

DOI: 10.19783/j.cnki.pspc.250426

## 对称点模式与 ECA-ConvNeXt 结合的并网逆变器故障诊断

韩素敏<sup>1,2</sup>, 张树志<sup>1,2</sup>, 吕文龙<sup>1,2</sup>, 贾焦心<sup>3</sup>

(1. 河南理工大学电气工程与自动化学院, 河南 焦作 454003; 2. 河南省煤矿装备智能检测与控制重点实验室, 河南 焦作 454003; 3. 河北省分布式储能与微网重点实验室(华北电力大学), 河北 保定 071003)

**摘要:** 为解决并网中性点钳位型逆变器同桥臂双管和内侧单管开路故障诊断困难, 以及过多检测信号引起的计算资源消耗和诊断时间增加的问题, 提出对称点模式与改进增强卷积神经网络(efficient channel attention-ConvNeXt, ECA-ConvNeXt)结合的故障诊断模型。首先, 定义三相“上下桥臂中点间电压”区分同桥臂双管和内侧单管开路故障, 并结合 A 相电流对其他故障类型进行诊断。然后, 利用对称点模式将 4 种信号融合为一张“雪花图”, 丰富数据特征的同时降低计算量。最后, 引入双尺寸卷积核和高效跨通道注意力机制提升 ECA-ConvNeXt 模型特征捕获与泛化能力, 同时优化激活函数和残差模块堆叠次数, 以兼顾故障诊断精度与速度。实验表明, 其对包含同桥臂双管和内侧单管开路故障在内的 79 种单、双开关管开路故障的诊断精度达 99.53%, 平均测试时间为 8.82 ms, 实现了故障诊断精度与速度的平衡。

**关键词:** 三电平逆变器; 故障诊断; 对称点模式; 卷积神经网络; 通道注意力

### Fault diagnosis of grid-connected inverters based on symmetric-point pattern and ECA-ConvNeXt

HAN Sumin<sup>1,2</sup>, ZHANG Shuzhi<sup>1,2</sup>, LÜ Wenlong<sup>1,2</sup>, JIA Jiaoxin<sup>3</sup>

(1. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China; 2. Henan Key Laboratory of Intelligent Detection and Control of Coal Mine Equipment, Jiaozuo 454003, China; 3. Hebei Province Key Laboratory of Distributed Energy Storage and Microgrid (North China Electric Power University), Baoding 071003, China)

**Abstract:** To solve the difficulty in diagnosing open-circuit faults in same-arm double-switch and inner single-switch in grid-connected neutral point clamped inverters, as well as the increased computational load and diagnosis time caused by excessive detection signals, a fault diagnosis model combining symmetric-point pattern and enhanced convolutional neural network (ECA-ConvNeXt) is proposed. First, the three-phase “midpoint voltages between upper and lower bridge arms” are defined to distinguish same-arm dual-switch faults from inner single-switch open-circuit faults, while A-phase current is used to diagnose other fault types. Then, four types of signals are fused into a single “snowflake diagram” using the symmetric-point pattern, enriching data features while reducing computational complexity. Finally, dual-size convolution kernels and an efficient cross-channel attention mechanism are introduced to improve the feature acquisition and generalization ability of the ECA-ConvNeXt model. At the same time, the activation function and residual module stacking are optimized to balance diagnosis accuracy and speed. Experiments show that the proposed method achieves a diagnosis accuracy of 99.53% for 79 types of single- and double-switch open-circuit faults, including same-arm double-switch and inner single-switch faults, with an average test time of 8.82 ms, effectively balancing accuracy and speed.

This work is supported by the National Natural Science Foundation of China (No. 52207102).

**Key words:** three-level inverter; fault diagnosis; symmetric-point pattern; convolutional neural network; channel attention

**基金项目:** 国家自然科学基金项目资助(52207102); 河南省科技攻关项目资助(252102241061); 河南省研究生教育改革与质量提升工程项目资助(YJS2025AL30)

## 0 引言

三电平中点钳位型(neutral point clamped, NPC)并网逆变器因开关损耗均匀、谐波畸变率低和输出波形失真小等优点,在光伏并网系统中广泛应用<sup>[1-2]</sup>。但高频开关操作与运行环境多变的双重影响使得NPC并网逆变器故障频发,其中开关管故障问题尤为突出<sup>[3-5]</sup>。NPC并网逆变器开关管的故障可分为短路故障和开路故障<sup>[6]</sup>。短路故障因其演变速度快且危害程度大的特点,系统中通常有硬件检测装置和保护电路,以便及时将其转化为开路故障<sup>[7]</sup>。若不及时处理,将导致NPC并网逆变器性能大幅降低,甚至引起光伏并网系统发生严重安全事故<sup>[8]</sup>。因此,快速准确地诊断出NPC并网逆变器开关管开路故障,对于保障光伏并网系统稳定运行具有重要意义。

目前,对NPC并网逆变器开关管开路故障的诊断方法主要分为解析模型、信号分析和数据驱动3类<sup>[9]</sup>。解析模型法通过建立数学模型,利用实际系统与参考模型输出的残差进行故障诊断<sup>[10-12]</sup>,包括自适应滑模观测器<sup>[13]</sup>、卡尔曼滤波<sup>[14]</sup>、扩展状态观测器<sup>[15]</sup>等。解析模型法因快速、实时和计算成本低等优点得到广泛应用,但建立精确模型较困难,且设备参数变化时需重新调整。信号分析法利用逆变器故障时电压或电流的特征进行故障检测和定位,主要包括电流矢量法<sup>[16]</sup>、归一化电流法<sup>[17]</sup>和电压分析法<sup>[18]</sup>等。此类方法无需建立模型,但在诊断的故障模式上受限制,且移植性较差。

当前,光伏发电系统在动态运行过程中受光照强度、天气条件、季节变化以及地理位置等复杂环境因素影响,具有高度的不确定性和随机性,增加了系统运行的复杂性和不可预测性。基于数据驱动的方法无需依赖复杂的数学模型,且移植性强,十分适合此类场景下的逆变器开关管开路故障诊断。文献[19]利用遗传算法优化反向传播神经网络,以逆变器电桥电压作为故障检测信号,实现了NPC逆变器单开关管开路故障的诊断。文献[20]将A相电流作为一维卷积神经网络的输入,实现了NPC逆变器单、双开关管开路故障的诊断。文献[21]在一维卷积神经网络中引入了深度可分离卷积和全局最大池化,进一步提升了NPC逆变器单、双开关管开路故障诊断的准确性。然而,在这些研究中未涉及同桥臂双管和内侧单管这类故障的区分。为解决这一问题,现有研究尝试采用多个信号进行诊断。文献[22]定义了上、中、下桥臂电压实现这类故障的准确区分,但需加装9个电压传感器。文献[23]采用

上、下桥臂电压和输出电流信号对这类故障进行诊断,但需加装6个电压传感器。然而,这些方法均未对多源信号进行融合处理,而是直接将多个信号输入神经网络模型中,导致模型过于复杂,进而降低了诊断速度。

为了解决上述问题,本文提出一种基于对称点模式(symmetric dot pattern, SDP)和改进增强卷积神经网络(efficient channel attention-ConvNeXt, ECA-ConvNeXt)。利用SDP算法将三相“上下桥臂中点间电压”和A相输出电流4个故障检测信号映射到极坐标下的不同扇区,并转化为一张二维“雪花图”,从而在丰富特征信息的同时降低数据量。在ConvNeXt T模型的基础上引入双尺寸卷积核结构和高效通道注意力(efficient channel attention, ECA)机制,增强模型在通道维度上的适应性,提升对“雪花图”特征信息的捕获和处理能力。同时,通过调整卷积核尺寸、激活函数类型和残差模块堆叠次数,降低模型复杂度,寻求故障诊断精度与速度之间的平衡。将SDP算法与ECA-ConvNeXt模型相结合,充分发挥SDP在特征提取上的优势以及ECA-ConvNeXt模型在特征处理和分类上的优势,实现了故障诊断精度与效率的双重提升。

## 1 故障检测信号的选择

鉴于实际应用中3个开关管同时故障的概率较小,本文主要研究NPC逆变器正常、单管和双管开路故障共79种情况<sup>[24]</sup>。基于图1的主电路拓扑结构,分析故障波形并选择故障检测信号。

