



(12) 发明专利

(10) 授权公告号 CN 113358993 B

(45) 授权公告日 2022.10.04

(21) 申请号 202110521593.6

(22) 申请日 2021.05.13

(65) 同一申请的已公布的文献号
申请公布号 CN 113358993 A

(43) 申请公布日 2021.09.07

(73) 专利权人 武汉大学
地址 430072 湖北省武汉市武昌区八一路
299号

(72) 发明人 何怡刚 曾昭琰 王泉 熊元新
张慧

(74) 专利代理机构 湖北武汉永嘉专利代理有限
公司 42102
专利代理师 张宇

(51) Int. Cl.
G01R 31/26 (2014.01)
G06K 9/62 (2022.01)
G06N 3/04 (2006.01)

(56) 对比文件

- CN 107271925 A, 2017.10.20
 - CN 112115877 A, 2020.12.22
 - CN 109522600 A, 2019.03.26
 - KR 20190123609 A, 2019.11.01
 - CN 109902563 A, 2019.06.18
 - US 2020327663 A1, 2020.10.15
 - US 2021027140 A1, 2021.01.28
 - US 2020089772 A1, 2020.03.19
 - WO 2020247545 A1, 2020.12.10
 - US 2019220704 A1, 2019.07.18
- Ran Gu 等. CA-Net: Comprehensive Attention Convolutional Neural Networks for Explainable Medical Image Segmentation. 《IEEE TRANSACTIONS ON MEDICAL IMAGING》. 2021, 第42卷 (第2期), 第699-711页.

审查员 宋婉甜


权利要求书2页 说明书7页 附图2页

(54) 发明名称

一种多电平变换器IGBT的在线故障诊断及系统

(57) 摘要

本发明公开了一种基于注意力模块的可分离卷积神经网络的多电平变换器IGBT的故障诊断及系统,属于电力电子电路故障诊断领域。改变实验条件,模拟变换器中各IGBT分别故障的情况,获取变换器的若干组传感器监测数据,利用滑动时间窗口将数据分段并归一化后得到样本片段,同时确定各样本的状态标签,构成离线训练数据集。构建包含注意力模块的可分离卷积神经网络,在减少参数量的同时能够提高诊断精度,把离线训练数据集输入分类网络中进行训练,保存最优网络。将实时采集到的各传感器数据分段并归一化,再输入最优网络中,网络将输出实时片段的诊断结果。本发明不仅诊断时间短、诊断精度高,还具有广泛的适用性,可应用于在线诊断之中。



CN 113358993 B

1. 一种多电平变换器IGBT的在线故障诊断方法,其特征在于,包括:

(1) 改变实验条件,模拟多电平变换器中各IGBT分别故障的情况,获取多电平变换器的若干组传感器的监测数据,通过滑动时间窗口将各监测数据分段并归一化后得到离线训练数据集中的样本片段;

(2) 确定各样本片段的状态标签,由样本片段与其对应的状态标签构成离线训练数据集;

(3) 构建基于注意力模块的可分离卷积神经网络,将离线训练数据集划分训练集和验证集,训练集用于训练可分离卷积神经网络,验证集用于评估可分离卷积神经网络效果,保存训练得到的最优可分离卷积神经网络,以通过最优可分离卷积神经网络对多电平变换器IGBT的故障进行实时诊断;

所述基于注意力模块的可分离卷积神经网络包括:三个可分离卷积层、注意力模块、丢弃层、展平层、全连接层及Softmax分类器;

离线训练数据集输入第一个可分离卷积层,以提取全局核心特征,接着利用第二个可分离卷积层和注意力模块来提取全局核心特征的有效特征,其中,使用残差连接将第一个可分离卷积层的输出与注意力模块的输出相连;然后将有效特征和全局核心特征输入第三个可分离卷积层以提取更多的特征;丢弃层在训练过程中以一定的概率从神经网络中随机丢弃神经元,防止过拟合;展平层将经过前面步骤的特征展开;最后通过全连接层连接到Softmax分类。

2. 根据权利要求1所述的在线故障诊断方法,其特征在于,经过第 t 个滑动时间窗口得到的第 i 个传感器的监测数据分段后为 $data_i^t = \{a_{i,1}^t, a_{i,2}^t, \dots, a_{i,j}^t, \dots, a_{i,M}^t\}$, $i \in [1, N]$, 其中, N 为传感器的数量, $a_{i,j}^t$ 为第 i 个传感器数据中第 j ($j \in [1, M]$) 点对应的监测值, M 为滑动时间窗口监测的数据点数,滑动时间窗口的步长为 ΔM 。

