

基于深度自编码器网络的逆变器 开关管开路故障诊断

宋保业, 鲁朋, 许琳

(山东科技大学 电气与自动化工程学院, 山东 青岛 266590)

摘要: 逆变器开关管的开路故障是影响逆变器系统安全、可靠运行的关键问题, 为此研究了基于深度自编码器网络的逆变器开关管开路故障诊断。首先, 给出了逆变器开关管开路故障的模型分析和故障编码, 并通过仿真实验平台采集了不同开路故障情况下的原始故障信号数据。为避免人工进行网络结构设计的繁冗工作, 提出一种自编码器网络的规则化设计方法。该方法能够快速确定隐含层神经元的数量和网络深度, 利用故障数据自动学习开关管的故障特征, 实现端到端的智能故障诊断。对比实验表明, 提出的自编码器网络能够自动挖掘故障信号中的关键特征信息, 对不同类型的故障信号数据均能得到稳定的故障识别率, 验证了所提方法的有效性和优越性。

关键词: 深度神经网络; 自编码器网络; 逆变器; 开关管; 开路故障诊断

中图分类号: TM464

文献标志码: A

Open-circuit fault diagnosis of switch tube in inverters based on deep autoencoder network

SONG Baoye, LU Peng, XU Lin

(College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao 266590, China)

Abstract: The open-circuit fault diagnosis of the switch in inverters is of critical importance for the safe and reliable operation of the inverter system. This paper studied the open-circuit fault diagnosis of inverters based on deep autoencoder network. It first presented the model analysis and fault coding for the open-circuits fault of inverters and collected the original fault data in different cases through a simulation platform. To avoid the tedious work of manual network design, it then proposed a new design method for the autoencoder network. This method could determine the amount of the hidden neurons and the depth of the network quickly and extract the fault features of the switch tube by using the fault data, realizing the intelligent end-to-end fault diagnosis. The results of several comparison experiments indicate that the proposed autoencoder network can mine the key features from the fault data automatically and achieve reliable fault identification based on different kinds of fault data, thus verifying the effectiveness and superiority of the new method.

Key words: deep neural network; autoencoder network; inverter; switch tube; open-circuit fault diagnosis

由于变频调速系统的优越性能, 永磁同步电机、无刷直流电机等开始在电力拖动系统中广泛应用。研究显示, 在所有变频电机的故障中, 有近 40% 的故障来源于变频逆变器的功率半导体开关器件损坏及其电路故障^[1-2]。由于元器件老化、过载和不当触发等原因, 功率开关器件极易发生短路故障或开路故障^[3]。短路故障主要是由过电压、过热和错误的触发信号等引起的, 一旦发生将在极短的时间内产生异常的过电流, 对功率变换器造成损坏。因此, 短路故障一般由标准的保护电路立即进行检测和隔离, 如熔断器、断路器等^[4]。

收稿日期: 2022-01-15

基金项目: 国家自然科学基金项目(61703242); 山东省自然科学基金项目(ZR2023MF067)

作者简介: 宋保业(1982—), 男, 山东青岛人, 副教授, 博士, 主要研究方向为机电系统的故障诊断。

许琳(1982—), 女, 山东聊城人, 讲师, 博士, 主要研究方向为智能控制, 本文通信作者。E-mail: xulin82@sdust.edu.cn

开路故障主要是由触发信号丢失,热、机械疲劳等导致的断线或开关管爆裂引起的,一般不会使驱动系统立即失效。但开路故障导致的系统电流不平衡,会显著降低驱动系统的性能,如电流畸变、转矩振荡等,若不及时诊断并排除故障将引发其他系统元器件故障^[5]。因此,研究逆变器功率开关管的路故障诊断,具有重要的工程实际意义和价值。

功率开关的故障诊断方法可分为基于模型的方法、基于信号的方法和基于知识的方法等^[6-7]。基于模型的方法以观测器/滤波器方法为主^[8],例如,Shao等^[9]设计了用于多电平逆变器功率管开路故障诊断的滑模观测器,采用桥臂电流和电容电压的理论值和实际输出构造残差,实现功率管开路故障的检测和分离;Jlassi等^[10]采用龙贝格观测器估计逆变器的相电流,并与测量值比较产生残差,用于诊断逆变器功率管的开路故障;Naseri等^[11]提出基于Kalman滤波器的逆变器输出电流估计方法,将平均的归一化残差信号用于开关管的开路故障检测,具有故障检测的快速性和鲁棒性的特点。开关管的开路故障会导致电流和电压测量信号的畸变,因此可以利用电流或电压信号处理方法进行故障检测^[12-13]。基于电流信号的方法不需要额外的硬件,但为保证检测结果的准确性需要的时间较长。基于电压信号的方法需要额外增加电压传感器,但具有较好的故障诊断速度、精度和对负载波动、信号噪声等的鲁棒性。基于知识的方法不依赖于系统模型、负载条件和信号模式,但需要大量的历史数据,所以也称为数据驱动的方法,受到国内外学者的广泛关注和深入研究^[6-7,14]。数据驱动方法的信号获取、特征提取和故障分类等主要步骤中,信号特征提取是最关键的,决定了故障诊断的成功率和效率,因此成为故障诊断领域的研究热点^[15]。例如,Gomathy等^[16]采用离散小波变换和主元分析提取三相逆变器的故障信号特征,然后基于相关向量机和布谷鸟搜索算法建立故障诊断模型;Wang等^[17]采用主元分析方法提取H桥多电平逆变器的开路故障特征,然后基于多分类相关向量机实现故障分类;Shafiullah等^[18]采用三相电流信号的S变换得到S矩阵,并将提取的故障特征输入前馈神经网络中进行故障识别;Ye等^[19]采用小波包变换提取故障特征,并采用长短时记忆(long short-term memory, LSTM)网络检测嵌套式中点可控型五电平变换器的开路和短路故障;Cai等^[20]首先采用快速傅里叶变换(fast Fourier transform, FFT)提取三相逆变器开路故障电压信号的特征,然后利用主元分析方法降低样本的维数,最后通过贝叶斯网络检测和诊断故障。但是,上述故障特征提取过程需要人工参与,且大都针对具体的故障诊断问题,不具有应用对象和场合的通用性。

