

基于小波分析的导弹装备备件需求组合预测

赵建忠,徐廷学,李海军,叶文

(海军航空工程学院 兵器科学与技术系,山东烟台 264001)

摘要: 针对导弹装备备件需求呈现非线性、非平稳的特征,提出了把小波分析理论应用于导弹装备备件需求预测的构想.首先根据总体评价指标来确定小波最佳分解级数,将备件需求时间序列分解到不同尺度上以减少原始序列的随机性和波动性;然后对具有平稳特性的高频信息用改进动态自适应隔代映射遗传算法和阻尼最小二乘法优化的 ARMA 模型进行预测,而对反映整体趋势的低频信息用 GM(1,1)模型进行预测;再将各模型的预测结果进行叠加,从而得到原始序列的预测值.最后通过导弹装备备件需求的实例,验证了本方法的有效性和可行性.

关键词: 备件;需求预测;小波分析;灰色模型;自回归移动平均模型

中图分类号: TP391.9 **文献标识码:** A **文章编号:** 0372-2112 (2014)03-0417-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2014.03.001

Combination Forecasting of Missile Equipment Spare Parts Demand Based on Wavelet Analysis

ZHAO Jian-zhong, XU Ting-xue, LI Hai-jun, YE Wen

(Department of Ordnance Science and Technology, Naval Aeronautical and Astronautical University, Yantai, Shandong 264001, China)

Abstract: Due to the non-stability and non-linearity characteristic of missile equipment spare parts demand, the thought of wavelet analysis theory used on missile equipment spare parts demand forecasting. The best grading of its decomposition of wavelet was determined in terms of the collective evaluation index, and spare parts demand time series were decomposed into different scales in order to reduce the randomness and volatility of original time series; The high frequency signals were forecasted with ARMA model optimized by the improved self-adaptive intergeneration projection genetic algorithm and damping least-squares method, and the low frequency was forecasted with GM(1,1) model; the respective forecast result were integrated to get the forecast value of the original time series. Through an experiment of missile equipment spare parts demand, the feasibility and effectiveness of this method was proven.

Key words: spare parts; demand forecasting; wavelet analysis; grey model; ARMA (Auto-Regressive Moving Average) model

1 引言

备件是导弹装备使用和维修等保障任务的重要物质基础,准确预测备件需求才能在有限的经费情况下,最大限度地满足导弹装备保障的备件需求.导弹装备备件需求受多种复杂因素的影响,其需求规律大都呈现非线性、非平稳特征.小波分析是近年来兴起的一种新的信号分析处理技术,具有多分辨率分析的特点,是处理非平稳随机时间序列的一种有效方法^[1].本文提出一种基于小波分析的导弹装备备件需求组合预测方法.首先利用小波多尺度分解和重构思想,将非平稳的备件需求时间序列通过小波分解成不同尺度下的趋势信号和细节信号;然后对趋势信号构建灰色模型进行拟合,对各层细节信号采用与之相匹配的 ARMA (Auto-Regressive Mov-

ing Average)模型进行拟合;再将各模型的预测值进行叠加,从而得到原始时间序列的预测值.这在充分拟合低频信息的同时,又避免对高频信息的过拟合,从而提高了非平稳时间序列的预测精度,为导弹装备备件需求预测提供了一种新的方法.

2 小波分解与重构

本文通过综合考虑信号的均方差变化量、互相关系数、信噪比及平滑度 4 个评价指标来确定最佳分解级数.小波 M 级分解与重构的信号均方根差为

$$\text{RMS}(M) = \sqrt{\left[\sum_{i=1}^n (x(i) - \hat{x}_M(i))^2 \right] / n} \quad (1)$$

式中, $\hat{x}_M(i)$ 为 M 级分解重构信号; $x(i)$ 为原始信号; n 为信号长度.

相邻两级的信号均方根差变化量为

$$v(M) = \text{RMS}(M+1) - \text{RMS}(M) \quad (2)$$

$v(M)$ 反映了相邻两级分解与重构数据信号的相似程度,评价准则为均方根差变化量越接近0越好.

互相关系数为

$$\rho(M) = \text{cov}(\hat{x}_M(i), x(i)) / (\sigma_x \cdot \sigma_{\hat{x}_M}) \quad (3)$$

式中, σ_x 、 $\sigma_{\hat{x}_M}$ 分别为原始信号和 M 级分解重构信号的方差.评价准则为互相关系数越接近1越好.

