基于 SE-DSCNN的 MMC 开关管故障诊断方法

曾昭瑢,何怡刚

(武汉大学 电气与自动化学院,湖北 武汉 430072)

摘要:为了实现模块化多电平变换器(MMC)子模块开关管的故障诊断,提出了一种基于挤压-激励模块的深 度可分离卷积神经网络(SE-DSCNN)。该网络直接利用原始电容电压数据,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,结合挤压-激励模块以突出通道域中具有代表性的特征,利用深 度可分离卷积(DSC)来减少网络的计算量。利用滑动时间窗口将数据分段并归一化后输入提前训练好的最 优模型中,模型输出预测标签。通过与其他人工特征提取方法及深度学习方法进行对比,结果表明模型参数 量比具有相同卷积层数的标准卷积神经网络(CNN)减少了70.92%左右。所提方法在已有样本片段上的分 类准确率及不同故障时期的诊断正确率均达99%及以上,诊断单个样本片段所需的时间约为0.34 ms,不但 能区分故障早期的耦合性特征,还能实现准确、可靠、高效、快速的故障诊断。

关键词:MMC;开关管故障;挤压-激励模块;深度可分离卷积神经网络;故障诊断 中图分类号:TM 46

文献标志码:A

DOI:10.16081/j.epae.202202029

0 引言

模块化多电平变换器 MMC(Modular Multilevel Converter)作为变换器中最具吸引力的拓扑结构之 一,凭借着模块化、易扩展、设计灵活、效率高及谐波 性能好等优点,被应用于中压电机驱动、高压直流输 电系统、统一潮流控制器等场景中^[1-3]。MMC由多个 级联子模块 SM(Sub-Module)组成,每个 SM 中又包 含多个功率半导体器件。一旦发生故障,会产生三 相不对称、过电流及电压电流波形畸变等不良影 响^[4]。因此,对故障部位进行快速、准确的诊断具有 重要的实际意义。

MMC中的开关管可能会发生开路或短路故障, 通常短路故障在硬件保护装置执行隔离操作后会转 化为开路故障^[5],因此MMC故障诊断研究主要是针 对其开关管的开路故障。多电平变换器的开路故障 诊断方法包括基于模型、基于机器学习的方法等。

收稿日期:2021-07-21;修回日期:2021-12-27 在线出版日期:2022-02-28

基金项目:国家自然科学基金资助项目(51977153,51977161, 51577046);国家自然科学基金重点项目(51637004);国家 重点研发计划"重大科学仪器设备开发"资助项目 (2016YFF0102200);装备预先研究重点项目(41402040301); 武汉市科技计划项目(20201G01)

Project supported by the National Natural Science Foundation of China(51977153,51977161,51577046), the Key Program of the National Natural Science Foundation of China (51637004), the National Key R&D Program of China "Important Scientific Instruments and Equipment Development" (2016YFF0102200), Equipment Research Project in Advance (41402040301) and Wuhan Science and Technology Plan Project(20201G01)

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。文献[6]借助观测器来检测和定位开关 管的开路故障,文献[7]建立SM分组输出电压的预 测模型以判断故障类型,这类方法需要设置故障阈 值。如果阈值设置过小,则可能会造成故障误判;如 果阈值设置过大,则很难在特征不明显的故障早期 实现诊断。此外,该类方法还易受到系统参数变化 的影响,具有一定的局限性。传统机器学习的故障 诊断方法通常分为人工特征提取、故障分类两步。 文献[8]先用主成分分析 PCA(Principal Component Analysis)选取输出电压经快速傅里叶变换 FFT(Fast Fourier Transform)后的特征,再利用多分类相关向 量机 mRVM(multiclass Relevance Vector Machine) 进行故障分类。文献[9]使用小波包分解 WPD(Wavelet Packet Decomposition)和PCA提取电容电压的故 障特征,基于遗传算法GA(Genetic Algorithm)优化 后的 BP 神经网络区分故障的开关管。这类方法中 的人工特征提取通常依赖大量的先验知识,需要根 据分类结果不断调整所选特征,很难获得数据中的 深层特征。而深度学习可以解决这个问题,其将特 征提取和故障分类合并成一个模型,模型自动从数 据中学习特征信息的表示方法,在实现自动提取特 征信息的同时提高模型的分类性能。文献[10]使用 深度学习中的栈式稀疏自动编码器 SSAE(Stacked Sparse Auto-Encoder)和Softmax分类器对故障子模 块进行定位,但未考虑对故障开关管的定位。

为了快速、准确地定位 MMC 故障开关管,识别 特征不够明显的早期故障,本文基于深度学习,将故 障诊断问题转变成分类问题,采用一种结合挤压-激

励 SE(Squeeze-and-Excitation)模块的深度可分离卷 积神经网络 DSCNN (Depthwise Separable Convolutional Neural Network) (简记为 SE-DSCNN),自动提 取深层故障特征,在网络结构参数缩减的情况下仍 有较好的诊断效果。

1 MMC的运行原理及故障分析

1.1 MMC的拓扑结构及工作原理

MMC 逆变器的拓扑结构如图 1 所示,每相包括 上、下 2 个桥臂,各桥臂分别由 N 个结构相同的 SM 和 一个桥臂电感 L₀ 串联而成,上、下桥臂的中点作为交 流出口连接到负载,每个 SM 由 2 个带反并联二极管 的 IGBT(S₁、S₂)和一个电容 C 构成。图中:U_{de} 为直 流侧电压;u_{sm}为 SM 输出电压;u_c 为电容两端电压。