针对上述故障特征提取方法存在的缺陷,近年来基于神经网络的方法开始在故障诊断领域广泛应用^[21-22]。崔江等^[23]采用堆栈自编码器提取故障电流信号的特征,并使用支持向量机(support vector machine, SVM)进行故障分类;Chen等^[24]研究了机械传动系统齿轮箱的故障诊断问题,将原始振动信号直接输入到具有一个卷积层和两个全连接层的卷积神经网络(convolutional neural network, CNN)。Kiranyaz等^[25]提出一种一维卷积神经网络用于模块化多电平逆变器的故障诊断,具有较高的故障诊断准确率;Wen等^[26]提出采用LeNet-5卷积神经网络诊断电机系统轴承故障,提高了系统的故障诊断准确率。以上方法尽管提升了故障诊断性能,但需要大量数据用于特征学习和故障分类,既加重了存储和计算负担,也容易引起梯度爆炸等不稳定问题。

针对以上方法的不足,本研究提出一种新的深度自编码器网络设计方法,用于逆变器开关管的路故障诊断。首先,对逆变器开关管的路故障进行建模、分析和编码,并基于仿真平台采集不同开路故障的信号数据;然后,提出一种自编码器网络的规则化设计方法,避免人工进行网络结构设计的繁冗过程;最后,基于设计的自编码器网络和采集的实验数据,进行开关管开路故障诊断实验,并与4种常用方法进行对比。实验结果表明,分别基于电压和电流两种不同类型的故障信号数据,本研究提出的方法均能够有效利用有限的自动学习开关管的路故障特征,实现端到端的智能故障诊断并得到较高的故障识别准确率,验证了本方法的有效性和优越性。

2 逆变器开关管开路故障模型

2.1 逆变器控制系统模型

考虑如图1所示的永磁同步电机-逆变器控制系统,其主电路拓扑主要由6个金属氧化物半导体场效晶

体管(metal-oxide-semiconductor field-effect transistor, MOSFET) $T_1 \sim T_6$, 和与之相对应的反并联续流二极管 $D_1 \sim D_6$ 构成。定义开关量 $S_1 \sim S_6$ 表示 6 个功率开关管的开关状态。当 S_1, S_3 或 S_5 为 1 时, 逆变器电路的上桥臂开关管导通, 下桥臂开关管切断(此时 S_2, S_4, S_6 为 0), 此状态记为 $S_a(S_b, S_c) = 1$; 反之, 当 S_2, S_4 或 S_6 为 1 时, 则逆变器电路的下桥臂开关管导通, 而上桥臂开关管关断(此时 S_1, S_3, S_5 为 0), 此状态记为 $S_a(S_b, S_c) = 0$ 。

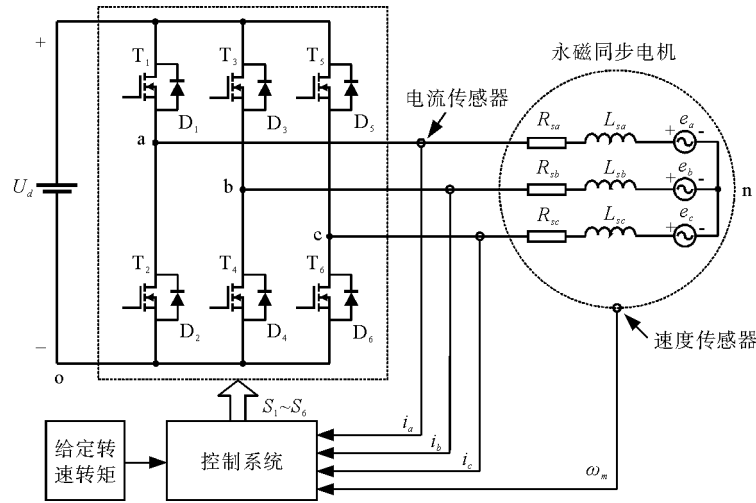


图 1 永磁同步电机-逆变器控制系统
Fig. 1 PMSM-inverter control system

2.2 开关管开路故障分析

在图 1 的逆变器主电路中, 假设发生开路故障的开关管最多为 2 个, 则全部的开关管开路故障可以分为 5 大类共 22 种情况, 主要包括 1 种正常状态(可看作一种特殊的故障), 6 种单管故障, 3 种同相桥臂双管故障, 6 种相邻相桥臂同侧双管故障和 6 种相邻相桥臂异侧双管故障, 如表 1 所示。

表 1 开关管开路故障类型
Table 1 Types of open-switch fault

故障类型	发生故障的功率管	种类
正常	无故障	1
单管故障	$T_1, T_2, T_3, T_4, T_5, T_6$	6
同相桥臂双管故障	$T_1 T_2, T_3 T_4, T_5 T_6$	3
相邻相桥臂同侧双管故障	$T_1 T_3, T_2 T_4, T_3 T_5, T_4 T_6, T_1 T_5, T_2 T_6$	6
相邻相桥臂异侧双管故障	$T_2 T_3, T_1 T_4, T_4 T_5, T_3 T_6, T_1 T_6, T_2 T_5$	6