信噪比为

$$\text{SNR}(M) = 10 \lg \left(\frac{\sum_{i=1}^N (x(i))^2}{\sum_{i=1}^N (x(i) - \hat{x}_M(i))^2} \right) \quad (4)$$

式中, N 为信号个数.信噪比为数据信号的能量与噪声能量之比,评价准则为信噪比越大越好.

平滑度为

$$r(M) = \frac{\sum_{i=1}^{N-1} (\hat{x}_M(i+1) - \hat{x}_M(i))^2}{\sum_{i=1}^{N-1} (x(i+1) - x(i))^2} \quad (5)$$

该项指标可以反映重构后信号的平滑程度,评价准则为平滑度越小则异常数据处理效果越好.

把信号均方根差变化量、互相关系数、信噪比、平滑度分别进行归一化处理,公式为

$$P_v(M) = [v_{\max} - v(M)] / (v_{\max} - v_{\min}) \quad (6)$$

$$P_\rho(M) = [\rho(M) - \rho_{\min}] / (\rho_{\max} - \rho_{\min}) \quad (7)$$

$$P_{\text{SNR}}(M) = [\text{SNR}(M) - \text{SNR}_{\min}] / (\text{SNR}_{\max} - \text{SNR}_{\min}) \quad (8)$$

$$P_r(M) = [r_{\max} - r(M)] / (r_{\max} - r_{\min}) \quad (9)$$

将各评价指标归一化值相加得到总体评价指标:

$$H(M) = P_v(M) + P_\rho(M) + P_{\text{SNR}}(M) + P_r(M) \quad (10)$$

归一化后的分指标值越大对应各分指标效果越好,所以总体评价指标 $H(M)$ 越大则去噪效果越好, $H(M)$ 最大值所对应的级数 M 即为最佳级数.可以看出,本文提出的新方法既包含了更多的评价指标,又能定量确定最佳级数,相对已有方法更加合理和严密.

3 ARMA 模型的改进

3.1 改进动态自适应隔代映射遗传算法

本文在隔代映射遗传算法(Intergeneration Projection Genetic Algorithm, IP_GA)^[2]基础上,通过引入自适应策略,自行调整个体的适应度,有效避免了早熟问题,提高了收敛速度与解的质量.改进 IP_GA 流程如图 1 所示.

适时利用 GA 搜索过程中获得的信息调整个体的适应度,可以引导 GA 搜索朝着更接近全局最优解方向

演化.假设已经知道 GA 到当前代进化中所发现的最佳个体是 $X^*(t)$,则在下一代的进化中采用适应度度量则可起到压制不优于已发现的 $X^*(t)$ 的个体重复复制的效果;取时变的适应度量 $J_t(X) = \exp(\alpha(t)f(X))$,则可起到在 GA 前期压制特别占优个体过度繁殖,保持种群多样性,而在后期强化局部搜索保证收敛性的效果.当处理约束优化问题 $\max_{X \in \Omega} f(X)$ 时,假设 $\Omega = \{X \in R^n | g_i(X) = 0, i = 1, 2, \dots, K\}$,常用罚函数方法将约束问题化归到一个无约束问题求解^[3],即通过求解

$$\max_{X \in \Omega} f_\alpha(X) = f(X) + \sum_{i=1}^K \alpha_i g_i^2(X),$$

来达到求解 $\max_{X \in \Omega} f(X)$ 的目的,这里 $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_k)$ 是一组非常大的正参数.

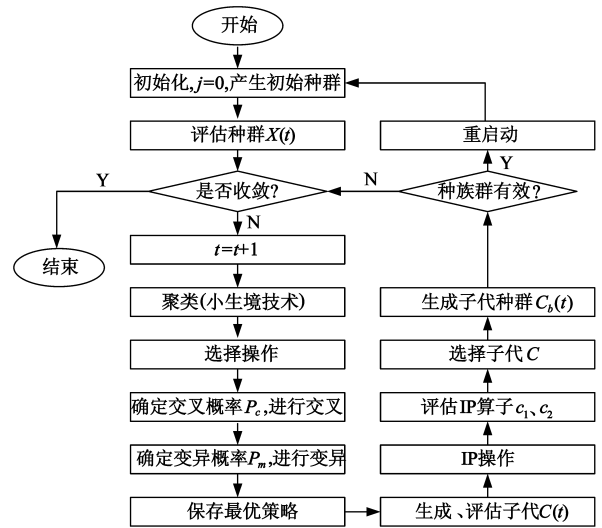


图1 改进IP_GA算法流程图

3.2 基于改进 IP-GA 和阻尼最小二乘法优化的自回归移动平均模型 ARMA

ARMA 模型是有限参数线性模型,适用于平稳随机序列,现已广泛用于时间序列分析、信号处理和状态估计等领域. ARMA(p, q)模型形式如下:

$$x_t = \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \dots + \varphi_p x_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (11)$$

