

文章编号:1001-5078(2024)12-1900-06

· 红外技术及应用 ·

红外光谱发射率测量设备检定状态预测研究

郭娟, 张金铭, 季新杰

(空军工程大学 航空机务士官学校, 河南 信阳, 464000)

摘要: 使用光谱发射率测量设备检测红外隐身涂层发射率, 是监控飞机红外隐身涂层状态的一种重要手段。在测量设备检定周期内, 受使用环境、使用频率、使用方法等因素影响, 偶发设备状态变得恶劣, 测量值偏离参考值, 对及时发现红外隐身涂层缺陷带来一定风险, 可能影响飞机整体红外隐身特性。针对检定周期内出现的测量值偏差问题, 建立格拉姆角场(GAF) - 并行卷积神经网络(PCNN)设备检定状态预测模型。将测量设备一维时序数据送入 GAF-PCNN 模型中, 经过深度学习, 训练出红外发射率测量设备检定状态预测模型。试验表明, 该检定状态预测模型平均识别准确率达到 95%, 且收敛速度快且稳定, 可应用于设备检定状态预测, 提示提前检定或者超检定周期使用, 在确保设备状态良好的同时, 减少设备检定活动, 提高保障效率。

关键词: 格拉姆角场; 并行卷积神经网络; 红外发射率; 预测; 检定状态

中图分类号: TN976; TH74 文献标识码: A DOI: 10.3969/j.issn.1001-5078.2024.12.014

Research on predicting the calibration status of infrared spectral emissivity measurement equipment

GUO Juan, ZHANG Jin-ming, JI Xin-jie

(Aviation Maintenance NCO School of Air Force Engineering University, Xinyang 464000, China)

Abstract: Using spectral emissivity measurement equipment to detect the emissivity of infrared stealth coatings is an important means of monitoring the status of aircraft infrared stealth coatings. During the calibration cycle of the measuring equipment, due to factors such as usage environment, usage frequency, usage method and so on, the condition of the equipment occasionally becomes worse, and the measured values deviate from the reference value which poses a certain risk for timely detection of infrared stealth coating defects and may affect the overall infrared stealth characteristics of the aircraft. To address the issue of measurement deviation during the calibration cycle, a Gramian Angular Field (GAF) and Parallel Convolutional Neural Network (PCNN) calibration status prediction model is established. By collecting one-dimensional time-series data from the device and feeding it into the GAF-PCNN mode, a prediction model for the calibration status of infrared emissivity measurement equipment is trained through deep learning. The experiment shows that the average recognition accuracy of the calibration state prediction model reaches 95%, and the convergence speed is fast and stable, which can be applied to equipment calibration state prediction, prompting early calibration or use beyond the calibration cycle. While ensuring good equipment condition, it reduces equipment calibration activities and improves guarantee efficiency.

Keywords: Gramian Angular Field (GAF); Parallel Convolutional Neural Network (PCNN); infrared emissivity; prediction; calibration status

作者简介: 郭娟 (1985 -), 女, 硕士, 讲师, 主要从事装备计量理论与技术研究。E-mail: 272216436@qq.com

通讯作者: 季新杰 (1981 -), 男, 博士, 讲师, 主要从事航空弹药设计、自动控制方面的研究。E-mail: jixnjie@126.com

收稿日期: 2024-05-31

1 引言

不断发展的目标红外探测能力已严重威胁飞机的突防能力和战场生存能力。在飞机主要辐射源上涂覆红外隐身涂层是降低飞机的红外可探测性、提高生存能力的主要手段。

在日常维护中,应用红外发射率测量设备测量涂层的红外发射率,是涂层状态的判定依据。为确保测量一致性、准确性,一般要求设备的检定周期为12个月。因使用环境、使用频率、使用方法等因素影响,会出现测量值与参考值的偏离。在检定周期内,大部分设备的偏离值在合理区间内,但也存在偏离值接近甚至超出合理区间的现象,无法为涂层状态提供有效的判定依据。因此,需要对测量设备进行动态监控,以重新确定测量设备的检定周期,或提前检定,或延长检定周期,确保涂层状态监控的可信度。

