2021 年 第 21 卷 第 35 期
2021, 21(35): 15255-07

科 学 技 术 与 工 程
Science Technology and Engineering

ISSN 1671—1815
CN 11—4688/T

引用格式:陈方圆, 邹永久, 张 鹏, 等. 基于 ARIMA-KF 模型的船舶系统设备状态参数预测[J]. 科学技术与工程, 2021, 21(35): 15255-15261.

Chen Fangyuan, Zou Yongjiu, Zhang Peng, et al. Prediction of equipment state parameters of ship system based on ARIMA-KF model[J]. Science Technology and Engineering, 2021, 21(35): 15255-15261.

基于 ARIMA-KF 模型的船舶系统设备状态参数预测

陈方圆, 邹永久, 张 鹏, 张跃文*, 孙培廷

(大连海事大学轮机工程学院, 大连 116026)

摘 要 针对目前大多数预测模型在船舶智能运维领域应用过程中存在的预测精度偏低、模型不易构建等问题,提出了自回归积分滑动平均模型(auto-regressive integrated moving-average model,ARIMA)和卡尔曼滤波(Kalman filter,KF)相结合的船舶系统设备状态参数组合预测模型——ARIMA-KF 模型。该模型首先构建了 ARIMA 单步和多步预测模型;然后利用 KF 算法对 ARIMA 预测模型参数值进行寻优,得到 ARIMA-KF 组合预测模型;最后,基于组合模型对船舶海水冷却系统状态参数进行预测,将预测值与实船获取的实际值进行对比及误差分析。结果表明,采用基于 ARIMA-KF 组合模型比单一的 ARIMA 模型预测精度提高 3% 左右。研究结果对船舶系统设备的健康管理和视情维修具有一定的指导意义。

关键词 智能运维; 组合模型; 状态参数预测; 卡尔曼滤波

中图法分类号 U664.81; **文献标志码** A

Prediction of Equipment State Parameters of Ship System Based on ARIMA-KF Model

CHEN Fang-yuan, ZOU Yong-jiu, ZHANG Peng, ZHANG Yue-wen*, SUN Pei-ting

(Marine Engineering College, Dalian Maritime University, Dalian 116026, China)

[**Abstract**] In order to solve the problems of low prediction accuracy and difficulty in model construction during the application of most prediction models in the field of intelligent operation and maintenance in ships, a combined prediction model of ship system and equipment state parameters, ARIMA-KF model, which combines autoregressive integral moving average model(auto-regressive integrated moving-average model,ARIMA) and Kalman filter(KF), was proposed. Firstly, the single-step and multi-step prediction models of ARIMA were constructed. Secondly, the Kalman filter algorithm was used to optimize the parameter values of the ARIMA prediction model, and the ARIMA-KF combined prediction model was obtained. Finally, the state parameters of Marine seawater cooling system were predicted based on the combined model, and the predicted values were compared with the actual values obtained by the actual ship and the error analysis is made. The results show that the prediction accuracy of the combined ARIMA-KF model is about 3% higher than that of the single ARIMA model. The results of this study have certain guiding significance for the health management and condition-based maintenance of ship system and equipment.

[**Keywords**] intelligent operation and maintenance; combined model; state parameter prediction; Kalman filter

随着大数据技术的快速发展和 5G 时代的到来,智能船舶已成为船舶行业未来发展的必然趋势[1]。船舶系统设备状态参数预测研究也将成为船舶智能化发展的重要基础技术之一。基于数据驱动的方法,如何有效地利用航参数据,建立预测模型,实现对船舶系统及设备工作状态的智能分析和准确预测,提高智能船舶的可靠性和船舶智能设备的可操作性,是目前亟需解决的问题[2]。此外,船舶系统设备状态参数预测不仅可以实现船舶系统设备剩余寿命预测,还能为轮机员提供辅助决策支持[3]。

目前,在船舶领域中常用的预测方法主要有灰色模型、BP(back propagation)神经网络等。南晓雪[4]采用灰色模型实现了对有变化趋势的港口船舶通航能力进行了准确预测。但灰色模型只能识别单一参数,限制了其使用范围,且使用单一算法对参数预测的精度较低,无法满足船舶系统设备状态参数预测的实际需求。王子铭等[5]基于长短期

收稿日期: 2021-04-13; **修订日期**: 2021-08-31

基金项目: 高技术船舶科研资助项目(MC-201712-C07);国家重点研发计划(2018YFB1601502);中央高校基本科研业务费专项(3132019006)

第一作者: 陈方圆(1997—),女,汉族,河南商丘人,硕士。研究方向:船舶智能运维。E-mail:cfy13037661363@dlmu.edu.cn。

* **通信作者**: 张跃文(1967—),男,汉族,辽宁铁岭人,硕士,教授。研究方向:船舶机械故障预测与健康管理技术。E-mail:zhangyuewen@dlmu.edu.cn。