图 1 MMC 逆变器拓扑结构 Fig.1 Topology structure of MMC inverter

SM正常运行时,S₁,S₂的驱动信号互补,分为投 入和切除2种运行模式。在投入模式下,S1导通、S2 关断,根据电流方向的不同,电容分别进行充、放电, 此时u_{sw}≈u_c;在切除模式下,S₁关断、S₂导通,u_c几乎 保持不变, usm=0。SM的运行模式由调制策略和电 容电压平衡方法共同决定。对于多电平变换器,目 前有空间矢量调制、特定次谐波消除、最近电平逼近 和载波移相PSC(Phase-Shifted Carrier)等多种调制 方式。相比于其他调制策略,载波移相调制技术具 有实现简单、等效开关频率高及谐波特性良好等优 点。在基于 PSC 的脉宽调制 PWM (Pulse Width Modulation)(PSC-PWM)策略中,每个桥臂的N个SM 对应1个特定的正弦调制波和N个依次错开2π/N相 位角的三角载波,通过调制波与三角载波比较得到 的N组 PWM 信号来驱动N个 SM,各 u_{sm} 相加便可得 到单个桥臂的输出电压。此控制策略下,可以通过 调节各SM的参考信号来实现电容电压平衡,具体的 实现方式参考文献[11]。

1.2 故障参量信号的选取

由于多个开关管同时故障的概率非常低,通常 只考虑单个开关管故障的情况,则开关管故障可分 为S₁开路故障和S₂开路故障2种。S₁开路故障会影 响 SM 的投入模式,使原本进行充、放电的电容进入 旁路状态;S₂开路故障会影响 SM 的切除模式,使原 本处于旁路状态的电容进入充、放电状态。某一 SM 的 S₁、S₂开路故障会导致该 SM 的电容异常充放电、 产生不正常的波动,进而偏离预期值。采用 PSC-PWM 策略时,每一相可以单独控制,其他相的 u_c不 会受故障相的影响,因此可以单独分析各相 SM 开关 管故障,将单相 SM 的 u_c 作为区分故障开关管的故 障参量信号。

1.3 故障参量信号的耦合性分析

由于MMC为非线性系统,各控制变量与状态变 量之间具有强耦合性,同相其他非故障SM的电容电 压也会受到故障SM的影响而偏离预期值。在一个 每相含有6个SM的MMC中,a相中各SM电容电压 由上至下分别记为uci、uc2、…、uc6。图2由上至下3 个子图依次为 MMC 上桥臂开关管 SM₁的 S₁、SM₁的 S_{2} 、SM₂的S₁在0.6 s发生开路故障的 u_c 变化曲线。 经对比MMC上桥臂开关管SM₁的S₁、SM₁的S₂开路 故障的uc变化曲线发现,同一SM中的不同开关管 故障后参量信号的变化趋势不同,故障特征明显;经 对比MMC上桥臂开关管SM1的S1、SM2的S1开路故 障的uc变化曲线发现,尽管故障SM与非故障SM的 电容电压之差会随时间逐渐增大,但在故障刚发生 后的几个周期内,不同SM在同一位置的开关管故障 参量信号变化趋势相似,故障特征不够明显。此时, 由于故障SM与非故障SM参量信号之间的差值较 小,基于模型的故障诊断方法难以设置合适的故障 阈值,需要花费一定的时间才能正确定位故障开关 管。基于传统机器学习的方法需要人工提取信号中 关键的非耦合性特征,而参数不同的系统其关键特 征也会有所不同,整个过程需要经过大量的实验。 因此,本文利用SE-DSCNN,在网络学习的过程中自





动提取各故障参量信号中具有代表性的特征信息, 以减少人工提取特征的工作量,提高故障诊断效率, 能够在故障早期准确判断故障类型。

2 基于SE-DSCNN的故障诊断方法

为了从具有耦合性的参量信号中提取深层次特征,同时满足计算量小、准确率高的诊断要求,基于 卷积神经网络(CNN),用深度可分离卷积(DSC)代 替标准卷积以提取信号中的特征信息同时减少计算 量,结合SE模块突出具有代表性的特征信息。

2.1 CNN基本理论

CNN 是一种使用卷积运算的前馈神经网络,通常由以下几种类型层组成。

1)卷积层。单个特征映射平面中各神经元通过 一组相同的权重与前向层的部分区域相连,该组共 享的权重被称为卷积核,经卷积层l输出的第n个特 征映射**x**^{*l*},为:

$$\boldsymbol{x}_{n}^{l} = \sum_{c=1}^{C_{i}} \boldsymbol{k}_{n,c}^{l} * \boldsymbol{x}_{c}^{l-1} + \boldsymbol{b}_{n}^{l}$$
(1)

式中: \mathbf{x}_{c}^{l-1} 为输入量,即前一层(l-1层)中第c个神经 元的特征映射; C_1 为输入通道总数,即前一层的神经 元总数; $\mathbf{k}_{n,c}^{l}$ 为l-1层中第c个神经元到l层中第n个 神经元的权重向量,即第n个卷积核; \mathbf{b}_{n}^{l} 为偏置向 量;*为卷积算子。

2)激活层。将前一层的线性输出经非线性激活 函数处理,以增强网络的表征能力,输出*x*;为:

$$\boldsymbol{x}_n^l = \boldsymbol{\sigma}(\boldsymbol{x}_n^{l-1}) \tag{2}$$

式中: $\sigma(\cdot)$ 为激活函数; x_n^{l-1} 为激活层的输入,也等于上一层的输出。

3)池化层。利用下采样函数将语义上相似的特征合并,经池化层*l*输出的第*n*个特征映射*x*₂为:

$$\boldsymbol{x}_{n}^{l} = f(\boldsymbol{x}_{n}^{l-1}, p, s)$$
(3)

