



(21) 申请号 202410577172.9

(22) 申请日 2024.05.10

(65) 同一申请的已公布的文献号

申请公布号 CN 118130984 A

(43) 申请公布日 2024.06.04

(73) 专利权人 山东博通节能科技有限公司

地址 250000 山东省济南市高新区龙奥北

路9号海信大厦4号楼503室

(72) 发明人 王赛 马琳 范鹏 范泽钰

范文龙 侯鲁剑

(74) 专利代理机构 安徽谷知知识产权代理事务

所(普通合伙) 34286

专利代理师 李航

(51) Int. Cl.

G01R 31/12 (2020.01)

(56) 对比文件

CN 117590173 A, 2024.02.23

CN 116736051 A, 2023.09.12

审查员 石敏

权利要求书3页 说明书9页 附图2页

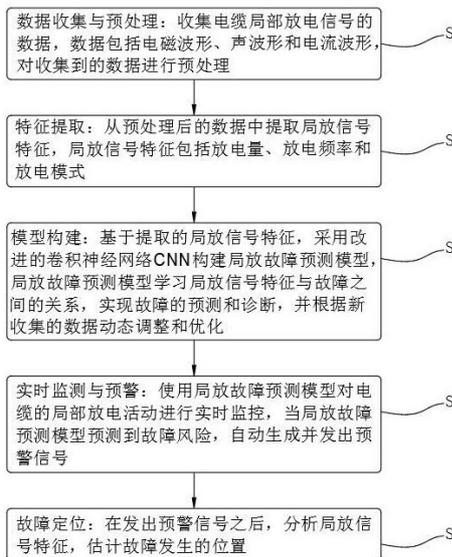
## (54) 发明名称

基于数据驱动的电缆局放故障实时监测方

法

## (57) 摘要

本发明涉及电缆故障监测技术领域,具体涉及基于数据驱动的电缆局放故障实时监测方法,包括以下步骤:S1,数据收集与预处理:收集电缆局部放电信号的数据,对收集到的数据进行预处理;S2,特征提取:提取局放信号特征;S3,模型构建:构建局放故障预测模型,局放故障预测模型学习局放信号特征与故障之间的关系,实现故障的预测和诊断;S4,实时监测与预警:使用局放故障预测模型对电缆的局部放电活动进行实时监控;S5,故障定位:在发出预警信号之后,分析局放信号特征,估计故障发生的位置。本发明,为故障预测模型提供了高质量的输入数据,从而大大提高了电缆局放故障检测的准确性和效率。



1. 基于数据驱动的电缆局放故障实时监测方法,其特征在于,包括以下步骤:

S1,数据收集与预处理:收集电缆局部放电信号的数据,数据包括电磁波形、声波形和电流波形,对收集到的数据进行预处理;

S2,特征提取:从预处理后的数据中提取局放信号特征,局放信号特征包括放电量、放电频率和放电模式;

S3,模型构建:基于提取的局放信号特征,采用改进的卷积神经网络CNN构建局放故障预测模型,局放故障预测模型学习局放信号特征与故障之间的关系,实现故障的预测和诊断,并根据新收集的数据动态调整和优化;

S4,实时监测与预警:使用局放故障预测模型对电缆的局部放电活动进行实时监控,当局放故障预测模型预测到故障风险,自动生成并发出预警信号;

S5,故障定位:在发出预警信号之后,分析局放信号特征,估计故障发生的位置;

所述S1中的数据收集与预处理包括:

S11,数据收集:通过部署在电缆周围的多种传感器收集局部放电信号的数据,多种传感器包括电磁波形传感器、声波形传感器以及电流波形传感器;

S12,数据预处理:对收集到的局放信号数据进行预处理操作,包括去噪处理、标准化处理以及同步校正;

所述S2中的特征提取包括:

放电量特征提取:放电量表示为电荷量,是局放事件中释放电荷的量度,通过积分局放电流波形对预处理后的电流波形数据进行计算;

放电频率特征提取:放电频率是在单位时间内局放事件发生的次数,通过局放事件间隔时间的倒数来计算放电频率;

放电模式特征提取:放电模式涉及到局放信号的波形分析,通过傅里叶变换,将时域信号转换为频域信号,从而分析不同频率成分;

所述S3中的模型构建包括:

特征融合:将提取的局放信号特征进行融合,形成综合特征向量;

模型选择与训练:通过改进的卷积神经网络CNN构建局放故障预测模型,使用局部放电信号的数据及对应的故障诊断结果作为训练集,训练局放故障预测模型学习局放信号特征与故障类型之间的关系;

模型验证与调优:在独立的测试集上评估局放故障预测模型的性能,包括准确率、召回率和F1分数,基于评估结果对局放故障预测模型的参数进行调优;

动态调整机制:引入动态调整机制,允许局放故障预测模型根据新收集到的数据自我学习和调整;

实时预测与诊断:将实时收集的局部放电信号的数据输入到训练好的局放故障预测模型中,局放故障预测模型对基于学习到的局放信号特征与故障关系进行故障的预测和诊断;

所述改进的卷积神经网络CNN在卷积层引入局放信号强度 $LSI$ 调制因子,使卷积核的应用更加敏感于局放信号的强度变化,计算公式为:

$$f_{out}(i) = \sum_{j=1}^k (f_{in}(i+j) \cdot \gamma \cdot LSI_{i+j}) \cdot w(j);$$

其中,  $f_{out}(i)$ 表示在输出特征图上位置*i*的值,  $f_{in}(i+j)$ 表示输入特征图上位置*i+j*的值, *j*是卷积核覆盖的相对位置索引, *k*是卷积核的大小,  $LSI_{i+j}$ 表示在位置*i+j*处局放信号的强度信息,  $\gamma$ 是调节参数,  $w(j)$ 是卷积核在位置*j*的权重值;

