

基于ARIMA-LSTM的飞机液压泵性能趋势预测方法*

崔建国¹, 李鹏程¹, 崔霄², 于明月¹, 蒋丽英¹, 王景霖³

(1. 沈阳航空航天大学自动化学院 沈阳, 110136)

(2. 航空工业空气动力研究院模型天平与风洞设备五部 沈阳, 110034)

(3. 故障诊断与健康安全技术航空科技重点实验室 上海, 201601)

摘要 针对飞机液压泵工作强度高、工作环境复杂而导致传统性能预测方法对飞机液压泵性能变化趋势预测精度不高的问题,提出了一种基于自回归积分滑动平均-长短期记忆(auto-regressive integrated moving average-long short-term memory,简称ARIMA-LSTM)网络的飞机液压泵性能趋势预测方法。首先,将获取的飞机液压泵性能表征参数回油流量数据进行线性分解,得到趋势项数据和细节项数据;其次,采用自回归积分滑动平均(auto-regressive integrated moving average,简称ARIMA)方法对趋势项数据进行预测,同时采用长短期记忆(long short term memory,简称LSTM)网络方法对归一化处理后的细节项数据进行预测;最后,将两部分预测结果进行叠加,得到最终的性能趋势预测结果。研究表明,采用ARIMA-LSTM的联合预测方法对飞机液压泵性能变化趋势的预测效果明显优于单一的ARIMA与LSTM预测方法,为飞机液压泵性能变化趋势预测的工程应用提供了一种新方法。

关键词 飞机液压泵;性能变化;趋势预测;自回归积分滑动平均模型;长短期记忆网络

中图分类号 TH136; TP206+.3

引言

飞机液压系统是飞机上以油液为驱动介质、为飞机提供驱动力的整套装置^[1]。飞机液压泵具有脉动频率低、体积小、转速高和散热性能良好等优点,能够满足飞机在高空严酷工作环境下及高强度飞行任务对液压泵性能的要求。飞机液压泵受体积与重量的限制,液压泵传感器网络相比于工业液压泵来说网络布局较为简单,无法完全监测液压泵所有物理参数^[2],不能对其工作状态和性能变化进行准确预测,故采用数据驱动的分析手段成为飞机液压泵故障预测诊断及趋势变化分析的有效工具^[3]。采集能有效表征飞机液压泵性能变化趋势的参数,进行飞机性能变化趋势预测分析,对飞机视情维修及事后保障都有重大意义。

目前,在工程中应用较为广泛的性能趋势预测分析方法中,多项式拟合法模型建立较简单,但预测准确度较低^[4]。人工神经网络对于数据量比较少的样本信息的适用能力较弱,网络结构不易确定且冗余过大,模型的训练时间难以把控,实时性较差^[5]。支持向量机则容易因参数的优化问题无法输出最优解,模型还有待改进^[6]。针对上述问题,笔者将长短

期记忆神经网络和自回归积分滑动平均模型结合起来,对飞机液压泵回油流量数据进行了预测,建立性能趋势预测模型,提升预测精度的同时避免了陷入局部最小值的风险。经实验验证,该模型的精确性和稳定性都高于传统模型,能够较好地实现对液压泵性能变化趋势的预测,有一定的工程实际意义。

1 ARIMA 预测模型

时间序列也称为动态数列,是一种定量预测分析参数未来可能值的方法,通过对时间序列数据的分析,根据事物发展的连续性规律,通过统计分析来建立趋势外推的数学模型^[7]。时间序列分析法也称为时间序列预测法、历史外推法或外推法^[8]。ARIMA模型作为时间序列分析法的一种,因其简便性与稳定性得到了广泛的使用。

该模型首先将非平稳时间序列转化为平稳的时间序列,然后仅对因变量的现值和滞后值以及随机误差项的现值和滞后值进行回归运算并建立模型^[9]。使用该模型的前提条件是需要进行分析的时间序列必须是平稳的非白噪声序列。若序列非平稳则需要差分处理,直到得到平稳序列。

* 国家自然科学基金资助项目(51605309);航空科学基金资助项目(201933054002,20163354004);辽宁省教育厅基金资助项目(JYT2020021)