式中: $f(\cdot)$ 为池化函数;p为池化大小;s为移动步幅。

4)全连接层。原理上与传统的多层感知器相同,该层中每个神经元都与上一层的所有神经元完 全连接,其输出x[']为:

$$\boldsymbol{x}^{l} = \boldsymbol{\sigma}(\boldsymbol{w}^{l} \boldsymbol{x}^{l-1} + \boldsymbol{b}^{l}) \tag{4}$$

式中:w¹为权重矩阵;b¹为偏置向量。

5)Softmax分类器。利用归一化指数函数输出 每种类别的条件概率。对于包含多种类别的输入样 本*x*,第*k*类的输出概率为:

$$\sigma(\mathbf{x})_{k} = \frac{\mathrm{e}^{\theta^{k} \mathbf{x}}}{\sum_{k=1}^{4N} \mathrm{e}^{\theta^{k} \mathbf{x}}}$$
(5)

式中: θ为需要学习的模型参数。

2.2 DSC原理

为了减少网络的参数量、提高网络的运行速度,

小型高效的神经网络逐渐成为当前的研究热点之一。MobileNet^[12]就是轻量卷积神经网络的一个代表,其核心组成部分为DSC。将DSC应用于多电容电压时间序列分类问题中,不仅可以大幅减少网络参数量,还可以将多电容电压时间序列的时间相关性和跨通道相关性解耦。

DSC将标准卷积分解成逐通道卷积和逐点卷积 2个部分,如附录A图A1(a)所示。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 射各通道序列的时间相关性。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2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。用式(6)、(7)来表示以上2个步骤。

$$\boldsymbol{y}_{c}^{l} = \boldsymbol{R}_{c} \ast \boldsymbol{x}_{c}^{l-1} + \boldsymbol{b}_{c}^{l}$$

$$\tag{6}$$

$$\boldsymbol{z}_{n}^{l} = \sum_{c=1}^{c_{i}} \boldsymbol{P}_{n} * \boldsymbol{y}_{c}^{l} + \boldsymbol{b}_{n}^{l}$$

$$\tag{7}$$

式中:输入量 $\mathbf{x}_{c}^{l-1} \in \mathbf{R}^{H \times W \times C_{i}}$, H和W分别为输入数据的 高度和宽度; \mathbf{y}_{c}^{l} 为逐通道卷积后的输出; \mathbf{R}_{c} 和 \mathbf{P}_{n} 分别 为逐通道卷积核和逐点卷积核; \mathbf{z}_{n}^{l} 为逐点卷积后的 输出。

2.3 SE模块原理

CNN 同时提取空间和通道中的特征信息,其卷 积层输出的特征映射包含不同程度的代表性信息,越 具有代表性的特征所包含的有用信息就越多。为了 突出通道中具有代表性的特征,文献[13]提出了一种 名为 SE 模块的网络结构,通过评估通道特征的信息 量来学习特征权重,在增大有用特征权重的同时降 低无用特征权重,从而实现通道特征的自适应校准。 具体而言,通道特征的自适应校准分为2步实现,包 括挤压操作和激励操作,如附录A图A1(b)所示。

首先,挤压操作通过全局平均池化,将上一卷积 层所有输出通道的全局信息 $\mathbf{x}^{t} \in \mathbf{R}^{1 \times W \times C_{t}}$ 压缩成一个 通道描述符 $\mathbf{u}^{t} \in \mathbf{R}^{C_{t}}, \mathbf{u}^{t}$ 中第c个通道的元素为:

$$u_{c}^{l} = \frac{1}{W} \sum_{w=1}^{W} x_{c,w}^{l}$$
(8)

接着,激励操作利用注意力门控机制来评估每 个通道的重要性,并产生相应的通道权重 ω '。注意 门控机制使用了2种激活函数,并由2个全连接层进 行参数化,包括一个带有 $C_1/r(r)$ 均能放参数)个神经 元的降维层和一个带有 C_2 个神经元的升维层。经过 激励操作得到的通道权重 ω '为:

$$\boldsymbol{\omega}^{l} = \boldsymbol{\sigma}_{2}(\boldsymbol{W}_{2}^{l}\boldsymbol{\sigma}_{1}(\boldsymbol{W}_{1}^{l}\boldsymbol{u}^{l}))$$
(9)

式中: $\sigma_1(\cdot)$ 和 $\sigma_2(\cdot)$ 分别为 ReLU和 sigmoid 激活函数; W_1', W_2' 为权重。最后,重新校准后的特征 $\tilde{\mathbf{x}}_c'$ 为卷积层特征 \mathbf{x}_c' 与权重 ω_c' 的通道乘积,即:

$$\tilde{\boldsymbol{x}}_{c}^{l} = \boldsymbol{\omega}_{c}^{l} \boldsymbol{x}_{c}^{l} \tag{10}$$

