

基于深度学习算法的直流换相失败预测研究

仝 哲^{1,3}, 邓慧琼^{2,3}, 潘登炜^{2,3}, 吴 辉^{2,3}

(1.中国电建集团河北省电力勘测设计研究院有限公司,河北 石家庄 050031;2.福建理工大学电子电气与物理学院,福建 福州 350118;3.智能电网仿真分析与综合控制福建省高校工程研究中心,福建 福州 350118)

摘要:随着交直流混联电网快速发展,换相失败作为典型故障,严重威胁交直流系统安全运行,因此提出一种基于 LSTM-SVM 算法的直流换相失败预测方法,旨在快速预测换相失败连锁故障和精准识别初始故障类型。通过建立交直流系统仿真模型,分析 HVDC 换相失败的原因及影响因素,以改进 IEEE9 节点和 IEEE39 节点交直流系统为例,针对故障信号的非平稳性,采用小波变换对原始数据进行多尺度分解,有效提取各频段能量特征,并利用 LSTM 挖掘时序数据的深层关联特征,构建高维特征向量输入 SVM 分类器完成预测和识别。实验结果表明,所提方法能够准确捕捉换相失败前兆特征,实现短时间窗内故障预测与类型识别,具有较高的精度和鲁棒性,为交直流系统连锁故障防控提供了有效技术支撑。

关键词:换相失败;交直流系统;深度学习算法;预测识别

中图分类号:TM711 文献标志码:A 文章编号:1001-9898(2026)01-0017-09

Research on DC Commutation Failure Prediction Based on Deep Learning Algorithm

TONG Zhe^{1,3}, DENG Huiqiong^{2,3}, PAN Dengwei^{2,3}, WU Hui^{2,3}

(1.Power China Hebei Electric Power Engineering Co., Ltd., Shijiazhuang 050031, China; 2.School of Electronic, Electrical Engineering and Physics, Fujian University of Technology, Fuzhou 350118, China; 3.Fujian Provincial University Engineering Research Center for Simulation Analysis and Integrated Control of Smart Grid, Fuzhou 350118, China)

Abstract: With the rapid development of AC-DC hybrid power grids, commutation failure, as a typical fault, poses a severe threat to the safe and stable operation of AC-DC systems. This paper proposes a commutation failure prediction method based on the LSTM-SVM algorithm, aiming to quickly predict cascading commutation failures and accurately identify the initial fault type. By establishing a simulation model of the AC-DC system, the causes and influencing factors of HVDC commutation failure are analyzed. Using the modified IEEE 9-bus and the modified IEEE 39-bus AC-DC system as examples, wavelet transform is applied to perform multi-scale decomposition of the raw data to effectively extract energy features from different frequency bands, addressing the non-stationarity of fault signals. Meanwhile, LSTM is utilized to mine deep temporal correlations within the time-series data, and high-dimensional feature vectors are constructed and fed into an SVM classifier for fault prediction and identification. The experimental results show that the proposed method can accurately capture the precursor features of commutation failure, realizing fault prediction and type identification within a short time window, and it exhibits high accuracy and robustness. This method provides effective technical support for the prevention and control of cascading faults in AC-DC systems.

Key words: commutation failure; AC-DC system; deep learning algorithms; prediction and recognition

0 引言

随着我国能源转型加快,直流跨区输电规模持续增长,交直流混联电网已成为现代新型电力

系统的重要组成部分^[1]。然而,高压直流输电系统(high voltage direct current, HVDC)的核心元件晶闸管为半控型器件,不具备自关断能力,因此换相失败的发生不可避免^[2]。换相失败是 HVDC

收稿日期:2025-02-14 修回日期:2025-03-07

作者简介:仝 哲(1996—),男,硕士研究生,主要研究方向为交直流电力系统连锁故障分析、预测和预防。

基金项目:国家自然科学基金项目(52377097);福建省自然科学基金项目(2022J01948);福建理工大学科研发展基金项目(GY-Z17149)。

系统最常见的故障之一,主要由直流系统内部故障及交流侧电网电压跌落、不对称故障、功率波动等引起^[3],但大多数直流换相失败是由受端电网发生交流短路故障引发的^[4-5]。

