

一种基于小波包分解的神经网络识别 γ 能谱方法

史东生 弟宇鸣 周春林

(第二炮兵工程学院 102 教研室 西安 710025)

摘要 提出了一种基于小波包分解的神经网络识别 γ 能谱方法, 该方法将 γ 能谱看作非平稳离散信号, 对 γ 能谱做小波包分解得到各频带的能量, 以各频带能量为元素构造特征向量作为神经网络的训练样本, 利用神经网络的分类功能实现 γ 能谱的识别。结果表明, 该方法不仅能准确地识别不同种类标准源的 γ 能谱, 还能准确识别不同批次标准源的 γ 能谱, 具有很好的实用价值。

关键词 γ 能谱识别, 小波包分解, 神经网络

中图分类号 TP393, O150

神经网络方法作为一种无模型的系统识别方法, 具有适应性广、非线性映射能力强和推广能力强等优点, 将它应用于 γ 能谱分析具有非线性自动修正、充分利用全谱信息、减少统计误差、提高计算精度等优点^[1-3]。在用神经网络识别 γ 能谱过程中, 有用全谱的每道计数构成特征向量作为网络的训练样本^[1], 或对全谱进行合并再组成特征向量^[2], 或选取全谱的特征谱段组成特征向量^[3]。这些方法虽能充分利用全谱信息, 但网络训练样本的维数大(文献[1]2048 维, 文献[2]127 维, 文献[3]130 维), 所构建神经网络规模特别大, 训练速度慢, 且不易收敛, 故需要找出一种既能表征能谱特征又能有效减少特征向量维数的特征提取方法。

近年来提出的小波、小波包理论是非平稳信号分析的有效工具。小波包分解技术能把信号分解到不同层次不同频带的序列, 为非平稳信号的特征提取提供有效手段, 广泛应用于故障诊断、模式识别等领域^[4,5]。本工作把小波包分解理论引入到 γ 能谱识别中, 将 γ 能谱看作非平稳离散信号, 对 γ 能谱做小波包分解, 得到各频带的能量, 以各频带能量为元素构造特征向量作为神经网络的训练样本, 利用神经网络的分类功能实现 γ 能谱的识别。实例表明, 该方法不仅能准确地识别不同种类标准源的 γ 能谱, 还能准确识别不同批次标准源的 γ 能谱, 具有很好的实用价值。

1 基本理论

1.1 小波变换与小波包

对 $\forall \psi(t) \in L^2(\mathbb{R})$, 如果 $\psi(t)$ 的 Fourier 变换

$\hat{\psi}(\omega)$ 满足条件

$$C_{\psi} = \int_{-\infty}^{\infty} \frac{|\hat{\psi}(\omega)|^2}{\omega} d\omega < +\infty \quad (1)$$

则称 $\psi(t)$ 是基本小波或小波母函数, 其连续小波变换为

$$W_f(t) = \langle f, \psi_{a,b} \rangle = |a|^{-1/2} \int_{\mathbb{R}} f(t) \overline{\psi\left(\frac{t-b}{a}\right)} dt \quad (2)$$

其重构(逆变换)公式为

$$f(t) = \frac{1}{C_{\psi}} \int_{\mathbb{R}^+} \int_{\mathbb{R}} \frac{1}{a^2} W_f(a,b) \psi\left(\frac{t-b}{a}\right) da db \quad (3)$$

小波分解未对信号的高频部分进行再分解, 高频部分的频率分辨率无法提高。小波包能够弥补这一不足, 对信号在全部分析频带内进行精细的正交分解。在多尺度分析中, 尺度函数 ϕ 与小波函数 ψ 满足双尺度方程:

$$\begin{cases} \phi(t) = \sum_{k \in \mathbb{Z}} h_k \phi(2t-k) & \{h_k\}_{k \in \mathbb{Z}} \in l^2 \\ \psi(t) = \sum_{k \in \mathbb{Z}} g_k \phi(2t-k) & \{g_k\}_{k \in \mathbb{Z}} \in l^2 \end{cases} \quad (4)$$

记 $u_0(t) = \phi(t)$ 和 $u_1(t) = \psi(t)$, 并将双尺度方程改写成如下的递推形

$$\begin{cases} u_{2n}(t) = \sqrt{2} \sum_{k \in \mathbb{Z}} h(k) u_n(2t-k) \\ u_{2n-1}(t) = \sqrt{2} \sum_{k \in \mathbb{Z}} g(k) u_n(2t-k) \end{cases} \quad (5)$$