记忆神经网络中的时间序列预测模型构建了主机油耗实时预报模型,实现了对船舶在航行过程中主机油耗参数的实时预测。吕鹏飞等[6]以船舶运输量为主要研究对象,结合马尔科夫预测模型,对 BP 神经网络进行优化,实现了对运输量趋势的准确预测。王新全等[7]构建了基于遗传算法优化的 BP 神经网络预测模型,实现了对船舶主机排气温度变化趋势的准确预测。尹倩[8]基于长短期记忆循环神经网络的温度预测分析模型,实现了对压缩机出风口和涡轮机出口的未来温度变化进行了预测。上述基于神经网络进行预测的方法虽然提高了预测的准确度,但是基于神经网络方法需要从训练集中选取一些典型的样本重新构建训练集,容易陷入局部收敛,对样本依赖性较大,只适用于个别条件下船舶系统设备状态参数预测。近年来,也有不少专家和学者通过采用自回归滑动平均(auto-regressive moving-average model,ARMA)模型,实现了对船舶系统及设备状态参数的预测。孙晓磊等[9]构建了自回归分布式滞后 ARMA 预测模型,实现了对船舶动力装置系统状态参数的预测。优化后的 ARMA 模型虽然提高了预测的准确度,但由于船舶工作环境恶劣,受到的影响因素具有很大的不确定性,增大了优化模型的构建难度。因此,这在很大程度上限制了上述方法在船舶领域中的实际应用,亟需研究新型的组合预测模型。

针对上述模型的局限性,现探究船舶系统设备状态参数的变化规律,提出一种基于 ARIMA-KF(auto-regressive integrated moving-average model,Kalman filter,KF)组合模型的船舶系统设备状态参数的预测方法。该模型将两种算法的优势结合在一起,能弥补单一模型的不足,提高模型的准确度。此外,该模型将外界复杂的影响因素归为单一的时间影响因素来考虑,可降低模型构建的难度[10],并依靠卡尔曼滤波算法强大的更新迭代能力,大大减少了工作量[3]。该模型对船舶系统状态监控和辅助决策具有一定的指导意义。

1 ARIMA 模型原理以及建模过程

ARIMA(p,d,q) 模型又称整合移动平均自回归模型,其中,p、q 为 ARIMA 模型的阶数,d 为模型差分次数,ARIMA(p,d,q) 模型的实质就是最原始的非平稳序列做 d 次差分处理,然后再进行 ARMA(p,q) 模型拟合[10]。ARIMA(p,d,q) 模型形式为

$$\left(1-\sum_{i=1}^{p}\varphi_i L^i\right)(1-L)^d y_t=\left(1+\sum_{i=1}^{q}\theta_j L^i\right)\varepsilon_t \tag{1}$$

当 $d=0$ 时,该模型为 ARMA(p,q) 模型,即

$$\mathrm{ARMA}(p,q):y_t=\varphi_0+\sum_{i=1}^{p}\varphi_i y_{t-i}+a_t-\sum_{j=1}^{q}\theta_j a_{t-j} \tag{2}$$

式中:y_t 为采集到的时序数据,t 代表采样时间;$\varphi_i(i=0,1,2,\cdots,p)$、$\theta_j(j=1,2,\cdots,q)$ 为 ARIMA 模型的参数;$\{a_t\}$ 为 t 时刻白噪声序列;ε_t 为 t 时刻的零均值白噪声;L 为滞后算子。

建模具体过程如下。

(1)平稳性检验。采集到一组实船数据后,首先对该序列进行平稳性检验,一般采用单位根检验方法。若时序中存在单位根即为非平稳性时间序列。反之,则为平稳性时间序列,单位根检验方法一共包含 6 种检验方式,一般联合使用 ADF 检验(augmented dickey-fuller test)、KPSS 检验(kwiatkowski-phillips-schmidt-shin test)可以提高结果的可靠性[11]。

(2)数据预处理。若原始数据没有通过平稳性检验,则需要对该序列进行零均值处理,一般是通过将 d 阶差分算子作用于原始序列 y_t,得到 ARIMA(p,d,q) 模型。一阶差分示例为

$$\nabla^2 y_t=\nabla(y_t-y_{t-1})=y_t-2y_{t-1}+y_{t-2} \tag{3}$$

式(3)中:∇为差分算子;y_t、y_{t-1}、y_{t-2} 分别表示相邻时刻采集的数据。

(3)模型判定。对 ARIMA(p,d,q) 模型的判定可以结合自相关函数和偏自相关函数性质进行初步估计,具体判定方法如表 1 所示。

表 1 模型判定方法

Table 1 Model determination method

自相关函数	偏相关函数	模型判定
拖尾	截尾	AR 模型
截尾	拖尾	MA 模型
拖尾	拖尾	ARMA 模型

根据估计得到的不同 p、q 值,采用 AIC 准则(akaike information criterion)和 BIC 准则(bayesian information criterion)给模型定阶。准则公式为

$$\begin{cases}\mathrm{AIC}(p+q)=B\ln\sigma_a^2+2(p+q)\\ \mathrm{BIC}(p+q)=B\ln\sigma_a^2+(p+q)\ln N\end{cases} \tag{4}$$

式(4)中:B 表示时间序列的似然函数;N 为 ARMA(p,q) 模型的似然函数;σ_a^2 为拟合时序和实测时序的残差方差,当 σ_a^2 最小时,得到 p、q 值即为所求的模型阶数。

