

基于 ARIMA-BP-LSTM 的无人机备件筹措预测方案

黄虹霞, 吴心怡, 万刚远, 陈思睿

江西科技学院, 江西 南昌 330098

DOI: 10.61369/IED.2024120006

摘 要 : 无人机备件已成为保障无人机持续作战能效的必需品, 为在备件采购筹措时精准预测无人机备件需求数量, 提供采购决策依据, 本文提出一种基于 ARIMA-BP-LSTM 无人机备件筹措预测方案。通过 ARIMA 和 BP 神经网络对预处理数据集进行重构生成训练数据集, 然后利用训练数据集训练 LSTM 神经网络得到无人机备件筹措预测模型, 进而对无人机备件需求进行预测。实验结果表明, 本文所提方案与传统的 LSTM 时间序列预测方案相比, 本文所提方案误差减少 1.33%, 更为精准, 可为无人机备件的采购筹措提供支撑。

关 键 词 : ARIMA; BP 神经网络; LSTM 神经网络; 无人机备件筹措

UAV Spare Parts Procurement Forecasting Scheme Based on ARIMA-BP-LSTM

Huang Hongxia, Wu Xinyi, Wan Gangyuan, Chen Sirui

Jiangxi University of Technology, Nanchang, Jiangxi 330098

Abstract : UAV spare parts have become essential to ensure the continuous operational efficiency of drones. To accurately predict the demand for UAV spare parts during procurement and provide a basis for purchasing decisions, this paper proposes a UAV spare parts procurement forecasting scheme based on ARIMA-BP-LSTM. The preprocessed dataset is reconstructed using ARIMA and BP neural networks to generate a training dataset. Then, the LSTM neural network is trained using this dataset to obtain a prediction model for UAV spare parts procurement, which is used to forecast the demand for UAV spare parts. Experimental results show that the proposed scheme reduces the error by 1.33% compared to traditional LSTM time series forecasting methods, providing more accurate results. This scheme can support the procurement of UAV spare parts.

Keywords : ARIMA; BP neural network; LSTM neural network; UAV spare parts procurement

引言

科学智能技术日益发展, 促使无人机成为智能科技焦点。战场生存能力强、作战环境要求低、体积小、造价低等优点, 使得无人机对未来空战具有重要意义^[1-2]。各军事强国正在对无人机进行大力研制, 预计 2022-2025 年全球军用无人机市场规模有望从 165 亿美元增长至 343 亿美元, 年复合增长率可高达 27.6%^[3-4]。

作为无人机必需品, 无人机备件在维护、保养和维修任务中占据重要地位。然而无人机备件消耗受使用环境、备件寿命等多重因素影响, 仅依靠人的经验难以明确采购筹措的数额需求。不确定性的采购筹措数量给军队采购无人机备件带来不便的同时也造成不合理的库存结构, 从而降低无人机备件利用率, 导致无人机作战效能下降。因此通过科学的预测技术精准确定无人机备件的采购数量需求非常重要, 然而无人机作为新型武器装备, 基础信息如供应商、编号等无法为备件数量预测提供决策依据, 如何基于时间属性构建无人机备件预测模型, 分析无人机备件内在数量关系成为一大挑战^[5-6]。

为实现精准确定无人机备件的采购数量需求, 本文设计了一种基于 ARIMA-BP-LSTM 无人机备件筹措预测方案。本文贡献如下:

(1) 对无人机备件原始数据集处理的方法。首先按照采购筹措时间整理原始数据集获得预处理数据集, 再通过 ARIMA 算法分析预处理数据集得到线性部分拟合数据集, 进而通过 BP 神经网络获得非线性部分拟合数据集, 接着通过 BP 神经网络初步探索预处理数据集得到探索数据集, 最后将线性部分拟合数据集、非线性部分拟合数据集和探索数据集组合成训练数据集, 以供后续预测模型的训练。

(2) 经过实验表明, 本方案与传统的 LSTM 预测方案相比, 误差可减少 1.33%, 更为精准, 可为无人机备件的采购筹措提供支撑。

一、预备知识

(一) ARIMA 模型

ARIMA 全称差分自回归移动平均模型,是目前最常用的拟合平稳时间序列的模型^[7-8]。ARIMA(p,d,q)中,AR为自回归、MA为移动平均、p为自回归项数、q为移动平均项数、d为差分时间序列数据的差分次数。以p、d、q为参数的ARIMA模型如式(1)所示。

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + \varepsilon_t + \theta_0 + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (1)$$

其中: X_t 为时间序列的样本值, $\varphi_i (i=1,2,\dots,p)$ 和 $\theta_i (i=1,2,\dots,q)$ 为模型参数, ε_t 为独立正态分布的白噪声。

(二) BP神经网络

BP神经网络是一种按误差逆传播算法训练的多层前馈网络,是应用最广泛的神经网络模型之一^[9],可逼近任意连续函数,具有很强的非线性映射能力,可用于处理分类、预测问题。BP神经网络模型拓扑结构包含输入层、隐含层和输出层,如图1所示。




图1 BP神经网络结构

(三) LSTM神经网络

LSTM神经网络全称长短期记忆神经网络,是一种时间循环神经网络^[10]。LSTM被用于解决RNN(循环神经网络)在随时间反向传播中权重消失的问题,其非常适合处理与时间序列高度相关的问题。