3. 根据权利要求2所述的在线故障诊断方法,其特征在于,步骤(2)包括:

各样本片段对应的状态标签为每组数据 $data_i^t$ 中占比最高的状态 s_i^t 来确定,正常状态的标签设为0,故障状态的标签根据故障的IGBT分别设为 $1, 2, 3, \dots, n$, 其中, n 为变换器中IGBT的数量,则网络的类别总数为 $(n+1)$, s_i^t 表示第 t 个滑动时间窗口得到的第 i 个传感器的监测数据中占比最高的状态。

4. 根据权利要求1至3任意一项所述的在线故障诊断方法,其特征在于,所述通过最优可分离卷积神经网络对多电平变换器IGBT的故障进行实时诊断,包括:

将实时采集到的各传感器数据分段并归一化,再输入最优可分离卷积神经网络中,网络将输出实时片段的诊断结果。

5. 一种多电平变换器IGBT的在线故障诊断系统,其特征在于,包括:

样本片段获取模块,用于改变实验条件,模拟多电平变换器中各IGBT分别故障的情况,获取多电平变换器的若干组传感器的监测数据,通过滑动时间窗口将各监测数据分段并归一化后得到离线训练数据集中的样本片段;

离线训练数据集构建模块,用于确定各样本片段的状态标签,由样本片段与其对应的状态标签构成离线训练数据集;

训练模块,用于构建基于注意力模块的可分离卷积神经网络,将离线训练数据集划分训练集和验证集,训练集用于训练可分离卷积神经网络,验证集用于评估可分离卷积神经网络效果,保存训练得到的最优可分离卷积神经网络;

诊断模块,用于通过最优可分离卷积神经网络对多电平变换器IGBT的故障进行实时诊断;

所述基于注意力模块的可分离卷积神经网络包括:三个可分离卷积层、注意力模块、丢弃层、展平层、全连接层及Softmax分类器;

离线训练数据集输入第一个可分离卷积层,以提取全局核心特征,接着利用第二个可分离卷积层和注意力模块来提取全局核心特征的有效特征,其中,使用残差连接将第一个可分离卷积层的输出与注意力模块的输出相连;然后将有效特征和全局核心特征输入第三个可分离卷积层以提取更多的特征;丢弃层在训练过程中以一定的概率从神经网络中随机丢弃神经元,防止过拟合;展平层将经过前面步骤的特征展开;最后通过全连接层连接到Softmax分类。

6. 根据权利要求5所述的在线故障诊断系统,其特征在于,经过第 t 个滑动时间窗口得到的第 i 个传感器的监测数据分段后为 $data_i^t = \{a_{i,1}^t, a_{i,2}^t, \dots, a_{i,j}^t, \dots, a_{i,M}^t\}$, $i \in [1, N]$, 其中, N 为传感器的数量, $a_{i,j}^t$ 为第 i 个传感器数据中第 j ($j \in [1, M]$) 点对应的监测值, M 为滑动时间窗口监测的数据点数,滑动时间窗口的步长为 ΔM 。

7. 根据权利要求6所述的在线故障诊断系统,其特征在于,所述离线训练数据集构建模块,用于各样本片段对应的状态标签为每组数据 $data_i^t$ 中占比最高的状态 s_i^t 来确定,正常状态的标签设为0,故障状态的标签根据故障的IGBT分别设为1, 2, 3, \dots , n , 其中, n 为变换器中IGBT的数量,则网络的类别总数为 $(n+1)$, s_i^t 表示第 t 个滑动时间窗口得到的第 i 个传感器的监测数据中占比最高的状态。

8. 一种计算机可读存储介质,其上存储有计算机程序,其特征在于,所述计算机程序被处理器执行时实现权利要求1至4任一项所述多电平变换器IGBT的在线故障诊断方法的步骤。