2.4 SE-DSCNN的结构框架

本文将SE模块与DSCNN相结合,网络结构如 图3所示,输入为各电容电压,输出为状态标签。首 先将各电容电压输入第一个DSC层,以提取全局核 心特征;接着利用第二个DSC 层和 SE 模块来提取各 通道的有效特征,为了同时保留全局特征和局部特 征,使用残差连接将上一卷积层的输出与SE模块的 输出相连:将提取到的特征输入第三个DSC 层以提 取更多的特征信息;最后展平(Flatten)层将所有的 特征展开,再通过全连接(Dense)层与Softmax分类 器相连。其中,每个DSC层与激活函数ReLU之间 进行了批归一化 BN(Batch Normalization)处理,其 作用是提高网络的泛化能力以及加快网络的训练速 度;丢弃(Dropout)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,是一种防止过拟合的 正则化方法;为了实现下采样,需要在DSC层之后使 用最大池化(Max Pooling)层及平均池化(Average Pooling)层。



图3 SE-DSCNN的结构

Fig.3 Structure of SE-DSCNN

2.5 基于SE-DSCNN的故障诊断流程

基于 SE-DSCNN 的 MMC 开关管故障诊断流程 如图 4 所示,具体步骤如下。

		•			
电容→	数据分段并	SE-DSCNN	状态		
电压►	归一化	模型	标签		
数据	数据	分类	输出		
采集	处理	网络	结果		
► 训练,► 测试					

图4 基于 SE-DSCNN 的故障诊断流程

Fig.4 Flowchart of fault diagnosis based on SE-DSCNN

1)数据采集。改变运行条件,模拟各开关管分 别故障的情况,采集各电容电压传感器从正常到故 障的数据,将数据分段并归一化后得到样本数据。

2)数据处理。首先通过滑动时间窗口将数据分 段,即利用大小一定、步长一定的滑动窗口按时间顺 序将每个通道序列的数据划分成各个小片段;接着 对分段后的样本做归一化处理,由于故障发生后,电 容电压会逐渐偏离正常值,为了消除局部幅值变化 的影响、突出样本的主要特征,根据式(11)将各通道 的样本数值控制在[0,1]的范围内。

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \tag{11}$$

式中: $X 和 X' 分别为原始数据和归一化后的数据; X_{min} 和 X_{max} 分别为数据 X 中的最小值和最大值。$

3)设置标签。单桥臂含有 N个 SM 的单相 MMC 开关管总数为 4N,将正常状态的标签设置为 0,开关 管故障状态的标签从上到下设置为 1、2、…、4N。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,这个阶段称为过渡时期。过渡时期的样本标 签通过"大多数原则"来确定,即样本片段中占比最 高的状态为样本标签。以大小为 2个自然周期的时 间窗口为例,绘出数据分段及标签设置的过程,如附 录 A 图 A 2 所示。其中,故障点前一个周期和后一个 周期分别用"-1"和"+1"表示,其他周期的表示方法 依此类推,则滑动时间窗口起点在"-2"和"-1"期间 取得的样本处于过渡期间,将起点在"-2"期间内样 本标签设置为 0、起点在"-1"期间内的样本标签设 置为 1、2、3、…、4N。

4)训练阶段。训练阶段的数据集包含样本片段 及样本标签,随机划分为训练集和验证集,训练集用 于训练分类网络,验证集用于评估模型效果,训练得 到最优模型。

5)测试阶段。将测试阶段的样本片段输入训练 阶段得到的最优模型,该模型自动提取片段特征并 输出测试片段的预测标签。

3 数据获取及模型设置

3.1 样本数据获取

为了验证所提方法的可行性,根据图1的拓扑 结构在 MATLAB / Simulink 的环境中搭建仿真系 统,参数如附录A表A1所示。为了采集不同运行条 件下的故障数据,需要改变故障发生时间。设故 障起始时间为2 s,以2 ms的步长在一个20 ms的周 期内设置10种时间偏移量,即 Δ_1 =0, Δ_2 =2 ms,…, Δ_{10} =18 ms,则10种故障发生时间为2 s+ Δ_i (*i*=1,2,…, 10)。额定负载下,改变10种故障发生时间,得到上 桥臂 SM₁中S₁,S₂故障后10个周期的各电容电压波 形图分别如附录A图A3(a)、(b)所示。从图中可以 看出,由于故障发生时间的不同,故障点的起始电容 电压不同,波形有细微的差别,但都属于同一种故障 类型。模拟12种开关管故障情况,每种情况下设置 10种故障发生时间,重复10次运行,每次随机改变 负载值(波动范围在±20%之内),以50kHz的采样 频率采集故障点前3个周期及后10个周期的6个电 容电压信号,则一共得到1200组数据。

3.2 模型参数设置

基于图3所示结构,将网络的参数设置如下:卷 积核的大小为1×13,移动步长为1,3个DSC层中核 的数量分别为16、32、64,SE模块中的缩放参数r为 8,最大池化层的大小为1×3,平均池化层的大小为 1×8,丢弃率设为0.2,具体的结构及参数见附录A表 A2。与其他的深度学习模型相似,该模型也可以通 过通过梯度下降和反向传播算法进行训练。训练 时,将预测状态标签和真实状态标签之间的交叉熵 作为损失函数,并使用Adam优化算法^[14]来最小化 损失函数。每次训练的样本数目设为128,训练集 与验证集之比为4:1,最大迭代次数设置为500。同 时设置提前结束训练的条件:若连续20次迭代中验 证集的损失函数不下降,则停止训练。

3.3 时间窗口设置

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。通常时间窗口越大,每个样本包含的特征信息 越多,诊断的精度越高,但诊断的总时间会相应延 长,所需要的内存空间也越大;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。为了充分提取各电容电压所包含的特 征信息,样本应至少包含正常或故障状态下的1个 完整周期。经权衡考虑,将滑动时间窗口的大小和 步长分别设置为2000、100,则3.1节中每组数据分 段后可得到111个样本,总样本数为133200。再按 4:1的比例随机划分数据集,训练阶段有106560个 样本,测试阶段有26640个样本。

