

# 基于 RBF-AR 的船舶变形极短期预报

高健钦, 彭侠夫

(厦门大学 航空航天学院, 福建 厦门 361100)

**摘要:** 统一空间基准是海上作战平台实现精准探测打击的重要保证, 而船体角变形的存在将严重影响空间基准的建立; 针对这一问题, 提出一种基于状态相依自回归 (state-dependent auto-regressive, SD-AR) 与径向基 (radial basis function, RBF) 神经网络的极短期变形预报方法, 实现船体角变形的实时预报, 为后续角变形的补偿提供依据; 不同于传统的时间序列预报方法, 该模型用一组 RBF 网络来逼近 SD-AR 模型中的函数系数, 并采用一种结构化的非线性参数优化方法 (structured nonlinear parameter optimization method, SNPOM) 辨识该模型; 基于该 RBF-AR 预报模型, 给出了船舶变形预报算法设计并进行了仿真实验; 实验结果表明, 该方法在船体变形预测精度上优于传统时间序列预测方法, 具有较好的应用前景。

**关键词:** 船体变形; 预报; 状态相依自回归模型 (SD-AR); 径向基神经网络 (RBF)

## Short-term Ship Deformation Prediction Based on RBF-AR

Gao Jianqin, Peng Xiafu

(School of Aerospace Engineering, Xiamen University, Xiamen 361100, China)

**Abstract:** The unified attitude reference is an important guarantee for the maritime combat platform to achieve accurate detection and strike. A prediction model combining state-dependent auto-regressive model with radial basis function neural networks is put forward for the problems that the existence of ship angular flexure makes it difficult to set up the unified attitude references. Unlike the current time series prediction methods, the model uses RBF neural networks to approximate the parameters of SD-AR model, and the parameters of RBF neural networks are estimated with a structured nonlinear parameter optimization method, providing a basis for angular deformation compensation. According to the RBF-AR model, a design of theoretical algorithm and a mathematical simulation are carried out. The simulation results show that the prediction method is better than common time series prediction methods. The prediction model possesses best potential application in the field of ship angular flexure.

**Keywords:** ship deformation; prediction model; state-dependent auto-regressive model; radial basis function neural network

## 0 引言

随着我国军事武器装备作战性能的不不断提升, 舰船在航行过程中产生的角形变已成为提升武器装备作战性能的瓶颈。大型舰船如导弹驱逐舰、航母等舰船并非刚体, 在运动过程中会产生角形变<sup>[1]</sup>。舰船角形变产生的主要原因有以下几点: 一方面是由于载荷变化使得重力分布产生变化引起的形变, 另一方面温度变化也会导致船体结构出现缓慢的变化, 此外舰船在航行过程中受到的海浪冲击、武器发射时产生的冲击等作用也会引起船体的形变<sup>[2]</sup>。船舶角形变可根据产生原因和数量级差异, 分为静态角形变和动态角形变。形变幅值高达  $1^{\circ} \sim 5^{\circ}$ , 且短时间内几乎不随时间变化, 为静态形变。形变幅值约为几十角秒, 随时间变化较快, 为动态形变。根据 Wei Wu<sup>[3-4]</sup> 的研究内容分别从伯努利-欧拉梁理论和先前实测数据特征分析证实动态角形变符合二阶马尔可夫分布。船体变形角的存在是制约大型舰船建立统一空间基准的根本原因, 直接影响舰载装备精度, 因