在设备状态预测领域,相关研究已开展大量研究,主要应用到轴承、变压器、电能质量、变速箱等设备状态预测监控中。文献[1]基于GAF和CNN-RNN建立了轴承故障预测模型预测轴承故障。文献[2]~[3]建立了GAF-CNN的变速箱故障诊断方法预测变速箱故障类型。文献[4]利用GAF和CNN建立斜拉索损伤识别模型识别斜拉索的损伤。文献[5]基于GAF和CNN建立了发动机振动信号故障诊断模型预测发动机振动类型。文献[6]应用GAF-CNN方法识别弓网电弧。

在红外辐射测量领域,开展测量校准和不确定度研究,能有效降低测量误差,确保测量有效、一致^[7-8],相关研究多为集中。而关于红外涂层光谱发射率测量设备的检定状态的预测研究,比较罕见。本文将设备状态一维时序数据作为输入,经过格拉姆角场变换成格拉姆求和场(Gramian Angular Summation Fields, GASF)和格拉姆差场(Gramian Angular Difference Fields, GADF)二维图像,分别送入PCNN模型的两个支路进行训练和学习,建立基于GAF-PCNN的红外涂层光谱发射率测量设备状态预测模型,为测量设备检定提供参考,解决可能因设备状态恶化带来的测量隐患。

2 基本原理

2.1 一维时序数据转二维图像

格拉姆角场(Gramian Angular Field, GAF)是WANG等提出的一种将一维时间序列数据转换为二

维图像的方法^[9],在神经网络领域得到快速应用^[1-6,10-14]。测试设备数据本质上是一维时序数据,GAF其转换为二维图像的同时,最大限度保留了原始数据的时间依赖性和潜在联系特征。同时,CNN是来源于生物视觉认知机制,更擅长识别二维图像。

GAF图像转换基本过程:首先对笛卡尔坐标系下的时间序列进行极坐标编码,再依据其特有的内积定义形式,通过三角函数和差运算生成格拉姆矩阵,从而将一维时间序列转化为二维图像。

针对时间序列 $X = \{x_1, x_2, \dots, x_i, \dots, x_n\}, i \in [1, n]$,首先采用公式(1)将 X 缩放到区间 $[-1, 1]$ 中^[5,12],转变为序列 \tilde{X} :

$$\tilde{x}_i = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (1)$$

再将笛卡尔坐标系下的时间序列转换为到极坐标系下的时间序列。方法是,将 \tilde{x}_i 的值映射为角度 ϕ ,将 x_i 对应的时间 t_i 映射为半径 r 。相应的转换公式为^[5,12]:

$$\begin{cases} \phi = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, t_i \in N \end{cases} \quad (2)$$

式中, t_i 为时间戳,将区间 $[0, 1]$ 分为 N 等份,使极坐标系的跨度正则化。公式(2)的编码映射具有唯一性且保持绝对的时间关系^[14]。

接着,建立Gram矩阵,通过考虑每个点之间的三角函数来识别不同时间间隔内的时间相关性。考虑到GAF有GASF和GADF两种不同的形式,定义分别如公式(3)和公式(4)所示:

$$G_{\text{GASF}} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cdots & \cos(\phi_2 + \phi_n) \\ \vdots & \vdots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (3)$$

$$G_{\text{GADF}} = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \sin(\phi_2 - \phi_1) & \cdots & \sin(\phi_2 - \phi_n) \\ \vdots & \vdots & \vdots \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{bmatrix} \quad (4)$$