(4)参数估计和模型检验。参数估计一般采用 yule-walker 逆矩阵法。模型检验一般采用白噪声检验方式。

2　卡尔曼滤波

时间序列模型可以转换成状态空间模型的一种形式,并通过卡尔曼滤波进行求解[12]。状态空间模型由状态方程和观测方程两部分组成,运用状态空间分析方法将时间作为动态系统的隐藏变量的一种动态时域模型[13]。

状态方程为

$$\boldsymbol{X}_t = \boldsymbol{F}_t \boldsymbol{X}_{t-1} + \boldsymbol{c}_t + \boldsymbol{R}_t \boldsymbol{w}_t \tag{5}$$

量测方程为

$$\boldsymbol{Y}_{t+1} = \boldsymbol{Z}_t \boldsymbol{X}_t + \boldsymbol{d}_t + \boldsymbol{v}_t \tag{6}$$

式中:$\boldsymbol{X}_t$ 为 t 时刻的状态估计值($t = 1,2,3,\cdots,T$);$\boldsymbol{F}_t$ 代表 $m \times m$ 维的状态转移矩阵;$\boldsymbol{c}_t$ 为 $m \times 1$ 维的常数向量;$\boldsymbol{R}_t$ 是 $m \times g$ 维的噪声矩阵;$\boldsymbol{Y}_{t+1}$ 是系统在 $t+1$ 时刻 $k \times 1$ 维的观测向量;$\boldsymbol{Z}_t$ 为 $k \times 1$ 维量程矩阵;$\boldsymbol{d}_t$ 是 $k \times 1$ 维的干扰项;$\boldsymbol{w}_t$、$\boldsymbol{v}_t$ 代表的是均值为 0、协方差矩阵分别为 $\boldsymbol{G}_t$、$\boldsymbol{Q}_t$ 的干扰项,即 $E(\boldsymbol{w}_t) = 0$, $\mathrm{var}(\boldsymbol{w}_t) = Q_t$。$E(\boldsymbol{v}_t) = 0$, $\mathrm{var}(\boldsymbol{v}_t) = \boldsymbol{G}_t$,且 $\boldsymbol{G}_t$、$\boldsymbol{Q}_t$ 相互独立。

卡尔曼滤波(Kalman filtering,KF)由状态方程和测量方程两部分构成,在状态方程和测量方程已知的情况下,从一系列存在观测噪声数据中可以迭代出系统的最优状态估计[14]。

状态方程为

$$\boldsymbol{X}_t = \boldsymbol{F}_t \boldsymbol{X}_{t-1} + \boldsymbol{B}_t \boldsymbol{u}_t + \boldsymbol{w}_t \tag{7}$$

测量方程为

$$\boldsymbol{Y}_t = \boldsymbol{H}_t \boldsymbol{X}_t + \boldsymbol{v}_t \tag{8}$$

式中:$\boldsymbol{X}_t$、$\boldsymbol{F}_t$、$\boldsymbol{Y}_t$ 分别代表状态向量、状态转移矩阵和量测向量;$\boldsymbol{B}_t$、$\boldsymbol{u}_t$、$\boldsymbol{H}_t$ 分别为控制矩阵、状态控制向量、转换矩阵;$\boldsymbol{w}_t$、$\boldsymbol{v}_t$ 分别为系统噪声和测量噪声且都服从高斯分布。在已知 $t-1$ 时刻 $\boldsymbol{X}_{t-1}$ 的情况下,通过状态方程和测量方程不断更新和预测,就可以得到 t 时刻的最优状态值 $\boldsymbol{X}_{t|t-1}$。

系统状态更新步为

$$\begin{cases} \boldsymbol{X}_{t|t-1} = \boldsymbol{F}_t \boldsymbol{X}_{t-1} + \boldsymbol{B}_t \boldsymbol{u}_t \\ \boldsymbol{P}_{t|t-1} = \boldsymbol{F}_t \boldsymbol{P}_{t-1|t-1} \boldsymbol{F}_t^{\mathrm{T}} + \boldsymbol{Q} \end{cases} \tag{9}$$

观测量预测步为

$$\begin{cases} \boldsymbol{Y}_{t|t-1} = \boldsymbol{H}\boldsymbol{X}_{t|t-1} + \boldsymbol{v}_t \\ \boldsymbol{e}_t = \boldsymbol{Y}_t - \boldsymbol{Y}_{t|t-1} \\ \boldsymbol{S} = E(\boldsymbol{e}_t \boldsymbol{e}_t^{\mathrm{T}}) \end{cases} \tag{10}$$

式(9)中:$\boldsymbol{X}_t$、$\boldsymbol{K}_t$、$\boldsymbol{P}_t$、$\boldsymbol{P}_t^-$ 分别为 t 时刻的后验状态估计、卡尔曼增益、后验估计协方差、先验估计协方差;$\boldsymbol{Y}_{t|t-1}$、$\boldsymbol{S}_t$、$\boldsymbol{e}_t$ 分别为单步预测结果、预测误差、预测误差的协方差。