此对船舶变形进行极短期预报研究具有重要的意义。

船舶变形极短期预报是指利用船舶变形以及其他海况等的测量数据对船舶变形规律建立模型并预报未来五秒到十秒钟的变形角大小, 以便更好地提前做出控制策略<sup>[5]</sup>。关于对船舶运动及变形极短期预报的研究, 国外最早开始于 20 世纪 70 年代。最初, 极短期预报采用的方法计算繁杂, 难以实际开展。20 世纪 80 年代以后, 现代控制理论发展成熟, 在线实时预报与控制得以实现, 预报工作进入可行性研究阶段。目前, 基于不同的原理, 已相继提出了多种船体变形预报方法。船体变形预报方法大致可以分为试验方法和理论方法两个方面, 现阶段对舰船角形变的极短期预报方法主要是孙佳丽等采用基于有限元分析技术<sup>[6]</sup>或黄强等采用基于船体梁弹性变形的理论计算为主<sup>[7]</sup>。试验方法由于比较依赖形变模型及参数准确程度, 因此未得到广泛的应用。时间序列分析方法通常是按时间顺序排列的一系列被观测数据, 按固定时间间隔对观测数据进行采样。在用此方法作预测时, 常以过去的历史资料为依据, 寻找观测数据序列的规律, 预测将来的变化。由于舰船的变形具有很强的随机性和非线性, 使用传统时间序列分析的方法进行预报并不能获得理想的效果。

近些年来, 神经网络因其非线性映射、自学习、自适应等特点, 已经成为一种流行的系统建模和时间序列预测

收稿日期: 2019-11-26; 修回日期: 2020-01-07。

**作者简介:** 高健钦(1994-), 男, 江苏人, 硕士研究生, 主要从事惯性制导导航技术方向的研究。

彭侠夫(1963-), 男, 江西人, 博士生导师, 教授, 主要从事导航控制一体化方面的研究。

工具。RBF 神经网络作为一种高效的前馈式神经网络，具有独特优势。相较于 BP 神经网络，RBF 神经网络收敛速度更快，其最佳逼近性能也更便于得到全局最优解<sup>[6]</sup>。其中，RBF 神经网络由于其结构简单、非线性逼近精度优和学习速度快等特点得到了广泛青睐。在 20 世纪 90 年代，就先后有学者利用 RBF 网络来逼近 SD-AR 模型中的函数系数<sup>[9-10]</sup>。然而由于对模型参数准确性过分依赖，早期建立的 RBF 预测模型虽能达到预测大致趋势的效果，但因其模型具有较强的随机性，始终无法应用于工程项目之中。

目前，将 RBF 神经网络应用于船舶变形的相关研究较少。应用 RBF-AR 模型进行船舶变形极短期预报的难点在于模型参数的辨识，包括模型阶次、RBF 网络中心的选取以及线性权重等。甘敏等<sup>[11]</sup>提出了两种用于 RBF 神经网络参数估计的混合算法，其中 SNPOM 辨识方法收敛速度快，精度高，优于现有其他算法。本文使用径向基神经网络建立船舶变形模型并采用 SNPOM 辨识方法，克服了 RBF 网络预测随机性的问题，能有效减少训练时间并提高预报精度。并结合符合挠曲变形特征的仿真数据对提出方法的可行性与有效性进行了验证。

### 1 船体变形预报模型

针对船舶角变形的非线性特征，对于一个确定的时间序列  $\{y(t) \in \mathbf{R}^1, t = 1, \dots, N\}$ ，非线性时间序列建模主要任务是构建如下映射关系， $f: \mathbf{R}^p \rightarrow \mathbf{R}^1$ ，可表示为：

$$\begin{cases} y(t) = f(X(t-1)) + e(t) \\ X(t-1) = [y(t-1) \quad y(t-2) \quad \dots \quad y(t-p)] \end{cases} \quad (1)$$

式中， $y(t) \in \mathbf{R}$  为预测输出值， $f(\cdot)$  为非线性映射， $e(t)$  为高斯白噪声， $X(t-1)$  为  $t$  时刻的状态向量， $p$  为模型阶次。

式 (1) 为一般表达形式，不能直接应用。在实际控制中，通常采用状态相依自回归模型<sup>[12]</sup>，其结构特征如下：

$$y(t) = \varphi_0(X(t-1)) + \sum_{i=1}^p \varphi_i(X(t-1))y(t-i) + e(t) \quad (2)$$