以开关管 T_1 发生开路故障为例, 此时的主电路拓扑如图 2 所示。定义相电流流入电机定子的方向为参考正方向, 于是 a 相电流的流电路径如图 3 所示。当 $i_a < 0$ 时, a 相电流的主要通路经过 T_2 , 续流通路经过 D_1 。由于 T_2 和 D_1 均可以正常导通或续流, 所以此时 a 相电流的负半周期不受开关管 T_1 发生开路故障的影响。当 $i_a > 0$ 时, a 相电流的主要通路经过 T_1 , 续流通路经过 D_2 。尽管 D_2 可以正常续流, 但由于开关管 T_1 发生开路故障不能导通, 所以 a 相电流不能正向增大, 在正半周期基本为零。

图 4 为开关管 T_1 发生开路故障时, 逆变器的三相电流和端电压信号的归一化示例。为了能清晰表示, 三相电流和端电压波形都只截取了一部分, 开路故障发生在图中的第 100 个采样点时刻(下同)。对于表 1 中的其他故障情况, 可进行类似分析, 在此不再赘述。可以看出, 当故障发生后, 逆变器的电流和电压信号均

发生畸变,而这些畸变的电流、电压信号蕴含着对应故障的特征信息,可以通过机器学习算法进行故障特征的学习、提取,进而实现开关管的开路故障诊断。

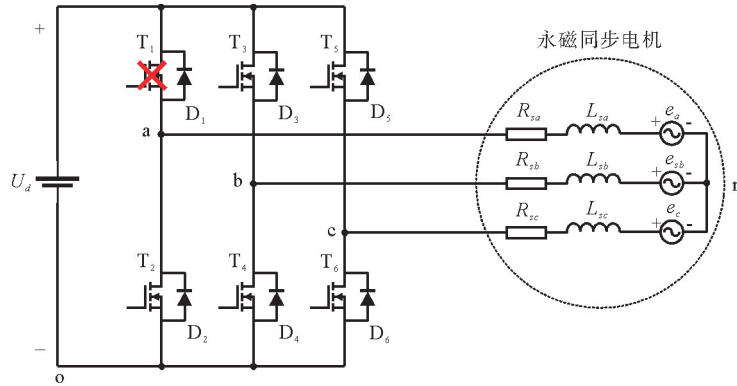


图 2 T₁ 发生开路故障的主电路

Fig. 2 Main circuit in the case of T₁ fault




图 3 T₁ 发生开路故障的电流通路

Fig. 3 Current path in the case of T₁ fault

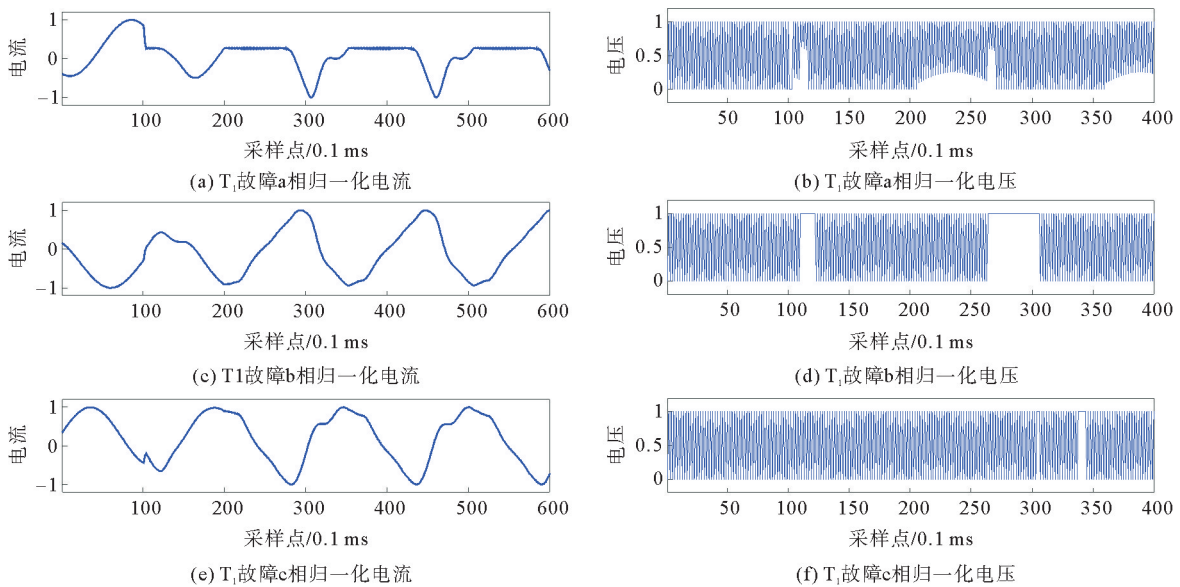


图 4 T₁ 发生开路故障的电流和电压

Fig. 4 Current and voltage in the case of T₁ fault

2.3 故障信号采集与编码

本研究故障诊断实验采用的开关管开路故障信号来源于 MATLAB/Simulink 的电机运动控制仿真平台,仿真时将触发信号置零来模拟逆变器开关管的开路故障。通过仿真平台采集电机驱动器开关管发生开路故障时的电流和电压信号,并分别选用三相电流和端电压进行故障诊断,具体故障类型与编码如表 2 所示。