4 结果分析

4.1 模型的评价指标

4.1.1 分类效果的评价指标

由于采集到的每组数据包含3个周期的正常数 据和10个周期的故障数据,正常类别的样本数量和 故障类别的样本数量不完全相等。因此,除了准确 率之外,本文还使用了混淆矩阵、宏查准率、宏查全 率、宏F1等指标来衡量模型的分类效果。

混淆矩阵 *M* 中的元素 *m*_{*i*,*j*}表示类型*i* 的样本被预 测成类型*j* 的数量。则准确率*A*₁的定义为:

$$A_{1} = \frac{\sum_{i=0}^{4N} m_{i,i}}{\sum_{i=0}^{4N} \sum_{j=0}^{4N} m_{i,j}}$$
(12)

对于每一类的查准率 P_i 、查全率 R_i 、F1分数 F_i 分别为:

$$P_{i} = \frac{m_{i,i}}{\sum_{j=0}^{4N} m_{j,i}}$$
(13)

$$R_{i} = \frac{m_{i,i}}{\sum_{i=0}^{4N} m_{i,j}}$$
(14)

$$F_i = \frac{2P_i R_i}{P_i + R_i} \tag{15}$$

则宏查准率 P_{macro} 、宏查全率 R_{macro} 、宏F1分数 F_{macro} 分别为:

$$P_{\text{macro}} = \frac{1}{4N+1} \sum_{k=0}^{4N} P_k$$
 (16)

$$R_{\text{macro}} = \frac{1}{4N+1} \sum_{k=0}^{4N} R_k$$
 (17)

$$F_{\text{macro}} = \frac{1}{4N+1} \sum_{k=0}^{4N} \frac{2P_k R_k}{P_k + R_k}$$
(18)

4.1.2 不同时期的诊断正确率

为了验证模型在故障早期的分类效果,需要 计算出不同时期的诊断正确率。所有的样本片段 可分为正常、过渡、故障3种时期,不同时期对"诊断 正确率"的定义不同,将第 k 类故障的诊断正确率 设为 A⁴。

在正常时期,A⁴定义为预测结果为正常状态(标签0)的样本数与样本总数之比,即:

$$A_{2}^{k} = \frac{m_{0,0}}{\sum_{i=0}^{4N} m_{0,i}}$$
(19)

在过渡时期,样本同时包含正常点和特定故障 点,因此样本被预测为正常状态(标签0)或对应的 故障状态(标签*k*)都属于"诊断正确"。在第*k*类故 障的过渡期间,*A*^{*k*}₂为:

$$A_{2}^{k} = \frac{m_{0,0} + m_{k,k} + m_{0,k} + m_{k,0}}{\sum_{j=0}^{4N} m_{0,j} + \sum_{j=0}^{4N} m_{k,j}}$$
(20)

在故障时期,A^{*}定义为预测结果为对应故障状态(标签*k*)的样本数与样本总数之比,即:

$$A_{2}^{k} = \frac{m_{k,k}}{\sum_{i=0}^{4N} m_{k,i}}$$
(21)

4.2 模型的整体诊断效果

根据第3节获取的样本数据及设置的模型参

108

数,使用SE-DSCNN重复10次实验,每次实验都重新 随机划分训练集、验证集和测试集。将10次测试集 片段分类结果汇总,画出标准化后的混淆矩阵,如附 录A图A4所示。从图中可以看出,大部分的误报率 都集中在正常片段与故障片段的分类,这主要是处 于过渡时期样本所造成的混淆。此外,故障类型之 间的误报率主要集中在处于同一位置上的开关管, 从图2可以看出同一位置上的开关管在故障刚发生 的1个周期内,各电容电压的变化曲线几乎完全重 合,这造成了故障类型1、3、5和故障类型7、9、11之 间的分类出现了极小的偏差。但总体而言,故障与 故障之间的区分效果较好,绝大部分的故障都能被 模型正确识别。

将基于SE-DSCNN的诊断方法与其他几种基于 机器学习的多电平变换器诊断方法进行对比,包括 文献[8-10]的方法。重复10次实验取平均值,得到 各方法在 A_1 、 P_{macm} 、 R_{macm} 、 F_{macm} 这4个指标上的测试 样本结果,如表1所示,其他4种诊断方法的相关参 数设置和标准化混淆矩阵结果分别见附录A表A3 和图A5。经尝试发现:方法1无法处理第3节的样 本规模,文献[8]使用mRVM进行故障诊断的样本 只有450个,此处将样本数量压缩到原来的1/10,方 法1的分类结果不太理想,说明mRVM无法处理规 模较大的样本;方法2的几个分类指标达到了90% 以上,但观察混淆矩阵后发现各类别的查全率差距 非常大,说明SVM只能区分特定的类别;方法3通过 PCA提取的主成分数量比文献[9]更多,说明本文的 数据特征没有文献[9]的数据特征明显。方法1-3 在文献[8-9]中使用的样本都没有经过滑动时间窗 口分段,而是将较长时间范围内的数据作为一个样 本,包含了特征明显的故障后期数据,所以诊断准确 率较高。但本文所采用的数据不仅有特征明显的故 障后期样本片段,还有特征不够明显的故障早期样 本片段。在这种情况下,这3种方法都很难区分不 同类型的故障,即使是对特征明显的故障分类也会 产生混淆。方法4出现误报率的主要原因来自处于 同一位置的开关管,比如故障类型1、3、5之间和故 障类型2、4、6之间出现混淆,说明SSAE区分耦合性 特征的效果很差。方法4对处于不同位置的开关管

