

基于 TransGAN 算法的柔性直流配电网 故障检测方法研究

曾 飞*, 叶保璇, 余盛达

(海南电网有限责任公司 文昌供电局, 海南 文昌 571300)

Research on Fault Detection Method of Flexible DC Distribution Network Based on TransGAN Algorithm

ZENG Fei*, YE Baoxuan, YU Shengda

(Wenchang Power Supply Bureau, CSG Hainan Power Grid Corporation, Wenchang 571300, China)

Abstract: [Objective] Aiming at the problem that the existing methods for detecting faults in flexible DC distribution networks have low accuracy and high cost of acquiring fault signals, this paper proposes a fault accurate detection method based on the Transformer algorithm and the generative adversarial network (GAN) fusion model. [Methods] Firstly, the effective modal components of the preprocessed DC distribution network fault voltage and current signals were extracted by adaptive variational mode decomposition method, and the effective feature vectors were extracted by Transformer algorithm. Then, the GAN model generator was replaced by Transformer algorithm, and the TransGAN deep learning model was established based on it. Finally, a simulation model was established based on Matlab/Simulink to verify the effectiveness and accuracy of the proposed method. [Results] Experimental results showed that this method has significant advantages in improving fault detection accuracy and reducing false alarm rate. Compared with the existing detection methods, it has higher fault recognition accuracy and stronger generalization ability. [Conclusion] The proposed method achieving higher detection accuracy, the required data set size is smaller than other methods, which reduces the data acquisition cost and computational complexity, and improves the practical application value and engineering feasibility of the model.

Key words: DC distribution network; generative adversarial network; variational mode decomposition; Transformer; deep learning

摘 要:【目的】针对柔性直流配电网故障现有方法准确度低且故障信号获取成本高的问题,本文提出一种基于 Transformer 算法和生成对抗网络(GAN)融合模型的故障精确检测方法。【方法】首先,将预处理后的直流配电网故障电压和电流信号经过自适应变分模态分解提取有效模态分量,并利用 Transformer 算法提取有效特征向量。然后,采用 Transformer 算法替代 GAN 模型生成器,据此建立 TransGAN 深度学习模型。最后,基于 Matlab/Simulink 建立仿真模型对所提方法的有效性和准确性进行验证。【结果】试验结果表明,该方法在提高故障检测准确度、降低误报率方面具有显著优势,相比于现有检测方法,具有更高故障的识别精度和更强的泛化能力。【结论】所提方法在实现更高检测准确度的同时,所需的数据集大小相比于其他方法更低,降低了数据获取成本和计算复杂度,提升了模型的实际应用价值和工程可行性。

关键词: 直流配电网;生成对抗网络;变分模态分解;Transformer;深度学习

0 引言

以新能源为主要发展趋势的新型电力系统,随着电力电子器件在电力系统中大面积使用,柔性直流配电网因其灵活性和稳定性优势已成为未来新型电力系统规划和发展的重点方向^[1-4]。当直流配电网发生短路故障时,由于系统惯量低,导致直流系统故障发展速度迅速,短时间内波及系统安全稳定^[5-6]。为快速降低直流短路故障对配电网的影响,保障直流配电网安全稳定运行,增强系统在故障情况下的穿越能力及快速隔离与自我恢复功能,需快速准确识别系统短路故障,为后续故障定位和故障清除及恢复提供重要支撑^[7-9]。

基金项目:南方电网创新项目(070500KK5222005)

Innovation Project of CSG Co., Ltd. (070500KK5222005)

目前,直流系统故障检测主要分为基于时频域信号处理方法和基于数据驱动方法^[10-11]。基于时频域信号处理方法通过提取直流配网故障暂态特征与设定的阈值特征匹配,以此判断故障发生的类型^[12-13]。时频域方法通过快速傅里叶变换(Fast Fourier Transform, FFT)^[14]、广义 S 变换^[15]、小波分析、经验模态分解(Empirical Mode Decomposition, EMD)^[16]和变分模态分解(Variational Mode Decomposition, VMD)^[17-18]提取暂态特征,但存在计算复杂、依赖人工阈值的问题。

数据驱动方法通过机器学习直接挖掘故障特征,无需依赖物理模型^[19-20]。无监督学习如堆叠自编码器^[21]和主成分分析法(Principal Component Analysis, PCA)^[22]可自动提取特征;有监督学习从传统支持向量机(Support Vector Machine, SVM)^[23]、Bayesian 网络^[24]逐步发展为深度学习方法,包括人工神经网络(Artificial Neural Network, ANN)^[25]、卷积神经网络(Convolutional Neural Network, CNN)^[26]、双向长短期记忆(Bidirectional Long Short-Term Memory, Bi-LSTM)网络^[27]和 CNN-LSTM^[28],其中 CNN-LSTM 精度达 96.6%。Transformer^[29]凭借时序建模优势,进一步提升了检测性能。

但由于直流配电网故障信号获取需配置大量传感器,获取成本较高。且基于数据驱动的方法对数据量的要求高,数据量不足时会导致模型检测精度受到较大影响。

为此,本文针对上述方法的局限性,提出了一种基于 Transformer 算法和生成对抗网络(Generative Adversarial Network, GAN)融合的 TransGAN 深度学习模型结构,用来实现直流配电网故障精确检测。首先将处理后的直流配电网故障电压和电流信号经过自适应 VMD 方法提取有效模态分量,再输入至 Transformer 算法,凭借其强大的特征提取能力和并行计算能力实现有效特征提取。其次,将提取的特征向量经过 GAN 的对抗训练,增强数据集并以期实现较小样本输入的故障检测,其中生成器采用 Transformer 结构代替传统使用的 CNN 结构。最后,基于 Matlab/Simulink 建立仿真模型,对本文方法的有效性和

