DOI:10.3969/j.issn.1671-024x.2026.04.008

基于深度NCA与原型网络的MMC-HVDC故障诊断方法

黄志光[1],连攀杰[2],骆 玮[1],刘嘉宸[1],时艳强[1],刘伟成[1]
(1.国家电网有限公司 华东分部,上海 200120;2.中国电力科学研究院有限公司,北京 100192)

摘 要: 针对模块化多电平换流器柔性直流输电(MMC-HVDC)系统的故障暂态过程复杂、浅层特征易混叠及在线诊断实时性要求高等问题,提出一种基于深度邻域成分分析(Deep NCA)与原型网络的故障诊断方法。首先,利用一维卷积神经网络从桥臂电流、子模块电容电压和接地电流等多通道暂态序列中自适应提取深层特征;其次,引入Deep NCA对嵌入空间进行监督度量约束,增强类内紧凑性和类间分离性;最后,基于类别原型实现快速距离判别。仿真结果表明:所提方法在5类运行状态识别中准确率达到95.20%,高于1D-CNN+Softmax、1D-ResNet和1D-Transformer等典型深度模型;负荷偏移条件下的平均准确率为91.73%,单类训练样本数减少至50组时准确率仍为86.93%,表明该方法具有一定的工况适应性和有限训练样本适应能力。

关键词: 柔性直流(HVDC)输电;模块化多电平换流器(MMC);故障诊断;深度邻域成分分析(Deep NCA);原型网络;度量学习

中图分类号: TM721.1 **文献标志码:** A **文章编号:** 1671-024X(2026)04-0062-11

Fault diagnosis method for MMC-HVDC based on Deep NCA and prototypical networks

Huang Zhiguang[1], Lian Panjie[2], Luo Wei[1], Liu Jiachen[1], Shi Yanqiang[1], Liu Weicheng[1]
(1. East China Branch, State Grid Corporation of China, Shanghai 200120, China; 2. China Electric Power Research Institute Co., Ltd., Beijing 100192, China)

Abstract: To address the complex fault transient process, feature overlapping in shallow feature spaces, and high real-time requirements for online diagnosis in modular multilevel converter-based flexible high voltage direct current (MMC-HVDC) systems, a fault diagnosis method based on deep neighborhood components analysis (Deep NCA) and prototypical networks is proposed. First, a one-dimensional convolutional neural network is used to adaptively extract deep features from multi-channel transient sequences, including arm current, submodule capacitor voltage, and grounding current. Second, Deep NCA is introduced to impose supervised metric constraints on the embedding space, enhancing intra-class compactness and inter-class separability. Finally, fast distance-based classification is achieved through class prototypes. The simulation results show that the proposed method achieves an accuracy of 95.20% for five operating states, outperforming typical deep learning models including 1D-CNN+Softmax, 1D-ResNet and 1D-Transformer. Under load-shift conditions, the average diagnostic accuracy is 91.73%, and an accuracy of 86.93% is retained when only 50 training samples per class are used. Results demonstrates that the proposed method possesses favorable adaptability to varying operating conditions and the capability to learn from limited training samples.

Key words: flexible high voltage direct current (HVDC) transmission; modular multilevel converter (MMC); fault diagnosis; deep neighborhood components analysis (Deep NCA); prototypical network; metric learning

我国可再生能源与电力负荷呈现明显逆向分布特征,西部风、光资源集中,而东部负荷中心密集[1]。为

收稿日期: 2026-07-09
基金项目: 国家电网有限公司华东分部科技项目(52992425001L);国家自然科学基金项目(52407079);湖南省自然科学基金项目(2025JJ60372)
第一作者: 黄志光(1984—),男,高级工程师,主要研究方向为电网稳定控制。E-mail:huangzhiguang1107@163.com
通信作者: 连攀杰(1994—),男,博士,高级工程师,主要研究方向为高压直流输电和电磁暂态仿真。E-mail:lianpanjie2026@163.com

实现清洁能源跨区外送与区域电网灵活互联，基于模块化多电平换流器的柔性直流输电（MMC-HVDC）系统已成为新型电力系统的重要支撑技术[2]。新能源经柔性直流送出系统已成为新型电力系统中的典型场景，但故障电流受换流器控制策略影响易出现波形畸变，传统保护的灵敏度和可靠性面临挑战[3]。同时，多类型柔直线路故障易受过渡电阻和噪声等因素影响，导致不同故障类型在局部波形和特征空间中出现混叠[4]。因此，如何构建稳定可分的故障特征空间，并兼顾在线诊断效率，是 MMC-HVDC 故障诊断需要解决的关键问题。

现有柔性直流故障诊断研究多从暂态电气量中构造判别特征。时域方法通常利用电压、电流及其变化率建立故障判据[5-6]，或基于差动电流变异特征和行波动态时间扭曲距离实现故障检测[7-8]。此类方法物理意义明确、响应速度快，但主要依赖人工提取的局部时域特征。当故障电阻增大或故障初始能量较弱时，电压突变量、桥臂电流冲击和差动电流特征可能被削弱；噪声增强时，接地电流异常也易被掩盖，导致时域可分性下降。为进一步刻画故障暂态中的振荡和频率成分，频域及时频域方法被用于故障识别。文献[9]利用暂态电压中的高频能量比区分区内外故障；文献[10]基于小波包能量谱构建暂态特征向量，并结合深度学习实现故障测距；文献[11]分析柔直电网拓扑对故障电流谱分布的影响，为复杂拓扑下的特征选取提供依据。上述方法增强了暂态信号的多尺度表达能力，但频带选择、分解尺度和特征组合仍依赖经验设定。由于故障频率成分同时受桥臂电抗器、子模块电容、线路参数和控制响应影响，固定时频特征难以稳定保持类内紧凑和类间分离。

随着智能算法的快速发展，数据驱动方法逐渐用于柔性直流故障诊断。文献[12]针对 MMC-HVDC 系统故障检测问题，引入卷积神经网络（CNN）和深度神经网络等学习方法，实现了基于原始电流信号的故障识别；文献[13]考虑 MMC-HVDC 系统的直流线路故障暂态演化规律，分析了故障电流特征变化；文献[14]针对 MMC 子模块开路故障，利用数据驱动异常检测模型实现故障识别。然而，现有数据驱动方法仍主要依赖分类网络或特征统计方式，在复杂工况、弱故障以及有限样本条件下，故障特征空间的稳定可分性仍有提升空间。针对复杂样本可分性不足的问题，近年来研究开始关注深度特征融合与度量学习方法。文献[15]针对 MMC 开关器件的故障诊断问题，引入多模态注意力融合机制，提高了复杂故障特征的提取能力；文献[16]提出基于改进原型网络的小样本故障诊断方法，通过优化类别原型提升跨域条件下的识别性能；文献[17]进一步结合原型网络与距离度量优化策略，提高了噪声和有限样本条件下的故障诊断稳定性。然而，现有方法多依赖浅层特征、固定度量或经验参数，难以充分刻画柔性直流暂态信号中的非线性耦合关系；若在线阶段采用全样本近邻搜索，计算量还将随样本规模增加，不利于实时部署。

为解决复杂工况下柔性直流故障特征可分性不足及在线判别计算量随样本规模增加的问题，本文提出一种基于深度邻域成分分析（deep neighborhood components analysis，Deep NCA）与原型网络的 MMC-HVDC 故障诊断方法。首先，利用一维卷积神经网络（1D-CNN）从桥臂电流、子模块电容电压和接地电流等多通道暂态序列中提取深层特征，以降低人工构造特征可能造成的信息损失；其次，引入 Deep NCA 对嵌入空间施加监督度量约束，增强同类样本的聚集性和异类样本的分离性；利用训练样本构建类别原型，通过待测样本与各类别原型之间的距离完成故障判别，使在线距离计算量主要与故障类别数相关；并通过模型对比、特征可视化、负荷偏移、有限训练样本和关键模块消融实验，对所提方法的诊断性能进行验证。

