

基于动态模式识别的交直流电力系统换相失败早期征兆捕获与分类研究

全哲^{1,2}, 潘登炜^{1,2}, 吴辉^{1,2}, 王弘^{1,2}

¹福建理工大学电子电气与物理学院, 福建 福州

²福建理工大学, 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

收稿日期: 2025年3月27日; 录用日期: 2025年4月18日; 发布日期: 2025年4月29日

摘要

换相失败是交直流电力系统运行中的常见故障, 尤其在高压直流输电(HVDC)系统中, 其发生会导致直流电压下降、交流电网电压畸变, 甚至引发系统振荡和大规模停电。换相失败通常由交流系统电压扰动、直流系统功率波动及控制策略不足等因素引起, 准确捕获其早期征兆并进行分类对于提升电网稳定性具有重要意义。现有方法主要依赖物理模型计算或基于传统特征提取的机器学习方法, 难以满足复杂电网环境下的实时检测需求。动态模式识别技术能够从时序数据中提取关键特征, 并结合深度学习方法提高故障检测的准确性。针对换相失败的时序特征, 基于动态模式识别的故障检测方法能够在换相失败发生前识别关键信号, 提高系统的预警能力, 并实现对不同类型换相失败的分类, 有助于电网安全策略的优化。

关键词

交直流电力系统, 换相失败, 动态模式识别, 早期征兆捕获与分类

Research on Early Detection and Classification of Commutation Failure in AC-DC Power Systems Based on Dynamic Pattern Recognition

Zhe Tong^{1,2}, Dengwei Pan^{1,2}, Hui Wu^{1,2}, Hong Wang^{1,2}

¹School of Electronic, Electrical Engineering and Physics, Fujian University of Technology, Fuzhou Fujian

²Smart Grid Simulation Analysis and Comprehensive Control Fujian Provincial University Engineering Research Center, Fujian University of Technology, Fuzhou Fujian

Received: Mar. 27th, 2025; accepted: Apr. 18th, 2025; published: Apr. 29th, 2025

文章引用: 全哲, 潘登炜, 吴辉, 王弘. 基于动态模式识别的交直流电力系统换相失败早期征兆捕获与分类研究[J]. 智能电网, 2024, 14(6): 59-68. DOI: 10.12677/sg.2024.146007

Abstract

Commutation failure is a common fault in the operation of AC-DC hybrid grids, particularly in high-voltage direct current (HVDC) systems. Its occurrence can result in a reduction of DC voltage, distortion of AC grid voltage, and may even lead to system oscillations and large-scale power outages. Commutation failure is typically caused by factors such as voltage disturbances in the AC system, fluctuations in the DC system's power, and inadequate control strategies. Accurately capturing its early signs and classifying them is critical for enhancing grid stability. Current methods primarily rely on physical model calculations or machine learning techniques based on traditional feature extraction, which are inadequate for meeting the real-time detection requirements in complex grid environments. Dynamic pattern recognition methods, when combined with deep learning, can extract key features from time-series data, improving fault detection accuracy. For commutation failure's time-series characteristics, the dynamic pattern recognition-based fault detection method can identify key signals before failure occurs, enhancing early warning capabilities and enabling classification of different types of commutation failures. This helps optimize grid safety strategies.

Keywords

AC-DC Power System, Commutation Failure, Dynamic Pattern Recognition, Early Warning Detection and Classification

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

基于电网换相换流器的高压直流(HVDC)输电系统因具有传输容量大、损耗低和允许非同步联网等优点得到了广泛应用[1]。由于 HVDC 换流站采用无自关断能力的晶闸管作为换流元件,所以受端交流电网故障极易引发逆变站发生换相失败。换相失败不仅造成直流电流短时激增,对换流阀产生冲击,还会造成直流传输功率大幅暂降,甚至进一步引发直流闭锁,给交直流混联电网的安全稳定运行带来严重的威胁[2]。传统的换相失败检测方法主要基于物理模型计算和规则阈值判断,依赖系统参数精确建模,计算复杂度较高,且难以适应电网运行状态的动态变化。随着电力系统智能化的发展,基于数据驱动的方法逐渐受到关注,尤其是深度学习技术的发展,使得利用动态模式识别的方法对换相失败进行早期征兆捕获成为可能。通过从时序数据中自动提取特征,并结合先进的模式识别算法,可以提高换相失败检测的实时性和准确性,为电力系统的安全调控提供更可靠的支撑。

