

DOI: 10.12158/j.2096-3203.2025.02.017

基于行波特征与 KOA-CNN-BiGRU-AM 的柔直 输电线路故障诊断

余波, 高学军, 王灿, 李瑞灵, 徐彦彬, 荣梦杰

(三峡大学电气与新能源学院, 湖北宜昌 443002)

摘要:针对多端柔性直流电网(multi-terminal direct current grid based on modular multilevel converter, MMC-MTDC)故障诊断存在的人工整定阈值过程复杂、高阻故障不易检测的问题,提出一种基于行波特征的诊断方法。首先,通过分析系统的故障特征,得出边界元件对高频信号的阻滞作用;其次,利用经验模态分解(empirical mode decomposition, EMD)对功率进行分解,得到本征模态函数(intrinsic mode function, IMF)分量,将其能量值作为故障特征量训练由卷积神经网络(convolutional neural network, CNN)和双向门控循环单元(bidirectional gated recurrent unit, BiGRU)组成的 CNN-BiGRU 网络;然后,采用开普勒优化算法(Kepler optimization algorithm, KOA)和注意力机制(attention mechanism, AM)对 CNN-BiGRU 网络进行改进,实现 MMC-MTDC 的故障诊断;最后,在 PSCAD/EMTDC 中搭建仿真模型。结果表明,该方法不仅可以实现母线故障和线路故障的检测,还可以在满足保护可靠性和速动性的前提下,解决高阻故障保护易拒动的问题。

关键词:多端柔性直流电网(MMT-MTDC);故障特性;经验模态分解(EMD);开普勒优化算法(KOA);注意力机制(AM);卷积神经网络(CNN);双向门控循环单元(BiGRU);故障诊断

中图分类号:TM712; TM773; TP18 **文献标志码:**A **文章编号:**2096-3203(2025)02-0185-12

0 引言

我国的可再生能源分布与电力需求存在逆向分布趋势,多端柔性直流电网(multi-terminal direct current grid based on modular multilevel converter, MMC-MTDC)具有控制灵活、无换相失败等优势^[1-4],适合长距离、大容量输电。但 MMC-MTDC 的发展面临一些关键技术问题,其中之一便是如何快速而可靠地检测直流线路中的故障^[5]。

目前,MMC-MTDC 的故障检测方法主要分为时域、频域和人工智能。基于时域的方法关注信号的时域瞬态特性,如直流线路电压电流的变化率^[6]。文献[7]利用限流电抗器两端的电压变化率进行故障检测,但该方法对抗干扰较为敏感。文献[8]基于电流变化率的特征来识别柔性直流输电线路的故障极点,虽然具备较高的敏感性和可靠性,但在高电阻情况下存在难以及时检测和隔离故障的问题。同时,为了提高保护的灵敏性,基于时域的方法通常要求较高的采样频率^[9]。

基于频域的方法关注信号的频率特性,通常采用傅里叶变换、小波变换和希尔伯特黄变换等信号处理方法来提取频率信息。文献[10]利用边界元件特性,通过线路侧与母线侧暂态电压的中高频分

量进行故障诊断。文献[11]中保护方案基于线路边界特定频带能量比值,能够快速识别区内外故障,但需要双端电气量并人工计算整定值。

基于人工智能的方法避免了人工计算整定值这一繁琐的过程,通过智能算法对故障数据进行学习和训练,无须设置定值即可实现故障诊断^[12]。目前,智能定位方法存在依赖高采样率、高阻故障不易检测等问题。如文献[13]使用希尔伯特黄变换提取时间、能量和频率特征,并结合支持向量机和蝙蝠算法进行故障诊断,但在采样频率较低时定位精度差。文献[14]采用 S 变换提取高频特征量,并使用极限学习机进行故障诊断,但仅采用电流数据作为输入,在高阻故障下性能较差。

直流故障数据多呈现非线性时间维度特征^[15],故文中提出一种基于行波特征和开普勒优化算法(Kepler optimization algorithm, KOA)-卷积神经网络(convolutional neural network, CNN)-双向门控循环单元(bidirectional gated recurrent unit, BiGRU)-注意力机制(attention mechanism, AM)的故障诊断方案。首先,分析系统故障特征,发现边界元件对高频信号的阻滞作用,并利用经验模态分解(empirical mode decomposition, EMD)对线路功率进行特征提取,构造故障判据。其次,利用 KOA 进行模型参数寻优,避免陷入参数人为选定的局部最优问题;利用 AM 改进 BiGRU 模型,使模型更加关注数据的

收稿日期:2024-06-23;修回日期:2024-09-12

基金项目:国家自然科学基金资助项目(52107108)

重要部分,提高模型性能,利用改进后的模型实现故障诊断。最后,在PSCAD/EMTDC中搭建四端仿真模型,验证该方案的可行性。结果表明,文中所提方案适用于MMC-MTDC的直流线路和直流母线保护,其准确性高、耐过渡电阻能力强、抗干扰性能好。

1 基于模块化多电平换流器的直流电网故障特性分析

1.1 四端柔性直流电网拓扑

图1为半桥型模块化多电平换流器(modular multilevel converter, MMC)直流电网的典型拓扑。该系统利用固态断路器(solid state circuit breaker, SSCB)进行故障隔离。为了抑制故障电流的上升速度,架空线(overhead line, OHL)两侧安装了限流电抗器,大小为0.2 H。架空线采用频率依赖模型。系统为对称双极系统,参数见表1。

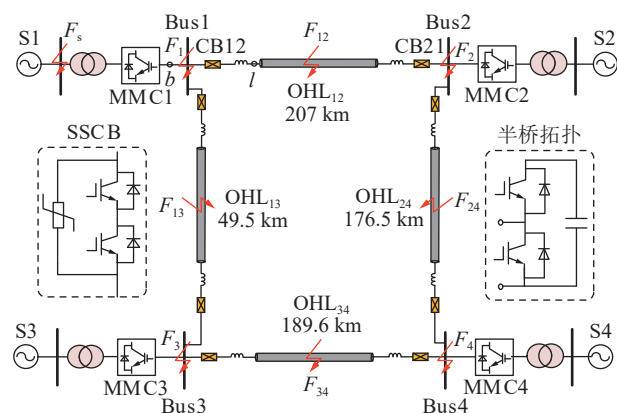


图1 四端柔性直流输电系统

Fig.1 Four-terminal flexible direct transmission system

表1 系统参数

Table 1 System parameters

换流站	额定电压/kV	额定功率/GW	桥臂电感/mH	子模块电容/mF	子模块数N
MMC1	±500	1.5	40	15	100
MMC2	±500	1.5	75	15	100
MMC3	±500	3	40	15	100
MMC4	±500	3	40	15	100

图1中,S1—S4为交流侧电源;MMC1—MMC4为换流站;CB12、CB21分别为架空线OHL₁₂两侧的固态断路器;F₁—F₄为母线Bus1—Bus4上的故障点;F₁₂、F₁₃、F₃₄、F₂₄分别为输电线路OHL₁₂、OHL₁₃、OHL₃₄、OHL₂₄上的故障点;F₅为交流侧故障点;b、l为录波装置安装处,即测量点。当系统发生故障时,保护装置应能够有选择性地切除故障部分,以保证非故障部分能继续运行,最小化停电范