表 2 故障类型与故障编码
Table 2 Fault types and codes

故障类型	故障编码	故障类型	故障编码
T ₁	10000000000000000000	T ₂ T ₃	00000000001000000000
T ₂	01000000000000000000	T ₂ T ₄	0000000000001000000000
T ₃	00100000000000000000	T ₂ T ₅	0000000000000100000000
T ₄	00010000000000000000	T ₂ T ₆	0000000000000010000000
T ₅	00001000000000000000	T ₃ T ₄	000000000000000010000000
T ₆	00000100000000000000	T ₃ T ₅	000000000000000001000000
T ₁ T ₂	00000010000000000000	T ₃ T ₆	000000000000000000100000
T ₁ T ₃	00000001000000000000	T ₄ T ₅	000000000000000000001000
T ₁ T ₄	00000000100000000000	T ₄ T ₆	000000000000000000000100
T ₁ T ₅	00000000010000000000	T ₅ T ₆	000000000000000000000010
T ₁ T ₆	00000000001000000000	无故障	00000000000000000000000001

3 基于自编码器网络的开关管开路故障诊断

3.1 自编码器网络

自编码器(autoencoder, AE)是一个对称的三层神经网络,可通过无监督学习从原始数据信号中提取特征信息^[27]。如图 5 所示,自编码器包括编码和解码两个步骤^[28]。

在编码阶段,将无标签数据 $\{x_i\}_{i=1}^M, x_i \in \mathbf{R}^{N \times 1}$ 输入自编码器的输入层,则隐含层的输出可通过非线性激活函数计算为:

$$h_i = f(x_i) = \text{Sigmoid}(W_1 x_i + b_1). \quad (1)$$

式中, W_1 和 b_1 分别为编码器的权值矩阵和偏置向量。在解码阶段,隐含层向量 h_i 用于重构输入向量 x_i 得到重构结果 \hat{x}_i :

$$\hat{x}_i = g(h_i) = \text{Sigmoid}(W_2 h_i + b_2). \quad (2)$$

式中, W_2 和 b_2 分别为解码器的权值矩阵和偏置向量。实际上自编码器的目标就是学习一个重构映射 $F: x \rightarrow \hat{x}$,使得重构的输出等于自编码器的输入,即:

$$\hat{x} = F(x) = g(f(x)) \approx x. \quad (3)$$

这样,隐含层向量 h_i 则包含从无标签数据中提取到的特征信息。实际上,式(3)就是要使得重构误差的代价函数最小化,通常可将重构误差的代价函数定义为:

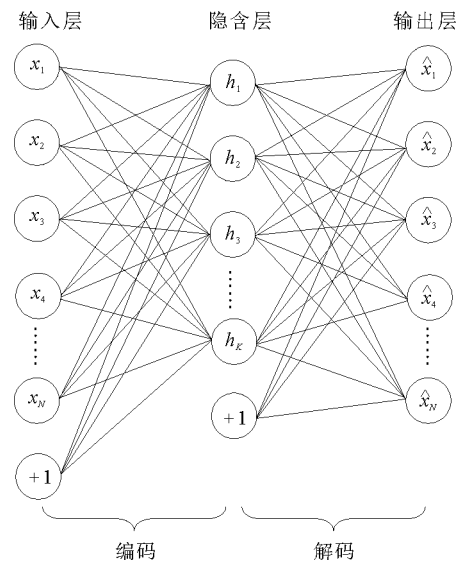


图 5 自编码器结构

Fig. 5 Structure of the autoencoder

$$J_{AE}(\mathbf{W}, \mathbf{b}) = \frac{1}{M} \sum_{i=1}^M \frac{1}{2} \|\mathbf{x}_i - \hat{\mathbf{x}}_i\|_2^2 + \frac{\lambda}{2} \sum_{l=1}^{n_l-1} \sum_{i=1}^{s_l-1} \sum_{j=1}^{s_l} (\omega_{ji}^l)^2 \quad (4)$$

式中: M 为训练数据集的样本数量; λ 为调节前后两项相对权重的系数, 用于防止出现过拟合现象; n_l 为自编码器的层数; s_l 表示第 l 层的神经元数量。为获得更好的性能, 通常将稀疏性约束条件加入到式(4)的代价函数中, 实现特征表示的稀疏化。考虑到稀疏惩罚项, 将稀疏自编码器(sparse autoencoder, SAE)的重构误差代价函数重新定义为:

$$J_{SAE}(\mathbf{W}, \mathbf{b}) = J_{AE}(\mathbf{W}, \mathbf{b}) + \beta \sum_{j=1}^K \text{KL}(\rho \parallel \hat{\rho}_j) \quad (5)$$

式中: β 为稀疏惩罚项的权重系数; K 为隐含层的神经元数量; $\text{KL}(\rho \parallel \hat{\rho}_j)$ 为 KL 散度(Kullback-Leibler divergence), 用于度量两个分布之间的差异性,

$$\text{KL}(\rho \parallel \hat{\rho}_j) = \rho \log_2 \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log_2 \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (6)$$

式中: ρ 为预定义的稀疏性参数, 即以上均值的期望值, 起稀疏性约束条件的作用; $\hat{\rho}_j$ 为当输入向量为 $\{\mathbf{x}_i\}_{i=1}^M$ 时, 第 j 个隐含层神经元激活函数的均值, 即

$$\hat{\rho}_j = \frac{1}{M} \sum_{i=1}^M h_j^i \quad (7)$$

式中, h_j^i 是第 j 个隐含层的第 i 个节点输出。显然, 当 $\hat{\rho}_j = \rho$ 时, $\text{KL}(\rho \parallel \hat{\rho}_j) = 0$; 否则, $\text{KL}(\rho \parallel \hat{\rho}_j)$ 将随着 $\hat{\rho}_j$ 与 ρ 的差距增大而迅速递增。

