



(12) 发明专利

(10) 授权公告号 CN 113707176 B

(45) 授权公告日 2022. 09. 09

(21) 申请号 202111026413.3

(51) Int.Cl.

(22) 申请日 2021.09.02

G10L 25/03 (2013.01)

(65) 同一申请的已公布的文献号

G10L 25/30 (2013.01)

申请公布号 CN 113707176 A

G10L 25/51 (2013.01)

G10L 15/06 (2013.01)

(43) 申请公布日 2021.11.26

审查员 武金花

(73) 专利权人 国网安徽省电力有限公司铜陵供电公司

地址 244099 安徽省铜陵市长江中路91号

专利权人 安徽南瑞继远电网技术有限公司  
安徽大学

(72) 发明人 程汪刘 倪修峰 童昉 鲍文霞

曹成功 高志国 李飞 卢俊结

(74) 专利代理机构 合肥国和专利代理事务所

(普通合伙) 34131

专利代理师 张祥骞

权利要求书4页 说明书10页 附图2页

(54) 发明名称

一种基于声信号及深度学习技术的变压器故障检测方法

(57) 摘要

本发明涉及一种基于声信号及深度学习技术的变压器故障检测方法,与现有技术相比解决了难以应用声纹信号对变压器故障进行准确检测的缺陷。本发明包括以下步骤:电力变压器声音数据的采集获取;训练样本集内声信号的预处理;声信号数据的声纹特征提取;构建变压器故障检测模型;变压器故障检测模型的训练;待检测变压器声信号数据的获取及预处理;待检测变压器故障检测结果的获得。本发明能够基于声纹信号进行变压器的故障检测。



1. 一种基于声信号及深度学习技术的变压器故障检测方法,其特征在于,包括以下步骤:

11) 电力变压器声音数据的采集获取:通过声纹采集传感器实地采集获取变压器声音数据,经过标注分为“正常”和“故障”两类,并将其定义为训练样本集;

12) 训练样本集内声信号的预处理:运用分段、分帧、声音加窗和自适应滤波法的预处理方法对所采集的电力变压器声音数据进行去噪预处理;再通过切割、加噪、调音处理对声信号进行数据增强;

13) 声信号数据的声音特征提取:通过采用梅拉尔倒谱系数对预处理后的电力变压器声音数据进行声音特征提取,提取出MFCC系数;

14) 构建变压器故障检测模型:基于双门控卷积网络模型和变压器声信号的特点构建变压器故障检测模型;

15) 变压器故障检测模型的训练:将提取到的MFCC系数输入变压器故障检测模型进行训练;

16) 待检测变压器声信号数据的获取及预处理:获取待检测变压器声信号数据,并进行去噪预处理,对去噪预处理后的待检测变压器声信号数据提取MFCC系数;

17) 待检测变压器故障检测结果的获得:将MFCC系数输入训练后的变压器故障检测模型,得到变压器故障检测的结果;

所述训练样本集内声信号的预处理包括以下步骤:

21) 对采集的电力变压器声音数据 $s(t)$ 进行分段操作:

对获得的电力变压器声音数据进行分段,

切分成 $s(t) = \{s_1(t), s_2(t), \dots, s_q(t), \dots, s_r(t)\}$ ,计算声纹数据的总长度 $L$ ,其计算公式如下:

$$L = \text{time} \times f_{S_{\text{sample}}} = r \times r_L,$$

其中, $f_{S_{\text{sample}}}$ 为该声音的采样频率, $\text{time}$ 是采样时间, $r$ 为分段数量, $r_L$ 为分段长度;

22) 对已经分段的变压器声音数据 $s_q(t)$ 进行分帧处理:

将变压器声纹帧长设为500ms,进行分帧处理为

$$s_q(t) = \{s_{q1}(t), s_{q2}(t), \dots, s_{qp}(t), \dots, s_{q\text{Length}}(t)\},$$

其中,每一帧长度设定为500ms,每一段分为Length帧;

23) 对分帧后变压器声音加窗处理:

对分帧数据进行端点平滑的加窗处理,使用Hamming窗对帧进行加窗处理,Hamming窗的函数 $w(t)$ 表示如下:

$$w(t) = \begin{cases} 0.54 - 0.46 \cos\left(\frac{2\pi t}{M-1}\right) & 0 \leq t \leq M-1 \\ 0 & \text{otherwise} \end{cases}$$

其中 $M$ 为帧长, $t$ 为时间;

针对每一帧得到时域信号 $f_{qp}(t)$ ,其表达式如下:

$$f_{qp}(t) = s_{qp}(t) * w(n),$$

其中, $f_{qp}(t)$ 是第 $q$ 段信号的第 $p$ 帧的时域信号, $w(n)$ 为加窗函数, $s_{qp}(t)$ 为第 $q$ 段信号的第 $p$ 帧的信号值;24) 对加窗处理后的声音使用自适应滤波器进行去噪处理;

对 $f_{qp}(t)$ 进行采样得到 $X_i(n)$ 数字信号序列,并设置滤波器初值如下:

$$W(k)_{k=0} = 0, 0 < \mu < \frac{1}{\lambda_{\max}};$$

其中, $W(k)$ 为最优的权系数, $\mu$ 为收敛因子, $\lambda$ 为相关矩阵的最大特征值;

计算滤波器输出的实际输出估计值:

$$y(k) = W^T(k) X_i(n),$$

其中, $y(k)$ 是实际输出估计值, $W^T(k)$ 为最优权系数的转置, $X_i(n)$ 为输入信号序列;

$e(k)$ 是误差信号,为计算误差:

$$e(k) = d(k) - y(k),$$

其中, $d(k)$ 是期望输出值,更新 $k+1$ 时刻滤波器系数:

$$W(k+1) = W(k) + \mu e(k) X(k),$$

其中, $W(k+1)$ 是 $k+1$ 时刻的最优权系数, $W(k)$ 为 $k$ 时刻的最优权系数, $e(k)$ 为 $k$ 时刻的误差, $X(k)$ 为 $k$ 时刻的输入序列;