围。因此,当母线故障时,与母线相邻的全部断路器都要断开;当直流线路故障时,断开相应的断路器即可。

1.2 故障特性分析

架空线两侧的限流电抗器为MMC-MTDC的保护提供了边界条件。根据叠加定理,故障发生后系统可以分成正常网络和故障网络。图2为F₁₂发生故障时,零模和线模分量的Peterson等效电路。图中,U_{fi}为故障模态电压,i为0时表示零模分量,i为1时表示线模分量,下文含义相同;Z_{Ci,12}、Z_{Ci,13}分别为OHL₁₂、OHL₁₃的模量波阻抗;Z_{T1}、Z_{T3}分别为MMC1、MMC3的等效阻抗;Z_d为限流电抗器阻抗。




图2 区内故障模量等效网络

Fig.2 Internal fault modulus equivalent network

由图2可以看出,b点和l点的电流、电压关系为:

$$\begin{cases} \frac{\Delta i_{bi}}{\Delta i_{li}} = \frac{Z_{T3} + Z_{Ci,13} + Z_d}{Z_{T1} + Z_{T3} + Z_{Ci,13} + Z_d} \\ \frac{\Delta u_{bi}}{\Delta u_{li}} = \frac{Z_d}{Z_d + Z_{eqi}} \end{cases} \quad (1)$$

式中:Δi_{bi}、Δi_{li}分别为测量点b和l的电流模态分量;Δu_{bi}、Δu_{li}分别为测量点b和l的电压模态分量;Z_{eqi}为等效模态阻抗。

$$Z_{eqi} = \frac{Z_{T1}(Z_d + Z_{Ci,13} + Z_{T3})}{Z_{T1} + Z_d + Z_{Ci,13} + Z_{T3}} \quad (2)$$

文献[16-17]指出,流过线路的电流频率或者两端电压频率过高时,换流站可等效为电抗。同时,考虑到零模阻抗Z_{C0}大于线模阻抗Z_{C1}^[18],因此,式(1)可转换为式(3)。由式(3)可知,区内故障时测量点b的电流电压高频远小于测量点l的电流电压高频,这表明限流电抗器对高频分量具有阻滞作用。这种故障特征为选线提供了一种潜在方法。

$$\begin{cases} \left| \frac{\Delta i_{bi}}{\Delta i_{li}} \right| = \left| \frac{L_{T3} + Z_{C0,13} + L_d}{L_{T3} + Z_{C0,13} + L_d + L_{T1}} \right| \\ \left| \frac{\Delta u_{bi}}{\Delta u_{li}} \right| = \left| \frac{L_d}{L_d + Z_{eq0}} \right| \end{cases} \quad (3)$$

式中:L_{T1}、L_{T3}分别为高频下MMC1和MMC3的等效电抗;L_d为架空线两侧限流电抗器的电抗值。

发生故障时,利用相模变换将故障电压分解为零模分量ΔU₀和线模分量ΔU₁:

$$\begin{cases} \Delta U_0 = -\frac{\sqrt{2}Z_{eq0}U_{ns}}{Z_{eq0}+Z_{eq1}+2R_g} \\ \Delta U_1 = -\frac{\sqrt{2}Z_{eq1}U_{ns}}{Z_{eq0}+Z_{eq1}+2R_g} \end{cases} \quad (4)$$

式中: U_{ns} 为系统正常运行时点对地的电压; R_g 为过渡电阻。由式(4)得故障线路正极电压 ΔU_p 与负极电压 ΔU_N 之比为:

$$\left| \frac{\Delta U_p}{\Delta U_N} \right| = \left| \frac{\Delta U_0 + \Delta U_1}{\Delta U_0 - \Delta U_1} \right| = \left| \frac{Z_{eq0} + Z_{eq1}}{Z_{eq0} - Z_{eq1}} \right| \quad (5)$$

发生正极故障时, $\Delta U_p > \Delta U_N$; 发生负极故障时, $\Delta U_p < \Delta U_N$; 发生双极故障时, $\Delta U_p = \Delta U_N$ 。这种故障特征为选极提供了一种潜在方法。

1.3 区内外故障的频谱分析

分别对稳态下测量点 b 和 l 进行功率频谱分析, 以正极为例, 其特性如图 3 所示。可以看出, 系统处于稳态时, 线路功率几乎不含高频分量。




图 3 稳态下的功率频谱

Fig.3 Power spectrum in steady state

分别在线路 OHL₁₂ 中点、母线 Bus1 和区外设置极间短路, 并分别提取测量点的功率进行频谱分析, 以正极功率频谱为例, 如图 4 所示。

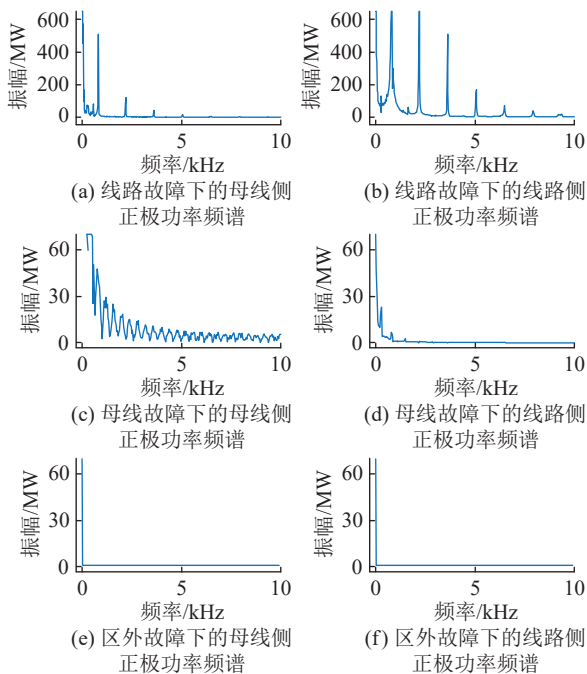


图 4 不同位置故障下的功率频谱

Fig.4 Power spectrum when faults occur at different locations

由图 4(a)、(b)可以看出, 直流线路发生双极短路时, 功率会出现明显的振荡。直流线路在高频段具有大量的暂态能量, 而母线由于限流电抗器的作用在高频段内的暂态能量较少。由图 4(c)、(d)可以看出, 母线发生双极短路时, 母线的高频段内具有大量的暂态能量, 而直流线路在高频段内的暂态能量较少, 与区内故障时呈现出相反的特性。由图 4(e)、(f)可以看出, 发生区外故障时, 由于边界元件的作用, 母线处和直流线路处功率的高频量都很小, 这与区内故障和母线故障时的特性完全不同。