若已知 $t-1$ 时刻系统的最优状态服从高斯分布的情况下,即 $\boldsymbol{X}_{t-1} \sim (\boldsymbol{x}_{t-1}, \boldsymbol{P}_{t-1})$,根据预测方程(9)可以直接推导出 t 时刻的状态预测值 $\boldsymbol{X}_{t|t-1}$,也为 $t+1$ 时刻的先验估计,然后再由测量方程[式(10)]得到 t 时刻的量测状态 $\boldsymbol{Y}_t$。将 t 时刻的预测值和量测方程服从的高斯分布相乘,得到 t 时刻状态的最优估计服从的高斯分布,即 $\boldsymbol{X}_{t|t} \sim (\boldsymbol{x}_t, \boldsymbol{P}_t)$,再返回卡尔曼滤波更新步即式(10)便得到了卡尔曼滤波的结果最优状态估计 $\boldsymbol{X}_t$ 和最优状态协方差估计 $\boldsymbol{P}_t$。

3　ARIMA-KF 组合模型预测方法

根据以往研究表明,在不需要以往存储的历史数据和已知状态向量初始值、状态协方差矩阵初始值的情况下,卡尔曼滤波可通过计算机程序对状态空间模型参数进行估计,并且调整卡尔曼滤波的参数可以寻求和真实曲线吻合度更高的仿真曲线,达到提高预测精度的目的[11]。因时间序列 ARIMA 可以实现单步预测和多步预测,故下面将从单步预测和多步预测两方面构建线性状态参数的组合预测模型,对船舶系统与设备状态参数进行预测研究。

3.1　ARIMA-KF 单步预测方法

利用 ARIMA 模型对船舶系统及设备状态参数建立预测模型,得到初始参数估计。具体步骤如下。

Step 1　建立时间序列 ARIMA 模型。对状态参数时序进行平稳性检验和季节性调整,确定差分阶数,依照 AIC 准则、BIC 准则给模型定阶,用 yule-walker 逆矩阵法对模型系数 $\{\varphi_1,\varphi_2,\cdots,\varphi_p\}$,$\{\theta_1,\theta_2,\cdots,\theta_q\}$ 进行求解。

Step 2　构建状态空间模型的状态转移矩阵。将 ARIMA 模型系数值引入状态空间模型的 $m \times m$ 维的状态转移矩阵 $\boldsymbol{F}_t$ 中,其中 $m = \max(p,q)$,p、q 为 ARIMA 模型阶数。用模型预测方程来表示状态空间模型的状态转移方程。综上所述,ARIMA 模型系数来表示状态空间模型的状态转移矩阵可以写为

$$\begin{cases} \boldsymbol{X}_{t+1} = \boldsymbol{F}\boldsymbol{X}_t + \boldsymbol{R}\eta_t \\ \boldsymbol{Y}_t = \boldsymbol{H}\boldsymbol{X}_t \end{cases} \tag{12}$$

且 $\eta_t \sim N(0,\sigma_a^2)$ 则 $\boldsymbol{F} = \begin{bmatrix} \varphi_1 & 1 & 0 & \cdots & 0 \\ \varphi_2 & 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \vdots & & \vdots \\ \varphi_{m-1} & 0 & 0 & \cdots & 1 \\ \varphi_m & 0 & 0 & 0 & 0 \end{bmatrix}$,

$\boldsymbol{R} = [1 \quad -\theta_1 \quad \cdots \quad -\theta_{m-1} \quad -\theta_m]^{\mathrm{T}}$,$\boldsymbol{H} = [1 \quad 0 \quad 0 \quad \cdots \quad 0_m]$,$m = \max(p,q)$。其中,$\boldsymbol{X}_{1t}$ 的初始值为 $\{y_1 \quad y_2 \quad \cdots \quad y_m\}$。$\boldsymbol{X}(t)$ 其他元素通过递推公式 $\boldsymbol{X}_{mt} = \varphi_m \boldsymbol{Y}_{t-1} - \theta_{m-1} a_{t+1}$,最后得到状态初始值 $\boldsymbol{X}_{1|0} = (s_{1t} \quad s_{2t} \quad \cdots \quad s_{mt})^{\mathrm{T}}$ 和观测初始值 $\boldsymbol{Y}_t =$

$(y_{1t}\quad 2_{2t}\quad \cdots\quad y_{mt})^{\mathrm{T}}$，根据式(8)、式(9)得到最优估计状态向量 $\boldsymbol{X}_{t|t}$。

Step 3 采用 MATLAB 软件，对 ARIMA 模型进行单步预测。

Step 4 构建状态空间模型的观测方程。

ARIMA 模型和组合模型单步预测值作为卡尔曼滤波的观测量，在已知 $\boldsymbol{X}_{t|t}$ 的情况下，状态空间模型参数估计后，就能够得到 $t+1$ 时刻的预测。

$$\boldsymbol{Y}_{t+1|t} = E(\boldsymbol{Y}_{t+1} \mid \boldsymbol{Y}_t) = \boldsymbol{H}\boldsymbol{X}_{t+1|t} + E(\boldsymbol{v}_{t+1}) = \boldsymbol{H}\boldsymbol{F}\boldsymbol{X}_{t|t} \tag{13}$$

3.2 ARIMA-KF 外推预测方法

由于卡尔曼滤波无法单独进行向后预测，因此需要借助模型拟合的预测数据进行卡尔曼滤波分析，在模型预测的基础上提供新的观测值，利用卡尔曼滤波强大的迭代功能对状态向量估计不断修正进而得到最优估计，提高模型的预测精度。建模流程如图 1 所示。