为区分高斯噪声,格拉姆角场定义了两种带有惩罚项的内积形式,用以消除高斯噪声影响,其内积形式如公式(5)和公式(6):

$$\langle \tilde{x}_i, \tilde{x}_j \rangle = \cos(\phi_i + \phi_j) \quad (5)$$

$$\langle \tilde{x}_i, \tilde{x}_j \rangle = \sin(\phi_i - \phi_j) \quad (6)$$

则公式(3)和(4)可统一成内积形式,如公式(7)^[14]所示:

$$G = \begin{bmatrix} \langle \tilde{x}_1, \tilde{x}_1 \rangle & \cdots & \langle \tilde{x}_1, \tilde{x}_n \rangle \\ \langle \tilde{x}_2, \tilde{x}_1 \rangle & \cdots & \langle \tilde{x}_2, \tilde{x}_n \rangle \\ \vdots & \vdots & \vdots \\ \langle \tilde{x}_n, \tilde{x}_1 \rangle & \cdots & \langle \tilde{x}_n, \tilde{x}_n \rangle \end{bmatrix} \quad (7)$$

式中,因 $G_{(i,j)|i-j=k}$ 表示时间相关性是通过时间间隔 k 的方向所叠加,并且用相关性来解释。

从公式(7)可以看出,当 $i = j$ 时, Gram 矩阵的主对角线元素 $G_{(i,i)}$, 是缩放后的时间序列 \tilde{X} 的原始值,包含了原始序列 X 的数值和角度信息。因此,利用该主对角线,可根据神经网络学习获得的高维度特征似地重构时间序列^[14]。

2.2 双通道并行卷积神经网络模型

PCNN 包括两个支路,每个支路依次具有由卷积层、批量归一化层、ReLU 激活函数层、池化层、完全连接层等组成。经过支路 CNN 完全连接层之后,展平、融合成 1 路,再经 1 个完全连接层,进入 Softmax 分类器处理后,输出设备状态分类数据。

卷积层的作用是,通过卷积运算能加强原始信号的某些特征,提取出 GAF 图像中的隐藏特征。计算过程如下式:

$$x_j^l = \sum_{i \in m} x_j^{l-1} \times k_{ij}^l + b_j^l \quad (8)$$

式中, l 表示层数; x_j^l 表示第 l 层的第 j 个神经元; m 表示上一层与当前层由连接的神经元个数; k 表示权重; b 表示偏置。

为使 CNN 网络能够设定较高的初始学习率,加速模型收敛过程,在卷积层之后插入批量归一化层 (Batch Normalization, BN), 将数据进行归一化处理,以提高网络的泛化能力,使得网络能够使用误差更小的 L2 损失函数。

经过 BN 层处理的数据,导入 ReLU 激活函数层。该层不仅增加了网络的非线性分割能力,同时还避免了反向传播时的梯度消失问题。ReLU 激活函数公式如公式(9)所示:

$$ReLU(x) = \begin{cases} x, & \text{if } x > 0 \\ 0, & \text{if } x \leq 0 \end{cases} \quad (9)$$

针对卷积、BN、ReLU 依次处理后特征维数的增加问题,采用池化层对数据进行缩放,以降低数据维数,提取重要信息。池化层分为最大池化层和平均

池化层,本文采用最大池化层。

全连接层通常在 CNN 的尾部,与上层所有的节点相连接,以集成从前层提取的特征,并将输出值送给分类器,完成输入图像到标签集的映射。由于其完全连接的性质,全连接层的参数也是最多的,全连接层表示如公式(10)所示。

$$x_o^l = f(x_i^{l-1} \times D_{io}^l + b^l) \quad (10)$$

式中, D_{io}^l 表示第 l 层的学习参数。

3 设备状态识别流程

本文采用的 PCNN 识别设备检定状态的流程如图 1 所示。




图 1 设备检定状态识别流程示意图

Fig. 1 Calibration status identification process for equipment

设备一维时序数据经 GAF 转化为二维 GASF 和 GADF 图像,如图 1 所示,GASF 图像经一条支路输入到 CNN1 提取和场图像特征,GADF 图像经另一条支路输入到 CNN2 提取差场图像特征,实现两类高维图像特征融合,再经 PCNN 模型识别设备状态。

4 设备状态分类与模型训练

4.1 设备检定状态划分

按照每 3 个月为 1 个状态,将某红外发射率测量设备检定周期内 12 个月划分为 4 个周期,分别是 G1、G2、G3、G4;超过 12 个月,最大延伸至 18 个月,也按照 3 个月分段,设置 G5、G6 两个状态。因此,设备的检定状态共有 6 个,如表 1 所示。

