

# 基于 CNN-MD 的军用电站健康状态评估方法

尹志勇, 钟明威, 王 勇, 任晓琨

(陆军工程大学石家庄校区, 石家庄 050003)

**摘要:** 基于健康状态评估的军用电站预先维修对提高其可靠性、安全性有着重要意义, 采用基于 CNN-MD 的评估方法, 对军用电站健康状态进行评估。建立卷积神经网络(convolutional neural network, CNN)军用电站健康状态识别模型, 通过采用不同的状态样本训练模型, 可使模型识别和输出健康状态类别; 再引入马氏距离(Mahlanobis distance, MD)算法, 计算不同状态下样本与健康样本的 MD 距离, 并将其归一化为健康指数, 即可进一步量化军用电站健康评价结果。以某型军用电站人工模拟不同健康状态的工况获取实验数据, 通过模型能对正常、退化和注意三种状态进行有效区分, 并得到量化评价健康指数 0.6 为正常状态的临界阈值, 0.6 以下为退化以下状态的具体量化评估值, 验证了所方法的有效性。该方法通过 CNN 和 MD 结合, 可实现军用电站健康状态定性与定量评估目的, 为开展预先维修提供依据。

**关键词:** 军用电站; 健康评估; 卷积神经网络; 马氏距离; 健康指标

**中图分类号:** TP207; TM314 **文献标志码:** A **文章编号:** 1671-1807(2024)10-0129-07

随着装备系统电气化、信息化程度的不断提高, 军用电站作为野战条件下重要的电能来源, 工作环境恶劣, 持续运行时间长, 一旦发生故障, 不仅影响装备的作战效能发挥, 还可能危及人员生命, 甚至引发战局失利的严重后果<sup>[1]</sup>。目前军用电站的运维多以定期维护检修与事后维修为主, 这种保障模式难以满足装备系统对电能的高可靠性要求, 基于健康状态的预先维修技术可在很大程度上缓解这一矛盾。

当前国内研究人员对一些装备上的发电机组健康状态评估进行了理论研究, 并取得一定成果。赵东明等<sup>[2]</sup>提出一种基于卷积神经网络(convolutional neural network, CNN)模型针对无人艇上柴油发电机组的健康评估方法, 并通过比较基于误差反向传播算法的人工神经网络(back propagation neural network, BP 神经网络), 验证该方法能提高效率, 但只是对研究对象进行了定性的分类, 没有具体到量化的评估; 张盼盼<sup>[3]</sup>对电源车柴油发电机组健康评估问题进行研究, 通过建立基于降噪自动编码器(denoising autoencoder, DAE)的健康状态识别模型, 给研究对象健康状态定性分类, 并用模型输出结合马氏距离(Mahlanobis distance, MD)算

法实现对健康状态的定量评价, 但其数据是利用仿真平台获取, 仅进行了理论和仿真的研究, 没有用实际装备数据进行验证; 王德民等<sup>[4]</sup>基于包含变权处理的层次分析法和模糊评判法, 对船用柴油发电机组性能进行综合健康评估, 通过算例证明该方法对研究对象进行有效评估, 但也存在健康状态指标权重主观性强、评估结果易受专家经验影响的问题。目前针对军用电站健康状态评估的研究很少, 根据军用电站运维方面的需求, 开展与之相关的健康评估方法与应用的研究具有重要意义。

针对以上发电机组的健康评估问题, 并鉴于开展军用电站健康评估的研究意义, 提出一种基于 CNN-MD 的军用电站健康状态评估方法。先建立 CNN 军用电站健康状态识别模型, 用不同的状态样本训练, 可使模型具备有效的健康状态类别输出能力; 通过 CNN 识别模型得到健康状态定性输出后, 再利用 MD 算法, 以正常状态 MD 为评估基准, 计算电站装备当前状态与正常状态样本数据的距离, 即可得到量化后的电站健康状态评估值。以某型军用电站装备进行实验研究, 结果验证了所提方法的可行性。

**收稿日期:** 2024-02-23

**作者简介:** 尹志勇(1979—), 男, 天津宝坻人, 博士, 副教授, 研究方向为装备供电系统试验与评估、军事微电网技术与应用; 通信作者钟明威(1987—), 男, 广西桂平人, 硕士, 研究方向为装备供电系统试验与评估; 王勇(1984—), 男, 河南确山人, 博士, 讲师, 研究方向为电力工程与微电网技术; 任晓琨(1987—), 男, 河北石家庄人, 硕士, 讲师, 研究方向为军事微电网技术与应用。