收稿日期:2019-11-06;修回日期:2019-12-09

ARIMA模型通用表达式为

$$\Phi(L)(1-L)^d y_t = \varepsilon + \Theta(L)\varepsilon_t \quad (1)$$

其中： $\Phi(L) = 1 - \lambda_1 L - \lambda_2 L^2 - \dots - \lambda_p L^p$ ，为 p 阶自回归系数多项式； $\Theta(L) = 1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q$ ，为 q 阶移动平均系数多项式； L 为滞后算子； λ 和 θ 分别为各自变量的估计值； $y_t = c + y_{t-1} + \mu_t$ ，为 d 阶单整序列； c 为常数； μ_t 为平稳序列； $t = 1, 2, \dots, T$ ； ε_t 为均值是0、方差为 σ^2 的白噪声序列。

2 LSTM预测模型理论

与传统的前馈神经网络模型相比，循环神经网络(recurrent neural network, 简称RNN)将隐含层的节点相互连接起来，使从输入层到隐含层的信息在隐含层实现定向循环，即隐藏层的输入不仅包括来自输入层的输出，还有来自上一时刻隐藏层的输出，有效提高了处理时间相关性大数据的能力^[10]。但是，在当前信息与先前信息时间间隔较大时，不可避免地会出现梯度消失的问题，而LSTM可有效解决这个问题。

2.1 LSTM网络模型结构

LSTM网络作为新型深度学习网络，属于RNN的一种。相比于传统的RNN，LSTM网络在每一个隐含层神经元中加入了1个由1个存储单元和3个逻辑门组成的记忆模块，能够实现读取、写入和保存的功能，使网络在梯度传播的过程中具有保存反馈误差的功能，大大提高了网络收敛性，使网络不易陷入局部最优解^[11]。3个逻辑门分别为输入门、遗忘门和输出门。LSTM网络记忆单元结构如图1所示。

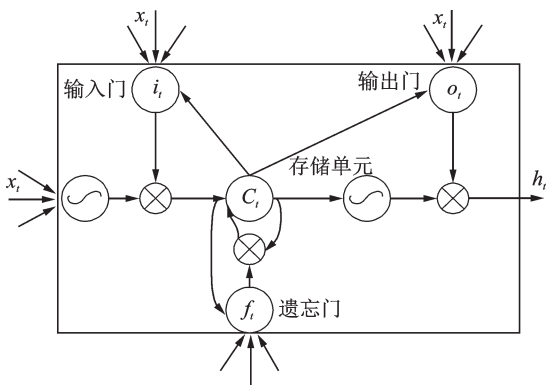


图1 LSTM网络记忆单元结构图

Fig.1 LSTM network memory unit structure

2.2 LSTM网络数学模型

图1中的神经元即为循环神经网络中的隐含层神经元，加入长短期记忆模块结构后，使网络具备了学习长期信息的能力。该记忆模块的3个逻辑门会同时接收当前时刻来自输入层的状态信息和上一个

记忆模块的输出结果，并加入了当前记忆单元的状态，由逻辑函数(S型函数)进行激活计算。

该神经元状态的输出为

$$c_t = f_t c_{t-1} + i_t \tanh(W_{xc} x_t + W_{hc} h_{t-1} + b_c) \quad (2)$$

其中： c_{t-1} 为第 $t-1$ 个神经元的输出； f_t 和 i_t 分别为遗忘门和输入门的输出结果； W_{xc} 为从网络的输入层到当前隐含层的网络权重系数； W_{hc} 为从上一个记忆模块到当前记忆模块的网络权重系数； h_{t-1} 为上一个记忆模块的输出结果； b_c 为当前记忆模块的偏置。

信息在3个逻辑门中的计算过程^[12]如下。

1) 输入门。输入门接收来自输入层的当前信息 x_t 和上一时刻的隐藏状态 h_{t-1} ，通过S型函数对不同来源的信息进行计算，决定是否激活。输入门输出的计算公式为

$$i_t = s(W_{xi} x_t + W_{hi} h_{t-1} + W_{ci} c_{t-1} + b_i) \quad (3)$$

其中： $s(\cdot)$ 为输入门的激活函数； W_{xi} 为网络输入层到隐含层中当前记忆模块的权重； W_{hi} 为上一个记忆模块到当前记忆模块输入门的权重； h_{t-1} 为上一个记忆模块的输出； W_{ci} 为上一个神经元状态到当前输入门的权重； b_i 为输入门的偏置。