表 1 设备检定状态分类

Tab. 1 Classification of equipment calibration status

状态	说明
G1	检定周期内 0 ~ 3 个月
G2	检定周期内 3 ~ 6 个月
G3	检定周期内 6 ~ 9 个月
G4	检定周期内 9 ~ 12 个月
G5	超检定周期 0 ~ 3 个月
G6	超检定周期 3 ~ 6 个月

4.2 设备数据集

在试验环境下(室温 25 ℃、相对湿度 95 %),采集红外发射率测量设备信号,每次采集持续 10 s,在采样时间期间,每 0.1 s 读取一次,即采样频率为 10 Hz。数据集分为训练样本集和测试样本集,训练样本和测试样本的比例为 5 : 1。


训练集:采集正常设备(在一个检定周期内,其测量值和标准值偏差在合理范围内)一个检定周期(12 个月)和超出检定周期 6 个月以内的数据作为模型训练样本。通过长期监控分布于多个地理区域、不同环境、不同使用频率的设备,每个设备状态采集 50 个样本,共计 300 个样本,作为训练集。

测试集:测试样本则选取正常设备不同检定状态下的 60 个样本。

4.3 数据学习与训练

每个设备状态的 50 个训练样本,经过 GAF 变换,将分别产生 50 张 100×100 的 GADF 和 GASF 二维图像,即每个 CNN 支路输入 GAF 图像总数为 300 张。同时,每个设备状态对应的 10 条测试样本,将产生与状态对应的 10 张 100×100 的 GADF 和 GASF 二维图像,也即每个 CNN 支路输入图像总数为 60 张。

设置 PCNN 模型的学习率为 0.001,学习轮次为 10 轮,每轮最大迭代次数为 20 次,最大迭代次数为 200 次,优化算法采用 Adam 算法^[5]。运行模型,部分 GAF 图像如图 2 所示,训练和损失曲线如图 3 所示。



(a)训练集GAF图像 (b)测试集GAF图像

图 2 部分 GAF 图像

Fig. 2 Partial GAF images




图 3 训练损失曲线和准确率曲线

Fig. 3 Training set loss curve and accuracy curve

训练曲线显示,经过 27 次迭代,准确率达到 96.0%,损失降低到 2.96%;经过 40 次迭代,准确率达到 100%,损失降到 0。且从第 40 次迭代一直到 200 次迭代运算,准确率稳定在 100%,损失稳定在 0,无波动,表明该模型的收敛速度快且稳定,能够快速预测出测试集的设备状态类型。

测试集中提供的 60 个测试样本,总的预测精确度达到 95.0%,各个设备状态类型其预测结果如表 2 所示。测试集与训练模型之间的对比结果显示,除了状态 G3 之外,其他 5 个状态的精确度均达到了 100%。而 G3 状态的精确度为 76.9%,表明 G3 状态与其他状态的状态关联性较强,区分度不高。为提高 G3 状态的预测精确度,可以采集类似设备状态的数据,替换测试集 G3 标签的测试样本。

表 2 测试集设备状态预测结果

Tab. 2 Device status prediction results for test set

参数	G1	G2	G3	G4	G5	G6
精确率/%	100	100	76.9	100	100	100

5 检定状态预测试验

5.1 试验对象

为了检验模型的预测能力和预测效率,分别准备了 1#设备:超出检定周期 6 个月,设备状态为 G6; 2#设备:距离 12 个月的检定周期还有 1 个月,设备状态为 G4。

5.2 试验方法

首先,将 1#设备的 10 条数据,依次划分为状态类型 G1、G2、G3、G4、G5、G6,共形成 60 条新的测试数据,这些数据构成了新的测试集。再将新测试集数据,经过 GAF 变换后,输入训练模型进行识别,通过观察新测试集的混淆矩阵,预测设备 1#的检定状态。接着,同设备 1#的方法,用设备 2#的 10 条数据,构成新的测试集,再经 GAF 变换,作为模型的输入,通过观察对应的混淆矩阵,判定设备 2#预测的检定状态。