准确性进行验证和分析。

1 故障特性分析

柔性直流配电网故障特性分析是故障识别的基础,其中直流配电网中线路的故障率最高,因此本文所述的故障识别主要为直流线路故障。

1.1 直流配电网拓扑结构

本文针对典型五端低压双极方式运行的直流配电网开展研究,直流配电网拓扑结构如图 1 所示,该结构由光伏发电、风力发电、交流电网、储能电站和终端负载等组成。DC/DC 变换器 1~3 分别将光伏电站、储能电站及恒阻抗负载连接至直流母线端,AC/DC1 和 AC/DC2 变换器分别将交流电网和风力发电机组连接至直流母线端,其中 AC/DC 变换器采用三相六桥结构的电压源型换流器(Voltage Source Converter, VSC)。

1.2 区外内故障分析

根据故障发生的位置和影响范围,将直流配电网故障分为区外故障和区内故障。典型的区外故障电路如图 2 所示, kq 区间发生区外故障时 $i_m = i_n$, 其中 i_m 为直流线路电流, i_n 为流出电流。图中, L_T 为附加电感, u_{Ck} 、 u_{Cq} 分别为 k 端、 q 端电容电压。

由于直流线路发生故障时,故障区段线路压降大,非故障区段相对较小,为此本文引入伪电压作为判别线路故障的重要依据^[30]。通过本端的电压和电流计算得到直流线路另一端电压,称为对端伪电压。 k 端电容电压 u_{Ck} 对应的伪电压设为 u'_{Cqk} ; q 端电容电压 u_{Cq} 对应的伪电压设为 u'_{Ckq} 。此时区外故障可表示为

$$\begin{cases} u'_{Ckq} = u_{Ck} - (Ll_0 + 2L_T) \frac{di_k}{dt} - Lr_0 i_k = u_{Cq} \approx U_{line} \\ u'_{Cqk} = u_{Cq} + (Ll_0 + 2L_T) \frac{di_q}{dt} - Lr_0 i_q = u_{Ck} \approx U_{line} \end{cases} \quad (1)$$

式中: L 为线路长度; l_0 、 r_0 分别为直流线路每千米电感、电阻; i_k 和 i_q 为直流电流; U_{line} 为系统电压。

由式(1)可知,当线路 kq 发生区外故障, k 端伪电压 u'_{Cqk} 与 k 端电容电压 u_{Ck} 相等, q 端电压情况与 k 端相同。实际上,处于暂态下的 u'_{Cqk} 和 u'_{Ckq} 接近直流系统电压。




图1 典型直流配电网拓扑结构

Fig. 1 Typical DC distribution network topology




图2 典型区外故障电路图

Fig. 2 Typical out-of-zone fault circuit diagram

典型的区内故障电路如图3所示,其中 γ_1 为金属性短路故障, γ_2 为阻性故障。

当 γ_1 发生区内金属性故障,该故障点电压

$$\left. \begin{aligned} u'_{Ckq} &= u_{Ck} - (Ll_0 + L_T) \frac{di_k}{dt} - Lr_0 i_k = \\ &= \underbrace{u_{Ck} - (xl_0 + L_T) \frac{di_k}{dt} - xr_0 i_k}_{u_F \approx 0} - \left[(L-x)l_0 + L_T \right] \frac{di_k}{dt} - (L-x)r_0 i_k \end{aligned} \right\} (k \rightarrow q) \quad (2)$$

式中: x 为故障长度。

此外, k 端伪电压 u'_{Cqk} 为

$$u'_{Cqk} = u_F - xr_0 i_q - (xl_0 + L_T) \frac{di_q}{dt} < 0 \quad (k \leftarrow q) \quad (3)$$

由式(2)、式(3)分析可知,当发生区内金属性故障时,两端伪电压值均小于0。

当 γ_2 发生区内阻性故障,该故障点电压 $u_F > 0$, q 端伪电压 u'_{Ckq} 为




图3 典型区内故障电路图

Fig. 3 Typical in-of-zone fault circuit diagram

u_F 为0, q 端伪电压 u'_{Ckq} 为

$$\left. \begin{aligned} u'_{Ckq} &= u_{Cq} - [(L-x)l_0 + L_T] \left(\frac{di_k}{dt} + \frac{di_q}{dt} \right) - \\ &= (L-x)r_0(i_k + i_q) \end{aligned} \right\} \ll U_{line} \quad (4)$$

此外, k 端伪电压 u'_{Cqk} 为

$$\left. \begin{aligned} u'_{Cqk} &= u_{Ck} - (xl_0 + L_T) \left(\frac{di_k}{dt} + \frac{di_q}{dt} \right) - \\ &= xr_0(i_k + i_q) \end{aligned} \right\} \ll U_{line} \quad (5)$$

1.3 不同极性故障分析

直流配电网故障按其严重程度主要分为单极接地短路故障和双极短路故障^[31],通常情况下单极故障对系统影响较小,发生故障时仍能继续运行,其中单极接地故障分为正极接地故障(Positive to Ground Fault, PGF)和负极接地故障(Negative to Ground Fault, NGF)。而双极故障(Pole to Pole Fault, PPF)会导致整个系统停运,单双极短路故障电路如图 4 所示。图中,VSC 由基于三相六臂配置的绝缘栅双极型晶体管、电感 L_s 及母线电容等组成。




图 4 单双极短路故障电路图

Fig. 4 Single and double pole short circuit fault circuit diagram

图 4 中,当发生正极接地故障时,故障电流由正极通过故障点流入大地,形成回路,此时正极对地电压降低,接近于零,负极对地电压升高,接近系统额定电压。发生负极接地故障时,故障电流和电压变化情况与正极接地故障相同。