综上所述, 发生区内故障、母线故障和区外故障时, 测量点处功率的高低频分量均呈现出不同的特性, 因此利用功率的频率特性可以实现故障选线。

1.4 不同极故障的频谱分析

由式(5)分析可得, 在双极高压直流输电系统中, 单极故障时, 故障极的电压故障分量幅值较正常极幅值振荡显著; 极间故障时, 两极之间的电压故障分量幅值相近。以线路 OHL₁₂ 中点处分别发生双极短路和正极短路故障为例, 得到图 5 所示极电压波形。对图 5 的正极故障进行频谱分析, 如图 6 所示。




图 5 故障时的电压特征

Fig.5 Voltage characteristic when faults occur




图 6 正极故障下的电压频谱

Fig.6 Pole voltage spectrum when positive pole fault occurs

由图 5 和图 6 可以看出, 当系统发生故障时, 故障极的电压故障分量波动幅度大, 高频分量丰富, 因此利用极电压的高频特性可实现故障选极。

1.5 故障特征量的选定

1.5.1 启动判据

启动判据是为了避免线路正常的波动引起保护系统的频繁启动。考虑到利用电压变化率作为故障启动元件在高阻下无法正常启动, 文中利用

Teager 能量算子 (Teager energy operator, TEO) 作为启动判据。将 TEO 运用于直流电压信号, 以突出信号中的能量变化。

连续时间信号 $x(t)$ 的 TEO 定义为:

$$\varphi(x(t)) = (\dot{x}(t))^2 - x(t)\ddot{x}(t) \quad (6)$$

式中: $\varphi(x(t))$ 为连续时间信号 $x(t)$ 的瞬时能量值; $\dot{x}(t)$ 、 $\ddot{x}(t)$ 分别为信号 $x(t)$ 的一阶导数和二阶导数。

离散信号 $x(n)$ 的 TEO 定义为:

$$\varphi(x(n)) = (x(n))^2 - x(n+1)x(n-1) \quad (7)$$

式中: $\varphi(x(n))$ 为离散信号 $x(n)$ 的瞬时能量值; $x(n)$ 、 $x(n+1)$ 、 $x(n-1)$ 分别为采样点 n 、 $n+1$ 、 $n-1$ 的信号。

当直流电压的瞬时能量值超过阈值 φ_{set} 后, 保护启动, 如式(8)所示。

$$|\varphi(x(n))| > \varphi_{\text{set}} \quad (8)$$

为了保证在高阻情况下保护仍能可靠启动, 文中需要考虑线路高阻接地故障的情况, 表 2 为不同故障位置和过渡电阻下瞬时能量值的阈值。分析表 2 可知, 发生不同故障时, 最小阈值为 2 000, 故文中取 φ_{set} 为 2 000。

表 2 不同故障下的阈值
Table 2 Threshold values under different faults

故障类型	过渡电阻/ Ω	φ_{set}	
		Bus1 母线故障	线路 100% 处故障
单极故障	600	2 700	2 200
	1 000	2 500	2 000
双极故障	600	2 500	2 200
	1 000	2 400	2 000

1.5.2 基于 EMD 的故障特征量

EMD 在多频叠加信号分解方面具有很好的效果, 可自适应地将非平稳信号平稳化, 不用选择基函数^[19]。因此文中选取 EMD 对信号进行处理。EMD 步骤如下:

- (1) 寻找原始信号极值点。
- (2) 用包络线对极值点进行拟合, 对极大值和极小值分别进行上包络和下包络拟合。
- (3) 计算包络线均值。
- (4) 计算原始信号与均值的差, 即中间信号。
- (5) 判断中间信号是否满足本征模态函数 (intrinsic mode function, IMF) 分量条件, 若不满足则回到步骤(1)。
- (6) 满足分量条件的中间信号则作为原始信号重复以上步骤继续进行分解。

原始信号 $s(t)$ 为各阶 IMF 分量与残余函数的叠加, 即:

$$s(t) = \sum_{j=1}^J c_j(t) + r_j(t) \quad (9)$$

式中: $c_j(t)$ 为第 j 阶 IMF 分量; J 为 IMF 分量阶数; $c_j(t)$ 从高频至低频对信号进行表征, 每个分量对应于信号中的一个本地振荡模式; $r_j(t)$ 为残余函数, 代表信号的平均趋势, 即故障信号的变化方向^[20]。

分析故障特性可知, 发生故障时, 不同区间正负极线路的高频分量存在较大区别, 故文中利用 EMD 对测量点 b 和 l 的正负极功率进行分解, 并提取频率最高的 IMF1 分量, 利用式(10)计算母线正极能量 $E_{\text{P-bus}}$ 、母线负极能量 $E_{\text{N-bus}}$ 、直流线路正极能量 $E_{\text{P-line}}$ 、直流线路负极能量 $E_{\text{N-line}}$, 将其作为故障特征量输入到神经网络中。

$$E = \sum_{i=1}^N c_i^2 \quad (10)$$

式中: c_i 为 IMF1 中的第 i 个元素; N 为元素的个数。

2 基于 KOA-CNN-BiGRU-AM 的诊断方案

2.1 KOA

KOA 是一种基于物理学的元启发式算法, 其基于开普勒行星运动定律, 可以预测行星在任何时间的位置和速度。每个行星的位置都是一个候选解, 且在优化过程中随机更新, 以寻找最优解^[21]。KOA 的搜索过程可以简单概括为以下 4 个步骤:

- (1) 在多维空间中随机分布 K 个行星 (求解的参数量)。
- (2) 根据万有引力定律模拟太阳对行星 k 的引力 $F_{gk}(t)$ 和速度 $V_k(t)$ 。
- (3) 考虑到物体绕太阳公转轨迹是个椭圆, 算法根据行星与太阳之间的距离更新最优解。当该距离较远时, 利用式(11)更新每个远离太阳的行星的新位置, 否则利用式(12)进行更新。这种策略旨在平衡局部搜索和全局搜索的需求, 从而提高算法的性能和鲁棒性。

$$\vec{X}_k(t+1) = (F_{gk}(t) + |r|) \vec{U}(\vec{X}_s(t) - \vec{X}_k(t)) + \vec{X}_k(t) + \lambda V_k(t) \quad (11)$$

式中: $\vec{X}_k(t+1)$ 、 $\vec{X}_k(t)$ 分别为行星 k 的新位置和上一次位置; r 为根据正态分布随机生成的个数; \vec{U} 为 0 或 1 的条件函数; $\vec{X}_s(t)$ 为目前为止发现的太阳的最佳位置; λ 为 1 或 -1 的条件函数。

$$\vec{X}_k(t+1) = (1 - \vec{U}_1) \left[\frac{\vec{X}_k(t) + \vec{X}_s + \vec{X}_a(t)}{3} + h \left(\frac{\vec{X}_k(t) + \vec{X}_s + \vec{X}_a(t)}{3} - \vec{X}_b(t) \right) \right] + \vec{X}_s(t) \vec{U}_1 \quad (12)$$

式中: \vec{U}_1 为 0 或 1 的条件函数; h 为 t 时刻太阳与当前行星距离的自适应因子; $\vec{X}_a(t)$ 、 $\vec{X}_b(t)$ 为从当前全部方案中随机选择的方案。