使用最陡下降法不断迭代求解,使得误差信号最小,得到自适应滤波去噪后的输出 $y(k)$ ;

25) 对自适应滤波去噪的输出 $y(k)$ 通过切割、加噪、调音处理对声信号进行数据增强;所述构建变压器故障检测模型包括以下步骤:

41) 基于双门控卷积神经网络设定变压器故障检测模型,其包括两个卷积门控层、两个池化层、一个全连接层和一个输出层;

42) 设定卷积门控层:卷积门控层通过对输入数据与卷积核的卷积操作来提取特征,得到特征图,特征图的深度取决于设定的卷积核的数量;

假设输入为 $X \in \mathbb{R}^{A \times B}$ ,其中 $A$ 与 $B$ 分别代表输入数据的长与宽,卷积操作定义为:

$$X_j^l = f \left( \sum_{i=1}^M X_i^{l-1} * k_{ij}^l + b_j^l \right);$$

其中: $X_j^l$ 代表第 $l$ 层卷积层的第 $j$ 个特征平面图, $X_i^{l-1}$ 代表第 $l-1$ 层卷积层的第 $i$ 个平面特征图, $M$ 代表平面特征图的个数, $k_{ij}^l$ 代表卷积核, $b_j^l$ 代表偏置, $k_{ij}^l$ 和 $b_j^l$ 的具体参数通过训练优化来确定, $f$ 代表激励层函数,激励函数为sigmoid函数,其表达式如下:

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}};$$

门控的输出表示为: $h(X) = (X * W + b) \otimes \sigma(X * V + c)$ ;其中: $h(X)$ 表示Gated CNN的输出, $W$ 和 $V$ 表示不同的卷积核, $b$ 和 $c$ 表示不同的偏置, $\otimes$ 表示矩阵的元素对应相乘, $\sigma$ 表示sigmoid门控函数, $X$ 表示上一层的输出;

43) 设计池化层:采用最大池化或平均池化方法来设定池化层;

44) 搭建全连接层和采用softmax分类器作为输出层进行最后分类输出。

2. 根据权利要求1所述的一种基于声信号及深度学习技术的变压器故障检测方法,其

特征在于,所述声信号数据的声特征提取包括以下步骤:

31) 对进行数据增强后的 $y(k)$ 进行逆变换生成 $s(t)$ , $s(t)$ 进行预加重操作,其计算公式如下:

$$y(z) = s(z)H(z),$$

其中, $y(z)$ 是预加重的输出, $s(z)$ 是信号 $s(t)$ 的Z域表达, $H(z)$ 为高通滤波器的传递函数,该传递函数为: $H(Z) = 1 - \mu z^{-1}$ ,

该高通滤波器在z域的形式,其中 $\mu$ 的值介于0.9-1.0之间;

32) 对预加重后的变压器声音数据 $s_q(t)$ 进行分帧处理:

将变压器声纹帧长设为30ms,进行变压器声音数据的分帧处理,处理后结构为每一帧30ms;

33) 对分帧后的声音数据加窗:使用hamming窗对帧进行加窗处理,假设经过前两步预处理得到的输出为 $S(n)$ ,窗函数为 $W(n)$ ,则计算公式为:

$$S'(n) = S(n) \times W(n);$$

其中窗函数 $W(n)$ 为:

$$W(n,a) = (1-a) - a \times \cos\left(\frac{2\pi n}{N-1}\right)$$

该式中 $n$ 代表 $n$ 时刻,其取值范围 $0 \leq n \leq N-1$ , $N$ 为采样点数,且根据设置不同的 $a$ 值得到不同的Hamming窗, $n$ 表示序列自变量, $a$ 为设定的常数;

34) 对加窗后的数据进行快速傅里叶变换:

对于每一帧信号进行FFT得到频域信号 $W(k)$ :

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi nk/N} \quad 0 \leq k \leq N$$

其中 $X(k)$ 代表频域输出, $x(n)$ 代表时域输入, $N$ 是采样点数;

35) 对快速傅里叶变换后的数据进行梅尔滤波,梅尔滤波转换公式为:

$$Mel(f) = 2595 \times \lg\left(1 + \frac{f}{700}\right)$$

其中, $f$ 代表物理频率, $Mel(f)$ 代表梅尔频率;将得到的梅尔频率通过 $M$ 个梅尔尺度的三角形滤波器组进行滤波,滤波器组的公式为:

$$H_{m(k)} = \begin{cases} 0 & k < f(m-1) \text{ 或 } k > f(m+1) \\ \frac{2(k-f(m-1))}{(f(m+1)-f(m-1))(f(m)-f(m-1))} & f(m-1) \leq k \leq f(m) \\ \frac{2(f(m+1)-k)}{(f(m+1)-f(m-1))(f(m+1)-f(m))} & f(m) \leq k \leq f(m+1) \end{cases}$$

在该式中:  $\sum_{m=0}^{M-1} H_m(k) = 1$ , 再计算每个滤波器组输出的对数能量:

$$E(m) = \ln \left( \sum_{k=0}^{N-1} H_m(k) \times |X(k)|^2 \right) \quad 0 \leq m \leq M$$

其中,  $E(m)$  为对数能量,  $H_m(k)$  为滤波器组;

36) 对梅尔滤波后的数据进行倒谱分析, 提取出MFCC系数  $C(n)$ , MFCC系数  $C(n)$  通过进行离散余弦变换DCT来实现提取:

$$C(n) = \sum_{m=0}^{M-1} E(m) \cos\left(\frac{\pi n(m-0.5)}{M}\right) \quad 0 \leq n \leq M$$

其中,  $M$  代表滤波器的个数。

3. 根据权利要求1所述的一种基于声信号及深度学习技术的变压器故障检测方法, 其特征在于, 所述变压器故障检测模型的训练包括以下步骤:

51) 将训练样本集提取后的MFCC系数输入变压器故障检测模型;