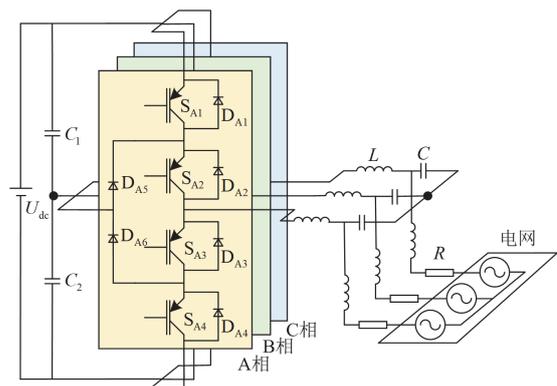


图1 并网NPC逆变器拓扑结构

Fig. 1 Topology of grid-connected NPC inverter

由于 $S_{A2}$ 和 $S_{A1}S_{A2}$ 、 $S_{A3}$ 和 $S_{A3}S_{A4}$ 故障时的拓扑结构相同,导致输出电流 $I_A$ 、 $I_B$ 、 $I_C$ 和线电压 $U_{AB}$ 波形几乎一样,如图2所示。同理 $S_{B2}$ 和 $S_{B1}S_{B2}$ 、 $S_{B3}$ 和 $S_{B3}S_{B4}$ 、 $S_{C2}$ 和 $S_{C1}S_{C2}$ 、 $S_{C3}$ 和 $S_{C3}S_{C4}$ 的故障波形也无法区分。因此使用电流和线电压作为故障诊断信

号无法区分同桥臂双管和内侧单管故障。

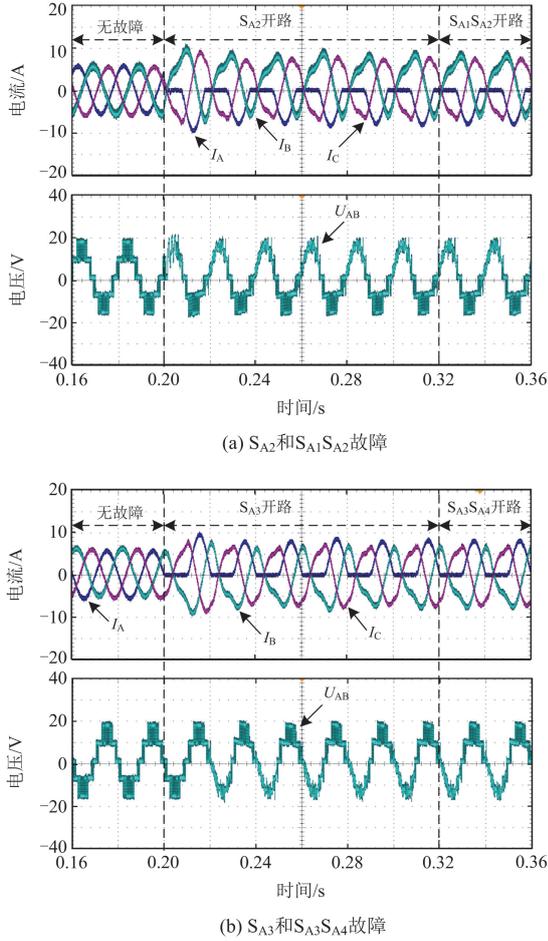


图 2 开路故障波形

Fig. 2 Waveforms for open-circuit faults

为此, 引入“上下桥臂中点间电压”即上桥臂中点 M 和下桥臂中点 N 之间的电压, 记为  $U_{AMN}$  (其中  $X = A, B, C$ ), 来区分这一类故障。由于系统的对称性, 为简化分析过程, 故只针对 A 相进行分析。如图 3 所示, A 相的“上下桥臂中点间电压”记为  $U_{AMN}$ 。

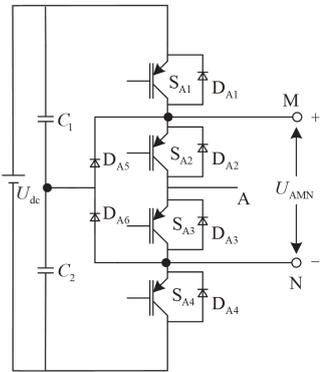


图 3 A 相“上下桥臂中点间电压”

Fig. 3 A phase “upper-and-lower bridge arm midpoint voltage”

$U_{AMN}$  波形如图 4 所示, 通过观察图 4(a)和图 4(b), 可以清晰分辨  $S_{A2}$  和  $S_{A1}S_{A2}$ 、 $S_{A3}$  和  $S_{A3}S_{A4}$  故障的波形。同理,  $U_{BMN}$  和  $U_{CMN}$  可用于区分 B、C 相的同桥臂双管和内侧单管故障。基于此, 在  $U_{AMN}$  的基础上, 以 A 相输出电流  $I_A$  作为故障诊断信号, 能够有效区分 NPC 逆变器的 79 种单双管故障类型, 具体故障类型及其标签如附录 A 表 A1 所示。

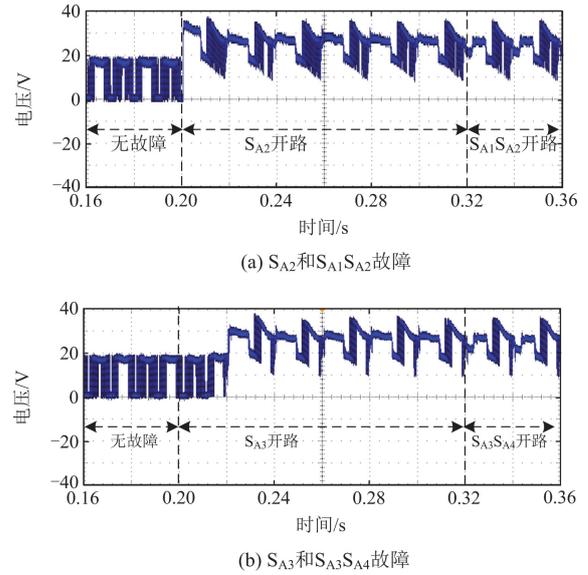


图 4  $U_{AMN}$  波形

Fig. 4 Waveforms for  $U_{AMN}$

## 2 故障诊断方法

### 2.1 基于 SDP 的信息融合

信息融合通过综合多源信号可更准确地分析目标状态<sup>[25]</sup>。SDP 算法将多源信号映射到极坐标特定扇区并转化为二维“雪花图”, 从而整合多个信号, 减少数据量, 为故障诊断提供丰富特征信息, 其原理如式(1)所示。

$$\begin{cases} r(i) = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \\ \theta(i) = \theta_k + \frac{x_{i+t} - x_{\min}}{x_{\max} - x_{\min}} \xi \\ \phi(i) = \theta_k - \frac{x_{i+t} - x_{\min}}{x_{\max} - x_{\min}} \xi \\ \theta_m = \frac{360^\circ}{n} \times m \end{cases} \quad (1)$$

式中:  $x_i$  为第  $i$  个采样点的值;  $x_{i+t}$  为第  $i+t$  个采样点的值, 其中  $t$  为时间偏移量;  $x_{\min}$  为时域信号最小值;  $x_{\max}$  为时域信号最大值;  $\theta_m$  为每个通道对应的对称轴角度;  $m$  为通道索引,  $m = 0, 1, \dots, n-1$ ;  $n$

为通道个数;  $r(i)$  为第  $i$  个数据点在极坐标系中的半径;  $\theta(i)$ 、 $\phi(i)$  分别为极坐标中沿  $\theta_m$  对称平面的顺时针和逆时针旋转角度;  $\xi$  为增益角度。

图 5 为  $S_{A2}$  和  $S_{A1}S_{A2}$ 、 $S_{A3}$  和  $S_{A3}S_{A4}$  开路故障下的“雪花图”。可以看出, 采用  $I_A$  和  $U_{AMN}$  作为故障诊断信号, 并通过 SDP 算法处理后, 可以通过各扇区数据点分布变化, 清楚直观地区分这 4 种故障类型。

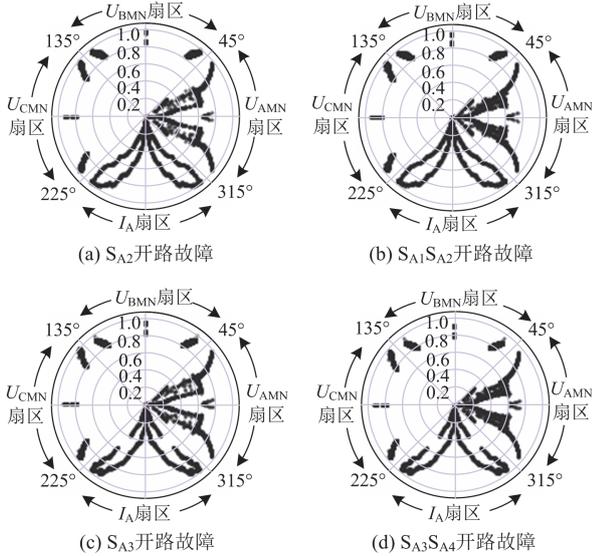


图 5 经 SDP 处理后的“雪花图”