(4) 评估新解的适应度以确定最优解。

2.2 CNN

CNN 是一种前馈神经网络, 设计灵感来源于生物学中对视觉系统的理解, 模仿了人类视觉系统中的感受野和分层抽象的特点, 其优势在于通过卷积操作挖掘数据的潜在关联和局部空间特征^[22-25], 以提高模型的效率和精确性。CNN 结构包括输入层、卷积层、池化层、全连接层和输出层, 如图 7 所示, 其中 GRU 为门控循环单元。卷积层是 CNN 的核心, 通过卷积核与输入数据之间的卷积操作获得潜在特征, 其数学表达为式(13); 池化层的作用是在保持特征不变的前提下去除一些冗余信息, 实现数据降维^[26]; 全连接层将池化层的输出映射到一个平坦的向量。




图 7 CNN 层结构

Fig.7 Layer structure of CNN

$$\mathbf{x}_{op} = f(\mathbf{x}_{o-1} * \omega_{op} + \mathbf{b}_{op}) \quad (13)$$

式中: \mathbf{x}_{op} 为第 o 层输出的第 i 个特征; f 为卷积函数; \mathbf{x}_{o-1} 为第 $o-1$ 层的输出; ω_{op} 为第 o 层第 p 个卷积核的权重矩阵; \mathbf{b}_{op} 为第 o 层第 p 个卷积核的偏置项; $*$ 为卷积算子。

2.3 BiGRU

长短时记忆(long short-term memory, LSTM)是一种循环神经网络模型^[27], 其内部结构复杂, 训练时间长。相比于 LSTM, GRU 参数更少, 收敛速度更快, 但只考虑了单向信息。BiGRU 引入了反向循环, 由 2 层 GRU 构成, 分别从正向与反向处理序列, 可以充分捕捉时序信息, 并将隐藏神经元的隐藏向量拼接作为最终的输出结果^[28]。具备门控机制的 BiGRU 能够在学习过程中选择性地传递信

息, 包括遗忘门、更新门和输出门, 从而有效缓解梯度消失问题, 提高对整个序列中复杂关系的理解和建模能力, 适用于直流线路的故障诊断, 其结构见图 8。图中, \vec{h}_t 、 \overleftarrow{h}_t 分别为 t 时刻前向和后向输出; \vec{h}_{t+1} 、 \overleftarrow{h}_{t+1} 分别为 $t+1$ 时刻前向和后向输出; \vec{h}_{t-1} 、 \overleftarrow{h}_{t-1} 分别为 $t-1$ 时刻前向和后向输出; y_t 为 t 时刻输出; x_t 为 t 时刻输入。




图 8 BiGRU 层结构

Fig.8 Layer structure of BiGRU

BiGRU 的表达式为:

$$\vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}) \quad (14)$$

$$\overleftarrow{h}_t = \text{GRU}(x_t, \overleftarrow{h}_{t-1}) \quad (15)$$

$$y_t = \vec{h}_t \oplus \overleftarrow{h}_t \quad (16)$$

式中: $\text{GRU}(\cdot)$ 为对输入的非线性变换函数; \oplus 为按位加法。

2.4 AM

在模型中, AM 的主要目标是赋予关键特征更高的权重, 在模型训练时分配更多比重^[29], 从而在特征数据中突出重要信息。文中模型中, AM 被嵌入到 BiGRU 中, 输入 x_n 经过 CNN-BiGRU 模型输出 h_n , h_n 再经过权重 a_n 求和得到输出 y , 其结构如图 9 所示。




图 9 AM 结构

Fig.9 Structure of AM

2.5 基于 KOA-CNN-BiGRU-AM 的故障诊断模型

高压直流系统故障暂态波形表现出强烈的非线性特性和复杂的时序结构。CNN 可以从非线性数据中提取特征, 实现对数据的降维处理, 但在处理时序信号方面存在一定限制, 因此需要更具时序特征提取能力的模型。BiGRU 凭借其卓越的时序特征提取能力成为理想选择, 与故障暂态行波的时序特征相契合。但在 MMC-MTDC 中, 由于其涉及大量电力电子元件, 采集到的信号往往会受到一定强度的噪声干扰。BiGRU 模型的抗干扰能力相对较弱, 容易受到噪声的干扰而导致准确率下降。因此, 文中将 CNN 和 BiGRU 结合起来用于线路的故

障诊断。算法模型的结构如图 10 所示。

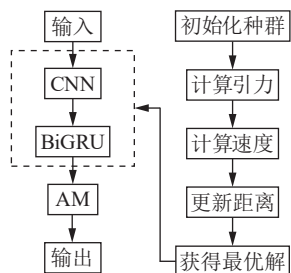


图 10 算法模型结构

Fig.10 Algorithm model structure

文中输入数据为 E_{P-bus} 、 E_{N-bus} 、 E_{P-line} 和 E_{N-line} 这 4 个故障因子。将数据平铺得到矩阵, CNN 经过一层的卷积层和池化层处理后得到更高级别的抽象特征表示,同时可以更好地用于后续 BiGRU 网络的特征提取和输出。BiGRU 网络能够有效捕捉时序数据中的依赖关系。AM 的引进加强了模型的特征能力,使得模型更专注于与故障检测和诊断相关的关键信息,从而提高模型的性能。CNN-BiGRU 模型的具体结构和参数如表 3 所示。

表 3 CNN-BiGRU 模型结构和参数

Table 3 Structure and parameters of CNN-BiGRU model

层数	结构
1	一维卷积层(1×2×32)
2	批归一化层
3	激活层(线性整流函数)
4	最大池化层(2×1)
5	展平层
6	BiGRU层(106)
7	自注意力层(1×10)
8	全连接层(7)
9	Softmax层
10	分类层