一种多电平变换器IGBT的在线故障诊断及系统

技术领域

[0001] 本发明属于电力电子电路故障诊断技术领域,更具体地,涉及一种基于注意力模块的可分离卷积神经网络的多电平变换器IGBT在线故障诊断及系统。

背景技术

[0002] 近年来,多电平变换器不仅在静态同步补偿器、中压电机驱动、柔性直流输电系统等领域中得到了广泛的应用,还在储能系统、电动汽车电池、船舶推进系统等方面受到了广泛的关注。绝缘栅双极型晶体管 (Insulated Gate Bipolar Transistor, IGBT) 由于开关速度快、驱动简单、耐压性好、电流容量大等优势,应用在多电平变换器中。IGBT作为变换器中最脆弱的部件之一,可能会发生开路或短路故障。对于短路故障,通常使用硬件保护隔离装置进行保护,在硬件执行隔离操作后,短路故障转化为开路故障。这些故障会造成三相不对称、过电流、电压电流波形畸变等不良影响,因此对故障部位进行快速、准确地诊断具有重要的实际意义。

[0003] 目前,关于多电平变换器的开路故障诊断方法可大致分为三类:基于硬件、基于模型、基于机器学习的方法。基于硬件的故障诊断方法通常简单、快速且易于实现,但会增加额外的硬件电路或传感器;基于模型的方法需要建立系统的数学或物理模型,通过比较测量的输出值和模型的估计值来进行故障诊断,这种方法往往很难确定故障阈值,也容易受到系统参数变化的影响,且大多数方法仅适用于固定的拓扑或控制策略,无法应用到其他的变换器之中;传统机器学习的故障诊断方法通常分为特征提取和故障识别两步,由于特征提取方法需要手动设计,既复杂又耗时,通常很难实现在实时故障诊断之中。

[0004] 因此,在不增加额外硬件或传感器的情况下,能够快速、准确地对变换器中发生故障的IGBT进行诊断,且要保证诊断方法具有广泛的适用性,这是目前亟需解决的技术难题。

发明内容

[0005] 针对现有技术的以上缺陷或改进需求,本发明提出了一种多电平变换器IGBT的在线故障诊断及系统,通过基于注意力模块的可分离卷积神经网络来实现多电平变换器IGBT的故障诊断,本发明所提出的网络直接利用传感器数据,不需要任何的特征提取算法,能够自动提取隐藏在原始数据中的深层特征,可应用于使用不同拓扑结构或控制策略的变换器之中,有较广的适用性。

[0006] 为实现上述目的,按照本发明的一个方面,提供了一种多电平变换器IGBT的在线故障诊断方法,包括:

[0007] (1) 改变实验条件,模拟多电平变换器中各IGBT分别故障的情况,获取多电平变换器的若干组传感器的监测数据,通过滑动时间窗口将各监测数据分段并归一化后得到离线训练数据集中的样本片段;

[0008] (2) 确定各样本片段的状态标签,由样本片段与其对应的状态标签构成离线训练数据集;

[0009] (3) 构建基于注意力模块的可分离卷积神经网络,将离线训练数据集划分训练集和验证集,训练集用于训练可分离卷积神经网络,验证集用于评估可分离卷积神经网络效果,保存训练得到的最优可分离卷积神经网络,以通过最优可分离卷积神经网络对多电平变换器IGBT的故障进行实时诊断。

[0010] 在一些可选的实施方案中,经过第 t 个滑动时间窗口得到的第 i 个传感器的监测数据分段后为 $data_i^t = \{a_{i,1}^t, a_{i,2}^t, \dots, a_{i,j}^t, \dots, a_{i,M}^t\}$, $i \in [1, N]$,其中, N 为传感器的数量, $a_{i,j}^t$ 为第 i 个传感器数据中第 j ($j \in [1, M]$)点对应的监测值, M 为滑动时间窗口监测的数据点数,滑动时间窗口的步长为 ΔM 。

[0011] 在一些可选的实施方案中,步骤(2)包括:

[0012] 各样本片段对应的状态标签为每组数据 $data_i^t$ 中占比最高的状态 s_i^t 来确定,正常状态的标签设为0,故障状态的标签根据故障的IGBT分别设为1,2,3, ..., n ,其中, n 为变换器中IGBT的数量,则网络的类别总数为 $(n+1)$, s_i^t 表示第 t 个滑动时间窗口得到的第 i 个传感器的监测数据中占比最高的状态。