1　故障暂态特性与度量失效机理分析

1.1　MMC-HVDC 系统建模

本文以双端 MMC-HVDC 系统为研究对象，其拓扑结构如图 1 所示。该系统由两端交流系统、换流变压器、模块化多电平换流器及直流线路组成。MMC 每相桥臂由上、下桥臂及串联子模块构成。正常运行时，换流器通过控制子模块投入状态实现交流侧与直流侧功率交换；当直流线路、换流器子模块或交流侧发生故障时，桥臂电流、子模块电容电压和接地支路电流等电气量会出现不同形式的暂态扰动，可反映桥臂电流冲击、子模块能量波动及接地支路异常变化。本文考虑正常运行、极间短路、极接地、子模块电容电压异常和交流电压暂降耦合等 5 类状态。其中：子模块电容电压异常用于表征子模块运行异常引起的电容电压波动；交流电压暂降耦合用于表征交流侧电压暂降经换流器作用传递至直流侧的暂态响应。为兼顾多工况样本生成效率与故障暂态特征的有效表征，本文采用统一的控制—调制平均值等效框架。控制作用通过负荷运行点、交直流电压偏差以及故障后的闭锁和阻断电压动态进行表征；调制作用则通过桥臂平均电

压和子模块等效电容能量变化进行表征。各类运行及故障样本均采用相同的控制与调制等效条件，以避免控制参数和调制条件差异对故障类别识别及诊断方法对比造成额外影响。

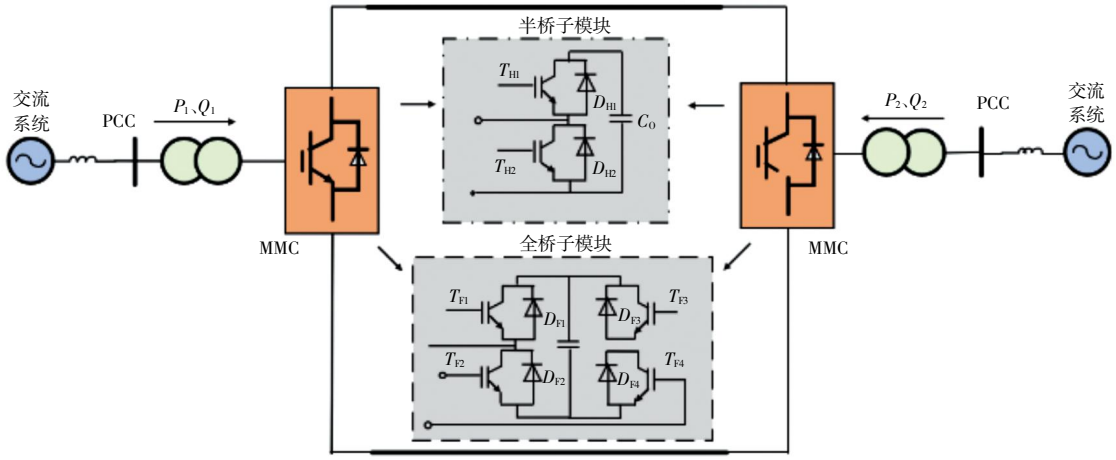


图 1　MMC–HVDC 系统拓扑结构

Fig.1　Topological structure of the MMC–HVDC system

该模型重点保留桥臂电流冲击、子模块电容能量变化和接地支路异常等与故障类别密切相关的低频暂态信息，忽略器件级开关脉冲及高频调制纹波，从而在保证主要故障特征可观测性的同时，提高多工况样本批量生成效率，为后续故障特征提取和诊断模型训练提供统一的数据基础。

1.2　故障暂态特性分析与传统判据的局限性

MMC–HVDC 系统发生故障后，换流器桥臂电流、子模块电容电压和接地电流会在短时间内产生突变、振荡和衰减等暂态响应。为对比不同运行状态下的暂态差异，选取各类状态的典型样本进行三通道波形展示，结果如图 2 所示。由图 2 可以看出，极间短路故障下桥臂电流冲击较为明显；极接地故障主要表现为接地电流异常扰动；换流器子模块故障会引起电容电压和桥臂电流振荡变化；交流故障耦合则会同时影响多个通道的暂态响应。上述现象说明，不同故障类型在多通道电气量中具有可观测的暂态差异。

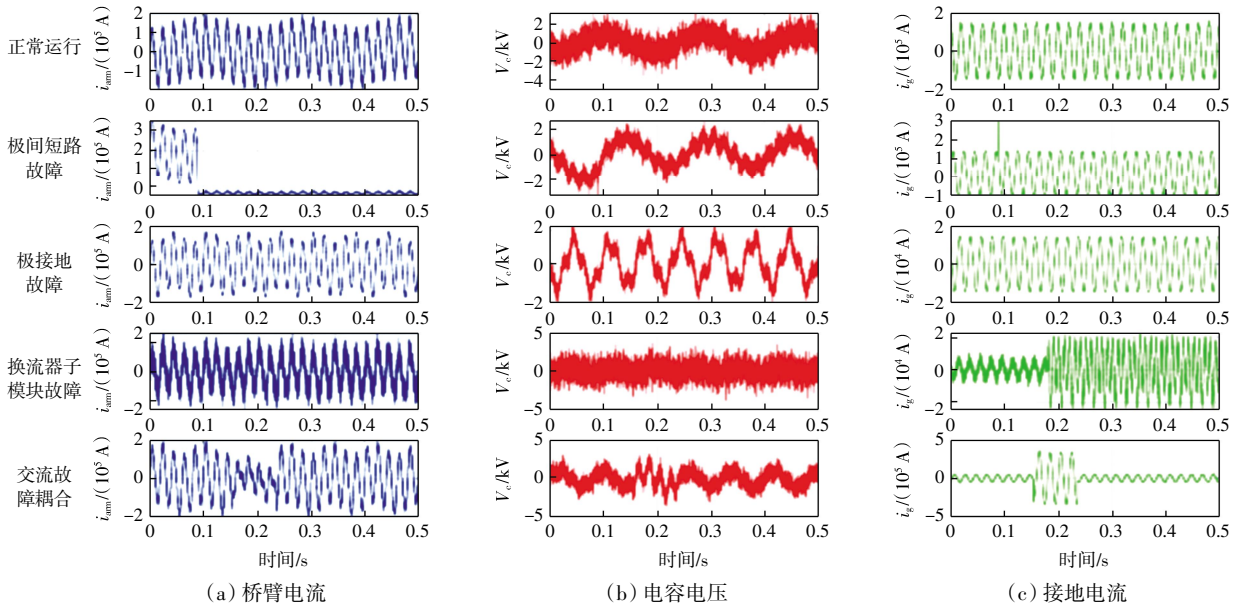


图 2　不同运行状态下三通道暂态响应样本

Fig.2　Examples of three–channel transient responses under different operating states

除故障类型外，MMC–HVDC 的控制与调制方式也会影响暂态特征。外环功率或直流电压控制决定故障前运行点，内环电流控制、限流及闭锁策略影响故障后桥臂电流峰值和衰减过程；对于半桥(HB)/全桥

（FB）混合型 MMC，FB 子模块比例及阻断电压建立速度还会改变故障回路中的有效驱动电压，进而影响桥臂电流、子模块电容电压和接地电流。不同调制方式及开关频率则会改变桥臂电压合成误差、电流纹波和电容电压波动，从而引起故障特征分布变化。

本文主要研究上述电气量的低频故障暂态特征。为保证不同故障类别及诊断方法之间的可比性，各类样本均在统一的控制与调制等效条件下生成，不逐一模拟器件级开关脉冲及高频调制纹波，重点考察故障时刻、过渡电阻、故障严重程度、负荷水平、交直流电压偏差及噪声等因素的影响。

然而，故障暂态差异并不等同于固定判据下的稳定可分。受故障电阻、接地电阻、故障严重程度、负荷水平及噪声强度等因素影响，不同故障的局部振荡、幅值衰减和多通道耦合特征可能发生变化。传统故障判据多基于电压、电流突变量、变化率、能量或频带分量构建，虽然物理意义明确、实现简单，但在弱故障、高阻故障和噪声扰动条件下容易受到阈值整定影响。当故障特征被削弱或不同类别暂态响应发生局部交叠时，单一时域或频域判据难以同时兼顾灵敏性和可靠性。