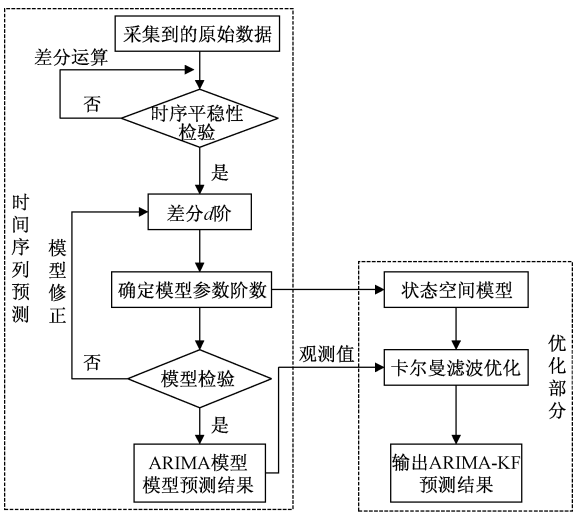

图 1 建模流程图

Fig. 1 Modeling flow chart

4 实例分析

4.1 基于 ARIMA-KF 的设备主要状态参数预测仿真

以小时为单位，将采集到 312 h 的实船海水冷却系统淡水出口温度值作为原始数据样本。利用 MATLAB 软件，将前 300 个数据作为训练样本输入预测模型中，预测未来 12 h 的温度值。将预测值和采集到的实船测量值进行误差对比分析，具体步骤内容如下。

Step 1 确保在船舶正常运行的情况下，对实船冷却水系统淡水出口的温度进行采集，采集到的原始样本数据如图 2 所示。

Step 2 采用 MATLAB 软件进行数据处理和编程，利用 KPSS 函数和 ADF 函数检验数据的平稳性，当 KSPP = 0，ADF = 1 时说明被检验序列为平稳序列。运行后的结果显示原始序列需经过 2 阶差分才转换为平稳序列，故该模型初定为 ARIMA(p,2,q)模型。该模型的自相关函数图形与偏自相关函数图形如图 3 所示。

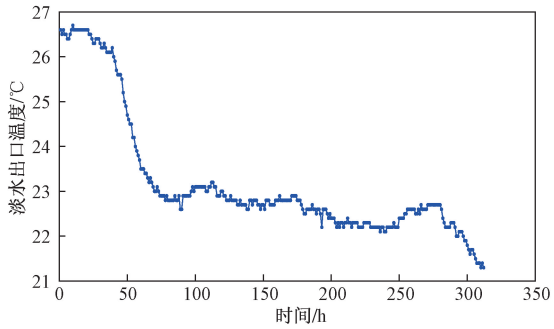

图 2 信号采集原始图

Fig. 2 Original diagram of signal acquisition

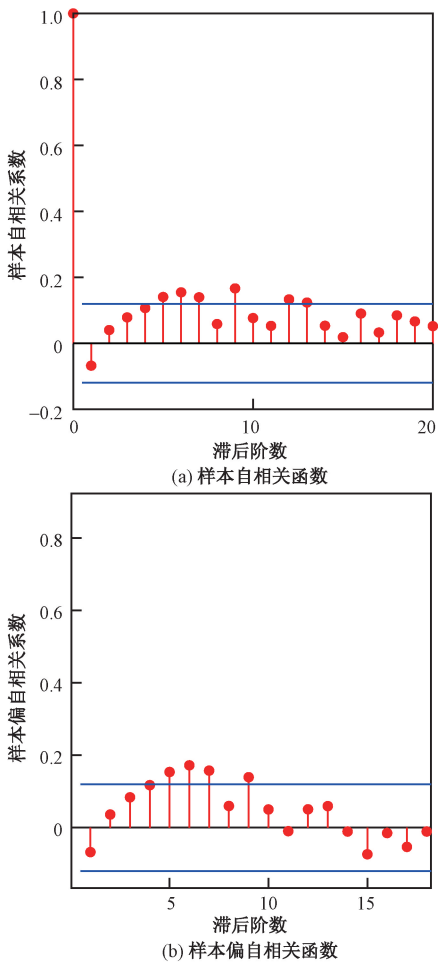

图 3 自相关函数、偏自相关函数图像

Fig. 3 Autocorrelation function、Partial autocorrelation function image

Step 3　确定阶数 p、q。根据表 1 和图 3 可知模型的自相关函数与偏自相关函数均为拖尾性。初步将阶数的范围定为 $5 \leqslant p \leqslant 12$, $5 \leqslant q \leqslant 12$。根据式(6)计算不同组合阶数对应的 AIC、BIC 值,依照 AIC 准则、BIC 准则,当 $p = 12$、$q = 5$ 时,AIC、BIC 值相对最小,又 $d = 2$,故时间序列模型为 ARIMA(12,2,5)。接下来对该模型的拟合残差进行检验。结果如图 4 所示,可知,拟合残差均值为 0,且服从正态分布,样本正态分位数分布在红线的周围,满足理想模型对拟合残差的要求。