堆栈稀疏自编码器(stacked sparse autoencoder, SSAE)网络是由多个稀疏自编码器堆叠而成的深层神经网络, 能够采用逐层训练的方式实现无监督学习, 是常用的深度学习网络之一。SSAE 通过与 Softmax、SVM 等分类算法相结合, 可用于解决模式分类问题。如图 6 所示, 在 SSAE 网络中, 首先利用输入的样本数据对网络的第一个 SAE 进行预训练, 得到权重矩阵 \mathbf{W}_{11} 、 \mathbf{W}_{21} 和偏置向量 \mathbf{b}_{11} 、 \mathbf{b}_{21} , 保存 \mathbf{W}_{11} 和 \mathbf{b}_{11} ; 然后将第一个 SAE 的隐含层输出向量 \mathbf{h}_1 作为第二个 SAE 的输入, 对第二个 SAE 进行预训练, 得到权重矩阵 \mathbf{W}_{12} 、 \mathbf{W}_{22} 和偏置向量 \mathbf{b}_{12} 、 \mathbf{b}_{22} , 保存 \mathbf{W}_{12} 和 \mathbf{b}_{12} ; 依次对网络的所有 SAE 进行训练直到最后一层。最终, 在给定期望的数据标签之后, 通过反向传播(back propagation, BP)算法对整个深度学习网络参数进行微调, 其代价函数可以表示为:

$$J_{SSAE}(\mathbf{W}_{n_L}, \mathbf{W}_{1,k} \mid_{k=1}^{n_L-1}, \mathbf{b}_{1,k} \mid_{k=1}^{n_L-1}) = \arg \min_{\mathbf{W}_{n_L}, \mathbf{W}_{1,k}, \mathbf{b}_{1,k}} \frac{1}{M} \sum_{i=1}^M \frac{1}{2} \|\mathbf{y}_i - g_{n_L}(f_{n_L}(\mathbf{h}_i^{n_L-1}))\|_2^2 \quad (8)$$

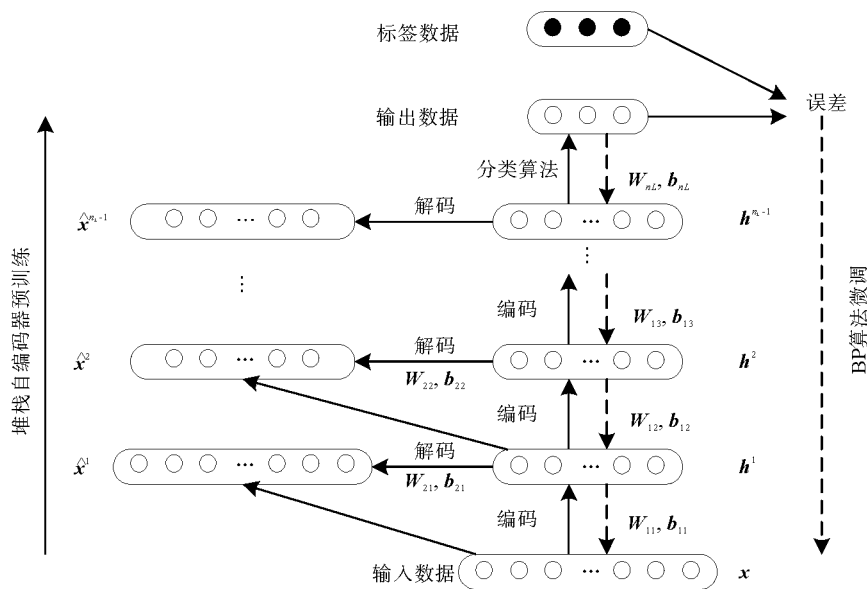


图 6 堆栈稀疏自编码器网络结构

Fig. 6 Structure of the stacked sparse autoencoder network

式中: n_L 为 SSAE 网络的总层数; $\mathbf{h}_i^{n_L-1} = f_{n_L-1}(f_{n_L-2}(\dots f_1(\mathbf{x}_i)))$ 表示第 n_L-1 个隐含层的输出特征向量; \mathbf{y}_i 为与输入向量 \mathbf{x}_i 对应的标签向量; \mathbf{W}_{n_L} 为最后一层的权值矩阵, $\mathbf{W}_{1,k}$ 和 $\mathbf{b}_{1,k}$ 分别为深度学习网络第 k 层的权值矩阵和偏置向量。

3.2 堆栈稀疏自编码器网络的设计

堆栈稀疏自编码器网络是深度神经网络的实现方式之一,其网络结构目前主要通过经验确定,尚无规范的设计方法。为此,本研究提出一种规范的自编码器网络设计方法。首先,基于输入数据维数采用二进制递减方法设计各隐含层的神经元数量;然后,根据输出分类的类别数选择特征输出隐含层的位置,从而确定自编码器网络的拓扑结构,其原理如图 7 所示。

