-504.
- [22] 马尽文, 青慈阳. 对角型广义 RBF 神经网络与非线性时间序列预测[J]. 信号处理, 2013, 29(12): 1609-1614.
J. Ma, C. Y. Qing. Diagonal generalized RBF neural network and nonlinear time series prediction [J]. Journal of Signal Processing, 2013, 29(12): 1609-1614.
- [23] J. Ma, T. Wang, L. Xu. A gradient BYY harmony learning rule on Gaussian mixture with automated model selection[J]. Neurocomputing, 2004, 56: 481-487.
- [24] J. Ma, L. Wang. BYY harmony learning on finite mixture: adaptive gradient implementation and a floating RPCL mechanism[J]. Neural Processing Letters, 2006, 24(1): 19-40.
- [25] J. Ma, J. Liu. The BYY annealing learning algorithm for Gaussian mixture with automated model selection [J]. Pattern Recognition, 2007, 40: 2029-2037.

作者简介



李 焱 女, 1980 年生, 哈尔滨人。2008 年毕业于大连理工大学应用数学专业, 获理学硕士学位。现为黑龙江科技大学理学院副教授。2012.9-2013.6 在北京大学数学科学学院信息科学系进修。主要研究方向为人工智能, 模糊数学。
E-mail: gdsx06@yahoo.com.cn



马尽文 男, 1962 年生, 陕西人。1992 年毕业于南开大学数学系, 获理学博士学位。现为北京大学数学科学学院信息科学系主任、教授、博士生导师, 中国电子学会信号处理分会委员, 中国工业与应用数学学会理事, 主要从事智能信息处理、神经计算、模式识别、生物信息学等方面的研究。

E-mail: jwma@math.pku.edu.cn