52) MFCC系数在变压器故障检测模型内进行前向传播和反向传播不断迭代, 进行参数优化得到训练后的变压器故障检测模型。

## 一种基于声信号及深度学习技术的变压器故障检测方法

### 技术领域

[0001] 本发明涉及变压器故障检测技术领域,具体来说是一种基于声信号及深度学习技术的变压器故障检测方法。

### 背景技术

[0002] 电网中的变压器具有使用量大、使用种类和规格繁多的特点,并且使用时间较长,这导致变压器在电网系统中发生故障的频率过高。据统计,每200台运行时间超过4年的变压器就有大约5台变压器发生故障。因此,变压器的故障排除和检修成为电网稳定工作的一个重要程序。

[0003] 针对变压器故障排除,传统的处理方法是需要人工前往待排除地点,并依靠人工经验,根据变压器发出的声音来诊断该变压器是否有故障。该方式不仅需要耗费大量的时间与精力,而且会受到人为因素的干扰,有可能故障诊断错误。

[0004] 近年来,深度学习发展日新月异,该处理信号的方式具有高效性的特点。若能采用深度学习方式对变压器声音进行处理,其将会自动化分析变压器发出声音的特征,并对特征进行归类,即可快捷地诊断出有故障的变压器,能够大大降低了人工成本且能更快维护电网的稳定。

[0005] 现有技术中,虽存在一些声纹检测方法,其多是利用混合高斯模型和隐马尔可夫模型作为有效的声学模型来进行声纹检测,而在深度学习兴起之后,包括卷积神经网络、自编码器、递归神经网络(Recurrent Neural Network, RNN)等,越来越多的深度学习网络应用在声音检测领域。从声音检测的准确率和精确度等指标来看,基于深度学习的声纹检测方法远比传统声学模型的声纹检测方法要好得多,但现有技术中基于深度学习的声纹检测方法多采用振动数据,尚无利用音频数据来进行故障检测。

[0006] 因此,如何将深度学习技术更好地应用于变压器声纹故障检测已经成为急需解决的技术问题。

### 发明内容

[0007] 本发明的目的是为了解决现有技术中难以应用声纹信号对变压器故障进行准确检测的缺陷,提供一种基于声信号及深度学习技术的变压器故障检测方法来解决上述问题。

[0008] 为了实现上述目的,本发明的技术方案如下:

[0009] 一种基于声信号及深度学习技术的变压器故障检测方法,包括以下步骤:

[0010] 11) 电力变压器声音数据的采集获取:通过声纹采集传感器实地采集获取变压器声音数据,经过标注分为“正常”和“故障”两类,并将其定义为训练样本集;

[0011] 12) 训练样本集内声信号的预处理:运用分段、分帧、声音加窗和自适应滤波法的预处理方法对所采集的电力变压器声音数据进行去噪预处理;再通过切割、加噪、调音处理对声信号进行数据增强;

[0012] 13) 声信号数据的声信号特征提取:通过采用梅拉尔倒谱系数对预处理后的电力变压器声音数据进行声信号特征提取,提取出MFCC系数;

[0013] 14) 构建变压器故障检测模型:基于双门控卷积网络模型和变压器声信号的特点构建变压器故障检测模型;

[0014] 15) 变压器故障检测模型的训练:将提取到的MFCC系数输入变压器故障检测模型进行训练;

[0015] 16) 待检测变压器声信号数据的获取及预处理:获取待检测变压器声信号数据,并进行去噪预处理,对去噪预处理后的待检测变压器声信号数据提取MFCC系数;

[0016] 17) 待检测变压器故障检测结果的获得:将MFCC系数输入训练后的变压器故障检测模型,得到变压器故障检测的结果。

[0017] 所述训练样本集内声信号的预处理包括以下步骤:

[0018] 21) 对采集的电力变压器声音数据 $s(t)$ 进行分段操作:

[0019] 对获得的电力变压器声音数据进行分段,

[0020] 切分成 $s(t) = \{s_1(t), s_2(t), \dots, s_q(t), \dots, s_r(t)\}$ ,计算声纹数据的总长度 $L$ ,其计算公式如下:

[0021]  $L = \text{time} \times fS_{\text{Sample}} = r \times r_L$ ,

[0022] 其中, $fS_{\text{sample}}$ 为该声音的采样频率, $\text{time}$ 是采样时间, $r$ 为分段数量, $r_L$ 为分段长度;

[0023] 22) 对已经分段的变压器声音数据 $s_q(t)$ 进行分帧处理:

[0024] 将变压器声纹帧长设为500ms,进行分帧处理为

[0025]  $s_q(t) = \{s_{q1}(t), s_{q2}(t), \dots, s_{qp}(t), \dots, s_{q\text{Length}}(t)\}$ ,

[0026] 其中,每一帧长度设定为500ms,每一段分为Length帧;

[0027] 23) 对分帧后变压器声音加窗处理:

[0028] 对分帧数据进行端点平滑的加窗处理,使用Hamming窗对帧进行加窗处理,Hamming窗的函数 $w(t)$ 表示如下:

[0029] 
$$w(t) = \begin{cases} 0.54 - 0.46 \cos\left(\frac{2\pi t}{M-1}\right) & 0 \leq t \leq M-1; \\ 0 & \text{otherwise} \end{cases};$$

[0030] 其中 $M$ 为帧长, $t$ 为时间;

[0031] 针对每一帧得到时域信号 $f_{qp}(t)$ ,其表达式如下:

[0032]  $f_{qp}(t) = s_{qp}(t) * w(n)$ ,

[0033] 其中, $f_{qp}(t)$ 是第 $q$ 段信号的第 $p$ 帧的时域信号, $w(n)$ 为加窗函数, $s_{qp}(t)$ 为第 $q$ 段信号的第 $p$ 帧的信号值;

[0034] 24) 对加窗处理后的声音使用自适应滤波器进行去噪处理:

[0035] 对 $f_{qp}(t)$ 进行采样得到 $X_i(n)$ 数字信号序列,并设置滤波器初值如下:

[0036] 
$$W(k)_{k=0} = 0, 0 < \mu < \frac{1}{\lambda_{\max}},$$

[0037] 其中, $W(k)$ 为最优的权系数, $\mu$ 为收敛因子, $\lambda$ 为相关矩阵的最大特征值;

[0038] 计算滤波器输出的实际输出估计值:

[0039]  $y(k) = W^T(k) X_i(n)$ ,

[0040] 其中,  $y(k)$  是实际输出估计值,  $W^T(k)$  为最优权系数的转置,  $X_i(n)$  为输入信号序列;

[0041]  $e(k)$  是误差信号, 为计算误差:

[0042]  $e(k) = d(k) - y(k)$ ,

[0043] 其中,  $d(k)$  是期望输出值, 更新  $k+1$  时刻滤波器系数:

[0044]  $W(k+1) = W(k) + \mu e(k) X(k)$ ,

[0045] 其中,  $W(k+1)$  是  $k+1$  时刻的最优权系数,  $W(k)$  为  $k$  时刻的最优权系数,  $e(k)$  为  $k$  时刻的误差,  $X(k)$  为  $k$  时刻的输入序列;

[0046] 使用最陡下降法不断迭代求解, 使得误差信号最小, 得到自适应滤波去噪后的输出  $y(k)$ ;

[0047] 25) 对自适应滤波去噪的输出  $y(k)$  通过切割、加噪、调音处理对声信号进行数据增强。

[0048] 所述声信号数据的声音特征提取包括以下步骤:

[0049] 31) 对进行数据增强后的  $y(k)$  进行逆变换生成  $s(t)$ ,  $s(t)$  进行预加重操作, 其计算公式如下:

[0050]  $y(z) = s(z) H(z)$ ,

[0051] 其中,  $y(z)$  是预加重的输出,  $s(z)$  是信号  $s(t)$  的 Z 域表达,  $H(z)$  为高通滤波器的传递函数, 该传递函数为:

[0052]  $H(Z) = 1 - \mu z^{-1}$ ,

[0053] 该高通滤波器在  $z$  域的形式, 其中  $\mu$  的值介于 0.9-1.0 之间;

[0054] 32) 对预加重后的变压器声音数据  $s_q(t)$  进行分帧处理:

[0055] 将变压器声纹帧长设为 30ms, 进行变压器声音数据的分帧处理, 处理后结构为每一帧 30ms;

[0056] 33) 对分帧后的声音数据加窗: 使用 hamming 窗对帧进行加窗处理, 假设经过前两步预处理得到的输出为  $S(n)$ , 窗函数为  $W(n)$ , 则计算公式为:

[0057]  $S'(n) = S(n) \times W(n)$ ;

[0058] 其中窗函数  $W(n)$  为:

[0059]  $W(n, a) = (1-a) - a \times \cos\left(\frac{2\pi n}{N-1}\right)$ ,

[0060] 该式中  $n$  代表  $n$  时刻, 其取值范围  $0 \leq n \leq N-1$ ,  $N$  为采样点数, 且根据设置不同的  $a$  值得到不同的 Hamming 窗,  $n$  表示序列自变量,  $a$  为设定的常数;

[0061] 34) 对加窗后的数据进行快速傅里叶变换:

[0062] 对于每一帧信号进行 FFT 得到频域信号  $X(k)$ :

[0063]  $X(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi nk/N} \quad 0 \leq k \leq N$ ,

[0064] 其中  $X(k)$  代表频域输出,  $x(n)$  代表时域输入,  $N$  是采样点数;

[0065] 35) 对快速傅里叶变换后的数据进行梅尔滤波, 梅尔滤波转换公式为:



$$[0066] \quad Mel(f) = 2595 \times \lg\left(1 + \frac{f}{700}\right),$$

[0067] 其中,  $f$  代表物理频率,  $Mel(f)$  代表梅尔频率; 将得到的梅尔频率通过  $M$  个梅尔尺度的三角形滤波器组进行滤波, 滤波器组的公式为:

$$[0068] \quad H_{m(k)} = \begin{cases} 0 & k < f(m-1) \text{ 或 } k > f(m+1) \\ \frac{2(k-f(m-1))}{(f(m+1)-f(m-1))(f(m)-f(m-1))} & f(m-1) \leq k \leq f(m) \\ \frac{2(f(m+1)-k)}{(f(m+1)-f(m-1))(f(m+1)-f(m))} & f(m) \leq k \leq f(m+1) \end{cases},$$

$$[0069] \quad \text{在该式中: } \sum_{m=0}^{M-1} H_m(k) = 1,$$

[0070] 再计算每个滤波器组输出的对数能量:

$$[0071] \quad E(m) = \ln\left(\sum_{k=0}^{N-1} H_m(k) \times |X(k)|^2\right) \quad 0 \leq m \leq M,$$

[0072] 其中,  $E(m)$  为对数能量,  $H_m(k)$  为滤波器组;

[0073] 36) 对梅尔滤波后的数据进行倒谱分析, 提取出 MFCC 系数  $C(n)$ , MFCC 系数  $C(n)$  通过进行离散余弦变换 DCT 来实现提取:

$$[0074] \quad C(n) = \sum_{m=0}^{M-1} E(m) \cos\left(\frac{\pi n(m-0.5)}{M}\right) \quad 0 \leq n \leq M,$$

[0075] 其中,  $M$  代表滤波器的个数。

[0076] 所述构建变压器故障检测模型包括以下步骤:

[0077] 41) 基于双门控卷积神经网络设定变压器故障检测模型, 其包括两个卷积门控层、两个池化层、一个全连接层和一个输出层;

[0078] 42) 设定卷积门控层: 卷积门控层通过对输入数据与卷积核的卷积操作来提取特征, 得到特征图, 特征图的深度取决于设定的卷积核的数量;

[0079] 假设输入为  $X \in \mathbb{R}^{A \times B}$ , 其中  $A$  与  $B$  分别代表输入数据的长与宽, 卷积操作定义为:

$$[0080] \quad X_j^l = f\left(\sum_{i=1}^M X_i^{l-1} * k_{ij}^l + b_j^l\right),$$