当发生双极接地故障时,若正负极同时接地,电流从正极通过故障点流入大地,再从大地通过故障点流入负极;若正负极直接短路,电流直接从正极流向负极,形成大电流回路。

2 直流配电网故障检测方法

基于上述分析,若仅通过对单一特征值设定阈值判断或对比某种暂态特征量值难以实现有效检测,因此本文考虑采用自适应 VMD 方法充分提取故障电压和电流信号的暂态关键特征,并以此数据作为检测模型的输入。检测模型采用模块化设计,将数据增强的 GAN 和强大分类能力的 Transformer 结合,有效地对处理后的信号进行深度学习分析,识别出故障模式和异常故障情况。

2.1 自适应 VMD

VMD 是一种高性能的信号分解方法,将原始信号 $f(t)$ 分解为多个具有唯一中心频率和有限带

宽的分量。VMD 能够将复杂序列分解为多个简单子信号,提取非线性特征。其求解过程需满足两个条件:各模态频带宽之和最小,且所有模态分量之和等于原始信号。求解过程可归结为最优化问题,如式(6)所示:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_{k=1}^K u_k = f(t) \end{cases} \quad (6)$$

式中: $\delta(t)$ 为狄拉克分布函数; K 为模态个数; $\{u_k\}$ 为模态集 $\{u_1, u_2, \dots, u_K\}$; $\{\omega_k\}$ 为中心频率集 $\{\omega_1, \omega_2, \dots, \omega_K\}$ 。

引入二次惩罚 λ 和拉格朗日乘子 α ,将上述最优化问题转化为无约束优化问题,即:

$$\begin{aligned} L(\{U_k\}, \{\omega_k\}, \lambda) = & \alpha \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \end{aligned} \quad (7)$$

利用乘数交替方向法 (Alternating Direction Method of Multipliers, ADMM) 对 u_k, ω_k, λ 进行交替迭代优化求解方程(6)。根据 ADMM 方法对方程进行简化,得到 u_k, ω_k, λ 更新迭代方程为

$$\begin{cases} u_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i \neq k} u_i(\omega) + \frac{\lambda(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \\ \omega_k^{n+1} = \frac{\int_0^\infty \omega |u_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |u_k^{n+1}(\omega)|^2 d\omega} \\ \lambda^{n+1} = \lambda^n + \tau \left[f(t) - \sum_{k=1}^K u_k^{n+1} \right] \end{cases} \quad (8)$$

式中: n 为迭代次数; τ 为更新参数; $f(\omega), u_i(\omega), \lambda(\omega), u_k^{n+1}(\omega)$ 分别为 $f(t), u_i(t), \lambda(t), u_k^{n+1}(t)$ 的傅里叶变换。

给定求解精度 ε ,若式(9)为真,则停止迭代。

$$\sum_{k=1}^K \frac{\|u_k^{n+1} - u_k^n\|_2^2}{\|u_k^n\|_2^2} < \varepsilon \quad (9)$$

基于 VMD 算法原理可知,分解模态数 K 太小,会导致原始信号不能完全分解,容易导致模态

混叠;相反, K 过大则会导致原始信号过度分解,从而产生无用的杂散分量。本文采用自适应优化方法确定 K 值,具体流程如图 5 所示。




图 5 自适应求解最优模态数 K 流程图

Fig. 5 Flow chart of adaptive solution to the optimal modal number K

优化过程以 $\alpha=2\ 000$ 为基准,设置 $K_{\max}=20$ 。通过计算滤波序列 Fm 与一阶模态 Imf^1 的欧氏距离 D_K ,如式(10)所示,并分析其差分序列 $\{FO_K\}$ 的均值变化,最终选取使 FO_K 均值显著下降前的最大 K 值作为最优解。

$$D_K = \frac{1}{L} \sum_{i=1}^L Imf_i^1 - Fm_i \quad (10)$$

式中: Imf^1 为分解后的第一个模态; Fm 为滤波后的序列; D_K 为分解模态数为 K 时的欧氏距离。

2.2 TransGAN 检测模型构建

2.2.1 Transformer 模型构建

Transformer 模型架构如图 6 所示。图中,位置编码将输入数据贴上唯一的位置标识符,该模块使得模型更全面的学习数据序列中远距离依赖




图 6 Transformer 模型架构图

Fig. 6 Transformer model architecture diagram

关系。

将输入数据嵌入到高维空间,通过线性向量映射到所选定的编码维度,同时通过添加由 L 层 Transformer 模块组成的特征提取模块,通过探究各编码段向量间的关联信息,提取故障电流数据序列中的全局特征,具体为

$$\begin{cases} I' = f_{LN}[I + f_{\text{multihead}}(I)] \\ f_{\text{block}}(I) = f_{LN}[I' + f_{\text{MLP}}(I')] \end{cases} \quad (11)$$

式中: $f_{LN}(\cdot)$ 为正则化层操作; $f_{\text{block}}(\cdot)$ 为 Transformer 模型的输出。

分类器由两个线性层组成,并采用 softmax 激活函数得到每种故障类型的概率输出,概率最大的类别即为模型预测的故障类型。

2.2.2 GAN 模型构建

GAN 由 Goodfellow 等人提出^[30],主要用于生成与真实数据相似的新数据。GAN 模型结构如图 7 所示,该模型主要由生成器(Generator)和判别器(Discriminator)构成。

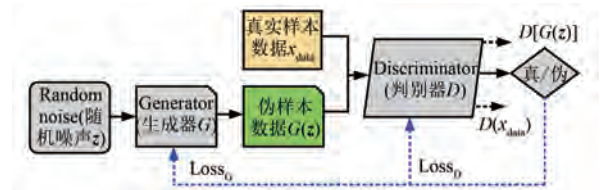


图 7 GAN 模型架构图

Fig. 7 GAN model architecture diagram

生成器 G 通过输入的随机噪声 z 生成新样本 $G(z)$,即 $G:Z \rightarrow G(z)$ 。其中 $z \in \mathbb{R}^d$, z 通常是从高斯分布 p_z 中采样的向量, d 为 z 的维度。通过学习与真实数据分布 p_{data} 匹配,生成数据分布 p_{model} ,生成样本 $G(z)$ 和真实样本 x_{data} 的概率分布分别由 p_{model} 和 p_{data} 给出。