2. 交直流电力系统换相失败机理

在高压直流输电(HVDC)系统中,换相失败是指换流器无法完成预定的电流换相过程,导致直流电流持续流经原换流器并无法顺利转移至目标换流器[3]。换相失败的发生不仅影响直流系统的电压和电流稳定性,还可能引发交流系统的电压波动和系统失稳,对电网安全造成严重威胁。了解换相失败的机理是提高故障检测和防护能力的基础[4]。

2.1. 换相过程及其原理

HVDC 系统中的换相过程通常发生在换流站的换流器中,换流器的作用是将交流电流转化为直流电流,

或将直流电流转化为交流电流。在换流过程中，交流电流的相位和幅值对换相的成功与否至关重要[5]。换流器通过晶闸管(Thyristor)控制电流的导通与关断，通过精确的触发控制换流器在适当的时间进行换相，换相原理过程如图 1 所示，即在交流电网电压零交点时对晶闸管进行触发，以保证换相的顺利进行[6]。




Figure 1. Process diagram of commutation principle
图 1. 换相原理过程图

2.2. 换相失败的主要诱因

2.2.1. 交流系统电压暂降或畸变

交流系统的电压波动是换相失败的主要诱因之一[7]。当交流电网发生故障(如短路故障)，交流电压会出现暂时的跌落，严重时可能会造成电压暂降达到换相失败的临界值。电压暂降使得交流电流的相位和幅值发生变化，换流器无法在适当的时刻触发晶闸管，导致换相失败[8]。下列公式描述了电压和电流相位变化如何影响换相角，进而影响换流器的换相能力。

$$\begin{aligned}\alpha + \beta &= \pi \\ \beta &= \mu + \gamma \\ \gamma &= \arccos\left(\frac{\sqrt{2}I_d X_c}{U_L} + \cos \beta\right)\end{aligned}$$

2.2.2. 直流系统的功率波动

在 HVDC 系统中，直流电流的变化直接影响换相角的控制。若直流电流发生突变，可能导致换相角超出临界值，使换流器失去换相能力[9]。例如，当直流功率出现大幅波动时，控制系统会调整换相角度以适应新的电流状态。如果换相角调节不及时或不准确，换相器将无法顺利完成换相，导致换相失败。

2.2.3. 控制系统的响应不及时

换流器的控制系统负责精确调整换相角、触发角等参数，以确保换相的顺利进行。然而，控制系统响应滞后或对交流电网扰动的调节能力不足时，可能导致换相角未能及时调整到最佳状态，进而导致换相失败[10]。例如，当交流电网发生较大扰动时，若控制系统没有及时做出调整，可能会导致换相失效。

2.3. 换相失败的后果

2.3.1. 直流电流与电压异常

换相失败后，直流电流将无法正确换向，可能出现电流急剧上升或下降的现象，直流电压也会随之

发生变化。长时间的电流异常可能导致电力设备损坏，甚至影响直流输电线路的稳定性[11]。

2.3.2. 交流电网电压波动

由于直流系统与交流系统的耦合关系，换相失败会对交流系统造成影响。具体表现为交流电网电压的波动，甚至可能导致交流电网的振荡，影响其他设备的正常运行[12]。

2.3.3. 系统失稳

当换相失败发生时，如果无法及时采取补救措施，可能引发电力系统的进一步失稳，导致大范围的电力系统崩溃或停运。特别是在高负荷和高风险情况下，换相失败可能引发连锁故障，威胁整个电网的安全。

3. 基于动态模式识别的换相失败早期征兆捕获方法

3.1. 动态模式识别概述

动态模式识别(Dynamic Pattern Recognition, DPR)是一种通过分析系统动态行为、时序数据及其演变规律，识别系统潜在故障或异常的技术。与传统的静态模式识别方法不同，动态模式识别更注重时序数据中的变化和趋势，能够捕捉到系统中潜在的动态变化和逐步发展的异常对于换相失败等突发性故障的早期预警至关重要[13]。换相失败的发生通常伴随着电压、电流、功率等关键电气参数的非线性波动，这些波动往往在初期阶段就可以被检测到，尽管它们可能十分微小。为了及时捕捉这些变化，需采用适合处理时序数据的先进算法。为提高模型的透明度，研究引入了 Grad-CAM 可视化技术，通过对卷积神经网络(CNN)模型的输出进行类激活映射，能够直观地展示模型在做出预测时，主要关注的时序数据区域。通过这种方式，研究人员能够清晰地了解哪些电力系统的动态特征(如电流、电压变化)对换相失败的预测具有重要影响，从而提高了模型的透明度与可信度。

