

基于深度卷积神经网络与高斯混合模型的 水电机组异常声音检测

张 勇¹, 元文智¹, 段贵金¹, 王博宇¹, 刘豪睿²

(1. 雅砻江流域水电开发有限公司, 四川 成都 610051; 2. 北京华控智加科技有限公司, 北京 100084)

摘要: 为实现水电机组运行状态的安全监测, 解决自动化值守问题, 依据语音识别技术, 基于发电机组运行监测信息对水轮机部分测点的正常状态建模, 以实现异常检测。先使用西储大学轴承试验数据, 验证深度卷积神经网络(CNN)与高斯混合模型(GMM)组合建模方法的正确性; 其次针对水轮机组共布置了42个测点, 根据过速前后 RMS 的上升率, 选择10个敏感测点进行位置分类; 然后选取部分数据作为训练数据, 得到 CNN 模型及机组声音特征, 进一步训练并得到 GMM 模型; 最后利用测试数据的打分结果, 判断机器运行状态——即偏离正常状态的程度, 实现异常状态检测。该试验方案通过人工标注确认, 验证了方法的可行性, 实现了基于声音的水电机组异常检测算法设计。

关键词: 水轮发电机组; 深度卷积神经网络; 高斯混合模型; 异常检测; 声谱图

中图分类号: TK730; [TV734.1]

文献标志码: A

文章编号: 1000-7709(2023)08-0188-04

1 引言

机械设备出现故障时, 其产生的机械噪声特征通常会相应改变。振动和噪声信号可以真实地反映设备运行过程中的各种状态信息, 利用噪声信号对设备进行故障诊断具有设备安装位置灵活、可以监测带电设备及监测更高频率的设备信息等优点^[1,2]。水电机组作为水电站的关键设备, 在运行时主要会受到水流冲击、电磁耦合及机械旋转等三方面的耦合作用, 机组的噪声信号亦包含以上三个因素的信息^[3]。但现有研究仅依靠声音分贝值对水电机组进行状态监测, 极易受到噪声影响^[1]。在其他领域, 基于声音的设备故障诊断方法使用了正常数据和故障数据, 而在水电机组监测系统部署初期, 由于缺少标注的故障数据, 无法实现基于监督学习的诊断模型^[4]。因此, 针对故障数据特征选择及解决无标注故障数据的问题, 本文提出了深度卷积神经网络(CNN)结合高斯混合模型(GMM)共同建模的方法, 并经过开源数据集和人工标注共同验证了该方法适用于水电机组的异常检测。

2 深度卷积神经网络与高斯混合模型

基于声音识别技术的水轮机组异常检测方案, 算法流程见图1。整个过程可分成4个阶段: ①将原始声音信号数据转换为时频特征图; ②训练模型阶段利用 CNN 提取的声音特征建立 GMM 模型; ③阈值确定阶段用训练得到的模型对大量正常数据进行打分, 对这些打分分值统计分析, 确定异常检测阈值, 通常阈值可选择为低于均值3倍或6倍标准差; ④判别阶段将检测打分分值与阈值比对给出异常检测结果, 即检测分值低于异常检测阈值判定为异常状态, 否则为正常状态。




图1 基于声音识别技术的水轮机组异常检测方案
Fig. 1 Hydro-turbine anomaly detection scheme based on sound data

使用基于 MobileNetV2 的 bottlenecks 作为构建网络的主要模块, 激励函数采用 PReLU, 在网络的开始部分采用快速采样, 在最后几个卷积

层采用早期降维,在线性全局深度卷积层后加入一个线性卷积层作为特征输出。在训练中采用批量正则化。使用 CNN 模型,二维图像作为输入层,经过多级卷积池化操作,在全连接层之前得到深度结构化的抽象特征 embedding,这个 embedding 即为该类数据经 CNN 提取到的特征,可以作为其他模型的特征输入^[5,6]。

时间一维信号由短时傅里叶(STFT)进行时频分析,将得到的二维时频谱图作为 CNN 的输入。在生成时频图样本时,设置 STFT 参数帧长为 2 048,帧移为 512,帧数为 128,则生成的每个样本的尺寸为 2 048×128×1。