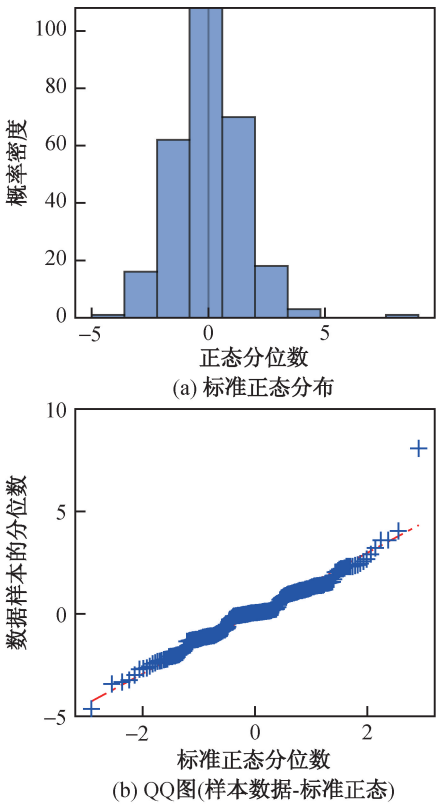

(a) 标准正态分布

(b) QQ图(样本数据-标准正态)

图 4　模型检测结果图

Fig. 4　Model test results

Step 4　在已知 $p = 12$, $d = 2$, $q = 5$。由式(4)得到 ARMA 模型的预测方程为

$$x(t+1) = 1.983x(t) + \cdots - 0.153x(t-13) - \alpha(t+1) - \cdots - 0.189\alpha(t-4) \tag{14}$$

根据式(14)转化为状态空间模型的状态方程和观测方程(令 $\boldsymbol{H} = [1,0,0,0,0,0,0,0,0,0,0,0,0]$)分别为

$$\begin{bmatrix} x(t+1) \\ x(t) \\ \vdots \\ x(t-12) \\ x(t-13) \end{bmatrix} = \begin{bmatrix} 1.983\,895\,7 & 1 & 0 & \cdots & 0 \\ -1.109\,477\,4 & 0 & 1 & \cdots & 0 \\ \vdots & 0 & 0 & & 0 \\ 0.473\,867 & 0 & 0 & \cdots & 1 \\ -0.153\,698 & 0 & 0 & \cdots & 0 \end{bmatrix} \begin{bmatrix} x(t) \\ x(t-1) \\ \vdots \\ x(t-13) \\ x(t-14) \end{bmatrix} + \begin{bmatrix} 1 & -1.044\,4 & 0.284 & \cdots & 0 \\ 0 & 0 & 0 & 0 & 0 \\ \vdots & \vdots & & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} \alpha(t+1) \\ \alpha(t) \\ \vdots \\ \alpha(t-12) \\ \alpha(t-13) \end{bmatrix} \tag{15}$$

$$\boldsymbol{Y}(t+1) = \boldsymbol{H} = [1,0,0,\cdots,0] \begin{bmatrix} x(t) \\ x(t+1) \\ \vdots \\ x(t-12) \end{bmatrix} + \omega(t+1) \tag{16}$$

式中:$\alpha(t)$、$\omega(t)$ 均为白噪声序列。一般取状态初始值 $\boldsymbol{X}_{1|0} = (s_{1t} \quad s_{2t} \quad \cdots \quad s_{mt})^{\mathrm{T}} = (y_{1t} \quad y_{2t} \quad \cdots \quad y_{mt})^{\mathrm{T}}$, 观测初始值 $p(0|0) = 10\boldsymbol{I}$, $\boldsymbol{I}$ 为多维的单位矩阵,应用 MATLAB 软件根据式(8)~式(10)实现卡尔曼滤波优化和递推预测。

4.2　仿真结果与分析

为进一步验证组合预测模型的有效性,选取图 2 前 300 个实测数据作为组合预测模型的输入,采用 MATLAB 软件编程预测未来 12 h 的数据,和实测数据以及单一的 ARIMA 模型的预测值进行误差对比分析。如图 5~图 7 所示,从整体上看,无论是单一的 ARIMA 模型还是 ARIMA-KF 组合模型,预测结果都是呈现线性下降趋势,符合真实值的变化趋势,但 ARIMA-KF 组合模型较单一的 ARIMA 模型明显更接近实测值。图 5 为 ARIMA 模型和 ARIMA-KF 组合模型的多步预测结果表明,组合模型的单步预测结果较单一的 ARIMA 模型预测结果的准确性高。图 6、图 7 是两种模型对实测数据的单步预测整体图和分时图,从中可看出:组合模