2) 遗忘门。遗忘门的主要功能是对记忆单元的数据进行处理，并选择是否保留上一个记忆单元的状态，然后将处理结果与输入门处理过的状态信息相叠加，形成新的记忆单元状态。遗忘门输出的计算公式为

$$f_t = s(W_{xf} x_t + W_{hf} h_{t-1} + W_{cf} c_{t-1} + b_f) \quad (4)$$

其中： W_{xf} 为从网络输入层到隐含层当前记忆模块中遗忘门的网络权重； W_{hf} 为上一个(即第 $t-1$)记忆模块输出到当前记忆模块遗忘门的权重； W_{cf} 为上一个状态神经元到当前记忆模块遗忘门的网络权重； b_f 为遗忘门的偏置。

3) 输出门。输出门主要依据上一个记忆单元的输出，并结合当前遗忘门的动态控制来决定当前LSTM记忆模块的输出。输出门输出的计算公式为

$$o_t = s(W_{xo} x_t + W_{ho} h_{t-1} + W_{co} c_t + b_o) \quad (5)$$

其中： W_{xo} 为输入层到当前隐含层输出门的网络权重； W_{ho} 为上一个记忆模块到当前记忆模块输出门的网络权重； W_{co} 为上一个状态神经元到当前输出门的网络权重； b_o 为当前输出门的偏置。

3 飞机液压泵性能趋势预测模型的建立

3.1 数据的来源与分析

笔者以某型飞机液压泵为研究对象，对飞机液压泵的性能变化趋势开展预测研究。首先，通过专

用实验平台中的传感器网络获取该液压泵的性能表征参数;其次,结合工程经验分析采集的参数数据,得知液压泵长期工作在高强度的环境中,由于油液污染和颗粒磨损等原因,液压泵的内泄漏量逐渐增大,导致回油流量随时间不断增大,使飞机液压泵出口压力和流量逐渐减小,飞机液压泵性能也随之降低^[13],直到回油流量值大于某一阈值(一般为 2.8L/min)时,飞机液压泵的工作性能将会进入失效状态,剩余使用寿命快速减少,严重影响飞机的正常运行。因此,笔者以回油流量作为飞机液压泵性能表征参数,对该型号飞机液压泵的性能变化趋势进行研究。

结合实际工程经验分析数据结构可知,回油流量数据序列随着时间呈逐渐上升的趋势,是一个非平稳、带有近似线性趋势的序列 $\{x_t\}$, 可以将其分解为趋势项 $\{x_{t1}\}$ 和细节项 $\{x_{t2}\}$, 分别进行预测研究。具体线性分解公式为

$$x_{t1} = \begin{cases} \frac{1}{t} \sum_{j=0}^t x_j & (t \leq k) \\ \frac{1}{k} \sum_{j=t-k}^t x_j & (k < t \leq n) \end{cases} \quad (6)$$

$$x_{t2} = x_t - x_{t1} \quad (7)$$

其中: k 为光滑系数,多次实验后取 $k=25$ 。

在分解数据后,通过研究分析可知,趋势项数据变化趋势较为平缓,数据的波动性不强,故采用对近线性时间序列适应性更好的 ARIMA 预测模型对其进行预测分析。细节项数据主要由回油流量数据中的随机部分组成,数据呈现较为明显的波动性,故采用对随机信息处理能力强的 LSTM 深度学习模型进行预测。

3.2 基于 ARIMA-LSTM 预测模型的建立

图 2 为基于 ARIMA-LSTM 液压泵性能变化趋势预测流程。使用分解后的趋势项数据和细节项数据分别建立 ARIMA 预测模型和 LSTM 预测模型,并对分解后的数据进行预测。将 2 个模型得到的结果进行叠加,得到最终的预测结果,具体流程如图 2 所示。