CNN 设计需要考虑输入样本尺寸、模型层数、每层卷积核的尺寸、每层卷积核的个数等参数。采用 CNN 结构输入样本尺寸为 2 048×128×1,在此基础上根据测试结构进行后续优化^[7]。表 1 为网络层参数说明,其中 IRB 表示 Inverted residual block 模块, t 表示通道扩张倍数, c 表示输出通道数, n 表示重复次数, s 表示步长。

表 1 CNN 模型结构

Tab. 1 CNN model structure

输入	操作	t	c	n	s
2 048×128×1	Conv 3×3		64	1	2
1 024×64×64	Depthwise Conv	1	64	2	1
1 024×64×64	IRB		64	1	1
1 024×64×64	IRB	2	64	5	2
512×32×64	IRB	4	128	1	2
256×16×128	IRB	2	128	6	1
256×16×128	IRB	4	128	1	2
128×8×128	IRB	4	128	1	2
64×4×128	IRB	4	128	1	2
32×2×128	IRB	4	128	1	2
16×1×128	Pointwise Conv		128	1	1
16×1×128	Linear GD Conv		128	1	1
1×1×128	Linear Conv 1x1		128	1	1

损失函数使用 ArcFace 损失函数,ArcFace 是对传统 Softmax Loss 的改进,Softmax Loss 的完整公式为:

$$L_1 = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{\mathbf{w}_{yi}^T \mathbf{x}_i + b_{yi}}}{\sum_{j=1}^{n_c} e^{\mathbf{w}_j^T \mathbf{x}_i + b_j}} \quad (1)$$

式中, L_1 为 Softmax 损失值; N 为样本数量; n_c 为样本分类的数量; \mathbf{W} 为权重矩阵; \mathbf{b} 为偏差向量, \mathbf{W} 和 \mathbf{b} 一起是获得特征向量的全连接层; \mathbf{x} 为特征向量。

令 $b_j = 0$, $\mathbf{W}_j^T \mathbf{x}_i = \|\mathbf{W}_j\| \|\mathbf{x}_i\| \cos\theta_j$, $\|\mathbf{W}_j\| = 1$, $\|\mathbf{x}_i\| = s$,则:

$$L_2 = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{s \cos\theta_{yi}}}{e^{s \cos\theta_{yi}} + \sum_{j=1, j \neq yi}^{n_c} e^{s \cos\theta_j}} \quad (2)$$

为了使类内对象紧致,类间对象分离,加上角度的 margin m ,则得到 ArcFace 的最终形式为:

$$L_{Arc} = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{s[\cos(\theta_{yi} + m)]}}{e^{s[\cos(\theta_{yi} + m)]} + \sum_{j \neq yi}^{n_c} e^{s[\cos(\theta_j, i)]}} \quad (3)$$

式中, L_{Arc} 为 ArcFace 损失值。

通过 CNN 提取声音特征后,利用统计学习方法建立异常检测模型。拟定算法为高斯混合模型(GMM)。多维混合高斯模型是一个实现如下目标的统计学习模型:

$$p(\vec{x}) = \sum_{i=1}^K \phi_i \xi(\vec{x} | \vec{\mu}_i, \Sigma_i) \quad (4)$$

$$\xi(\vec{x} | \vec{\mu}_i, \Sigma_i) = \frac{1}{\sqrt{(2\pi)^K |\Sigma_i|}} \cdot \exp\left(-\frac{1}{2}(\vec{x} - \vec{\mu}_i)^T \Sigma_i^{-1}(\vec{x} - \vec{\mu}_i)\right) \quad (5)$$

$$\sum_{i=1}^K \phi_i = 1 \quad (6)$$

式中, $p(\vec{x})$ 为观测值为 \vec{x} 的概率; \vec{x} 为观测值; ϕ_i 为混合权重; $\xi(\vec{x} | \vec{\mu}_i, \Sigma_i)$ 为高斯函数; K 为需要给定的超参数; $\vec{\mu}_i$ 为第 i 个高斯分布均值; Σ_i 为第 i 个高斯分布的协方差。