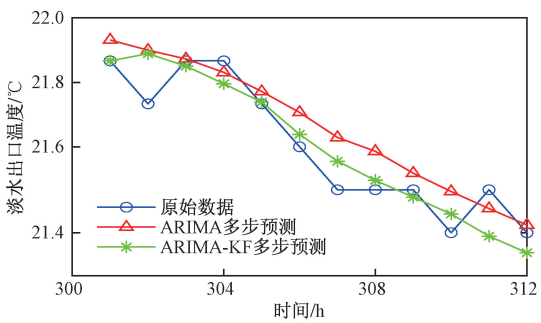

图 5　多步预测结果对比

Fig. 5　Multi step predictionresult comparison

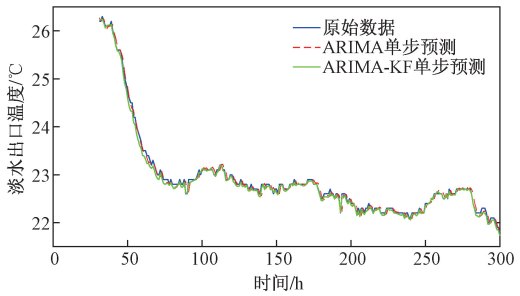

图 6 单步预测结果整体对比

Fig. 6 Overallcomparison of single step prediction result

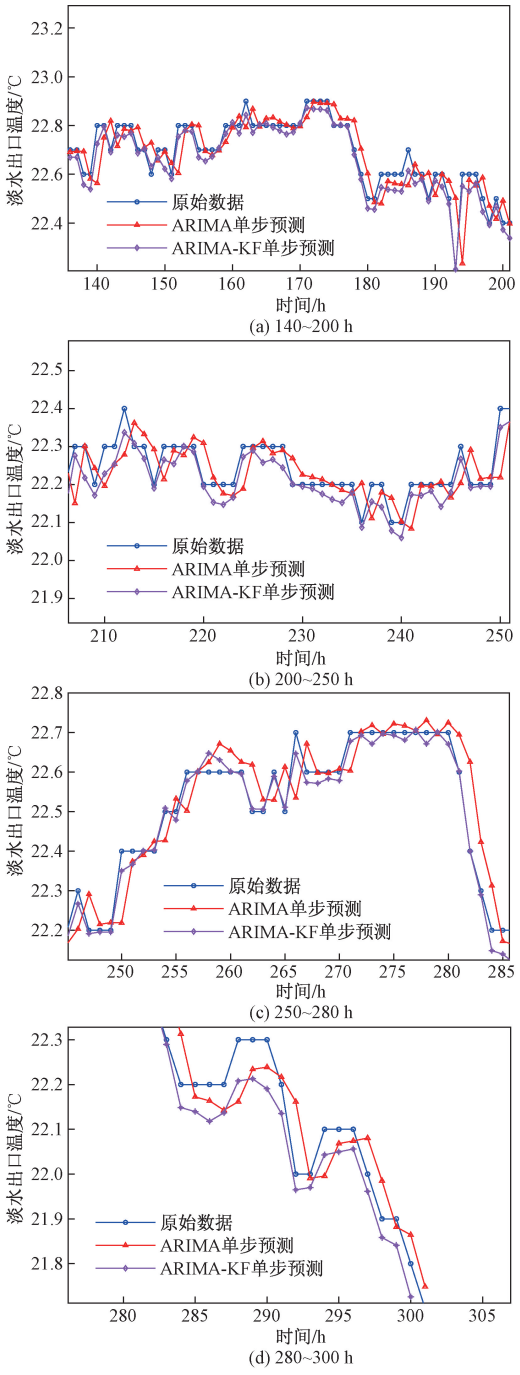

图 7 单步预测结果分时对比

Fig. 7 Time-sharing comparison of single-step prediction results

型的单步预测基本与是实测数据保持一致,能够较好地反映冷却水淡水出口温度的变化趋势。从图 5 和图 6、图 7 对比来看,无论是 ARIMA-KF 组合模型还是单一 ARIMA 预测模型,单步预测的准确度更高。

4.3 模型评价

为进一步分析不同预测方法的预测效果,本文对每种模型算法进行了均方误差(MSE)、平均绝对误差(MAE)、均方根误差(RMSE)计算分析。最终结果如表 2 所示。

表 2 误差计算

Table 2 Error calculation

误差	MSE	MAE	RMSE/%
ARIMA 多步预测	0.536 0	2.067 5	20.9
ARIMA-KF 多步预测	0.007 7	0.067 0	8.88
ARIMA 单步预测	0.007 1	0.081 1	8.44
ARIMA-K 单步预测	0.003 4	0.044	5.84

从图 7 和表 2 中可以看出,单一的 ARIMA 模型多步预测误差是最大。ARIMA-KF 组合模型的多步预测误差和 ARIMA 模型的单步预测误差结果差别很小,但均比单一的 ARIMA 模型预测效果好。ARIMA-KF 组合模型单步预测误差最低,预测效果最好。

5 结论

介绍了 ARIMA 模型单步预测和多步预测方法,分析了现有船舶设备状态参数预测模型的不足之处,利用卡尔曼滤波算法强大迭代能力,对 ARIMA 模型的参数进行寻优,弥补了单一算法的不足的同时降低了建模难度。该算法对监测信号样本少、呈线性的非平稳船舶系统及设备状态参数进行预测研究,将外界的复杂影响因素归为单一的时间因素来考虑。通过对实船海水冷却系统设备的淡水出口温度进行单步和多步预测,验证了模型有效性。将组合模型与单一的 ARIMA 模型的预测值进行对比,结果表明,组合模型的预测精度更高,预测效果更为理想。为发展船舶系统设备的智能维修决策提供了理论支持。

参 考 文 献

[1] 孙晓磊, 丁亚委, 郭克余, 等. 基于 ARMA 模型的船舶海水冷却系统参数预测[J]. 计算机测量与控制, 2017, 25(7): 285-289.
Sun Xiaolei, Ding Yawei, Guo Keyu, et al. Ship seawater cooling system parameter prediction based on ARMA model[J]. Comput Measurement & Control, 2017, 25(7): 285-289.