所述局放信号强度 $LSI$ 反映局放事件的电荷量大小,通过分析局放信号的电磁波形、声波形或电流波形中的峰值强度来计算,计算方法包括:

信号强度提取:对于每个局放信号样本,计算在不同通道中的峰值强度,计算公式为:

$$PeakIntensity_{channel} = \max(|f_{in}|);$$

其中,  $|f_{in}|$ 代表在通道中的局放信号绝对值;

标准化处理:对提取的信号强度进行标准化处理,计算公式为:

$$LSI_{channel} = \frac{PeakIntensity_{channel} - \min(PeakIntensity_{channel})}{\max(PeakIntensity_{channel}) - \min(PeakIntensity_{channel})};$$

处理后的每个通道的 $LSI$ 值将位于[0,1]区间内,其中,0表示最低信号强度,1表示最高信号强度;

$LSI$ 调制因子计算:综合各通道的 $LSI$ 值得到最终的 $LSI$ 调制因子,计算公式为:

$$LSI = \frac{1}{N} \sum_{n=1}^N LSI_{channel_n}, \text{其中, } N \text{是通道数。}$$

2. 根据权利要求1所述的基于数据驱动的电缆局放故障实时监测方法,其特征在于,所述模型验证与调优包括:

独立测试集的准备:从收集的电缆局放数据中分割出一部分数据作为测试集;

性能评估指标计算:

$$\text{准确率 } Accuracy \text{ 计算公式为: } Accuracy = \frac{TP + TN}{TP + TN + FP + FN};$$

其中, $TP$ 和 $TN$ 分别是局放故障预测模型正确识别的故障和非故障事件数量, $FP$ 和 $FN$ 分别是局放故障预测模型错误识别的故障和非故障事件数量;

$$\text{召回率 } Recall \text{ 的计算公式为: } Recall = \frac{TP}{TP + FN};$$

$$F1 \text{ 分数的计算公式为: } F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall};$$

$$\text{其中,精确度 } Precision \text{ 的计算公式为: } Precision = \frac{TP}{TP + FP};$$

基于评估结果对模型参数进行调优:根据评估指标的结果,对局放故障预测模型的参数进行细微调整以优化性能,包括调整学习率、修改网络层的数量或大小、调整正则化项。

3. 根据权利要求2所述的基于数据驱动的电缆局放故障实时监测方法,其特征在于,所述动态调整机制包括:

持续监控模型性能:定期评估局放故障预测模型的性能评估指标,当性能评估指标低于预定阈值时,自动触发动态调整流程;

数据驱动的调整决策:分析新收集的局部放电信号的数据,分析局放故障预测模型性能下降的原因,基于分析结果,决定执行调整策略,调整策略包括局放故障预测模型参数的微调、训练集的更新以及重新训练;

模型参数的微调:对局放故障预测模型进行微调,微调包括调整卷积层权重、偏置项;

训练集的更新:将新收集到的局部放电信号的数据及对应的故障诊断结果定期加入训练集,扩大训练集的覆盖范围,使局放故障预测模型学习到电缆运行条件的变化和新出现故障模式的信息;

重新训练过程:在训练集发生变化或局放故障预测模型性能下降时,进行局放故障预测模型的重新训练,重新训练包括使用更新后的训练集或者调整模型结构。

4. 根据权利要求3所述的基于数据驱动的电缆局放故障实时监测方法,其特征在于,所述S5中的故障定位包括:

信号特征分析:在发出预警信号之后,对与预警相关的局放信号特征进行分析,分析包括局放信号特征之间的关系以及局放信号特征与已知故障位置之间的相关性;

利用空间信息:结合局放信号的空间信息,应用时间差定位技术来估计故障位置;

所述时间差定位技术具体包括:

信号时间记录:在多个已知位置的传感器上记录局放信号到达的确切时间;

计算时间差:对于每一对传感器,计算信号到达每一对传感器之间的时间差,即

$$\Delta t = t_2 - t_1;$$

多边测量定位:根据信号传播速度 $v$ 和时间差 $\Delta t$ ,应用多边测量法求解故障位置,对于每一对传感器,故障到传感器的距离差等于信号传播速度乘以时间差,即 $d_{diff} = v \cdot \Delta t$ ;

故障位置推算:结合所有传感器对的时间差数据,推算故障的位置。

5. 根据权利要求4所述的基于数据驱动的电缆局放故障实时监测方法,其特征在于,所述故障定位还包括信号强度差异技术,所述信号强度差异技术具体包括:

信号强度测量:测量每个传感器接收到的局放信号的强度;

建立衰减模型:使用路径损耗模型表示信号强度与距离之间的关系,路径损耗模型表示为:

$$RSSI = RSSI_0 - 10 \cdot m \cdot \log_{10}(d/d_0);$$

其中, $RSSI$ 是在距离 $d$ 处测量到的信号强度, $RSSI_0$ 是在参考距离 $d_0$ 处的信号强度, $m$ 是环境因子, $d$ 是从故障点到传感器的距离;

距离估计:根据测量到的 $RSSI$ 值和路径损耗模型,估算故障点到各个传感器的距离;