GMM 建模就是给定混合数后估计每个高斯函数的均值与方差及其混合权重。将采集到的所有正常数据输入基于 CNN 的声音特征提取模型提取声音特征向量,对所有特征向量训练得到一个水轮机组正常状态的高斯混合模型(GMM)。

3 CNN-GMM 模型检测效果测试

为验证 CNN 与 GMM 联合方法(GNN-GMM)的性能,采用美国凯斯西储大学轴承数据中心的振动数据作为测试对象^[8,9]。其试验平台主要构件为一个 150 kg·m/s 的电机、扭矩传感器、功率测试计及电控设备,电机通过联轴器和扭矩传感器与功率测试计连接。电机驱动端的轴承型号为 SKF6205,信号采样频率为 12 kHz。轴承数据的状态分类为正常、滚动体故障、内圈故障、外圈故障。

经统计,每类轴承状态数据的总时长约 160~280 s,数据量总体较小。为避免因数据量少造成模型无法收敛、过拟合等问题,对每条数据扩充处

理以增大数据量。扩充方案为设置固定长度窗口 n_t ，窗口移动步长 h ，按照类别逐条移动截取原始轴承信号，依次获得各个类别扩充后的新样本数据。

将扩充得到的四类轴承样本数据，按照一定的规则选取每类数据的 50% 作为训练数据，导入 CNN 训练，得到关于这四类轴承状态的模型。本次训练将样本数据经 STFT 变换得到的时频谱图作为 CNN 的输入，设置 STFT 参数帧长 2 048，帧移 512，帧数 128，导入模型的每条样本的尺寸为 $2\ 048 \times 128 \times 1$ 。选取每个轴承状态的全部数据作为测试数据，导入训练得到的模型，得到每类信号的分类效果。图 2 显示了使用原始声音测试数据，导入 CNN 模型训练得到的模型分类测试的打分结果。结合分类测试结果(图 2(c))，可以看出 CNN 训练得到的模型在内圈测试样本具有一定的局限性，




图 2 轴承不同故障信号 CNN 分类测试结果
Fig. 2 Classification of different bearing fault signal based on CNN

将各类测试数据导入 CNN 模型进行分类测试，得到该类数据的 embedding 特征，再经过训练得到相应的 GMM 模型。结合图 3 中四类测试模型的分类测试结果，可以看出 CNN+GMM 训练得到的模型可以很好地区分各类数据，本次测试数据识别的准确率达到 100%。




图 3 轴承不同故障信号特征的 GMM 测试结果
Fig. 3 GMM test results for different bearing fault

4 水电机组声音数据异常检测

以雅砻江水电站#2 机组声音监测系统部分测点的声音数据为例。声音采集装置采集信号数

据为声压，对各个测点的声压进行有效值趋势分析 RMS 的计算，声压值计算公式为：

$$x_{RMS} = \sqrt{(x_1^2 + x_2^2 + \dots + x_n^2) / n_{all}} \quad (7)$$

式中， x_1, x_2, \dots, x_n 为采样时间内样本点的声压值； n_{all} 为样本点数量。

图 4 为各个测点声压的 RMS 趋势图。由图 4 可看出，水车室侧壁测点采集到的声音有效值对机组的负荷和负荷变化具有良好的区别性。尾水进人门测点采集到的声音有效值对机组的负荷具有区别性，但对负荷的瞬间变化不是特别敏感。发电机风洞侧壁和定子机座测点采集到的声音有效值对机组的甩负荷具有良好的指示性，但对负荷稳定状态和升负荷没有区分性。依据表 2 中 RMS 上升率的最大值，在每处位置选定反应较为明显的 10 个测点用于建立模型。