[0081] 其中:  $X_j^l$  代表第  $l$  层卷积层的第  $j$  个特征平面图,  $X_i^{l-1}$  代表第  $l-1$  层卷积层的第  $i$  个平面特征图,  $M$  代表平面特征图的个数,  $k_{ij}^l$  代表卷积核,  $b_j^l$  代表偏置,  $k_{ij}^l$  和  $b_j^l$  的具体参数通过训练优化来确定,  $f$  代表激励层函数, 常用的激励函数有 ReLu 与 sigmoid 函数, 其表达式如下:

$$[0082] \quad \text{sigmoid}(x) = \frac{1}{1 + e^{-x}};$$

[0083] 门控的输出表示为:

$$[0084] \quad h(X) = (X * W + b) \otimes \sigma(X * V + c),$$

[0085] 其中: $h(X)$ 表示Gated CNN的输出, $W$ 和 $V$ 表示不同的卷积核, $b$ 和 $c$ 表示不同的偏置, $\otimes$ 表示矩阵的元素对应相乘, $\sigma$ 表示sigmoid门控函数, $X$ 表示上一层的输出;

[0086] 43) 设计池化层:采用最大池化或平均池化方法来设定池化层;

[0087] 44) 搭建全连接层和采用softmax分类器作为输出层进行最后分类输出。

[0088] 所述变压器故障检测模型的训练包括以下步骤:

[0089] 51) 将训练样本集提取后的MFCC系数输入变压器故障检测模型;

[0090] 52) MFCC系数在变压器故障检测模型内进行前向传播和反向传播不断迭代,进行参数优化得到训练后的变压器故障检测模型。

[0091] 有益效果

[0092] 本发明的一种基于声信号及深度学习技术的变压器故障检测方法,与现有技术相比能够基于声纹信号(非振动信号)进行变压器的故障检测;通过采集变压器声音并进行分类标注为“正常”和“故障”两类,构建变压器工况声音数据集;针对环境噪声的干扰,变压器工况声音数据集进行预先处理进行去噪处理;考虑到训练模型的实用性,为了增强后续搭建的神经网络的鲁棒性,对数据进行了一系列数据增强操作;之后,变压器声音数据集经过MFCC特征提取送入网络训练;基础CNN网络在用于情况比较复杂的故障检测时,由于音频数据量很少或者音频时长比较长,存在训练效率低下和过拟合现象,检测的准确率低。

[0093] 本发明针对变压器故障检测效果,设计了双门控卷积神经网络变压器声音检测模型,为实现变压器故障在线监测提供了有利方法基础和检测模型实现。

## 附图说明

[0094] 图1为本发明的方法顺序图;

[0095] 图2为本发明的方法实现逻辑流程图;

[0096] 图3为本发明所涉及的双门控卷积神经网络结构图。

## 具体实施方式

[0097] 为使对本发明的结构特征及所达成的功效有更进一步的了解与认识,用以较佳的实施例及附图配合详细的说明,说明如下:

[0098] 如图1和图2所示,本发明所述的一种基于声信号及深度学习技术的变压器故障检测方法,包括以下步骤:

[0099] 第一步,电力变压器声音数据的采集获取。通过声纹采集传感器实地采集获取变压器声音数据,经过标注分为“正常”和“故障”两类,并将其定义为训练样本集。在实验室环节,可以将获取变压器声音数据并划分为两类,正常工作状态和故障工作状态,构建实验数据库,并对该实验数据库进行训练集和测试集按照一定比例划分。

[0100] 第二步,训练样本集内声信号的预处理。运用分段、分帧、声音加窗和自适应滤波法的预处理方法对所采集的电力变压器声音数据进行去噪预处理;再通过切割、加噪、调音处理对声信号进行数据增强。其具体步骤如下:

[0101] (1) 对采集的电力变压器声音数据 $s(t)$ 进行分段操作:

[0102] 对获得的电力变压器声音数据进行分段,

[0103] 切成 $s(t) = \{s_1(t), s_2(t), \dots, s_q(t), \dots, s_r(t)\}$ , 计算声纹数据的总长度 $L$ , 其计算公式如下:

$$[0104] \quad L = \text{time} \times f_{S_{\text{sample}}} = r \times r_L,$$

[0105] 其中,  $f_{S_{\text{sample}}}$  为该声音的采样频率,  $\text{time}$  是采样时间,  $r$  为分段数量,  $r_L$  为分段长度。

[0106] (2) 对已经分段的变压器声音数据 $s_q(t)$ 进行分帧处理:

[0107] 将变压器声纹帧长设为500ms, 进行分帧处理为

$$[0108] \quad s_q(t) = \{s_{q1}(t), s_{q2}(t), \dots, s_{qp}(t), \dots, s_{q\text{Length}}(t)\},$$

[0109] 其中, 每一帧长度设定为500ms, 每一段分为Length帧。

[0110] (3) 对分帧后变压器声音加窗处理:

[0111] 对分帧数据进行端点平滑的加窗处理, 使用Hamming窗对帧进行加窗处理, Hamming窗的函数 $w(t)$ 表示如下:

$$[0112] \quad w(t) = \begin{cases} 0.54 - 0.46 \cos\left(\frac{2\pi t}{M-1}\right) & 0 \leq t \leq M-1; \\ 0 & \text{otherwise} \end{cases};$$

[0113] 其中 $M$ 为帧长,  $t$ 为时间;

[0114] 针对每一帧得到时域信号 $f_{qp}(t)$ , 其表达式如下:

$$[0115] \quad f_{qp}(t) = s_{qp}(t) * w(n),$$

[0116] 其中,  $f_{qp}(t)$  是第 $q$ 段信号的第 $p$ 帧的时域信号,  $w(n)$  为加窗函数,  $s_{qp}(t)$  为第 $q$ 段信号的第 $p$ 帧的信号值。