表1	不同诊断方法的结果对比	
----	-------------	--

Table 1	Comparison	of	different	diagnostic	methods
	Comparison	01	unnerent	ulagnostic	memous

序号	方法	$A_1 / \%$	$P_{ m macro}$ / %	$R_{ m macro}$ / %	$F_{ m macro}$ / %
1	文献[8]-mRVM	76.48	81.73	73.35	74.78
2	文献[8]-SVM	93.30	92.99	92.49	92.70
3	文献[9]	85.25	86.43	83.56	84.66
4	文献[10]	92.74	92.82	91.81	91.95
5	本文方法	99.00	99.07	99.25	99.16

分类并不会出现偏差,而前3种方法会出现误报,说 明自动特征提取在区分明显特征时比人工特征提取 的效果更好。经对比发现,本文所提基于SE-DSCNN 的诊断方法在包含耦合性特征的总样本上的整体分 类效果远好于其他4种诊断方法,可以实现早期故 障诊断。

4.3 故障早期的诊断效果

为了研究所提网络在故障早期的诊断效果,并 且验证模型的改进效果,将SE-DSCNN与其他3个 深度学习分类网络进行对比,分别是DNN、CNN、 DSCNN。DNN是只包含Dense层的深度学习网络, CNN和DSCNN已第2节中介绍。这3种网络的核心 层(Dense层或卷积层)数量与SE-DSCNN相同,均为 3个,具体结构及参数见附录A表A4—A6。

通过模拟12种故障情况,随机改变故障发生时 间及负载50次,得到600条运行记录。取每条记录 中故障点前10个周期和后10个周期进行分析,以滑 动窗口起点所在的1个周期为单位,计算出各网络 在不同时期的准确率,如附录A表A7所示。从表中 可以看出,正常时期的分类准确率为100%,说明几 个深度学习网络在正常时都不会出现误诊的情况。

为了进一步分析网络诊断不同故障类型的效 果,按照4.1.2节的定义,计算出各网络在故障发生 后不同时期的诊断正确率,其具体数值及网络参数 量见表2,表中"-2"、"-1"、"+1"、"+2"、"+3"分别表 示滑动时间窗口中的样本分别包含了故障发生后 第1-5个周期的数据。从表中可以看出:所提网络 的分类性能最好,故障刚发生后的2个过渡时期的 诊断正确率在99%以上,此后的诊断正确率均达 100%;其他网络在故障发生后,诊断正确率会先下 降再上升,有2~3个周期的误诊率较高。相比于 DNN和CNN,SE-DSCNN的参数量大幅减少,这是 DSC 发挥的作用。SE-DSCNN 的模型参数量比 CNN 的参数量减少了70.92%左右,但诊断性能却得到了 小幅度提升;DSCNN 在故障发生后第2个和第3个 周期的诊断正确率均不到90%,诊断性能远不如 SE-DSCNN,无法正确识别早期故障。这说明了SE 模块对网络性能有较大的提升效果。

表2 不同深度学习网络的结果对比

Table 2 Comparison of results among different

deep learning networks

1714/2		幺粉旱				
网络	-2	-1	+1	+2	+3	沙 奴里
DNN	99.07	89.88	96.13	99.53	100.0	419069
CNN	99.75	97.02	99.82	100.00	100.0	42141
DSCNN	98.68	84.28	89.07	96.42	99.6	10971
SE-DSCNN	99.98	99.97	100.00	100.00	100.0	12255

4.4 样本片段的诊断时间

本文基于 Python 的 Tensorflow 框架实现了所提出的网络,实验所用计算机的内存为 32 GB,显卡为 Nvidia GTX-3080。在该计算机上,单个样本片段的 平均诊断时间约为 0.34 ms。

5 结论

本文采用一种 SE-DSCNN 的网络结构对 MMC 开关管进行故障诊断,使用大小为40 ms、步长为 2 ms的滑动时间窗口划分样本片段,与其他的诊断 算法和深度学习网络进行了对比,模型在各评价指 标上都表现出了高达99%的正确率,单个样本片段 的平均诊断时间约为0.34 ms。所得到的主要结论 如下:

1)所提方法避免了特征提取、特征选择、人工设 置故障阈值的复杂过程,直接将原始的电容电压数 据输入网络便可以得到诊断结果,使用简单;

2)所提方法无需建立MMC的数学模型,因此该 方法可以使用在不同的拓扑结构、控制策略下的 MMC开关管故障诊断之中,应用范围广;

3)所提方法能够区分具有耦合性的特征,在故障早期就能达到较高的诊断正确率,诊断的时间延迟大幅缩短,具有较高的可靠性;

4)所提网络的参数量相比于其他的一些深度学 习网络有所减少,精度却得到了提升,总体计算量不 大,实现了高效、准确的诊断。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

 [1]荣飞,严家俊,孙文隆,等. 基于H-MMC的直驱式永磁同步风力发电系统的运行与控制[J]. 电力自动化设备,2020,40(1): 38-45.

RONG Fei, YAN Jiajun, SUN Wenlong, et al. Operation and control of direct-drive permanent magnet synchronous wind power generation system based on H-MMC[J]. Electric Power Automation Equipment, 2020, 40(1): 38-45.