3.2. 换相失败的动态特征分析

换相失败的早期征兆通常表现为电力系统状态变量(如电流、电压等)中的微小波动。这些变化积累后会导致更为明显的故障迹象，因此，及时捕捉这些动态特征是关键。通过分析系统的多维时序数据，可以发现潜在的动态模式，并在换相失败发生之前发出预警。

系统状态可以表示为一个时序向量：

$$x(t) = [x_1(t), x_2(t), \dots, x_N(t)]$$

其中， $x(t)$ 代表在时刻 t 的系统状态， $x_i(t)$ 为第 i 个变量(例如电压、电流等)。换相失败的早期征兆通常隐匿在这些时序信号中，通过对这些信号的动态特征进行建模与识别，能够有效提取出故障的早期指示。

3.3. 深度学习模型在动态模式识别中的应用

深度学习，尤其是卷积神经网络(CNN)和长短期记忆网络(LSTM)，在时序数据分析中取得了显著成果，特别是在电力系统故障诊断方面。

3.3.1. 卷积神经网络(CNN)

卷积神经网络(CNN)能够自动从原始时序数据中提取局部特征。对于电力系统的时序数据，CNN 可通过卷积操作识别数据中的局部模式，从而帮助识别换相失败的早期征兆。假设使用一个卷积核 K 作用于输入数据序列 $x(t)$ ，卷积操作输出特征 $y(t)$ 可以表示为：

$$y(t) = \sum_{i=0}^{w-1} x(t-i) \cdot K_i$$

其中， w 是卷积窗口的大小， K_i 是卷积核的参数。CNN 在处理电力系统的多维时序数据时，可以有效地

从数据中提取有用的局部动态特征。

3.3.2. 长短期记忆网络(LSTM)

LSTM 在时序数据的建模中尤为有效，因为它能够捕捉数据中的长期依赖性，尤其适用于换相失败这类逐步积累的动态故障[14]。LSTM 通过三个门控机制(输入门、遗忘门和输出门)对时间序列进行建模，更新每个时间步的隐藏状态 h_t 和记忆单元状态 C_t ，其更新规则如下：

输入门：

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

遗忘门：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

候选记忆单元状态：

$$\bar{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

更新记忆单元状态：

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \bar{C}_t$$

输出门：

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

隐藏状态更新：

$$h_t = o_t \cdot \tanh(C_t)$$

通过这些门控机制，LSTM 可以有效地记住长时间的依赖信息，对于捕捉换相失败前期的系统状态变化十分有效。

3.3.3. CNN-LSTM 联合模型

为了同时提取时序数据的空间特征和时间依赖性，提出了 CNN-LSTM 联合模型。在该模型中，CNN 负责从时序数据中提取局部动态特征，LSTM 则用于捕捉这些特征的时间变化关系。结合两者的优势，能够更准确地捕获换相失败的早期征兆。

设输入数据为 $X = \{x_1, x_2, \dots, x_T\}$ 经过 CNN 提取局部特征后，得到特征序列 $F_{CNN} = \{f_1, f_2, \dots, f_T\}$ 。然后，将这些特征输入 LSTM 进行时序建模，得到最终的分类结果 $\hat{y}$ ：

$$\hat{y} = \text{softmax}(W_{out} \cdot h_T + b_{out})$$

其中， h_T 为 LSTM 最后一层的输出， W_{out} 和 b_{out} 为全连接层的权重和偏置， $\hat{y}$ 是故障预测的输出。模型图如图 2 所示。




Figure 2. CNN-LSTM joint model diagram

图 2. CNN-LSTM 联合模型图

3.4. 换相失败的早期征兆捕获与分类框架

结合上述深度学习模型，构建了一个针对交直流电力系统的换相失败早期征兆捕获与分类框架。该框架首先进行数据预处理(如去噪和归一化)，然后通过 CNN 提取系统状态数据的局部特征，再通过 LSTM 建模时序依赖，最终输出分类结果，判断当前是否发生换相失败，图 3 展示了该算法的完整流程。该框架具有较高的实时性和准确性，可以在换相失败发生前的短时间内(例如 3 秒内)提前发出预警，极大提高了电力系统的安全性和稳定性。




Figure 3. Algorithm flowchart
图 3. 算法流程图

4. 实验与结果分析

4.1 实验设置

为了验证基于动态模式识别的换相失败早期征兆捕获与分类方法，采用了改进后 IEEE 39 节点交直流电力系统进行实验，如图 4 所示。实验中的数据采集周期设定为 1 毫秒(1 ms)，这一采样频率能够精确捕捉到系统的快速动态变化，确保能够及时发现换相失败等故障的早期征兆。实验总时长为 1500 秒(约 25 分钟)，期间系统经历了多种负荷波动和系统故障等情境，以确保数据的代表性和多样性。在实验数据分析部

