

基于 Autoencoder-TCN 的航空发动机排气温度预测

孔晨亦, 李学仁, 杜 军

(空军工程大学航空工程学院, 西安, 710038)

摘要 针对目前航空发动机排气温度预测模型精度不高、传统 RNN 类神经网络对飞行数据时间维度信息挖掘不充分的问题,提出了一种结合自编码器 Autoencoder 和时间卷积神经网络 TCN 的航空发动机排气温度预测模型。首先通过 Autoencoder 方法从飞行数据中提取与排气温度相关的特征,以降维后的特征作为输入,建立 TCN 网络深度学习模型,以航空发动机排气温度作为输出,充分挖掘飞行数据的时间维度信息,从而提高模型精度。最后选取真实飞行数据进行实验,结果表明,与 BP、LSTM 神经网络模型相比,该模型的平均绝对百分比误差由 13.035% 和 9.593% 降低至 3.369%,有效提高了模型预测精度。

关键词 航空发动机;排气温度;自编码器;时间卷积神经网络

DOI 10.3969/j.issn.1009-3516.2020.05.009

中图分类号 V239 **文献标志码** A **文章编号** 1009-3516(2020)05-0055-07

Prediction of Aeroengine Exhaust Gas Temperature Based on Autoencoder-TCN Model

KONG Chenyi, LI Xueren, DU Jun

(Aerospace Engineering College, Air Force Engineering University, Xi'an 710038, China)

Abstract Aimed at the problems that the prediction of aero-engine exhaust gas temperature is low in precision, and the mining of the time dimension information of flight data by traditional RNN neural networks is inadequate, an exhaust gas temperature prediction model is proposed in combination with Autoencoder neural network and temporal convolutional network (TCN). First, the features related to the exhaust gas temperature (EGT) from the flight data are extracted by the Autoencoder method, and then the reduced-dimensional features are taken as the input to build up a TCN network deep learning model. Secondly, the exhaust gas temperature of the aero-engine is used as the output to fully mine the flight data dimensional information, improving model accuracy. Finally, the actual flight data is selected to be an experiment. The results show that compared BP to LSTM, the average absolute percentage error is reduced from 13.035%, 9.593% to 3.369% respectively, effectively improving the prediction accuracy of the model.

Key words aero-engine; exhaust gas temperature; Autoencoder networks; temporal convolutional networks

排气温度(Exhaust Gas Temperature, EGT)是 表征航空发动机健康状态和确定发动机可用性的重

收稿日期: 2020-06-22

基金项目: 国家自然科学基金(61573373)

作者简介: 孔晨亦(1996—),男,浙江丽水人,硕士生,主要从事智能检测与健康管理研究。E-mail: kcy1921@163.com

引用格式: 孔晨亦, 李学仁, 杜军. 基于 Autoencoder-TCN 的航空发动机排气温度预测[J]. 空军工程大学学报(自然科学版), 2020, 21(5): 55-61. KONG Chenyi, LI Xueren, DU Jun. Prediction of Aeroengine Exhaust Gas temperature based on Autoencoder-TCN Model[J]. Journal of Air Force Engineering University (Natural Science Edition), 2020, 21(5): 55-61.

要时间序列参数之一^[1],高精度的 EGT 预测模型可为维修决策提供重要支持。由于航空发动机是一个典型的复杂系统,排气温度又与多种因素呈现复杂非线性关系^[2],因此难以构造精确数学模型来描述 EGT 的变化规律。

目前使用的预测方法有最小二乘法、支持向量机、人工神经网络等^[3-5]。近年来,随着人工智能技术的不断发展,由于人工神经网络对复杂非线性系统具有高度的拟合性,其在排气温度预测方面应用广泛。Yusuf 等^[6]研究了发动机转速、燃料流量、进气管平均温度等参数作为输入层,排气温度作为输出的人工神经网络预测模型。陈庆贵等^[7]使用径向基过程神经网络来实现航空发动机排气温度预测。Kumar 等^[8]利用自回归神经网络并结合移动平均技术对燃气涡轮发动机排气温度进行建模和预测。随着循环神经网络(RNN)的不断发展,衍生出长短期记忆网络(LSTM)、门控循环网络(GRU)等变体,广泛应用于时间序列数据处理。杨洪富等^[9]使用长短期记忆网络构建发动机排气温度预测模型,探究了排气温度的变化规律。张帅等^[10]设计了一种输出层增强的 LSTM 模型,进一步提高了预测精度。