Fig. 5 The “snowflake diagram” processed by SDP

## 2.2 ECA-ConvNeXt 故障诊断模型

### 2.2.1 ECA 机制和 ConvNeXt T 模型

1) ECA 机制: ECA 机制通过局部跨通道交互, 加强网络整体的通道特征。如图 6 所示,  $w$  为特征图的宽,  $h$  为特征图的高,  $c$  为通道数, 将  $w \times h \times c$  大小的特征信息经全局平均池化得到  $1 \times 1 \times c$  的特征向量。然后对特征向量进行一维卷积操作, 提取通道特征和通道间的相关性。再经过 Sigmoid 激活函数后得到各通道的权重。

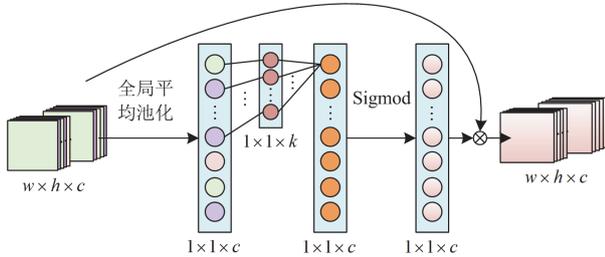


图 6 ECA 机制结构

Fig. 6 ECA mechanism structure

在图 6 中,  $k$  为卷积核的大小, 反映了局部跨通道交互覆盖率。 $k$  值与通道数成正比, 并由式(2)

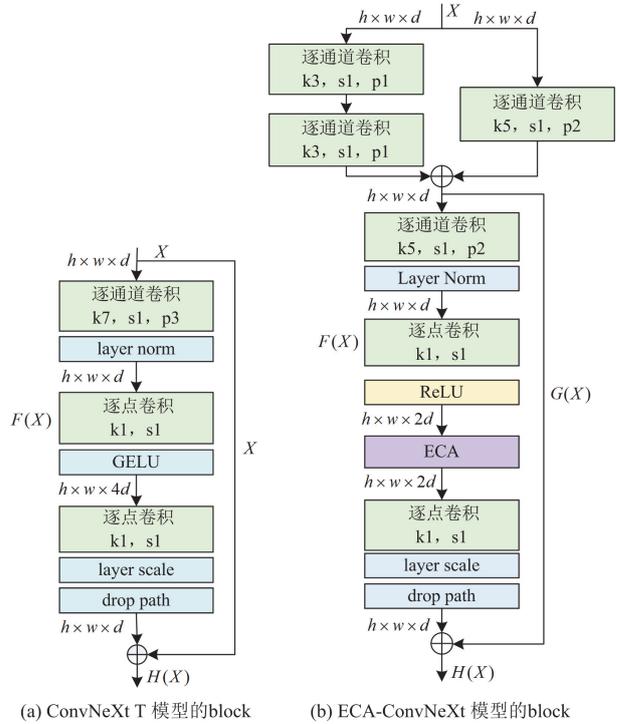
自适应确定。

$$c = \phi(k) = 2^{(\gamma k - b)} \quad (2)$$

$$k = \left\lfloor \frac{\log_2(c)}{\gamma} + \frac{b}{\gamma} \right\rfloor \text{ odd} \quad (3)$$

式中: odd 表示  $k$  只能取奇数;  $\gamma$ 、 $b$  表示用于调整  $c$  和  $k$  的比例关系。

2) ConvNeXt T 模型结构: ConvNeXt T 模型融合了 Swin Transformer 结构与卷积神经网络。该模型输入为  $224 \times 224 \times 3$  的 RGB 图像, 经过卷积核大小为 4、步长为 4 的卷积层处理后, 通过层归一化 (layer norm) 得到  $56 \times 56 \times 96$  的数据。接着进行 4 个阶段的深度卷积处理, 通道数分别为 96、192、384、768, 各阶段堆叠残差模块 (block) 的数量分别为 (3、3、9、3), block 结构如图 7(a) 所示。



(a) ConvNeXt T 模型的 block

(b) ECA-ConvNeXt 模型的 block

图 7 对 ConvNeXt T 模型 block 结构的改进

Fig. 7 Improvement of the block structure of ConvNeXt T

在该模型的 block 中, 首先使用  $7 \times 7$  逐通道卷积提取特征, 再经层归一化优化特征表达。为提高网络的非线性拟合能力, 在残差模块中的第一个逐点卷积后使用 GELU 激活函数。

$$\text{GELU}(X) = xP(X \leq x) = x\varphi(x) \quad (4)$$

式中:  $x$  为实数取值;  $X$  为服从高斯分布的随机变量;  $\varphi(x)$  为  $x$  的高斯正态分布的累积分布, 表示为

$$P(X \leq x) = \varphi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx \quad (5)$$

最后使用随机丢弃层(Drop Path)将网络中多分支结构的子路径随即删除, 防止过拟合以及网络退化问题。

### 2.2.2 ECA-ConvNeXt 模型设计

在基于神经网络的故障诊断领域, 提升诊断方法的适用性与准确性同等关键<sup>[26]</sup>。为保障诊断的时效性, 需要在有限的计算资源前提下确保快速响应。因此, 本文引入双尺寸卷积核和 ECA 注意力机制, 增强 ConvNeXt T 模型的特征获取与处理能力, 提升精度与泛化能力。同时, 通过调整 ConvNeXt T 各阶段中 block 的堆叠次数和通道扩张比例, 降低网络复杂度, 缩短诊断时间, 平衡故障诊断的精度与速度。改进后的 ECA-ConvNeXt 模型的 block 结构如图 7(b)所示。

改进后的 block 在原 block 起始位置引入双尺寸卷积核结构: 第一路为两层连续的  $3 \times 3$  逐通道卷积, 第二路为一层  $5 \times 5$  逐通道卷积。这种设计使 ECA-ConvNeXt 能够提取不同尺寸下的特征信息, 提高特征利用率。将原 block 中  $7 \times 7$  逐通道卷积缩小为  $5 \times 5$  逐通道卷积, 在保证整体感受野大小为  $7 \times 7$  的前提下, 降低网络复杂度。原 block 中的 GELU 激活函数虽然能自适应调整激活值, 增强模型对复杂特征的捕捉能力, 但计算复杂度较高。因此, 改用 ReLU 激活函数, 表示为

$$f(x) = \max(0, x) \quad (6)$$

ReLU 仅涉及简单的阈值操作, 计算更加简单快速。在 ReLU 激活函数之后, 添加 ECA 机制以提取和强调各通道的重要特征信息, 避免通道压缩时重要特征信息的丢失。为了平衡 ECA-ConvNeXt 模型在故障诊断时的精度和速度, 将 4 个阶段中 block 的堆叠数量改为 1、1、3、1, 并将通道扩张比例由 4 降为 2。

### 2.3 故障诊断流程

基于上述分析, 本文的故障诊断方法基本流程主要分为 3 步, 如附录 A 图 A1 所示。

第一步, 采集故障信号。采集  $U_{AMN}$ 、 $U_{BMN}$  和  $U_{CMN}$  信号。

第二步, 基于 SDP 的信息融合。将采集的 4 种信号通过 SDP 算法映射到极坐标的不同扇区, 可以反映不同故障模式下各种信号的关系, 为故障诊断提供了额外特征。

第三步, 基于 ECA-ConvNeXt 的故障诊断。将 SDP 图像输入到改进后的 ECA-ConvNeXt 模型中进行特征提取, 最终按照附录 A 表 A1 输出故障标签。

## 3 实验验证

本节通过搭建实验平台收集数据, 对逆变器不同故障模式进行诊断分析。实验平台由控制器、驱动电路、三相逆变电路和采样电路组成, 如图 8 所示。

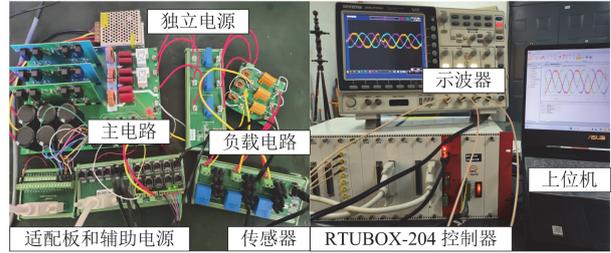


图 8 实验平台

Fig. 8 Experimental platform

RTUBOX-204 控制器配备了 TMS320C28346 处理器, 并与 MATLAB/Simulink 集成。高精度电流采样模块 RTS-CUR-253 的响应时间小于  $0.5 \mu\text{s}$ , 标准精度为  $\pm 0.3\%$ , 带宽为 200 kHz, 从而最大限度地减少了噪声干扰。

