

小波包神经网络预测方法在瓦斯涌出量中的应用

彭晓华¹, 刘利强²

(1 辽宁工程技术大学 基础教学部, 辽宁 葫芦岛 125105;

2 辽宁工程技术大学 电气与控制工程学院, 辽宁 葫芦岛 125105)

摘 要: 针对煤矿井下回采工作面瓦斯积聚和瓦斯超限等严重问题, 将小波包神经网络模型引入煤矿瓦斯涌出量预测中. 首先由改进小波包变化对采集数据进行分解、重构并提取特征向量, 然后输入到基于动态节点生成算法的 RBF 神经网络模型中训练学习, 同时采用删除策略简化该模型, 最后通过时频联合仿真验证. 结果表明, WP-RBF 模型在预测精度及训练误差方面明显优于 QPSO-RBF 模型, 是一种非常适合煤矿瓦斯量预测的有效方法.

关键词: 小波包神经网络; 删除策略; 特征值提取; 瓦斯涌出量

中图分类号: TP301.9

文献标识码: A

文章编号: 1000-7180(2016)03-0129-05

Wavelet Packet Neural Network Prediction Method Applied in the Gas Emission

PENG Xiao-hua¹, LIU Li-qiang²

(1 Ministry of Basic Education, Liaoning University of Engineering and Technology, Huludao 125105, China;

2 College of Electrical and Control Engineering, Liaoning University of
Engineering and Technology, Huludao 125105, China)

Abstract: According to serious problems such as gas accumulation and gas concentration exceeding limits on the working face underground coal mines, Introducing wavelet packet and neural network model in prediction of mine gas emission. First, The collected data decomposition, reconstruction and extracted feature vectors by wavelet packet transform, Then input to generation algorithm based on dynamic node RBF neural network model training and learning, While using the simplified model delete policy. Finally, By joint time-frequency simulation, The results show that WP-IRBF model is far superior to QPSO-RBF model in prediction accuracy and training error and is a very suitable for effective method for prediction of coal mine gas quantity.

Key words: wavelet packet and neural network; deletion policy; feature extraction; gas quantity

1 引言

我国煤矿是以地下开采为主, 地下瓦斯涌出远远高于露天瓦斯涌出, 所以说我国是瓦斯事故发生最为频繁和严重的国家, 解决煤矿瓦斯事故问题迫在眉睫, 正确预测瓦斯涌出量, 是预防瓦斯事故的重中之重.

文献[1]通过建立 BP 神经网络模型进行非线性应用, 达到了工程实际能够接受的预测精度, 待寻

优的参数少, 方法简便; 文献[2]用基于 RBF 神经网络进行瓦斯涌出量预测, 它的学习速度超过了 BP 神经网络, 具有更少的训练次数和较高的预测精度; 文献[3,4]使用小波变换加神经网络的语音去噪和瓦斯涌出量预测, 小波分析充分发挥了其时频局域化的优势; 文献[5,6,7]提出小波包分解算法在故障诊断领域中的应用, 小波包充分发挥了其分解频带的的能力; 文献[8,9]展示了基于算法融合的新耦合算法在瓦斯涌出量预测中的应用. 考虑到 RBF

神经网络强大的非线性映射能力和小波包变化精细的局部分解能力,将两种算法融合,构成小波包神经网络耦合算法.煤矿瓦斯涌出量具有复杂多变,无规律性,并且从瓦斯历史监测数据中往往表现出差异性和多元性,而这些因素特别适合训练高精度的RBF网络,小波包分析不仅可以区分噪声和有效信号,最重要的是它可以区分出有效信号中的低频信号和高频信号,而这种特性可以找到常规智能算法中容易被忽略的正常信号或故障信号,即瓦斯涌出量中的不正常涌出现象.