现有换相失败故障诊断技术主要分为传统方法和智能方法。传统方法包括基于换相面积理论分析^[6],直流电流和交流电压双预测的预防策略^[7],以及多馈入系统影响因子的研究,如 MOVIF 用于换相失败判定^[8],MISCR 用于评估受端电网强度^[9]。尽管这些方法为理论分析提供了依据,但在效率和实施复杂度上存在不足。智能方法则依托现代机器学习技术,如基于小波分解的 BP 神经网络训练^[10],结合知识图谱与机器学习的智能溯源及预测方法^[11],以及经验模态分解结合 Elman 神经网络诊断方案^[12],部分研究已验证其有效性。然而,当前智能方法仍面临难以捕获中长期依赖关系的问题,亟需进一步优化。

综上所述,本文提出了一种基于深度学习算法的交直流系统换相失败预测方法。首先,基于 PSCAD 电磁暂态仿真分析平台,建立交直流系统仿真模型,分析换相失败的原因及影响因素,并获取大量相关数据;然后,提出基于深度学习算法模型对交直流系统中考虑交流初始故障引发直流换相失败的预测和识别;利用小波变换对数据进行处理,提取故障特征,构建并训练长短期神经网络(LSTM),结合支持向量机(SVM)进行换相失败故障预测和识别;最后,以国际大电网会议 CIGRE HVDC 标准测试模型和改进 IEEE9 节点交直流系统为例进行仿真分析,验证所提预测识别模型的有效性。

1 交直流系统仿真模型

1.1 HVDC 系统换相失败分析

高压直流输电系统的核心元件晶闸管属于半控型电力电子器件,具有单向可控特点^[13]。刚退出导通的阀未恢复阻断能力,此时施加在阀上的电压转为正向电压,该刚退出导通的阀组又导通,称之为换相失败。换相失败是换流阀应关断而未关断导致的,本质上是由于晶闸管为半控型器件这一特性造成的,现有技术条件下无法避免。

根据相关研究,换相失败发生在 HVDC 系统

逆变侧的概率远大于整流侧,结合换相失败机理可得关断角为

$$\gamma = \arccos\left(\frac{\sqrt{2} I_d X_c}{U_L} + \cos \beta\right) \quad (1)$$

当换相电压发生相角偏移时,如逆变侧交流系统发生不对称故障,关断角为

$$\gamma = \arccos\left(\frac{\sqrt{2} I_d X_c}{U_L} + \cos \beta\right) - \varphi \quad (2)$$

式中: I_d 为直流线路电流; X_c 为等效电抗; U_L 为逆变侧交流母线电压有效值; β 为触发超前角; φ 为换相电压波形过零点偏移电角度。

换相失败的本质原因是外部或内部因素导致逆变侧关断角 γ 过小,小于极限关断角 $\gamma_{\min}$, $\gamma_{\min}$ 为晶闸管换流阀完成载流子复合、恢复阻断能力的时间所对应的关断角,一般约为 $400 \mu\text{s}$,对应的电角度约为 7° ,因此当关断角 $\gamma < \gamma_{\min}$ 时,则发生换相失败。

将 $\gamma_{\min}$ 代入式(2),可得换相失败的临界换相电压和电流:

$$U_{L,\min} = \frac{\sqrt{2} I_d X_c}{\cos \gamma_{\min} - \cos \beta} \quad (3)$$

$$I_{d,\max} = \frac{U_L (\cos \gamma_{\min} - \cos \beta)}{\sqrt{2} X_c} \quad (4)$$

1.2 交直流系统仿真模型搭建

在 PSCAD 电磁暂态仿真分析平台中,以 IEEE9 节点交流系统和 CIGRE 标准 HVDC 模型为基础,通过拓扑改造将母线 7 与 8 之间的架空线路改造为高压直流输电线路,调整和优化相关参数,搭建了改进 IEEE9 节点交直流系统仿真模型,如图 1 所示。IEEE9 节点交流系统的相关参数设置如表 1—4 所示,基准容量为 100 MVA,基准电压为 230 kV。




图 1 改进 IEEE9 节点交直流系统仿真模型

表 1 电源节点参数

节点编号	电压/kV	相角/deg	有功功率 P /p.u.	无功功率 Q /p.u.
1	17.160 0	0.000 0	0.716 3	0.279 1
2	18.450 0	9.350 7	1.630 0	0.049 0
3	14.145 0	5.142 0	0.850 0	-0.114 5