## 1 基本原理

### 1.1 CNN 基本原理

自从 Hinton 等<sup>[5]</sup>提出深度学习的概念以来,深度学习广泛应用于图像处理、语音识别、目标检测、信息检索、自然语音处理等领域<sup>[6]</sup>。CNN 作为一种典型的深度学习网络模型,以其强大的非线性特征提取、模式识别能力和学习速率快等优点得到广泛应用<sup>[7-10]</sup>。

CNN 主要包括输入层、多个隐藏层、全连接层和输出层;隐藏层主要由卷积层和子采样层组成<sup>[11]</sup>。以一维 CNN 为例介绍,典型结构如图 1 所示<sup>[12]</sup>。




图 1 典型一维 CNN 结构示意图

卷积层主要用来提取特征,通常一个卷积层包含多个卷积核,每个卷积核根据扫描步长,多次使用相同的权值和偏置扫描输入数据,得到输出特征,称为特征图,为下一步的输入。经过卷积后的向量大小为  $(n-k+m)/m$ ,其中,  $n$  为输入向量的大小,  $k$  为卷积核的大小,  $m$  为扫描的步长,它们的取值可根据经验调整。其数学模型如下

$$y_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} k_{ij}^l + b_j^l\right) \quad (1)$$

式中:  $M_j$  为输入特征;  $l$  为第  $l$  层网络;  $k$  为卷积核;  $b$  为偏置;  $y_j^l$  为第  $l$  层输出;  $x_i^{l-1}$  为第  $l-1$  层输出,也是第  $l$  层的输入。

子采样层(又称池化层)主要用来特征降维,它将卷积输出特征图划分为多个不相交的区域,并取该区域数据的最大值或平均值作为采样后的特征,其数学模型如下:

$$y_i^k = \max(x_{k,1+\text{step}(i-1)}, \dots, x_{k,\text{step}i}) \text{ or } \frac{\sum_{r=1}^{\text{step}} x_{k,r+\text{step}(i-1)}}{\text{step}} \quad (2)$$

式中:  $\text{step}$  为池化层的步长;  $x_k$  为池化层的第  $k$  个输入特征图;  $y_i^k$  为池化层第  $k$  个特征图第  $i$  个节点的输出。

全连接层通过全连接结构,建立网络学习的特征与样本间的映射关系,其计算公为

$$y_i = f_{fc}\left(\sum_{j=1}^m \omega_{ij} x_j + b_i\right) \quad (3)$$

式中:  $y_i$  为第  $i$  个输出节点值;  $f_{fc}(\cdot)$  为激活函数;  $m$  为输入节点个数;  $\omega_{ij}$  为全连接层第  $i$  个输出节点与第  $j$  个输入节点的连接权重;  $x_j$  为第  $j$  个输入节点值;  $b_i$  为偏置。

### 1.2 马氏距离

MD 表示数据的协方差距离,它能有效地计算两个样本或向量的距离和相似度<sup>[13]</sup>。采用 MD 进行健康度评估的研究比较多,这主要得益于 MD 可以不用考虑参数相关性和量纲影响<sup>[14]</sup>,其计算方法如下<sup>[15]</sup>。

(1) 对原始数据进行标准化,计算公式为

$$Z_{ij} = \frac{x_{ij} - \bar{x}_i}{s_i} \quad (4)$$

式中:  $x_{ij}$  为第  $i$  个参数第  $j$  个值;  $\bar{x}_i$  为均值;  $s_i$  为标准差。  $\bar{x}_i$ 、 $s_i$  分别由式(5)和式(6)计算可得。

$$\bar{x}_i = \frac{\sum_{j=1}^n x_{ij}}{n} \quad (5)$$

$$s_i = \sqrt{\frac{\sum_{j=1}^n (x_{ij} - \bar{x}_i)^2}{n}} \quad (6)$$

(2) 计算相关矩阵  $\mathbf{A}$ , 其中每个元素为

$$a_{ij} = \frac{\sum_{m=1}^n Z_{im} Z_{mj}}{n-1} \quad (7)$$

(3) 计算马氏距离,公式为

$$d_{\text{MD}ij} = \mathbf{Z}^T \mathbf{A}^{-1} \mathbf{Z} \quad (8)$$

电站偏离健康状态时,其状态参数可能升高或降低,这都会导致 MD 增加,MD 越大,说明电站当前状态偏离正常状态越远,其性能退化越为严重。为了更直观地描述,将 MD 归一化为健康指数  $H_{\text{MD}}$ <sup>[16]</sup>,计算公式为

$$H_{\text{MD}} = 1 - \frac{\arctan(d_{\text{MD}ij} + b) - \arctan b}{\pi/2 - \arctan b} \quad (9)$$