时间卷积神经网络(Temporal Convolutional Network, TCN)是由 Bai S 等^[11]2018 年提出的处理时间序列模型的神经网络新架构,并且在几类数据集集中取得了比 RNN 更为准确的结果。TCN 网络在文本、视频、时序图等时间序列数据的分析中提高了预测的准确性^[12-14]。飞行数据是一类典型的时间序列数据,数据的时间关联性较强,对模型的时域信息提取能力有更高的要求。TCN 网络则是利用一维卷积变形成可用于处理时间序列数据,采用多层网络结构学习长时间跨度信息。

同时,飞行数据具有数据量大、维度高的特点,约减维度可以有效降低计算的复杂度,减少训练难度。Hilton 等^[15]利用自编码器进行数据降维实验,实验效果相比主成分分析法(Principal Component Analysis, PCA)有明显提高。宋亚等^[16]整合自编码器和双向短期记忆神经网络,构建涡扇发动机剩余寿命预测模型,有效降低了模型训练难度。

由此本文提出了 Autoencoder-TCN 混合预测模型,利用自编码器(Autoencoder)降低 TCN 网络的输入数据维度,将 EGT 作为 TCN 网络的输出,使用真实飞行数据训练模型,可以深入挖掘飞行数据的时间关联性特征,并且分别与 BP(反向传播)神

经网络和 LSTM 神经网络预测模型作对比实验,验证了预测模型的有效性。

1 基础理论

1.1 Autoencoder 神经网络

Autoencoder 神经网络利用自监督学习方式,可对输入数据进行有效降维,提取相关特征。Autoencoder 由输入层、隐藏层、输出层组成,结构分为编码器和译码器两部分,其拓扑结构见图 1。




图1 自编码器结构图

给定原始飞行数据 $x = (x_1, x_2, \dots, x_n)$, 其中 x_i 是输入数据的第 i 维度 ($i = 1, 2, \dots, n$)。给定特征空间 $H = (h_1, h_2, \dots, h_m)$, 其中 h_j 是第 j 维特征向量 ($j = 1, 2, \dots, m, m < n$)。Autoencoder 神经网络需要求解两者的映射 f, g , 使输入特征的重构误差最小:

$$\begin{aligned} f: x &\rightarrow h \\ g: h &\rightarrow x \\ f, g &= \arg \min_{f, g} \|x - g[f(x)]\|^2 \end{aligned} \quad (1)$$

采用非线性激活函数,可求解得两者映射 f, g 以及输出低维特征 H 。自编码器可学习从高维到低维的非线性映射,获得原始数据的显著特征,因此可用于深度学习网络输入数据的预训练,减少输入数据维度,降低训练难度。

1.2 时间卷积神经网络(TCN)

卷积网络的算法关键在于利用卷积操作跨区域提取特征^[14]。卷积网络普遍应用于图像领域,在时间序列数据的处理上,大多采用循环神经网络(RNN)和长短时间记忆网络(LSTM),但在 RNN 框架上很难再找到新的模型可以超越 LSTM 的学习效果。因此, Bai Shaojie^[11]将卷积神经网络改造成可用于处理时间序列数据的 TCN, 直接利用卷积的强大特性,跨时间提取特征信息。

为了更好地适应时间序列数据的处理要求, TCN 网络引入了一维全卷积(1-D FCN)和膨胀因果卷积(Dilated Casual Convolutions):