[0117] (4) 对加窗处理后的声音使用自适应滤波器进行去噪处理:

[0118] 对 $f_{qp}(t)$ 进行采样得到 $X_i(n)$ 数字信号序列, 并设置滤波器初值如下:

$$[0119] \quad W(k)_{k=0} = 0, 0 < \mu < \frac{1}{\lambda_{\max}},$$

[0120] 其中,  $W(k)$  为最优的权系数,  $\mu$  为收敛因子,  $\lambda$  为相关矩阵的最大特征值;

[0121] 计算滤波器输出的实际输出估计值:

$$[0122] \quad y(k) = W^T(k) X_i(n),$$

[0123] 其中,  $y(k)$  是实际输出估计值,  $W^T(k)$  为最优权系数的转置,  $X_i(n)$  为输入信号序列;

[0124]  $e(k)$  是误差信号, 为计算误差:

$$[0125] \quad e(k) = d(k) - y(k),$$

[0126] 其中,  $d(k)$  是期望输出值, 更新 $k+1$ 时刻滤波器系数:

$$[0127] \quad W(k+1) = W(k) + \mu e(k) X(k),$$

[0128] 其中,  $W(k+1)$  是 $k+1$ 时刻的最优权系数,  $W(k)$  为 $k$ 时刻的最优权系数,  $e(k)$  为 $k$ 时刻的误差,  $X(k)$  为 $k$ 时刻的输入序列;

[0129] 使用最陡下降法不断迭代求解, 使得误差信号最小, 得到自适应滤波去噪后的输出 $y(k)$ 。

[0130] (5) 对自适应滤波去噪的输出 $y(k)$ 通过切割、加噪、调音处理对声信号进行数据增

强。

[0131] 第三步,声信号数据的声音特征提取:与语音识别相同,对于音频数据,在故障检测时有两种应用方法,第一种是直接输入一维信号进行处理,第二种是将音频数据转化为图像来提取音频特征从而进行后续的处理,其中最常用的一种特征是梅尔倒谱系数Mel-scale Frequency Cepstral Coefficients,简称MFCC。通过采用梅尔倒谱系数对预处理后的电力变压器声音数据进行声音特征提取,提取出MFCC系数,提取得到的MFCC系数后期送入网络以产生特征图。其具体步骤如下:

[0132] (1) 对进行数据增强后的 $y(k)$ 进行逆变换生成 $s(t)$ , $s(t)$ 进行预加重操作,其计算公式如下:

$$[0133] \quad y(z) = s(z)H(z),$$

[0134] 其中, $y(z)$ 是预加重的输出, $s(z)$ 是信号 $s(t)$ 的Z域表达, $H(z)$ 为高通滤波器的传递函数,该传递函数为:

$$[0135] \quad H(Z) = 1 - \mu z^{-1},$$

[0136] 该高通滤波器在z域的形式,其中 $\mu$ 的值介于0.9-1.0之间。将声音数据经过一个高通滤波器,从而提升高频部分的能量,尽量使得高频部分与低频部分的能量保持一致,能够在整个频带用相同的信噪比求得频谱。

[0137] (2) 对预加重后的变压器声音数据 $s_q(t)$ 进行分帧处理:

[0138] 将变压器声纹帧长设为30ms,进行变压器声音数据的分帧处理,处理后结构为每一帧30ms。

[0139] (3) 对分帧后的声音数据加窗。加窗函数的目的是增加每一帧声音左端与右端的连续性,具体做法是将每一帧声音与窗函数相乘。

[0140] 使用hamming窗对帧进行加窗处理,假设经过前两步预处理得到的输出为 $S(n)$ ,窗函数为 $W(n)$ ,则计算公式为:

$$[0141] \quad S'(n) = S(n) \times W(n);$$

[0142] 其中窗函数 $W(n)$ 为:

$$[0143] \quad W(n, a) = (1 - a) - a \times \cos\left(\frac{2\pi n}{N - 1}\right),$$

[0144] 该式中 $n$ 代表 $n$ 时刻,其取值范围 $0 \leq n \leq N - 1$ , $N$ 为采样点数,且根据设置不同的 $a$ 值得到不同的Hamming窗, $n$ 表示序列自变量, $a$ 为设定的常数。

[0145] (4) 对加窗后的数据进行快速傅里叶变换。快速傅里叶变换(fast Fourier transform,即FFT)是一种常用的将时域信号转变到频域的方式。

[0146] 对于每一帧信号进行FFT得到频域信号 $X(k)$ :

$$[0147] \quad X(k) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi nk/N} \quad 0 \leq k \leq N,$$

[0148] 其中 $X(k)$ 代表频域输出, $x(n)$ 代表时域输入, $N$ 是采样点数。

[0149] (5) 对快速傅里叶变换后的数据进行梅尔滤波,梅尔滤波转换公式为:

$$[0150] \quad Mel(f) = 2595 \times \lg\left(1 + \frac{f}{700}\right),$$

[0151] 其中,  $f$  代表物理频率,  $Me1(f)$  代表梅尔频率; 将得到的梅尔频率通过  $M$  个梅尔尺度的三角形滤波器组进行滤波, 滤波器组的公式为:

$$[0152] \quad H_{m(k)} = \begin{cases} 0 & k < f(m-1) \text{ 或 } k > f(m+1) \\ \frac{2(k-f(m-1))}{(f(m+1)-f(m-1))(f(m)-f(m-1))} & f(m-1) \leq k \leq f(m) \\ \frac{2(f(m+1)-k)}{(f(m+1)-f(m-1))(f(m+1)-f(m))} & f(m) \leq k \leq f(m+1) \end{cases},$$

[0153] 在该式中:  $\sum_{m=0}^{M-1} H_m(k) = 1$ ,

[0154] 再计算每个滤波器组输出的对数能量:

$$[0155] \quad E(m) = \ln \left( \sum_{k=0}^{N-1} H_m(k) \times |X(k)|^2 \right) \quad 0 \leq m \leq M,$$