位置推算:结合所有传感器的距离估计,推算故障的位置。

## 基于数据驱动的电缆局放故障实时监测方法

### 技术领域

[0001] 本发明涉及电缆故障监测技术领域,尤其涉及基于数据驱动的电缆局放故障实时监测方法。

### 背景技术

[0002] 在现有的电力系统运维中,电缆局放是一种常见且具有潜在破坏性的现象,它通常预示着电力设备绝缘材料的老化或损坏,可能导致设备故障甚至系统事故,因此,对电缆局放活动进行实时监测和准确诊断变得尤为重要,传统的局放监测方法主要依赖于周期性的物理检查和简单的信号分析技术,这些方法往往耗时长、成本高,且无法实现对电缆局放行为的连续实时监控,同时在故障诊断的准确性和及时性上也存在不足。

[0003] 随着信息技术和人工智能的迅速发展,基于数据驱动的智能监测方法为电缆局放的检测与诊断提供了新的解决方案,这些方法能够利用各种传感器实时收集电缆局放信号,并通过先进的信号处理和机器学习技术,自动分析局放信号的特征,实现对电缆局放故障的即时预警和精确定位,然而,如何更有效地提取局放信号中的关键特征,构建准确可靠的故障预测模型,并实现对电缆局放故障的快速定位,仍是当前研究和应用中需要解决的关键问题。

### 发明内容

[0004] 基于上述目的,本发明提供了基于数据驱动的电缆局放故障实时监测方法。

[0005] 基于数据驱动的电缆局放故障实时监测方法,包括以下步骤:

[0006] S1,数据收集与预处理:收集电缆局部放电信号的数据,数据包括电磁波形、声波形和电流波形,对收集到的数据进行预处理;

[0007] S2,特征提取:从预处理后的数据中提取局放信号特征,局放信号特征包括放电量、放电频率和放电模式;

[0008] S3,模型构建:基于提取的局放信号特征,采用改进的卷积神经网络CNN构建局放故障预测模型,局放故障预测模型学习局放信号特征与故障之间的关系,实现故障的预测和诊断,并根据新收集的数据动态调整和优化;

[0009] S4,实时监测与预警:使用局放故障预测模型对电缆的局部放电活动进行实时监控,当局放故障预测模型预测到故障风险,自动生成并发出预警信号;

[0010] S5,故障定位:在发出预警信号之后,分析局放信号特征,估计故障发生的位置。

[0011] 进一步的,所述S1中的数据收集与预处理包括:

[0012] S11,数据收集:通过部署在电缆周围的多种传感器收集局部放电信号的数据,多种传感器包括电磁波形传感器、声波形传感器以及电流波形传感器;

[0013] S12,数据预处理:对收集到的局放信号数据进行预处理操作,包括去噪处理、标准化处理以及同步校正。

[0014] 进一步的,所述S2中的特征提取包括:

[0015] 放电量特征提取:放电量表示为电荷量,是局放事件中释放电荷的量度,通过积分局放电流波形对预处理后的电流波形数据进行计算;

[0016] 放电频率特征提取:放电频率是在单位时间内局放事件发生的次数,通过局放事件间隔时间的倒数来计算放电频率;

[0017] 放电模式特征提取:放电模式涉及到局放信号的波形分析,通过傅里叶变换,将时域信号转换为频域信号,从而分析不同频率成分。

[0018] 进一步的,所述S3中的模型构建包括:

[0019] 特征融合:将提取的局放信号特征进行融合,形成综合特征向量;

[0020] 模型选择与训练:通过改进的卷积神经网络CNN构建局放故障预测模型,使用局部放电信号的数据及对应的故障诊断结果作为训练集,训练局放故障预测模型学习局放信号特征与故障类型之间的关系;

[0021] 模型验证与调优:在独立的测试集上评估局放故障预测模型的性能,包括准确率、召回率和F1分数,基于评估结果对局放故障预测模型的参数进行调优;

[0022] 动态调整机制:引入动态调整机制,允许局放故障预测模型根据新收集到的数据自我学习和调整;

[0023] 实时预测与诊断:将实时收集的局部放电信号的数据输入到训练好的局放故障预测模型中,局放故障预测模型对基于学习到的局放信号特征与故障关系进行故障的预测和诊断。

[0024] 进一步的,所述改进的卷积神经网络CNN在卷积层引入局放信号强度 $LSI$ 调制因子,使卷积核的应用更加敏感于局放信号的强度变化,计算公式为:

$$[0025] \quad f_{out}(i) = \sum_{j=1}^k (f_{in}(i+j) \cdot \gamma \cdot LSI_{i+j}) \cdot w(j);$$

[0026] 其中, $f_{out}(i)$ 表示在输出特征图上位置 $i$ 的值, $f_{in}(i+j)$ 表示输入特征图上位置 $i+j$ 的值, $j$ 是卷积核覆盖的相对位置索引, $k$ 是卷积核的大小, $LSI_{i+j}$ 表示在位置 $i+j$ 处局放信号的强度信息, $\gamma$ 是调节参数, $w(j)$ 是卷积核在位置 $j$ 的权重值。

[0027] 进一步的,所述局放信号强度 $LSI$ 反映局放事件的电荷量大小,通过分析局放信号的电磁波形、声波形或电流波形中的峰值强度来计算,计算方法包括:

[0028] 信号强度提取:对于每个局放信号样本,计算在不同通道(如电磁、声波、电流)中的峰值强度,计算公式为:

$$[0029] \quad PeakIntensity_{channel} = \max(|f_{in}|);$$

[0030] 其中, $|f_{in}|$ 代表在通道中的局放信号绝对值;

[0031] 标准化处理:对提取的信号强度进行标准化处理,计算公式为:

$$[0032] \quad LSI_{channel} = \frac{PeakIntensity_{channel} - \min(PeakIntensity_{channel})}{\max(PeakIntensity_{channel}) - \min(PeakIntensity_{channel})};$$