2 改进小波包变换

针对按二进制尺度变化的多分辨分析在低频段和高频段的缺陷,引入小波包变换,它能对尺度空间和小波空间同时进行分解,还可以对低、高频段进行分解,只要选择合适的分解层数便可得到所需的频带宽度及各频段起止频率.同时,考虑小波包分解层数与重构误差的关系,选择3层小波包分解.为了解决正常分解得到的频率顺序错乱问题^[10],对其进行算法改进,基本思路是:在进一步分解低频部分时,低频部分向左分解,高频部分向右分解;进一步分解高频部分时,低频部分向右分解,高频部分向左分解.得到改进小波包3层分解树结构如图1所示.




图1 改进小波包3层分解树结构

离散信号 $d(0,0)$ 下层 $J+1$ 的第 $2n$ 与 $2n+1$ 两个子频带的小波包分解算法为

$$\begin{cases} d_1(j+1,2n) = \sum_k a(k-2l)d_k(j,n) \\ d_l(j+1,2n+1) = \sum_k b(k-2l)d_k(j,n) \end{cases} \quad (1)$$

小波包重构算法为

$$d_l(j,n) = \sum_k [p(n-2k)d_1(j+1,2k) + q(n-2k)d_l(j+1,2k+1)] \quad (2)$$

式中, $a(k), b(k)$ 为分解共轭滤波器系数; $p(n), q(n)$ 为重构共轭滤波器系数.

由传感器输出的数据的频带特点,经过3层小

波包分解后,得到每种影响因子对应8个频率范围无重叠的最优小波包基,通过经分解、重构和特征向量提取,构成一组特征能量谱,从而更加有利于清晰地分析每一个影响影子在瓦斯涌出量预测中的作用.

3 RBF神经网络

3.1 基于动态节点构造RBF神经网络

动态节点生成构造RBF神经网络,是通过使用新生节点的输出逼近误差方向来获得隐层核函数的中心向量,基宽向量和网络输出层权值,使隐层节点在线训练中根据给定的学习要求动态生长.具体见图2.




图2 RBF神经网络残差分析示意图

由图2得到,在隐层节点数为 $j-1$ 时,记此时隐层输出向量 $G(j-1)$ 与RBF神经网络输出 $y(j-1)$ 在空间 R^N 中的夹角为 θ ,将 y 进行分解, y_1 是 y 在 G 上的投影, y_2 是残差矢量. 隐层节点从 $j-1$ 增加为 j 而产生的误差为 $e_j = y(j-1) - G(j)W(j)$, 隐层节点动态地增加,学习误差将会不断减少,隐层的中心向量、基宽向量和输出层的连接权值也会随着误差地减小不断地调整,直到 $e_j \leq \varepsilon$. 算法流程图见图3.




图3 动态节点构造RBF网络过程图

训练误差最小时,得到最终网络参数公式如下所示.

输出权值为

$$W_j(k+1) = W_j(k) - \eta_1 \frac{\partial E_j(k)}{\partial W_j(k)} \quad (3)$$

中心向量为

$$C_j(k+1) = C_j(k) - \eta_2 \frac{\partial E_j(k)}{\partial C_j(k)} \quad (4)$$

基宽向量为

$$\sigma_j(k+1) = \sigma_j(k) - \eta_3 \frac{\partial E_j(k)}{\partial \sigma_j(k)} \quad (5)$$

式中, η_1, η_2, η_3 为学习速率, 取值范围均为 $(0, 1)$ 。

3.2 RBF 神经网络删除策略

RBF 神经网络所选训练样本疏密程度及差异程度会直接影响到网络的泛化能力. 故引入删除策略.

删除策略是针对每个隐层节点对整个网络所作贡献大小而提出的, 对任意隐层节点 i , 用 A_i 来表示它对整个网络所做贡献, 即

$$A_i = \sum_{k=1}^N \left| \frac{w_i \varphi(\|x_k - c_i\|)}{y_k} \right| \quad (6)$$

$$A'_i = A_i / A_{\max} \quad (7)$$

互相关系数是衡量隐层节点输出相似性最为有效的办法^[11], 若神经网络隐含层中有两个或多个节点的输出表现出足够的相似性时, 可以对其进行压缩或删除. 其表达式为

$$\rho_{(h_i^{(m)}, h_j^{(m)})} = \frac{\text{cov}(h_i^{(m)}, h_j^{(m)})}{\sqrt{D(h_i^{(m)})} \cdot \sqrt{D(h_j^{(m)})}} \quad (8)$$

式中, $\rho_{(h_i^{(m)}, h_j^{(m)})}$ 为互相关系数, $\text{cov}(h_i^{(m)}, h_j^{(m)})$ 为协方差.