Step 1 利用 1-D FCN 结构,保证每一个隐层

的输入输出时间长度都相等,对于第一个没有任何历史信息的时间步,使用 zero padding 操作。

Step 2 为了不漏接历史信息,以及应对网络长历史信息问题,引入膨胀因果卷积,增大感受野(receptive field)的同时降低计算量,使模型能够学习到更长时间段内的信息。膨胀卷积作用在 s 元素上,可描述输出 $F(s)$ 如下:

$$F(s) = (X * _d f)(s) = \sum_{i=0}^{k-1} f(i) X_{s-di} \quad (2)$$

式中: $*_d$ 为卷积操作运算符; $f(i)$ 为卷积核, $i=0, 1, \dots, k-1$ 。

TCN 模型整体架构见图 2。




图 2 TCN 模型结构图

图中 x_t 为时间序列数据, $\hat{y}_t$ 为输出预测值, $d=1, 2, 3$ 表示膨胀卷积的空洞值, $k=3$ 表示一维卷积核尺寸(kernel size)。

2 Autoencoder-TCN 混合预测模型

2.1 总体框架

本文建立的深度学习混合预测模型首先将 Autoencoder 神经网络作为特征提取工具,将每一时间点与排气温度相关的 11 个参数降至 5 维后,再进行时序连接,得到 $5 \times t$ 的时序数据,输入到 TCN 网络进行时间信息的学习,输出排气温度的时间序列值,如图 3 所示。




图 3 混合模型结构示意图

图中, $x = (x^{(1)}, x^{(2)}, \dots, x^{(t)})$ 表示 Autoencoder 的输入空间, $x^{(j)}$ 为 m 维输入向量,本文中 $m=11$;

$h = (h^{(1)}, h^{(2)}, \dots, h^{(t)})$ 表示特征空间,由 Autoencoder 输出后经过时序连接形成,作为 TCN 网络的时间序列输入数据, $h^{(j)}$ 为 n 维特征向量,本文中 $n=5$; $y = (y^{(1)}, y^{(2)}, \dots, y^{(t)})$ 表示输出空间, $y^{(i)}$ 为排气温度数值, t 表示时间序列长度。

本文建立的 Autoencoder-TCN 混合预测模型训练过程分为特征提取、TCN 网络训练、网络性能测试 3 个阶段。

2.2 特征提取阶段

首先将飞行数据使用 Zscore 归一化处理方法,然后将归一化的数据输入 Autoencoder 网络,经过编码层进行编码,与解码层输出数据生成损失函数,自编码器的连接权值和偏置采取自适应性动量估计法(Adam)进行学习。

对于 Autoencoder 网络,本文采用线性整流函数(ReLU)作为编码层激活函数,采用 Sigmoid 函数作为解码层激活函数。

$$\text{ReLU}(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (3)$$

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

$$h_j = \text{ReLU}\left(\sum_{i=1}^m W_{i,j} x_i + b_j\right) \quad (5)$$

$$r_i = \text{Sigmoid}\left(\sum_{j=1}^n W_{j,i} h_j + b_i\right) \quad (6)$$

式中: n 为输入数据的维度, m 为隐藏神经元的个数,即降维后的维度; $W_{i,j}$ 为输入层神经元与隐藏层神经元的连接权值; $W_{j,i}$ 为隐藏层神经元与输出层神经元的连接权值; b_i, b_j 均为偏置;隐藏层中, h_j 为第 j 个神经元的输出值;输出层中, r_i 为第 i 个神经元的输出值。

损失函数如式(7)所示:

$$L(W_{i,j}, W_{j,i}, b_i, b_j) = \frac{1}{k} \sum_{p=1}^k \frac{1}{2} \|x^{(p)} - r^{(p)}\|^2 \quad (7)$$

式中: k 为批处理的总数目; $x^{(p)}$ 和 $r^{(p)}$ 分别为第 p 个样本的输入和重构向量。本文选用 Adam 优化器训练网络中的参数,使重构误差,即损失函数值最小。

2.3 TCN 网络训练阶段

使用训练好的 Autoencoder 网络提取数据集的低维特征后,作为 TCN 网络训练样本,利用 Adam 优化器训练 TCN 网络参数。

对于 TCN 的网络结构,使用 ReLU 函数作为激活函数,能够有效避免深度学习网络梯度消失问题,增加拟合精度。但由于多卷积层的网络结构容易学习到训练数据中的过度依赖关系,导致出现过拟合现象,TCN 网络结构引入随机丢弃(Dropout)优化方法,通过随机丢弃局部神经元的方式(灰色部

