

doi: 10.3969/j.issn.1006-1576.2012.02.022

## 小波神经网络在陀螺漂移预测中的应用

黄晓冬, 朱四华

(海军航空工程学院电子信息工程系, 山东 烟台 264001)

**摘要:** 针对传统预测方法存在的不足, 建立一种基于小波神经网络的陀螺漂移预测模型。重点研究利用小波分析理论对陀螺输出信号的漂移趋势识别提取方法, 结合小波神经网络建立漂移信号的非线性预测模型, 并以某陀螺实测信号为例预测其漂移趋势。结果表明: 该模型能降低人为因素影响, 提高漂移预报效果和导航系统精度。

**关键词:** 小波神经网络; 陀螺漂移; 预测模型; 导航精度

**中图分类号:** TP183 **文献标志码:** A

## Application of Wavelet Neural Network on Gyro Drift Prediction

Huang Xiaodong, Zhu Sihua

(Dept. of Electronic Information Engineering, Naval Aeronautical & Astronautical University, Yantai 264001, China)

**Abstract:** Aiming at the shortage of tradition prediction method, established a new prediction model of gyro drift based on wavelet neural network. This paper mainly studies recognition and abstraction method of gyro output signal's drift trend using wavelet analysis theory, set up the non-linear prediction model of drift signal combining the wavelet neural network, and predicts the drift trend taking certain gyro measured signal as example. Result shows that the model can reduce human factor influence, advance drift prediction effect and navigation system precision.

**Keywords:** wavelet neural network; gyro drift; prediction model; navigation precision

### 0 引言

陀螺数据经小波分析后, 所得到的随机漂移具有较强的非线性, 对于这种非线性系统的建模研究, 通常的处理方法是将非线性系统做一定的变换, 转化为线性系统, 或对某些特殊的非线性系统作特殊的处理。因此, 在实际的预测环境中模型常常失去效用, 同时, 对于大量的实际预测问题, 数据的采集通常是不精确的, 甚至可能是错误的, 而且只有当预测模型参数的选取随着预测环境的不同而变化, 才会得出较好的预测结果, 传统的预测方法很难解决这些问题, 而小波神经网络<sup>[1]</sup>(wavelet neural network, WNN)可以很好地解决这个问题。

小波神经网络是小波分析理论与神经网络理论相结合的产物。1992年 Qinghu Zhang 等正式提出小波神经网络的概念, 其思想是用小波元代替神经元, 即用已定位的小波函数代替 Sigmoid 函数作为启动函数, 通过仿射变换建立起小波变换与网络系数之间的连接, 可以避免 BP 神经网络等结构设计上的盲目性, 有更强的学习能力, 精度更高, 对同样的学习任务, 小波神经网络结构更简单, 收敛速度更快。因此, 笔者将小波神经网络的非线性预测算法与小波趋势提取算法结合, 建立一个基于小波

神经网络的陀螺漂移的预测模型。

### 1 小波神经网络的预测原理

如图 1, 小波神经网络包括输入层、隐含层和输出层, 输出层采用线性输出, 输入层有  $M(m=1,2,\dots,M)$  个神经元, 隐含层有  $K(k=1,2,\dots,K)$  个神经元, 输出层有  $N(n=1,2,\dots,N)$  个神经元。

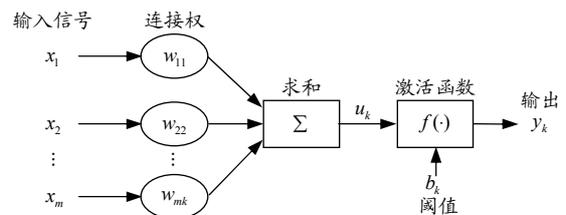


图 1 小波神经网络结构图

网络的输出方程可表示为:

$$y_i(t) = \sigma \left[ \sum_{k=1}^n W_{ij} \left( \sum_{k=1}^m x_k(t) \Psi \left( \frac{k-b_j}{a_j} \right) \right) \right], (i=1,2,\dots,n) \quad (1)$$