[0013] 在一些可选的实施方案中,所述基于注意力模块的可分离卷积神经网络包括:三个可分离卷积层、注意力模块、丢弃层、展平层、全连接层及Softmax分类器;

[0014] 离线训练数据集输入第一个可分离卷积层,以提取全局核心特征,接着利用第二个可分离卷积层和注意力模块来提取全局核心特征的有效特征,其中,使用残差连接将第一个可分离卷积层的输出与注意力模块的输出相连;然后将有效特征和全局核心特征输入第三个可分离卷积层以提取更多的特征;丢弃层在训练过程中以一定的概率从神经网络中随机丢弃神经元,防止过拟合;展平层将经过前面步骤的特征展开;最后通过全连接层连接到Softmax分类。

[0015] 在一些可选的实施方案中,所述通过最优可分离卷积神经网络对多电平变换器IGBT的故障进行实时诊断,包括:

[0016] 将实时采集到的各传感器数据分段并归一化,再输入最优可分离卷积神经网络中,网络将输出实时片段的诊断结果。

[0017] 按照本发明的另一方面,提供了一种多电平变换器IGBT的在线故障诊断系统,包括:

[0018] 样本片段获取模块,用于改变实验条件,模拟多电平变换器中各IGBT分别故障的情况,获取多电平变换器的若干组传感器的监测数据,通过滑动时间窗口将各监测数据分段并归一化后得到离线训练数据集中的样本片段;

[0019] 离线训练数据集构建模块,用于确定各样本片段的状态标签,由样本片段与其对应的状态标签构成离线训练数据集;

[0020] 训练模块,用于构建基于注意力模块的可分离卷积神经网络,将离线训练数据集划分训练集和验证集,训练集用于训练可分离卷积神经网络,验证集用于评估可分离卷积神经网络效果,保存训练得到的最优可分离卷积神经网络;

[0021] 诊断模块,用于通过最优可分离卷积神经网络对多电平变换器IGBT的故障进行实时诊断。

[0022] 在一些可选的实施方案中,经过第 t 个滑动时间窗口得到的第 i 个传感器的监测数据分段后为 $data_i^t = \{a_{i,1}^t, a_{i,2}^t, \dots, a_{i,j}^t, \dots, a_{i,M}^t\}$, $i \in [1, N]$,其中, N 为传感器的数量, $a_{i,j}^t$ 为第 i 个传感器数据中第 j ($j \in [1, M]$)点对应的监测值, M 为滑动时间窗口监测的数据点数,滑动时间窗口的步长为 ΔM 。

[0023] 在一些可选的实施方案中,所述离线训练数据集构建模块,用于各样本片段对应的状态标签为每组数据 $data_i^t$ 中占比最高的状态 s_i^t 来确定,正常状态的标签设为0,故障状态的标签根据故障的IGBT分别设为1,2,3, \dots , n ,其中, n 为变换器中IGBT的数量,则网络的类别总数为 $(n+1)$, s_i^t 表示第 t 个滑动时间窗口得到的第 i 个传感器的监测数据中占比最高的状态。

[0024] 在一些可选的实施方案中,所述基于注意力模块的可分离卷积神经网络包括:三个可分离卷积层、注意力模块、丢弃层、展平层、全连接层及Softmax分类器;

[0025] 离线训练数据集输入第一个可分离卷积层,以提取全局核心特征,接着利用第二个可分离卷积层和注意力模块来提取全局核心特征的有效特征,其中,使用残差连接将第一个可分离卷积层的输出与注意力模块的输出相连;丢弃层在训练过程中以一定的概率从神经网络中随机丢弃神经元,防止过拟合;展平层将经过前面步骤的特征展开;最后通过全连接层连接到Softmax分类。

[0026] 在一些可选的实施方案中,所述诊断模块,用于将实时采集到的各传感器数据分段并归一化,再输入最优可分离卷积神经网络中,网络将输出实时片段的诊断结果。

[0027] 按照本发明的另一方面,提供了一种计算机可读存储介质,其上存储有计算机程序,所述计算机程序被处理器执行时实现上述任一项所述方法的步骤。

[0028] 总体而言,通过本发明所构思的以上技术方案与现有技术相比,能够取得下列有益效果:

[0029] (1) 所提的故障诊断方法通过基于注意力模块的可分离卷积神经网络在训练时从数据中学习特征的表示,避免了人工选择特征的复杂过程,直接将原始数据输入训练好的网络中便可以得到诊断结果,使用简单;