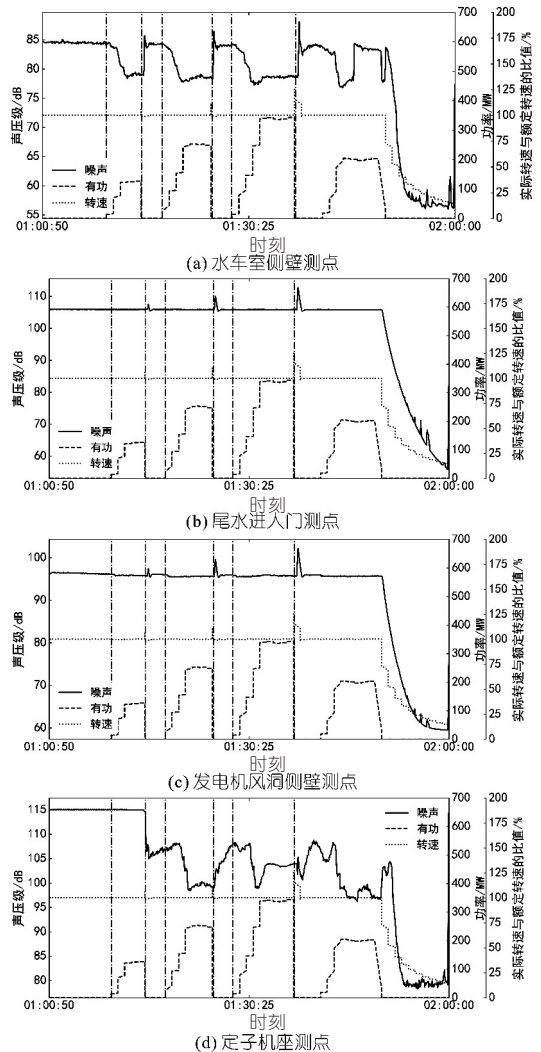


图 4 部分测点声音有效值趋势分析图

Fig. 4 Sound effective value trend analysis of some points

将传感器测点位置作为分类依据，导入 CNN 构建的机组正常状态模型，模型可以很好地将各类数据正确分类，说明 CNN 模型提取的每类数据的特征很好地匹配了该类别数据。将待检测机

表 2 过速时刻 RMS 上升率对比表

Tab. 2 Comparison of RMS rise rate at overspeed moment

测点编号	测点名称	过速前	过速后	上升率/%
94C96000C3A5	水车室侧壁 4	71.9	73.8	2.8
94C96000C33D	顶盖腹板上部 1	99.9	101.7	1.8
94C96000C39A	水导轴承 2	90.9	97.5	7.3
94C96000C31C	发电机风洞侧壁 2	92.3	95.9	3.8
94C96000C324	下导轴承 2	91.2	102.2	12.0
94C96000C350	下机架支臂 2	91.2	95.2	4.4
94C96000C3BB	滑环室侧壁 4	71.2	75.5	6.1
94C96000C336	定子机座 4	70.2	74.3	5.8
94C96000C390	蜗壳进入门 1	106.1	109.3	3.1
94C96000C38C	尾水进入门 1	96.9	100.7	3.9

组状态数据经过 CNN 模型得到的特征作为输入,导入机组异常检测 GMM 模型,模型对每条输入的数据打分,分值越低的数据偏离模型的程度越大,需要重点关注数据异常的原因。

机组测点每条原始数据的长度为 60 s,设置 42 ms 窗长,25%的重叠率,将一条原始数据截取为多个样本。依次对每个测点的每条输入数据打分,最终得到每个测点的异常检测分数分布图。

异常数据标注步骤中,图 5 为水轮机组异常检测模型对其中一个测点数据的打分结果,异常检测模型的打分越低数据越偏离模型。按照一定的规则初步设置阈值,筛选每个测点分数较低的数据,得到一个初步的异常样本集合,见表 3。该

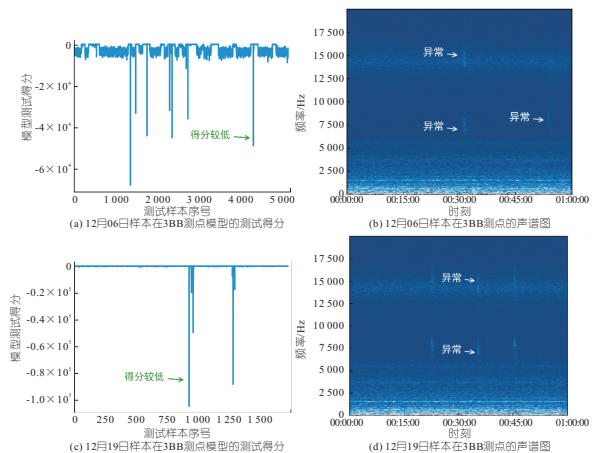


图 5 3BB 测点测点的异常检测结果

Fig. 5 Abnormal detection results of 3BB measurement point

表 3 水轮机组各测点异常数据标注结果

Tab. 3 Hydro-turbine generator set abnormal data labeling results for the respective measurement points