采用 ARIMA-LSTM 方法对飞机液压泵性能变化趋势进行预测,可分为以下 3 个部分。

3.2.1 对趋势项数据进行预测

趋势项数据的预测分为 4 个步骤。

1) 数据平稳性检验。数据的平稳性对时间序列分析结果有着重要影响,一般使用时序图检验法和自相关以及偏相关系数图对数据的平稳性进行检

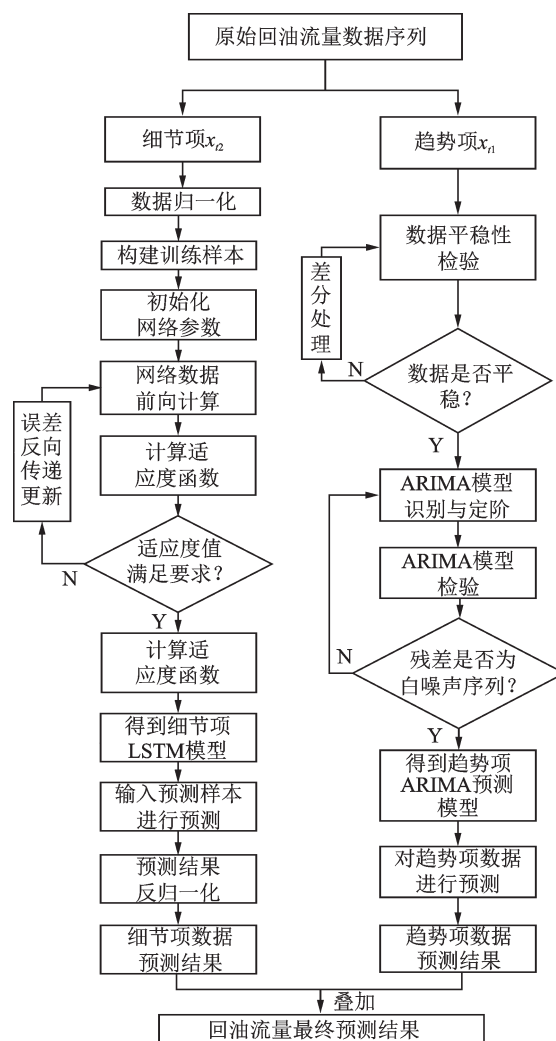


图 2 基于 ARIMA-LSTM 液压泵性能变化趋势预测流程
Fig.2 Hydraulic pump performance change trend prediction process based on ARIMA-LSTM

验。若数据不平稳,则需要对其进行适当的差分处理并重新检验,直到数据平稳为止。其中,差分处理的次数就是 ARIMA(p, d, q) 中的阶数^[14]。通过时序图检验法检验得知,细节项数据为非平稳数据,需要进行差分处理。

2) 模型的识别与定阶。模型的识别是指根据时间序列的自相关函数和偏自相关函数的截尾和拖尾性来初步判断适合的模型类型。模型的识别判定方法如表 1 所示。

依据模型自相关函数的特性,确定模型的阶数,

表 1 模型的识别判定方法

模型	自相关函数	偏自相关函数
AR(p)	拖尾性	截尾性
MA(q)	截尾性	拖尾性
ARMA(p, q)	拖尾性	拖尾性

使用模型识别后得到赤池信息准则(akaike information criterion, 简称 AIC) 统计量、许瓦兹检验(schwarz criterion, 简称 SC) 统计量以及异方差准则(heteroskedasticity criterion, 简称 HC) 统计量, 并依据最小信息准则来比较3种统计量的大小, 最终确定模型为 ARIMA(5, 1, 5), 其中 AIC 值为 -9.2139 。

3) 模型的参数估计与检验。模型的参数估计通常使用最小二乘估计法和极大似然估计法等。由于最小二乘估计法计算量较小, 且精度满足估计要求, 故笔者采用最小二乘估计法对参数进行估计^[15]。模型的残差检验主要是判断残差序列是否能够通过白噪声序列检验。若通过检验, 则模型可以对未来的数据进行预测; 若模型不通过检验, 则需要重新拟合直至残差序列能够通过白噪声检验为止^[16]。

4) 趋势项预测。将 520 个趋势项数据分为 52 组, 每组 10 个, 将前 50 组数据作为训练数据, 对后 2 组数据值进行预测, 得到趋势项预测结果。