式中， $\{\varphi_i(X(t-1)), i = 1, 2, \dots, p\}$  为状态相依函数系数。

RBF 网络可以任意精度逼近任何函数，因此可用于逼近模型 (2) 中系数。高斯 RBF 网络的结构如图 1 所示。

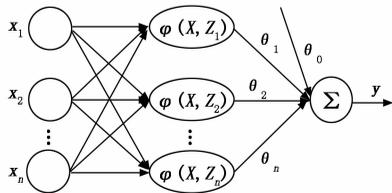


图 1 RBF 网络结构

根据图 1 所示结构，RBF 神经网络是前馈神经网络，输入向量和输出向量的函数关系通过非线性映射表现出来。其结构可分为三层，包括输入层、隐含层和输出层。第一层是输入层，由信号源节点组成。第二层为隐含层，其输出由输入矢量与径向基函数中心之间的距离确定，中心函

数一般选择高斯函数。第三层是输出层，表现为隐含层的输出到输出层的线性映射。

高斯 RBF 神经网络可以表示为：

$$y = \omega_0 + \sum_{k=1}^m \omega_k \exp(-\lambda_k \|X - Z_k\|) \quad (3)$$

式中， $\omega_0$  为偏置， $\{\omega_i, i = 0, 1, \dots, m\}$  为隐含层到输出层的权重， $m$  为隐含层节点数， $\lambda_k$  表示 RBF 网络的比例缩放因子， $X$  为输入向量， $Z$  为中心向量， $\|\cdot\|$  为欧几里得范数，表示向量的欧氏距离。

用式 (3) 所示 RBF 网络逼近式 (2) 中状态相依函数系数，得到 RBF-AR 模型结构如下：

$$\begin{cases} y(t) = \varphi_0(X(t-1)) + \sum_{i=1}^p \varphi_i(X(t-1))y(t-i) + e(t) \\ \varphi_i(X(t-1)) = \omega_{i0} + \sum_{k=1}^m \omega_{ik} \exp(-\lambda_k \|X(t-1) - Z_k\|^2) \\ Z_k = (z_{k1}, z_{k2}, \dots, z_{kd})^T \end{cases} \quad (4)$$

式中， $\{\omega_{ik}, i = 0, 1, \dots, p; k = 0, 1, \dots, m\}$  为线性权重， $d$  为模型的阶次。

由此可以看出，RBF 网络是 RBF-AR 模型的一个组成部分，因此 RBF-AR 模型更具普适性。一般情况下，式 (4) 中不同回归部分具有不同中心值，即使 RBF 网络中心相同，其回归多项式系数也可能不同。因此，在达到相同精度条件下，RBF-AR 模型可能拥有更少的中心值。为了简化计算，本文采用相同中心值与不同回归多项式系数。

### 2 变形预报模型参数辨识

由式 (4) 可得，对于给定的一组训练样本，RBF-AR 模型框架已基本确定，还需进一步考虑网络的径向基节点数  $m$ 、各径向基函数的中心  $Z$ 、宽度  $\|X - Z_k\|$  以及线性权重  $\omega_k$ 。模型阶数的确定一般使用 AIC (akaike information criterion, AIC) 定阶准则。因此问题的重点就在于其他参数的辨识。已知的非线性参数辨识方法有很多<sup>[13]</sup>，例如高斯-牛顿法 (gauss-newton method, GNM)、梯度下降法 (gradient descent method, GDM) 以及列文伯格-马夸尔特法 (Levenberg-Marquardt) 等，但是以上几种方法没有将线性参数与非线性参数进行分类，导致出现计算量大，模型参数精度不高等问题。本文采用一种结构化的非线性参数辨识方法 (SNPOM)。SNPOM 方法将需要辨识的参数空间划分为线性空间和非线性空间，使用最小二乘法 (least square method, LSM) 估计线性参数，使用 LMM 方法来优化非线性参数。SNPOM 参数估计方法相较于其他方法，收敛速度更快，精度更高。具体参数辨识过程如下。

#### 2.1 模型定阶

对于船舶角形变预测模型阶次的选择，采用高 AIC 准则进行定阶，AIC 值越大表示阶次更为合适，计算过程如下：

$$AIC = N \log \bar{\sigma}_e^2 + 2(s+1), N \geq p \quad (5)$$

式中， $\bar{\sigma}_e^2$  为模型残差的方差， $s$  为所要估计的参数总数，其中线性参数个数为  $(m+1)(p+1)$ ，非线性参数个数为  $(m+d)$ ， $p$  为回归部分最大阶数，因此  $s = (m+1)(p+1) + m + d$ 。