判别器 D 将生成的样本与真实样本区分开,

其输出被视为真实样本的概率。因此,判别器 D 使 $D(x_{\text{data}}) \approx 1, \forall x_{\text{data}} \sim p_{\text{data}}$ 且 $D[G(z)] \approx 0, \forall z \sim p_v$, 其中 p_{data} 为真实样本的概率分布。生成器 G 使 $D[G(z)] \approx 1, \forall z \sim p_v$ 。GAN 的训练目标可表示为极小极大博弈,其损失函数为

$$L_{\text{GAN}}(G, D) = \text{Min}_G \text{Max}_D \{ E_{x_{\text{data}} \sim p_{\text{data}}} [\log D(x_{\text{data}})] + E_{z \sim p_v} \{ \log \{ 1 - D[G(z)] \} \} \} \quad (12)$$

式中: $L_{\text{GAN}}(G, D)$ 为对抗损失函数; E 为真实数据或生成数据的期望值。

目标函数 $L_{\text{GAN}}(G, D)$ 为 p_{data} 和 p_{model} 间 Jensen-Shannon 散度,全局最优(纳什均衡)由 p_{data} 和 p_{model} 共同得出。在纳什均衡状态下,生成器 G 和判别器 D 达到最优解。判别器 D 通常采用 CNN 架构,其最后一层使用 sigmoid 函数输出样本真实概率,仅用于训练阶段。该网络能够将低维输入映射为高维特征空间,有效区分真实与生成数据。

2.3 TransGAN 算法流程

为检测直流配电网各类型故障,模型需捕捉数据的时序特征,本文利用 Transformer 的强大时序建模能力,帮助生成器 G 捕捉到电力系统中较长时间范围内的复杂依赖关系,生成更加接近实际故障的波形。Transformer 生成器参数设置如表 1 所示。

表 1 Transformer 生成器参数设置

Tab. 1 Transformer generator parameter settings	
参数名称	参数值
输入维度 d_{input}	512
嵌入维度 d_{model}	512
注意力头数	8
Transformer 层数	6
前馈网络的维度	2 048
Dropout 率	0.2
学习率	5e-5
输出维度 d_{output}	256

鉴于 CNN 的局部特征提取能力和强泛化能力,本文选用 CNN 作为 GAN 结构中的判别器。CNN 模型架构如图 8 所示,该模型由 5 个卷积块及一个多层全连接层组成,卷积块主要用于输入数据的特征提取,包含多层感知机的全连接层,主要用于分类预测。卷积块一由一维卷积层、批量归一化层(BN 层)及 ReLU 激活函数层组成;卷积

块二由一维卷积层、BN 层、ReLU 激活函数层、最大池化层(Maxpooling 层)及 Dropout 层组成。




图 8 CNN 模型架构图

Fig. 8 CNN model architecture diagram

CNN 判别器模型参数值设置如表 2 所示,该模型主要由 2 个卷积块一、2 个卷积块二(池化层选择最大池化函数)和二层全连接层分类器构成。该结构均采用小卷积核组合,可极大减少网络中的参数,进而提高模型的泛化性能。

表 2 CNN 判别器参数设置

Tab. 2 CNN discriminator parameters settings	
参数名称	参数值
卷积核大小	3×3
连接层神经元个数(二层)	512, 1
卷积步长	1
池化核大小	2×2
Dropout 率	0.5
学习率	5e-5

TransGAN 算法试验流程如图 9 所示。首先,多传感器采集直流配网电流/电压信号;其次,通过 VMD 分解抑制噪声并提取多频段特征本征模态函数(Intrinsic Mode Function, IMF);然后,利用 GAN 生成合成数据扩充训练集;最后,输入 TransGAN 模型进行分类。该模型融合 Transformer 自注意力、长程依赖和 CNN 局部特征提取的优势,实现高精度故障识别。




图 9 TransGAN 算法试验流程图

Fig. 9 TransGAN algorithm experimental flow chart

3 试验与分析

为验证本文所提方法的有效性和准确性,通过 Matlab/Simulink 环境搭建如图 1 所示的 ± 0.6 kV 柔性直流配电系统仿真模型,以此获取故障数据,系统采样频率为 10 kHz,系统主要参数如表 3 所示。

表 3 仿真系统主要参数

Tab. 3 Main parameters of simulation system

参数名称	参数值
直流系统电压等级/kV	± 0.6
直流线路单位电阻/($\text{m}\Omega \cdot \text{km}^{-1}$)	40
直流线路单位电感/($\text{mH} \cdot \text{km}^{-1}$)	0.95
直流线路长度/km	1
故障电阻/ Ω	0~10
母线电容容量/ μF	3 500

针对直流线路各场景故障,随机选择某一线路区段进行仿真测试,并计算得到归一化伪电压值,本文选择 Cable2 直流线路作为测试代表。Cable2 区段直流线路发生 3 种直流故障时双端归一化伪电压计算值如表 4 所示。