神经网络运行在配备 8 G 显存的 NVIDIA RTX 4060ti 显卡和 16 G 运行内存的英特尔 i5-12490k 处理器上。在 PyCharm 平台上使用 PyTorch 搭建 ECA-ConvNeXt 模型框架。训练模型时, 训练输入批次大小为 42; 训练轮数为 50 轮; 初始学习率设置为  $3 \times 10^{-4}$ ; 学习率衰减  $1 \times 10^{-5}$ ; 随机丢弃率为 0.04。采样时设置电流周期为 0.02 s, 采样频率为  $10^5 \text{ Hz}$ , 采样时间为 4 s, 每种故障模式下采集对应的电压和电流信号  $4 \times 10^5$  个点, 选取每 2000 个点作为一个原始样本。每种故障模式有 200 张  $128 \times 128 \times 1$  的“雪花图”样本, 按照 7:1:2 的比例划分训练集、验证集和测试集。

### 3.1 故障检测信号可行性验证

为验证  $I_A$  和  $U_{AMN}$  作为故障检测信号的有效性, 进行以下的对比测试。a 组采用  $I_A$  和  $U_{AMN}$ ; b 组采用  $I_A$  和三相线电压; c 组仅采用  $I_A$ 。

按照 a、b、c 三种组合, 对 79 种故障类型的检测信号进行采集。这些信号经过 SDP 处理后生成样本, 随后使用 ECA-ConvNeXt 模型进行训练和测试。图 9 为 3 种故障检测信号的组成方式在训练过程中的精度。

图 9 中, 采用 a 组的故障检测信号进行训练时精度达到了 100%, 采用 b 组的故障检测信号进行训练时精度为 90.57%, 采用 c 组的故障检测信号进行训练时精度为 89.05%。

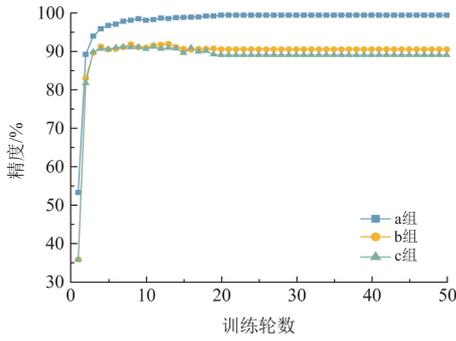


图 9 不同故障检测信号的训练精度

Fig. 9 Training accuracy of different fault detection signals

针对 12 种同桥臂双管和内侧单管进行诊断, 诊断结果如图 10 所示。对图 10 中的 3 组诊断结果进行分析, 发现对于上述的 11 种易混淆故障, a 组的诊断精度为 100%; b 组的诊断精度为 50.83%; c 组的诊断精度为 48.75%。

图 11 利用 t-SNE(t-distributed Stochastic Neighbor Embedding)算法对 a、b、c 3 组测试集进行特征可视化处理。从图 11 中可以观察到, 相较于 b 组和 c 组, a 组的测试集经过 ECA-ConvNeXt 模型处理后同类故障特征聚集更为紧密, 且边缘明显。

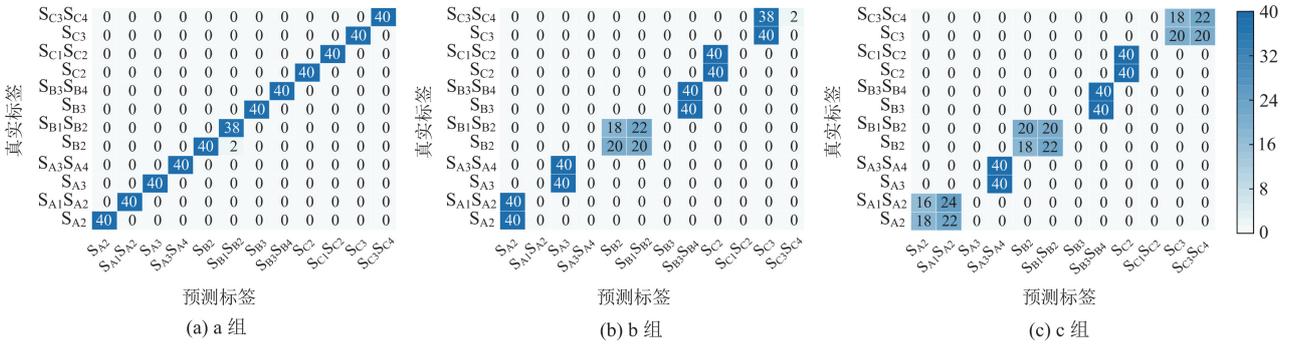


图 10 不同故障检测信号的诊断结果

Fig. 10 Diagnosis results of different fault detection signals

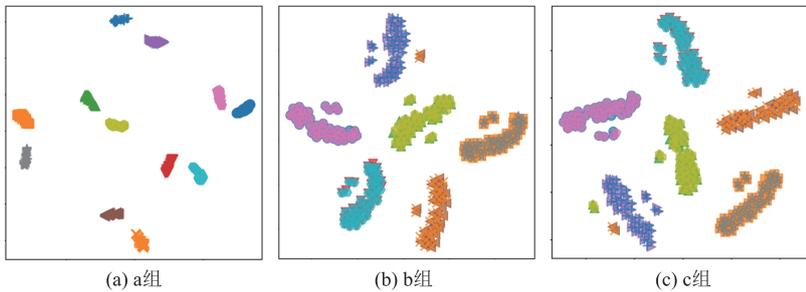


图 11 不同故障检测信号的特征可视化

Fig. 11 Feature visualization of different fault detection signals

结果表明, 采用  $I_A$  和  $U_{XMN}$  的信号组合在诊断精度上显著优于其他组合, 能够为故障诊断提供更丰富的特征信息, 从而有效区分同桥臂双管和内侧单管故障。

### 3.2 数据处理方式比较

本节对比了故障检测信号经 SDP 处理后输入故障诊断模型与直接输入故障诊断模型的效果。为了数据结构的一致性, 将  $I_A$  和  $U_{XMN}$  重构为  $96 \times 96$  的矩阵后输入模型。图 12 为这两种数据处理方式下数据集原始特征的 t-SNE 可视化结果。

通过图 12 可发现, 采用直接重构矩阵的处理方式时, 多种故障类型的特征混合在一起十分混乱, 而

经过 SDP 处理后特征的混乱程度明显下降。随后, 通过 ECA-ConvNeXt 模型和 ConvNeXt 模型对这两种数据处理方式进行训练和测试, 结果如表 1 所示。

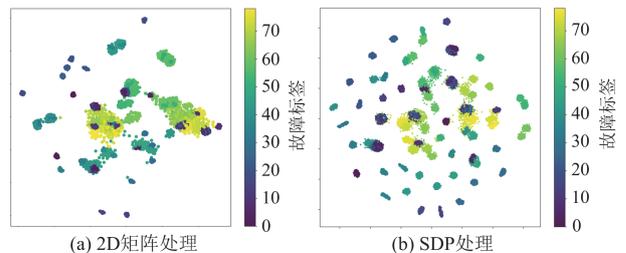


图 12 不同数据处理方式的特征可视化

Fig. 12 Feature visualization of different data processing methods

表 1 不同数据处理方式的测试结果

模型	参数/M	FLOPs/M	时间		精度/%
			训练/s	测试/ms	
SDP + ECA-ConvNeXt	6.10	301.1	10.89	8.82	99.53
SDP + ConvNeXt T	27.86	1452.0	21.67	11.10	95.72
2D + ECA-ConvNeXt	6.10	169.39	6.05	5.47	94.24
2D+ ConvNeXt T	27.86	816.52	7.74	5.87	91.14

由表 1 可知, 相较于直接使用 2D 矩阵, 经 SDP 处理的数据在 ECA-ConvNeXt 模型与 ConvNeXt T 模型上的测试精度分别提升 5.29% 和 4.58%。通过上述对比, 证明 SDP 处理能够挖掘出不同故障类型的特征信息, 为神经网络提供了更加丰富的特征信息, 有助于神经网络准确诊断故障。

### 3.3 ECA-ConvNeXt 模型的消融实验

本节在同样的 SDP 数据集上进行消融实验, 以验证各个改进操作的可行性和有效性, ECA-ConvNeXt 模型的消融实验结果如表 2 所示。

实验中每次加入新的改进操作, 先对模型进行虚拟输入测试得到参数、浮点运算次数 (floating-point operations, FLOPs) 和推理时间的数据。随后进行 50 轮训练, 当模型训练完成后, 使用训练得到的模型权重在测试集上进行测试。