CNN-BiGRU 模型存在一些对诊断精度影响较大的超参数,因此文中对学习率、卷积核大小和神经元个数这 3 个参数进行寻优,结果见表 4。

表 4 参数寻优区间

Table 4 Parameter optimization interval

参数	寻优区间	寻优结果
学习率	[0.001, 0.1]	0.050 6
卷积核大小	[1, 2]	2
神经元个数	[100, 120]	106

3 仿真分析

利用 PSCAD/EMTDC 仿真平台搭建图 1 所示四端柔性直流输电系统,诊断流程如图 11 所示。

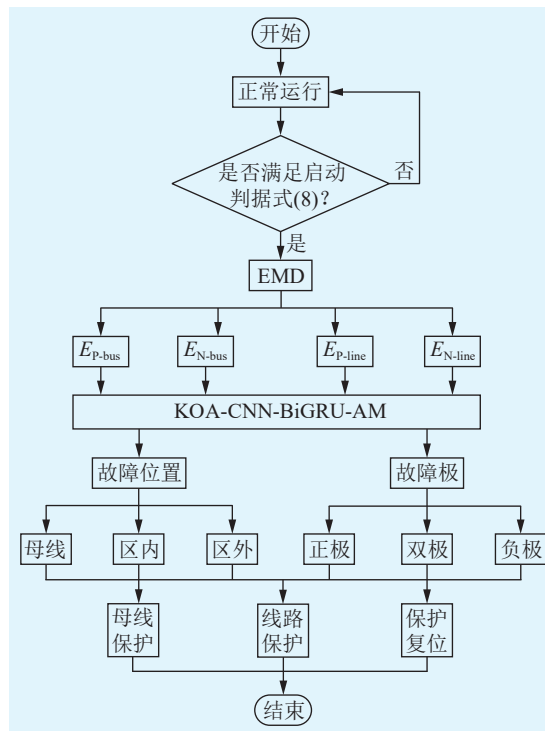


图 11 诊断流程

Fig.11 Diagnosis process

以 Bus1 和 OHL₁₂ 为例进行大量仿真来验证文中方案的可行性。采样频率为 20 kHz,采集不同情况下故障数据。故障位置包括区内外线路和母线;故障位置为每条线的 0%、25%、50%、75% 和 100% 处;过渡电阻为 0.01~1 000 Ω;故障类型包括双极短路故障与正负极短路故障。文中选取启动元件启动后 1.5 ms 内测量点 b 和 l 的功率数据,故障数据共 1 070 组,按 4 : 1 划分为训练集和验证集。经过 KOA-CNN-BiGRU-AM 模型离线训练后,验证集的混淆矩阵如图 12 所示。




图 12 验证集的混淆矩阵

Fig.12 Confusion matrix of validation set

由图 12 可以看出,验证集的准确度达到了 100%,说明文中模型在经过训练集的学习后,可以准确识别不同故障情况下的 7 种故障类型。

3.1 可靠性分析

利用训练集和验证集调整好模型参数后,分别

在直流线路 OHL₁₂ 的 20%、40%、60%、80% 处、OHL₁₃ 的 20% 处、OHL₂₄ 的 20% 处和母线 Bus1 上分别设置 3 种故障, 过渡电阻为 0.01~1 000 Ω (随机取 30 组电阻)。系统的保护情况如表 5 所示。

表 5 系统保护情况
Table 5 Protection status of the system

故障位置	故障类型	准确率/%
OHL ₁₂ 的20%处	双极	100
	正极	100
OHL ₁₂ 的40%处	双极	100
	正极	100
OHL ₁₂ 的60%处	双极	100
	正极	100
OHL ₁₂ 的80%处	双极	100
	正极	100
OHL ₁₃ 的20%处	双极(区外)	100
	正极(区外)	100
	负极(区外)	100
OHL ₂₄ 的20%处	双极(区外)	100
	正极(区外)	100
	负极(区外)	100
Bus1	双极	100
	正极	100
	负极	100

由表 5 可知, 该模型能准确识别文中的各种故障, 准确率高。以表中 OHL₁₂ 的正极故障、母线的正极故障以及 OHL₂₄ 的区外双极故障为例, 得到图 13 所示的测量点正负极功率的 IMF1 分量图。由图 13(a)、(b)可以看出, 直流线路和母线发生正极故障时, 故障侧的高频能量波动大于非故障侧; 负极因为线路存在耦合关系也会产生少量波动, 但波动程度远小于正极侧, 不会对诊断结果产生影响, 由此系统判定为区内线路正极故障, 线路保护动作。由图 13(c)可以看出, 发生区外故障时, 由于经过多个限流电抗器的阻滞作用, 两侧的高频分量几乎为 0, 由此系统判定为区外故障。

3.2 过渡电阻分析

非金属故障的过渡电阻较大, 为测试神经网络在非金属故障下的有效性, 采用不同故障电阻进行仿真测试。在不同位置设置过渡电阻为 800、900、1 000 Ω 的故障, 测试结果如表 6 所示。由表 6 可




图 13 各种故障下的 IMF1 分量

Fig.13 IMF1 component under various faults

知, 文中方法可以准确识别过渡电阻高达 1 000 Ω 的故障类型, 具有优良的耐过渡电阻能力。

表 6 不同过渡电阻下的测试结果

Table 6 Test results under different transition resistances

电阻/ Ω	故障位置	测试次数	准确率/%
800	区内	20	100
	母线	20	100
	区外	20	100
900	区内	20	100
	母线	20	100
	区外	20	100
1 000	区内	20	100
	母线	20	100
	区外	20	100

以表 6 中过渡电阻为 1 000 Ω 的区内正极故障为例, 得到电抗器两侧测量点的正负极功率的 IMF1 分量, 如图 14 所示。




图 14 过渡电阻 1 000 Ω 下 IMF1 分量

Fig.14 IMF1 component with transition resistance of 1 000 Ω

由图 14 可以看出, 在过渡电阻为 1 000 Ω 的情况下, 故障侧的高频分量仍远大于非故障侧, 因此系统会判定为区内线路正极故障。

3.3 交流故障分析

文中保护区为母线和直流线路,因此交流故障属于区外故障。以图 1 中 F_3 处发生三相交流故障为例。图 15 为过渡电阻 0.01Ω 时三相故障下直流电压波形,5 s 为故障发生时刻。由图 15 可以看出,直流电压波动小,由式(7)计算得到的最大 Teager 能量数值为 1 161,未达到门槛值,故保护未动作,由此可得文中方法不受交流故障影响。这也得益于柔性直流输电系统的特性:当交流侧发生故障时,通过其多电平输出、电容滤波、电压平衡控制和快速响应等特点,通常能够保持直流电压波动较小,维持电力系统的稳定性。




图 15 交流故障下电压波形

Fig.15 Voltage waveform under AC fault

3.4 潮流分布分析

当电力系统中出现负荷变化、发电站操作或可再生能源波动等现象时,系统的潮流分布可能会发生变化,影响电网稳定性和性能,故有必要验证系统潮流改变时文中保护的适用性。

文中系统在 5 s 时发生功率扰动,系统潮流分布改变,MMC1—MMC4 发出或接收的功率都相应减少,约 0.2 s 后系统稳定,在 5.3 s 时发生直流线路双极短路,MMC1—MMC4 的功率波形如图 16 所示。




图 16 换流站功率

Fig.16 Active power waveforms of converter stations

在 5.3 s 发生故障后,文中系统判定故障类型为区内双极短路,线路保护启动。图 17 为故障时直流电压波形和测量点处暂态能量波形。由图 17(a)可以看出,发生功率扰动时,电压波动程度未达到启动判据门槛,故保护不会误动作。由图 17(b)可以看出,双极故障后,线路侧功率的高频能量远比母线侧丰富,故线路保护启动。

系统潮流改变后,虽然换流站的功率发生改




图 17 静态扰动下故障波形

Fig.17 Fault waveforms under static disturbance

变,但电压信号波动并未像功率一样剧烈改变,故文中方法可以很好地在潮流改变的情况下保护系统。

3.5 泛化性分析

文中方案是基于高频能量的保护策略,电抗器的大小和线路长度决定了高频的削弱和阻滞作用,故有必要讨论文中方案的泛化性。

文中线路的电抗器大小为 0.2 H,线路长度为 207 km,分别讨论电抗器大小为 0.1、0.15、0.25 H,线路长度为 150、250、300 km 情况下,文中方案进行故障诊断的准确率,每种线路参数下设置 20 组故障进行仿真测试,测试结果如表 7 所示。