式中:  $b$  为归一化参数,可根据实际调整  $b$  的参数值;  $H_{\text{MD}}$  介于 0~1,  $H_{\text{MD}}$  越接近 1 说明电站的性能越好,越接近 0 说明其性能退化越严重。

## 2 模型设计

### 2.1 健康等级划分

军用电站作为一种复杂的机电设备,不同的健康状态系统表现出来的状态特性不相同,并且其日常运维过程中健康状态居多,退化和故障状态少并缺乏相应的状态数据,通常只进行正常和故障的区分,缺乏中间过渡状态和量化评价。为了更客观地评价军用电站的健康状态,根据实际情况,建立 5 级评价标准,从高到低依次为优良、正常、退化、注意、故障,如表 1 所示。在讨论中,重点以其中正常、退化和注意三种情况展开探讨。

表 1 军用电站健康状态等级划分

状态	健康等级说明
优良	健康程度非常高,各项指标十分优秀,一般是刚投入使用不久的设备,不需要维护检修
正常	处于中等偏上或常规健康状态,性能退化微弱,不影响系统功能,短时间可以不维护检修
退化	处于亚健康状态,功能受到轻微影响,但还能完成工作,可能某个单项指标接近阈值,需要按计划维护检修
注意	处于中等偏下健康水平,多个指标已达到或超过上限,若未能及时检修,在短时间内电站的状态会骤然下降,需及时检修
故障	健康状态已经处于危及情况,可能已经发生故障,需立即停产检修

### 2.2 流程图

考虑先对军用电站进行健康状态的识别分类,再通过合适的量化评价指标,计算得出电站健康状态的量化评价。由此提出的健康状态评估方法流程如图 2 所示。

### 2.3 具体步骤

综上所述,健康状态评估方法步骤具体如下:

- ①采集电站不同健康状态下的状态数据,并按要求进行预处理,将其分为训练、测试验证 2 个数据子集;
- ②训练 CNN 模型,用训练数据子集训练模型,直到模型符合要求,完成不同健康状态分类模型;
- ③输入电站测试验证样本数据对该模型进行测试验证,获取电站不同健康状态类别;
- ④利用 MD 计算待评估电站状态与正常状态的距离;
- ⑤将 MD 距离值归一化,计算健康指数  $H_{DM}$ ,给出电站的量化评估结果。