表 2 架空线路参数

线路		电阻 R /p.u.	电感 X /p.u.	电纳 B /p.u.
送端节点	受端节点			
4	5	0.010 0	0.068 0	0.176 0
4	6	0.017 0	0.092 0	0.158 0
5	7	0.032 0	0.161 0	0.306 0
6	9	0.039 0	0.173 8	0.358 0
7	8	0.008 5	0.057 6	0.149 0
8	9	0.011 9	0.100 8	0.209 0

表 3 负荷参数

节点编号	有功功率 P /p.u.	无功功率 Q /p.u.
5	1.25	0.50
6	0.90	0.30
8	1.00	0.35

表 4 线路潮流参数

节点编号		有功功率 P /p.u.	无功功率 Q /p.u.
送端节点	受端节点		
1	1	0.715 2	0.276 1
2	2	1.632 0	0.045 4
3	3	0.851 2	-0.117 0
4	5	0.432 2	0.233 4
4	6	0.283 0	0.011 5
5	7	0.843 0	-0.104 1
6	9	0.634 0	-0.181 0
7	8	0.789 2	-0.008 9
8	9	0.217 2	0.022 9

同理,将 IEEE39 节点系统中母线 15 与 16 之间的架空线路改造为高压直流输电线路,搭建了改进 IEEE39 节点交直流系统仿真模型,如图 2 所示。其中,系统均采用统一参数配置,HVDC 均基于 CIGRE 标准直流模型设计,额定功率为 500 MW,额定电压为 500 kV。




图 2 改进 IEEE39 节点交直流系统仿真模型

在交直流电力系统中,可将交直流系统看成由直流系统与纯交流系统共同构成的有机整体,直流系统是含有换流器与直流线路构成的子系统。通常直流换相失败可由逆变系统内部故障导致和逆变侧交流系统故障导致^[14]。而对于正常运行的 HVDC 系统,逆变系统内部故障概率很小,90%以上的换相失败由逆变侧交流系统故障导致。因此,本文重点研究逆变侧交流系统故障导致的直流换相失败。

2 基于小波变换的特征提取

换相失败发生时故障波形会在交直流电网数个周期内发生剧烈变化,产生的谐波分量在时间刻度上呈现不均匀性^[15]。小波变换作为高效的信号处理工具,特别适用于分析时变信号,因此,本文采用小波变换对数据进行处理,将换相失败阶段的时域信号变换到频域,以便挖掘多时频尺度上的特征信息。

而在交直流混联电网中,交直流电网特征事件受电网运行状态量、故障类型、故障地点等因素影响,本文重点关注逆变侧交流系统故障导致的直流换相失败连锁故障,为保证预测和识别的准确性、可靠性,本文选取了电压、电流、功率等 11 维变量作为关键特征量,相关特征量如表 5 所示。

表 5 相关特征量

特征量	特征描述
i_1	逆变侧交流母线 A 相电压瞬时值
i_2	逆变侧交流母线 B 相电压瞬时值
i_3	逆变侧交流母线 C 相电压瞬时值
i_4	逆变侧换流母线线电压有效值
i_5	直流线路电压
i_6	直流线路电流
i_7	逆变侧交流母线 A 相电流
i_8	逆变侧交流母线 B 相电流
i_9	逆变侧交流母线 C 相电流
i_{10}	逆变侧换流母线有功功率 P
i_{11}	逆变侧换流母线无功功率 Q

2.1 小波变换及能量熵

能量熵是一种衡量信号分布无序程度的指标,信号的能量分布越均匀,其能量熵越大;反之,能量集中在少数几个频段时,能量熵较小。将故障数据通过小波变换后得到的多频带波形,进行能量熵计算,以便在另一个维度上得到电压电流等信号的特征信息^[16]。

小波分解算法为:

$$\begin{cases} d_l^{j,2n} = \sum_k a_{k-2l} d_k^{j+1,n} \\ d_l^{j,2n+1} = \sum_k b_{k-2l} d_k^{j+1,n} \end{cases} \quad (5)$$