[2] 王 凯, 徐 浩, 黄连忠, 等. 基于机器学习的船舶能耗智能

预测方法分析[J]. 船舶工程, 2020, 42(11): 87-93.
Wang Kai, Xu Hao, Huang Lianzhong, et al. Analysis of intelligent prediction method of ship energy consumption based on machine learning[J]. Ship Engineering, 2020, 42(11): 87-93.

[3] 徐野男. 基于时间序列的船舶冷却水系统状态参数预测分析[D]. 大连: 大连海事大学, 2015.
Xu Yenan. Research on ship's colling water system state parameter forecast based on time series[D]. Dalian: Dalian Maritime University, 2015.

[4] 南晓雪. 基于灰色模型的港口船舶通航能力估计[J]. 舰船科学技术, 2020, 42(12): 196-198.
Nan Xiaoxue. Estimation of navigation capacity of port ships based on grey model[J]. Ship Science and Technology, 2020, 42(12): 196-198.

[5] 王子铭, 陈顺怀. 基于 LSTM 神经网络的船舶主机油耗实时预报[J]. 武汉理工大学学报(交通科学与工程版), 2020, 44(5): 923-927.
Wang Ziming, Chen Shunhuai. Real-time forecast of fuel consumption of ship main engine based on LSTM neural network[J]. Journal of Wuhan University of Technology (Transportation Science&Engineering), 2020, 44(5): 923-927.

[6] 吕鹏飞, 庄　元, 李　洋, 等. 船舶交通量的 BP 神经网络-马尔科夫预测模型[J]. 上海海事大学学报, 2017, 38(2): 17-21, 28.
Lü Pengfei, Zhuang Yuan, Li Yang, et al. BP neural network combined with Markov prediction model of ship traffic flow[J]. Journal of Shanghai Maritime University, 2017, 38(2): 17-21, 28.

[7] 王新全, 孙培廷, 邹永久, 等. 基于 GA-BP 模型的船舶柴油机排气温度趋势预测[J]. 大连海事大学学报, 2015, 41(3): 73-76.
Wang Xinquan, Sun Peiting, Zou Yongjiu, et al. Prediction of marine main engine exhaust temperature changing trend based on GA-BP model[J]. Journal of Dalian Maritime University, 2015, 41(3): 73-76.

[8] 尹　倩. 基于时间序列的船舶推进装置温度预测[D]. 大连: 大连海事大学, 2020.
Yin Qian, Temperature prediction of ship propulsion devices based on time series[D]. Dalian: Dalian Maritime University, 2020.

[9] 孙晓磊, 邹永久, 张　鹏, 等. 基于混合预测模型的船舶海水冷却系统状态参数预测[J]. 舰船科学技术, 2018, 40(15): 104-109.
Sun Xiaolei, Zou Yongjiu, Zhang Peng, et al. Ship seawater cooling system state parameter prediction based on hybrid prediction model[J]. Ship Science and Technology, 2018, 40(15): 104-109.

[10] 张逸飞, 付玉慧. 基于 ARIMA-BP 神经网络的船舶交通事故预测[J]. 上海海事大学学报, 2020, 41(3): 47-52.
Zhang Yifei, Fu Yuhui. Prediction of ship traffic accidents based on ARIMA-BP neural network[J]. Journal of Shanghai Maritime University, 2020, 41(3): 47-52.

[11] 林宝城, 林　琳. 基于 VAR 的港口物流与区域经济关联性分析——以福建省港口为例[J]. 物流工程与管理, 2019, 41(9): 48-51, 56.
Lin Baocheng, Lin Lin. Correlation analysis of port logistics and regional economy based on VAR: taking the port of Fujian Province as an example[J]. Logistics Engineering and Management, 2019, 41(9): 48-51, 56.

[12] 徐　鑫, 刘　彬, 刘东洋. 基于线性二次调节器算法的两轮自平衡机器人最优控制方法[J]. 科学技术与工程, 2021, 21(21): 8957-8964.
Xu Xin, Liu Bin, Liu Dongyang. Optimal control method of two-wheeled self-balancing robot based on linear quadratic regulator algorithm[J]. Science Technology and Engineering, 2021, 21(21): 8957-8964.

[13] 吴晓倩, 卢秀山, 王胜利, 等. 一种基于改进自适应卡尔曼滤波的 GNSS/INS 组合导航算法[J]. 科学技术与工程, 2020, 20(3): 913-917.
Wu Xiaoqian, Lu Xiushan, Wang Shengli, et al. A GNSS / INS integrated navigation algorithm based on modified adaptive Kalman filter[J]. Science Technology and Engineering, 2020, 20(3): 913-917.

[14] 宋平岗, 郑雅芝, 杨声弟, 等. 基于卡尔曼滤波的电力电子变压器直流电压平衡控制[J]. 科学技术与工程, 2020, 20(6): 2285-2291.
Song Pinggang, Zheng Yazhi, Yang Shengdi, et al. Direct current voltage balance control of power electronic transformer based on Kalman filter[J]. Science Technology and Engineering, 2020, 20(6): 2285-2291.