式中, x_t 为时间数据序列; p, q 为模型阶数; $\varphi_1, \varphi_2, \dots, \varphi_p$ 为自回归系数; $\theta_1, \theta_2, \dots, \theta_q$ 为移动平均系数; $\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}$ 为残差序列(白噪声序列).

(1) 模型阶数的确定

由于 ARMA 模型的定阶过程存在一定的随机性和不确定性,本文结合赤池信息(Akaike Info Criterion, AIC)准则^[4],采用改进 IP_GA 对 ARIMA 模型阶数进行优化,以期提高 ARIMA 模型的预测精度.具体优化过程如下:首先设定迭代次数、初始种群及数据长度等基本

信息.综合考虑实时性、有效性等各种要求,本文设定的迭代次数为 100 代,初始种群数量为 40 组,每组数据长度为 6 位二进制数,即前 3 位代表自回归阶数 p ,后 3 位代表移动平均阶数 q .将随机生成的初始种群进行解码,即可得到 40 组自回归阶数和移动平均阶数的十进制数组合:

$$(b_0 b_1 \cdots b_n)_2 = \left(\sum_{i=0}^n b_i 2^i \right)_{10}$$

进而确定 ARMA 模型的具体阶数,并通过 `armax` 函数进行参数估计^[5],分别计算得到此次迭代循环下每组阶数组合的预测结果.

在用改进动态自适应 IP_GA 计算 ARMA 模型阶数时,如果预测值与实测值相差越少,说明预测参数越接近参数真值.通常衡量预测值与实测值差别的变量采用平均相对变动值 (Average Relative Variance, ARV)^[6],其定义为:

$$V_{AR} = \frac{\sum_{i=1}^N [\hat{x}_i - x_i]^2}{\sum_{i=1}^N [\hat{x}_i - \bar{x}]^2} \quad (12)$$

式中, N 表示比较数据个数; x_i 为实测数据值; \bar{x} 为实测数据平均值; \hat{x}_i 为预测值.

显然,平均相对变动值 V_{AR} 越小,表明选定参数越好, $V_{AR} = 0$ 表示达到了理想预测效果,当 $V_{AR} = 1$ 时,表明模型仅达到平均值的预测效果.根据适应度值越大越利于遗传到下一代的特性,可以构造如下适应度函数:

$$f(x) = \frac{1}{V_{AR}} \quad (13)$$

利用适应度函数得出适应度函数值最大的个体,然后对父代种群进行复制、交叉和变异等遗传算子运算,从而繁殖出下一代新种群中的其他 $N - 1$ 个基因串.本文采用联赛法^[7]作为复制方法,交叉和变异是产生新个体的遗传算子:交叉率太大,将使高适应度的基因串结构很快被破坏掉,交叉率太小则使搜索停止不前,一般取为 0.5 ~ 0.9 (本文取交叉率为 0.6); 变异率太大,将使遗传算法变为随机搜索,太小则不会产生新个体,一般取为 0.001 ~ 0.100 (本文取变异率为 0.001).循环往复,直到进行 100 次迭代为止.从 100 组最优结果中再进行选择,将适应度最大的数据序列作为最终的优化结果.

(2) 模型参数估计

本文重点对模型参数的估计进行研究.利用反向过程确定数据初值,结合阻尼最小二乘法,利用 EViews 统计软件求解出 ARMA 模型满足精度的参数^[8].

对于观测时序 $\{x_t\}$ ($t = 1, 2, \dots, n$),需对其拟和出

数学模型:

$$x_t = f(X_t, \beta) + \varepsilon_t \quad (14)$$

式中, $\mathbf{X}_t = [x_{t-1} x_{t-2} \cdots x_{t-k}]^T = [x_{t-1} x_{t-2} \cdots x_{t-p} \varepsilon_{t-1} \varepsilon_{t-2} \cdots \varepsilon_{t-q}]^T$ ($k = p + q$),是由不同时刻的观测值组成的 k 维向量; $\beta = [\beta_1 \beta_2 \cdots \beta_m]^T = [\varphi_1 \varphi_2 \cdots \varphi_p \theta_1 \theta_2 \cdots \theta_q]^T$ ($m = p + q$),是由待估计的模型参数 β_i ($i = 1, 2, \dots, m$) 组成的 m 维向量; ε_t 是模型的残差; f 表示 \mathbf{X}_t 与 β 之间的函数关系;一般 $k, m < n$.