小波重构算法为

$$d_l^{j+1,n} = \sum_k [h_{l-2k} d_k^{j,2n} + g_{l-2k} d_k^{j,2n+1}] \quad (6)$$

对于信号序列 $f(n)$ 在各个频段上的小波系数为 $D_j(i)$, 则第 j 个频段的小波能量为

$$E_j = \sum_{i=1}^n D_j^2(i) \quad (7)$$

为了获得小波系数在各个频段的能量分布, 定义相对小波能量为

$$P_j = \frac{E_j}{\sum_{i=1}^n E_j} \quad (8)$$

显然 $\sum P_j = 1$, P_j 的大小可以认为是信号在时频域上的能量概率。最终, 可用小波能量熵 ϵ 描述小波能量谱的分布情况, 表达式为

$$\epsilon = - \sum_j P_j \ln(P_j) \quad (9)$$

小波能量熵代表某段序列所蕴含的特征信息, 因此, 在对信号做特征提取时, 需要对其进行窗口划分, 拆分成同等长度的多条时间序列进行处理。求取每一窗口的小波能量熵并重构, 最终实现电压电流等信号的特征向量提取。

2.2 特征向量提取流程

特征向量的提取主要分为时间窗口划分、小波分解和能量熵求取三步, 流程如图 3 所示。




图 3 故障波形特征向量提取流程

兼顾故障前后波形截取的范围与故障预测识别的实时性, 选取故障前 0.02 s 至故障后 0.06 s 范围内的 4 000 个数据点, 按时间顺序依次分为 80 组, 对每组时间序列数据进行 10 级小波分解, 共进行 80 组小波分解变换。

基于能量熵最小化准则, 此处小波分解时选取的小波基函数是 Sym8 小波函数, Symlets 函数系是由 Daubechies 提出的近似对称的小波函数, 它是对 Daubechies 函数的一种改进, sym8 作为对称型小波函数, 具有较好的对称性和局部化特性。本文通过实验比较了 db4、sym4、sym8 及 coif3 4 种常用小波函数在不同频带的能量熵值, 1 000 组数据样本测试结果显示: sym8 的各频带能量熵平均值约为 0.021 Bit, 显著低于 db4(0.158 Bit)、sym4(0.132 Bit) 和 coif3(0.166 Bit), 其紧支撑性、近似对称性和正则性能够有效抑制信号分解时的频谱泄漏问题, 最有效保留信号的主要特征, 与关于 sym 系列小波在非平稳信号分析中的优势结论一致^[17]。此外, 10 级小波分解则是根据 Nyquist 采样定理并结合模型测试结果选定的, 对比结果如表 6 所示。

表 6 不同小波分解层级下的实验结果

指标	8 级	9 级	10 级	11 级	12 级
MAE	0.060 2	0.034 5	0.027 7	0.029 8	0.041 1
RMSE	0.108 7	0.063 2	0.051 4	0.057 3	0.079 9

各个时间窗口下的原始数据在经过 10 级小波分解后, 均被分解为 11 段不同频段的新信号。对各个时间窗口求得的 11 段小波分解波形用公式(9)求取能量熵, 即: 将一路 4 000 数据点的电压、电流和功率信号变成 80 个数据点的能量熵序列, 最终构成表征原始故障波形的小波能量熵特征向量。

3 LSTM-SVM 网络模型构建

支持向量机(SVM)是一种有效的分类算法, 特别适用于高维数据和小样本问题, 但在处理时序数据和捕捉长期依赖关系时存在局限性。而长短期记忆神经网络(LSTM)具有强大的非线性建模能力, 并能够有效提取时序特征。然而, LSTM 在分类任务中的表现受到高维特征空间复杂性和计算效率的限制, 特别是在面对复杂决策边界时, LSTM 往往难以提供与 SVM 相匹配的分类精度。

和泛化能力^[18]。为克服这一局限性,在换相失败预测识别任务中,提出了一种 LSTM 与 SVM 相结合的级联模型,利用 LSTM 提取时序特征,并借助 SVM 进行最终的分类预测,提高了模型的准确性与泛化能力。

3.1 长短期记忆神经网络

LSTM 是一种针对传统 RNN 梯度消失问题提出的改进型循环神经网络。如图 4 所示,其核心在于通过门控机制实现时序特征的动态选择与长期记忆保持。每个 LSTM 单元包含输入门、遗忘门和输出门 3 个控制模块,以及用于信息传递的单元状态(cell state)。在时间步 t 的计算过程中,单元接收当前输入向量 x_t 、前序隐藏状态 h_{t-1} 和细胞状态 C_{t-1} ,并通过门控函数完成以下运算^[19]:

$$\begin{cases} f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, x_t] + \mathbf{b}_f) \\ i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, x_t] + \mathbf{b}_i) \\ C'_t = \tanh(\mathbf{W}_C \cdot [h_{t-1}, x_t] + \mathbf{b}_C) \\ C_t = f_t \odot C_{t-1} + i_t \odot C'_t \\ o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, x_t] + \mathbf{b}_o) \\ h_t = o_t \odot \tanh(C_t) \end{cases} \quad (10)$$