## 3 实例验证和分析

### 3.1 实验数据获取和说明

以某型军用电站为研究对象,根据其实际情况,重点研究正常、退化和注意三种情况。由理论

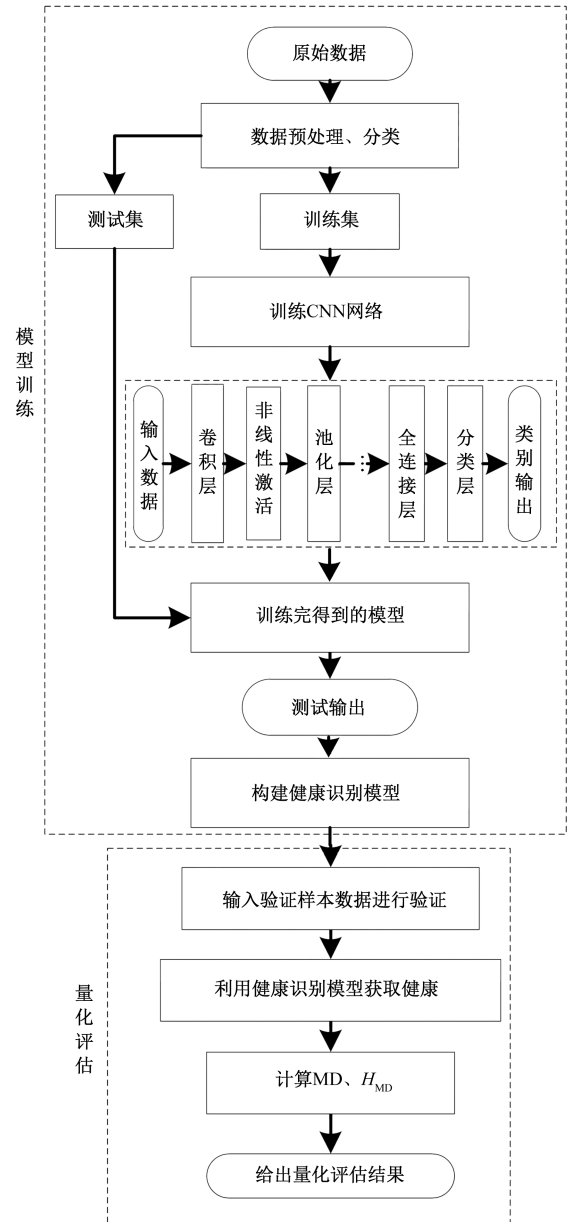


图 2 CNN-MD 健康评估流程

分析和专家经验,根据有些退化状态反馈是在不同的有效负载下出现,设置实验获取数据时电站带载分别为额定功率的 10%、25%、50%、75% 和 100%;并在设定其他模块正常的状况下,通过人工模拟空气滤清器阻塞、调速器调节退化失灵、调压器调整不当失灵等退化过程运行工况,从而获取能反映正常、两种退化和注意等共四种状态数据集;在相应的工况模式下采集转速、水温、振动幅度、蓄电池电压,发动机排气缸体温度、工作相电压、工作相电流和频率等 12 组状态的测量数据。每种状态下各采集 300 组数据,共 1 200 组,具体数据集描述如表 2 所示。

表 2 数据集描述

序号	转速/ (r·min <sup>-1</sup> )	振动幅度/ (mm·s <sup>-1</sup> )	水温/ ℃	蓄电电 压/V	缸体温 度/℃	A 相电 压/V	B 相电 压/V	C 相电 压/V	A 相 电流/A	B 相电 流/A	C 相电 流/A	频率/ Hz	状态
1	3 000	1.023	65	12.8	162	220.2	220.3	220.5	1.098	1.106	1.098	50	正常 1
2	3 010	1.112	70	13.1	165	220.3	220.2	220.1	1.097	1.104	1.098	50.1	正常 1
3	3 000	0.985	70	13.0	165	220.5	220.4	220.2	1.097	1.103	1.097	50	正常 1
...	...	...	...	...	...	...	...	...	...	...	...	...	...
1 199	3 020	1.987	85	13.6	182	227.2	227.1	227.2	11.62	11.64	11.65	50.2	注意 4
1 200	3 020	1.878	85	13.6	182	227.1	226.8	227.3	11.61	11.59	11.66	50.2	注意 4

3.2 数据预处理

由于 12 种数据量纲并非完全一致,若不对数据进行预处理,会造成数值较大的指标吞噬数值较小的指标的误差,影响整体健康状态的判断,为了统一标准,同时为了模型更快、更好地收敛,因此引入式(10)对输入的数据进行归一化处理<sup>[17]</sup>,方法如下:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

式中:  $x'$  为调整后的数据;  $x_{\max}$  和  $x_{\min}$  为指标特征的最大和最小值。

经过预处理后样本如表 3 所示。

3.3 健康状态分类模型的训练和验证

通过超参数寻优的方法,确立了一个精度较高的模型。确定的 CNN 模型相关参数设置如表 4 所示。

模型构建完毕,将处理后的数据样本随机分为两个部分,样本数据 70%用于模型的训练,剩余 30%用于测试验证。训练过程的准确率和最终测试集的准确率如图 3 和图 4 所示。

由训练过程图 3 可以得出 220 轮训练后,训练集的分类预测准确率已稳定达到 99.5%以上;但由图 4 可见,测试集则需要到 300 轮的时候才达到准确率的最点,此后准确率会有所下降,说明在 300 轮迭代时效果最佳,模型可用。然后重复用 300 轮最佳模型测试集测试验证训练好的网络模型,平均准确度为 96%以上,其中一次测试集预测分类和实际类别对比结果如图 5 所示,分类识别混淆矩阵结果如图 6 所示。