[0030] (2) 对于不同的拓扑结构、控制策略下的变换器,只要采集其IGBT的故障监测数据,输入所提的网络进行训练,便可以实现相应的故障诊断,所提出的方法与变换器本身的结构无关,应用范围广;

[0031] (3) 由于采用了可分离卷积,所提网络的参数量有所减少,此外,注意力模块的加入使得网络的精度得到了提高,总体计算量不大,误诊率非常低,因此能够实现高效、可靠的诊断。

附图说明

[0032] 图1是本发明实施例提供的模块化多电平变换器在线故障诊断方法示意图;

[0033] 图2是本发明实施例提供的改变实验条件时某一故障情况下模块化多电平变换器的各电容电压图;

[0034] 图3是本发明实施例提供的不同时间窗口大小对系统平衡精度的影响;

[0035] 图4是本发明实施例提供的基于注意力模块的可分离卷积神经网络的结构图。

具体实施方式

[0036] 为了使本发明的目的、技术方案及优点更加清楚明白,以下结合附图及实施例,对本发明进行进一步详细说明。应当理解,此处所描述的具体实施例仅仅用以解释本发明,并不用于限定本发明。此外,下面所描述的本发明各个实施方式中所涉及到的技术特征只要彼此之间未构成冲突就可以相互组合。

[0037] 在本发明实例中,“第一”、“第二”等是用于区别不同的对象,而不是用于描述特定的顺序或先后次序。

[0038] 实施例一

[0039] 下面以一个模块化多电平变换器 (Modular multilevel converter, MMC) 为具体实施例,具体参数详见表1。基于注意力模块的可分离卷积神经网络,对多电平变换器IGBT进行故障诊断。

[0040] 表1 MMC的电路参数

参数	数值	参数	数值
单桥臂子模块数	3	调制比	0.9
直流侧电压	3kV	子模块电容	4.7mF
基频	50Hz	桥臂电感	5mH
载波频率	1kHz	额定负载	5 Ω ,10mH

[0042] 本发明提出的IGBT故障诊断系统可以分为离线训练和在线诊断两个部分,离线训练、在线诊断的流程在图1中分别用实线、虚线表示。从图1中可以看出,离线训练和在线诊断都要经过数据预处理的步骤,包括滑动时间窗口分段、样本归一化。具体步骤将分为两个阶段进行阐述。

[0043] A. 离线训练阶段

[0044] A1: 为了采集12个开关管的故障数据,改变实验条件,以50kHz的采样频率采集每次实验中故障点前十个周期及后十个周期的六个电容电压信号,可以得到在某种故障情况下各电容电压的波形图,如图2所示。

[0045] A2: 根据滑动时间窗口将采集到的数据划分成样本片段并归一化。滑动时间窗口的大小和步长会直接影响样本中特征信息的含量、诊断的时间延迟、检测到故障的时间点、系统的诊断精度、诊断总时长及占用的硬件内存。为了分析时间窗口大小对系统的影响,将时间窗口分别设置为10ms、20ms、40ms、60ms、80ms进行五倍交叉验证实验,重复十次得到的平衡精度箱形图如图3所示。从这些箱形图可以看出,10ms的滑动时间窗口无法覆盖一个自然周期的完整信息,因此相对于其他时间窗口,该窗口的精度明显较低,且诊断性能的波动较大。同时,时间窗口越大,每个样本包含的特征信息越多,诊断的平衡精度越高、波动越小,说明增大时间窗口可以有效地提高系统的分类性能,这与前面的分析一致。然而,随着时间窗口的增大,输入向量的尺寸也越大,此时需要更多的硬件内存空间和诊断时间。滑动步长越小,检测到故障的时间点越精准,对数据传输和硬件内存的要求也越高。经过权衡,该实例将诊断系统的时间窗大小设置为40ms (两个自然周期),离线训练的平衡精度可达99%以上。

[0046] 在本发明实施例中,经过第t个滑动时间窗口得到的第i个传感器的监测数据分段后为 $data_i^t = \{a_{i,1}^t, a_{i,2}^t, \dots, a_{i,j}^t, \dots, a_{i,M}^t\}$, $i \in [1, N]$, 其中, N为传感器的数量, $a_{i,j}^t$ 为第i个传感器数据中第j ($j \in [1, M]$) 点对应的监测值, M为滑动时间窗口监测的数据点数, 滑动时间窗口的步长为 ΔM 。