式中: σ 为 sigmoid 函数; $\tanh$ 为双曲正切函数; $\odot$ 为 Hadamard 积; $\mathbf{W}$ 和 $\mathbf{b}$ 分别为各门的权重矩阵和偏置向量。




图 4 LSTM 原理

遗忘门控制历史信息的保留程度,输入门调节新特征的融合比例,输出门决定当前状态的输出特征^[20]。

这种结构使 LSTM 能有效捕获长距离时序依赖关系,但其在分类任务中仍存在一定不足。由于 LSTM 依赖复杂的神经网络结构进行特征提取,容易受到高维特征空间的影响,导致决策边界不够清晰,分类性能可能受限。

3.2 支持向量机

SVM 是一种基于结构风险最小化的监督学习算法,在解决小样本、非线性及高维数据的分类问题上具有显著优势。其核心思想是通过构建最大间隔超平面实现数据的最优划分^[21],其决策函数仅依赖于支持向量,使得模型具有较好的泛化能力和抗过拟合特性。SVM 原理如下:

给定训练样本集 $\{(x_i, y_i)\}_{i=1}^n$, 其中 $x_i \in R^d$ 为特征向量, $y_i \in \{-1, 1\}$ 为类别标签。SVM 通过求解以下凸优化问题确定最优分类超平面。

$$\begin{cases} \min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \\ \text{s.t. } y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \xi_i \geq 0 \end{cases} \quad (11)$$

式中: $\mathbf{w}$ 为法向量; b 为偏置项; C 为惩罚系数; ξ_i 为松弛变量。

通过拉格朗日对偶变换可转化为:

$$\begin{cases} \max_{\alpha_i} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \\ \text{s.t. } 0 \leq \alpha_i \leq C, \sum_{i=1}^n \alpha_i y_i = 0 \end{cases} \quad (12)$$

考虑到故障类型的多样性和非线性,本文选择径向基核函数(RBF)作为 SVM 的核函数,将原始特征空间映射到高维空间。RBF 核函数定义为

$$K(x_i, x_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (13)$$

最终, SVM 根据已学习的最优决策边界,将特征向量 $\mathbf{x}_i$ 分类到对应的故障类别 y , 决策函数为

$$f(x) = \text{sgn} \left[\sum_{i,j=1}^n \alpha_i^* y_i K(x_i, x_j) + b^* \right] \quad (14)$$

式中: $\text{sgn}()$ 为符号函数; α_i^* 为最优解; b^* 为阈值。

SVM 的优越性体现在:1)通过核技巧处理非线性可分数据;2)基于支持向量的稀疏解降低计算复杂度;3)间隔最大化准则保证泛化性能。但该模型对时序特征的动态演变缺乏建模能力,难以捕获序列数据中的状态转移规律^[22]。因此,本文采用 LSTM-SVM 级联架构,将 LSTM 提取的时序特征作为 SVM 输入,通过二者的优势互补提升预测识别性能。

3.3 基于 LSTM-SVM 的换相失败预测

本文将 SVM 模块与传统的 LSTM 进行级联,构建了 LSTM-SVM 级联网络。其中 LSTM

有效地提取时序特征并捕捉长期依赖关系,而 SVM 则在分类阶段提供了强大的判别能力,特别是在处理复杂决策边界时,能够显著提高分类精度。该换相失败预测识别模型的整体流程如图 5 所示。




图 5 预测识别流程

预测识别流程运算步骤如下：

步骤 1: 数据预处理。将通过仿真系统获得的原始数据进行小波变换,计算能量熵以表征信号的状态变化。同时,对处理后的数据按一定比例划分为训练集、验证集和测试集,用于模型的训练和测试。

步骤 2: 故障特征提取与模型训练。将划分好的训练集输入到 LSTM 模块中,提取时序特征,捕捉信号的长期依赖关系;接着,将提取的特征传递给 SVM 模块,进行换相失败连锁故障的预测和初始故障分类识别。在模型训练过程中,对 LSTM 和 SVM 的参数进行微调,优化模型性能。完成训练后,保存训练好的 LSTM-SVM 级联网络模型。