由式(15) 计算各隐层神经元输出的互相关系数, 若某两个神经元的互相关系数大于给定的互相关系数的阈值 L_ρ , 则删掉其中的一个隐层节点. 由经验值 $L_\rho = 0.75$. 而当两隐层神经元输出的互相关系数过大, 必然有一个对整个网络的贡献太小, 即贡献阈值 $\delta = 1 - L_\rho$. 故若 $A'_i < \delta = 0.25$, 需删除第 i 个隐层节点.

4 基于小波包神经网络瓦斯涌出量预测

考虑到内蒙古平庄能源股份有限公司六家煤矿为瓦斯矿井, 结合自然因素和开采因素, 采用主成分分析法确定某回采工作面影响瓦斯涌出量的主要影响因子, 并依次给出影响权重, 通过阈值剔除最终得到 8 个主控因子. 分别是: 煤层瓦斯含量、开采深度、煤层厚度、煤层倾角、煤层间距、日进度、日产量、工作面采出率等.

小波包神经网络瓦斯涌出量的预测步骤如下所示.

Step1: 初始化参数. 设置 RBF 网络训练样本数为 400, 最大训练次数为 2 500, 目标误差为 0.9, η_1, η_2, η_3 均为 0.001. 而 8 个影响因子采集值 $X = [X_1,$

$X_2, \dots, X_8]$ 对 X 进行标准化: $X = D^{-1}[X - E(x)]$, 其中 $E(x)$ 为 X 对应的均值, D 为标准差.

Step2: 为更准确地描述信号中幅度较小的瞬态现象以及能量的变化设置惩罚阈值. 由图 1 和式(1) 可得到从低到高的各个节点的分解系数向量 $x_{3i} = [x_{30}, x_{31}, x_{33}, x_{32}, x_{34}, x_{35}, x_{37}, x_{36}]$, 设置惩罚

阈值 $M_{3i} = \sqrt{\frac{1}{k} \sum_{i=1}^k x_{3ij}^2}$, 按

$$x_{3i\ k} = \begin{cases} 2x_{3i\ k} & (|x_{3ik}| \geq M_{3i}) \\ \frac{1}{2}x_{3ik} & (|x_{3i\ k}| \leq M_{3i}) \end{cases}$$

对 x_{3i} 中元素做如下调整得到 $x_{3i} = [x_{3i1} x_{3i2} \dots x_{3ik}]$.

Step3: 首先按 Step2 中各个节点分解系数按照式(2) 进行重构, 得到对应重构数据: $S_{3i} = [S_{30}, S_{31}, S_{33}, S_{32}, S_{34}, S_{35}, S_{37}, S_{36}]$, 然后得到各频带信号的总能量: $E_{3i} = \int |S_{3i}|^2 dt = \sum |S_{3i}|^2$, 最后对总能量

E_{3i} 归一化处理 $E_{3i} = E_{3i} / \sum_{i=0}^7 E_{3i}$, 构造特征向量: $T = [E_{30}, E_{31}, \dots, E_{37}]$, 作为 RBF 神经网络的输入.

Step4: 首先根据核函数获得样本输入输出, 输入 RBF 神经网络的各频带能量 T , 不断添加动态节点进行训练, 记录每次权值调整后的训练误差, 依次比较每个影响因子当前训练误差是否优于上一次训练结果, 如果是, 则将此影响因子占整个影响因子中的权值加 1, 否则减 1; 再计算模型输出 $Y_1(t)$ 与期望输出 $Y_2(t)$ 的差的平方和, 判断是否停止学习, 直到满足给定精度且算法终止条件时的 RBF 神经网络输出权值 $W_j(k+1)$, 中心向量 $C_j(k+1)$ 及此时对应隐层节点数 N , 并通过删除策略得最终隐层节点 N ; 最后通过 WP-RBF 模型对瓦斯测试样本进行测试.