[0047] 对分段后的样本做归一化处理是因为故障发生后,各传感器数据会逐渐偏离正常值,为了消除局部幅值变化的影响、突出样本的主要特征,需要根据公式(1)将各传感器的样本都控制在[0,1]的范围内:

$$[0048] \quad (data_i^t)^t = \frac{a_{i,j}^t - (data_i^t)_{\min}}{(data_i^t)_{\max} - (data_i^t)_{\min}} \quad (1)$$

[0049] A3:根据样本片段设置相应的样本标签。时间窗口在滑动时会经历正常状态过渡到故障状态的阶段,这个阶段被称为过渡时期。过渡时期的样本标签通过以下原则来确定:即样本片段片段中占比最高的状态为样本标签。在采集单相的数据时,正常状态的标签设置为0,12个开关管故障的标签从上到下分别设置为1,2,3...12。

[0050] 在本发明实施例中,各样本片段对应的状态标签为每组数据 $data_i^t$ 中占比最高的状态 s_i^t 来确定,正常状态的标签设为0,故障状态的标签根据故障的IGBT分别设为1,2,3,...n,其中,n为变换器中IGBT的数量,则网络的类别总数为(n+1), s_i^t 表示第t个滑动时间窗口得到的第i个传感器的监测数据中占比最高的状态。

[0051] A4:将样本片段和样本标签输入基于注意力模块的可分离卷积神经网络中进行训练,训练集用于训练基于注意力模块的可分离卷积神经网络,验证集用于评估基于注意力模块的可分离卷积神经网络效果,训练得到的最优网络保存至系统中,网络的结构如图4所示。该基于注意力模块的可分离卷积神经网络包括:三个可分离卷积层、注意力模块、丢弃层、展平层、全连接层及Softmax分类器;

[0052] 其中,将离线训练数据集输入第一个可分离卷积层,以提取全局核心特征,可分离卷积既可以大大减少网络参数量,还可以将多传感器时间序列的时间相关性和跨通道相关性解耦;

[0053] 接着利用第二个可分离卷积层和注意力模块来提取全局核心特征的有效特征,为了同时保留全局特征和局部特征,使用残差连接将第一个可分离卷积层的输出与注意力模块的输出相连;

[0054] 将有效特征和全局核心特征输入第三个可分离卷积层以提取更多的特征;

[0055] 丢弃层在训练过程中以一定的概率从神经网络中随机丢弃神经元,防止过拟合;展平层将经过前面步骤的特征展开;最后通过全连接层连接到Softmax分类。

[0056] 其中,可分离卷积层将标准卷积分解成两个部分:逐通道卷积和逐点卷积。首先,逐通道卷积给每个输入通道分配一个单独的过滤器,分别映射各传感器序列的时间相关性。然后,逐点卷积执行 1×1 卷积,生成逐通道卷积输出量的线性组合,以映射不同传感器的跨通道相关性。通过以上两个独立的步骤,时间相关性和跨通道相关性可以被充分解耦,计算量也会比标准卷积少。

[0057] 其中,注意力模块通过评估特征的信息量来学习特征权重,在增大有用的特征权

重的同时降低无用的特征权重,从而实现特征的自适应校准。具体来说,特征的自适应校准分为两步实现,包括挤压操作和激励操作。通过注意力模块,具有代表性的特征被重点突出,而作用不大的特征会受到抑制。

[0058] B. 在线诊断阶段

[0059] B1:将实时采集到的各通道数据分段并归一化,再输入A4训练得到的最优分类网络之中;

[0060] B2:分类网络能够自动提取特征并输出实时片段的预测标签。

[0061] 在线诊断的测试集是通过模拟12种故障情况得到的,改变50次实验条件,共有600条实验记录。离线训练集经过五倍交叉验证,保存在验证集上表现最优的模型,再把在线训练的测试集输入该模型之中,得到在线诊断的实验结果。以一个周期为单位计算各时期的分类正确率,得到模型在故障发生后三个周期的分类正确率分别为99.98%、99.87%、99.97%,其他时期的分类正确率均为100%。由此可知,所提网络在线诊断的准确率非常高。