结合 ARMA(p, q) 模型形式,式(14)可以记为 $x_t = \mathbf{X}_t \beta + \varepsilon_t$.其中, $f(\mathbf{X}_t, \beta) = \mathbf{X}_t \beta$.

由 $\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$ 是 $x_{t-1}, x_{t-2}, \dots, x_{t-p}$ 的函数,从而导致 β 的非线性项出现.故对于 ARMA 模型 \mathbf{X}_t 与 β 之间具有非线性关系,从而 ARMA 模型的目标函数 $s(\beta)$ 定义为模型的残差平方和:

$$s(\beta) = \sum_{t=p+1}^n \varepsilon_t^2 = \sum_{t=p+1}^n [x_t - f(\mathbf{X}_t, \beta)]^2 \quad (15)$$

从优化理论的角度来看,参数 β 的估值问题就是对 $s(\beta)$ 的寻优(求极小值)问题.本文采用条件最小二乘法^[9]精确求解方程,并采用反向推导过程确定初值.

假设时间序列 x_1, x_2, \dots, x_n ,需要去估计 x_{-i} ($i = 1, 2, \dots, n$),可以由反向模型所产生 $\varphi(B)x_k = \theta(B)\varphi_k$.其中, B 为后移算子,且有 $(1 - \varphi_1 B - \varphi_2 B^2 - \cdots - \varphi_p B^p) \mathbf{X}_t = (1 - \theta_1 B - \theta_2 B^2 - \cdots - \varphi_q B^q) \varepsilon_t$.

由于该算子的平稳性,在一定的范围 $t = l$ ($l \leq n$) 以外,估计值基本上等于零^[10].因此,对充分的近似值,用式(16)来求解

$$x_t = \varphi^{-1}(B)\theta(B)\varphi_t = \sum_{j=0}^{\infty} \psi_j \varphi_{t-j} \approx \sum_{j=0}^l \psi_j \varphi_{t-j} \quad (16)$$

将混合过程用一个 l 阶滑动平均过程代替.接着将

模型线性化,而且要极小化 $S(\varphi, \theta) = \sum_{t=1-l}^n [\varphi_t]^2$.

将 (φ_t) 用 Taylor 级数展开,使用 β 作为 $m = p + q$ 个参数 (φ, θ) 的记号,在该值附近有一组推测的对应参数值 $\beta_0 = (\beta_{1,0}, \beta_{2,0}, \dots, \beta_{m,0})$,则有

$$[\varphi_t] = [\varphi_{t,0}] - \sum_{i=1}^m (\beta_i - \beta_{i,0}) x_{t,i} \quad (17)$$

式中, $[\varphi_{t,0}] = [\varphi_t | x, \beta_0]$, $x_{t,i} = - \left. \frac{\partial [\varphi_t]}{\partial \beta_i} \right|_{\beta = \beta_0}$.

再结合 ARMA 模型参数的优化理论估计法,本文使用阻尼最小二乘法^[11]进行计算,以得到使目标函数 $s(\beta)$ 取值为极小时的模型参数.

对于给定的模型,值 $[\varphi_m | x, \beta_{1,0}, \beta_{2,0}, \dots, \beta_{m,0}]$ 对于 $t = 1 - l, \dots, n$ 用递推方法,然后对 $[\varphi_m | x, \beta_{1,0} + \delta_1, \beta_{2,0}, \dots, \beta_{m,0}]$ 重复递推计算,继而又对 $[\varphi_m | x, \beta_{1,0}, \beta_{2,0} + \delta_2, \dots, \beta_{m,0}]$ 进行递推计算,由 $x_{t,i} = ([\varphi_m | x, \beta_{1,0}, \beta_{2,0}, \dots, \beta_{i,0}, \dots, \beta_{m,0}] - [\varphi_m | x, \beta_{1,0}, \beta_{2,0}, \dots, \beta_{i,0} + \delta_i,$

$\dots, \beta_{m,0}] / \delta_i$ 给出了具有足够精度的所需导数负值, 计算出 $[\varphi_i]$, 最后计算出预期的 ARMA 模型参数.