表 4 双端归一化伪电压

Tab. 4 Two-terminal normalized pseudo voltage

归一化伪电压	故障类型		
	PGF	NGF	PPF
u'_{C12}/U_{line}	0.996	1.041	0.965
u'_{C21}/U_{line}	0.996	1.013	1.041
u'_{C23}/U_{line}	-1.498	-1.531	-1.463
u'_{C32}/U_{line}	-1.519	-1.473	-1.546
u'_{C34}/U_{line}	1.016	0.988	0.956
u'_{C43}/U_{line}	1.018	0.968	1.043
u'_{C45}/U_{line}	1.021	0.995	1.011
u'_{C54}/U_{line}	1.013	0.987	0.992
u'_{C51}/U_{line}	0.996	1.014	1.036
u'_{C15}/U_{line}	1.021	0.995	0.973

由表 4 可知,非故障区间双端归一化伪电压计算值接近 1,而故障区间其值接近-1.5。

本文试验在故障前 0.02 s 开始采样,采样时间为 1 s,故障类型设置为负极接地故障、正极接地故障及双极接地故障 3 种。为符合直流电网的实际状况,本试验正常情况占 90%,其余 10% 为

故障情况。通过上述设置和 VMD 信号处理,形成电压、电流数据集,其中电压通过式(2)~式(5)换算成伪电压,以此得到的数据集大小为 10 000×3,并按 6:2:2 的比例分为训练集、验证集和测试集。

3.1 评价指标构建

故障检测本质上是分类任务,可用混淆矩阵表 5 分类结果与实际值进行比较,从而直观地表示各类别的分类状态。

表 5 故障检测中的混淆矩阵

Tab. 5 Confusion matrix in fault detection

类别	预测为正类别	预测为负类别
实际为正类别	TP	FN
实际为负类别	FP	TN

由表 5 可知,对于某类别而言,可将故障按真实标签与预测标签分为真阳性(True Positive, TP)、假阳性(False Positive, FP)、真阴性(True Negative, TN)与假阴性(False Negative, FN),可得到结果的评价指标,包括准确率(ACC)和 F1 分数(F1-Score, F1),如式(13)、式(14)所示:

$$\text{ACC} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (13)$$

$$\text{F1} = \frac{2[\text{TP}/(\text{TP} + \text{FP})] \cdot \text{Recall}}{[\text{TP}/(\text{TP} + \text{FP})] + \text{Recall}} \quad (14)$$

此外,受试者工作特征(Receiver Operating Characteristic, ROC)曲线描述了假阳率(FP Rate, FPR)和真阳率(TP Rate, TPR)变化时的相对关系,适用于在数据集不平衡时评估分类器的整体性能,曲线下面积(Area Under the Curve, AUC)越大,模型性能越好。

3.2 故障电压信号处理

自适应 VMD 信号处理结果如图 10 所示。对于配电网故障检测,一般采用 IMF1~IMF2 作为检测尺度^[31]。IMF1 和 IMF2 分量曲线保留了原始信号的绝大部分分量,IMF3~IMF5 受谐波分量影响,并不能体现原始故障信号的主要特征。因此,本文选择 IMF1 和 IMF2 作为检测尺度,其他故障类型及电流信号 VMD 分析过程与此类似。

3.3 模型超参数分析

在 TransGAN 模型中,Transformer 个数 L 、多头注意力头数 h 以及 CNN 卷积核大小 k 共同决




图 10 自适应 VMD 信号处理结果

Fig. 10 Adaptive VMD signal processing results

定 TransGAN 模型的复杂度和检测效果。超参数值越大,模型检测性能越强,但模型复杂度越大,模型存在过拟合风险, TransGAN 模型超参数选择范围及本文试验结果如表 6 所示。

表 6 TransGAN 模型超参数设置

超参数	设置范围	最优值
L	2、3、4、5、6	6
h	4、6、8、16	8
k	3×3、5×5、7×7	3×3

根据模型选择的最优超参数值进行 TransGAN 模型训练,其模型训练在不同遍历次数时 ACC 随之变化的模型损失曲线如图 11 所示。




图 11 不同遍历次数 ACC 与模型损失图

Fig. 11 ACC and model loss graph for different Epochs

由图 11 可知,该图曲线较为光滑,训练过程平稳,且训练集和验证集损失与 ACC 趋于重合,从而可判断该模型无欠拟合和过拟合风险。

3.4 本文方法试验与分析

本文将采集的直流电网电压电流样本数据集按 6:2:2 比例划分为训练集、测试集以及验证集,利用 TransGAN 方法故障检测混淆矩阵如图 12 所示。




图 12 本文方法故障检测混淆矩阵

Fig. 12 Confusion matrix for fault detection using the proposed method

由图 12 可知,TransGAN 模型在故障检测中表现优异:正常状态识别准确率达 0.983,正极接地故障(0.94)和负极接地故障(0.963)的检测精度也较高。由于正负极接地故障的电压电流特征相似,存在少量交叉误判(正极误判为负极 0.025,负极误判为正极 0.028)。双极故障检测准确率最高,达到 0.989。整体而言,该方法对各类故障均展现出可靠的检测能力。

各故障类型检测的 ROC 曲线如图 13 所示,其中微平均 (Micro average) AUC 值均大于 0.97,




图 13 各故障类型检测 ROC 曲线

Fig. 13 ROC curve for each fault type detection

表明 TransGAN 模型在样本不平衡情况下仍能保持较高检测精度。

3.5 与现有方法比较与分析

为进一步验证本文所提 TransGAN 模型故障检测方法的有效性和准确性,分别采用 SVM、Bayesian、ANN、CNN、Bi-LSTM、CNN-LSTM 和 Transformer 7 种检测方法进行比较试验。各方法主要参数如表 7 所示,各比较方法的试验结果如表 8 所示。