分, 为了进一步提高模型的可解释性, 本研究使用了 SHAP 值分析方法, 来量化每个特征(如电流、电压、功率等)对最终模型输出的贡献, 从而帮助我们理解电流、电压和功率等特征如何影响换相失败的预测结果。




Figure 4. Improved IEEE39 AC/DC system model diagram
图 4. 改进 IEEE39 交直流系统模型图

在数据集的构建方面, 本实验准备了三类样本, 每类样本包含不同的系统运行状态, 并针对每种状态设计了不同的样本数量实验中所有电力系统数据(如电压、电流、功率等)均通过数字化测量装置采集, 采样频率为 1 kHz (每秒 1000 次采样), 确保能够捕获系统动态变化。数据采集通过电力系统的硬件模拟器完成, 模拟了多种工况下的系统运行行为, 包括正常运行、换相失败、控制系统故障等多种场景。

① 正常运行状态样本(3000 个): 这些样本包含电流、电压、功率等关键参数在正常工况下的时序数据, 用于训练和验证系统正常运行的状态。

② 换相失败样本(1000 个): 这些样本记录了换相失败发生时的电力系统数据, 主要包含在换相过程中电流、电压等关键参数的异常波动。

③ 混合状态样本(500 个): 这些样本是将正常运行状态与故障状态混合的样本, 模拟了电力系统在不同故障场景下的动态变化, 帮助模型学习如何在复杂场景下进行故障检测。

数据采集以每秒 1000 个数据点的频率进行, 每个数据点的时间间隔为 1 毫秒。数据通过滑动窗口方法进行分割, 每个窗口包含 50 个时间点, 即 50 毫秒的数据, 用于捕捉系统的瞬时变化, 参数设置如表 1 所示。

Table 1. Parameter setting table
表 1. 参数设置表

参数名称	设置内容
数据采集周期	1 毫秒(1 ms)
采样频率	每秒 1000 次采样
交流电压采样	0~765 kV (考虑到电力系统的电压等级)
直流电压采样	0~1500 V

续表

交流电流采样	0~3000 A
直流电流采样	0~2000 A
有功功率采样	0~2000 MW
无功功率采样	0~1000 MVar
换相角采样	0°~180°

4.2. 数据预处理

使用低通滤波器对电流、电压等时序数据进行去噪处理，去除高频噪声的影响，从而使得系统的动态特征更加突出。对所有数据进行了归一化处理，确保不同量纲的数据能够在相同的尺度下进行比较，避免某些变量因数值差异较大而主导模型训练过程。归一化处理将所有输入数据映射至 0 到 1 的范围，有效消除了不同电力参数之间的尺度差异。数据预处理后，使用滑动窗口技术将原始数据切分为多个小段，确保每个数据片段都能够反映系统在某一时刻的动态状态。这些窗口大小为 50 个时间点，即每段数据代表 50 毫秒的时间序列，方便深度学习模型处理和学习系统行为的时序特征。在数据预处理阶段，需要计算电力系统中关键的最小电压和电流值。为了准确模拟和预测系统行为，特别是换相失败等故障事件的早期征兆，使用了以下公式来计算最小电压和最小电流：

$$U_{L\min} = \frac{\sqrt{2}I_d X_c}{\cos \gamma_{\min} - \cos \beta}$$
$$I_{d\min} = \frac{U_L (\cos \gamma_{\min} - \cos \beta)}{\sqrt{2}X_c}$$

在实验中，我们模拟了三种类型的换相失败：

交流电压暂降型换相失败：模拟了在交流电网出现短路故障或电压暂降时，换相过程无法顺利进行的情景。

直流功率波动型换相失败：通过引入直流电流的快速波动，模拟了在直流系统功率大幅波动时，换相过程出现失败的情况。

控制系统响应滞后型换相失败：模拟了由于控制系统响应滞后或不及时调整换相角度导致的换相失败。

4.3. 实验结果

在实验中，所提出的基于动态模式识别的深度学习方法与两种对比方法进行了性能对比：支持向量机(SVM)和传统基于阈值的检测方法。以下表 2 是不同方法的评估结果：

Table 2. Statistical table of experimental results

表 2. 实验结果统计表

方法	准确率	精确度	召回率	F1 值
CNN-LSTM 深度学习模型	97.20%	98.40%	95.80%	97.10%
支持向量机(SVM)	87.50%	89.20%	85.30%	87.20%
基于阈值的经典方法	80.30%	82.10%	77.60%	79.80%