5.3 预测结果分析

1#设备构成新测试集,输出的混淆矩阵如图 4 所示。可以看出,提供的 1#设备的 10 条样本数据,全部预测为类型 G6,概率为 100%。预测为其他类型的数量为 0,概率为 0。因此,可以说明,尽管 1#设备在实际使用中,还有 1 个月即将满 12 个月检定周期,处于检定状态 G4,但模型预测结果显示,其设

备检定状态处于 G6。表明,1#设备的检定状态已经超出设定的检定周期,需要提前进行设备的计量检定,确保设备处于良好的技术状态。




图4 1#设备对应的混淆矩阵

Fig. 4 Confusion matrix corresponding to device 1#




图5 2#设备对应的混淆矩阵

Fig. 5 Confusion matrix corresponding to device 2#

基于2#设备构建了新测试集,使用训练好的模型,输出的混淆矩阵如图5所示。已知,2#设备已经过了规定的12个月检定周期6个月,即处于状态G6。但从图6可以看出,经过双通道PCNN检定状态预测模型预测,10条样本数据中,2条被预测为状态G3,概率为20%,8条被预测为状态G4,概率为80%,表明,2#设备实际检定状态介于G3和G4之间。若认为概率>50%即为确认状态,则表明2#设备检定状态为G4。

尽管该设备由于特殊原因,已经超过检定12个月规定的检定周期,但设备的实际状态更趋于G4。同时也表明,基于2#设备目前的实际状态,还可以使用该设备进行红外辐射特性的测量或者认定之前使用该设备的测量偏差在合理区间。

6 结论

结合GAF和PCNN建立的红外隐身涂层红外

发射率测量设备检定状态预测模型,经过训练和学习,以及仿真和测试对比,结论如下:

(1) 建立的红外发射率测量设备GAF-PCNN检定状态预测模型,预测准确率达到95%以上,预测准确率高速度快。

(2) 对于预测准确率不高的样本数据,将继续测量,并在此基础上重新对模型进行训练。

(3) 建立的检定状态预测模型具有普适性,只需调整神经网络参数,即可用于建立其他测试设备检定状态预测模型。

参考文献:

- [1] Yao Li, Sun Jianjun, Ma Chenbo. Fault diagnosis method for rolling bearings based on Gramian angular fields and CNN-RNN[J]. BEARING, 2022(2): 61-67. (in Chinese)
姚立, 孙见君, 马晨波. 基于格拉姆角场和CNN-RNN的滚动轴承故障诊断方法[J]. 轴承, 2022(2): 61-67.
- [2] Pang Xinyu, Tong Yu, Wei Zihan. A fault diagnosis method for planetary gearbox based on GAF-CNN[J]. Transactions of Beijing Institute of Technology, 2020, 40(11): 1161-1167. (in Chinese)
庞新宇, 仝钰, 魏子涵. 一种GAF-CNN行星齿轮箱故障诊断方法[J]. 北京理工大学学报, 2020, 40(11): 1161-1167.
- [3] Gu Yingkui, Shi Changwu, Chen Jaifang. Fault diagnosis of planetary gear box based on Gramian angular fields and deep convolutional generative adversarial network[J]. Noise and Vibration Control, 2024, 44(1): 111-118. (in Chinese)
古莹奎, 石昌武, 陈家芳. 基于格拉姆角场与深度卷积生成对抗网络的行星齿轮箱故障诊断[J]. 噪声与振动控制, 2024, 44(1): 111-118.
- [4] Li Yanqiang, Han Jiahao. Research on cable damage identification based on gramian angular field and convolutional neural network[J]. Journal of Shijiazhuang Tiedao University: Natural Science Edition, 2023, 36(4): 1-7. (in Chinese)
李延强, 韩家浩. 基于格拉姆角场和卷积神经网络的斜拉索损伤识别研究[J]. 石家庄铁道大学学报: 自然科学版, 2023, 36(4): 1-7.
- [5] Li Shaokang, Chen Long, Chen Hui, et al. Fault diagnosis of diesel engine vibration signal based on GAF-CNN[J]. Journal of Wuhan University of Technology: Transportation