4 基于小波分析和 GM(1,1)-ARMA 预测模型的建立

对导弹装备备件需求预测方法的思路和框架进行规划. 首先对备件需求序列进行分解与重构; 然后对低频趋势和低频趋势和低频趋势信号分别建模和预测; 最后, 将各个预测结果进行叠加, 便得到原始序列的预测结果. 预测框架如图 2 所示.



图2 基于小波分析和改进GM(1,1)-ARMA的导弹装备备件需求预测框架图

设 $x(t) = (t = 1, 2, \dots, n, \dots)$ 是备件需求时间序列, 用 Mallat 算法对其进行小波分解和重构, 可以得到:

表 1 1998 年 ~ 2010 年某种导弹装备备件的需求数据

年份	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010
需求量	49	53	60	55	61	65	76	63	72	77	89	80	87

导弹装备备件需求数据样本共 13 组, 选取前 10 组数据样本构建模型, 拟合模型; 后 3 组数据样本用来作为预测值的比较对象, 以检验预测效果的好坏.

5.1 需求预测

(1) 小波分解与重构

为选择合适的小波基函数, 选用常见小波对备件需求数据进行了分解与重构, 预测误差结果如表 2 所示.




图3 备件需求时间序列及用db3小波分解后重构结果

表 2 不同小波基函数分解后预测误差

小波	Sym2	Sym3	Sym5	Db3	Coif3	Meyer
MAPE/%	1.837	1.524	1.792	1.681	1.704	2.349

(2) 低频趋势信号预测

对低频信号数据序列 $\{X_1(i)\} (i = 1, 2, \dots, 13)$ 采用

$$X = D_1 + D_2 + \dots + D_J + C_J \quad (18)$$

对重构后的低频趋势信号 C_J 采用 GM(1,1) 模型进行预测; 对重构后的高频细节信号 D_1, D_2, \dots, D_J 采用 ARMA 模型进行拟合. 确定模型参数后, 就可预测 $x(t+1)$ 值, 即求:

$$x(t+1) = D_{1,t+1} + D_{2,t+1} + \dots + D_{J,t+1} + C_{J,t+1} \quad (1)$$

式中, $D_{j,t+1} (j = 1, 2, \dots, J)$ 为高频细节信号预测值; $C_{J,t+1}$ 为低频趋势信号的预测值.

5 案例分析

某型导弹装备由于电流电压不稳或电子器件到寿、振动或冲击、橡胶老化或受力等因素, 导致导弹装备出现电子件短路断路或击穿烧蚀、机械件断裂或磨损、橡胶件断裂或磨损等现象, 进而导致相应备件的需求. 这里统计了该型导弹装备某种备件 1998 年 ~ 2010 年的需求情况, 如表 1 所示.

可见, sym3 分解后预测得到的效果最好. 各级小波分解与重构去噪效果各项评价指标值及归化值, 如表 3 所示. 可见, 采用二级小波分解重构时 $H(M)$ 最大, 故最佳级数为 2. 低频逼近信号、高频细节信号和重构信号见图 3, 重构误差为 0.8153×10^{-10} . 由此可见, 在分解过程中小波和分解层数的选择是比较合理的.

GM(1,1) 模型进行预测, 数据拟合情况如图 4 所示. 经检验: 平均相对误差 $\bar{\epsilon} = 0.0179$, 关联度 $r = 0.9928$, 后验差比值 $C = 0.032 < 0.35$, 小误差概率 $P = 1 > 0.95$, 模型预测精度为一级, 说明可以用于 $\{X_1(i)\} (i = 1, 2, \dots, 13)$ 的预测.

表 3 需求数据的各级分解重构评价指标归化值

M	1	2	3	4	5
$P_v(M)$	0.8247	1	0.8997	0	0.4679
$P_p(M)$	1	0.8375	0.7616	0.4862	0
$P_{SNR}(M)$	1	0.6319	0.5140	0.3175	0
$P_r(M)$	0	0.7632	0.9283	0.9893	1
$H(M)$	2.8247	3.2326	3.1036	1.7930	1.4679