第一作者: 史东生, 男, 1978 年 12 月出生, 2004 年毕业于第二炮兵工程学院, 现为第二炮兵工程学院在读硕士研究生, 从事辐射防护及环境保护专业的研究

收稿日期: 初稿 2006-07-12, 修回 2007-01-11

由此定义函数系 $\{u_n\}_{n \in \mathbb{Z}_+}$, 称为由正交尺度函数 φ 确定的正交小波包。式(5)中, $g(k)=(-1)^k h(1-k)$, 即两系数满足正交关系。这就把多分辨分析中的正交小波分解推广到小波包分解, 得到信号的小波包表示为

$$g_j^n(t) = \sum_l d_l^{j,n} u_n(2^j t - l) \quad (6)$$

式中, $d_l^{j,n}$ 为分解所得的系数。

1.2 频带能量特征提取

小波包分解中, 增加分解层数, 使信号的高频成分和低频成分都达到很精细的分解程度。信号经 N 层小波包分解后, 可得到信号在某一频段内的特征信息, 即原信号的能量被分解到 2^N 个正交频带上, 信号在各频带上的能量总和与原信号的能量一致, 每个频带内的信号表征原信号在该频率范围内的特征信息。信号在各频带投影序列的能量 E_{Nj} 定义为

$$E_{Nj} = \int |S_{Nj}(t)|^2 dt = \sum_{k=1}^n |x_{jk}|^2 \quad (j=1, 2, \dots, 2^N) \quad (7)$$

式中, S_{Nj} 为小波包分解第 N 层从低频到高频 2^N 个频带成分的系数构成的特征信号; x_{jk} 为分解信号序列 S_{Nj} 第 k 个离散点幅值; n 为分解信号序列 S_{Nj} 的离散点的个数。

基于小波包分解的频带能量 E_{Nj} 反映了原信号在该频率范围内的能量大小, 频带能量特征提取步骤如下:

(1) 对实验测得的信号 S 进行 N 层小波包分解, 得到第 N 层从低频到高频 2^N 个频带成分的系数构成的特征信号 $S_{Nj}(j=1, 2, \dots, 2^N)$, 则总信号 S 可以表示为:

$$S = S_{N1} + S_{N2} + \dots + S_{Nj} \quad (8)$$

(2) 计算信号的频带能量 E_{Nj} 。

(3) 构造特征向量。对每一信号进行小波包分解, 计算各频带的能量, 得到一组与信号相对应的能量序列 $\{E_{Nj}\}(j=1, 2, \dots, 2^N)$, 可构造如下特征向量

$$T' = [E_{N1}, E_{N2}, \dots, E_{N2^N}] \quad (9)$$

能量较大时, $\{E_{Nj}\}(j=1, 2, \dots, 2^N)$ 通常较大, 不利于数据处理, 应对其作归一化处理。

令

$$E = (\sum_{j=1}^{2^N} |E_{Nj}|^2)^{1/2} \quad (10)$$

则

$$T = [E_{N1}/E, E_{N2}/E, \dots, E_{N2^N}/E] \quad (11)$$

向量 T 即为归一化后的特征向量。

2 小波包分解在神经网络识别 γ 能谱中的应用

2.1 γ 能谱识别总体思路

不同的辐射源具有各自的 γ 能谱, 可作为其“特征指纹”。如将 γ 能谱作为非平稳离散信号处理, 对 γ 能谱做小波包分解, 提取各频带的能量, 以各频带能量为元素构造的频带能量特征向量与 γ 能谱相对应, 频带能量特征向量可作为 γ 能谱的识别因子。据此, 我们形成了“频带能量特征向量— γ 能谱”的 γ 能谱识别方法, 将频带能量特征向量作为神经网络的训练样本, 利用神经网络的分类功能就可实现 γ 能谱的识别。