5 实例分析

5.1 现场数据

取出第三节所选出的 2013 年 12 月某回采工作面 8 个主控因子及绝对瓦斯涌出量的统计数据作为预测模型训练样本集. 取各因素及绝对瓦斯涌出量 500 组, 其中前 450 组为训练样本, 后 50 组是预测样本.

根据小波包分解特征能量谱的向量长度和 RBF 神经网络参数训练, 在保证收敛性和各参数最优的情况下, 得到小波包神经网络的结构是: 8-5-1.

5.2 数据分析

由3层改进小波包分解的分解结果: $d(0,0) = d(3,0) d(3,1) d(3,3) d(3,2) d(3,4) d(3,5) d(3,7) d(3,6)$,其中 $d(3,0) d(3,1) d(3,3) d(3,2) d(3,4) d(3,5) d(3,7) d(3,6)$ 对应的频带范围分别是0~250 Hz,250~500 Hz,500~750 Hz,750~1 000 Hz,1 000~1 250 Hz,1 250~1 500 Hz,1 500~1 750 Hz,1 750~2 000 Hz.取采样频率4 000 Hz,分析频率2 000 Hz,通过MATLAB 仿真煤层瓦斯含量、煤层开采深度、煤层厚度、煤层倾角等影响因子对应小波包系数的频带^[12]如下:

- 煤层瓦斯含量: $d(3,1) d(3,3) d(3,2)$;
- 煤层开采深度: $d(3,1) d(3,3)$;
- 煤层厚度: $d(3,3) d(3,2)$;
- 煤层倾角: $d(3,3) d(3,2) d(3,4)$.

即煤层瓦斯含量频带主要集中在250~1 000 Hz处,煤层开采深度频带主要集中在250~700 Hz处,煤层厚度频带主要集中在500~1 000 Hz,煤层倾角频带主要集中在500~1 250 Hz处,其频带范围内的能量较大,范围之外较小.这种特征频带的数据处理过程挖掘了不同的数据成分,通过大幅度地滤除多余的噪声干扰等误差信号,提取出了瓦斯涌出量主要影响因子的分布特征数据,使WP-RBF(Wavelet packet RBF neural network)模型有更加快速的收敛速度和更加稳定的预测性能.

这些影响因子大小相异的能量数据都将依次作为8输入的RBF神经网络的输入值,在通过动态添加节点算法和删除策略来进行训练学习,最终确定网络结构和网络参数.图4所示为将小波分析的特征向量输入到RBF神经网络后,得到的学习误差曲线.

图4所示为样本数据经过大量数据分析,可以看出,小波包神经网络模型预测的学习误差要比直接神经网络模型预测小很多,这充分说明经过小波处理过后的特征数据完全可代表从传感器检测出来的数据成分,基于动态节点生成算法的RBF神经网络具有更快更精确的训练能力.而小波包神经网络预测模型经过训练学习达到收敛后,可得出样本输出、理想输出和WP-RBF模型输出比较图见图5,由图5可以说明基于小波包神经网络模型的瓦斯涌出量预测结果的跟随性和准确性.

为了验证WP-RBF模型具有较强的信号提取能力和局部逼近能力,取出测试样本中后4组绝对瓦斯涌出量数据,对比本文预测模型与文献[2]中




图4 小波包神经网络学习误差曲线




图5 瓦斯涌出量样本值、理想值与模型值对比图

预测模型后4组绝对瓦斯涌出量数据,得到输出结果如表1所示.其中迭代次数 $G=200$,学习速率:0.25,训练精度设置为:0.001,预测时间为:2.855 0 s.