图4 低频信号的灰色拟合

(3)高频细节信号预测

首先对高频信号 1 数据序列 $\{X_2(i)\} (i = 1, 2, \dots, 13)$ 进行 ADF(augmented dickey-fuller)单位根检验^[12], 结果如表 4 所示. 在 1% 的显著水平下, 高频信号 1 数据序列拒绝存在一个单位根的原假设, 说明高频信号 1 数据序列是平稳的. 选用 AIC 准则进行定阶, 设定 p 和 q 的变化范围为 1 ~ 5, 经过多次运算可得到若干个 ARMA(p, q)模型的 AIC 估计值. 比较 AIC 估计值的大小, 得到其最小值为 -4.2762, 并且确定最小值对应的阶数组为 $(p, q) = (2, 1)$. 应用阻尼最小二乘法进行参数估计后, 将残差序列进行白噪声检验. 选择 $k = 5$ 作为残差序列自相关系数分析的阶数, 分别计算 5 步自相关系数, 求得卡方统计量 F_k 为 2.519. F_k 服从自由度为 k 的 χ^2 分布^[13], 自由度为 5 的 $\chi_{0.05}^2$ 为 6.14, $F_k < \chi_{0.05}^2$. 可知残差序列为白噪声序列, ARMA(2, 1)可作为预测模型对小波分解后的高频信号进行预测. 同理, 可以对高频信号 2 数据序列 $\{X_3(i)\} (i = 1, 2, \dots, 13)$ 进行建模.

表 4 高频信号 1 序列 ADF 检验结果


ADF 统计量	显著性水平 (%)	ADF 检验临界值	P 值
-4.8361	1	-3.6943	0.0007
	5	-2.7517	
	10	-2.4358	

最后, 高频信号 1 和 2 的拟合情况如图 5 和图 6 所示. ARMA 模型的预测信号值和原始信号很接近, 预测精度较高, 可以用于高频细节信号的预测.


5.2 结果分析

作为对比, 采用 GM(1, 1)、选用 AIC 准则和最小二乘法优化的 ARMA 模型、选用改进 IP_GA 和阻尼最小

二乘法优化的 ARMA 模型分别对备件需求进行预测, 结果如表 5 和图 7 所示. 选取相对误差 (Relative Percent Error, RPE) 和平均相对误差 (Mean Relative Error, MRE) 作为各种预测方法的评价指标.




(a) 原始信号




(b) 预测误差的自相关函数

图5 高频信号1的ARMA拟合及其误差相关系数



(a) 原始信号



(b) 预测误差的自相关函数

图6 高频信号2的ARMA拟合值及其误差相关系数

由表 5 可知, 基于改进遗传算法和阻尼最小二乘法优化的 ARMA 模型的预测精度高于选用 AIC 准则和最小二乘法优化的 ARMA 模型, 基于小波分析和改进 GM(1, 1) - ARMA 的预测方法预测准确度高于其他预测方法, 而且性能稳定.

表 5 不同方法的预测值及相对误差

年份	实际值	GM(1,1)模型		传统 ARMA		改进 ARMA		小波分析和 GM(1,1) - ARMA	
		预测值	RPE	预测值	RPE	预测值	RPE	预测值	RPE
2008	89	94.1329	0.0577	85.1865	0.0695	92.5972	0.0404	87.5895	0.0158
2009	80	87.2335	0.0904	83.7340	0.0467	82.7541	0.0344	82.1363	0.0267
2010	87	90.3587	0.0386	89.8592	0.0328	89.4634	0.0283	86.7269	0.0031
MRE		0.0622		0.0497		0.0344		0.0152	




图7 预测结果对比图

6 结束语

小波分解和重构可以将非平稳的备件需求时间序列分解为多层频率成分更加单纯、相关性更强的序列,并且针对各层的特点,本文采用 GM(1,1)和 ARMA 模型分别对分解后的低频趋势信息和高频细节信息进行预测,叠加各子序列的最终预测效果优于单纯的 GM(1,1)模型或 ARMA 模型.研究表明,基于小波分析的多种模型相结合的方法,不仅能够反映原始备件需求数据的结构特征及变化规律,而且还可以发挥各模型的优势,取得了较高的预测精度且预测性能稳定,对进一步解决实际问题具有良好的应用前景.