步骤 3: 故障预测与诊断。将测试集数据输入到已训练好的 LSTM-SVM 级联模型中,进行换相失败故障的预测与初始故障诊断。模型输出预测结果与故障类别,验证其预测识别的准确性。当模型预测到换相失败时,依据设定的判据启动相应的保护机制,及时切除故障。本文所构建的换相失败预测识别模型如图 6 所示。




图 6 换相失败预测识别模型

4 算例分析

本文以 PSCAD 仿真平台搭建的改进 IEEE9 节点和 IEEE39 节点交直流系统仿真模型为基础,对基于 LSTM-SVM 深度学习算法的模型进行训练和测试,验证本文所提方法模型的有效性和合理性。

4.1 实验设置与数据预处理

通过大量仿真实验,并系统分析交直流混联电网在不同运行工况下的动态响应特性。在高压交直流系统稳定运行状态下,换流母线三相电压、三相电流均为标准正弦波形,且换流母线线电压、有功功率、无功功率均维持在额定值稳定运行,直流电压和直流电流亦保持额定值稳定运行状态。

当高压交直流输电系统达到稳定运行状态时,在直流线路逆侧交流系统线路发生 AB 两相瞬时金属性短路接地故障,设置故障起始时刻为 2.0 s,持续时间 0.2 s。此时,系统将呈现显著的非线性动态特性:换流母线 AB 两相电压瞬时值骤降至零,C 相电压发生剧烈下降波动,三相电流波形发生剧烈畸变并失去正弦特性,换流母线电压有效值瞬时跌落,有功功率降为零,直流系统功率传输中断,无功功率出现剧烈波动,直流电压迅速下降至零,直流电流因短路故障瞬间增大,触发低压限流环节后逐渐下降,直流系统发生换相失败,严重危及电力系统的安全稳定运行。

充足的数据是神经网络的生命,数据的质量是提升准确度的关键,将改进 IEEE9 节点和 IEEE39 节点两种交直流仿真系统进行不同运行状态的仿真分析,并分别采集 20 000 组仿真数据,作为本文模型训练的数据集,数据集的基本信息如表 7 所示。

表 7 数据集的基本信息

仿真模型	改进 IEEE9 节点 交直流系统	改进 IEEE39 节点 交直流系统
特征量数	11	11
样本组数	20 000	20 000
样本数据点数	150 000	150 000
样本采样点数	4 000	4 000
小波变换后窗口数	80	80

小波变换适用于分析时变信号,将信号分解成多个不同频带,分析信号在不同时间尺度上的特征,而故障信号会在时域上发生剧烈的变化,小波变换可以精细地提取这些变化,有效捕捉电力系统中的瞬时性故障。将数据集中每组样本采样数据经过 10 级小波分解提取特征向量后的效果如图 7—8 所示。




图 7 正常状态经小波变换提取特征向量图




图 8 故障状态经小波变换提取特征向量图

由图 7、图 8 可知,小波变换可以有效提取电力系统数据的时频特征,捕捉信号的局部奇异性特征和细节。

神经网络的训练质量还与数据集划分和网络参数设置密切相关。基于 MATLAB 平台构建 LSTM-SVM 深度学习模型,对模型参数进行调整设置,并分别将改进 IEEE9 节点和 IEEE39 节点交直流系统各自的 20 000 组数据集经过小波预处理后进行整理划分为训练集 60%、验证集 20% 和测试集 20%,用于模型的训练学习。

4.2 模型仿真结果

4.2.1 换相失败预测结果

经过多次训练与测试,取实验趋于稳定的平均值作为最终预测结果,验证结果如表 8 和图 9—10 所示。

表 8 换相失败预测结果相关指标

相关指标	改进 IEEE9 节点测试集	改进 IEEE39 节点测试集
R^2	0.981 3	0.976 1
MAE	0.027 1	0.030 7
MBE	0.012 6	0.015 4
RMSE	0.049 5	0.056 6