- Science & Engineering, 2023, 47(4): 648 – 653. (in Chinese)
- 李少康, 陈龙, 陈辉, 等. 基于 GAF-CNN 的柴油机振动信号故障诊断[J]. 武汉理工大学学报: 交通科学与工程版, 2023, 47(4): 648 – 653.
- [6] Li Bin, Yan Junyu. Research on recognition method of pantograph arc based on GAF-CNN[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 188 – 195. (in Chinese)
- 李斌, 阎君宇. 基于 GAF-CNN 的弓网电弧识别方法研究[J]. 电子测量与仪器学报, 2022, 36(1): 188 – 195.
- [7] Li Meng, Guo Juan, Ji Xinjie, et al. Research on calibration of infrared stealth coating spectral emissivity measurement[J]. Laser & Infrared, 2022, 52(3): 382 – 387. (in Chinese)
- 李猛, 郭娟, 季新杰, 等. 红外隐身涂层光谱发射率测量定标研究[J]. 激光与红外, 2022, 52(3): 382 – 387.
- [8] Zhang Yufeng, Dai Jingmin, Zhang Yi, et al. Correction method for infrared spectral emissivity measurement system based on integrating sphere reflectometer[J]. Spectroscopy and Spectral Analysis, 2013, 33(8): 2267 – 2271. (in Chinese)
- 张宇峰, 戴景民, 张昱, 等. 基于积分球反射计的红外光谱发射率测量系统校正方法[J]. 光谱学与光谱分析, 2013, 33(8): 2267 – 2271.
- [9] Wang Z, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks[C]//The Twenty-ninth Aai Conference on Artificial Intelligence, Tokyo, 2015.
- [10] Zhou Tian, Si Jikun, Du Weidong, et al. Active recognition of underwater targets using GAF-D3Net deep learning network[J]. Acta Acustica, 2023, 48(5): 950 – 958. (in Chinese)
- 周天, 司吉坤, 杜伟东, 等. 采用 GAF-D3Net 深度学习网络的水下目标有源识别方法[J]. 声学学报, 2023, 048(5): 950 – 958.
- [11] Liu Wei, Huang Yongming, Lu Yong, et al. Seismic events classification based on Gram's angle field and multi-scale residual neural network[J]. Acta Selsmologica Sinica, 2024, 46(1): 69 – 80. (in Chinese)
- 刘蔚, 黄永明, 卢永, 等. 基于格拉姆角场和多尺度残差神经网络的地震事件分类方法[J]. 地震学报, 2024, 46(1): 69 – 80.
- [12] Xiao Yusong, Ma Hongzhong. Transformer winding looseness fault diagnosis model based on GAF and depth residual network[J]. Electric Machines & Control Application, 2024, 51(1): 29 – 38. (in Chinese)
- 肖雨松, 马宏忠. 基于格拉姆角场和深度残差网络的变压器绕组松动故障诊断模型[J]. 电机与控制应用, 2024, 51(1): 29 – 38.
- [13] Zhao Yan, Tang Wenshi, Nie Yonghui, et al. Broadband oscillation classification method based on GADF-AlexNet[J]. Power System Technology, 2022, 46(11): 4364 – 4372. (in Chinese)
- 赵妍, 唐文石, 聂永辉, 等. 基于格拉姆角差场和卷积神经网络的宽频振荡分类方法[J]. 电网技术, 2022, 46(11): 4364 – 4372.
- [14] Zheng Wei, Lin Ruiquan, Wang Jun, et al. Power quality disturbance classification based on GAF and a convolutional neural network[J]. Power System Protection and Control, 2021, 49(11): 97 – 104. (in Chinese)
- 郑炜, 林瑞全, 王俊, 等. 基于 GAF 与卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2021, 49(11): 97 – 104.