实验结果表明，基于 CNN-LSTM 深度学习模型的动态模式识别方法在准确率、精确度、召回率和 F1

值等指标上均优于传统方法，尤其在识别正类样本和处理复杂数据时表现更为出色。传统方法在各项指标上相对较低，说明其在电力系统故障检测中的性能有限。因此，本文所提方法在电力系统故障早期预警中具有明显优势。本文方法实验结果如图 5 混淆矩阵所示。

	正常运行状态	换相失败	混合状态
正常运行状态	2946	30	24
换相失败	60	900	40
混合状态	90	40	370

Figure 5. Confusion matrix diagram

图 5. 混淆矩阵图

4.4. 结果分析

高准确性和可靠性：所提方法通过 CNN 和 LSTM 的联合使用，在特征提取和时序建模上充分发挥了深度学习算法的优势。模型不仅能够准确分类正常与故障状态，还能够有效区分不同类型的故障，从而提供较高的准确率和精确度。

优异的实时性能：该方法能够在换相失败发生前快速准确捕捉到系统的动态变化并发出预警。这一时间提前量对于电力系统的稳定性和安全性至关重要，因为及时的故障预警可以为系统提供足够的响应时间。

强大的鲁棒性：实验数据中包括了不同负荷条件、系统波动等多种复杂情况，而所提方法在这些复杂工况下仍能保持较高的分类精度和实时性。这表明，所提出的方法对数据中的噪声和变化具有较强的鲁棒性。

较低的计算复杂度：尽管采用了深度学习模型，但由于使用了 CNN-LSTM 联合结构，模型在捕捉时序特征的同时，计算效率较高。相比于传统的基于模型的诊断方法，本文深度学习方法大大降低了计算复杂度。

5. 结语

随着电力系统的规模不断扩大及其复杂性日益增加，传统的故障检测方法已难以满足对实时性和精确性的高要求。换相失败作为一种潜在的系统威胁，及早识别其征兆对保障电力系统的安全稳定至关重要。文章提出的基于动态模式识别的深度学习方法，通过结合卷积神经网络和长短期记忆网络的优势，为电力系统故障预测提供了一种新的解决方案。尽管目前的研究已在实验中展示了良好的结果，但要真正实现该方法的广泛应用，还需克服一些挑战，随着人工智能技术和数据处理能力的进一步发展，基于

深度学习的故障预警方法将在电力系统的故障诊断与预防中扮演越来越重要的角色。

参考文献

- [1] 邹常跃, 韦嵘晖, 冯俊杰, 周月宾. 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.
- [2] 李寒冰. 高压直流输电技术在电力系统中的应用与性能分析[J]. 消费电子, 2024(2): 55-57.
- [3] 任震, 陈永进, 梁振升, 等. 高压直流输电系统换相失败的概率分析[J]. 电力系统自动化, 2004, 28(24): 19-22.
- [4] 王永平, 赵文强, 杨建明, 等. 混合直流输电技术及发展分析[J]. 电力系统自动化, 2017, 41(7): 156-167.
- [5] 苏常胜, 尹纯亚, 李凤婷. 基于直流电流动态上升的高压直流输电系统换相失败分析[J]. 电力自动化设备, 2023, 43(3): 204-209.
- [6] 郑睿娜, 胡忠山, 文兆新, 等. 高压直流输电系统交流侧故障检测方法[J]. 广东电力, 2020, 33(5): 97-104.
- [7] 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]. 陕西电力, 2020, 48(6): 1-7, 34.
- [8] 郑晨一, 汤奕. 考虑多直流无功交互影响的换相失败预防协调控制方法[J]. 电力系统自动化, 2023, 47(4): 102-110.
- [9] 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): 1-13.
- [10] 汤连军. 电力系统中柔性直流输电技术的应用研究[J]. 电力设备管理, 2024(3): 32-34.
- [11] 周博昊, 李凤婷, 尹纯亚. 高压直流输电系统后续换相失败风险评估及抑制方法[J]. 电力系统自动化, 2021, 45(5): 143-151.
- [12] 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.
- [13] 周博昊, 李凤婷, 尹纯亚, 等. 基于直流电流有限时域预测算法的换相失败预防策略[J]. 电力系统自动化, 2020, 44(6): 178-185.
- [14] 张懿, 吴艳. 基于 LSTM 的变电站电气设备运行状态自动化预测方法[J]. 科学技术创新, 2025(2): 39-42.