2.2 实例分析

2.2.1 不同种类标准源 γ 能谱的识别 采用 ^{133}Ba 、 ^{137}Cs 、 ^{152}Eu 等标准源的 γ 能谱为网络训练和识别样本, 测量仪器为便携式 γ 谱仪, 取 1024 道谱宽。源—探测器距离范围 0—60cm, 每 6cm 测量一次 (共 11 次/标准源), 测量时间 1000s。对 33 个样本谱进行本底消除处理, 分别用 db1 小波包进行 3 层小波包分解, 提取各自的频带能量特征向量, 分别编号为 $^1T_{\text{Ba}}, ^2T_{\text{Ba}}, \dots, ^{11}T_{\text{Ba}}; ^1T_{\text{Cs}}, ^2T_{\text{Cs}}, \dots, ^{11}T_{\text{Cs}}; ^1T_{\text{Eu}}, ^2T_{\text{Eu}}, \dots, ^{11}T_{\text{Eu}}$ 。选取奇数编号频带能量特征向量组成训练样本集, 偶数编号频带能量特征向量组成识别样本集。下面给出了 $^2T_{\text{Ba}}, ^2T_{\text{Cs}}, ^2T_{\text{Eu}}$ 的提取结果:

$$^2T_{\text{Ba}} = [0.8456 \quad 0.4296 \quad 0.2097 \quad 0.1827 \\ 0.0960 \quad 0.0888 \quad 0.0512 \quad 0.0587]$$

$$^2T_{\text{Cs}} = [0.9258 \quad 0.2348 \quad 0.0735 \quad 0.2520 \\ 0.0398 \quad 0.1135 \quad 0.0344 \quad 0.0570]$$

$$^2T_{\text{Eu}} = [0.9659 \quad 0.1899 \quad 0.1090 \quad 0.0664 \\ 0.0752 \quad 0.0551 \quad 0.0564 \quad 0.0532]$$

$^jT_{\text{Ba}}, ^jT_{\text{Cs}}, ^jT_{\text{Eu}}(j=1, 2, \dots, 11)$ 的输出分别设为 $[0 \ 0 \ 0]$ 、 $[0 \ 1 \ 0]$ 、 $[0 \ 0 \ 1]$ 。据此建立三层 BP (Back Propagation) 神经网络, 8 个输入神经元, 3 个输出神经元, 隐含层神经元数取为 5 个。

用矩阵实验室 (Matrix laboratory, MATLAB) 神经网络工具箱函数 $\text{net} = \text{newff}(\text{minmax}(P), [5, 3])$,

{'logsig','tansig'}, 'traingdm')生成网络, 其中 P 为训练样本组成的矩阵, 5 和 3 分别为网络中间层与输出层神经元个数, logsig、tansig 分别为中间层和输出层的传递函数, traingdm 为训练函数。设置训练参数为 net.trainParam. epochs=5000, net.trainParam.goal= 0.001。训练结束后, 运行时间 Elapsed time= 1.172672 s, 训练次数 epoch=4, 训练误差曲线见图 1。对识别样本集中的样本进行识别, 正确率为 100%。图 2 给出了利用全谱每道计数组成的向量作为网络输入参数的训练误差曲线, 此网络的中间层神经元个数为 55 个。训练结束后, 运行时间 elapsed-time=27.791132s, 训练次数 epoch=23, 对识别样本的识别正确率也为 100%。




Fig.1 Network error




Fig.2 Network error

2.2.2 不同批次标准源 γ 能谱的识别 采用不同批次的 ^{60}Co 标准源的 γ 能谱作为网络训练和识别样本, 分别记为 01 批、02 批、03 批。测量仪器和谱宽同上。源—探测器距为 10cm, 每批分别进行 30、50、100、200、400、600s 等 6 次测量, 三个批次共获得 18 个样本谱。消除本底后, 分别用 db1 小波包对各样本谱进行 5 层小波包分解, 提取各自的频带能量特征向量, 分别编号为 $^1T_{01}, ^2T_{01}, \dots, ^6T_{01}; ^1T_{02}, ^2T_{02}, \dots, ^6T_{02}; ^1T_{03}, ^2T_{03}, \dots, ^6T_{03}$ 。选取奇数编号频带能量特征向量组成训练样本集, 偶数编号频

带能量特征向量组成识别样本集。 $^jT_{01}, ^jT_{02}, ^jT_{03}(j=1, 2, \dots, 6)$ 均为 32 维向量, 它们的输出分别设为 $[0\ 0\ 0], [0\ 1\ 0], [0\ 0\ 1]$ 。据此建立三层 BP 神经网络, 32 个输入神经元, 3 个输出神经元, 隐含层神经元数取为 10 个。