[0033] 处理后的每个通道的 $LSI$ 值将位于 $[0,1]$ 区间内,其中,0表示最低信号强度,1表示最高信号强度;

[0034]  $LSI$ 调制因子计算:综合各通道的 $LSI$ 值得到最终的 $LSI$ 调制因子,计算公式为:

[0035]  $LSI = \frac{1}{N} \sum_{n=1}^N LSI_{channel_n}$ , 其中,  $N$  是通道数。

[0036] 进一步的, 所述模型验证与调优包括:

[0037] 独立测试集的准备: 从收集的电缆局放数据中分割出一部分数据作为测试集;

[0038] 性能评估指标计算:

[0039] 准确率 *Accuracy* 计算公式为:  $Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$ ;

[0040] 其中,  $TP$  (真正例) 和  $TN$  (真负例) 分别是局放故障预测模型正确识别的故障和非故障事件数量,  $FP$  (假正例) 和  $FN$  (假负例) 分别是局放故障预测模型错误识别的故障和非故障事件数量;

[0041] 召回率 *Recall* 的计算公式为:  $Recall = \frac{TP}{TP + FN}$ ;

[0042] *F1* 分数的计算公式为:  $F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$ ;

[0043] 其中, 精确度 *Precision* 的计算公式为:  $Precision = \frac{TP}{TP + FP}$ ;

[0044] 基于评估结果对模型参数进行调优: 根据评估指标的结果, 对局放故障预测模型的参数进行细微调整以优化性能, 包括调整学习率、修改网络层的数量或大小、调整正则化项。

[0045] 进一步的, 所述动态调整机制包括:

[0046] 持续监控模型性能: 定期评估局放故障预测模型的性能评估指标, 当性能评估指标低于预定阈值时, 自动触发动态调整流程;

[0047] 数据驱动的调整决策: 分析新收集的局部放电信号的数据, 分析局放故障预测模型性能下降的原因, 基于分析结果, 决定执行调整策略, 调整策略包括局放故障预测模型参数的微调、训练集的更新以及重新训练;

[0048] 模型参数的微调: 对局放故障预测模型进行微调, 微调包括调整卷积层权重、偏置项;

[0049] 训练集的更新: 将新收集到的局部放电信号的数据及对应的故障诊断结果定期加入训练集, 扩大训练集的覆盖范围, 使局放故障预测模型学习到电缆运行条件的变化和新出现故障模式的信息;

[0050] 重新训练过程: 在训练集发生变化或局放故障预测模型性能下降时, 进行局放故障预测模型的重新训练, 重新训练包括使用更新后的训练集或者调整模型结构。

[0051] 进一步的, 所述  $S5$  中的故障定位包括:

[0052] 信号特征分析: 在发出预警信号之后, 对与预警相关的局放信号特征进行分析, 分析包括局放信号特征之间的关系以及局放信号特征与已知故障位置之间的相关性;

[0053] 利用空间信息: 结合局放信号的空间信息, 应用时间差定位技术来估计故障位置;

[0054] 所述时间差定位技术具体包括:

[0055] 信号时间记录: 在多个已知位置的传感器上记录局放信号到达的确切时间;

[0056] 计算时间差: 对于每一对传感器, 计算信号到达每一对传感器之间的时间差, 即

$$\Delta t = t_2 - t_1;$$

[0057] 多边测量定位:根据信号传播速度 $v$ 和时间差 $\Delta t$ ,应用多边测量法求解故障位置,对于每一对传感器,故障到传感器的距离差等于信号传播速度乘以时间差,即 $d_{diff} = v \cdot \Delta t$ ;

[0058] 故障位置推算:结合所有传感器对的时间差数据,推算故障的位置。

[0059] 进一步的,所述故障定位还包括信号强度差异技术,所述信号强度差异技术具体包括:

[0060] 信号强度测量:测量每个传感器接收到的局放信号的强度;

[0061] 建立衰减模型:使用路径损耗模型表示信号强度与距离之间的关系,路径损耗模型表示为:

[0062]  $RSSI = RSSI_0 - 10 \cdot m \cdot \log_{10}(d/d_0)$ ;

[0063] 其中, $RSSI$ 是在距离 $d$ 处测量到的信号强度, $RSSI_0$ 是在参考距离 $d_0$ 处的信号强度, $m$ 是环境因子, $d$ 是从故障点到传感器的距离;

[0064] 距离估计:根据测量到的 $RSSI$ 值和路径损耗模型,估算故障点到各个传感器的距离;

[0065] 位置推算:结合所有传感器的距离估计,推算故障的位置。

[0066] 本发明的有益效果:

[0067] 本发明,通过高效的数据收集与预处理步骤,能够精确捕捉和处理来自电缆局部放电的关键信号数据,包括电磁波形、声波形和电流波形,预处理操作提高了数据的质量和后续分析的准确性,这一优点确保了从信号中提取的特征能够准确反映局放事件的实际情况,为故障预测模型提供了高质量的输入数据,从而大大提高了电缆局放故障检测的准确性和效率。

[0068] 本发明,通过改进的卷积神经网络CNN构建的局放故障预测模型,能够深入学习局放信号特征与故障之间的复杂关系,实现对故障的准确预测和诊断,特别是,模型通过引入局放信号强度调制因子,增强了对电缆局放故障特征的识别能力,特别是在分析局放信号强度变化时更加敏感,这对于识别和预测电缆局放故障至关重要,此外,模型还具有根据新收集的数据动态调整和优化的能力,确保随着时间的推移和电缆系统状态的变化,模型能够持续适应新的故障模式和条件变化。