表 7 各方法主要参数设置

Tab. 7 Main parameter settings of each method

方法	主要参数
SVM	核函数为径向基函数,惩罚系数 $C=15$
Bayesian	节点网络结构、概率表采用离散变量的多维表格
ANN	隐藏层数 3,激活函数 sigmoid,学习率 $1e-5$
CNN	卷积核大小 3×3 ,激活函数 ReLU,学习率 $5e-5$
Bi-LSTM	神经元个数 64,学习率为 0.1,树的数目为 500
CNN-LSTM	CNN: 卷积核大小 3×3 ,激活函数 sigmoid; LSTM: 神经元个数 64,学习率为 0.1,树的数目为 500
Transformer	$L=6, h=6$, 编码向量维度 $d_e=32$

表 8 各比较方法试验结果

Tab. 8 Experimental results of the compared methods

方法	评价指标			
	ACC	PRE	Recall	F1
SVM	0.895 6	0.889 6	0.861 5	0.801 1
Bayesian	0.905 6	0.894 7	0.870 1	0.899 7
ANN	0.910 9	0.900 4	0.884 3	0.901 2
CNN	0.921 2	0.920 3	0.899 1	0.934 2
Bi-LSTM	0.926 8	0.925 6	0.897 6	0.933 7
CNN-LSTM	0.948 1	0.944 7	0.910 1	0.960 3
Transformer	0.952 3	0.951 1	0.902 2	0.962 6
本文方法	0.963 3	0.972 1	0.920 3	0.981 3

由表 8 可知,本文所提 TransGAN 模型检测方法各项评价指标均为优于其他比较方法,其中 ACC 值为 0.963 3、PRE 值为 0.972 1、Recall 值为 0.920 3、F1 值为 0.981 3。纵向比较各方法评价指标,深度学习方法优于机器学习方法,机器学习方法中 Bayesian 网络略优于 SVM 方法。

为全面评估及量化本文所提 TransGAN 模型检测方法的性能,采用 AUC 量化 7 种比较模型与本文模型的检测性能,试验结果如图 14 所示。




图 14 各检测方法的 ROC 曲线

Fig. 14 ROC curves of each detection method

由图 14 可知,本文提出的 TransGAN 模型检测方法 AUC 值更大,检测效果相比于其他方法更优。

本文方法通过 VMD 高效提取非平稳信号特征,结合 GAN 生成数据解决样本不足问题,并利用 Transformer 的时序建模优势提升检测精度。相比 CNN,其全局特征提取能力更强;与 LSTM 相比,并行计算效率更高。模型能有效捕捉特征关联性,降低对原始数据的依赖,鲁棒性显著提升。

为验证本文方法对数据的低依赖性,通过比较各方法在不同数据集比例时 ACC 值变化情况,如图 15 所示。




图 15 各检测方法 ACC 值随数据比例变化

Fig. 15 ACC values of various detection methods vary with the proportion of data

由图 15 可知,本文方法在数据比例仅 5% 时 ACC 值已达 0.812 3,远优于其他方法;当数据比例达到 60% 后,ACC 值稳定在 0.963 3,验证了 GAN 结构对数据依赖性的显著降低。图 16 对比了 6 种深度学习模型的训练时间,其中 SVM 和 Bayesian 网络因性能差距较大未参与比较,结果




图 16 各模型的训练时间

Fig. 16 Training times of each model

显示本文方法在计算效率上同样具有优势。

由图 16 可知,Transformer 模型训练时间最长,为 73.022 s;本文方法减少 GAN 对抗训练成本,同时采用最优化的模型参数设置使得计算复杂度最低,训练时间最短,为 47.03 s。

3.6 灵敏度分析

本文将输入模型的数据集大小作为实际参数,通过对其进行敏感度分析,以此验证本文方法的稳定性。TransGAN 模型在不同数据集上的试验结果如图 17 所示。




图 17 不同数据集比例对模型性能影响

Fig. 17 Impact of different dataset proportionation on model performace

图 17 采用 FPR 和 TPR 两个指标评价模型的性能表现。当数据比例低于 60% 时,FPR 随数据量减少显著上升,TPR 则随数据增加稳步提高;超过 60% 后,两者均趋于稳定。这表明小样本下模型性能对数据量敏感,而 GAN 的强生成能力使其在数据稀缺时仍能保持较高精度,特别适合直流故障检测这类数据获取困难的场景。

4 结语

本文提出了基于 Transformer 算法优化 GAN 模型的柔性直流配电网故障检测方法,实现了故障的准确检测。试验结果表明:通过自适应 VMD 对故障信号分解和处理,实现了信号有效模态分量的准确提取;Transformer 对处理后的信号完成了特征向量的全局准确提取;通过基于 Transformer 算法替代 GAN 模型生成器建立的 TransGAN 深度学习模型实现了直流配电网故障的准确检测;相比于现有方法,本文提出方法的检测精度更高、实用性强,对数据量的要求更低,尤其是降低了数据获取成本和计算复杂度,提升了模型的实际应用价值和工程可行性,并为直流配电网故障定位和故障清除及恢复提供重要技术支撑。

利益冲突声明

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

作者贡献

曾飞进行了方案设计、内容总结与论文撰写,叶保璇进行了试验研究,余盛达参与了论文的审核与修改。所有作者均阅读并同意了最终稿件的提交。

The scheme design, content summary and paper writing were carried out by Zeng Fei. The experiment was conducted by Ye Baoxuan. The manuscript was revised by Yu Shengda. All authors have read and approved the finnal version of the paper for submission.

参考文献

[1] 舒印彪,赵勇,赵良,等.“双碳”目标下我国能源电力低碳转型路径[J].中国电机工程学报,2023,43(5):1663-1672.

SHU Y B, ZHAO Y, ZHAO L, et al. Study on low carbon energy transition path toward carbon peak and carbon neutrality [J]. Proceedings of the CSEE, 2023, 43(5): 1663-1672.