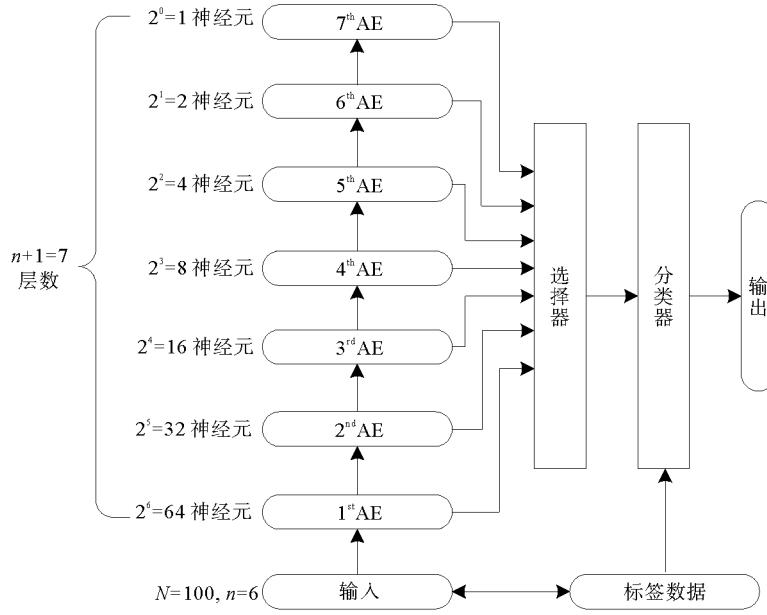


图 7 自编码器网络拓扑设计方法

Fig. 7 Topology design method of the autoencoder network

具体地,自编码器的隐含层神经元数量通常小于输入层神经元数量,输入信号的特征可以通过压缩后的隐含层输出来表示。假设输入层神经元数量为 N ,则将第一个隐含层的神经元数量设计为 2^n ,其中 n 为满足 $2^n \leq N$ 的最大正整数,如 $N=100$,则可将 n 设计为 6。然后,在第二个隐含层的神经元数量设计为 2^{n-1} ,第三个隐含层的神经元数量设计为 2^{n-2} ,即当前隐含层的神经元数量是上一层的一半,以此类推。这样,最后一个隐含层的神经元数量为 $2^0=1$,则整个堆栈稀疏自编码网络的最大层数为 $n+1$ 。

然后,将隐含层的输出送入一个选择器,并将提取的隐含层特征送入分类器进行特征分类。其中,进入分类器的隐含层特征值数量一般应大于分类器的输出类别。于是,假设分类器的输出类别数量为 M ,进入分类器的是第 m 个隐含层的输出特征,则可将 m 设计为满足 $2^{n-m+1} \geq M$ 的最大正整数。综上,上述自编码器网络拓扑的设计方法可总结为算法 1。

算法 1 自编码器网络拓扑设计算法

- 1) 初始化:设定输入层神经元数量 N 和分类器输出类别数量 M ;
- 2) 选择满足 $2^n \leq N$ 的最大正整数 n ,并将第一个隐含层神经元数量设计为 2^n ;
- 3) 选择满足 $2^{n-m+1} \geq M$ 的最大正整数 m ,并将第 m 个隐含层神经元数量设计为 2^{n-m+1} ;
- 4) 从第二个隐含层开始,将隐含层神经元数量设计为上一个隐含层神经元数量的一半,直到第 m 个隐含层;
- 5) 输出自编码器网络拓扑。

以上自编码器网络采用 Softmax(归一化指数函数)分类器。Softmax 分类器是 Logistic 回归在多分类问题上的推广,目前被广泛用于机器学习算法中,同时还用于在深度神经网络的训练过程中对整个网络进行微调,其定义为:

$$\text{Softmax}(x_i) = \frac{e^{\theta_j^T x_i}}{\sum_{j=1}^K e^{\theta_j^T x_i}} \quad (9)$$

式中: $\theta_1, \theta_2, \dots, \theta_K$ 为模型参数; K 为模型输出的类别数。式(9)表示对输入数据 x_i ,先通过指数运算将其变为正数,然后进行归一化,从而得到将 x_i 分类成第 j 类数据的概率。实际上,Softmax 分类器常用于神经网络的最后一层进行多类别分类,其结构如图 8 所示,图中 $K=3$ 。

3.3 实验结果

本节通过仿真实验,验证上述堆栈稀疏自编码器网络在逆变器开关管开路故障诊断中的有效性和优越性。实验数据来自上述电机运动控制仿真平台,数据处理采用 MATLAB/Simulink 仿真平台。实验中采用三相电压或三相电流中的 a 相信号作为自编码网络的输入信号。在采样开始后以 10 kHz 的采样频率采集 3 s 内的实验数据,则每种故障情况总共可以获得 30 000 个采样数据。

实验中,通过将驱动信号置零模拟开关管的开路故障,并设定开路故障发生在采样开始后的 0.2 s。同一类故障的每一个样本由 2 400 个连续采样点组成。为增加样本数量,采用重叠采样的方式制作数据集,数据采集的滑动步长为 10,如图 9 所示。实验中的数据集包括训练样本数 $1\ 600 \times 22 = 35\ 200$ 个,测试样本数 $600 \times 22 = 13\ 200$ 个。实验中的自编码网络共设有 7 个隐含层,第一个和最后一个隐含层分别有 2 048 和 32 个神经元。




图 8 Softmax 分类器结构

Fig. 8 Structure of the Softmax classifier

为增加样本数量,采用重叠采样的方式制作数据集,数据采集的滑动步长为 10,如图 9 所示。实验中的数据集包括训练样本数 $1\ 600 \times 22 = 35\ 200$ 个,测试样本数 $600 \times 22 = 13\ 200$ 个。实验中的自编码网络共设有 7 个隐含层,第一个和最后一个隐含层分别有 2 048 和 32 个神经元。




图 9 数据采样示意图

Fig. 9 Description of data sampling

为对比分析,除采用设计的自编码器网络进行故障诊断实验外,分别采用 4 种常用的故障诊断方法,即 BP 网络、FFT+BP 网络、PCA+BP 网络、WPT+BP 网络进行故障诊断实验。其中,BP 网络方法直接将原始信号输入 BP 网络进行分类;FFT+BP 网络方法先采用 FFT 算法对原始信号进行特征提取,然后输入 BP 网络进行分类;PCA+BP 网络方法先采用 PCA 对原始信号进行降维,然后输入 BP 网络进行分类;WPT+BP 网络方法先采用小波包变换对原始信号进行特征提取,然后输入 BP 网络进行分类。为方便比较,除 BP