1.3　浅层度量方法与特征混叠机理分析

除固定阈值判据外，K 近邻（KNN）、支持向量机（SVM）和基于邻域成分分析的 K 近邻算法（NCA-KNN）等浅层分类方法也常用于故障识别。此类方法通常依赖人工统计特征或浅层时频特征，并基于欧氏距离、核函数或线性度量关系完成分类。当故障差异较为明显时，浅层方法能够取得一定识别效果；但在复杂扰动条件下，同类样本可能分布分散，异类样本则可能在局部区域相互接近，导致原有距离关系失真。

为分析浅层特征空间的混叠现象，本文基于时域统计量、频带能量比例和故障前后能量比构建浅层时频特征，并采用主成分分析（PCA）进行二维投影，结果如图 3 所示。

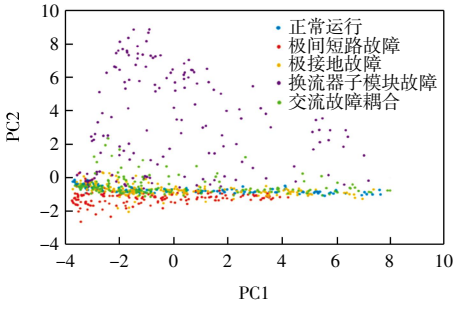


图 3　浅层时频特征空间 PCA 投影结果

Fig.3　PCA projection results of the shallow time-frequency feature space

由图 3 可以看出，部分类别样本存在明显重叠，说明人工特征和固定距离度量难以形成稳定的类内紧凑、类间分离结构。

综上，复杂工况会削弱柔性直流故障暂态差异在浅层特征空间中的稳定表达，导致人工特征与固定度量方法难以保持可靠判别。为此，后续章节将引入一维卷积神经网络（1D-CNN）提取深层暂态特征，并结合 Deep NCA 与原型网络构建面向在线诊断的距离判别模型。

2　基于深度度量与可学习原型的故障诊断模型

2.1　基于 1D-CNN 的暂态特征自适应提取

柔性直流输电系统发生故障后，换流器内部电磁能量平衡遭到破坏。其中，桥臂电流 i_{arm} 包含了交流侧基波、直流侧输送分量及阀内环流动能的非线性电磁叠加；子模块电容电压 V_{c} 动态映射了阀组内部功率的稳态纹波与充放电平衡；接地电流 i_{g} 则直接锁定了零序故障通路的暂态演化历程。受双极分层控制环路非线性耦合、高阻弱故障阻尼等多重扰动干扰，不同故障类别的精细暂态流形在局部高度混叠，人工构造特征极易发生物理信息遗漏。为此，本文利用 1D-CNN 沿时间轴提取三通道暂态序列中的局部突变与振荡衰减特征。三通道信号的采样频率为 10 kHz，采样周期为 0.1 ms，单个样本时间窗长度为 0.5 s，每通道包含 5 001 个采样点[18]。首先进行通道标准化以消除运行点偏移：

$$\tilde{x}_{i,c,t}=\frac{x_{i,c,t}-\mu_{i,c}}{\sigma_{i,c}+\varepsilon} \tag{1}$$

式中：$x_{i,c,t}$ 和 $\tilde{x}_{i,c,t}$ 分别为标准化前、后的采样值；$\mu_{i,c}$ 和 $\sigma_{i,c}$ 分别为第 i 个样本第 c 个通道的均值和标准差；ε 为极小常数。标准化后的暂态序列输入 1D-CNN 后，通过卷积核沿时间轴滑动提取局部突变、振荡衰减及多通道耦合特征。第 l 层特征映射可表示为：

$$H^{(l)}=\sigma[\mathrm{BN}(W^{(l)}*H^{(l-1)}+b^{(l)})] \tag{2}$$

式中：* 为一维卷积运算；$W^{(l)}$、$b^{(l)}$ 分别为卷积核权重和偏置；BN(·) 为批归一化；$\sigma(\cdot)$ 为激活函数。为配合后续度量学习，1D-CNN 不直接输出故障类别，而是将输入样本映射为深层嵌入向量：

$$z_i=f_\theta(x_i),z_i\in\mathbf{R}^d \tag{3}$$

式中：$f_\theta(\cdot)$ 为 1D-CNN 特征映射函数；z_i 为故障暂态深层表征；$\mathbf{R}^d$ 为 d 维实数空间；d 为嵌入特征维数，本文取值 $d=64$。该表征作为 Deep NCA 度量空间重构和原型分类的输入。

本文采用 6 层一维卷积构建暂态特征提取器，各卷积层输出通道数依次为 32、32、64、64、128 和 128，卷积核尺寸依次为 15、7、7、5、5 和 3，步长均设置为 2。每个卷积层后依次采用批归一化和修正线性单元（ReLU）激活，并在 3 个卷积模块末端分别设置随机失活（Dropout），丢弃率分别为 0.15、0.21 和 0.30。网络不设置常规最大池化层，而是通过步长卷积逐级压缩时间维度，最后利用全局平均池化获得 128 维特征向量。

在此基础上，Deep NCA 投影头采用“128—128—64”的 2 层全连接结构，中间层依次设置批归一化、ReLU 激活和丢弃率为 0.20 的 Dropout，最终将 CNN 特征映射为 64 维嵌入向量。为统一后续 Deep NCA 和原型分类所采用的相似性度量，对嵌入向量进行 L_2 归一化。

2.2　基于 Deep NCA 的非线性度量空间重构

经 1D–CNN 提取后的特征虽包含通道耦合信息，但常规分类损失通常仅关注离散分类边界的划分。在实际运行中，当发生高阻极接地故障时，较大的过渡电阻限制了暂态电流突变幅值，使得换流站宏观电气量表现出类似于正常负荷波动或微弱交流故障的电磁响应，导致局域嵌入特征大面积交叠。为此，本文引入 Deep NCA 度量约束，利用双极分层控制系统中外环功率解耦与内环电流控制在恶劣工况下的非线性动力学差异，在损失函数中施加监督度量惩罚。在重构的空间中，样本 i 选择样本 j 作为邻近样本的概率定义为：

$$p_{ij}=\frac{\exp(-\|\boldsymbol{z}_i-\boldsymbol{z}_j\|_2^2/\tau)}{\sum_{k\neq i}\exp(-\|\boldsymbol{z}_i-\boldsymbol{z}_k\|_2^2/\tau)},\ j\neq i \tag{4}$$

式中：$\boldsymbol{z}_i$、$\boldsymbol{z}_j$ 分别为当前训练批次内样本 i 和样本 j 的嵌入向量；$\|\boldsymbol{z}_i-\boldsymbol{z}_j\|_2^2$ 表示两样本在嵌入空间中的平方欧氏距离；τ 为温度系数，用于调节距离概率分布的平滑程度，本文设置为 0.1。温度系数较小时，邻域概率更集中于距离较近的样本；温度系数增大时，概率分布相对平滑。其中，$j\neq i$ 以及分母求和条件 $k\neq i$ 表明邻域概率计算过程中排除了样本自身。样本 i 被正确归类的概率为其选择同类样本作为邻近样本的概率之和：

$$p_i=\sum_{j:y_j=y_i}p_{ij} \tag{5}$$

式中：y_i 和 y_j 分别为样本 i 和样本 j 的类别标签。由此构造 Deep NCA 损失函数：

$$L_{\mathrm{NCA}}=-\frac{1}{N}\sum_{i=1}^{N}\ln(p_i+\varepsilon) \tag{6}$$

式中：N 为当前训练批次内的样本数量，本文训练批大小设置为 64；ε 为保证对数计算稳定性的极小常数。Deep NCA 损失在每个训练批次内部计算，首先根据该批次内样本两两之间的距离获得邻域概率，再对批次内 N 个样本的损失取平均。