测点位置	信号类型	数据条数	测点位置	信号类型	数据条数
水车室侧壁	正常	5 263	下机架支臂	正常	5 263
	关机	15 632		关机	15 632
	其他(异常)	19		其他(异常)	20
顶盖腹板	正常	5 263	滑环室侧壁	正常	5 263
	关机	15 632		关机	15 632
	其他(异常)	23		其他(异常)	56
水导轴承	正常	5 263	定子基座	正常	5 263
	关机	15 632		关机	15 632
	其他(异常)	34		其他(异常)	35
发电机风洞侧壁	正常	5 263	尾水进入门	正常	5 263
	关机	15 632		关机	15 632
	其他(异常)	26		其他(异常)	45
下导轴承	正常	5 263			
	关机	15 632			
	其他(异常)	21			

异常样本经后期人工标注进行逐条验证,识别为设备蜂鸣声、切割、设备启动、施工干扰、停机过程和物体掉落。

5 结论

a. 以西储大学轴承数据为试验数据,验证了 CNN 与 GMM 组合的异常检测模型的有效性。通过采集水轮机组工况状态中声音信号,以正常运行状态采集的声音数据为训练样本,建立正常状态的声学识别模型。将 10 个测点的实时采集的声音数据输入声学识别模型打分(分值越高表示测试样本属于打分模型对应状态的概率越高),根据分值判断当前状态和正常状态的偏离程度。设定一个 6 倍标准差作为阈值判别准则,打分值低于该阈值就判别为异常状态,并发出报警。

b. 通过记录机组的实际运行工况,包括升/甩负荷、过速、停机等机组试验,并结合人工标注进行验证。数据分析证明了基于 CNN 与 GMM 组合的异常检测模型的有效性。

参考文献:

- [1] 杜江. 声音监测在水轮发电机组状态监测中的应用[J]. 自动化应用,2020(10):91-92,96.
- [2] 季燕羽,吴贤芳,刘厚林,等. 轴流泵内部流动诱导噪声数值研究[J]. 水电能源科学,2018,36(7):130-134.
- [3] 王惠芝,周大庆,张蓝国. 低比转速混流式水轮机流动噪声数值模拟[J]. 水电能源科学,2014,32(8):153-156.
- [4] CARALHO A T, LIMA A C S, CUNHA F F C, et al. Identification of partial discharges immersed in noise in large hydro-generators based on improved wavelet selection methods [J]. Measurement, 2015, 75: 122-133.
- [5] 何胜明,刘剑,胡捷,等. 基于声音特征的水力发电机组试验分析[J]. 中国农村水利水电,2022(2):226-232,238.
- [6] 张志博,钟献词,谢仁奎. 基于比率方法和 BP 神经网络的柳州市工业需水量区间预测[J]. 水电能源科学,2022,40(4):54-57.
- [7] 梁腾,姜文宗,王立,等. 神经网络的声场景自动分类方法[J]. 应用声学,2022,41(3):373-380.
- [8] 万晓静,孙文磊,陈坤. 小波包能量熵和改进的 LSSVM 在风力机轴承故障诊断中的应用[J]. 水电能源科学,2021,39(2):142-145.
- [9] 唐磊,陈启卷,王卫玉,等. 基于征兆驱动和专家推理的水电机组轴承状态分析[J]. 水电能源科学,2018,36(5):137-140,178.