[0062] 在本发明实例中所使用计算机上,单个样本片段的平均诊断时间约为0.34ms,而时间窗口的滑动步长为2ms,说明所提出的网络可满足在线诊断的实时性。上述根据本发明的方法还可以在其他计算机、处理器、微处理器控制器或可编程硬件中实现。

[0063] 实施例二

[0064] 本发明还提供了一种多电平变换器IGBT的在线故障诊断系统,包括:

[0065] 样本片段获取模块,用于改变实验条件,模拟多电平变换器中各IGBT分别故障的情况,获取多电平变换器的若干组传感器的监测数据,通过滑动时间窗口将各监测数据分段并归一化后得到离线训练数据集中的样本片段;

[0066] 离线训练数据集构建模块,用于确定各样本片段的状态标签,由样本片段与其对应的状态标签构成离线训练数据集;

[0067] 训练模块,用于构建基于注意力模块的可分离卷积神经网络,将离线训练数据集划分训练集和验证集,训练集用于训练可分离卷积神经网络,验证集用于评估可分离卷积神经网络效果,保存训练得到的最优可分离卷积神经网络;

[0068] 诊断模块,用于通过最优可分离卷积神经网络对多电平变换器IGBT的故障进行实时诊断。

[0069] 在一些可选的实施方案中,经过第 t 个滑动时间窗口得到的第 i 个传感器的监测数据分段后为 $data_i^t = \{a_{i,1}^t, a_{i,2}^t, \dots, a_{i,j}^t, \dots, a_{i,M}^t\}$, $i \in [1, N]$,其中, N 为传感器的数量, $a_{i,j}^t$ 为第 i 个传感器数据中第 j ($j \in [1, M]$)点对应的监测值, M 为滑动时间窗口监测的数据点数,滑动时间窗口的步长为 ΔM 。

[0070] 在一些可选的实施方案中,离线训练数据集构建模块,用于各样本片段对应的状态标签为每组数据 $data_i^t$ 中占比最高的状态 s_i^t 来确定,正常状态的标签设为0,故障状态的标签根据故障的IGBT分别设为1,2,3, \dots , n ,其中, n 为变换器中IGBT的数量,则网络的类别总数为 $(n+1)$, s_i^t 表示第 t 个滑动时间窗口得到的第 i 个传感器的监测数据中占比最高的状态。

[0071] 在一些可选的实施方案中,基于注意力模块的可分离卷积神经网络包括:三个可分离卷积层、注意力模块、丢弃层、展平层、全连接层及Softmax分类器;

[0072] 离线训练数据集输入第一个可分离卷积层,以提取全局核心特征,接着利用第二个可分离卷积层和注意力模块来提取全局核心特征的有效特征,其中,使用残差连接将第一个可分离卷积层的输出与注意力模块的输出相连;然后将有效特征和全局核心特征输入第三个可分离卷积层以提取更多的特征;丢弃层在训练过程中以一定的概率从神经网络中随机丢弃神经元,防止过拟合;展平层将经过前面步骤的特征展开;最后通过全连接层连接到Softmax分类。

[0073] 在一些可选的实施方案中,诊断模块,用于将实时采集到的各传感器数据分段并归一化,再输入最优可分离卷积神经网络中,网络将输出实时片段的诊断结果。

[0074] 需要指出,根据实施的需要,可将本申请中描述的各个步骤/部件拆分为更多步骤/部件,也可将两个或多个步骤/部件或者步骤/部件的部分操作组合成新的步骤/部件,以实现本发明的目的。

[0075] 本领域的技术人员容易理解,以上所述仅为本发明的较佳实施例而已,并不用以限制本发明,凡在本发明的精神和原则之内所作的任何修改、等同替换和改进等,均应包含在本发明的保护范围之内。