为对比 CNN 方法评估分类的优势,以传统的 BP 网络和 SVM 方法用同样的实验数据集进行训练

表 3 预处理后的数据集

序号	转速/ (r·min <sup>-1</sup> )	振动幅度/ (mm·s <sup>-1</sup> )	水温/ ℃	蓄电电 压/V	缸体温 度/℃	A 相电 压/V	B 相电 压/V	C 相电 压/V	A 相 电流/A	B 相电 流/A	C 相电 流/A	频率/ Hz	状态 编码
1	0.750 0	0.149 8	0.646 5	0.622 2	0.581 8	0.740 2	0.747 6	0.759 0	0.010 9	0.010 7	0.010 9	0.500 0	正常 1
2	0.775 0	0.228 7	0.697 0	0.688 9	0.636 4	0.747 6	0.740 2	0.732 8	0.010 8	0.010 4	0.010 9	0.533 3	正常 1
3	0.750 0	0.116 1	0.697 0	0.666 7	0.636 4	0.759 0	0.751 4	0.740 2	0.010 8	0.010 2	0.010 8	0.500 0	正常 1
...	...	...	...	...	...	...	...	...	...	...	...	...	...
1 199	0.800 0	0.979 7	0.848 5	0.800 0	0.945 5	0.976 4	0.964 4	0.976 4	0.986 3	0.986 5	0.987 0	0.566 7	注意 4
1 200	0.800 0	0.928 3	0.848 5	0.800 0	0.945 5	0.964 4	0.961 2	0.975 1	0.986 1	0.985 7	0.987 2	0.566 7	注意 4

表 4 CNN 结构相关参数设置

描述	数值
输入向量尺寸	12×1
卷积层 1 滤波器大小和数量	[8×1],32
池化层 1 滤波器大小	[2×1]
卷积层 2 滤波器大小和数量	[8×1],32
池化层 2 滤波器大小	[2×1]
全连接层节点数	4
随机失活率大小	0.1
输出神经元个数	4
池化操作	最大池化
激活函数	Relu 函数
分类器为	Softmax
迭代轮数	300




图 3 训练过程识别准确率与迭代轮数关系



和验证,3种方法重复10次,最终验证分类准确度平均值对比结果如表5所示。

由表5可知,CNN方法与传统的BP和支持向量机(support vector machines, SVM)方法对比存在较大优势,平均准确度分别提高7.01%和15.78%,自身的健康评估分类模型准确度也达到96%以上,训练好的CNN模型可以用来对电站进行健康状态评估的分类识别。




图4 训练集和测试集准确率与迭代轮数关系

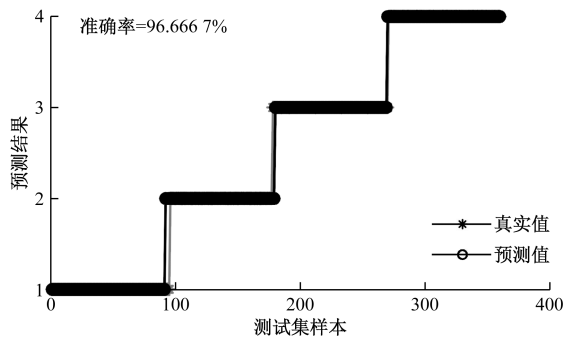


图5 测试集预测分类和实际类别对比结果

实际标签	1	90	4	1		94.7%	5.3%
	2		82			100.0%	
	3	1	1	88	3	94.6%	5.4%
	4		1	1	88	97.8%	2.2%
		98.9%	93.2%	97.8%	96.7%		
		1.1%	6.8%	2.2%	3.3%		
		1	2	3	4		
		预测标签					

图6 CNN分类识别的混淆矩阵

表5 各种方法准确度对比

方法	最高准确度/%	最低准确度/%	平均准确度/%
CNN	97.52	95.32	96.46
BP	91.02	85.26	89.45
SVM	82.23	75.24	80.68

### 3.4 健康状态量化评估

在完成CNN健康状态分类模型后,将测试验证数据输入模型,可定性得出电站健康状态种类,但不能定量评估,而且从前文混淆矩阵中可以看到,有一些分类判别时相邻的更容易误判,说明健康状态之间界线有些还不够明显,需要进一步用定量的方法衡量电站的健康状态。由前文知,可利用MD进行量化评估,分别计算正常状态样本本身的MD距离和三种不同健康状态样本与正常样本之间的距离,其结果分别如图7和图8所示;将整个实验样本的MD趋势综合如图9所示。