[0156] 其中,  $E(m)$  为对数能量,  $H_m(k)$  为滤波器组。

[0157] (6) 对梅尔滤波后的数据进行倒谱分析, 提取出 MFCC 系数  $C(n)$ , MFCC 系数通过进行离散余弦变换 DCT 来实现提取:

$$[0158] \quad C(n) = \sum_{m=0}^{M-1} E(m) \cos\left(\frac{\pi n(m-0.5)}{M}\right) \quad 0 \leq n \leq M,$$

[0159] 其中,  $M$  代表滤波器的个数。  $M$  越大, 每一帧提取的特征值就越多, 信息量就越多, 从而越能准确地描述信号。

[0160] 第四步, 构建变压器故障检测模型: 基于双门控卷积网络模型和变压器声信号的特点构建变压器故障检测模型。

[0161] 变压器声信号能够反应出变压器工作状态, 传统人工排查变压器故障需有经验人工进行现场声音检测。该检测变压器故障的方式存在一定滞后性, 即通常情况下某处位置变压器发生故障后需有经验的人工介入进行变压器的逐一排查。拥有丰富变压器故障排查经验的人力需要多年实操培养, 耗费大量时间成本。变压器在线监测系统利用深度学习方法能够快捷方便地进行故障监测, 目前深度学习方法与传统的故障检测方法类似, 大多数使用的仍旧是振动数据, 仅利用音频数据来进行故障检测的研究还比较少。而相比于振动数据, 音频数据更容易获取且成本低廉, 更加适合于大规模实际应用。因此本发明提出了一种基于双门控卷积神经网络利用变压器音频数据来进行故障检测的方法, 并且设计了一个基于声信号来进行变压器故障检测与识别的模型。

[0162] 由于变压器通常放置在户外, 其声信号往往具有很大的噪声, 当噪声的能量过大, 就会导致变压器本机发出的真实声信号被淹没, 从而导致训练出来的检测模型效果不高。本发明前面步骤对采集而来的声信号进行了去噪预处理, 采用自适应滤波法, 降低噪声能量, 保留变压器本机声信号。变压器声音数据在去除噪声的前提下, 采用一些列数据增强方式, 将数据集样本进行扩充, 使得网络在训练时, 输入更加复杂情况的样本集, 以增强变压器检测模型的鲁棒性。

[0163] 针对变压器音频数据的输入处理,若音频直接采用一维方式输入进网络训练,这样会导致训练所需要的内存过大,物理上难以实现。一维方式的声音数据作为时域信号若直接输入网络,网络只能提取少部分的特征信息,不利于网络模型的训练。故在数据输入网络之前,采用MFCC系数特征提取方式,将时域信号转变为时频信号,以二维信号方式输入网络。MFCC系数是时频信号,包含了更多的特征信息,结果使得网络提取到更多有效的特征,训练出来的模型更好。

[0164] 一般的卷积神经网络因受音频格式的影响,往往会出现训练效率低下和过拟合现象,从而导致故障检测准确率低。不同于一般的卷积神经网络,本发明采用门控卷积的网络结构思想,在卷积网络的输出上加入门控开关。门控开关的作用是在信息在训练传递时,实现一个缓冲控制的效果,从而解决过拟合现象并提升训练效率。针对变压器声音的特点,本发明在单门控卷积网络的基础上,增加一个卷积门控层,设计了双门控卷积神经网络。双门控卷积神经网络采取两个卷积门控层,其能够有效地提取到变压器本机声音的深层次特征,提升训练效果,从而得到优良效果的训练模型。

[0165] 其具体步骤如下:

[0166] (1) 如图3所示,基于双门控卷积神经网络设定变压器故障检测模型,其包括两个卷积门控层、两个池化层、一个全连接层和一个输出层。

[0167] (2) 设定卷积门控层:卷积门控层通过对输入数据与卷积核的卷积操作来提取特征,得到特征图,特征图的深度取决于设定的卷积核的数量;

[0168] 假设输入为 $X \in \mathbb{R}^{A \times B}$ ,其中A与B分别代表输入数据的长与宽,卷积操作定义为:

$$[0169] \quad X_j^l = f \left( \sum_{i=1}^M X_i^{l-1} * k_{ij}^l + b_j^l \right),$$

[0170] 其中: $X_j^l$ 代表第l层卷积层的第j个特征平面图, $X_i^{l-1}$ 代表第l-1层卷积层的第i个平面特征图,M代表平面特征图的个数, $k_{ij}^l$ 代表卷积核, $b_j^l$ 代表偏置, $k_{ij}^l$ 和 $b_j^l$ 的具体参数通过训练优化来确定,f代表激励层函数,常用的激励函数有ReLU与sigmoid函数,其表达式如下:

$$[0171] \quad \text{sigmoid}(x) = \frac{1}{1 + e^{-x}};$$

[0172] 门控的输出表示为:

$$[0173] \quad h(X) = (X * W + b) \otimes \sigma(X * V + c),$$

[0174] 其中:h(X)表示Gated CNN的输出,W和V表示不同的卷积核,b和c表示不同的偏置, $\otimes$ 表示矩阵的元素对应相乘, $\sigma$ 表示sigmoid门控函数,X表示上一层的输出。经过门控结构,降低了模型的梯度弥散,促进了模型的训练,简化了模型的结构,同时保留了模型的非线性表示能力;

[0175] (3) 设计池化层:当卷积核比较小时,经过卷积层之后的特征图仍然很大,这时候就需要经过池化操作来进行降维,减少特征数量、增强网络对于输入特征的鲁棒性,在此采用最大池化或平均池化方法来设定池化层。

[0176] (4) 搭建全连接层和采用softmax分类器作为输出层进行最后分类输出。

[0177] 第五步,变压器故障检测模型的训练:将提取到的MFCC系数输入变压器故障检测模型进行训练。其具体步骤如下:

[0178] (1) 将训练样本集提取后的MFCC系数输入变压器故障检测模型;