分为丢弃神经元)来减少不同神经元之间的过度依赖关系,有效防止过拟合,见图 4。




图 4 Dropout 示意图

为了提高模型的泛化能力,解决较深的网络结构可能引起的梯度弥散或者梯度爆炸问题,引入残差神经网络(ResNet)中的残差块结构。残差块结构将输入 x 与经过非线性变换后的 $F(x)$ 进行求和操作,形成短路连接:

$$H = x + F(x) \quad (8)$$

这种结构能够优化深层网络,较好地拟合输入发生的变化。而 TCN 网络感受野的扩大依赖于卷积网络层的增加,而残差结构可以很好地抑制网络

层增加带来的梯度消失或者梯度爆炸问题。




图 5 使用残差块的 TCN 网络流程图

2.4 网络性能测试阶段

保存 2.3 节中训练好的 TCN 网络结构,使用测试集数据验证网络预测精度,得到均方误差和平均百分比误差,作为衡量网络性能的量化指标。总体训练流程如图 6 所示。




图 6 Autoencoder-TCN 混合预测模型

3 实验验证

3.1 数据准备

本文选取某型军用运输机性能良好发动机的 150 个架次真实飞行数据作为研究对象,140 个架次作为训练集和验证集数据,10 个架次作为测试集数据,每个架次选取与 EGT 相关的 11 个参数。由于不同飞行阶段下,发动机的工作状态的影响因素有所差异,对预测模型的精确度有一定的影

响。为减小飞行阶段对模型预测精度的影响,本文选取每个架次飞机巡航阶段的 3 000 个时间点,各个时间点的 11 维向量依次输入 Autoencoder 网络进行维度压缩,输出 3 000 个 5 维特征向量,时序连接后作为 TCN 网络的输入。以左发为例,11 个输入参数分别为: α_1 (低压转子导流叶片角)、 α_2 (高压转子导流叶片角)、 N_1 (低压转子转速)、 N_2 (高压转子转速)、进气道斜板高度、燃油消耗量、大气机高度、喷口直径大小、油门杆位置、滑油压力、大气机速度。

3.2 性能评价指标

本文采用均方误差(MSE)和平均绝对百分比误差(MAPE)来衡量预测精度。

均方误差公式如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \tag{9}$$

式中: $\hat{y}_i$ 为输出预测值; y_i 为实际值; n 为数据时间序列长度。

平均绝对百分比误差公式为:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \tag{10}$$

3.3 实验环境和参数配置

本文模型在配备 Intel i5 以及 NVIDIA GTX 1080Ti CPU 的计算机上进行训练与测试,集成开发环境为 Anaconda,采用深度学习框架 PyTorch。由于深度学习模型中超参数的不同对实验结果影响较大,本文采取实验结合经验的方式对提出的网络结构进行调整,使混合预测模型能够更好地适应飞行数据特点。本文调整的超参数包括 TCN 隐藏层数、卷积核大小(kernel size),学习率(learning rate)等。不同的超参数设置对网络性能有如下影响:

1)理论上说,隐藏层数越多,TCN 网络结构的非线性表达能力越强。但层数过多增加了过拟合风险,同时也增加了训练难度。

2)卷积核的大小影响 TCN 对时域跨度信息的提取能力。当卷积核太小时,一维卷积运算能够提取到的时间关联性较小,无法深入挖掘飞行数据的时域信息;当卷积核太大时,容易将无关信息纳入计算,增加噪声,破坏网络对数据特征的学习。