3.2.2 对细节项数据进行预测

细节项数据的预测分为 5 个步骤。

1) 数据归一化。为提升神经网络模型的训练效果, 需要将数据进行归一化处理, 使归一化后的数据在 $-1 \sim 1$ 之间。

2) 构成训练数据与测试数据。细节项数据共有 520 个, 将前 500 个数据作为模型的训练数据, 向后预测 20 个数据, 第 501~520 原始数据作为对比数据。对 500 组数据分别进行相空间重构, 重构嵌入维度为 12, 得到模型输入数据矩阵维度为 480×12 , 重构后的训练模型输出数据矩阵维度为 480×5 , 输入输出数据同时输入到网络中进行训练。

3) 构建网络。LSTM 输入神经元个数为 12, 输出神经元个数为 5, 隐含层神经元个数为 18, 模型迭代次数为 500。在模型训练过程中, 通过计算模型的适应度函数值来判断模型是否达到精度要求。当模型达到精度要求时, 则输出构建好的 LSTM 网络; 若模型未达到精度要求, 则需通过误差反向传递更新不断修正模型, 直到模型达到预测精度的要求。

4) 细节项预测。将重构后前 500 个输入输出数据同时代入 LSTM 进行训练, 得到细节项的 LSTM 预测模型。将后 20 个数据的输入代入预测模型, 得到细节项预测结果。

5) 反归一化。将得到的 LSTM 模型预测结果反归一化, 还原细节项的预测结果。

3.2.3 得到最终预测结果

将趋势项预测结果与细节项预测结果叠加, 得到最终 ARIMA-LSTM 组合预测结果。

4 实验验证

4.1 数据的预处理

在实验中, 对所获取的参数数据进行预处理, 剔除干扰数据, 选择其中时间关联性较强的数据作为实验数据, 以此来保证实验数据的有效性。在整个实验过程中, 在实验连续时间内获取回油流量数据, 采集 250 个数据。由于数据量较小, 且只能观测单一指标的时间序列, 无法有效寻找数据间的潜在关系^[17], 故笔者对数据进行插值处理, 将数据扩大为 500 个。将数据进行分解后, 选择适当的嵌入维度对趋势项数据进行相空间重构。将原始的一维时间序列转化为多维相空间矩阵, 利用重构好的矩阵数据进行网络建模和测试。

4.2 实验结果

为了验证 ARIMA-LSTM 模型的预测效果, 笔者将 ARIMA-LSTM 模型、单一的 ARIMA 模型和单一的 LSTM 模型对回油流量的预测结果与真实值进行对比。ARIMA-LSTM 模型与单一模型预测效果对比如图 3 所示。可以看出, 飞机液压泵的回油流量随着采样点数的增加而逐渐增大, 呈近线性、非平稳上升的趋势。这说明随着回油流量的增加, 飞机液压泵的性能逐渐下降, 3 种预测模型均可描述飞机液压泵性能变化趋势, 实现了预测的效能。

通过对 2 种模型预测值与真实值接近程度的比较, 可以看出 ARIMA-LSTM 模型对回油流量的预测曲线与真实值曲线的贴合程度明显优于单一的 ARIMA 模型和单一的 LSTM 模型。ARIMA-LSTM 模型的预测效果更好, 其细节项预测模型预测均方误差如图 4 所示。由图 4 可以看出, LSTM 细节项预测模型在迭代到约 900 时, 达到了收敛, 模型实现了预测精度最优化。

趋势项预测模型全部样本预测误差如图 5 所示。从图 5 可以看出, ARIMA 趋势项预测模型的预




图3 ARIMA-LSTM模型与单一模型预测效果对比
Fig.3 Comparison of ARIMA-LSTM model and single model prediction




图 4 细节项预测模型预测均方误差

Fig.4 Detailed item prediction model predicting mean square error

测误差值维持在 0.1 以下,对趋势项数据实现了较为准确的预测。




图 5 趋势项预测模型全部样本预测误差

Fig.5 Prediction error of all samples of the trend term prediction model

基于 ARIMA-LSTM 模型的第 51,52 组数据预测结果如图 6 所示。可以看出,ARIMA-LSTM 模型预测得到的回油流量曲线和回油流量真实值曲线的贴合程度很高,证明了 ARIMA-LSTM 模型对回油流量数据预测效果良好,具有较高的预测精度,适用于液压泵性能变化趋势的预测。