[2] 李双健,贾秀芳,季一鸣,等. 基于 MMC 拓扑的混合型滤波器 设计及其在 LCC-HVDC 中的应用[J]. 电力自动化设备,2020, 40(6):115-121.

LI Shuangjian, JIA Xiufang, JI Yiming, et al. Design of hybrid filter based on MMC topology and its application in LCC-HVDC [J]. Electric Power Automation Equipment, 2020, 40(6):115-121.

[3]郑涛,王赟鹏,李厚源,等. 基于混合型 Chopper 电路的 MMC-UPFC故障渡越方案[J]. 电力自动化设备,2021,41(2):97-103, 117.

ZHENG Tao, WANG Yunpeng, LI Houyuan, et al. Fault ride through scheme of MMC-UPFC based on hybrid Chopper circuit[J]. Electric Power Automation Equipment, 2021, 41(2):97-103, 117.

[4] 刘玉林,齐静静,李家宁,等.一种基于桥臂电流畸变及自适应 观测的 MMC 子模块开路故障诊断定位方法[J].电源学报, 2020,18(3):106-115. LIU Yulin, QI Jingjing, LI Jianing, et al. Diagnosis and location method for open-circuit fault in MMC sub-module based on bridge arm current distortion and adaptive observation [J]. Journal of Power Supply,2020,18(3):106-115.

- [5] BENTO F, MARQUES CARDOSO A J. A comprehensive survey on fault diagnosis and fault tolerance of DC-DC converters[J]. Chinese Journal of Electrical Engineering, 2018, 4 (3):1-12.
- [6] SHAO S, WHEELER P W, CLARE J C, et al. Fault detection for modular multilevel converters based on sliding mode observer[J]. IEEE Transactions on Power Electronics, 2013, 28 (11):4867-4872.
- [7] 荣飞,朱语博,周诗嘉,等.基于子模块电压分组检测的 MMC 子模块开路故障诊断定位方法[J].电力自动化设备,2020,40 (12):127-135.
 RONG Fei, ZHU Yubo, ZHOU Shijia, et al. Sub-module open fault diagnosis and location method of MMC based on submodule voltage packet detection[J]. Electric Power Automation Equipment,2020,40(12):127-135.
- [8] WANG T Z, XU H, HAN J G, et al. Cascaded H-bridge multilevel inverter system fault diagnosis using a PCA and multiclass relevance vector machine approach [J]. IEEE Transactions on Power Electronics, 2015, 30(12):7006-7018.
- [9] 杨桢,马子莹,李鑫. 基于WPD-PCA与GA-BP的MMC子模块故 障定位方法研究[J]. 电子测量与仪器学报,2019,33(7):181-187. YANG Zhen, MA Ziying, LI Xin. Fault location of MMC submodule based on WPD-PCA and GA-BP[J]. Journal of Electronic Measurement and Instrumentation,2019,33(7):181-187.
- [10] 尹桥宣,段斌,沈梦君,等.模块化五电平逆变器子模块开路故 障的智能诊断方法[J].电力系统自动化,2018,42(12):127-133,147.

YIN Qiaoxuan, DUAN Bin, SHEN Mengjun, et al. Intelligent diagnosis method for open-circuit fault of sub-modules in modular five-level inverter[J]. Automation of Electric Power Systems, 2018, 42(12):127-133, 147.

- [11] LI B B, YANG R F, XU D D, et al. Analysis of the phaseshifted carrier modulation for modular multilevel converters [J]. IEEE Transactions on Power Electronics, 2015, 30(1): 297-310.
- [12] HOWARD A G,ZHU M,CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [EB / OL]. (2017-04-17)[2021-03-10]. https://arxiv.org/abs/ 1704.04861.
- [13] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City, USA; IEEE, 2018;7132-7141.
- [14] KINGMA D P, BA J. Adam: a method for stochastic optimization[EB / OL]. (2017-01-30)[2021-3-10]. https://arxiv.org/ abs/1412.6980v9.

作者简介:



曾昭瑢

曾昭瑢(1997—),女,硕士研究生,主 要研究方向为电力装备及电子电路的故障 诊断(E-mail:zhaorongzeng@whu.edu.cn);

何怡刚(1966—),男,教授,博士,研究方 向为智能电网自动监测与健康管理、电力电子 电路设计测试与诊断等(E-mail:yghe1221@ whu.edu.cn)。

(编辑 王欣竹)

Fault diagnosis method for switches in MMC based on SE-DSCNN

ZENG Zhaorong, HE Yigang

(School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China)

Abstract: In order to realize the fault diagnosis for switches in MMC(Modular Multilevel Converter), a SE-DSCNN (Depthwise Separable Convolutional Neural Network based on Squeeze-and-Excitation) module is proposed. The network directly uses the original capacitance voltage data without any feature extraction algorithm, and can automatically extract the deep features hidden in the original data. It highlights representative features through the combination of SE module, then reduces the calculation of network through DSC (Depthwise Separable Convolution). A sliding time window is used to segment and normalize the data that is then fed into the optimal model trained in advance, and then the model outputs the prediction label. Compared with other manual feature extraction methods and deep learning methods, the results show that the amount of model parameters is reduced by about 70.92% compared to the standard CNN(Convolutional Neural Network) that has the same number of convolutional layers. The classification accuracy on the existing sample fragments and the diagnosis accuracy between different fault periods for the proposed method are both 99% and above. The time required to diagnose a single sample fragment is about 0.34 ms. It can not only distinguish the coupling characteristics of early failures, but also realize accurate, reliable, efficient and fast fault diagnosis.