图7 正常样本本身的MD示意图




图8 四种状态与正常样本的MD示意图




图9 健康状态全过程合成的MD示意图

由图 7 可知,即使电站是相同的正常性能状态下,不同的负载也会使电站表现出稍微不一样的特征参数,导致对应的 MD 上下有浮动,整个健康样本的最大距离不大于 5.885,说明实验中正常样本的 MD 上限阈值为 5.885,也即计算出来的 MD 在 5.885 以下表现出来的状态特征为正常,大于 5.885 为电站健康状态退化。

由图 8 可知,在同样的带载条件下不同健康状态的样本能很好区别开来,经计算四种健康状态的 MD 均值分别为 3.379 8、7.406 2、21.043 5、27.962 2。但从整体上看,在不同的负载下,即使是设置了不一样健康状态,但在最终计算结果上有可能部分指标会与其他状态会重叠,这在退化后期和注意阶段尤为明显,这是由于电站装备本身是复杂的机电设备,整体表现的健康状态特征不是由单一因素造成的,在没有导致故障的前提下,个别性能退化的因素可能会影响整机性能,但也可能由于电站负载量没有在退化因素触发的条件和被其他控制系统调节下减缓输出性能下降趋势,从而使某部分性能指标类似,从而导致评估结果相近。这说明退化状态和注意的界限不是那么明显,需要进一步进行判断;同时部分退化状态是在一定的带载条件下才能显露出来,同样的退化状态在不同的负载条件下表征的状态参数是不一样的;这就导致在退化阶段,不同的退化状态也有可能评估结果会相近。

由图 9 可知,电站的健康状态随着退化的发展,相应的 MD 越大。并且根据机电设备的特性,状态性能在没有人干预下是一个不断退化的不可逆过程。如果运维工作做得比较好,其能保持在健康区域时间长一些,如放任不管,即使暂时没有达到注意或故障的状态,但随着工作的继续或负载的变化,会使电站健康性能出现注意状态表现,需要及时干预进行维护维修,使其恢复正常状态和消除隐患。结合图 8 可知,如果电站的健康状态类别判别在退化后期和注意状态时,但 MD 没有超过对应状态的均值,说明没有触发进一步退化或突发注意异常的条件,在保证有人值守关注和任务紧急的情况下,可保持当前电站运行状态继续使用。

为了更直观地表现电站的健康状态,前文已引进归一化健康指标的概念,通过多次调整归一化参数(取  $b=6.9$ ,较为合适),在此次实验样本条件下,对应的 MD 归一化健康指标如图 10 所示。

由图 10 可知,对应 MD 为正常状态样本阈值时,健康指标为 0.6,即指标值 0.6 以上为正常状




图 10 MD 相应归一化健康指数  $H_{MD}$  示意图

态,数值越大性能说明越好,数值越小说明性能退化越严重。注意状态 MD 均值时对应健康指标阈值为 0.24 左右,故当健康指标在 0.24 以下时必须进行停机排查原因,及时更换其他备用机组,否则容易出现某系统部件性能突然下降,引起电站故障从而影响工作任务的完成等不良后果;当电站健康指标在 0.24~0.6,可根据实际情况决定是否继续使用,或及时进行维修维护,但需密切关注电站状态,发现健康指标持续下降,需要找到原因排除,尽快恢复性能。

综上所述,通过 MD 和归一化指标计算可得到军用电站的量化评价,能给运维人员提供一个很好的参考指导。

#### 4 结论

本文以军用电站为研究对象,提出了基于 CNN-MD 的健康状态评估方法,实装实验结果如下。

(1)该方法不仅充分利用了 CNN 的优势,完成了对电站正常、退化、注意等健康状态的分类,而且将 CNN 与 MD 结合,实现了对军用电站健康状态定性与定量的评估。

(2)训练好的 CNN 模型能够对电站的不同健康状态进行有效识别区分,相比传统的 BP 和 SVM 方法平均准确度分别提高了 7.01% 和 15.78%,自身的准确度也达到 96% 以上。

(3)结合 MD 和归一化健康指数  $H_{MD}$ ,可得到电站客观详细的量化评价,并且得出正常状态  $H_{MD}$  阈值为 0.6、且  $H_{MD}$  在 0.24~0.6 可视情况继续运行电站和  $H_{MD}$  为 0.24 以下时必须停机检修维护的结论,证明该方法的有效性,可为其开展预先维修提供参考依据。