[0069] 本发明,通过时间差定位技术和信号强度差异技术,能够估计故障发生的位置,不仅提高了故障定位的准确性,还大大加快了故障诊断的速度,为快速解决电缆局放故障提供了有力支持,故障定位信息极大地减少了维护成本,提高了电力系统的可靠性和安全性,通过结合局放信号的空间信息,能够为维修工作和快速解决故障提供精确的指导,大大提升了电缆维护和管理的效率。

## 附图说明

[0070] 为了更清楚地说明本发明或现有技术中的技术方案,下面将对实施例或现有技术描述中所需要使用的附图作简单地介绍,显而易见地,下面描述中的附图仅仅是本发明,对于本领域普通技术人员来讲,在不付出创造性劳动的前提下,还可以根据这些附图获得其他的附图。

[0071] 图1为本发明实施例的监测方法流程示意图;

[0072] 图2为本发明实施例的模型构建流程示意图。

## 具体实施方式

[0073] 为使本发明的目的、技术方案和优点更加清楚明白,以下结合具体实施例,对本发明进一步详细说明。

[0074] 需要说明的是,除非另外定义,本发明使用的技术术语或者科学术语应当为本发明所属领域内具有一般技能的人士所理解的通常意义。本发明中使用的“第一”、“第二”以及类似的词语并不表示任何顺序、数量或者重要性,而只是用来区分不同的组成部分。“包括”或者“包含”等类似的词语意指出现该词前面的元件或者物件涵盖出现在该词后面列举的元件或者物件及其等同,而不排除其他元件或者物件。“连接”或者“相连”等类似的词语并非限定于物理的或者机械的连接,而是可以包括电性的连接,不管是直接的还是间接的。“上”、“下”、“左”、“右”等仅用于表示相对位置关系,当被描述对象的绝对位置改变后,则该相对位置关系也可能相应地改变。

[0075] 如图1-2所示,基于数据驱动的电缆局放故障实时监测方法,包括以下步骤:

[0076] S1,数据收集与预处理:收集电缆局部放电信号的数据,数据包括电磁波形、声波形和电流波形,对收集到的数据进行预处理,以提高数据的质量和后续分析的准确性;

[0077] S2,特征提取:从预处理后的数据中提取局放信号特征,局放信号特征包括放电量、放电频率和放电模式,用于描述和识别局放故障;

[0078] S3,模型构建:基于提取的局放信号特征,采用改进的卷积神经网络CNN构建局放故障预测模型,局放故障预测模型学习局放信号特征与故障之间的关系,实现故障的预测和诊断,并根据新收集的数据动态调整和优化,以提高预测的准确性;

[0079] S4,实时监测与预警:使用局放故障预测模型对电缆的局部放电活动进行实时监控,当局放故障预测模型预测到故障风险,自动生成并发出预警信号,以便及时采取相应的维护措施或预防行动;

[0080] S5,故障定位:在发出预警信号之后,分析局放信号特征,估计故障发生的位置,故障定位对于指导维修工作和快速解决故障至关重要;

[0081] 本发明通过上述步骤实现了对电缆局放故障进行实时监测和预警,不仅提高了故障检测的准确性和效率,而且还能实现故障的及时定位,大大减少了维护成本和提高了电力系统的可靠性。

[0082] S1中的数据收集与预处理包括:

[0083] S11,数据收集:通过部署在电缆周围的多种传感器收集局部放电信号的数据,多种传感器包括电磁波形传感器(用于捕捉电缆局放过程中产生的电磁波动)、声波形传感器(用于记录局放事件引发的声波特征,这些特征能够提供关于局放性质和位置的重要线索)以及电流波形传感器(用于监测电缆中电流的变化),多种传感器被精确地布置在电缆线路上,以确保能够全面捕捉到与电缆局放相关的所有必要数据;

[0084] S12,数据预处理:对收集到的局放信号数据进行预处理操作,以提高数据分析的准确性和效率,包括去噪处理、标准化处理以及同步校正。

[0085] S2中的特征提取包括:

[0086] 放电量特征提取:放电量表示为电荷量,是局放事件中释放电荷的量度,通过积分局放电流波形对预处理后的电流波形数据进行计算,放电量是反映局放强度和严重性的关键指标,通过比较放电量的大小,可以评估局放故障的严重程度;

[0087] 积分局放电流波形的计算公式为： $Q = \int i(t)dt$ ，其中， $Q$ 是放电量， $i(t)$ 是局放事件期间的电流波形， $t$ 是时间；

[0088] 放电频率特征提取：放电频率是在单位时间内局放事件发生的次数，通过局放事件间隔时间的倒数来计算放电频率，放电频率是判断放电活动类型（如持续放电或间歇放电）的重要依据；

[0089] 放电频率的计算公式为： $f = \frac{1}{T}$ ，其中， $f$ 是放电频率，是连续两次局放事件之间的时间间隔；

[0090] 放电模式特征提取：放电模式涉及到局放信号的波形分析，通过傅里叶变换，将时域信号转换为频域信号，从而分析不同频率成分，通过分析数据中的特定模式和波形特征，可以准确地划分和识别不同的放电模式（例如内部放电、表面放电等），这对于故障分析和预防至关重要；

[0091] 频域信号的计算公式为： $F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-j\omega t}dt$ ，其中， $F(\omega)$ 是信号的频域表示， $\omega$ 是角频率， $f(t)$ 是时域中的局放信号；

[0092] 通过特征提取，可以从复杂的局放信号数据中准确地识别出关键的局放特征，包括放电量、放电频率和放电模式，这些特征为后续的模式构建、实时监测与预警以及故障定位提供了关键信息，极大提高了电缆局放故障监测方法的准确性和效率。