在模型训练过程中，三通道暂态序列首先经 1D–CNN 提取深层特征，再通过 Deep NCA 投影头映射为 L_2 归一化的嵌入向量。在此基础上，分别计算 Deep NCA 度量损失和原型分类损失，并采用二者的加权和作为联合训练目标。联合损失通过端到端反向传播，同步优化 1D–CNN 特征提取器、Deep NCA 投影头和类别原型参数，从而实现暂态特征提取、度量空间重构和原型分类的协同优化。

2.3　基于原型网络的快速在线分类机制

柔性直流输电系统对故障诊断具有较高的实时性要求。若在线阶段采用全样本近邻搜索，距离计算量将随训练样本规模增加，可能提高边缘诊断的在线计算开销。原型网络利用重构空间中各类故障特征的几何中心作为分类代表，使在线距离计算量主要与故障类别数相关，因而适用于换流站监测终端或柔性直流控制保护装置的快速辅助诊断场景[19]。

设第 k 类故障样本集合为 S_k，其类别原型定义为该类样本嵌入特征的均值：

$$\boldsymbol{c}_k=\frac{1}{|S_k|}\sum_{(X_i,y_i)\in S_k}f_\theta(X_i) \tag{7}$$

式中：$\boldsymbol{c}_k$ 为第 k 类故障原型；$|S_k|$ 为该类样本数量。对于待诊断样本 X_q，经 1D–CNN 映射得到嵌入向量 $\boldsymbol{z}_q=f_\theta(X_q)$，其与各类别原型之间的距离为：

$$d_k=\|\boldsymbol{z}_{\mathrm{q}}-\boldsymbol{c}_k\|_2^2 \tag{8}$$

最终故障类别按最小距离原则确定：

$$\hat{y}=\arg\min_k d_k \tag{9}$$

为提高诊断结果的可解释性，可进一步将距离转换为类别置信度：

$$P(y=k|X_{\mathrm{q}})=\frac{\exp(-d_k/\tau_{\mathrm{p}})}{\sum_{m=1}^{K}\exp(-d_m/\tau_{\mathrm{p}})} \tag{10}$$

式中：k 为故障类别数；τ_{p} 为温度系数；下标 q 表示待诊断样本；下标 p 表示原型分类。本文诊断任务包括正常运行、极间短路、极接地、子模块电容电压异常和交流电压暂降耦合 5 类状态，因此在线判别阶段仅需计算待测样本嵌入与 5 个类别原型之间的余弦相似度。

为协同优化暂态特征提取、嵌入空间重构和原型分类，本文采用原型分类损失与 Deep NCA 损失构成

联合训练目标：

$$L_{\text{total}} = L_{\text{cls}} + \lambda_{\text{NCA}} L_{\text{NCA}} \tag{11}$$

式中：L_{cls} 为基于式(10)类别概率计算的原型分类损失，训练中采用标签平滑交叉熵，标签平滑系数设置为 0.1；L_{NCA} 为式(6)定义的批内 Deep NCA 损失；λ_{NCA} 为 Deep NCA 损失权重，本文设置为 0.5。在每个训练批次中，联合损失通过一次端到端反向传播同步更新 1D-CNN 特征提取器、Deep NCA 投影头和类别原型参数，从而使 3 个模块在统一目标下协同优化。

类别原型仅基于训练集样本的联合损失反向传播进行学习。验证集用于选择最优模型，测试集仅用于最终性能评价，二者均不参与类别原型参数更新。训练完成后，类别原型随最优模型参数一同固定。测试及在线判别阶段仅进行特征前向映射和原型相似度计算，不再更新网络及类别原型参数。在线原型更新仅作为应对长期运行中样本分布漂移的后续扩展策略，未纳入本文实验。该方式将在线分类计算量由训练样本规模相关转化为类别数量相关，在保持度量判别能力的同时降低在线判别复杂度。

2.4　在线诊断整体流程与工程应用讨论

在线故障诊断流程如图 4 所示，主要包括离线联合训练与原型固定、在线原型判别 2 个阶段。离线阶段，通过多工况故障样本完成暂态序列标准化、1D-CNN 特征提取和 Deep NCA 度量空间训练，并据此构建类别原型库。在线阶段，当保护或录波装置触发后，截取短时窗暂态信号，经特征映射后计算其与各类别原型之间的距离，并输出故障类型及置信度。当置信度低于设定阈值时，诊断结果进入复核流程。

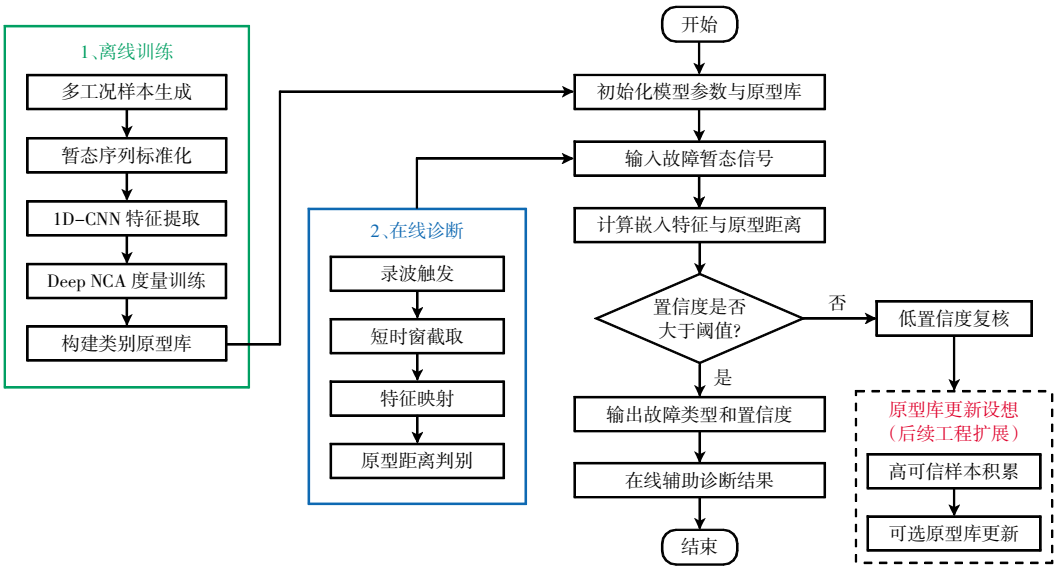


图 4　基于 Deep NCA 与原型网络的在线故障诊断流程

Fig.4　Online fault diagnosis process based on Deep NCA and prototypical networks

从工程实现角度看，本文所提方法将主要计算量集中在离线训练阶段，在线侧仅需完成一次特征前向映射和少量原型距离计算，计算复杂度与故障类别数相关。本文诊断任务包括 5 类运行状态，因此在线判别阶段仅需计算待测样本与 5 个类别原型之间的距离，较全样本近邻搜索更适合部署于换流站监测终端或边缘计算平台。

现场采集信号易受互感器误差、通信干扰、开关动作和背景噪声影响，尤其在高阻接地、弱故障和复合扰动条件下，接地电流异常、桥臂电流冲击及子模块电容电压波动可能被噪声削弱，导致不同故障暂态特征局部接近。为提高抗噪性，本文在样本构建阶段引入不同噪声水平和多工况扰动，使模型在离线训练过程中学习噪声背景下的暂态特征分布；在线诊断时，可利用类别置信度对低置信度样本进行人工复核或保护逻辑复核，以降低噪声扰动导致的误判风险。

此外，实际工程中故障样本通常存在类别不平衡问题，正常运行和常见故障样本较多，而高阻接地、子模块异常及复合扰动样本相对有限。针对该问题，工程应用中可在离线训练阶段引入类别均衡采样、少数类样本扩充和类别权重约束，降低多数类样本对模型训练的主导作用。原型网络以类别中心参与在线判别，可避免在线阶段因某类样本数量过多而增加计算量。本文实验采用训练完成后固定的类别原型，测试及在线判别过程中不实施原型更新。对于长期运行中可能出现的样本分布漂移，后续工程部署中可探索利用人工复核或保护逻辑确认的高可信样本更新原型库，该策略属于扩展设想，未纳入本文实验验证。因