表 7 不同情况下模型的准确率

Table 7 The accuracy rate of the model under different conditions

线路长度/km	电抗器大小/H	模型准确率/%
150	0.10	100
	0.15	100
	0.25	100
250	0.10	100
	0.15	100
	0.25	100
300	0.10	100
	0.15	100
	0.25	100

由表 7 可知,文中方案存在一定的泛化性能,对于一定范围内的线路和电抗器同样适用。

3.6 速动性分析

对于母线和直流线路的保护不仅需要选择性,也需要速动性。针对张北±500 kV 柔性直流电网,国家电网公司要求保护系统在 6 ms 内实现故障的

隔离和清除^[30]。文中系统的检测速度主要取决于启动元件启动时间和数据时间窗时间。过渡电阻越大,故障位置越远,保护完成时间就越久。图 18 为 OHL₁₂ 末端发生过渡电阻为 1 000 Ω 的正极短路故障时电压的 TEO 波形。正极短路故障在采样点为 20 时发生。




图 18 TEO 波形
Fig.18 TEO waveform

由图 18 可以看出,故障发生 0.7 ms 后电压波动达到了门限值,系统开始采集 1.5 ms 数据,因此检测时间为 2.2 ms,满足速动性要求。

在实际工程化时,文中方案可以采用离线训练,在线测试的方式,既可以在离线环境中充分利用计算资源,考虑实际情况多次训练模型调整模型参数,优化模型结构来降低模型实际运行时的计算和内存需求,同时保证了在线测试时的准确率。若处理器性能限制导致无法同时满足高精度和快速性的要求,可考虑采用级联式保护系统,将传统主保护作为第一层保护,负责快速检测和处理常见故障,人工智能保护作为第二层保护,用于识别和处理主保护难以判断的故障情况,从而兼顾速度和准确性。

3.7 不同优化算法的比较

为验证 KOA 的优越性,将其与粒子群优化 (particle swarm optimization, PSO) 算法、蜣螂优化 (dung beetle optimizer, DBO) 算法、模拟退火 (simulated annealing, SA) 算法优化文中神经网络的效果进行对比,结果如图 19 所示。




图 19 不同优化算法的适应度曲线
Fig.19 The fitness curves of different optimization algorithms

由图 19 可以看出,相比于另外 3 种算法, KOA 不仅适应度更低,而且收敛速度快,表明 KOA 对文中神经网络具有很好的寻优性能。这是因为在启发式算法中,算法很容易陷入局部最优值问题。而在太阳系中,大多数物体都是逆时针绕太阳旋转的,但有些物体以顺时针方向围绕太阳公转, KOA 就是利用这种行为来逃离局部最优区域。

3.8 与其他文献方法的比较

将文中方法与其他文献方法进行对比,结果如表 8 所示。

表 8 方法对比
Table 8 Methods comparison

方法	保护区域	耐过渡电阻能力/Ω	采样率/kHz
文中方法	母线和直流线路	1 000	20
文献[31]	母线和直流线路	200	20
文献[32]	直流线路	2 000	100

文献[31]利用小波变换和双向长短时记忆网络进行故障识别,准确率高,满足系统速动性要求,但耐过渡电阻能力只有 200 Ω,远低于文中方法。

文献[32]利用格拉姆角差场和迁移残差网络,准确率高,耐过渡电阻能力达到 2 000 Ω,但该方案未考虑单独母线故障,且采样率高达 100 kHz,远高于文中的 20 kHz。

4 结论

针对当前四端柔性直流输电线路故障检测阈值人工计算整定复杂和耐受故障电阻能力差的问题,文中在分析故障行波传输特性的前提下,提出一种基于 EMD 和 KOA-CNN-BiGRU-AM 的故障诊断方法。通过仿真测试可以得出以下结论:

(1) EMD 可以很好地提取故障行波的特征,有助于神经网络获得更高的诊断准确度。

(2) KOA-CNN-BiGRU-AM 网络可以有效地从故障判据中提取关键特征,实现高准确率的故障诊断。

(3) 该方法不仅在 1 000 Ω 的高阻情况下仍能准确可靠地进行选线和选极,且满足速动性要求,不受潮流分布改变和交流侧故障的影响,对于具有相似线路参数的线路也同样适用。

文中利用行波的频率特性构造故障特征,但仅考虑了单极故障和双极故障,未考虑雷击干扰的影响,在故障特征的构造上仍有改进空间,并且文中保护方案只能用于故障选线和选极,后期可考虑改进方案进行故障测距以达到精确定位效果。

参考文献:

- [1] 邹常跃, 韦嵘晖, 冯俊杰, 等. 柔性直流输电发展现状及应用前景[J]. 南方电网技术, 2022, 16(3): 1-7.
ZOU Changyue, WEI Ronghui, FENG Junjie, et al. Development status and application prospect of VSC-HVDC[J]. Southern Power System Technology, 2022, 16(3): 1-7.
- [2] 管恩齐, 何晋, 骆通. 含直流潮流控制器的真双极多端柔性直流电网潮流计算研究[J]. 电力电容器与无功补偿, 2023, 44(2): 68-76.
GUAN Enqi, HE Jin, LUO Tong. Research on power flow calculation of true bipolar multi-terminal flexible DC power grid with DC power flow controller[J]. Power Capacitor & Reactive Power Compensation, 2023, 44(2): 68-76.
- [3] 侯婷, 刘涛, 杨柳, 等. 新一代高性能柔性直流背靠背技术及工程应用[J]. 南方能源建设, 2023, 10(5): 1-8.
HOU Ting, LIU Tao, YANG Liu, et al. New generation high-performance VSC-HVDC back-to-back technology and application in project[J]. Southern Energy Construction, 2023, 10(5): 1-8.
- [4] 赵平, 高亨孝, 贾浩森, 等. 基于自适应参考功率的多端柔直系统附加频率控制[J]. 电力建设, 2024, 45(9): 133-141.
ZHAO Ping, GAO Hengxiao, JIA Haosen, et al. Additional frequency control based on adaptive reference power for MTDC systems[J]. Electric Power Construction, 2024, 45(9): 133-141.
- [5] 陈力绪, 袁帅, 严俊, 等. 考虑多端协同的柔性直流电网直流故障保护和恢复策略[J]. 中国电机工程学报, 2022, 42(22): 8164-8177.
CHEN Lixu, YUAN Shuai, YAN Jun, et al. DC fault protection and recovery strategy for VSC-HVDC grid considering multi-terminal cooperation[J]. Proceedings of the CSEE, 2022, 42(22): 8164-8177.
- [6] HUANG Q, ZOU G B, WEI X Y, et al. A non-unit line protection scheme for MMC-based multi-terminal HVDC grid[J]. International Journal of Electrical Power & Energy Systems, 2019, 107: 1-9.
- [7] SNEATH J, RAJAPAKSE A D. Fault detection and interruption in an earthed HVDC grid using ROCOV and hybrid DC breakers[J]. IEEE Transactions on Power Delivery, 2016, 31(3): 973-981.
- [8] HALEEM N M, RAJAPAKSE A D. Fault-type discrimination in HVDC transmission lines using rate of change of local currents[J]. IEEE Transactions on Power Delivery, 2020, 35(1): 117-129.
- [9] LI Y J, WU L, LI J P, et al. DC fault detection in MTDC systems based on transient high frequency of current[J]. IEEE Transactions on Power Delivery, 2019, 34(3): 950-962.
- [10] LIU J, TAI N L, FAN C J. Transient-voltage-based protection scheme for DC line faults in the multiterminal VSC-HVDC system[J]. IEEE Transactions on Power Delivery, 2017, 32(3): 1483-1494.
- [11] 戴志辉, 刘宁宁, 何永兴, 等. 基于直流滤波环节暂态能量比的高压直流线路纵联保护[J]. 电工技术学报, 2020, 35(9): 1985-1998.
DAI Zhihui, LIU Ningning, HE Yongxing, et al. A pilot protection for HVDC transmission lines based on the ratio of DC filter link transient energy[J]. Transactions of China Electrotechnical Society, 2020, 35(9): 1985-1998.
- [12] 和敬涵, 张可欣, 李猛, 等. 基于深度学习的柔性直流线路单端量波形特征保护[J]. 清华大学学报(自然科学版), 2021, 61(5): 478-486.
HE Jinghan, ZHANG Kexin, LI Meng, et al. Single terminal waveform characteristic protection of flexible DC lines based on deep learning[J]. Journal of Tsinghua University (Science and Technology), 2021, 61(5): 478-486.
- [13] HAO Y Q, WANG Q, LI Y N, et al. An intelligent algorithm for fault location on VSC-HVDC system[J]. International Journal of Electrical Power & Energy Systems, 2018, 94: 116-123.
- [14] HADAEGHI A, SAMET H, GHANBARI T. Multi extreme learning machine approach for fault location in multi-terminal high-voltage direct current systems[J]. Computers & Electrical Engineering, 2019, 78: 313-327.
- [15] 杨冬锋, 李绍伟, 刘晓军, 等. 基于GRU网络的柔性直流配电网线路保护方案[J]. 电网技术, 2021, 45(10): 3885-3896.
YANG Dongfeng, LI Shaowei, LIU Xiaojun, et al. Protection scheme for flexible DC distribution lines based on GRU network[J]. Power System Technology, 2021, 45(10): 3885-3896.
- [16] 李小鹏, 汤涌, 朱清代, 等. 利用测量波阻抗相位特征的高压直流输电线路纵联保护[J]. 电网技术, 2018, 42(4): 1251-1259.
LI Xiaopeng, TANG Yong, ZHU Qingdai, et al. Pilot protection for HVDC transmission lines utilizing phase features of measured surge impedance[J]. Power System Technology, 2018, 42(4): 1251-1259.
- [17] 杨亚宇, 邵能灵, 范春菊, 等. 利用峰值频率的高压直流输电线路纵联保护方案[J]. 中国电机工程学报, 2017, 37(15): 4304-4314.
YANG Yayu, TAI Nengling, FAN Chunju, et al. A pilot protection scheme for HVDC transmission lines based on specific-frequency[J]. Proceedings of the CSEE, 2017, 37(15): 4304-4314.
- [18] 王珺, 董新洲, 施慎行. 考虑参数依频变化特性的辐射状架空配电网行波传播研究[J]. 中国电机工程学报, 2013, 33(22): 96-102.
WANG Jun, DONG Xinzhou, SHI Shenxing. Traveling wave transmission research for overhead lines of radial distribution power systems considering frequency characteristics[J]. Proceedings of the CSEE, 2013, 33(22): 96-102.
- [19] 朱玥, 顾洁, 孟璐. 基于EMD-LSTM的光伏发电预测模型[J]. 电力工程技术, 2020, 39(2): 51-58.
ZHU Yue, GU Jie, MENG Lu. Photovoltaic power generation prediction model based on EMD-LSTM[J]. Electric Power Engineering Technology, 2020, 39(2): 51-58.