使用前面的函数生成网络, 训练参数同上。训练结束后, 运行时间 Elapsed time=2.681033 s, 训练次数 epoch=8, 训练误差曲线见图 3。对识别样本集中的样本进行识别, 正确率为 100%。利用全谱每道计数组成的向量作为网络训练样本, 由于下降梯度小于默认的最小梯度, 未达误差目标, 也未达最大训练次数就训练结束, 运行时间 Elapsed time=21.453183s, 训练次数 epoch=1373, 网络不能收敛, 训练误差曲线见图 4。




Fig.3 Network error




Fig.4 Network error

2.2.3 结果分析 由上述标准源 γ 能谱的识别可见, 虽然用频带能量特征向量和全谱数据作为训练样本训练好的网络都具有很高的识别正确率, 但用小波包分解提取频带能量特征向量将 1024 维能谱数据降低为 8 维特征数据, 可有效提取了能谱特征, 也大大降低了神经网络的输入维数, 同时也减少了中间层神经元的个数, 故网络训练速度快, 收敛效果好。而采用全谱数据作为网络的训练样本, 网络训

训练速度慢,且极易陷入局部极小。图 2 训练误差曲线呈台阶状趋势,这除了与选取的学习算法有关外,还因为网络输入维数高、规模大。

在不同批次标准源 γ 能谱的识别中,使用频带能量特征向量作为训练样本进行训练,网络能够收敛且速度很快,训练好的网络具有很高的识别正确率;而使用全谱数据作为训练样本,网络不能收敛(见图 4),无法识别不同批次标准源 γ 能谱。这主要是因为, ^{60}Co 的半衰期很长,不同批次标准源的出厂时间间隔很短,能谱间的差异很小,仅利用全谱作为网络输入不能实现识别。而小波包分解将频带进行多层次的划分,对低频和高频部分进行进一步分解,为能谱提供一种更加精细的分析方法,能够提取能谱细微的特征,区分能谱细微的差异,所以实现了对不同批次标准源 γ 能谱的识别。

3 结论

基于小波包分解的神经网络识别 γ 能谱方法将 γ 能谱看作非平稳离散信号,对 γ 能谱做小波包分解得到各频带的能量,以各频带能量为元素构造特征向量作为神经网络的训练样本,有效提取了 γ 能谱特征,降低了神经网络的输入维数,提高了训练速度,能够对差异细微的 γ 能谱做出准确识别,是一种很好的 γ 能谱识别方法,具有很好的实用价值。

参考文献

- 1 白立新,张一云,徐家云,等.核电子学与探测技术,2003,23(5):404-406
BAI Lixin, ZHANG Yiyun, XU Jiayun, *et al.* Nucl Electron Detect Technol, 2003, 23(5): 404-406
- 2 陈泽民,李明涛,徐四大,等.核技术,1996,19(8):449-454
CHEN Zemin, LI Mingtao, XU Sida, *et al.* Nucl Tech, 1996, 19(8): 449-454
- 3 许伟.基于 BP 神经网络的核部件识别技术研究.第二炮兵工程学院硕士学位论文,2005,48-52
XU Wei. A Study of Nuclear Components Identification Based on BP Neural Network. The Second Artillery Engineering Institute, 2005, 48-52
- 4 王洪刚,郑海启,马吉胜,等.振动与冲击,2001,20(2):61-63
WANG Honggang, ZHENG Haiqi, MA Jisheng, *et al.* J Vibration Shock, 2001, 20(2): 61-63
- 5 杨选辉,沈萍,刘希强,等.地球物理学报,2005,48(1):148-156
YANG Xuanhui, SHEN Ping, LIU Xiqiang, *et al.* Chin J Geophys, 2005, 48(1): 148-156

γ -ray spectrum identification with neural network based on wavelet packet decomposition

SHI Dongsheng DI Yuming ZHOU Chunlin

(No.2 Artillery Engineering Institute, Xi'an 710025)

ABSTRACT A new method was developed to identify γ -ray spectra with neural network based on wavelet packet decomposition. γ -ray spectra are regarded as non-stationary discrete signals. By using wavelet packet decomposition of γ -ray spectra, characteristic vector of the energy over all frequency band is obtained and used as an input variable into neural network to identify γ -ray spectra results of applying the method to γ -ray sources shows that the method can identify accurately γ -ray spectra from standard sources of different species and batches.

KEYWORDS γ -ray spectrum identification, Wavelet packet decomposition, Neural network

CLC TP393, O150