此，本文所提流程为柔性直流输电系统在线辅助诊断提供了一种可行的实现思路，但其完整工程性能仍需结合现场录波或硬件在环数据进一步验证。

3　仿真与结果分析

3.1　仿真模型搭建与多工况样本集构建

为验证所提方法在不同运行与故障状态下的诊断性能，本文基于图 1 所示 MMC–HVDC 拓扑构建仿真模型。仿真信号采样频率为 10 kHz，单样本时间窗为 0.5 s，模型输入包括桥臂电流、子模块电容电压和接地电流 3 个通道。本文设置正常运行、极间短路、极接地、子模块电容电压异常和交流电压暂降耦合 5 类状态，各类状态的主要仿真实现、响应电气量及样本数量如表 1 所示。每类状态生成 500 组样本，共获得 2 500 组样本。数据集按 7∶1.5∶1.5 划分为训练集、验证集和测试集，分别用于模型训练、参数选择和最终性能评价。实验平台为 Intel Core i5–1135G7@2.40 GHz 处理器、16 GB 内存的 Windows 11 计算机，所有方法均采用 CPU 模式运行，软件环境为 Python 3.13、PyTorch 2.11、NumPy 和 scikit–learn。

表 1　5 类运行状态及其仿真实现

Tab.1　Five operating states and their simulation implementations

状态类别	主要仿真实现	主要响应量	样本数
正常运行	不施加故障扰动	三通道正常响应	500
极间短路	直流电压跌落及快速阻断	桥臂电流、电容电压	500
极接地	接地支路动态特性变化	接地电流、电容电压	500
子模块电容电压异常	故障后电容电压波动	电容电压	500
交流电压暂降耦合	交流电压暂降及交直流耦合响应	桥臂电流、电容电压	500

不同状态在 3 类输入电气量中呈现出不同的暂态响应。桥臂电流主要反映换流器内部电流冲击、直流阻断及交直流侧能量交换过程；子模块电容电压能够表征子模块充放电状态、内部能量平衡及异常电压波动；接地电流对接地支路和极接地故障通道的暂态变化较为敏感。因此，3 类电气量分别从电流冲击、能量波动和接地支路异常等方面描述不同运行状态下的暂态特征，为后续深层特征提取和故障判别提供输入基础。

样本生成过程中，对故障发生时刻、接地支路电阻、故障严重程度、负荷系数、直流电压偏差、交流电压偏差及信噪比进行随机设置。其中，故障发生时刻为 0.08~0.15 s，接地支路电阻为 0.01~5.00 Ω，故障严重程度系数为 0.5~1.0，负荷系数为 0.7~1.3，直流电压偏差和交流电压偏差均为–5%~5%，信噪比为 15~40 dB。上述参数均在相应范围内采用均匀随机采样，并在桥臂电流、子模块电容电压和接地电流 3 个通道中分别叠加加性高斯白噪声，以增加不同运行点和扰动条件下暂态样本的多样性。

3.2　度量空间的特征流形可视化

为直观观察 Deep NCA 重构后故障特征的分布情况，采用 t 分布随机邻域嵌入（t–SNE）方法对测试样本的嵌入特征进行二维可视化，结果如图 5 所示。图中不同颜色散点表示不同故障类别样本，星形标记表示各类别样本在二维可视化空间中的中心位置，与高维嵌入空间中的类别原型并不等同。

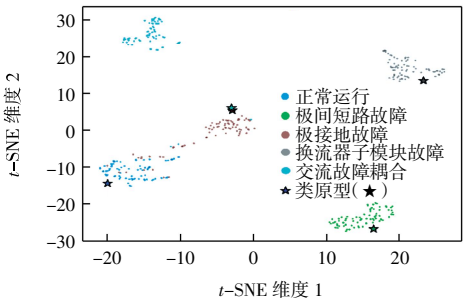


图 5　Deep NCA 重构故障特征空间的 t–SNE 可视化结果

Fig.5　t–SNE visualization results of the fault feature space reconstructed by Deep NCA

由图 5 可以看出，各故障类别在二维投影中呈现较清晰的主簇结构和类间分离趋势。从可视化结果看，Deep NCA 重构后的同类样本较为集中，不同类别样本之间保持一定间隔。仅在聚类边缘存在少量弱故障、高阻接地及混合扰动样本的混叠，这可能与此类样本暂态幅值较弱、部分电气量变化与正常扰动或其他故障类型存在相似性有关。但上述边缘混叠未破坏整体可分结构，总体上仍能够观察到较好的类内聚集和类间分离趋势。由于二维投影受 t–SNE 降维过程影响，主要用于定性观察特征分布，模型性能需结合后续定量结果综合评价。

3.3　综合诊断精度与实时性能对比

为验证所提方法的综合性能，选取 KNN、NCA–KNN、SVM、1D–CNN+Softmax、1D–ResNet（一维残差网络）和 1D–Transformer 作为对比方法[20–21]，结果如表 2 所示，所提方法的归一化混淆矩阵如图 6 所示。表 2 中，单样本推理时间仅统计测试样本的模型计算与分类判别过程，不包括数据预处理和后处理，各方法均在相同平台和统一计时条件下完成测试。

表 2　不同诊断方法的综合性能对比

Tab.2　Comparison of comprehensive performance of different diagnostic methods

方法	准确率/%	单样本推理时间/ms
KNN（K=3）	68.53	5.865
NCA-KNN	84.27	0.008
SVM（RBF）	81.33	0.076
1D-CNN+Softmax	90.93	1.749
1D-ResNet	94.13	8.895
1D-Transformer	87.47	1.866
本文方法	95.20	0.400

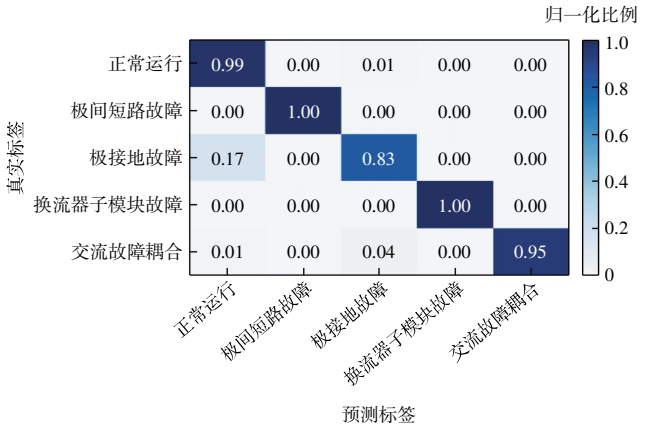


图 6　所提方法的归一化混淆矩阵

Fig.6　Normalized confusion matrix of the proposed method

结合表 2 可知，不同方法的性能差异主要来源于特征表征方式和分类机制。KNN 和 SVM 依赖浅层特征，在故障电阻、负荷水平和噪声扰动共同作用下难以稳定区分不同故障类别。NCA-KNN 通过度量学习改善了样本间距离关系，但仍受浅层特征表达能力限制。1D-CNN+Softmax、1D-ResNet 和 1D-Transformer 等深度模型能够直接提取多通道暂态序列中的局部突变和振荡衰减特征，因此整体准确率较高。

由表 2 可知，本文方法准确率达到 95.20%，高于所有对比方法。这表明所提方法并非仅依赖深层网络的特征提取能力，而是通过 Deep NCA 进一步优化嵌入空间中的距离关系，使故障样本具有更好的类内紧凑性和类间分离性。从推理时间看，本文方法的单样本推理时间为 0.400 ms，低于所比较的深度学习方法，但高于 NCA-KNN 和 SVM，因此并非全部对比方法中推理时间最低。NCA-KNN 虽然推理时间更短，但其诊断准确率低于本文方法。综合来看，本文方法在提高诊断准确率的同时，保持了较低的深度模型计算开销。在线分类阶段仅需计算待测样本与有限个类别原型之间的相似度，分类计算量不随训练样本数量直接增加。