参考文献

- [1] 任三孩,常文革,刘向君.一种基于小波变换和变尺度圆模板融合的景象匹配算法[J].电子学报,2011,39(9):2200-2203.
REN San-hai, CHANG Wen-ge, LIU Xiang-jun. A scene matching method based on wavelet transform and multi-scale circular template fusion[J]. Acta Electronica Sinica, 2011, 39(9):2200-2203. (in Chinese)
- [2] Zaouche A, Dayoub I, Rouvaen J M. Baud-spaced constant modulus blind equalization via hybrid genetic algorithm and generalized pattern search optimization[J]. AEU-International Journal of Electronics and Communications, 2008, 62(2): 122-131.
- [3] 杨凤凤,黄海风,梁甸农.基于遗传算法的分布式星载 SAR-GMTI 编队优化[J].电子学报,2007,35(6):1037-1041.
YANG Feng-feng, HUANG Hai-feng, LIANG Dian-nong. GMTI mode formation optimization for distributed satellites SAR system[J]. Acta Electronica Sinica, 2007, 35(6): 1037-1041. (in Chinese)
- [4] 崔建国,赵云龙,董世良,等.基于遗传算法和 ARMA 模型的航空发电机寿命预测[J].航空学报,2011,32(8):1506-1511.
CUI Jian-guo, ZHAO Yun-long, DONG Shi-liang, et al. Life prognostics for aero-generator based on genetic algorithm and ARMA model[J]. Journal of Aeronautics, 2011, 32(8): 1506-1511. (in Chinese)
- [5] Mohammadi K, Eslami H R, Kahawita R. Parameter estimation of an ARMA model for river flow forecasting using goal programming[J]. Journal of Hydrology, 2006, 331(1-2): 293-299.
- [6] Song S K, Gorla N A genetic algorithm for vertical fragmentation and access path selection[J]. The Computer Journal, 2000, 43(1): 81-92.
- [7] Kuk-Hyun Han, Jong-Hwan Kim. On setting the parameters of quantum-inspired evolutionary algorithm for practical applications[A]. Proceedings of the 2003 IEEE Congress on Evolutionary Computation[C]. Daejeon, South Korea: Dept of Electr Eng & Comput Sci Korea Adv Inst of Sci & Technol, 2003. 178-194.
- [8] 韩志杰,王汝传,凡高娟,肖甫.一种基于 ARMA 的 WSN 非均衡分簇路由算法[J].电子学报,2010,38(4):865-893.
HAN Zhi-jie, WANG Ru-chuan, FAN Gao-juan, XIAO Fu. An unequal clustering algorithm in wireless sensor networks based on ARMA[J]. Acta Electronica Sinica, 2010, 38(4): 865-893. (in Chinese)
- [9] 李瑞莹,康锐.基于 ARMA 模型的故障率预测方法研究[J].系统工程与电子技术,2011,36(2):375-379.
LI Rui-ying, KANG Rui. Research on failure rate forecasting method based on ARMA model[J]. Systems Engineering and Electronics, 2011, 36(2): 375-379. (in Chinese)
- [10] CARDEN E P, BROWNJOHN J M W. ARMA modeled time-series classification for structural health monitoring of civil infrastructure[J]. Mechanical Systems and Signal Processing, 2008, 22(2): 295-314.
- [11] IVES A, ABBOTT K C, ZIEBARTH N L. Analysis of ecological time series with ARMA(p, q) model[J]. Ecology, 2010, 91(3): 858-871.
- [12] 刘亮,唐海萍,张丽军.基于 ARMA 模型的财政教育投资

时间序列分析[J].北京师范大学学报(自然科学版), 2010,46(2):194-196.

LIU Liang, TANG Hai-ping, ZHANG Li-jun. Non-steady time-series analysis of finance investment in education based on ARMA model[J]. Journal of Beijing Normal University (Natural Science), 2010,46(2):194-196. (in Chinese)

[13] 栾培贤,肖建华,陈欣,等.基于灰色模型和 ARMA 模型

的猪瘟疫月新发生次数预测比较[J].农业工程学报,2011, 27(2):223-226.

Luan Pei-xian, Xiao Jian hua, Chen Xin, et al. Comparison of grey model and ARMA model for predicting the number of monthly new outbreaks of CSF [J]. Transactions of the CSAE, 2011, 27(2):223-226. (in Chinese)

作者简介



赵建忠(通讯作者) 男,1978年11月生于山东省聊城市.现为海军航空工程学院博士研究生.主要研究方向为装备综合保障理论与技术.

E-mail: zjznavy@163.com



徐廷学 男,1962年4月出生于河南省驻马店.现为海军航空工程学院教授,博士生导师.主要研究方向:装备综合保障、武器系统与运用工程.

E-mail: xte1962@163.com