表 2 ECA-ConvNeXt 模型的消融实验结果

模型	参数/M	FLOPs/M	推理时间/ms	精度/%
原模型	27.88	1452.00	8.998	95.72
原模型+双尺寸卷积核	28.02	1465.00	10.732	97.52
原模型 + 双尺寸卷积核 + 堆叠数量修改	10.41	527.12	4.823	96.23
原模型 + 双尺寸卷积核 + 堆叠数量修改 + ECA	10.42	528.06	6.864	99.56
原模型 + 双尺寸卷积核 + 堆叠数量修改 + ECA + ReLU	10.42	528.05	6.136	99.56
原模型 + 双尺寸卷积核 + 堆叠数量修改 + ECA + ReLU + 2 倍通道扩张	6.10	301.10	5.617	99.53

综上所述, ECA-ConvNeXt 模型在改进过程中, 通过引入双尺寸卷积核、调整 block 堆叠数量、加入 ECA 注意力机制、替换激活函数以及调整通道扩张比例等操作, 提升模型的精度, 且在一定程度上降低了模型的参数量、计算复杂度和推理时间, 充分证明了这些改进措施的有效性和可行性。

### 3.4 ECA-ConvNeXt 的训练、测试及对比

ECA-ConvNeXt 的训练结果如图 13 所示, 随着训练轮数的增加, 训练精度达到 100%, 训练损失降低到 0.0018, 验证精度达到 99.62%, 验证损失降低到 0.0282。经过 50 轮训练得到一个训练效果良好

的 ECA-ConvNeXt 模型。

从表 2 可知, 改进前的原 ConvNeXt T 模型在参数、FLOPs、推理时间和精度上的效果并不理想, 当原模型中引入双尺寸卷积核后, 模型精度提升 1.8%, 但推理时间也增加了 1.734 ms。这表明双尺寸卷积核虽然能够有效提升模型精度, 但也增加了模型的复杂度, 导致推理时间变长。对模型 block 堆叠数量进行修改后, 模型精度虽下降了 1.29%, 但参数量减少了 17.61 M, FLOPs 降低了 937.88 M, 推理时间减少了 5.943 ms。这说明, 通过调整 block 堆叠数量, 可以在略微降低模型精度的前提下, 大幅降低模型的参数量、FLOPs 和推理时间, 从而在一定程度上优化模型的计算效率和运行速度。当加入 ECA 注意力机制后, 模型精度提升了 3.33%, 但推理时间增加了 2.041 ms。这表明, ECA 注意力机制能够显著提高模型的精度, 但会增加模型的计算负担, 进而导致推理时间增加。将 GELU 函数替换为 ReLU 函数后, 模型的推理时间进一步减少, 降低了 0.728 ms。这说明, ReLU 函数在该模型中具有更高的计算效率, 能够在基本维持模型性能的前提下, 进一步加快推理速度。将模型通道扩张比例降低到 2 倍后, 模型的精度仅下降了 0.03%, 但参数量减少了 4.32 M, FLOPs 降低了 226.95 M, 推理时间减少了 0.519 ms。这表明, 降低通道扩张比例可以在几乎不影响模型精度的情况下, 有效减小模型的参数量和计算复杂度, 进一步优化模型的性能。

的 ECA-ConvNeXt 模型。

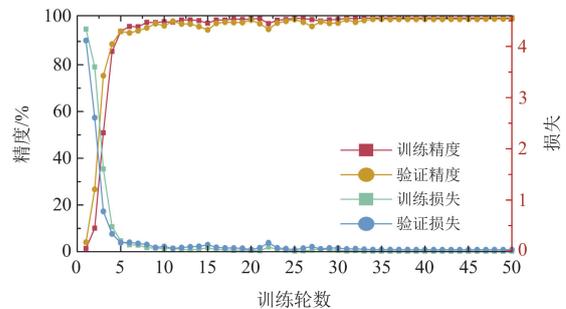


图 13 训练精度与训练损失

Fig. 13 Training accuracy and loss

图 14 为随机抽取的 20 种故障类型的混淆矩阵,可以看出除故障标签“34”的诊断精度为 95%外,其余 19 种故障类型的诊断精度均为 100%。

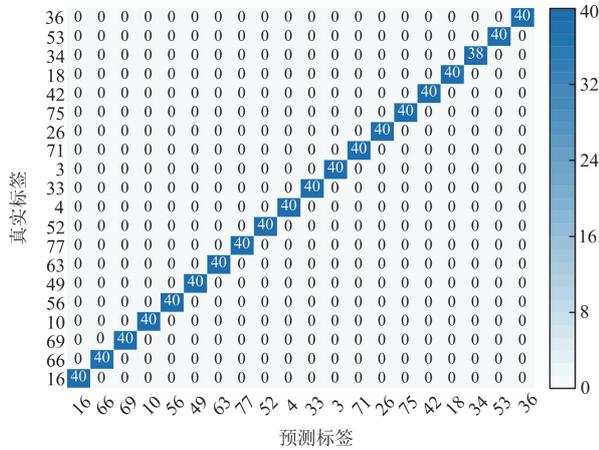


图 14 20 种随机故障类型诊断结果的混淆矩阵  
Fig. 14 Confusion matrix for diagnosis results of 20 random fault types

表 3 为不同模型的训练和测试结果对比。ECA-ConvNeXt 模型与 ConvNeXt T 模型相比,参数降低了 21.76 M, FLOPs 下降了 79.26%; 与 ResNet 34 和视觉几何组 16(visual geometry group, VGG16)相比,参数分别降低 15.69 M 和 128.48 M,在 FLOPs 上分别下降了 74.40%和 94.11%。ECA-ConvNeXt 一轮的训练时间仅为 10.89 s,测试时间为 8.82 ms,与 ConvNeXt T、ResNet 34 和 VGG 16 相比,其测试集的精度分别高出 3.81%、2.27%和 14.12%。与 ConvNeXt T 和 ResNet 34 相比, ECA-ConvNeXt 的平均测试时间分别降低 2.28 ms 和 2.49 ms。在 ECA-ConvNeXt 模型与轻量级神经网络 MobileNet V1 的对比中,虽然相比 MobileNet V1 模型, ECA-ConvNeXt 模型的参数增加了 2.81 M、FLOPs 增加 194.4 M、训练时间和测试时间分别增加了 6.64 s 和 4.33 ms,但 ECA-ConvNeXt 模型的测试精度比 MobileNet V1 模型高出 20.99%。

表 3 不同模型训练及测试结果

Table 3 Training and testing results of different models

模型	参数/M	FLOPs/M	时间		精度/%
			训练/s	测试/ms	
SDP+ ECA-ConvNeXt	6.10	301.1	10.89	8.82	99.53
SDP+ ConvNeXt T	27.86	1452.0	21.67	11.10	95.72
SDP+ ResNet 34	21.79	1176	11.89	11.31	97.26
SDP+ VGG 16	134.58	5112.0	28.53	7.86	85.41
SDP+ MobileNet V1	3.29	106.7	4.25	4.49	78.54

上述分析表明 ECA-ConvNeXt 模型更加简洁,在计算资源受限的条件下也能部署,而且 ECA-ConvNeXt 在保证故障诊断精度的同时能够兼顾诊断速度,达到有效的平衡。图 15 为测试集输入不同模型输出特征的 t-SNE 可视化图像。

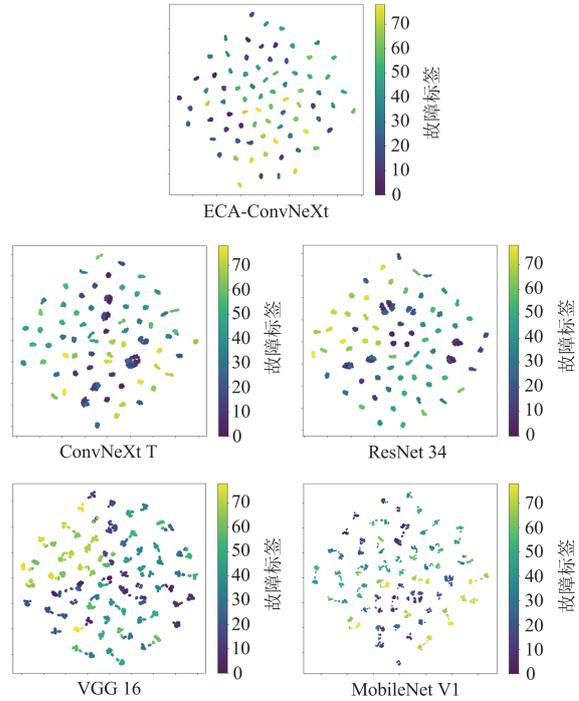


图 15 不同模型输出特征的可视化图像

Fig. 15 Visualization image of different model output feature

从图 15 可以看出,测试集经过 ECA-ConvNeXt 模型提取特征后,79 种故障类型的特征集中,边界清晰,没有出现不同特征混杂的情况。相比之下,ConvNeXt T 模型、ResNet 34 模型、VGG 16 模型和 MobileNet V1 模型提取的特征仍存在不同程度的类别混杂,79 种故障类型的特征没有完全地区分开。这表明 ECA-ConvNeXt 模型在故障特征提取上具有更加优异的性能。