结合图 6 的归一化混淆矩阵可知，各状态识别结果均紧密聚焦于主对角线。其中，仅极接地故障因高阻、弱故障暂态幅值微弱而存在少量误判。该现象与故障机理相符：当接地电阻较大时，接地电流突变量减小，故障特征容易与负荷扰动或弱交流故障响应接近。

3.4　负荷偏移条件下的工况适应性分析

为验证所提方法对运行工况变化的适应能力，设置不同负荷偏移系数进行测试，结果如图 7 所示。

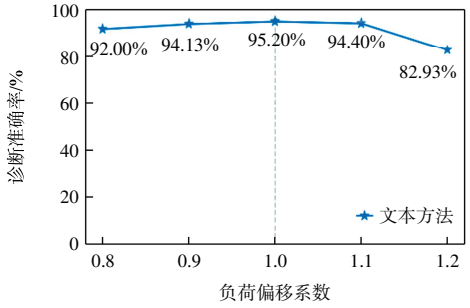


图 7　不同负荷偏移条件下本文方法的诊断准确率变化

Fig.7　Diagnostic accuracy of the proposed method under different load shift conditions

由图 7 可知，在 0.8~1.1 的轻中度负荷偏移下，模型准确率均稳定在 92.00%以上。这说明当系统运行点在一定范围内变化时，所提方法仍能保持较稳定的故障识别能力，表明模型并未过度依赖某一固定负荷条件下的暂态幅值特征。当负荷偏移系数达 1.2 时，由于严重的潮流改变使得换流站暂态运行轨迹大幅偏离基准状态，导致特征流形发生显著漂移，准确率降至 82.93%。整体平均准确率为 91.73%，验证了工况泛化能力。同时，该结果也表明，若要进一步提升极端运行条件下的诊断稳定性，后续可通过补充极端负荷样本或引入原型更新机制改善模型适应能力。

3.5　不同训练样本规模下的诊断性能分析

为分析训练样本规模对模型诊断性能的影响，保持验证集和测试集不变，分别选取低于完整训练规模的单类样本数量构成训练集，结果如表 3 所示。

表 3　不同训练样本规模下的模型诊断准确率

Tab.3　Diagnostic accuracy under different training-sample sizes

单类训练样本量	准确率/%			
	KNN	NCA-KNN	1D-CNN+Softmax	本文方法
50	66.13	72.27	82.67	86.93
100	67.47	76.00	89.33	90.13
200	67.20	81.60	90.67	93.07

由表 3 可以看出，诊断准确率随样本规模扩大而

整体提升。本文方法在单类仅 50 组样本的小样本极端条件下仍能取得 86.93%的准确率，且在各规模下均显著优于对比方法，证明了其在有限训练数据下的稳健适应性。

3.6　关键模块消融分析

为进一步验证 Deep NCA 度量约束和原型判别机制对模型性能的影响，设置不同模块组合进行消融实验，结果如图 8 所示。

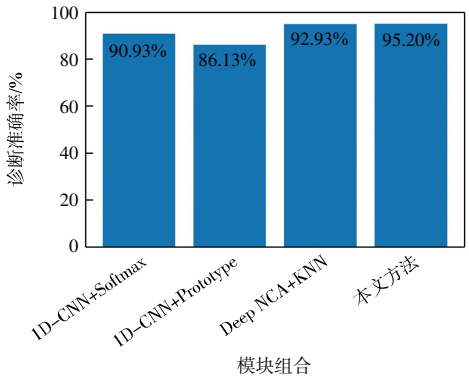


图 8　关键模块消融实验结果

Fig.8　Ablation results of key modules

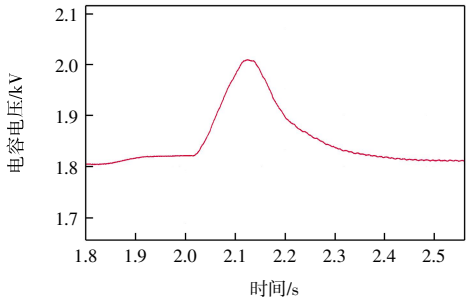
由图 8 可知，1D-CNN+Softmax 准确率为 90.93%，说明 1D-CNN 能够从多通道暂态序列中提取有效深层特征。移去度量约束后，1D-CNN+Prototype 准确率下降至 86.13%，说明原型判别机制需要建立在良好的嵌入空间结构之上；若直接在未经度量约束的特征空间中计算欧氏距离，类别原型难以准确代表复杂工况下的故障分布。引入度量约束后，Deep NCA+KNN 准确率回升至 92.93%，表明 Deep NCA 能够有效改善样本距离关系，提高特征空间的可分性。两模块协同的本文方法最终达到最高值 95.20%。这说明 Deep NCA 主要增强“特征空间可分性”，原型网络主要提升“在线判别效率”，二者结合后形成了较好的互补效果。消融结果表明，本文方法的性能提升来源于“深层特征提取—度量空间重构—原型判别”的协同作用，验证了所提模型结构设计的合理性。

3.7　工程参数下的高保真电磁暂态算例分析

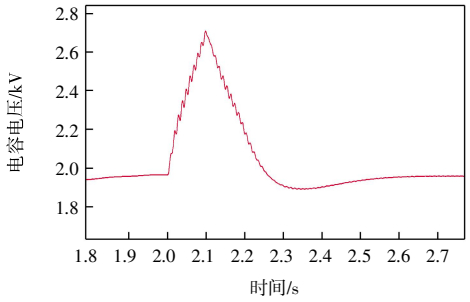
为进一步增强所选故障诊断输入量的工程机理支撑，本文采用中国电力科学研究院 PSModel 大电网级全电磁暂态仿真平台开展工程参数下的典型故障算例分析。该算例基于甘肃—浙江±800 kV 特高压柔性直流工程参数及华东电网运行方式构建，系统采用双极高低端分层柔直拓扑，包含混合型 MMC 换流阀、直流线路、换流变压器以及极—层—阀多层级控制与故障穿越环节。

需要说明的是，本节数据为基于工程参数生成的高保真电磁暂态仿真结果，并非现场故障录波或 RT-LAB 硬件实时仿真数据。由于该部分数据未按照本文样本集的三通道形式构建，也未直接作为故障诊断网络的独立测试集，因此本节主要用于分析典型工程故障下多种电气量的暂态演化规律，以及其与本文所选输入特征之间的物理一致性。

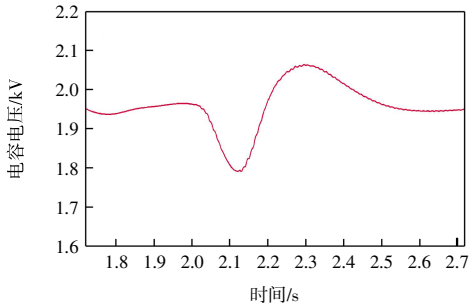
选取受端高端 MMC 单相短路故障进行分析，送端、受端高端和受端低端等各子模块电容电压的平均值如图 9 所示。



(a) 送端子模块电容电压平均值



(b) 受端高端子模块电容电压平均值



(c) 受端低端子模块电容电压平均值

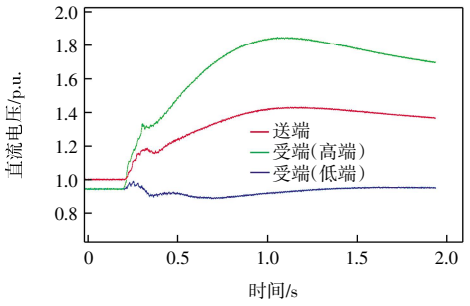
图 9　单相短路故障下不同换流站及阀组的子模块电容电压平均值

Fig.9　Average submodule capacitor voltages of different converter stations and valve groups under single-phase short-circuit fault