Key words: MMC; switch failure; squeeze-and-excitation module; depthwise separable convolutional neural network; fault diagnosis



Fig.A2 Illustration of data segmentation and label setting 表 A1 MMC 的电路参数 Table A1 Parameters of MMC circuit

Table A1	Parameters of MMC circuit					
参数	数值	参数	数值			
单桥臂子模块数	3	子模块电容	4.7 mF			
直流侧电压	3 kV	桥臂电感	5 mH			
基频	50 Hz	额定负载电阻	5 Ω			
载波频率	1 kHz	额定负载电感	10 mH			
调制比	0.9					



(b) 上桥臂 SM_1 的 S_2 故障

图 A3 10 种故障发生时间下的电容电压波形

Fig.A3 Capacitor voltage waveforms under ten kinds of fault occurrence time

表 A2 SE-DSCNN 的结构参数

Table A2Parameters of SE-DSCNN structure									
类型 (激活函数)	核数量	核大小	输出大小	参数量	类型 (激活函数)	核数量	核大小	输出大小	参数量
输入层			(2 000,6)	0	DSC 层(BN+ ReLU)	64	13	(223,64)	2 784
DSC 层(BN+ReLU)	16	13	(2 000,16)	254	MaxPooling 层			(75,64)	0
MaxPooling 层		3	(667,16)	0	AveragePooling 层		8	(9,64)	0
DSC 层(BN+ReLU)	32	13	(667,32)	880	Flatten 层			576	0
SE 模块	具体见 2.	3节, <i>r</i> =8	(667,32)	836	Dense 层(Softmax)	13		13	7 501

注:输出大小表示每一层输出的数据大小,当输出为二维张量时,使用"(数据长度,通道数量)"的格式表示,后同。



注: 每个小方格里的数字表示被预测为对应标签的样本数占对应真实标签样本数的百

分比;对角线上的元素表示每个类别的查全率。

图 A4 SE-DSCNN 的标准化混淆矩阵

Fig.A4 Standardized confusion matrix of SE-DSCNN

表 A3 4 种诊断方法的参数设置

Table A3	Parameter	settings	of four	diagnostic	methods

序号	方法	分类方法	人工特征提取方法	输入数据大小	训练/测试样本数	与原文献不同的设置
1	文献[8]-mRVM	mRVM	FFT+PCA	6	10 656/2 664	PCA 累积贡献率设为 98%
2	文献[8]-SVM	SVM	FFT+PCA	6	106 560/26 640	PCA 累积贡献率设为 98%
3	文献[9]	GA-BP	WPD+PCA	18	106 560/26 640	PCA 累积贡献率设为 98%
4	文献[10]	SSAE	无	1 200	106 560/26 640	采样频率设为5kHz







图 A5 不同诊断方法的标准化混淆矩阵



类型 (激活函数)	神经元数	输出大小	参数量
输入层		(2 000,6)	0
Dense 层(ReLU)	64	(2 000,64)	448
Dense 层(ReLU)	32	(2 000,32)	2 080
Dense 层(ReLU)	16	(2 000,16)	528
Flatten 层		320 000	0
Dense 层(Softmax)	13	13	416 013

表 A4 DNN 的结构参数 Table A4 Parameters of DNN structure

表 A5 CNN 的结构参数 Table A5 Parameters of CNN structure

类型 (激活函数)	核数量/丢弃率	核大小	输出大小	参数量
输入层			(2 000,6)	0
Conv 层(ReLU)	16	13	(2 000,16)	1 264
MaxPooling 层		3	(667,16)	0
Conv 层(ReLU)	32	13	(667,32)	6 688
MaxPooling 层		3	(223,32)	0
Conv 层(ReLU)	64	13	(223,64)	26 688
MaxPooling 层		3	(75,64)	0
AveragePooling 层		8	(9,64)	0
Flatten 层			576	0
Dense 层(Softmax)	13		13	7 501

Table A6	Parameters of DSCNN structure					
类型 (激活函数)	核数量	核大小	输出大小	参数量		
输入层			(2 000,6)	0		
DSC 层(ReLU)	16	13	(2 000,16)	190		
MaxPooling 层		3	(667,16)	0		
DSC 层(ReLU)	32	13	(667,32)	752		
MaxPooling 层		3	(223,32)	0		
DSC 层(ReLU)	64	13	(223,64)	2 528		
MaxPooling 层		3	(75,64)	0		
AveragePooling 层		8	(9,64)	0		
Flatten 层			576	0		
Dense 层(Softmax)	13		13	7 501		

表 A6 DSCNN 的结构参数 Table A6 Parameters of DSCNN structure

表 A7 4 种网络在不同时期的分类准确率

Table A7	Accuracy of	of four	networks	between	different	periods
----------	-------------	---------	----------	---------	-----------	---------

网络	各时期的准确率/%																	
	-10	-9	-8	-7	-6	-5	-4	-3	-2	-1	+1	+2	+3	+4	+5	+6	+7	+8
DNN	100	100	100	100	100	100	100	100	97.68	76.37	96.13	99.53	100	100	100	100	100	100
CNN	100	100	100	100	100	100	100	100	97.62	82.15	99.82	100	100	100	100	100	100	100
DSCNN	100	100	100	100	100	100	100	100	96.75	71.08	89.07	96.42	99.60	100	100	100	100	100
SE-DSCNN	100	100	100	100	100	100	100	100	96.47	90.18	100	100	100	100	100	100	100	100