3)学习率控制着模型训练参数的更新速度,过小的学习率会降低模型的收敛速度,过大的学习率则会导致训练参数在最优解附近震荡。

为验证不同的超参数设置对网络性能的综合影响,本文采取正交实验法(Orthogonal Experiment)在最小试验次数下确定最优超参数组合。

本文为 3 因素 4 水平正交实验,隐藏层数为因素 A,范围为[2,3,4,5];卷积核大小为因素 B,范围为[6,7,8,9];学习率为因素 C,范围为[0.1,0.2,0.3,0.4]。选取正交表为 L16(4³)正交表,共需要进行 16 次试验。16 次试验的组合方式见表 1。

测试评价指标为均方误差(MSE)和训练时间(time)。最终测试结果如表 2 所示。

由 16 组正交测试结果分析可以得到:NO. 10 的均方误差最小,但其训练时间较 NO. 1~NO. 5 偏大,主要是由于 NO. 1~NO. 5 的隐藏层数较小,模型结构较为简单,降低了训练难度,但导致其非线性

化表达能力不足,均方误差较大,因此在训练时间上不具有可比性;NO. 10 在同等训练难度的组别中(NO. 9~NO. 12),均方误差与训练时间均为最优,因此可考虑 NO. 10 为本试验最优组合,核心参数配置 TCN 隐藏层数为 4,卷积核大小为 7,学习率大小为 0.4。最终实验参数配置见表 3。

表 1 试验参数组合表

NO.	A	B	C	NO.	A	B	C
1	2	6	0.1	9	4	6	0.3
2	2	7	0.2	10	4	7	0.4
3	2	8	0.3	11	4	8	0.1
4	2	9	0.4	12	4	9	0.2
5	3	6	0.2	13	5	6	0.4
6	3	7	0.1	14	5	7	0.3
7	3	8	0.4	15	5	8	0.2
8	3	9	0.3	16	5	9	0.1

表 2 正交实验法测试结果

NO.	MSE	time/s	NO.	MSE	time/s
1	19.452	56.231	9	6.721	132.549
2	13.809	48.577	10	4.987	103.421
3	16.650	69.342	11	5.720	167.742
4	14.098	88.549	12	5.991	159.061
5	11.480	92.337	13	8.375	219.370
6	6.346	123.512	14	6.810	280.751
7	9.027	107.569	15	7.017	307.302
8	7.193	144.672	16	7.120	367.186

表 3 TCN 网络模型参数配置

参数名称	数值
隐藏层数	4
卷积核大小	7
学习率	0.4
隐藏层节点数	50
批尺寸大小	20
时间步长	10
训练时期数	50
Dropout 率	0.25

为验证 Autoencoder-TCN 预测模型的有效性,分别建立 BP 和 LSTM 网络作对比实验。为控制其他变量对网络性能的影响,设置相同的网络超参数进行试验。

3.4 实验结果与分析

前 140 个架次飞行数据以 9 : 1 的比例设置训练集和验证集,分别测试 3 种不同模型。取后 10 个架次飞行数据作为测试集,第 3 架次的部分拟合曲线和预测绝对误差比见图 7~8。




图7 不同模型排气温度拟合曲线




图8 不同模型预测绝对误差比图

采用均方误差(MSE)和平均绝对百分比误差(MAPE)作为模型性能测试指标。3种模型的测试结果见表4。

表4 3种模型预测误差

架次	BP 模型		LSTM 模型		Autoencoder-TCN 模型	
	预测误差 MSE	MAPE/%	预测误差 MSE	MAPE/%	预测误差 MSE	MAPE/%
1	29.493	12.958	15.293	9.601	5.062	3.189
2	30.210	13.241	19.039	10.544	6.293	3.863
3	27.781	12.570	18.483	10.092	4.523	2.042
4	31.335	13.893	21.549	11.605	7.895	4.013
5	35.907	14.301	17.680	10.433	5.604	3.422
6	26.390	12.447	16.774	9.475	7.893	4.278
7	37.781	15.017	19.031	9.883	6.058	4.169
8	31.964	13.235	18.920	9.012	8.237	4.660
9	25.439	10.907	13.204	7.256	3.549	1.897
10	26.037	11.781	15.094	8.031	4.961	2.156