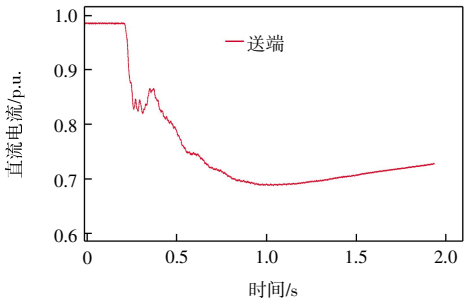
由图 9 可以看出，故障发生后，受端高端子模块电容电压出现明显过电压和振荡，送端及受端低端则受分层控制保护策略和系统耦合作用影响，呈现出

不同的动态变化趋势。这表明，大系统故障会在不同换流站和不同阀组之间形成具有空间差异的暂态响应，子模块电容电压能够反映故障期间阀组内部的能量积累、转移与释放过程。因此，将子模块电容电压作为故障诊断输入量，有助于表征换流器内部能量状态变化。

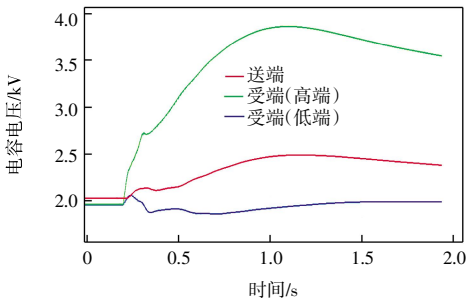
进一步选取受端高端 MMC 发生 5.5 Ω 三相非金属性接地故障的典型工况，其直流电压、直流电流和子模块电容电压响应如图 10 所示。



（a）直流电压



（b）直流电流



（c）子模块电容电压情况

图 10　三相非金属性接地故障下的电气量暂态响应

Fig.10　Transient responses of electrical quantities under three-phase non-metallic grounding fault

由图 10 可以看出，故障发生后，受端高端直流电压快速升高，直流电流受系统控制及故障穿越策略影响呈下降趋势，子模块电容电压则因阀组内部短时能量积累而明显升高。该过程表明，高阻或非金属性故障下的暂态特征不一定表现为单一电流突变量增强，还可能体现为直流电压、直流电流和子模块电容电压之间的耦合变化。因此，仅依靠单一电气量或固定阈值可能难以稳定识别此类故障，采用多通道暂态信息进行联合分析具有必要性。

上述工程参数算例表明，在多层级控制保护及大系统耦合条件下，柔性直流故障仍会在电流和子模块电容电压等电气量中形成可观测的暂态差异。这与本文从电流冲击、子模块能量变化及接地异常等不同角度构建多通道诊断输入的思路具有物理一致性，也为采用多通道特征融合方法识别弱故障和复杂故障提供了工程机理支撑。

但应指出，本节算例仅用于补充验证所选输入特征的物理合理性，尚不能代替现场故障录波或硬件在环条件下的算法性能验证。不同工程控制策略、现场测量误差和复杂噪声条件下的诊断泛化性能，仍需结合 RT-LAB 硬件在环试验或实际工程录波数据进一步研究。

4　结　论

本文针对 MMC-HVDC 系统故障暂态特征复杂、浅层特征易混叠及在线诊断实时性要求高等问题，提出了一种基于 Deep NCA 与原型网络的故障诊断方法，主要结论如下：

（1）Deep NCA 能够改善故障嵌入空间分布，使同类样本更加集中、异类样本间隔增大，为距离判别提供有效特征基础。

（2）所提方法在 5 类运行状态识别中取得 95.20% 的诊断准确率，优于 KNN、NCA-KNN、SVM、1D-CNN+Softmax、1D-ResNet 和 1D-Transformer 等对比方法。

（3）原型网络将在线分类转化为待测样本与类别原型之间的距离计算，在保持较高诊断精度的同时降低了在线判别复杂度。

（4）负荷偏移和不同训练样本规模实验表明，所提方法在本文仿真模型及参数变化范围内具有一定的工况适应性和有限样本适应能力。所提方法在不同工程拓扑、控制策略和现场噪声条件下的泛化性能仍需结合实时数字仿真、硬件在环试验和现场录波数据做进一步验证。

参考文献：

[1]　王佳，吴任博，肖健，等. 新型电力系统能源调度与碳排放计价优化方法研究[J]. 电测与仪表，2024，61(10)：17-25.
Wang Jia，Wu Renbo，Xiao Jian，et al. Research on the optimization method of energy dispatc hing and carbon emission

pricing for novel power system[J]. Electrical Measurement & Instrumentation, 2024, 61(10): 17–25(in Chinese).

[2] 雷顺广, 束洪春, 李志民. 基于桥臂功率特征的全–半混合型柔性直流输电线路保护[J]. 电工技术学报, 2023, 38(13): 3563–3575.
Lei Shunguang, Shu Hongchun, Li Zhimin. Full–half bridge hybrid VSC–HVDC transmission line protection method based on power characteristics of bridge arms[J]. Transactions of China Electrotechnical Society, 2023, 38(13): 3563–3575(in Chinese).

[3] 慕宗君, 邱俊宏, 李振兴, 等. 多类型故障影响下柔直线路故障机理分析及单端保护方法[J]. 中国电力, 2025, 58(1): 107–114.
Mu Zongjun, Qiu Junhong, Li Zhenxing, et al. Fault mechanism analysis and one–terminal protection method of flexible DC transmission line under the influence of multi–type faults[J]. Electric Power, 2025, 58(1): 107–114(in Chinese).

[4] 张博, 王聪博, 詹荣荣, 等. 计及控保协同的自适应电流差动保护方法[J]. 中国电力, 2025, 58(2): 1–8.
Zhang Bo, Wang Congbo, Zhan Rongrong, et al. Adaptive current differential protection method considering control and protection coordination[J]. Electric Power, 2025, 58(2): 1–8(in Chinese).

[5] 李景丽, 袁豪, 徐铭铭, 等. 小电阻接地系统高阻接地故障检测技术综述[J]. 电测与仪表, 2023, 60(6): 10–18, 51.
Li Jingli, Yuan Hao, Xu Mingming, et al. Overview of high impedance fault detection technology in small resistance grounding system[J]. Electrical Measurement & Instrumentation, 2023, 60(6): 10–18, 51(in Chinese).

[6] 茆美琴, 程德健, 袁敏, 等. 基于暂态能量流的模块化多电平高压直流电网接地优化配置[J]. 电工技术学报, 2022, 37(3): 739–749.
Mao Meiqin, Cheng Dejian, Yuan Min, et al. Optimal allocation of grounding system in high voltage direct current grid with modular multi–level converters based on transient energy flow[J]. Transactions of China Electrotechnical Society, 2022, 37(3): 739–749(in Chinese).

[7] 张心怡, 盖午阳, 孙巧玉, 等. 基于电流变异特性的直流配电系统单极接地差动保护方法[J]. 智慧电力, 2025, 53(6): 93–100.
Zhang Xinyi, Gai Wuyang, Sun Qiaoyu, et al. Single–pole grounding differential protection method for DC distribution systems based on current variation characteristics[J]. Smart Power, 2025, 53(6): 93–100(in Chinese).

[8] 韦延方, 吴凯航, 王晓卫, 等. 基于故障行波 VS–DDTW 距离的柔性直流输电线路保护方案[J]. 电力系统及其自动化学报, 2025, 37(12): 24–34.
Wei Yanfang, Wu Kaihang, Wang Xiaowei, et al. Protection scheme for flexible DC transmission line based on VS–DDTW distance of fault traveling waves[J]. Proceedings of the CSU–EPSA, 2025, 37(12): 24–34(in Chinese).

[9] 李杭泽, 戴志辉, 石旭, 等. 计及控制响应的多端混合直流输电系统短路电流近似计算方法[J]. 电工技术学报, 2024, 39(9): 2810–2824.
Li Hangze, Dai Zhihui, Shi Xu, et al. Approximate calculation method of short–circuit current of multi–terminal hybrid DC transmission system considering control strategy[J]. Transactions of China Electrotechnical Society, 2024, 39(9): 2810–2824(in Chinese).