3 种模型最后 2 组测试样本的预测结果如表 2

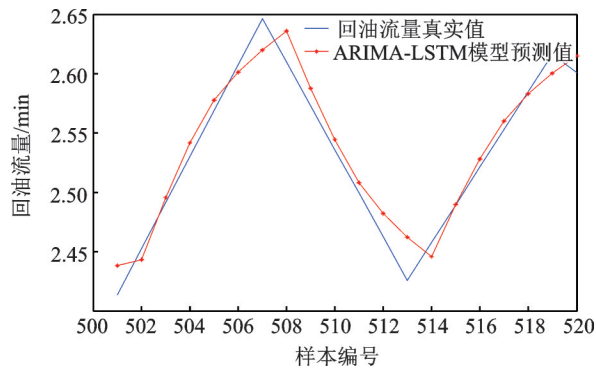


图 6 ARIMA-LSTM 模型第 51,52 组数据预测结果

Fig.6 ARIMA-LSTM model group 51, 52 data prediction results

所示。3 种预测模型的相对平均误差如表 3 所示。

表 2 3 种预测模型的预测结果

Tab.2 Prediction results of three prediction models				
编号	真实值	ARIMA 预测值	LSTM 预测值	ARIMA-LSTM 预测值
481	2.568 833	1.821 871	2.505 994	2.524 102
482	2.598 45	1.851 433	2.547 564	2.589 125
483	2.607 616	1.832 411	2.645 121	2.684 484
⋮	⋮	⋮	⋮	⋮
499	2.586 4	2.656 38	2.579 873	2.601 500
500	2.581 316	2.611 435	2.568 713	2.581 560

表 3 3 种预测模型的相对平均误差

Tab.3 Relative average error of three prediction models				%
模型类别	LSTM	ARIMA	ARIMA-LSTM	
平均误差	6.28	19.26	4.99	

通过计算 3 种模型的预测结果与相对平均误差可以看出,ARIMA-LSTM 模型的预测精度达到了约 95.01%,高于单一 ARIMA 模型的精度 80.74% 和单一 LSTM 模型的精度 93.72%,对液压泵回油流量数据预测效果更好。

5 结束语

实验结果表明,ARIMA-LSTM 预测模型通过将飞机液压泵回油流量数据拆分为趋势项数据和细节项数据,分别建立 ARIMA 预测模型和 LSTM 网络模型来对数据进行预测。将趋势项和细节项预测结果叠加,得到最终回油流量预测结果,采用某型飞机液压泵真实实验数据与预测结果进行对比验证。结果表明,相比于单一的 LSTM 和 ARIMA 预测模型,ARIMA-LSTM 模型有针对性地处理了具有非平稳特性的回油流量数据的不同组成部分,使飞机液压泵性能参数变化趋势的预测精度明显提升,能有效分析飞机液压泵的性能变化趋势,具有较高的工程实用价值。

参 考 文 献

[1] 赵四军,王少萍,尚耀星.飞机液压泵源预测与健康管理系统[J].北京航空航天大学学报,2010,36(1): 14-17.
ZHAO Sijun, WANG Shaoping, SHANG Yaoping.