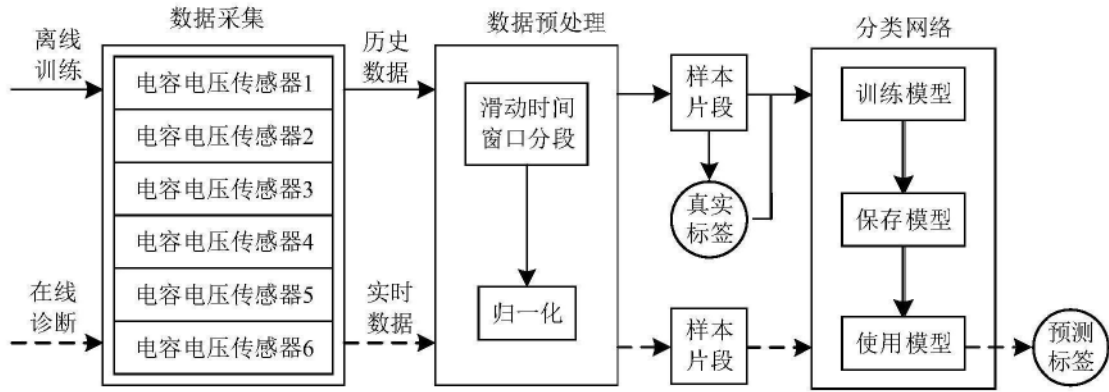


图1

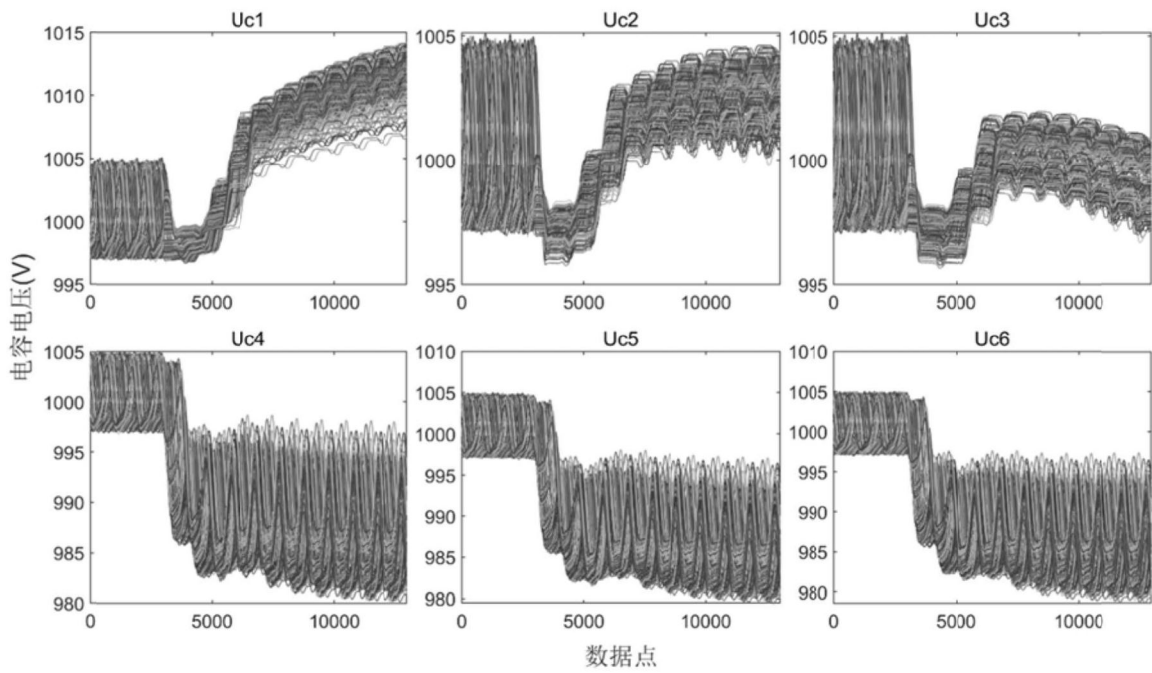


图2




图3

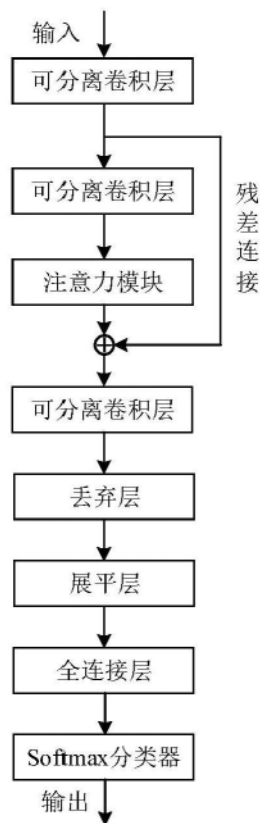


图4