[0179] (2) MFCC系数在变压器故障检测模型内进行前向传播和反向传播不断迭代,进行参数优化得到训练后的变压器故障检测模型。

[0180] 第六步,待检测变压器声信号数据的获取及预处理:获取待检测变压器声信号数据,并进行去噪预处理,对去噪预处理后的待检测变压器声信号数据提取MFCC系数。

[0181] 第七步,待检测变压器故障检测结果的获得:将MFCC系数输入训练后的变压器故障检测模型,得到变压器故障检测的结果。

[0182] 以上显示和描述了本发明的基本原理、主要特征和本发明的优点。本行业的技术人员应该了解,本发明不受上述实施例的限制,上述实施例和说明书中描述的只是本发明的原理,在不脱离本发明精神和范围的前提下本发明还会有各种变化和改进,这些变化和改进都落入要求保护的本发明的范围内。本发明要求的保护范围由所附的权利要求书及其等同物界定。

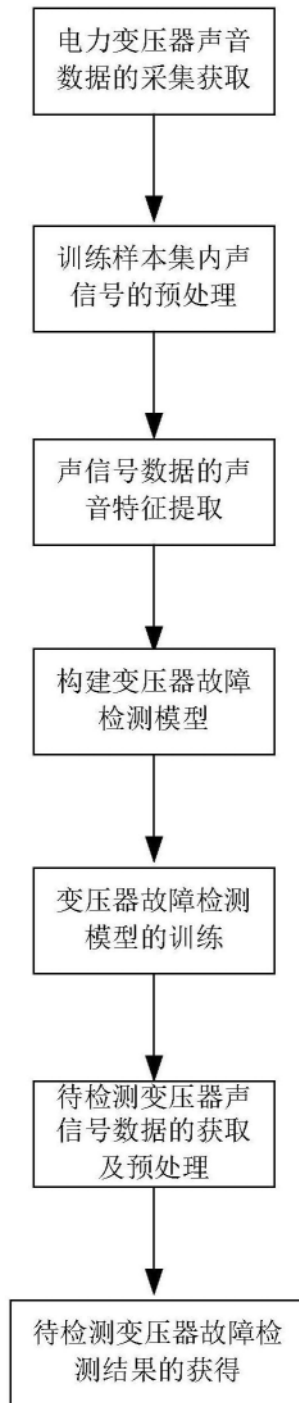


图1



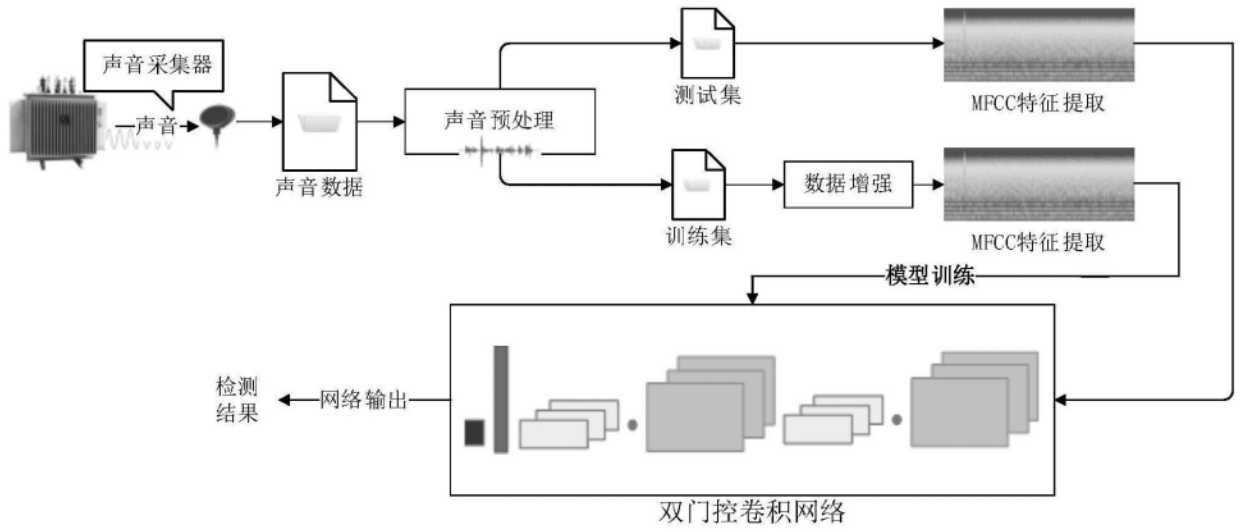


图2

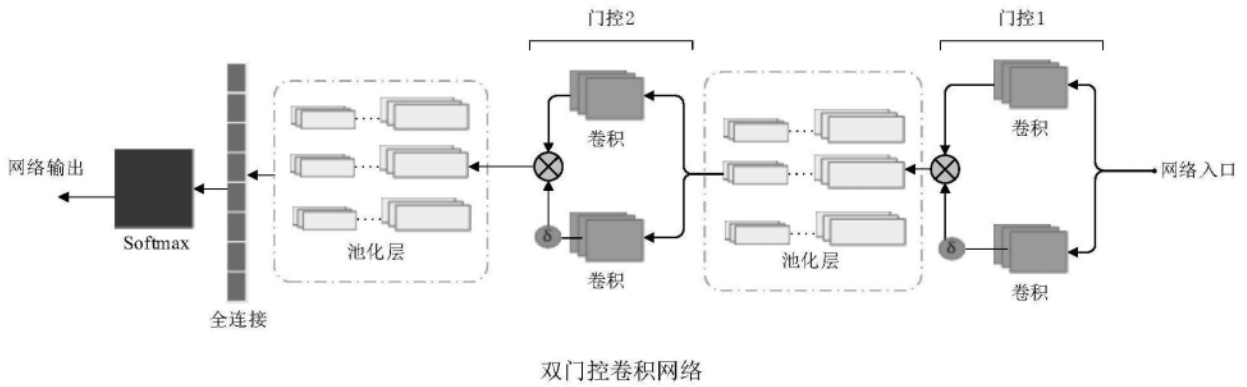


图3