为衡量混合模型的有效性及其泛化能力,取3种模型10个架次误差指标的平均值作为最终指标,见图9。




图9 3种模型预测误差对比图

从图7和图8直观上来看,Autoencoder-TCN

模型在测试集上的拟合曲线优于BP和LSTM模型,其拟合误差较BP和LSTM模型有所降低。由图9量化指标上看,Autoencoder-TCN混合预测模型较BP、LSTM模型的MSE和MAPE均有所降低,MAPE由13.035%和9.593%降低至3.369%。综上所述,本文提出的混合预测模型能够针对航空发动机排气温度的时间积累特性,深入挖掘飞行数据序列的时间维度信息,使用Autoencoder提取相关特征,利用TCN网络处理时间序列数据的优势,可以搭建多层网络结构学习长时间跨度信息,建立发动机排气温度和历史数据的关联模型,采用多组数据对混合模型进行测试,验证了模型的可行性和有效性,提高了预测精度。

4 结语

针对航空发动机排气温度预测模型精度不高、传统RNN类网络对飞行序列数据时间维度信息挖掘不充分的问题,本文提出了一种结合自编码器和时间卷积神经网络的Autoencoder-TCN预测模型。利用Autoencoder提取与排气温度相关的特征,降低输入TCN网络的数据维度,利用TCN挖掘历史数据的关联性,针对飞行数据特点,采取实验的方式配置模型参数,使模型性能最优化。经过实验验证,利用多架次数据分别对BP、LSTM、Autoencoder-TCN模型进行验证,Autoencoder-TCN预测模型较BP、LSTM均方误差和平均绝对误差百分比均有所降低,证明本文提出的混合预测模型能够有效提高预测精度。但测试结果表明,3种模型在不同架次飞行数据上的预测误差均有一定差距,如何提高模型的泛化性能需要进行进一步研究。

参考文献

- [1] 钟诗胜, 雷达, 丁刚. 卷积和离散过程神经网络及其在航空发动机排气温度预测中的应用[J]. 航空学报, 2012, 33(3):438-445.
- [2] 吕永乐, 郎荣玲, 路辉, 等. 航空发动机性能参数联合RBFPN和FAR预测[J]. 北京航空航天大学学报, 2010, 36(2):131-134,149.
- [3] 宋云雪, 张科星, 史永胜. 基于多元线性回归的发动机性能参数预测[J]. 航空动力学报, 2009, 24(2):427-431.
- [4] 皮骏, 黄江博, 黄磊, 等. 基于改进QPSO-SVR的航空发动机排气温度预测[J]. 振动·测试与诊断, 2019, 39(2):267-272, 440.
- [5] 张鹏, 张铖, 毛功平. 基于不同人工神经网络的CNG发动机排气温度预测模型研究[J]. 内燃机, 2020, 46

- (2):19-24.
- [6] CAY Y. Prediction of a Gasoline Engine Performance with Artificial Neural Network[J]. Fuel, 2013, 111: 324-331.
- [7] 陈庆贵, 李洪伟, 李明, 等. 基于径向基过程神经网络的航空发动机排气温度预测[J]. 兵器装备工程学报, 2019, 40(6):154-157.
- [8] KUMAR A, SRIVASTAVA A, GOEL N, et al. Exhaust Gas Temperature Data Prediction by Autoregressive Models[C]//Canadian Conference on Electrical and Computer Engineering, 2015: 976-981.
- [9] 杨洪富, 贾晓亮. 基于 LSTM 的航空发动机排气温度预测[J]. 航空计算技术, 2018, 48(4):61-65.
- [10] 张帅, 杜军, 严智. 基于输出层增强的 LSTM 发动机排气温度模型[J]. 电子测量与仪器学报, 2019, 33(8):124-132.
- [11] BAI S, KOLTER J Z, KOLTUN V, et al. An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling[Z]. ArXiv: Learning, 2018.
- [12] 韩建胜, 陈杰, 陈鹏, 等. 基于双向时间深度卷积网络的中文文本情感分类[J]. 计算机应用与软件, 2019, 36(12):225-231.
- [13] 张毅, 赵杰煜, 王翀, 等. 时域注意力 Dense-TCN 在多模手势识别中的应用研究[J/OL]. [2020-09-27]. 计算机工程:1-11. DOI:10.19678li.issn.1000-3428.0056808.
- [14] 周楚杰. 基于 LSTM 和 TCN 混合深度学习的风速短期预测模型[D]. 兰州:兰州大学, 2019.
- [15] HINTON G, SALAKHUTDINOV R. Reducing the Dimensionality of Data with Neural Networks[J]. Science, 2006, 313(5786): 504-507.
- [16] 宋亚, 夏唐斌, 郑宇, 等. 基于 Autoencoder-BLSTM 的涡扇发动机剩余寿命预测[J]. 计算机集成制造系统, 2019, 25(7):1611-1619.