二、本文方案

(一) 原始无人机备件数据处理

依据采购筹措时间处理原始数据集。对于无人机备件原始消耗数量的时间序列数据集 $S = \{x_i : i=0,1,2,\dots,n\}$, x_i 记录的是每天该备件消耗的数量。然而无人机备件进行采购筹措时,往往按季度、半年或者年度进行采购,因此为实现按采购时间段进行预测,对原始数据集 S 按照季度、半年或者年度进行数据的求和,得出预处理数据集 $S_1 = \{x_i : i=0,1,2,\dots,m\}$ 。

使用ARIMA拟合预处理数据集的线性部分数据。本文认为无

人机备件的预处理数据集可分解为线性和非线性两部分,数学表达如式(2)所示。

$$x_t = l_t + nl_t \quad (2)$$

其中, l_t 为原始数据的线性部分, nl_t 为原始数据的非线性部分。通过ARIMA模型对预处理数据 x_t 进行拟合得到线性部分拟合数据 $\hat{l}_t$, 再通过式(3)得到残差 e_t 。

$$e_t = x_t - \hat{l}_t \quad (3)$$

使用BP神经网络拟合原始数据的非线性部分数据。由于认为预处理数据可分解为线性和非线性两部分,在ARIMA模型中,若模型被很好地定义,则统计检验不应在残差序列上找到线性相关性,即残差 e_t 可认为是预处理数据的非线性部分。通过BP神经网络对残差 e_t 进行拟合得到非线性部分拟合数据值 $\hat{e}_t$ 。

使用BP神经网络初步探索 $\hat{l}_t$ 、 e_t 与 x_t 的关系。预处理数据可分解为线性和非线性两部分,但线性部分拟合数据和非线性部分拟合数据进行累加关联可能会导致预测性能的下降,因为并没有直接方式表明原始数据等价于线性预测值和非线性预测值的累加^[11-12]。因此,本文再次使用BP神经网络初步探索 x_t 中的非线性部分数据,以 x_t 作为BP神经网络的输入, x_t 再作为真实值,通过训练BP神经网络得出探索数据值 $\hat{x}_t$, 便于提高后续深度神经网络的训练速度和效果。

将 x_t 、 $\hat{l}_t$ 、 $\hat{e}_t$ 、 $\hat{x}_t$ 组合成训练数据集 S_2 , 即 $S_2 = \{x_t, \hat{l}_t, \hat{e}_t, \hat{x}_t\}$, 完成对原始无人机备件数据的处理。

(二) LSTM神经网络预测

无人机备件的消耗量与时间序列往往存在一定的长期依赖关系,然而BP神经网络作为浅层神经网络,并不会考虑数据的时序性,因此预测模型选择具有记忆功能的LSTM神经网络成为最佳选择。

因此本文借助LSTM神经网络工具构建了一种ARIMA-BP-LSTM预测模型。在获得训练数据集 S_2 后,用训练数据集训练LSTM模型,通过LSTM深度神经网络去挖掘更深层次的时间序列数量关系,最终得到无人机备件预测值 $\hat{x}_t$, 如式3所示。

$$\hat{x}_t = g(x_t, \hat{l}_t, \hat{e}_t, \hat{x}_t) \quad (4)$$

其中, $g(\cdot)$ 为非线性函数,通过LSTM网络模型实现。

(三) 整体方案

本文无人机备件整体方案主要包括两个部分,分别为对原始数据处理及LSTM神经网络预测,整体方案结构如图2所示。




图2 无人机备件筹措预测整体方案

三、实验

(一) 实验环境及评价指标

本文实验环境为PC机，Windows10 64位系统，i7-1075H主频3.59GHz，内存16G，使用Spyder和Python实验平台。为了验证方案的有效性，本文以某型无人机航电系统备件消耗数据为实验数据集，经过预处理后共37条数据，以前32条作为训练数据集，后5条作为测试数据集，整个数据如1所示。




图3 预处理的无人机备件实验数据集

为了验证方案的有效性，本文选用传统LSTM的时间序列预测方案作为对比，以平均绝对百分误差（MAPE）作为本文实验的评价指标，如式（5）所示。

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{f_t - d_t}{d_t} \right| \times 100\% \quad (5)$$

(二) 实验结果及分析

本文主要进行两次实验，第一次实验主要验证所提方案对无人机航电模块消耗量的拟合效果，如图4所示。




图4 预测模型对无人机备件数量拟合效果

由图4可知，本方案可有效拟合无人机航电模块消耗量，经计算训练数据集的平均绝对百分误差为0.36%，误差小于1%，效果良好。

第二次实验旨在验证所提方案的有效性。为直观比较，本方案与传统LSTM时间序列预测方案平均绝对百分误差见表1所示。

表1 方案平均绝对百分误差对比表

方案	平均绝对百分误差
本方案	1.78%
传统LSTM预测方案	3.11%

由表1可知，采用本文所提方案平均绝对百分误差为1.78%，而传统LSTM预测方案为3.11%，相比之下，本文所提方案误差减少1.33%，这表明文本所提方案是有效的，能够更为精准的预测无人机备件消耗数量。

四、结论

无人机诸多优点使得其成为当今各军事强国研制重点。作为无人机必需品，为实现在采购筹措时对无人机备件数量进行精确预测，本文设计了一种基于ARIMA-BP-LSTM无人机备件筹措预测方案。经实验表明，本方案在无人机备件筹措预测中表现良好，且与传统LSTM预测方案相比，本文所提方案误差减少1.33%，更为精准，可为无人机备件采购筹措提供支撑，为保障无人机作战能效奠定基础。