式 (1) 中:  $x_k(t)(k=1,2,\dots,m)$  为  $k$  第个输入变量;  $\hat{y}_i(t)(i=1,2,\dots,n)$  为第  $i$  个输出变量;  $n$  为隐层的单元数;  $\Psi \left( \frac{k-b_j}{a_j} \right)$  为由输入层第  $k$  个单元到隐层第  $j$  个单元的权函数;  $a_j, b_j$  分别表示小波函数的尺度因

收稿日期: 2011-09-01; 修回日期: 2011-10-04

基金项目: 国家自然科学基金“基于尺度的综合导航系统信息融合算法研究”(60874112); “泰山学者”建设工程专项经费资助

作者简介: 黄晓冬(1975—), 男, 四川人, 博士, 副教授, 从事仿真工程、智能算法研究。

子和平移因子;  $W_{ij}$  为隐层第  $i$  个单元到输出层第  $j$  个单元的连接权;  $\phi(\bullet)$  为非线性 Sigmoid 函数; 整个网络待训练的参数有  $W_{ij}$ 、 $a_j$ 、 $b_j$ 。网络中每层的神经元均使用 Morlet 小波基函数  $\Psi(x) = \cos(1.75x)e^{-x^2/2}$ ,  $\sigma(x) = 1/(1+e^{-x})$ 。

设训练样本集为  $X = [X_1, X_2, \dots, X_N]$ , 对应任一训练样本  $X_k = [X_{k1}, X_{k2}, \dots, X_{km}]^T, (k=1, 2, \dots, N)$  的期望输出为  $y$ , 实际输出为  $\hat{y}$ , 其中  $y$  满足  $y = f(\sum_{i=1}^J w_i f(\sum_{m=1}^M w_{mi} x_{km}))$ 。一般用误差平方来描述网络输出  $\hat{y}$  与期望输出  $y$  之间存在的差值  $e$ , 其表达式为

$$E(w) = \frac{1}{2}(y - \hat{y})^2 = \frac{1}{2}e^2 \quad (2)$$

由式 (2) 可知, 线性网络具有抛物面形的误差曲面, 因此只能有一个误差最小值。由于  $E(w)$  值取决于网络的权值和目标向量, 则可通过小波神经网络的非线性预测算法修改权值矩阵  $w$ , 减小  $e$ 。在逐个样本训练时, 为了避免引起权值和阈值修正时发生的振荡, 采用成批训练方法; 网络训练参数权值  $w$  采用权重贡献率分析法和关键神经节点法, 训练时, 在权值和阈值的修正算法中加入动量项, 利用前一步得到的修正值来平滑学习路径, 避免陷入局部极小值, 加速学习速度; 在学习过程中动态调整学习率  $\eta$  和惯性因子  $\alpha$ , 可实时动态控制网络的收敛速度和稳定性; 尺度因子  $a$  和平移因子  $b$  采用递推预报误差算法训练, 该算法具有优良的渐近性质。为了提高网络速度, 在训练过程中消除了无效迭代, 减少了计算量, 特别适合于处理复杂非线性系统<sup>[2]</sup>。对网络的输出也并不是简单的加权求和, 而是先对网络隐含层小波结点的输出加权求和, 再经 Sigmoid 函数变换后, 得到最终的神经网络输出, 有利于处理分类问题, 同时减少训练过程中发散的可能性。

## 2 实验验证

笔者采用国产中低精度的 ZD-100 光纤陀螺 (如图 2) 的实测数据进行分析处理, 该信号的采样周期为 2.5 ms, 采样时间为 1000 s, 选用 Daubechies4 小波进行分解观测其信号的变化, 依据随机漂移提取的方法, 通过逆序检验法判断各层的稳定性。经验证, 当  $k=1, 2, \dots, 10$  时  $\sum_{j=1}^{10} D_j f(t)$  均是平稳的, 直到

$k$  取 11 时  $\sum_{j=1}^{11} D_j f(t)$  不平稳, 则  $\sum_{j=1}^{10} D_j f(t)$  为该陀螺信号  $f(t)$  中的随机漂移, 因此对  $f(t)$  做 10 层分解, 如图 3~5 所示。