[0093] S3中的模型构建包括：

[0094] 特征融合：将提取的局放信号特征进行融合，形成综合特征向量，综合特征向量综合反映了局放事件的多维特性，为模型提供丰富的输入数据；

[0095] 模型选择与训练：通过改进的卷积神经网络CNN构建局放故障预测模型，使用局部放电信号的数据及对应的故障诊断结果作为训练集，训练局放故障预测模型学习局放信号特征与故障类型之间的关系；

[0096] 模型验证与调优：在独立的测试集上评估局放故障预测模型的性能，包括准确率、召回率和F1分数，基于评估结果对局放故障预测模型的参数进行调优，确保模型具有最优的预测性能；

[0097] 动态调整机制：引入动态调整机制，允许局放故障预测模型根据新收集到的数据自我学习和调整；

[0098] 实时预测与诊断：将实时收集的局部放电信号的数据输入到训练好的局放故障预测模型中，局放故障预测模型对基于学习到的局放信号特征与故障关系进行故障的预测和诊断，预测结果可用于即时的故障预警和后续为维护决策支持；

[0099] 通过上述过程，不仅能够实现高准确度的局放故障预测和诊断，还能通过持续的学习和优化，适应电缆局放特征的变化，从而在动态变化的电网环境中保持高性能。

[0100] 改进的卷积神经网络CNN在卷积层引入局放信号强度 $LSI$ 调制因子，使卷积核的应用更加敏感于局放信号的强度变化，计算公式为：

$$[0101] \quad f_{out}(i) = \sum_{j=1}^k (f_{in}(i+j) \cdot \gamma \cdot LSI_{i+j}) \cdot w(j);$$

[0102] 其中， $f_{out}(i)$ 表示在输出特征图上位置 $i$ 的值， $f_{in}(i+j)$ 表示输入特征图上位置 $i+j$

的值,  $j$ 是卷积核覆盖的相对位置索引,  $k$ 是卷积核的大小, 即卷积操作覆盖的输入特征图上的元素数量,  $LSI_{i+j}$ 表示在位置  $i+j$ 处局放信号的强度信息,  $\gamma$ 是调节参数, 用于控制局放信号强度对卷积输出的调制作用,  $w(j)$ 是卷积核在位置  $j$ 的权重值;

[0103] 改进的卷积神经网络CNN通过在卷积操作中引入局放信号强度 $LSI$ 调制因子, 增强了局放故障预测模型对电缆局放故障特征的识别和分析能力, 进而提高了电缆局放故障实时监测方法的效果和准确性。

[0104] 局放信号强度 $LSI$ 反映局放事件的电荷量大小, 通过分析局放信号的电磁波形、声波形或电流波形中的峰值强度来计算, 计算方法包括:

[0105] 信号强度提取: 对于每个局放信号样本, 计算在不同通道(如电磁、声波、电流)中的峰值强度, 计算公式为:

$$[0106] \quad PeakIntensity_{channel} = \max(|f_{in}|);$$

[0107] 其中,  $|f_{in}|$ 代表在通道中的局放信号绝对值;

[0108] 标准化处理: 为了使 $LSI$ 调制因子适用于不同规模的数据和不同强度的局部放电事件, 对提取的信号强度进行标准化处理, 计算公式为:

$$[0109] \quad LSI_{channel} = \frac{PeakIntensity_{channel} - \min(PeakIntensity_{channel})}{\max(PeakIntensity_{channel}) - \min(PeakIntensity_{channel})};$$

[0110] 处理后的每个通道的 $LSI$ 值将位于 $[0,1]$ 区间内, 其中, 0表示最低信号强度, 1表示最高信号强度;

[0111]  $LSI$ 调制因子计算: 综合各通道的 $LSI$ 值得到最终的 $LSI$ 调制因子, 计算公式为:

$$[0112] \quad LSI = \frac{1}{N} \sum_{n=1}^N LSI_{channel_n}, \text{ 其中, } N \text{ 是通道数};$$

[0113] 通过引入局放信号的强度 $LSI$ 调制因子, 能够使卷积神经网络CNN在分析局放信号时更加注重信号的强度特征, 对于识别和预测电缆局放故障至关重要, 信号强度往往与故障的严重性密切相关, 因此, 在识别电缆潜在缺陷和预测可能的故障方面更为有效和准确。

[0114] 模型验证与调优包括:

[0115] 独立测试集的准备: 从收集的电缆局放数据中分割出一部分数据作为测试集, 测试集在局放故障预测模型训练阶段未被使用, 确保可以在模型评估过程中提供独立的验证;

[0116] 性能评估指标计算:

[0117] 准确率 $Accuracy$ (模型正确预测的比例)计算公式为:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN};$$

[0118] 其中,  $TP$ (真正例)和 $TN$ (真负例)分别是局放故障预测模型正确识别的故障和非故障事件数量,  $FP$ (假正例)和 $FN$ (假负例)分别是局放故障预测模型错误识别的故障和非故障事件数量;

[0119] 召回率 $Recall$ (模型正确识别的故障事件占有所有实际故障事件的比例)的计算公式为:  $Recall = \frac{TP}{TP + FN};$

[0120] F1 分数（准确率和召回率的调和平均值）的计算公式为：

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall};$$

[0121] 其中,精确度  $Precision$  的计算公式为:  $Precision = \frac{TP}{TP + FP}$ ;

[0122] 基于评估结果对模型参数进行调优:根据评估指标的结果,对局放故障预测模型的参数进行细微调整以优化性能,包括调整学习率、修改网络层的数量或大小、调整正则化项,以达到更好的准确率、召回率和F1分数;