表1 WP-IRBF模型与QPSO-RBF模型预测结果对照表

参数 \ 组		组			
		497	498	499	500
实际值/(m^3/min)		4.920 0	8.040 0	8.210 0	8.710 0
预测值/(m^3/min)	QPSO-RBF	5.344 3	7.854 2	7.914 9	9.028 4
	WP-RBF	4.937 5	8.034 6	8.200 3	8.721 9
预测误差/(m^3/min)	QPSO-RBF	-0.424 3	0.185 8	0.295 1	-0.318 4
	WP-RBF	-0.017 5	0.005 4	0.009 6	-0.011 9
预测精度/%	QPSO-RBF	-3.834 9	1.344 7	2.587 3	2.794 4
	WP-RBF	-0.682 0	0.546 6	0.784 1	-0.442 9

从表1可明显看出,WP-RBF模型的与预测能力、预测误差及预测精度均明显胜过QPSO-RBF模型,充分验证了本文方法的准确性和有效性.

6 结束语

通过融合小波包变换和RBF神经网络两种算法优势,并对算法本身做了部分改进,建立了WP-RBF预测模型.采用改进的小波包变换对影响瓦斯

涌出量的主控因素采集数据进行了精细的分析,以及有效信号的提取,并将其作为径向基神经网络的输入信号。同时,基于残差最小原理,运用动态节点生成法构造 RBF 神经网络的参数及隐层节点个数,并引入删除策略对隐层节点进行删除合并,这种全监督式学习算法,可使网络的输出和样本的输出之间的误差最小。最后,通过对比仿真验证,得到平均预测误差为 0.011 1,平均预测精度为 0.613 9,充分验证了 WP-RBF 预测方法具有较强的跟随性,逼近能力及准确性。

参考文献:

- [1] 郭伟,张栋,李巨韬,等.改进型 BP 神经网络对电容称重传感器的非线性校正[J].传感技术学报,2012,25(10):1354-1360.
- [2] 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.
- [3] 赵鸿图,刘云.改进粒子群算法的小波神经网络语音去噪[J].计算机测量与控制,2013,21(10):2799-2807.
- [4] Yu-Min PAN, Yong-Hong DENG, Quan-Zhu Zhang. Dynamic prediction of gas emission based on wavelet neural network toolbox [J]. Journal of Coal Science and Engineering, 2013, 2(7):10-14.
- [5] 徐涛,王祁.基于小波包神经网络的传感器故障诊断

方法[J].传感技术学报,2006,19(4):1060-1064.

- [6] 冷军发,荆双喜,陈东海,等.基于小波包与同态滤波的低速重载齿轮箱故障诊断研究[J].煤炭学报,2006,31(5):670-673.
- [7] Chih-Hao Chen, Rong-Juin Shyu, Chih-Kao Ma. Rotating machinery diagnosis using wavelet packets-fractal technology and neural networks[J]. Journal of Mechanical Science and Technology, 2007, 21(7):268-273.
- [8] 付华,谢森,徐耀松,等.基于 MPSO_WLS_SVM 的矿井瓦斯涌出量预测模型研究[J].中国安全科学学报,2013,23(5):56-60.
- [9] 付华,姜伟,单欣欣.基于耦合算法的煤矿瓦斯涌出量预测模型研究[J].煤炭学报,2012,37(4):654-658.
- [10] 李绍泉.近距离煤层群煤与瓦斯突出机理及预警研究[D].北京:中国矿业大学,2013.
- [11] 汪家道,孔宪梅,陈大融.节点自删除神经网络及其在磨粒识别中的应用[J].清华大学学报,1998,38(4):42-46.
- [12] 胡广书.数字信号处理理论、算法与实现[M].北京:清华大学出版社,2003.

作者简介:

彭晓华 女,(1963-),博士,教授,硕士生导师.研究方向为煤层瓦斯渗流理论研究、智能控制理论与应用研究.

刘利强(通讯作者) 男,(1988-),硕士研究生.研究方向为智能检测与故障诊断、煤矿瓦斯涌出量预测.

E-mail:2965131477@qq.com

(上接第 128 页)

作者简介:

彭广 男,(1989-),硕士研究生.研究方向为数字电路系

统级设计. E-mail: 15026679168@163.com.

李小进 男,(1978-),副教授.研究方向为集成电路设计与器件建模.