- [20] 张大海, 杨宇辰, 刘艳梅, 等. 基于 EMD 与 Spearman 相关系数的混合直流线路纵联保护方法[J]. 电力系统保护与控制, 2021, 49(9): 1-11.
ZHANG Dahai, YANG Yuchen, LIU Yanmei, et al. Hybrid HVDC line pilot protection method based on EMD and Spearman correlation coefficient[J]. Power System Protection and Control, 2021, 49(9): 1-11.
- [21] ABDEL-BASSET M, MOHAMED R, ABDEL AZEEM S A, et al. Kepler optimization algorithm: a new metaheuristic algorithm inspired by Kepler's laws of planetary motion[J]. Knowledge-Based Systems, 2023, 268: 110454.
- [22] 陆云才, 廖才波, 李群, 等. 基于声纹特征和集成学习的变压器缺陷诊断方法[J]. 电力工程技术, 2023, 42(5): 46-55.
LU Yuncai, LIAO Caibo, LI Qun, et al. Transformer fault diagnosis method based on voiceprint feature and ensemble learning[J]. Electric Power Engineering Technology, 2023, 42(5): 46-55.
- [23] 裴东锋, 刘勇, 闫柯柯, 等. 一种基于 CNN 与 FFT-ELM 的输电线路故障识别与定位方法[J]. 电力科学与技术学报, 2024, 39(1): 164-170.
PEI Dongfeng, LIU Yong, YAN Keke, et al. A method based on CNN and FFT-ELM for fault identification and location of transmission lines[J]. Journal of Electric Power Science and Technology, 2024, 39(1): 164-170.
- [24] 杨秀, 胡钟毓, 田英杰, 等. 基于 Attention 机制的 CNN-GRU 配网线路重过载短期预测方法[J]. 电力科学与技术学报, 2023, 38(1): 201-209.
YANG Xiu, HU Zhongyu, TIAN Yingjie, et al. Short-term heavy overload forecasting method of distribution net line based on CNN-GRU with Attention mechanism[J]. Journal of Electric Power Science and Technology, 2023, 38(1): 201-209.
- [25] 王辉东, 姚海燕, 郭强, 等. 基于多尺度卷积神经网络的变压器故障诊断方法[J]. 电力科学与技术学报, 2023, 38(4): 104-112.
WANG Huidong, YAO Haiyan, GUO Qiang, et al. A transformer fault diagnosis method based on multiscale 1DCNN[J]. Journal of Electric Power Science and Technology, 2023, 38(4): 104-112.
- [26] 唐戈, 余一平, 秦川, 等. 基于 CNN-LSTM 分位数回归的母线负荷日前区间预测[J]. 电力工程技术, 2021, 40(4): 123-129.
TANG Ge, YU Yiping, QIN Chuan, et al. Day-ahead interval prediction of bus load based on CNN-LSTM quantile regression[J]. Electric Power Engineering Technology, 2021, 40(4): 123-129.
- [27] 钱甜甜, 王珂, 徐立中, 等. 基于双向长短时记忆网络的母线负荷分解方法[J]. 电力工程技术, 2020, 39(6): 104-109.
QIAN Tiantian, WANG Ke, XU Lizhong, et al. The bus load decomposition method based on bi-directional long short-term memory model[J]. Electric Power Engineering Technology, 2020, 39(6): 104-109.
- [28] 臧海祥, 赵勇凯, 张越, 等. 基于低风速功率修正和损失函数改进的超短期风电功率预测[J]. 电力系统自动化, 2024, 48(7): 248-257.
ZANG Haixiang, ZHAO Yongkai, ZHANG Yue, et al. Ultra-short-term wind power prediction based on low wind speed power correction and loss function improvement[J]. Power system automation, 2024, 48(7): 248-257.
- [29] 朱继忠, 苗雨旺, 董朝阳, 等. 基于 Attention-LSTM 与多模型集成的短期负荷预测方法[J]. 电力工程技术, 2023, 42(5): 138-147.
ZHU Jizhong, MIAO Yuwang, DONG Zhaoyang, et al. Short-term load forecasting method based on Attention-LSTM and multi-model integration[J]. Electric Power Engineering Technology, 2023, 42(5): 138-147.
- [30] 董新洲, 汤兰西, 施慎行, 等. 柔性直流输电线路保护配置方案[J]. 电网技术, 2018, 42(6): 1752-1759.
DONG Xinzhou, TANG Lanxi, SHI Shenxing, et al. Configuration scheme of transmission line protection for flexible HVDC grid[J]. Power System Technology, 2018, 42(6): 1752-1759.
- [31] 李正, 陈堂贤, 张赞宁, 等. 基于 ISSA-BiLSTM 的多端柔性直流输电线路保护方案[J/OL]. [2024-12-12]. 电测与仪表: 1-9. <http://kns.cnki.net/kcms/detail/23.1202.TH.20221103.1247.014.html>.
LI Zheng, CHEN Tangxian, ZHANG Yunning, et al. Protection scheme of multi-terminal flexible DC transmission line based on ISSA-BiLSTM[J/OL]. [2024-12-12]. Electrical Measurement & Instrumentation: 1-9. <http://kns.cnki.net/kcms/detail/23.1202.TH.20221103.1247.014.html>.
- [32] 赵妍, 孙延, 聂永辉. 基于格拉姆角差场和迁移残差网络的 HVDC 线路故障识别[J]. 电力建设, 2024, 45(8): 118-127.
ZHAO Yan, SUN Yan, NIE Yonghui. HVDC line fault identification based on Gram angle difference field and migration residual network[J]. Electric Power Construction, 2024, 45(8): 118-127.

作者简介:



余波

余波(2000), 男, 硕士在读, 研究方向为柔性直流输电(E-mail: yubo@ctgu.edu.cn);

高学军(1966), 男, 博士, 教授, 研究方向为高压直流输电、电力电子及其在电力系统中的应用等;

王灿(1987), 男, 博士, 副教授, 研究方向为综合能源系统优化运行、高比例新能源电力系统运行与控制。

Fault diagnosis of MMC-MTDC based on traveling wave characteristics and KOA-CNN-BiGRU-AM

YU Bo, GAO Xuejun, WANG Can, LI Ruiling, XU Yanbin, RONG Mengjie

(College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China)

Abstract: Based on travelling wave features, a diagnostic method is proposed to address the complexity of manual threshold setting process and the difficulty of detecting high-resistance faults in the fault diagnosis of multi-terminal direct current grid based on modular multilevel converter (MMC-MTDC). Firstly, the blocking effect of boundary elements on high-frequency signals is identified by analyzing the fault characteristics of the system. Secondly, empirical mode decomposition (EMD) is employed to decompose power signals into intrinsic mode function (IMF), and the energy values of the IMF is utilized as fault features to train the CNN-BiGRU network composed of convolutional neural network (CNN) and bidirectional gated recurrent unit (BiGRU). On this basis, the Kepler optimization algorithm (KOA) and attention mechanism (AM) are employed to enhance the CNN-BiGRU network to realize the fault diagnosis of the MMC-MTDC. Finally, the simulation model is built in PSCAD/EMTDC. The results show that the method can not only realize the detection of bus faults and line faults but also solve the problem of easy refusal of protection under the high resistance state while meeting the requirements of protection reliability and speed.

Keywords: multi-terminal direct current grid based on modular multilevel converter (MMC-MTDC); fault characteristics; empirical mode decomposition (EMD); Kepler optimization algorithm (KOA); attention mechanism (AM); convolutional neural network (CNN); bidirectional gated circulation unit (BiGRU); fault diagnosis

(编辑 方晶)

(上接第 171 页)

Improved piecewise coordinated frequency control of wind power generation system considering voltage restoration

CHEN Yuehai¹, PENG Qiao¹, LIU Tianqi¹, GU Tingyun², ZHANG Houyi², XIN Yue¹

(1. College of Electrical Engineering, Sichuan University, Chengdu 610065, China;

2. Electric Power Research Institute of Guizhou Power Grid Co., Ltd, Guiyang 550007, China)

Abstract: The large-scale integration of wind farms and power electronic devices reduces the total inertia and frequency regulation capability of power grid. The new energy systems, including wind power generation system, are required to provide sufficient inertia support to ensure the stability and safety of frequency. The wind power generation system can provide virtual inertia to the power grid by applying the kinetic energy of wind turbine rotor or the electrostatic energy of DC capacitor. However, how to coordinate the two sources to achieve optimal utilization of resources and efficient inertia support is the current research difficulty. On the other hand, the participation of DC capacitor of wind power generation system in virtual inertia provision may lead to sustaining deviation of DC voltage from the rated value. It is difficult for the wind power generation system to cope with subsequent possible disturbances, and the continuous frequency regulation capability of wind power generation system is constrained. Therefore, an improved piecewise coordinated frequency control method for wind power generation system considering voltage restoration is proposed. Firstly, a piecewise coordinated frequency control of wind power generation system considering virtual inertia provision from wind turbine rotor and DC capacitor is constructed. Then, a novel virtual inertia control of DC capacitor considering DC voltage restoration is proposed, based on which an improved piecewise coordinated frequency control of wind power generation system considering voltage restoration is developed. Finally, simulation analysis is carried out in PSCAD/EMTDC. The simulation results show that the proposed control method fulfills the participation of DC capacitor in virtual inertia provision, and it can restore the DC voltage rapidly without affecting the inertia support performance of wind power generation system. The proposed method optimizes the use of frequency regulation resources and improves the grid support capability of wind power generation system under cascading frequency disturbances.

Keywords: wind power generation system; frequency control; virtual inertia; DC capacitor; voltage restoration; piecewise control

(编辑 吴昊)