### 3.5 鲁棒性测试

#### 3.5.1 噪声测试

实际应用中,信号采集和传输易受噪声干扰,故障诊断方法需在噪声条件下仍能准确诊断故障。为了验证基于 SDP 和 ECA-ConvNeXt 的故障诊断方法对噪声的鲁棒性,采用添加 20 dB 信噪比(signal-to-noise ratio, SNR)的高斯白噪声数据训练神经网络。并使用 SNR 为 20 dB、25 dB、30 dB、35 dB 和 40 dB 的数据进行测试<sup>[27]</sup>。表 4 给出了不同信噪比下不同神经网络模型的测试结果。

表 4 结果表明,在不同信噪比条件下, ECA-

ConvNeXt 模型的精度普遍优于 ConvNeXt T 模型、ResNet 34 模型、VGG 16 模型和 MobileNet V1 模型。结合 SDP 和 ECA-ConvNeXt 的模型在 20 dB、25 dB、30 dB、35 dB 和 40 dB 条件下的平均精度始终在 95% 以上。结合 SDP 和 ECA-ConvNeXt 的模型在 20 dB 条件下的精度比 25 dB 时下降了 1.40%，25 dB 相比 30 dB 精度下降 0.88%，30 dB 相比 35 dB 精度下降 1.08%，35 dB 相比 40 dB 精度下降 0.37%，这些结果表明基于 SDP 和 ECA-ConvNeXt 的故障诊断模型对噪声有一定的抵抗能力。

表 4 噪声干扰下不同模型的测试结果

Table 4 Test results of different models under noise interference

模型	精度/%				
	40 dB	35 dB	30 dB	25 dB	20 dB
SDP + ECA-ConvNeXt	98.98	98.61	97.53	96.65	95.25
SDP + ConvNeXt T	94.14	93.86	93.04	92.47	91.08
SDP + ResNet 34	96.20	95.92	95.51	93.86	92.24
SDP + VGG 16	83.54	82.12	81.01	78.48	74.53
SDP + MobileNet V1	74.96	73.04	72.90	69.46	64.59
2D + ECA-ConvNeXt	93.67	93.42	93.10	92.41	90.01
2D + ConvNeXt T	92.45	91.14	89.87	87.34	85.09

### 3.5.2 并网电压波动测试

实际并网运行中，光伏发电间歇性输出以及电网自身稳定性，可能会导致电网电压发生波动，进而影响逆变器的输出特性和故障诊断的准确性。因此，验证故障诊断模型在电压波动条件下的性能，是确保逆变器在实际电网中可靠运行的必要环节。

为评估所提基于 SDP 和 ECA-ConvNeXt 故障诊断模型在电压波动条件下的鲁棒性和泛化能力，本文的电压波动测试涵盖了  $\pm 2\%$ 、 $\pm 3\%$  和  $\pm 4\%$  的电压波动范围，以模拟实际电网中可能出现的不同电压变化情况。测试数据分为训练集和测试集，训练集使用其中一种电压波动范围的数据进行训练，测试集则在其他波动条件下进行验证。具体测试配置如表 5 所示。图 16 展示了在不同电压波动范围下的测试精度。

表 5 训练集与对应的测试集

Table 5 Training set and corresponding test set

训练集	测试集
$\pm 2\%$ 训练集	$\pm 3\%$ 测试集
	$\pm 4\%$ 测试集
$\pm 3\%$ 训练集	$\pm 2\%$ 测试集
	$\pm 4\%$ 测试集
$\pm 4\%$ 训练集	$\pm 2\%$ 测试集
	$\pm 3\%$ 测试集

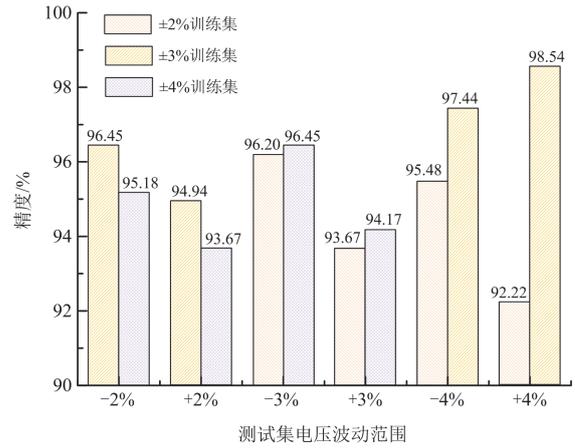


图 16 不同电压波动范围下的测试精度

Fig. 16 Test accuracy under different voltage fluctuation ranges

从图 16 可以看出，无论是使用  $\pm 2\%$ 、 $\pm 3\%$  还是  $\pm 4\%$  的电压波动数据进行训练，随后在不同电压波动条件下进行测试时，精度都能保持在 92% 以上。其中，使用  $\pm 2\%$  训练集的测试平均精度为 94.39%， $\pm 3\%$  训练集的测试平均精度为 96.84%， $\pm 4\%$  训练集的测试平均精度为 94.87%。结果表明，本文所提模型对电压波动具一定抵抗能力。

### 3.5.3 光照变化测试

实际运行中，环境温度、光照强度和天气条件对光伏发电系统影响显著<sup>[28]</sup>。为验证本文方法在不同光照强度下的表现，使用 MATLAB/Simulink 搭建仿真模型，设置标准温度为 25 °C，标准光照为 1000 W/m<sup>2</sup>，并设定 0.2 s 后光照强度发生变化。如图 17 所示，在  $t = 0.2$  s 时光照强度从 100% 开始下降。

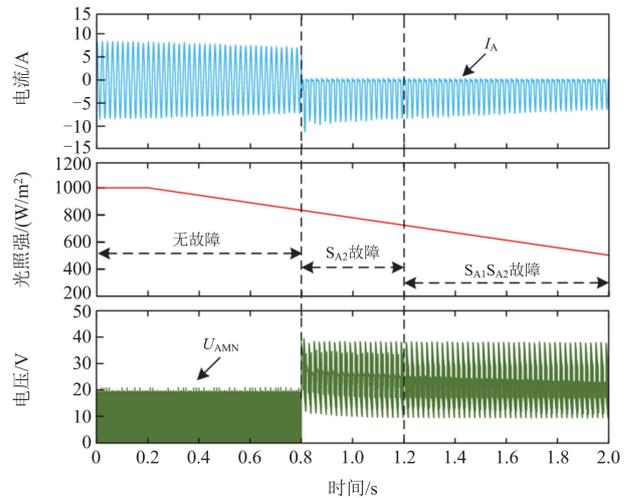


图 17 光照强度对故障检测信号的影响

Fig. 17 Influence of light intensity on fault detection signals

经过 50 轮训练后训练集精度达到了 99.83%，对训练好的模型进行测试精度达到了 99.15%，图 18 展示了随机抽取的 20 种故障类型的测试结果。可见 20 种故障类型的测试结果精度均为 100%。结果表明，本文方法在不同光照强度下能对 79 种故障类型进行准确区分。

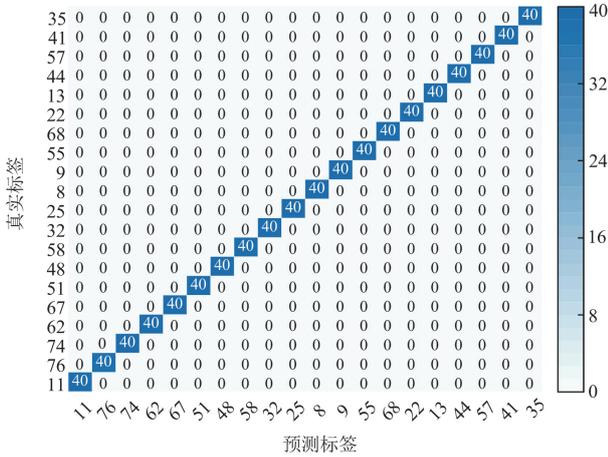


图 18 20 种随机故障类型诊断结果的混淆矩阵  
Fig. 18 Confusion matrix for diagnosis results of 20 random fault types