图 3 为陀螺信号 10 层分解后部分层的高频小波系数重构信号, 从图 3 中可以看到, 随着分解的深入, 信号的高频部分主要保留在第 1 层高频信号中, 之后迅速衰减, 到第 10 层时高频信号已经很微弱。图 4 为对应层的低频小波系数重构, 图 4 中第 1 层重构的信号类似于傅里叶变换滤波后的信号结果, 到第 5 层时仍然可见少量的短时抖动, 到第 10 层时, 重建的信号已完全看不到噪声及信号高频部分的影响, 从宏观上完整地显示了信号的主趋势。Db4 小波提取的主趋势  $A_{10}f(t)$  和随机漂移  $f(t) - A_{10}f(t)$  结果如图 5 所示。用 Coif2 小波识别漂移趋势结果如图 6 所示, 分别是  $A_{10}f(t)$  及随机漂移  $f(t) - A_{10}f(t)$ 。由上述漂移提取步骤可知, 提取到的陀螺漂移信号为平稳的时间序列, 将其作为神经网络的训练样本, 有利于神经网络的预测。



图 2 ZD-100 光纤陀螺

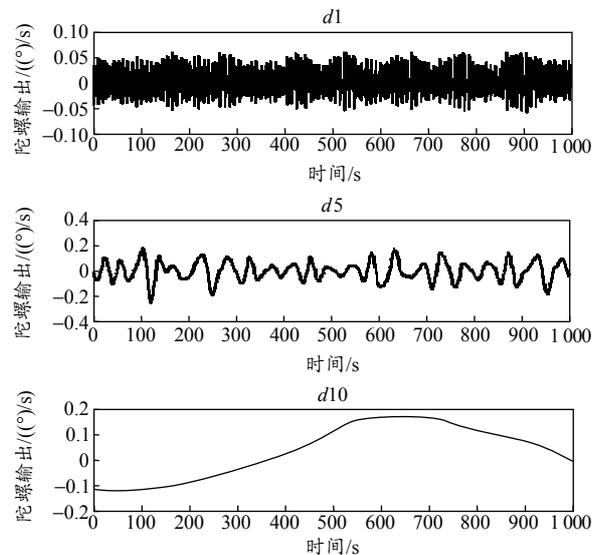


图 3 Db4 小波分解部分层的高频信号重构

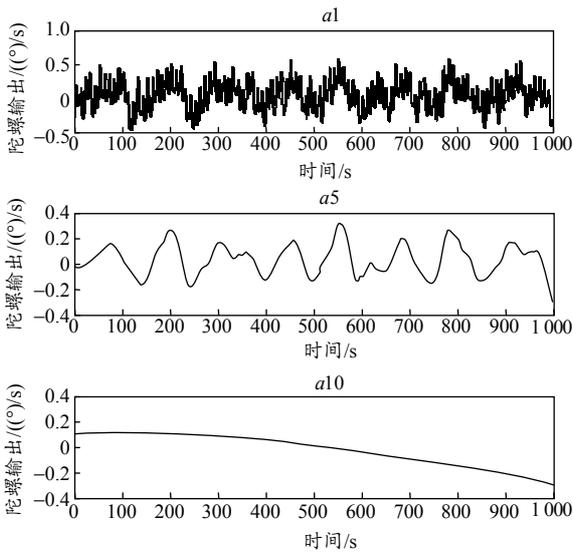


图 4 Db4 小波分解部分层的低频信号重构

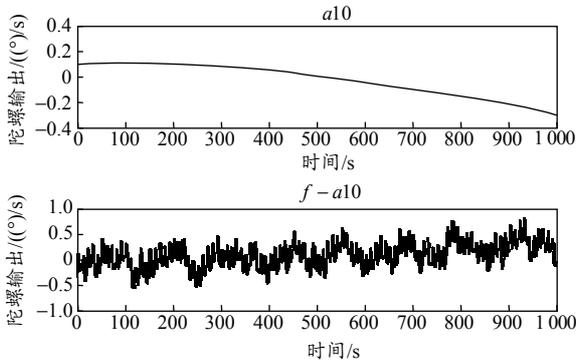


图 5 Db4 小波分解后的陀螺信号主趋势和随机漂移

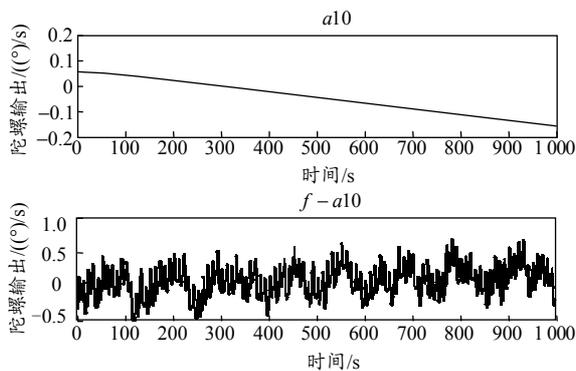


图 6 Coif2 小波分解后的陀螺信号主趋势和随机漂移

综上所述，应用小波分析为陀螺信号识别随机漂移步骤如下：