[0123] 通过在独立测试集上评估改进的卷积神经网络CNN的准确率、召回率和F1分数,可以全面了解模型对电缆局放故障预测的能力,召回率对于故障预测尤为重要,因为它直接关系到故障检测的完整性,即模型能否捕捉到所有的故障事件。

[0124] 基于评估结果,通过调优模型参数(如调整卷积核大小、层数、学习率等),可以进一步提高模型对局放故障的识别准确性和泛化能力,这样的调优过程确保了模型在实际应用中能够有效预测电缆局放故障,为及时维修和预防提供科学依据,大大提高电缆系统的可靠性和安全性。

[0125] 动态调整机制包括:

[0126] 持续监控模型性能:定期评估局放故障预测模型的性能评估指标,当性能评估指标低于预定阈值时,自动触发动态调整流程;

[0127] 数据驱动的调整决策:分析新收集的局部放电信号的数据,分析局放故障预测模型性能下降的原因,例如新出现的故障模式或电缆状态变化,基于分析结果,决定执行调整策略,调整策略包括局放故障预测模型参数的微调、训练集的更新(如引入最近发生的局放事件及其分析结果)以及重新训练;

[0128] 模型参数的微调:对局放故障预测模型进行微调,以反映最新数据中的信息,微调包括调整卷积层权重、偏置项;

[0129] 卷积层权重的微调通过梯度下降法来实现,计算公式为:

$$w_{new} = w - \eta \cdot \frac{\partial \mathcal{L}}{\partial w};$$

[0131] 其中,  $w_{new}$  是更新后的权重,  $w$  是当前的权重,  $\eta$  是学习率,微调时通常选择较小的值,  $\frac{\partial \mathcal{L}}{\partial w}$  是损失函数  $\mathcal{L}$  关于权重  $w$  的梯度;

[0132] 偏置项微调的计算公式为:

$$b_{new} = b - \eta \cdot \frac{\partial \mathcal{L}}{\partial b};$$

[0134] 其中,  $b_{new}$  是更新后的偏置项,  $b$  是当前的偏置项,  $\frac{\partial \mathcal{L}}{\partial b}$  是损失函数  $\mathcal{L}$  关于偏置项  $b$  的梯度;

[0135] 训练集的更新:将新收集到的局部放电信号的数据及对应的故障诊断结果定期加入训练集,扩大训练集的覆盖范围,使局放故障预测模型学习到电缆运行条件的变化和新出现故障模式的信息;

[0136] 重新训练过程:在训练集发生显著变化或局放故障预测模型性能下降时,进行局

放故障预测模型的重新训练,重新训练包括使用更新后的训练集或者调整模型结构(如增加卷积层、调整卷积核大小等);

[0137] 改进的卷积神经网络CNN能够根据新的局放数据自我学习和调整,持续优化其性能,这不仅提高了模型在初次部署时的预测准确性,还确保了随着时间推移和电缆系统状态变化,模型能够适应新的故障模式和条件变化,保持其长期的有效性和适应性。

[0138] S5中的故障定位包括:

[0139] 信号特征分析:在发出预警信号之后,对与预警相关的局放信号特征进行分析,分析包括局放信号特征之间的关系以及局放信号特征与已知故障位置之间的相关性;

[0140] 利用空间信息:结合局放信号的空间信息,例如由不同位置的传感器捕获的信号强度差异和到达时间差异,应用时间差定位技术来估计故障位置;

[0141] 时间差定位技术具体包括:

[0142] 信号时间记录:在多个已知位置的传感器上记录局放信号到达的确切时间;

[0143] 计算时间差:对于每一对传感器,计算信号到达每一对传感器之间的时间差,即

$$\Delta t = t_2 - t_1;$$

[0144] 多边测量定位:根据信号传播速度 $v$ 和时间差 $\Delta t$ ,应用多边测量法求解故障位置,对于每一对传感器,故障到传感器的距离差等于信号传播速度乘以时间差,即 $d_{diff} = v \cdot \Delta t$ ;

[0145] 故障位置推算:结合所有传感器对的时间差数据,推算故障的位置。

[0146] 故障定位还包括信号强度差异技术,信号强度差异技术具体包括:

[0147] 信号强度测量:测量每个传感器接收到的局放信号的强度;

[0148] 建立衰减模型:使用路径损耗模型表示信号强度与距离之间的关系,路径损耗模型表示为:

$$RSSI = RSSI_0 - 10 \cdot m \cdot \log_{10}(d/d_0);$$

[0150] 其中, $RSSI$ 是在距离 $d$ 处测量到的信号强度, $RSSI_0$ 是在参考距离 $d_0$ 处的信号强度,通常取1米, $m$ 是环境因子,取决于信号传播的环境特性, $d$ 是从故障点到传感器的距离;

[0151] 距离估计:根据测量到的 $RSSI$ 值和路径损耗模型,估算故障点到各个传感器的距离;

[0152] 位置推算:结合所有传感器的距离估计,推算故障的位置。

[0153] 所属领域的普通技术人员应当理解:以上任何实施例的讨论仅为示例性的,并非旨在暗示本发明的范围被限于这些例子;在本发明的思路下,以上实施例或者不同实施例中的技术特征之间也可以进行组合,步骤可以以任意顺序实现,并存在如上所述的本发明的不同方面的许多其它变化,为了简明它们没有在细节中提供。

[0154] 本发明旨在涵盖落入权利要求的宽泛范围之内的所有这样的替换、修改和变型。因此,凡在本发明的精神和原则之内,所做的任何省略、修改、等同替换、改进等,均应包含在本发明的保护范围之内。