图 9 改进 IEEE9 节点换相失败预测结果混淆矩阵




图 10 改进 IEEE39 节点换相失败预测结果混淆矩阵

由表 8、图 9、图 10 结果可知,本文模型方法在交直流系统中可以准确预测当交流系统发生故障时,直流是否发生换相失败连锁故障,在改进 IEEE9 节点交直流系统数据集中,测试准确率达到 99.5% 及以上,训练好的 LSTM-SVM 模型单次预测的平均推理时长为 5.4 ms;在改进 IEEE39 节点交直流系统数据集中,测试准确率达到 99.3% 及以上,训练好的 LSTM-SVM 模型单次预测的平均推理时长为 5.8 ms,准确率和计算效率均能基本满足换相失败的预测要求。

4.2.2 换相失败原因识别

算法模型输出识别引发直流换相失败的交流侧初始故障类型结果如表 9 和图 11、图 12 混淆矩阵所示,在改进 IEEE9 节点交直流系统中,测试识别准确率达到 99.65%,在改进 IEEE39 节点交直流系统中,测试识别准确率达到 99.54%。

综上,测试准确率均达到 99% 以上,决定系数 R^2 的值越接近 1,表示模型对数据的拟合越好,而平均绝对误差 MAE、均值偏差 MBE 的值越小,表示模型的预测误差和系统性偏差越小,同时, RMSE 值越小表示模型预测的越准确,以上指标

表 9 输出识别初始故障类型

类型编号	具体类型	故障发生位置
N	正常未发生换相失败	
1	单相接地 (AG、BG、CG)	
2	两相短路 (AB、AC、BC)	逆变侧交流
3	两相短路接地 (ABG、ACG、BCG)	系统故障
4	三相短路故障 (ABC、ABCG)	




图 11 改进 IEEE9 节点识别结果混淆矩阵




图 12 改进 IEEE39 节点识别结果混淆矩阵

和结果均证明了本文所提基于深度学习算法模型预测和识别的准确性与有效性。且本文所提方法无需对电力系统进行较大改造,仅需在换流站就地布置服务器计算资源,适合站点轻量化部署。

4.3 基于现场数据的验证分析

我国某 UHVDC 输电系统的结构如图 13 所示,其额定输送功率为 12 000 MW,额定电压 ± 1100 kV,额定直流电流 5 455 A。该直流系统采用极 1、极 2 bipolar 设计,每极使用双 12 脉动换流器。其中,受端 ± 1100 kV 换流站采用分层接入方式,高端接入 500 kV 交流电网,低端接入 1 000 kV 交流电网。每极直流母线配置有直流滤波器和平波电抗器,交流母线均配置有相对应电压等级的交流滤波器。

以极 1 低端换流器为例,选取 10 组正常运行波形和 10 次换相失败故障录波数据,构成含 20 组现场录波数据的测试集,其中 8 次由单相电网故障导致、1 次由两相短路故障导致、1 次由两相短路接地故障导致,暂缺三相电网故障导致的换




图 13 某 UHVDC 输电系统结构

相失败数据。使用前文已训练好的 LSTM-SVM 算法模型按照图 5 所示流程进行预测识别,换相失败预测识别结果如图 14、图 15 所示。




图 14 现场录波测试集下的预测结果混淆矩阵




图 15 现场录波测试集下的识别结果混淆矩阵

由图 14、图 15 可知,在现场录波数据测试中,前文已训练好的 LSTM-SVM 对换相失败连锁故障的预测准确率为 95.0%,并可以实现正常运行(类别 N)、单相电网故障(类别 1)和两相短路接地故障(类别 3)导致换相失败的精准判断;而由两相短路故障(类别 2)导致的换相失败事故中未能正确识别,由于缺少三相故障数据(类别 4),该项数据均为 0,最终得综合识别准确率为 95.0%,且模型单次预测识别平均推理时长为 5.7 ms,满足电力系统换相失败毫秒级响应实时性需求,具备工程应用可行性。

5 结论

本文提出了一种基于 LSTM-SVM 算法的交

直流系统换相失败预测方法,旨在解决交流初始故障引发的直流换相失败连锁故障问题。以有效预测交直流混联电网中交流系统初始故障引发直流换相失败为目标建立预测识别模型,通过分析交直流系统中 HVDC 换相失败的原因及影响因素,在 PSCAD 中搭建贴合实际的改进 IEEE9 节点和 IEEE39 节点交直流系统仿真模型,并在不同运行状态下对本文所提方法进行测试,同时用现场录波数据对本文方法进行了验证,实验结果表明:该方法能够快速准确预测直流换相失败连锁故障并精准识别交流初始故障类型,对提高交直流混联电网运行的安全性、可靠性具有重要意义,为交直流系统连锁故障的预测和预防提供了思路。后续将利用现场数据对模型进行增量式训练和在线升级,进一步提升换相失败预测和识别效率。未来的工作将专注于设计更适应交直流系统的模型,进一步优化模型的结构、精度与泛化能力等。