1) 选用适当的小波母函数对信号进行多尺度分解，母小波的选取由信号本身属性和分解结果而定，笔者采用的 Db4、Coif2 小波都能对文中处理的陀螺信号较好地识别出主趋势，提取出陀螺漂移。

2) 分解的层数一般要依据漂移提取算法决定，

经该算法检验后所提取到的随机漂移为平稳的时间序列，可在此基础上有效地对其建模和预测。一般当信号经 10 层以上分解后，最深层的低频重构信号已经能完整地显示信号的主趋势，所提取的随机漂移具有弱平稳性，所以可根据提取算法和建模的需要，选择适当的分解层数，可以有效地减少计算量。

将上文提取的陀螺随机漂移数据中选取连续的 100 个数据作为样本，采用相空间重构法<sup>[3]</sup>，每 9 个数据组成一个样本，将前 8 个值作为神经网络输入，以下一个时刻的数据为神经网络的输出信号，即  $P=[X(n-7), X(n-6), \dots, X(n)]$ ， $T=X(n+1)$ ，来进行对网络的训练。共形成 92 个样本，分成 2 组，前 82 个构成训练样本用于建模，后 10 个构成检验样本用于预测。根据节 1 提出的网络结构和算法策略，网络的精度选取为 0.000 1，考虑到隐含层节点数过多将增加网络运算的复杂性和运算时间，而节点数过少将限制网络的非线性建模精度，通过比较，最大神经元个数为 10，可以较好地实现漂移模型逼近，同时具备较快的运算速度，所得预测结果，如图 7、8 所示。

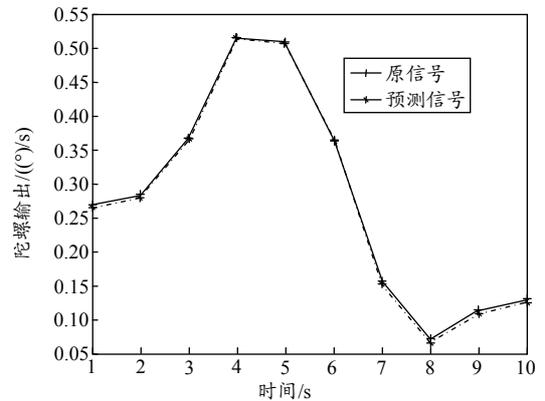


图 7 原始漂移与预测漂移结果对比

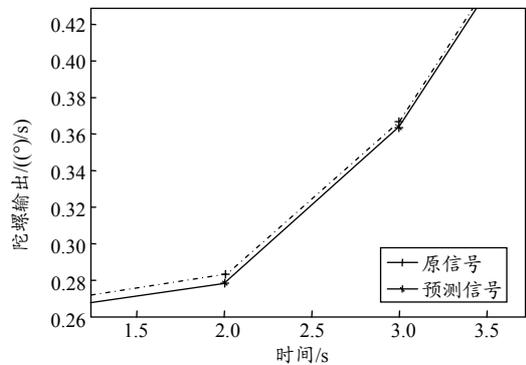


图 8 原始漂移与预测漂移结果对比细节