### 4 结论

针对并网 NPC 逆变器的开路故障，提出了一种

### 附录 A

表 A1 故障类型及标签

Table A1 Fault types and labels

故障类型	故障标签								
无	0	S <sub>A2</sub> S <sub>A3</sub>	16	S <sub>A1</sub> S <sub>B2</sub>	32	S <sub>A3</sub> S <sub>B2</sub>	48	S <sub>B1</sub> S <sub>C2</sub>	64
S <sub>A1</sub>	1	S <sub>A2</sub> S <sub>A4</sub>	17	S <sub>A1</sub> S <sub>B3</sub>	33	S <sub>A3</sub> S <sub>B3</sub>	49	S <sub>B1</sub> S <sub>C3</sub>	65
S <sub>A2</sub>	2	S <sub>A3</sub> S <sub>A4</sub>	18	S <sub>A1</sub> S <sub>B4</sub>	34	S <sub>A3</sub> S <sub>B4</sub>	50	S <sub>B1</sub> S <sub>C4</sub>	66
S <sub>A3</sub>	3	S <sub>B1</sub> S <sub>B2</sub>	19	S <sub>A1</sub> S <sub>C1</sub>	35	S <sub>A3</sub> S <sub>C1</sub>	51	S <sub>B2</sub> S <sub>C1</sub>	67
S <sub>A4</sub>	4	S <sub>B1</sub> S <sub>B3</sub>	20	S <sub>A1</sub> S <sub>C2</sub>	36	S <sub>A3</sub> S <sub>C2</sub>	52	S <sub>B2</sub> S <sub>C2</sub>	68
S <sub>B1</sub>	5	S <sub>B1</sub> S <sub>B4</sub>	21	S <sub>A1</sub> S <sub>C3</sub>	37	S <sub>A3</sub> S <sub>C3</sub>	53	S <sub>B2</sub> S <sub>C3</sub>	69
S <sub>B2</sub>	6	S <sub>B2</sub> S <sub>B3</sub>	22	S <sub>A1</sub> S <sub>C4</sub>	38	S <sub>A3</sub> S <sub>C4</sub>	54	S <sub>B2</sub> S <sub>C4</sub>	70
S <sub>B3</sub>	7	S <sub>B2</sub> S <sub>B4</sub>	23	S <sub>A2</sub> S <sub>B1</sub>	39	S <sub>A4</sub> S <sub>B1</sub>	55	S <sub>B3</sub> S <sub>C1</sub>	71
S <sub>B4</sub>	8	S <sub>B3</sub> S <sub>B4</sub>	24	S <sub>A2</sub> S <sub>B2</sub>	40	S <sub>A4</sub> S <sub>B2</sub>	56	S <sub>B3</sub> S <sub>C2</sub>	72
S <sub>C1</sub>	9	S <sub>C1</sub> S <sub>C2</sub>	25	S <sub>A2</sub> S <sub>B3</sub>	41	S <sub>A4</sub> S <sub>B3</sub>	57	S <sub>B3</sub> S <sub>C3</sub>	73
S <sub>C2</sub>	10	S <sub>C1</sub> S <sub>C3</sub>	26	S <sub>A2</sub> S <sub>B4</sub>	42	S <sub>A4</sub> S <sub>B4</sub>	58	S <sub>B3</sub> S <sub>C4</sub>	74
S <sub>C3</sub>	11	S <sub>C1</sub> S <sub>C4</sub>	27	S <sub>A2</sub> S <sub>C1</sub>	43	S <sub>A4</sub> S <sub>C1</sub>	59	S <sub>B4</sub> S <sub>C1</sub>	75
S <sub>C4</sub>	12	S <sub>C2</sub> S <sub>C3</sub>	28	S <sub>A2</sub> S <sub>C2</sub>	44	S <sub>A4</sub> S <sub>C2</sub>	60	S <sub>B4</sub> S <sub>C2</sub>	76
S <sub>A1</sub> S <sub>A2</sub>	13	S <sub>C2</sub> S <sub>C4</sub>	29	S <sub>A2</sub> S <sub>C3</sub>	45	S <sub>A4</sub> S <sub>C3</sub>	61	S <sub>B4</sub> S <sub>C3</sub>	77
S <sub>A1</sub> S <sub>A3</sub>	14	S <sub>C3</sub> S <sub>C4</sub>	30	S <sub>A2</sub> S <sub>C4</sub>	46	S <sub>A4</sub> S <sub>C4</sub>	62	S <sub>B4</sub> S <sub>C4</sub>	78
S <sub>A1</sub> S <sub>A4</sub>	15	S <sub>A1</sub> S <sub>B1</sub>	31	S <sub>A3</sub> S <sub>B1</sub>	47	S <sub>B1</sub> S <sub>C1</sub>	63		

基于 SDP 和 ECA-ConvNeXt 模型的故障诊断方法。并通过实验验证了其高效性和准确性，主要结论如下。

1) 以三相“上下桥臂中点间电压”和 A 相输出电流作为故障检测信号，能够准确区分出包含同桥臂双管和内侧单管故障在内的 79 种单、双管开路故障，减少了故障诊断所需的传感器数量，降低了系统的复杂性和成本。

2) 使用 SDP 进行处理，将 4 个信号映射在极坐标中，融合为一张“雪花图”作为模型的输入，与 2D 矩阵输入模型相比，ECA-ConvNeXt 模型的精度提升 5.29%，为故障诊断提供了更丰富的特征信息。

3) 改进后的 ECA-ConvNeXt 模型，在增强对特征信息的获取和处理能力的同时降低了网络复杂度。该模型诊断精度达 99.53%，平均测试时间为 8.82 ms，与 ConvNeXt T 模型相比精度提高 3.81%，平均测试时间减少 2.28 ms，参数降低 21.76 M，FLOPs 下降 79.26%，兼顾了精度和速度。同时在 20 dB、25 dB、30 dB、35 dB 和 40 dB 噪声条件下的平均精度分别为 95.25%、96.65%、97.53%、98.61%和 98.98%；不同电压波动条件下的平均精度为 96.84%；不同光照强度条件下平均精度为 99.15%。