- Aircraft hydraulic pump source prediction and health management system [J]. Journal of Beijing Aerospace University, 2010, 36(1):14-17. (in Chinese)
- [2] 欧阳小平, 杨华勇, 郭生荣, 等. 现代飞机液压技术 [M]. 杭州: 浙江大学出版社, 2016: 20-21.
- [3] GOMES J P P, RODRIGUES L R, LEAO B P, et al. Using degradation messages to predict hydraulic system failures in a commercial aircraft [J]. IEEE Transactions on Automation Science & Engineering, 2018, 15(1):214-224.
- [4] LYU J C, ZHANG J. BP neural network prediction model for suicide attempt among Chinese rural residents [J]. Journal of Affective Disorders, 2018, 246(1):465-473.
- [5] HAN J W, LI X Q, WU H R, et al. Prediction of cooling efficiency of forced-air precooling systems based on optimized differential evolution and improved BP neural network [J]. Applied Soft Computing Journal, 2019, 84:1-12.
- [6] JIA Z Y, MA J W, WANG F J, et al. Hybrid of simulated annealing and SVM for hydraulic valve characteristics prediction [J]. Expert Systems with Applications, 2011, 38(7):8030-8036.
- [7] 杨秀媛, 肖洋, 陈树勇. 风电场风速和发电功率预测研究 [J]. 中国电机工程学报, 2005(11):1-5.
- YANG Xiuyuan, XIAO Yang, CHEN Shuyong. Research on wind speed and power generation prediction of wind farms [J]. Proceedings of the CSEE, 2005(11):1-5. (in Chinese)
- [8] TRAN D T, IOSIFIDIS A, KANNIAINEN J, et al. Temporal attention-augmented bilinear network for financial time-series data analysis [J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(5):1-12.
- [9] 王振雷, 唐苦, 王昕. 一种基于D-S和ARIMA的多模型软测量方法 [J]. 控制与决策, 2014, 29(7):1160-1166.
- WANG Zhenlei, TANG Ku, WANG Xin. A multi-model soft measurement method based on D-S and ARIMA [J]. Control and Decision, 2014, 29(7):1160-1166. (in Chinese)
- [10] 张艳霞, 赵杰. 基于反馈型神经网络的光伏系统发电功率预测 [J]. 电力系统保护与控制, 2011, 39(15):96-101, 109.
- ZHANG Yanxia, ZHAO Jie. Prediction of power generation in photovoltaic system based on feedback neural network [J]. Power System Protection and Control, 2011, 39(15):96-101, 109. (in Chinese)
- [11] YU X, XU L, MA L, et al. Solar radio spectrum classification with LSTM [C] // 2017 IEEE International Conference on Multimedia & Expo Workshops. [S.l.]: IEEE, 2017.
- [12] 朱洪涛, 陈品帮, 魏晖, 等. 基于轨道数据对齐的ARIMA模型的轨道不平顺预测 [J]. 振动、测试与诊断, 2019(3):596-602.
- ZHU Hongtao, CHEN Pinbang, WEI Hui, et al. Prediction of track irregularities using ARIMA model based on orbit data alignment [J]. Journal of Vibration, Measurement & Diagnosis, 2019(3):596-602. (in Chinese)
- [13] 贺凯歌, 沈骋恺, 王鹏. 某型液压泵回油流量超标故障原因分析 [J]. 航空维修与工程, 2019(1):87-88.
- HE Kaige, SHEN Chengkai, WANG Peng. Analysis of the cause of the failure of the return flow of a certain type of hydraulic pump [J]. Aviation Maintenance and Engineering, 2019(1):87-88. (in Chinese)
- [14] 窦慧丽, 刘好德, 吴志周, 等. 基于小波分析和ARIMA模型的交通流预测方法 [J]. 同济大学学报(自然科学版), 2009, 37(4):486-489, 494.
- DOU Huili, LIU Haode, WU Zhizhou, et al. Traffic flow prediction method based on wavelet analysis and ARIMA model [J]. Journal of Tongji University (Natural Science), 2009, 37(4):486-489, 494. (in Chinese)
- [15] 彭月. ARIMA模型的介绍 [J]. 电子世界, 2014(10):259.
- PENG Yue. Introduction of ARIMA model [J]. Electronic World, 2014(10):259. (in Chinese)
- [16] 张利. 基于时间序列ARIMA模型的分析预测算法研究及系统实现 [D]. 镇江: 江苏大学, 2008.
- [17] 崔建国, 李慧华, 于明月, 等. 基于LSSVM与WNN的燃气轮机状态趋势预测 [J]. 火力与指挥控制, 2018, 43(8):160-163, 167.
- CUI Jianguo, LI Huihua, YU Mingyue, et al. State trend prediction of gas turbines based on LSSVM and WNN [J]. Fire Control & Command Control, 2018, 43(8):160-163, 167. (in Chinese)



第一作者简介: 崔建国, 男, 1963年8月生, 教授。主要研究方向为飞行器健康诊断、预测与综合健康管理等。曾发表《基于遗传算法和ARMA模型的航空发动机寿命预测》(《航空学报》2011年第32卷第8期)等论文。

E-mail: gordon_cjg@163.com