[10] 王雪芹, 张大海, 李猛, 等. 基于小波能量谱和 SSA–GRU 的混合直流输电系统故障测距方法[J]. 电力系统保护与控制, 2023, 51(12): 14–24.
Wang Xueqin, Zhang Dahai, Li Meng, et al. Fault location method for a hybrid DC transmission system based on wavelet energy spectrum and SSA–GRU[J]. Power System Protection and Control, 2023, 51(12): 14–24(in Chinese).

[11] 张英敏, 张文馨, 李保宏, 等. 柔直电网拓扑对故障电流的影响机理分析[J]. 电力工程技术, 2022, 41(5): 94–102.
Zhang Yingmin, Zhang Wenxin, Li Baohong, et al. Influence mechanism of MMC–HVDC grid topology on fault current[J]. Electric Power Engineering Technology, 2022, 41(5): 94–102(in Chinese).

[12] Wang Q H, Yu Y X, Ahmed H O A, et al. Fault detection and classification in MMC–HVDC systems using learning methods[J]. Sensors, 2020, 20(16): 4438.

[13] 李伟杰, 郝亮亮, 叶雪辉, 等. 考虑放电耦合的 MMC–HVDC 系统直流线路单极接地故障电流的计算方法[J]. 南方电网技术, 2023, 17(9): 68–75.
Li Weijie, Hao Liangliang, Ye Xuehui, et al. Calculation method for pole–to–ground fault current of DC lines in MMC–HVDC system considering discharging coupling[J]. Southern Power System Technology, 2023, 17(9): 68–75(in Chinese).

[14] 杨贺雅, 邢纹硕, 向鑫, 等. 基于多元高斯分布异常检测模型的 MMC 子模块开路故障诊断方法[J]. 电工技术学报, 2023, 38(10): 2744–2756.
Yang Heya, Xing Wenshuo, Xiang Xin, et al. A sub–module open–circuit fault detection and location strategy for modular multilevel converters based on multivariate Gaussian distribution[J]. Transactions of China Electrotechnical Society, 2023, 38(10): 2744–2756(in Chinese).

[15] Ke L Z, Hu G Z, Yang Y Q, et al. Fault diagnosis for modular multilevel converter switching devices via multimodal attention fusion[J]. IEEE Access, 2023, 11: 135035–135048.

[16] Tang T, Wang J W, Yang T Y, et al. An improved prototypical network with L2 prototype correction for few–shot cross–domain fault diagnosis[J]. Measurement, 2023, 217: 113065.

[17] Wang C D, Yang J L, Zhang B Q. A fault diagnosis method

（下转第 79 页）

material and metallic shielding[C]//2012 IEEE International Symposium on Electromagnetic Compatibility. Pittsburgh: IEEE, 2012: 640–645.

[9] Wang K, Zuo Z P, Sang L, et al. Comprehensive analysis for electromagnetic shielding method based on mesh aluminium plate for electric vehicle wireless charging systems[J]. Energies, 2022, 15(4): 1546.

[10] Shen Z, Wang H, Shen Y F, et al. An improved stray capacitance model for inductors[J]. IEEE Transactions on Power Electronics, 2019, 34(11): 11153–11170.

[11] Bubert A, Zhang J K, De Doncker R W. Modeling and measurement of capacitive and inductive bearing current in electrical machines[C]//2017 Brazilian Power Electronics Conference (COBEP), 2017: 1–6.

[12] SAE Technical Standards Board. Wireless power transfer for light–duty plug–in/electric vehicles and alignment methodology: SAE TIR J2954[S]. USA: SAE International, 2019.

[13] GB/T 38775.1—2020 电动汽车无线充电系统第 1 部分: 通用要求[S].
GB/T 38775.1–2020 Electric vehicle wireless power transfer—Part 1: General requirements[S](in Chinese).

[14] Deng Q J, Sun P, Hu W S, et al. Modular parallel multi–inverter system for high–power inductive power transfer[J]. IEEE Transactions on Power Electronics, 2019, 34(10): 9422–9434.

[15] Lee E S, Sohn Y H, Choi B G, et al. A modularized IPT with magnetic shielding for a wide–range ubiquitous wi–power zone[J]. IEEE Transactions on Power Electronics, 2018, 33(11): 9669–9690.

[16] Li S Z, Ma T Y. Systematic analysis of advanced wireless charging technology for electric vehicles[J]. Journal of Physics: Conference Series, 2023, 2649(1): 012029.

[17] 秦润杰, 张清鹏, 卢秋朋. 多导体传输线电容电感矩阵的分析求解[J]. 电子测量技术, 2015, 38(6): 34–36.
Qin Runjie, Zhang Qingpeng, Lu Qiupeng. Analysis and solution of capacitance and inductance matrix of multi–conductor transmission line[J]. Electronic Measurement Technology, 2015, 38(6): 34–36(in Chinese).

[18] Hou J, Chen Q H, Wong S C, et al. Analysis and control of series/series–parallel compensated resonant converter for contactless power transfer[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2015, 3(1): 124–136.

[19] Li H C, Wang K P, Fang J Y, et al. Pulse density modulated ZVS full–bridge converters for wireless power transfer systems[J]. IEEE Transactions on Power Electronics, 2019, 34(1): 369–377.

[20] Qu X H, Han H D, Wong S C, et al. Hybrid IPT topologies with constant current or constant voltage output for battery charging applications[J]. IEEE Transactions on Power Electronics, 2015, 30(11): 6329–6337.

[21] 陶壮意, 许建平, 陈强, 等. 共模滤波器对三相 Buck 整流器的影响[J]. 电工技术, 2020, 47(14): 63–66,77.
Tao Zhuangyi, Xu Jianping, Chen Qiang, et al. Influencing of common mode filter on three phase Buck rectifier[J]. Electric Engineering, 2020, 47(14): 63–66,77(in Chinese).

[22] Arai N, Okamoto K, Kato J, et al. Method of measuring conducted noise voltage with a floating measurement system to ground[J]. IEICE Transactions on Communications, 2020, 103(9): 903–910.

本文引文格式:

祝丽花, 赵帅, 李元, 等. 电动汽车无线充电系统的悬浮电位抑制策略[J]. 天津工业大学学报, 2026, 45(4): 73–79.
Zhu Lihua, Zhao Shuai, Li Yuan, et al. Floating potential suppression strategy for wireless charging system of electric vehicles[J]. Journal of Tiangong University, 2026, 45(4): 73–79(in Chinese).

(责任编辑:程晓英)

(上接第 72 页)

using improved prototypical network and weighting similarity: Manhattan distance with insufficient noisy data[J]. Measurement, 2024, 226: 114171.

[18] Liang Y, Zhang J W, Shi Z, et al. A fault identification method of hybrid HVDC system based on wavelet packet energy spectrum and CNN[J]. Electronics, 2024, 13(14): 2788.

[19] Zhang Y Q, Yu Y, Yang G S. An ultra–fast MMC–HVDC fault location algorithm based on transient voltage features and regression neural network[J]. International Journal of Electrical Power & Energy Systems, 2024, 162: 110249.

[20] Zhai Z Y, Wang N, Lu S R, et al. A novel open circuit fault diagnosis for a modular multilevel converter with modal time–frequency diagram and FFT–CNN–BIGRU attention[J]. Machines, 2025, 13(6): 533.

[21] Kheireddine M, Merzouk I, Hafaifa A, et al. A novel fault diagnosis methodology in modular multilevel converters to enhance reliability and resilience[J]. Results in Engineering, 2025, 27: 105682.

本文引文格式:

黄志光, 连攀杰, 骆玮, 等. 基于深度 NCA 与原型网络的 MMC–HVDC 故障诊断方法[J]. 天津工业大学学报, 2026, 45(4): 62–72, 79.
Huang Zhiguang, Lian Panjie, Luo Wei, et al. Fault diagnosis method for MMC–HVDC based on Deep NCA and prototypical networks[J]. Journal of Tiangong University, 2026, 45(4): 62–72, 79(in Chinese).

(责任编辑:程晓英)