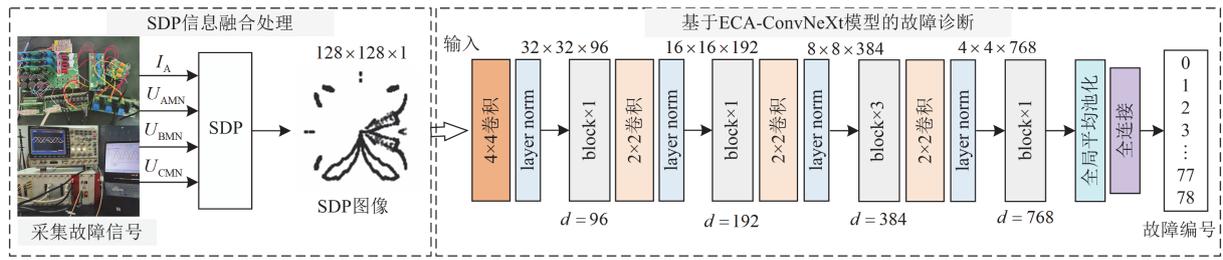


图 A1 故障诊断流程

Fig. A1 Fault diagnosis process

## 参考文献

- [1] 程杉, 蔡子威, 张旭军, 等. 基于雪消融算法的光伏并网逆变器低电压穿越模型多阶段参数辨识方法[J]. 电力系统保护与控制, 2025, 53(5): 47-58.  
CHENG Shan, CAI Ziwei, ZHANG Xujun, et al. A multi-stage parameter identification method for low-voltage ride-through model of grid-connected PV inverters based on a snow ablation algorithm[J]. Power System Protection and Control, 2025, 53(5): 47-58.
- [2] 任颀, 周鹏鹏. 用于光伏逆变器故障穿越的载波交叠调制优化[J]. 电力系统保护与控制, 2024, 52(14): 167-176.  
REN Jie, ZHOU Pengpeng. Optimization of carrier overlap modulation for fault ride-through of photovoltaic inverters[J]. Power System Protection and Control, 2024, 52(14): 167-176.
- [3] 张博宸, 周羽生, 周文晴, 等. 基于滑模观测器的三电平风力发电并网逆变器无差拍优化模型预测控制[J]. 电测与仪表, 2024, 61(4): 176-183.  
ZHANG Bochen, ZHOU Yusheng, ZHOU Wenqing, et al. Optimal model predictive control for three-level grid-connected windpower inverters without differential beat based on sliding mode observer[J]. Electrical Measurement & Instrumentation, 2024, 61(4): 176-183.
- [4] 陈怡薇, 徐永海, 袁敞, 等. 线性负载下三电平逆变器的两相箝位断续脉宽调制策略研究[J]. 电力系统保护与控制, 2025, 53(8): 96-104.  
CHEN Yiwei, XU Yonghai, YUAN Chang, et al. Research on two-phase clamped discontinuous pulse width modulation strategy for three-level inverters under linear load[J]. Power System Protection and Control, 2025, 53(8): 96-104.
- [5] 杨清, 黄景涛, 关海平. 基于 SVPWM 补偿优化的三电平 NPC 并网逆变器容错控制[J]. 电力工程技术, 2024, 43(2): 199-209.  
YANG Qing, HUANG Jingtao, GUAN Haiping. Fault tolerant control of three-level NPC grid-connected inverter based on SVPWM compensation optimization[J]. Electric Power Engineering Technology, 2024, 43(2): 199-209.
- [6] 陈怡薇, 徐永海, 袁敞, 等. 基于切换调制策略的 ANPC 三电平逆变器开路故障诊断方法研究[J]. 电力系统保护与控制, 2025, 53(2): 27-37.  
CHEN Yiwei, XU Yonghai, YUAN Chang, et al. Research on open-circuit fault diagnosis method of ANPC three-level inverter based on switching modulation strategy[J]. Power System Protection and Control, 2025, 53(2): 27-37.
- [7] WU Xun, CHEN Chunyang, CHEN Tefang, et al. A fast and robust diagnostic method for multiple open-circuit faults of voltage-source inverters through line voltage magnitudes analysis[J]. IEEE Transactions on Power Electronics, 2020, 35(5): 5205-5220.
- [8] ZHOU Yang, ZHAO Jin, SONG Yujin, et al. A seasonal-trend-decomposition-based voltage-source-inverter open-circuit fault diagnosis method[J]. IEEE Transactions on Power Electronics, 2022, 37(12): 15517-15527.
- [9] SHEN Haolan, TANG Xin, LUO Yifei, et al. Online Open-circuit fault diagnosis for neutral point clamped inverter based on an improved convolutional neural network and sample amplification method under varying operating conditions[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-12.
- [10] ZHOU Xinxu, SUN Jun, CUI Peiling, et al. A fast and robust open-switch fault diagnosis method for variable-speed PMSM system[J]. IEEE Transactions on Power Electronics, 2021, 36(3): 2598-2610.
- [11] CASEIRO L M A, MENDES A M S, CRUZ S M A. Cooperative and dynamically weighted model predictive control of a 3-level uninterruptible power supply with improved performance and dynamic response[J]. IEEE Transactions on Industrial Electronics, 2020, 67(6): 4934-4945.
- [12] ZHANG Zeliang, HU Yihua, LUO Guangzhao, et al. An embedded fault-tolerant control method for single open-switch faults in standard PMSM drives[J]. IEEE Transactions on Power Electronics, 2022, 37(7): 8476-8487.
- [13] 许水清, 黄文展, 何怡刚, 等. 基于自适应滑模观测器的中点钳位型三电平并网逆变器开路故障诊断[J]. 电

- 工技术学报, 2023, 38(4): 1010-1022.
- XU Shuiqing, HUANG Wenzhan, HE Yigang, et al. Open-circuit fault diagnosis method of neutral point clamped three-level grid-connected inverter based on adaptive sliding mode observer[J]. Transactions of China Electrotechnical Society, 2023, 38(4): 1010-1022.
- [14] XIAO Chengqi, WU Weimin, GAO Ning, et al. Fault diagnosis and reconfiguration for H6 grid-tied inverter using Kalman filter[C]// IECON 2021-47th Annual Conference of the IEEE Industrial Electronics Society, October 13-16, 2021, Toronto, Canada: 1-5.
- [15] CHEN Chaobo, YANG Yingna, ZHANG Binbin, et al. The diagnostic method for open-circuit faults in inverters based on extended state observer[J]. Mathematical Problems in Engineering, 2021: 1-11.
- [16] BAE C, LEE D, NGUYEN T H. Detection and identification of multiple IGBT open-circuit faults in PWM inverters for AC machine drives[J]. IET Power Electronics, 2019, 12(4): 923-931.
- [17] 李江伟, 石瑞才, 王愚, 等. UPS 系统中电压型逆变器开路故障诊断研究[J]. 电力系统保护与控制, 2020, 48(23): 148-153.
- LI Jiangwei, SHI Ruicai, WANG Yu, et al. Open-circuit fault diagnosis of a voltage-source inverter in a UPS system[J]. Power System Protection and Control, 2020, 48(23): 148-153.
- [18] 徐小健, 于飞. 基于输出电压轨迹的三相逆变器开关管开路故障诊断[J]. 中国电机工程学报, 2024, 44(3): 1106-1117.
- XU Xiaojian, YU Fei. A fault diagnosis method based on output voltage patterns for switch open-circuit fault of three-phase inverters[J]. Proceedings of the CSEE, 2024, 44(3): 1106-1117.
- [19] CHEN Danjiang, LIU Yutian, ZHOU Junwei. Optimized neural network by genetic algorithm and its application in fault diagnosis of three-level inverter[C]// 2019 CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes, July 5-7, 2019, Xiamen, China: 116-120.
- [20] 胡彬. NPC 型三电平逆变器故障诊断方法研究[D]. 徐州: 中国矿业大学, 2022.
- HU Bin. Research on the fault diagnosis methods of NPC three-level inverter[D]. Xuzhou: China University of Mining and Technology, 2022.
- [21] XIE Feng, TANG Xin, XIAO Fei, et al. Online diagnosis method for open-circuit fault of NPC inverter based on 1D-DSCNN-GMP lightweight edge deployment[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2023, 11(6): 6054-6067.
- [22] 陈丹江, 叶银忠. 基于多神经网络的三电平逆变器器件开路故障诊断方法[J]. 电工技术学报, 2013, 28(6): 120-126.
- CHEN Danjiang, YE Yinzong. Fault diagnosis of three level inverter based on multi neural network[J]. Transactions of China Electrotechnical Society, 2013, 28(6): 120-126.
- [23] SHEN Haolan, TANG Xin, AI Sheng, et al. Mixed-type open-circuit fault diagnosis for NPC inverters using a dual-input CNN[C]// 2021 IEEE 4th International Electrical and Energy Conference, May 28-30, 2021, Wuhan, China: 1-7.
- [24] CHEN Weiqiang, BAZZI A M. Logic-based methods for intelligent fault diagnosis and recovery in power electronics[J]. IEEE Transactions on Power Electronics, 2017, 32(7): 5573-5589.
- [25] 黄新波, 马玉涛, 朱永灿. 基于信息融合和 M-RVM 的变压器故障诊断方法[J]. 电力自动化设备, 2020, 40(12): 218-225.
- HUANG Xinbo, MA Yutao, ZHU Yongcan. Transformer fault diagnosis method based on information fusion and M-RVM[J]. Electric Power Automation Equipment, 2020, 40(12): 218-225.
- [26] 文成林, 吕菲亚. 基于深度学习的故障诊断方法综述[J]. 电子与信息学报, 2020, 42(1): 234-248.
- WEN Chenglin, LÜ Feiya. Review on deep learning based fault diagnosis[J]. Journal of Electronics & Information Technology, 2020, 42(1): 234-248.
- [27] XUE Z, XIAHOU K, LI M, et al. Diagnosis of multiple open-circuit switch faults based on long short-term memory network for DFIG-based wind turbine systems[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2020, 8(3): 2600-2610.
- [28] 陈炜, 艾欣, 吴涛, 等. 光伏并网发电系统对电网的影响研究综述[J]. 电力自动化设备, 2013, 33(2): 26-32, 39.
- CHEN Wei, AI Xin, WU Tao, et al. Influence of grid-connected photovoltaic system on power network[J]. Electric Power Automation Equipment, 2013, 33(2): 26-32, 39.

收稿日期: 2025-04-21; 修回日期: 2025-06-29

作者简介:

韩素敏(1979—), 女, 博士, 教授, 研究方向为智能信息处理、智能故障诊断; E-mail: hansumin@hpu.edu.cn

张树志(1999—), 男, 通信作者, 硕士研究生, 研究方向为逆变器故障诊断。E-mail: 3452712403@qq.com

(编辑 许威)