图 7 PL13-1、PL19-5、PL11-3 测点时效变形序列

Fig. 7 Aging deformation sequences of PL13-1, PL19-5 and PL11-3 measuring points




图 8 跨区域协整模型监控结果

Fig. 8 Monitoring results of the cross-regional co-integration model

5 结论

a. 利用小波分解得到时效变形, 提出描述各测点时效变形间相似程度的相对增速距离指标,

Co-integration Monitoring Model for Aging Deformation of Multi-measuring Points of Extra-high Arch Dam and Its Application

LIU Wei-qi^{1a,1b}, CHEN Bo^{1a,1b}, LIU Ting-he²

(1a. College of Water Conservancy and Hydropower Engineering; 1b. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China; 2. China Water Northeastern Investigation, Design & Research Co., Ltd., Changchun 130021, China)

Abstract: The measured deformation data contain rich temporal and spatial information and evolution laws of dam deformation. To study the co-integration relationship of the aging deformation of extra-high arch dams, wavelet decomposition was firstly used to obtain the aging component of the dam displacement. Considering the weak spatial integrity of extra-high arch dams, the FCM clustering algorithm was utilized to realize the regionalization of aging deformation. With the help of the idea of regional linearization, the spatial nonlinear co-integration relationship of the whole dam aging deformation was transformed into several approximate linear co-integration relationships within different regions. The zonal co-integration model was established to describe the development law of time-varying co-integration in different regions of the dam. The co-integration development monitoring and early warning of multi-measuring points aging deformation were realized by co-integration residual.

Key words: extra-high arch dam; aging deformation; co-integration theory; monitoring model

(上接第 191 页)

Detection of Abnormal Sound of Hydroelectric Unit Based on Combination of Deep Convolutional Neural Network and Gaussian Mixture Model

ZHANG Yong¹, YUAN Wen-zhi¹, DUAN Gui-jin¹, WANG Bo-yu¹, LIU Hao-rui²

(1. Yalong River Hydropower Development Company, LTD., Chengdu 610051, China; 2. Tsinghua AI Plus, Beijing 100084, China)

Abstract: In order to realize the safe monitoring of the operation status of hydroelectric units and solve the problem of automated watch keeping, based on speech recognition technology, the normal status model of measurement points based on the operation monitoring information of generating units was established to implement abnormality detection. Firstly, the experimental data of the bearings of Western Reserve University were used to verify the correctness of the selected modeling method of deep convolutional neural network (CNN) and Gaussian mixture model (GMM). Secondly, a total of forty-two measurement points were arranged for the turbine set, and ten sensitive measurement points were selected for position classification based on the rise rate of RMS before and after overspeed. Then some data were selected as training data to get CNN model and unit sound features. The GMM model was obtained by further training. Finally, the scoring results of the test data were used to determine the machine operation status, i. e., the degree of deviation from the normal status was determined to achieve abnormal status detection. The experimental scheme was confirmed by manual annotation, thus verifying the feasibility of the method, which realizes the design of sound-based abnormality detection algorithm for hydropower units.

Key words: hydroelectric unit; deep convolutional neural network; Gaussian mixture model; abnormal detection; spectrogram

并基于 FCM 聚类算法实现了时效变形的区域化分析, 并将时效变形空间非线性协整关系转化为区域线性协整关系。

b. 在聚类分区的基础上, 建立了多测点时效变形的协整监控模型, 以协整残差作为时效变形协整关系的监控指标。并以某特高拱坝为例, 检验各区域内测点时效变形的协整关系, 验证了同区域内时效变形协整关系成立的可能性; 建立了各区域测点时效变形的协整方程, 发现协整残差尚未出现异常, 各区域时效变形稳定均衡发展。

参考文献:

[1] 胡波, 刘观标, 吴中如. 基于原型监测的小湾特高拱坝首蓄期坝基变形特性分析[J]. 水电自动化与大坝监测, 2012, 36(5): 14-20.

[2] 王少伟, 包腾飞. 特高混凝土坝变形时变效应特征分析[J]. 常州大学学报(自然科学版), 2018, 30(6): 79-86.

[3] 顾冲时, 苏怀智, 王少伟. 高混凝土坝长期变形特性计算模型及监控方法研究进展[J]. 水力发电学报, 2016, 35(5): 1-14.

[4] 郑泓, 段忠东. 考虑非线性环境因素影响的结构损伤预警方法研究[J]. 振动工程学报, 2021, 34(6): 1101-1111.