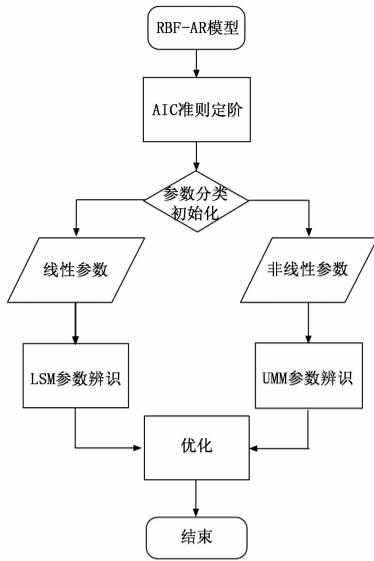


图 2 模型参数辨识流程

2.2 参数分类

RBF-AR 的模型 (4) 参数分为线性参数和非线性参数, 其中线性参数可表示为:

$$\theta_L = \{\omega_0, \omega_k \mid i = 0, 1, \dots, p; k = 0, 1, \dots, m\} \in R^{(m+1)(p+1)} \quad (6)$$

非线性参数主要是网络中心及宽度, 可表示为:

$$\theta_N = \{\lambda_k, Z_k \mid k = 0, 1, \dots, m\} \in R^{m+d} \quad (7)$$

将式 (4) 进行化简可得:

$$y(t) = f(\theta_L, \theta_N, X(t-1)) + e(t) \quad (8)$$

$$y(t) = \Psi(\theta_N, X(t-1))^T \theta_L + e(t) \quad (9)$$

2.3 参数初始化

首先对 RBF 神经网络中心初始值进行选择, 只需在向量空间  $X(t-1)$  中随机选择一个子空间  $Z_k (k = 1, 2, \dots, m)$ , 然后对高斯 RBF 网络宽度初始值进行计算:

$$\lambda_k = -\frac{\log \varepsilon_k}{\max\{\|X(t-1) - Z_k\|^2\}}, 0.0001 \leq \varepsilon_k \leq 0.1 \quad (10)$$

当非线性参数选定后, 线性参数  $\theta_L$  可用最小二乘法计算, 步骤如下:

$$\begin{cases} \theta_L = [\sum_{t=\tau+1}^M \bar{\Psi}_{r_0} \bar{\Psi}_{r_0}^T]^{-1} \sum_{t=\tau+1}^M \bar{\Psi}_{r_0} \bar{y}(t) \\ \bar{\Psi}_{r_0} = \Psi(\theta_N^0, \bar{X}(t-1)) \end{cases} \quad (11)$$

式中,  $\{\bar{y}(t), \bar{X}(t-1) \mid t = \tau+1, \tau+2, \dots, M\}$  为观测数据集,  $\tau$  为延迟时间。

2.4 优化过程

定义残差的平方和作为目标函数:

$$V(\theta_L, \theta_N) = \frac{1}{2} \|F(\theta_L, \theta_N)\|^2 \quad (12)$$

$$F(\theta_L, \theta_N) = \begin{bmatrix} f(\theta_L, \theta_N, \bar{X}(\tau)) - \bar{y}(\tau+1) \\ f(\theta_L, \theta_N, \bar{X}(\tau+1)) - \bar{y}(\tau+2) \\ \vdots \\ f(\theta_L, \theta_N, \bar{X}(M-1)) - \bar{y}(M) \end{bmatrix} \quad (13)$$

因此, 该优化问题可以转换为求:

$$(\hat{\theta}_L, \hat{\theta}_N) = \arg \min_{\theta_L, \theta_N} V(\theta_L, \theta_N) \quad (14)$$