由于电站构造复杂且退化因素多,本文只人工

模拟了几种工况,不能全面涵盖所有可能因素,后续进一步模拟更多工况以期更符合实际,增强该方法的指导针对性和实用性。

### 参考文献

- [1] 张祖森. 军用电站故障预测与健康管理系统设计分析[J]. 移动电源与车辆, 2018(4): 25-29.
- [2] 赵东明, 程焱明, 曹明. 基于卷积神经网络的柴油发电机健康评估[J]. 计算机科学, 2018, 45(Z11): 152-154.
- [3] 张盼盼. 基于数据驱动的电驱柴油发电机健康管理方法研究[D]. 兰州: 兰州理工大学, 2019.
- [4] 王德民, 王恒, 王起硕, 等. 基于层次分析法的船用柴油发电机组综合健康评估[J]. 机电设备, 2020, 37(3): 53-58.
- [5] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [6] 白雲杰, 贾希胜, 梁庆海, 等. 基于深度学习的柴油机气门健康状态评估[J]. 科学技术与工程, 2022, 22(10): 3941-3950.
- [7] SCHMID H J. Deep learning in neural networks: an overview[J]. Neural Networks, 2015(61): 85-117.
- [8] WANG H, XU J, YAN R Q. Intelligent bearing fault diagnosis using multi-head attention-based CNN[J]. Procedia Manufacturing, 2020(49): 112-118.
- [9] 刘万宇, 李宇鹏, 石怀涛, 等. 基于 WDCNN-DLSTM 的滚动轴承故障诊断方法[J]. 科学技术与工程, 2023, 23(13): 5522-5529.
- [10] 陈科, 段伟建, 吴胜利, 等. 多深度学习模型决策融合的齿轮箱故障诊断分类方法[J]. 科学技术与工程, 2022, 22(12): 4804-4811.
- [11] 丁石川, 厉雪衣, 杭俊, 等. 深度学习理论及其在电机故障诊断中的研究现状与展望[J]. 电力系统保护与控制, 2020, 48(8): 172-187.
- [12] 崔锦森. 基于卷积神经网络的滚动轴承故障识别方法研究[D]. 北京: 北京化工大学, 2021.
- [13] 孟亚辉. 基于最优特征集和马氏距离 KNN 分类的机械故障分类方法研究[J]. 机械设计与制造, 2017(7): 98-102.
- [14] 赵丽琴, 刘昶, 曹明生, 等. 复杂装备健康度评估方法研究综述[J]. 计算机测量与控制, 2021, 29(11): 1-7.
- [15] 和麟, 雷偲凡, 刘洋. 基于距离度量 and 健康指数的电子设备健康评估方法[J]. 计算机测量与控制, 2017, 25(10): 289-292.
- [16] 宋登巍, 吕琛, 齐乐, 等. 基于健康基线和马氏距离的液压系统变工况健康评估[J]. 系统仿真技术, 2017, 13(3): 201-208.
- [17] 孙鑫, 陈海松, 王清. 基于深度置信网络的移动电站电机故障诊断[J]. 装备制造技术, 2019(3): 168-170.

## A Health Status Evaluation Method for Military Power Station Based on CNN-MD

YIN Zhiyong, ZHONG Mingwei, WANG Yong, REN Xiaokun

(Shijiazhuang Campus, Army Engineering University of PLA, Shijiazhuang 050003, China)

**Abstract:** Pre maintenance of military power stations based on health status assessment is of great significance in improving their reliability and safety. Therefore, a CNN-MD based evaluation method is proposed to evaluate the health status of military power stations. It establishes a CNN military power station health status recognition model, which can recognize and output health status categories by training the model with different state samples. Introducing the MD algorithm again, calculating the MD distance between samples and healthy samples in different states, and normalizing it into a health index can further quantify the health evaluation results of power stations. Using a certain military power stations to artificially simulate different health conditions, experimental data was obtained. The model was able to effectively distinguish between normal, degraded, and attention states, and a quantitative evaluation health index of 0.6 was obtained as the critical threshold for normal states, and below 0.6 was the specific quantitative evaluation value for degraded states. The effectiveness of the proposed method was verified. This method combines CNN and MD to achieve the qualitative and quantitative evaluation of the health status of military power stations, providing a basis for pre maintenance.

**Keywords:** military power stations; health assessment; convolutional neural networks; mahalanobis distance; health indicators