[2] 马钊,张恒旭,赵浩然,等.双碳目标下配用电系

- 统的新使命和新挑战[J]. 中国电机工程报, 2022, 42(19): 6931-6945.
- MA Z, ZHANG H X, ZHAO H R, et al. New mission and challenge of power distribution and consumption system under dual-carbon target [J]. Proceedings of the CSEE, 2022, 42(19): 6931-6945.
- [3] 周孝信, 赵强, 张玉琼, 等. “双碳”目标下我国能源电力系统发展趋势分析: 绿电替代与绿氢替代[J]. 中国电机工程学报, 2024, 44(17): 6707-6721.
- ZHOU X X, ZHAO Q, ZHANG Y Q, et al. Analysis of the development trend of China's energy and power system under the dual carbon target: Green electricity substitution and green hydrogen substitution [J]. Proceedings of the CSEE, 2024, 44(17): 6707-6721.
- [4] 周珊, 张伟杰, 许丹宁, 等. 基于模糊二阶高通滤波的光伏混合储能直流微网的功率分配控制[J]. 电机与控制应用, 2025, 52(1): 52-63.
- ZHOU S, ZHANG W J, XU D N, et al. Power allocation control of photovoltaic hybrid energy storage DC microgrid based on fuzzy second-order high-pass filtering [J]. Electric Machines & Control Application, 2025, 52(1): 52-63.
- [5] 李伟军, 李天友, 苏俊. 基于随机森林的光伏直流侧串联电弧故障检测方法[J]. 供用电, 2025, 42(2): 108-115.
- LI W J, LI T Y, SU J. Series arc fault detection method for photovoltaic DC side based on random forest [J]. Distribution & Utilization, 2025, 42(2): 108-115.
- [6] 豆敏娜, 田影, 王毅钊, 等. 基于积分面积的直流配网单极接地故障选线方法[J]. 电网与清洁能源, 2025, 41(1): 10-16.
- DOU M N, TIAN Y, WANG Y Z, et al. A single-pole ground fault selection method for DC distribution networks based on integral area [J]. Power System and Clean Energy, 2025, 41(1): 10-16.
- [7] 温伟杰, 胡铁伟, 陈晓龙, 等. 典型配电故障下直流偏置电压形成及电压互感器熔断分析[J]. 电工技术学报, 2025, 40(1): 226-240.
- WEN W J, HU T W, CHEN X L, et al. Analysis of DC bias voltage formation and voltage transformer melting under typical distribution faults [J]. Transactions on China Electrotechnical Society,
- 2025, 40(1): 226-240.
- [8] POMPODAKIS E E, KRYONIDIS G C, DEMOULIAS C, et al. A generic power flow algorithm for unbalanced islanded hybrid AC/DC microgrids [J]. IEEE Transactions on Power Systems, 2021, 36(2): 1107-1120.
- [9] 韦延方, 杨萍, 杨湛晔, 等. 基于 EWT 改进限流电抗电压的柔性直流配电网故障保护方法[J]. 电力系统保护与控制, 2024, 52(23): 22-32.
- WEI Y F, YANG P, YANG Z Y, et al. An improved fault protection method for a flexible DC distribution network based on EWT current limiting reactance voltage [J]. Power System Protection and Control, 2024, 52(23): 22-32.
- [10] YADAV N, TUMMURU N R. Filter capacitor current dynamics-based frequency-domain fault detection approach for grid-connected low-voltage DC microgrid [J]. IEEE Transactions on Industrial Electronics, 2023, 70(12): 12784-12794.
- [11] 韦延方, 王志杰, 王鹏, 等. 基于限流电抗电压的柔性直流配电网故障保护方法[J]. 高电压技术, 2022, 48(12): 5068-5079.
- WEI Y F, WANG Z J, WANG P, et al. Protection method for flexible DC distribution network faults based on current limiting reactance voltage [J]. High Voltage Engineering, 2022, 48(12): 5068-5079.
- [12] 陈田田, 赵振廷, 李银红. 不依赖边界元件的柔性直流电网反时限过流保护配置方案[J]. 电力系统保护与控制, 2023, 51(16): 48-58.
- CHEN T T, ZHAO Z T, LI Y H. Inverse time overcurrent protection configuration scheme for a flexible DC power grid independent of boundary components [J]. Power System Protection and Control, 2023, 51(16): 48-58.
- [13] WANG B L, LIU Y, YUE K, et al. Improved dynamic state estimation based protection on transmission lines in MMC-HVDC grids [J]. IEEE Transactions on Power Delivery, 2022, 37(5): 3567-3581.
- [14] 贾科, 刘鑫, 钮厚敏, 等. 基于六次谐波分量的柔性直流电网后备保护[J]. 电网技术, 2023, 47(2): 784-793.
- JIA K, LIU X, NIU H M, et al. Backup protection of flexible DC power grid based on sixth harmonic component [J]. Power System Technology, 2023, 47(2): 784-793.