根据式 (11) 可推得线性参数  $\theta_L$  和非线性参数  $\theta_N$  的更新公式为:

$$\begin{cases} \theta_L^{k+1} = [\sum_{t=\tau+1}^M \Phi(\theta_N^{k+1}, \bar{X}(t-1)) \Phi(\theta_N^{k+1}, \bar{X}(t-1))^T]^{-1} \cdot \\ \sum_{t=\tau+1}^M \Phi(\theta_N^{k+1}, \bar{X}(t-1)) \bar{Y} \\ \theta_N^{k+1} = \theta_N^k + \beta_k d_k \end{cases} \quad (15)$$

式中,  $k$  为迭代步数,  $\beta_k$  为搜索步长,  $d_k$  为搜索方向。 $d_k$  的值难以直接求解, 因此引入雅克比 (Jacobian) 矩阵, 形式如下:

$$J(\theta_N) = (\frac{\partial F(\theta_L, \theta_N)}{\partial \theta_N})^T \quad (16)$$

因此, 可通过下式求出  $d_k$  值:

$$[J(\theta_N^k)^T J(\theta_N^k) + \gamma_k I] d_k = -J(\theta_N^k)^T F(\theta_L^k, \theta_N^k) \quad (17)$$

式中,  $\gamma_k$  决定了  $d_k$  的幅度和方向, 如果下降太快, 使用较小的  $\gamma_k$ , 使之更接近高斯牛顿法; 如果下降太慢, 使用较大的  $\gamma_k$ , 使之更接近梯度下降法<sup>[14]</sup>。

参数优化过程, 就是线性参数和非线性参数按照式 (15) 更新的过程, 停止条件为  $V(\theta_L^{k+1}, \theta_N^{k+1}) < V(\theta_L^k, \theta_N^k)$ , 此时该判别式由最小值, 求得全局最优解。

3 仿真实验

为验证所提变形预报方法对船舶角形变序列的跟踪能力, 设置了一组仿真实验, 通过模拟产生符合角形变特征的仿真数据, 采用 RBF-AR 预报算法与传统 AR 预报模型进行计算并比较其跟踪能力。

船体甲板基准坐标系的坐标原点一般选定在艏艉线的中部, 舰载设备沿艏艉线呈纵向分布。船体坐标系定义为  $oxyz$ ,  $oy$  沿着船体的纵轴指向船艏,  $oz$  垂直于甲板平面向上方,  $ox$  指向船体右舷, 与  $oy, oz$  构成直角坐标系, 即右前上坐标系。定义  $ox$  方向的变形为纵挠角 (pitch),  $oy$  方向的变形为横扭角 (rolling),  $oz$  方向的变形为艏绕角 (heading)。

文中所建立的是极短期的预报模型, 因此静态角形变可以视为常数<sup>[15]</sup>, 采用的仿真数据为服从二阶马尔科夫过程分布的动态角形变与为常值的静态角形变叠加而成的总形变角序列。船体强度理论研究和实际实验表明, 对于有限时间间隔来说, 船体动态形变可视为平稳随机过程, 即数学期望和相关函数不变。因此, 动态形变角由以下公式仿真获得:

$$\bar{\theta}_i + 2\mu_i \bar{\theta}_i + b_i^2 \theta_i = 2b_i \sqrt{D_i \mu_i} w(t), i = x, y, z \quad (18)$$

其中,  $\mu_i$  为动态形变不规则系数,  $\lambda_i$  为支配频率,  $D_i$  为动态形变方差,  $w(t)$  是单位方差高斯白噪声,  $b_i^2 = \mu_i^2 + \lambda_i^2$ 。动态形变模型单位参数设置如表 1 所示。

根据表 1 参数的设置, 船体变形角仿真数据如图 3 所示。

表 1 动态角形变参数设置

	$\mu$	$\lambda$	$D$
船绕角	0.13	0.19	$1.6 \times 10^{-7}$
横扭角	0.1	0.18	$4.625 \times 10^{-7}$
纵绕角	0.1	0.18	$2.5 \times 10^{-7}$