网络方法外,其他方法都将从原始信号中提取的 32 维特征数据输入 BP 网络。BP 网络的其他参数分别为:隐含层神经元个数 100,输出层神经元个数 22,学习率 0.02,惯性因子 0.01,激活函数为 Sigmoid,损失函数为均方误差。以上网络均采用表 2 的数据标签进行训练。

图 10~14 为采用电流信号作为输入信号的故障分类结果,图 15~19 为采用电压信号作为输入信号的故障分类结果。为便于比较,全部分类结果的统计见表 3。




图 10 基于电流数据的自编码网络分类结果
Fig. 10 Classification result of autoencoder network based on circuit data




图 11 基于电流数据的 BP 网络分类结果
Fig. 11 Classification result of BP network based on circuit data




图 12 基于电流数据的 FFT+BP 网络分类结果
Fig. 12 Classification result of FFT+BP network based on circuit data

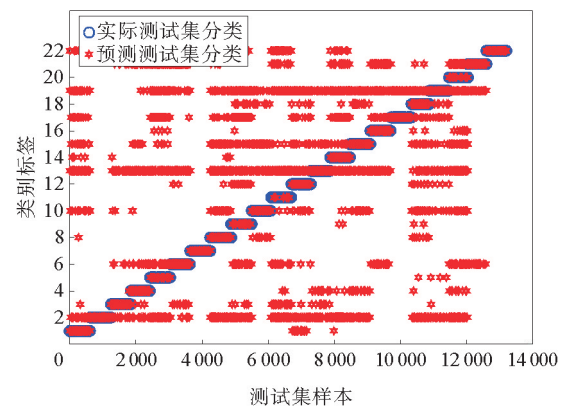


图 13 基于电流数据的 PCA+BP 网络分类结果
Fig. 13 Classification result of PCA+BP network based on circuit data




图 14 基于电流数据的 WPT+BP 网络分类结果
Fig. 14 Classification result of WPT+BP network based on circuit data




图 15 基于电压数据的自编码网络分类结果
Fig. 15 Classification result of autoencoder network based on voltage data




图 16 基于电压数据的 BP 网络分类结果

Fig. 16 Classification result of BP network based on voltage data




图 17 基于电压数据的 FFT+BP 网络分类结果

Fig. 17 Classification result of FFT+BP network based on voltage data




图 18 基于电压数据的 PCA+BP 网络分类结果

Fig. 18 Classification result of PCA+BP network based on voltage data




图 19 基于电压数据的 WPT+BP 网络分类结果

Fig. 19 Classification result of WPT+BP network based on voltage data

表 3 故障诊断准确率

Table 3 Accuracy of fault diagnosis

%

信号形式	自编码网络	BP 网络	FFT+BP 网络	PCA+BP	WPT+BP
电流信号	94.45	69.45	17.47	52.64	95.46
电压信号	98.80	59.47	18.13	30.21	54.99

由表 3 可见,尽管几种方法(FFT+BP、PCA+BP、WPT+BP)是先提取故障特征,然后通过分类器进行分类,但由于提取的故障特征不能准确反映各类故障现象,得到的故障分类结果反而不如直接将原始故障信号输入网络后得到的故障分类准确率高。WPT+BP 的方法尽管在基于电流数据的分类结果中表现优异,但采用电压信号数据则分类准确率骤降,说明该方法仅适合于特定的故障信号形式,不能从故障信号中准确挖掘故障特征信息。相比较而言,基于自编码器网络的方法,无论采用电流信号还是电压信号,都能得到较高的故障分类准确率,主要由于该方法能够从故障信号中自动提取最有效的故障特征,从而能够准确地进行故障分类。因此,基于自编码器网络的故障诊断方法,不仅能得到较高的故障分类正确率,而且相比其他方法具有对输入信号类型不敏感、鲁棒分类能力的特点。

4 结论

研究了基于深度自编码器网络的逆变器开关管开路故障诊断方法,在对逆变器开关管开路故障模型分析和故障编码的基础上,提出一种自编码器网络的规则化设计方法。该方法能够快速确定隐含层神经元的数量和网络深度,有效利用故障数据自动学习开关管的故障特征,实现端到端的智能故障诊断。实验表明,本研究提出的自编码器网络能够利用不同类型的故障数据,自动挖掘故障信号中的关键特征信息得到稳定的故障识别率。与BP网络等传统方法相比,所提方法具有较强的故障识别准确率和分类稳定性。

参考文献:

- [1] YANG S Y, XIANG D W, BRYANT A T, et al. Condition monitoring for device reliability in power electronic converters: A review[J]. *IEEE Transactions on Power Electronics*, 2010, 25(11): 2734-2752.
- [2] 宋保业, 徐继伟, 许琳. 基于小波包变换-主元分析-神经网络算法的多电平逆变器故障诊断[J]. *山东科技大学学报(自然科学版)*, 2019, 38(1): 111-120.
SONG Baoye, XU Jiwei, XU Lin. Multi-level inverter fault diagnosis based on WPT-PCA-NN algorithm[J]. *Journal of Shandong University of Science and Technology(Natural Science)*, 2019, 38(1): 111-120.
- [3] SONG Y T, WANG B S. Survey on reliability of power electronic systems[J]. *IEEE Transactions on Power Electronics*, 2013, 28(1): 591-604.
- [4] 徐继伟, 宋保业, 公茂法. 基于深度神经网络的多电平逆变器故障诊断[J]. *电测与仪表*, 2019, 56(2): 123-128.
XU Jiwei, SONG Baoye, GONG Maofa. Fault diagnosis of multilevel inverter based on deep neural network[J]. *Electrical Measurement & Instrumentation*, 2019, 56(2): 123-128.
- [5] GOU B, XU Y, XIA Y, et al. An online data-driven method for simultaneous diagnosis of IGBT and current sensor fault of three-phase PWM inverter in induction motor drives[J]. *IEEE Transactions on Power Electronics*, 2020, 35(12): 13281-13294.
- [6] GAO Z W, CECATI C, DING S X. A survey of fault diagnosis and fault-tolerant techniques-Part I: Fault diagnosis with model-based and signal-based approaches[J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(6): 3757-3767.
- [7] GAO Z W, CECATI C, DING S X. A survey of fault diagnosis and fault-tolerant techniques-Part II: Fault diagnosis with knowledge-based and hybrid/active approaches[J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(6): 3768-3774.
- [8] WASSINGER N, PENOVI E, RETEGUI R G, et al. Open-circuit fault identification method for interleaved converters based on time-domain analysis of the state observer residual[J]. *IEEE Transactions on Power Electronics*, 2019, 34(4): 3740-3749.
- [9] 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.
- [10] JLASSI I, ESTIMA J O, EL KHIL S K, et al. A robust observer-based method for IGBTs and current sensors fault diagnosis in voltage-source inverters of PMSM drives[J]. *IEEE Transactions on Industry Applications*, 2017, 53(3): 2894-2905.
- [11] NASERI F, SCHALTZ E, LU K. Real-time open-switch fault diagnosis in automotive permanent magnet synchronous motor drives based on Kalman filter[J]. *IET Power Electronics*, 2020, 13(12): 2450-2460.
- [12] GOU B, GE X L, LIU Y C, et al. Load-current-based current sensor fault diagnosis and tolerant control scheme for traction inverters[J]. *IET Electronics Letters*, 2016, 52(20): 1717-1719.
- [13] ZHOU D H, YANG S F, TANG Y. A voltage-based open-circuit fault detection and isolation approach for modular multilevel converters with model-predictive control[J]. *IEEE Transactions on Power Electronics*, 2018, 33(11): 9866-9874.
- [14] MOOSAVI S S, DJERDIR A, AIT-AMIRAT Y, et al. Artificial neural network-based fault diagnosis in the AC-DC converter of the power supply of series hybrid electric vehicle[J]. *IET Electrical Systems in Transportation*, 2016, 6(2): 96-106.
- [15] GAO Y T, WANG W, LIN Q B, et al. Fault diagnosis for power converters based on optimized temporal convolutional network[J/OL]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70. DOI:10.1109/TIM.2020.3021110.

- [16] GOMATHY V, SELVAPERUMAL S. Fault detection and classification with optimization techniques for a three-phase single-inverter circuit[J]. *Journal of Power Electronics*, 2016, 16(3): 1097-1109.
- [17] WANG T, XU H, HAN J G, et al. Cascaded H-bridge multilevel inverter system fault diagnosis using a PCA and multi-class relevance vector machine approach[J]. *IEEE Transactions on Power Electronics*, 2015, 30(12): 7006-7018.
- [18] SHAFIULLAH M, ABIDO M A. S-transform based FFNN approach for distribution grids fault detection and classification[J]. *IEEE Access*, 2018, 6: 8080-8088.
- [19] YE S, JIANG J G, LI J J, et al. Fault diagnosis and tolerance control of five-level nested NPP converter using wavelet packet and LSTM[J]. *IEEE Transactions on Power Electronics*, 2020, 35(2): 1907-1921.
- [20] CAI B P, ZHAO Y B, LIU H L, et al. A data-driven fault diagnosis methodology in three-phase inverters for PMSM drive systems[J]. *IEEE Transactions on Power Electronics*, 2017, 32(7): 5590-5600.
- [21] XIA M, LI T, XU L, et al. Fault diagnosis for rotating machinery using multiple sensors and convolutional neural networks[J]. *IEEE/ASME Transactions on Mechatronics*, 2018, 23(1): 101-110.
- [22] XU G W, LIU M, JIANG Z F, et al. Online fault diagnosis method based on transfer convolutional neural networks[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(2): 509-520.
- [23] 崔江, 唐军祥, 龚春英, 等. 一种基于改进堆栈自动编码器的航空发电机旋转整流器故障特征提取方法[J]. *中国电机工程学报*, 2017, 37(19): 5696-5706.
- CUI Jiang, TANG Junxiang, GONG Chunying, et al. A fault feature extraction method of aerospace generator rotating rectifier based on improved stacked auto-encoder[J]. *Proceedings of the CSEE*, 2017, 37(19): 5696-5706.
- [24] CHEN Z Q, LI C Q, SANCHEZ R V. Gearbox fault identification and classification with convolutional neural networks[J/OL]. *Shock and Vibration*, 2015(1). DOI:10.1155/2015/390134.
- [25] KIRANYAZ S, GASTLI A, BEN-BRAHIM L, et al. Real-time fault detection and identification for MMC using 1-D convolutional neural networks[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(11): 5299-5308.
- [26] WEN L, GAO L, LI X Y, et al. A jointed signal analysis and convolutional neural network method for fault diagnosis[J]. *Procedia CIRP*, 2018, 72: 1084-1087.
- [27] LIU W B, WANG Z D, LIU X H, et al. A survey of deep neural network architectures and their applications[J]. *Neurocomputing*, 2017, 234: 11-26.
- [28] XU L, CAO M Y, SONG B Y, et al. Open-circuit fault diagnosis of power rectifier using sparse autoencoder based deep neural network[J]. *Neurocomputing*, 2018, 311: 1-10.

(责任编辑: 齐敏华)