(编辑:徐敏)

(上接第 53 页)

- [17] 柳鹏, 杨锁昌, 郑思龙, 等. 一种防空导弹全任务维修训练模拟器设计[J]. 火力与指挥控制, 2017, 42(6):119-123.
- [18] 刘桂峰, 伍洁. 基于 Vega 的某装备虚拟维修系统技术研究[J]. 舰船电子工程, 2011, 31(11):128-131.
- [19] 梅朝, 舒涛, 宋涛, 等. 武器装备虚拟维修训练系统设计[J]. 火力与指挥控制, 2016, 41(9):151-155, 160.
- [20] HENDERSON S J, FEINER S. Evaluating The Benefits of Augmented Reality for Task Localization in Maintenance of an Armored Personnel Carrier Turret [C]//Proceedings of 2009 8th IEEE International Symposium on Mixed and Augmented Reality. Orlando: IEEE, 2009:135-144.
- [21] DODEVSKA Z A, MIHIC M, MANASIJEVI S. The Role of Augmented Reality in Defensive Activities [C]//Proceedings of 8th International Scientific Conference on Defensive Technologies. Serbia: [s. n.], 2018:590-593.
- [22] ULLO S L, PIEDIMONTE P, LECCESE F, et al. A Step Toward the Standardization of Maintenance and Training Services in C₄I Military Systems with Mixed Reality Application [J]. Measurement, 2019, 138: 149-156.
- [23] 白柯萌, 王威, 瞿珏, 等. 多传感器式诱导维修系统的设计与实现[J]. 火力与指挥控制, 2017, 42(2): 102-108.
- [24] 罗又文, 王威, 瞿珏. 基于 Faster R-CNN 的诱导维修自动交互设计[J]. 计算机工程与应用, 2019, 55(12): 181-187.
- [25] 胡江南, 赵鸿飞, 王海涛, 等. 装备远程虚拟化故障诊断支援系统设计与研究[J]. 机械制造与自动化, 2015, 44(2):192-195.
- [26] ARANSYAH D, ROSA F, COLOMBO G. Smart Maintenance: A Wearable Augmented Reality Application Integrated with CMMS to Minimize Unscheduled Downtime[J]. Computer-Aided Design and Applications, 2019, 17(4):740-751.
- [27] WESTERFIELD G, MITROVIC A, BILLINGHURST M. Intelligent Augmented Reality Training for Motherboard Assembly[J]. International Journal of Artificial Intelligence in Education, 2015, 25(1): 157-172.
- [28] SUN M, HE W, ZHANG L, et al. Smart Haproxxy: A Novel Vibrotactile Feedback Prototype Combining Passive and Active Haptic in AR Interaction[C]//Proceedings of 2019 IEEE International Symposium on Mixed and Augmented Reality Adjunct (ISMAR-Adjunct). Beijing: IEEE, 2019:42-46.
- [29] WEBEL S, BOCKHOLT U, ENGELKE T, et al. An Augmented Reality Training Platform for Assembly and Maintenance Skills[J]. Robotics and Autonomous Systems, 2013, 61(4):398-403.
- [30] ESCHEN H, KÖTTER T, RODECK R, et al. Augmented and Virtual Reality for Inspection and Maintenance Processes in the Aviation Industry[J]. Procedia Manufacturing, 2018, 19:156-163.

(编辑:徐敏)