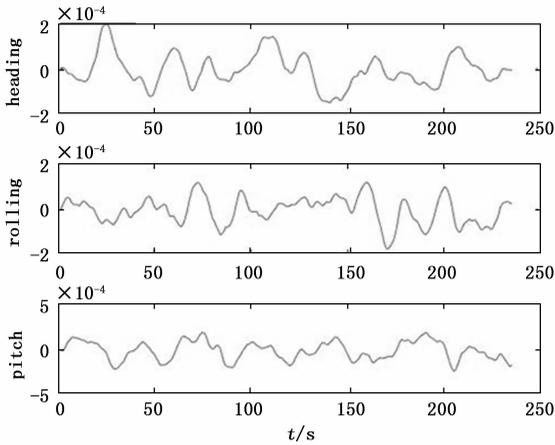


图 3 三轴的仿真变形角

图 3 所示为仿真环境中三轴角形变大小，从上至下分别为船绕角、横扭角、俯绕角，通过图片可以观察到，三轴的变形角曲线都具有一定的随机性。对数据进行截取，取 0~180 s 的船体变形角数据进行训练和辨识，180~235 s 的数据进行预报对比，通过对三轴角形变仿真数据的预报来验证 RBF-AR 模型的有效性。采用均方误差 (mean squared error, MSE) 来评价预测精度：

$$MSE = \frac{1}{N} \sum_{i=1}^N (x(i) - \hat{x}(i))^2 \quad (19)$$

为公平比较及说明 RBF-AR 模型的预测精度，分别采用两种船体变形极短期预报方法，在同一组变形仿真数据上测试两种预报方法的性能。图 4~图 9 分别为船体变形船绕角、横扭角、纵绕角两种方法的变形预报曲线，从图中可以看出两种方法都能够大致跟随船体角形变的变化趋势。从图 4 与图 5，图 6 与图 7，图 8 与图 9 的预报结果比较可以看出改进的算法提高了预报精度，大大减小了变形幅值预报误差。由此可得，RBF-AR 模型具有较强的跟踪能力，能够

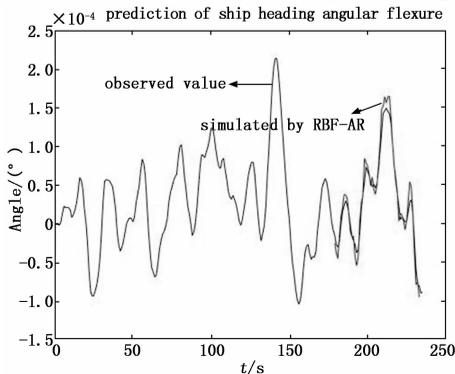


图 4 船绕角 RBF-AR 预报结果

有效、准确地对船舶角形变进行预报。与此同时我们也能通过图 4、图 6、图 8 的预报曲线观察到，对于船舶变形预报序列而言，同阶的非线性自回归模型比线性回归模型有更高的精度，但在最大幅值处的预测仍存在一定误差。