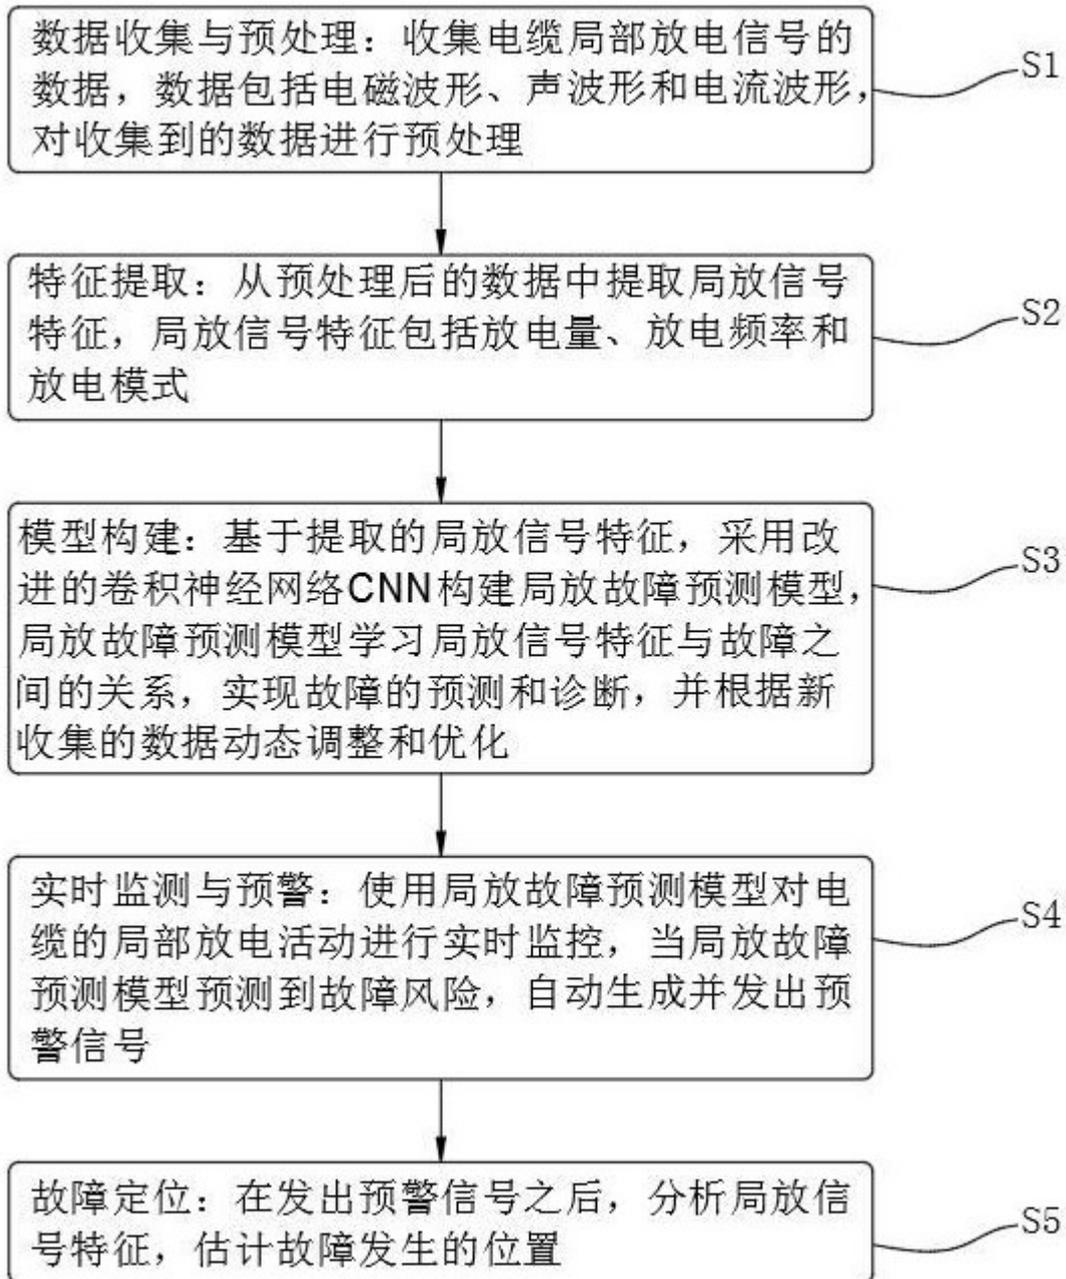


图 1

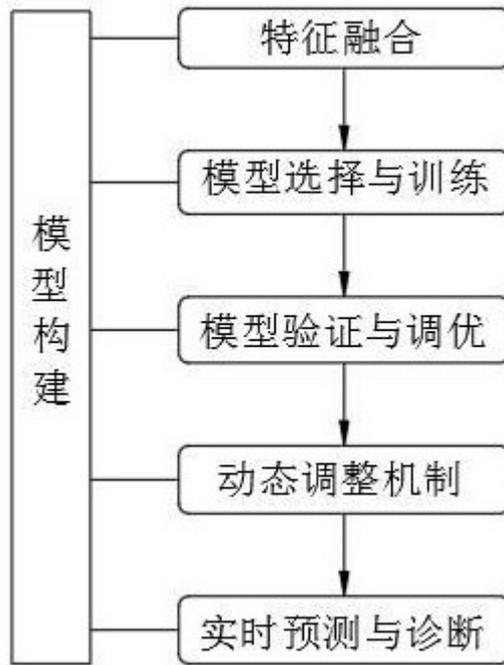


图 2