- [15] 杨志勇, 杨炳元, 任永峰, 等. 基于单端高频电流量的 MMC-MTDC 输电线路保护方案[J]. 电力系统保护与控制, 2022, 50(14): 151-160.
YANG Z Y, YANG B Y, REN Y F, et al. Transmission line protection scheme of MMC-MTDC based on single terminal high frequency current [J]. Power System Protection and Control, 2022, 50(14): 151-160.
- [16] 王晓卫, 高杰, 吴磊, 等. 柔性直流配电网高阻接地故障检测方法[J]. 电工技术学报, 2019, 34(13): 2806-2819.
WANG X W, GAO J, WU L, et al. A high impedance fault detection method for flexible DC distribution network [J]. Transactions on China Electrotechnical Society, 2019, 34(13): 2806-2819.
- [17] 韦延方, 王志杰, 王鹏, 等. 基于 VMD 模糊熵与 GG 聚类的直流配电网故障检测方法[J]. 电机与控制学报, 2024, 28(2): 129-141.
WEI Y F, WANG Z J, WANG P, et al. Fault detection method for DC distribution network based on VMD fuzzy entropy and GG clustering [J]. Electric Machines and Control, 2024, 28(2): 129-141.
- [18] 王思华, 王羚佰. 基于 SAO-VMD-S 的双端柔性直流输电故障测距方案[J]. 电力系统保护与控制, 2025, 53(1): 1-12.
WANG S H, WANG L B. Fault location scheme for dual-terminal flexible DC transmission based on SAO-VMD-S [J]. Power System Protection and Control, 2025, 53(1): 1-12.
- [19] 徐岩, 刘婧妍, 张诗杭, 等. 基于遗传算法的直流配电网线路故障定位方法[J]. 太阳能学报, 2020, 41(12): 1-8.
XU Y, LIU J Y, ZHANG S H, et al. Fault location method based on genetic algorithm for DC distribution network [J]. Acta Energaie Solaris Sincia, 2020, 41(12): 1-8.
- [20] 张晓华, 袁肖赟, 杨红英, 等. 基于 GNN 的电网动态特性评估及其知识图谱应用[J]. 华中科技大学学报(自然科学版), 2023, 51(3): 47-51+59.
ZHANG X H, YUAN X Y, YANG H Y, et al. Evaluation of dynamic characteristics of power grid based on GNN and application on knowledge graph [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2023, 51(3): 47-51+59.
- [21] 刁晓虹, 董昊, 侯磊, 等. 基于 CEEMDAN-HT 和 SAE 的直流故障电弧诊断方法研究[J]. 电网与清洁能源, 2023, 39(10): 1-8+18.
DIAO X H, DONG H, HOU L, et al. Research on the DC fault arc detection method based on CEEMDAN-HT and SAE [J]. Power System and Clean Energy, 2023, 39(10): 1-8+18.
- [22] 曹浩, 黄韬, 周舟, 等. 基于主成分分析法的变压器直流偏磁声学异常检测[J]. 湖南电力, 2021, 41(5): 1-6.
CAO H, HUANG T, ZHOU Z, et al. Detection of DC bias magnetic acoustic abnormality of transformer based on principal component analysis [J]. Hu'nan Electric Power, 2021, 41(5): 1-6.
- [23] 胡伟, 沈煜, 刘浴霜, 等. 改进支持向量机的 MMC-HVDC 系统故障识别[J]. 智慧电力, 2019, 47(7): 91-97.
HU W, SHEN Y, LIU Y S, et al. MMC-HVDC system fault identification based on modified support vector machines [J]. Smart Power, 2019, 47(7): 91-97.
- [24] 王鹤, 韦搏, 李石强, 等. 基于贝叶斯网络信息融合的直流配电网故障诊断方法[J]. 电力系统保护与控制, 2024, 52(5): 61-72.
WANG H, WEI B, LI S Q, et al. Fault diagnosis of a DC distribution network based on Bayesian network information fusion [J]. Power System Protection and Control, 2024, 52(5): 61-72.
- [25] JAYAMAHA D, LIDULA N W A, RAJAPAKSE A D. Wavelet-multi resolution analysis based ANN architecture for fault detection and localization in DC microgrids [J]. IEEE Access, 2019, 7: 145371-145384.
- [26] 刘浩宇, 刘挺坚, 刘友波, 等. 基于图卷积神经网络的直流送端系统暂态过电压评估[J]. 电力系统保护与控制, 2023, 51(23): 71-81.
LIU H Y, LIU T J, LIU Y B, et al. A method for evaluating transient overvoltage of an HVDC sending-end system based on a graph convolutional network [J]. Power System Protection and Control, 2023, 51(23): 71-81.
- [27] 王颖, 朱大伟, 郑迪, 等. 基于 Bi-LSTM-Attention 的直流配电网故障检测方法[J/OL]. 华北电力大学学报(自然科学版), 2025-3-2. <https://link.cnki.net/urlid/13.1212.TM.20240423.1129.002>.

- WANG Y, ZHU D A, ZHENG D, et al. Fault detection method of DC distribution network based on Bi-LSTM-Attention [J/OL]. Journal of North China Electric Power University (Natural Science Edition), 2025-3-2. <https://link.cnki.net/urlid/13.1212.TM.20240423.1129.002>.
- [28] 陈臣鹏, 陈仕龙, 毕贵红, 等. 基于并联 CNN-LSTM 的弱受端直流输电系统故障诊断[J]. 电机与控制应用, 2022, 49(6): 83-91.
- CHEN C P, CHEN S L, BI G H, et al. Fault diagnosis of weak receiving DC transmission system based on parallel CNN-LSTM [J]. Electric Machines & Control Application, 2022, 49(6): 83-91.
- [29] 杨隽豪, 韦延方, 王鹏, 等. 基于 Swin Transformer 的柔性直流电网单端量故障诊断[J]. 电力建设, 2023, 44(5): 53-60.
- YANG J H, WEI Y F, WANG P, et al. Single-ended fault diagnosis of flexible DC grid based on Swin Transformer [J]. Electric Power Construction, 2023, 44(5): 53-60.
- [30] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. Communications of the ACM, 2020, 63(11): 139-144.
- [31] YANG Y C, HUANG C, XU Q M. A fault location method suitable for low-voltage DC line [J]. IEEE Transactions on Power Delivery, 2020, 35(1): 194-204.
-
- 收稿日期:2025-04-11
收到修改稿日期:2025-06-06
作者简介:
曾 飞(1982-),男,博士,高级工程师,研究方向为人工智能在电力系统中的应用,zhoukuisf@126.com;
*通信作者:曾 飞(1982-),男,博士,高级工程师,研究方向为人工智能在电力系统中的应用,zhoukuisf@126.com。