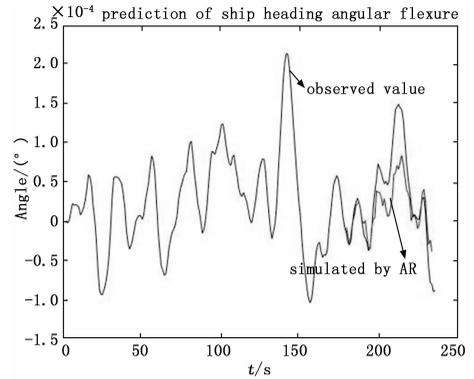


图 5 船绕角 AR 预报结果

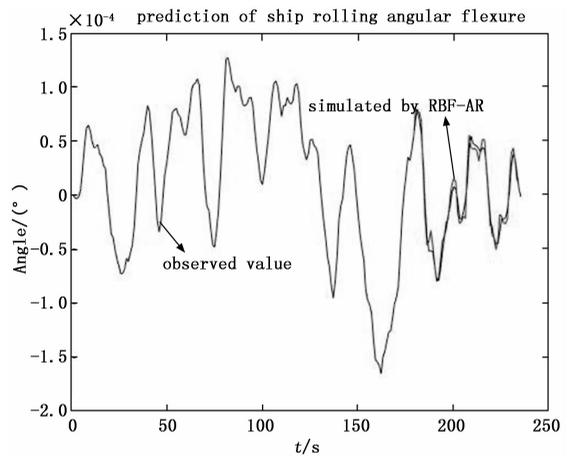


图 6 横扭角 RBF-AR 预报结果

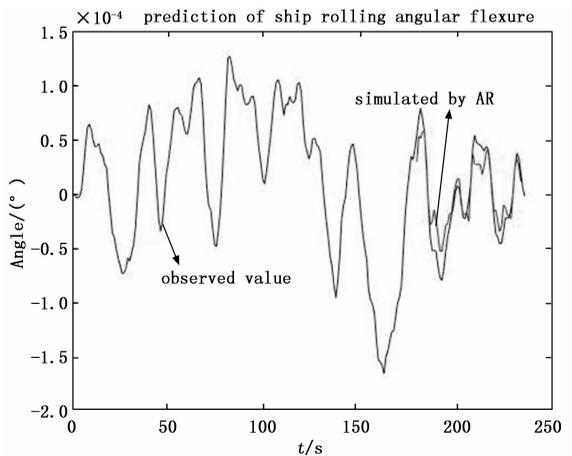


图 7 横扭角 AR 预报结果

表 2 预报性能指标

(MSE × 10 <sup>-4</sup> )	Heading	Rolling	Pitch
AR	13.1	9.6	8.1
RBF-AR	3.1	2.6	1.4

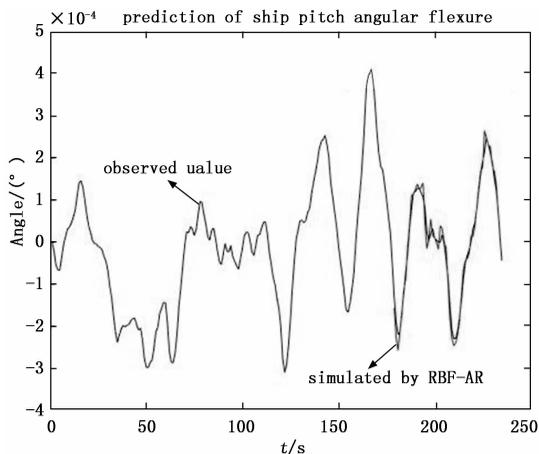


图 8 纵挠角 RBF-AR 预报结果

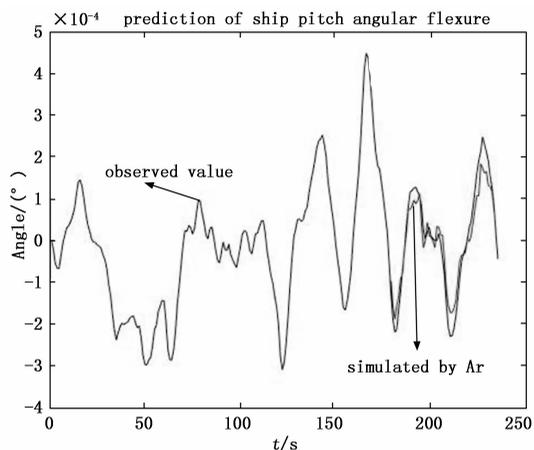


图 9 纵挠角 AR 预报结果

通过表 2 给出了两种预报方法的均方误差 (MSE), 通过对比两种预报方法的均方误差值也可以验证改进算法对于预报效果的提升。

综上所述, 文中提出的 RBF 极短期船舶变形角预报算法是有效的, 能取得比较好的效果。

#### 4 小结

本文针对传统 AR 模型难以预测船体角形变的问题, 在 AR 预报模型的基础上提出了一种用一组 RBF 神经网络逼近 AR-SD 模型参数的预报模型, 从而可在全局范围内搜索最优解。算法分析与实验结果表明: 传统的时间序列预测方法无法实现对变形角的跟踪, 预测模型误差较大。RBF-AR 模型相较于传统的时间序列模型具有跟踪效果好、计算过程少的优点, 对预报过程中船体变形随机性、非线性的问题, 具有较好的预报效果。在 Matlab 中使用自带函数拟合模型时, 模型存在较强的随机性。而使用结构化的非线性参数优化方法 (SNPOM), 不仅有效的解决了线性参数与非线性参数互相混杂、难以辨识的问题, 而且也使模型具有确定的参数。