参考文献:

- [1] 董新洲,汤 涌,卜广全,等.大型交直流混联电网安全运行面临的问题与挑战[J].中国电机工程学报,2019,39(11):3107-3119.
- [2] 刘席洋,王增平,乔 鑫,等.交直流混联电网换相失败分类及抑制措施研究综述[J].智慧电力,2020,48(6):1-7,34.
- [3] 闫晓虎,李凤婷,尹纯亚,等.基于直流电流变化量预测的后续换相失败抑制策略[J].现代电力,2025,42(1):191-200.
- [4] 汤 奕,郑晨一.高压直流输电系统换相失败影响因素研究综述[J].中国电机工程学报,2019,39(2):499-513,647.
- [5] 宋金钊,李永丽,曾 亮,等.高压直流输电系统换相失败研究综述[J].电力系统自动化,2020,44(22):2-13.
- [6] 刘 超,潘 岩,韩 伟.直流换相失败原因及对策研究[J].河南科技,2022,41(19):31-34.
- [7] 周泓宇,姚 伟,李 佳,等.基于电流电压预测的直流输电换相失败预防策略[J].中国电机工程学报,2022,42(16):5948-5959,6169.
- [8] 尹纯亚,李凤婷,宋新甫,等.多馈出直流系统换相失败快速判别方法[J].电网技术,2019,43(10):3459-3465.
- [9] 王书杰,文 俊,牛宇昆,等.交直流系统对多馈入短路比的影响研究[J].电网与清洁能源,2021,37(9):1-8.
- [10] 朱 艳,王渝红,丁志林,等.小波能量偏度神经网络的 HVDC 换相失败故障诊断[J].电力系统及其自动化学报,2017,29(2):39-44.
- [11] 张晓华,徐 伟,吴 峰,等.交直流混联电网连锁故障特征事件智能溯源及预测方法[J].电力系统自动化,2021,45(10):17-24.
- [12] 杨鸿雁,邢 超,陈仕龙,等.基于经验模态分解与 Elman 神经网络的永富直流换相失败故障诊断方法[J].电子测量技术,2020,43(1):169-175.
- [13] 欧阳金鑫,张 真,肖 超.直流输电系统换相失败预防控制改进策略[J].电力系统自动化,2020,44(22):14-21.
- [14] 王 宾,何小才.经 LCC-HVDC 输电送出系统单端混合等值计算[J].中国电机工程学报,2024,44(14):5441-5451.
- [15] 李培平,周泓宇,姚 伟,等.多馈入结构背景下的高压直流输电系统换相失败研究综述[J].电网技术,2022,46(3):834-850.
- [16] 张玉典,王宇驰.离散小波变换结合 BP 神经网络的光伏发电功率预测[J].现代工业经济和信息化,2024,14(12):262-263,266.
- [17] LUO G, LIN Q, ZHOU L, et al. Recognition of traveling surges in HVDC with wavelet entropy[J]. Entropy, 2017, 19(5):184.
- [18] 王步华,朱劭璇,熊浩清,等.基于长短期记忆神经网络的检修态电网暂态稳定评估方法[J].电气技术,2023,24(1):29-35,43.
- [19] 朱晓红,杨伟荣,张 蓉,等.基于 RNN-LSTM 神经网络的小电流接地故障选线方法[J].高压电器,2023,59(7):213-220.
- [20] 王 卉,王增平,刘席洋.基于深度循环神经网络的换相失败边界检测[J].现代电力,2019,36(6):88-93.
- [21] 栾 兰,吕腾飞,姜良刚,等.基于 TQWT 及 SVM 算法的有载分接开关带电检测技术研究[J].变压器,2024,61(2):44-50.
- [22] 李贝贝,孙深圳,刘秀梅,等.基于改进 SVM 算法的调节阀空化状态识别[J].机械工程学报,2023,59(24):312-322.

本文责任编辑:王丽斌