#### 5 结束语

对船体角形变进行精准预报, 实现全舰统一姿态基准

是舰载武器装备系统协同工作的重要前提。RBF-AR 模型在船体角形变预报任务中具有非常好的应用前景。在实际应用中可以节省大量的计算量和时间成本, 极大地提升预报效果, 对建立全舰统一姿态基准提供巨大帮助。在未来的工作中, 会将算法结合实测数据已经半物理仿真平台中进行试验, 提升算法的适用性, 对船体变形精确预报, 推动实现各站点姿态基准的精确引射和统一。

#### 参考文献:

- [1] 袁二凯, 杨功流, 于沛, 等. 一种基于惯性匹配的船体姿态基准传递方法 [J]. 舰船科学技术, 2013, 35 (12): 60-64.
- [2] 郑佳兴, 秦石乔, 王省书, 等. 基于姿态匹配的传体形变测量方法 [J]. 中国惯性技术学报, 2013, 35 (12): 60-64. . 2010, 18 (2): 175-180.
- [3] Wu W, Qin S Q, Chen S. Coupling influence of ship dynamic flexure on high accuracy transfer alignment [A]. Position, Location and Navigation Symposium [C]. 2014, IEEE /ION.
- [4] Wu W, Qin S Q, Wang X S, et al. A new integrated Gaussian-Markov process model for precision shipboard transfer alignment [J] Identification and Control, 2014, 19 (3): 224-234.
- [5] Wei W, Sheng C, Qin S Q. Determination of dynamic flexure model parameters for ship angular deformation measurement [A]. Control, 2012. UKACC International Conference of the IEEE [C]. 2012.
- [6] 孙佳丽. 舰船结构变形预报与统计分析 [D]. 哈尔滨: 哈尔滨工程大学, 2013.
- [7] 黄强, 李辉, 吴兆年, 等. 基于船体梁的船体弹性变形预报方法 [J]. 船舶工程, 2017, 39 (8): 13-17.
- [8] 王旭东, 邵惠鹤. RBF 神经网络理论及其在控制中的应用 [J]. 信息与控制, 1997 (4): 32-44.
- [9] Shi Y, Tamura Y, Ozaki T. Nonlinear time series modeling with the radial basis function-based state-dependent autoregressive model [J]. International Journal of System Science, 1999, 30 (7) 717-727.
- [10] Vesin J. An amplitude-dependent autoregressive signal model based on a radial basis function expansion [A]. Proc. Int. Conf. Acoustics, Speech, Signal Processing [C]. 1993, 3: 129-132.
- [11] 甘敏, 彭晓燕, 彭辉. RBF 神经网络参数估计的两种混合优化算法 [J]. 控制与决策, 2009, 34 (8): 1172-1176.
- [12] 徐文权, 胡慧, 卓张华, 等. RBF-AR 模型在三峡水电站上网日电量预测中的应用 [J]. 河海大学学报 (自然科学版), 2018, 46 (3): 275-282.
- [13] Xi Y H, Peng H, Mo H. Parameter estimation of RBF-AR model based on the EM-EKF Algorithm [J]. ACTA Automatica Sinica, 2017, 43 (9): 1636-1643.
- [14] Zhu X T, Xu B. Urban water consumption forecast based on QPSO-RBF neural network [A]. Computational Intelligence and Security (CIS), Eighth International Conference of the IEEE [C]. 2012.
- [15] 郑佳兴, 秦石乔, 王省书, 等. 考虑准静态变量的船体角形变测量 [J]. 中国惯性技术学报, 2011, 19 (1): 6-10.