

基于 RPM 映射和 GAN-CNN-RF 的输电线路故障诊断

陶 锴, 余子煜, 马国煜, 吴 祎*

南京邮电大学 江苏南京

【摘要】输电线路是电能传输的核心,对电力系统稳定性有重要影响。因此,当输电线路发生故障时,快速准确地识别出故障类型十分关键。在传统的故障诊断方法中,特征的选取过于依赖于主观判断,可能会遗漏重要特征信息。针对此问题,本研究提出一种基于 RPM 映射和 GAN-CNN-RF 的输电线路故障诊断方法,首先,采用 RPM(Relative Position Matrix)将原始故障信号映射为二维图像。然后,使用 CNN(Convolutional Neural Network)自动提取二维图像的典型特征并输入到 RF(Random Forest)中实现故障诊断。针对真实故障数据难以获得的问题,本研究采用 GAN(Generative Adversarial Network)对真实故障数据的训练集进行扩充,有效地提升了训练效果。采用 Simulink 模拟数据集和真实数据集两种数据集对模型进行了训练和测试。与 EfficientNet, AlexNet, LeNet 等模型相比,所提出的 CNN-RF 在两种数据集上的各项指标均为最优,验证了所提方法在输电线路故障诊断中的有效性。

【关键词】输电线路;故障诊断;RPM;二维特征提取

【基金项目】江苏省自然科学基金(BK20210600)

【收稿日期】2025 年 2 月 20 日 **【出刊日期】**2025 年 3 月 18 日 **【DOI】**10.12208/j.jeea.20250073

Transmission line fault diagnosis based on RPM mapping and GAN-CNN-RF

Kai Tao, Ziyu Yu, Guoyu Ma, Yi Wu*

Nanjing University of Posts and Telecommunications, Nanjing Jiangsu

【Abstract】 Transmission lines are the core component of electrical energy transmission. Consequently, rapid and accurate identification of fault types is considered crucial when faults occur in transmission lines. For traditional fault diagnosis methods, feature selection is excessively dependent on subjective judgment, which could miss the critical feature information. A transmission line fault diagnosis method based on RPM mapping and GAN-CNN-RF was proposed in this research. First, original signals were transformed into two-dimensional images by RPM (Relative Position Matrix) mapping. Subsequently, typical features of the two-dimensional images were automatically extracted by a CNN (Convolutional Neural Network) and fed into a RF (Random Forest) for fault diagnosis. Considering the difficulty in obtaining the real fault data, the training set of real fault data was augmented using a GAN, significantly improving the model's training performance. The model was validated on both Simulink-simulated datasets and real-world datasets. Compared with the models including EfficientNet, AlexNet, and LeNet, the proposed CNN-RF performed well across all evaluation metrics on both datasets. The effectiveness of this method in transmission line fault diagnosis was experimentally confirmed.

【Keywords】 Transmission lines; Fault diagnosis; RPM; Two-dimensional feature extraction

引言

输电线路作为电能传输的关键部分,常年暴露在复杂多变的环境里^[1]。自然环境中的自然灾害或

是偶发事件可能会导致输电线路发生故障^[2]。当输电线路发生故障造成电力中断时,不仅给生产生活带来不便,还可能会给电力系统带来极大危害^[3]。因

作者简介:陶锴(1993-),博士,副教授,研究方向为电力系统故障诊断;

*通讯作者:吴祎

此, 快速准确的确定输电线路的故障至关重要。随着人工智能技术的广泛应用, 相关的智能算法也逐渐应用于输电线路故障检测中^[4]。例如, Ni 等^[5]使用短时傅里叶变换在时频域中分解特征变量并使用极限学习机来挖掘故障和相关特征向量之间的非线性映射。Wang 等^[6]提出了一种基于电压-安培曲线和深度集成学习的配电网故障综合识别方法。所提出的方法对不同系统和真实数据具有良好的适应性和泛化能力。余等^[7]提出一种基于行波特征与 KOA-CNN-BiGRU-AM (Kepler Optimization Algorithm-Convolutional Neural Network-Bidirectional Gated Recurrent Unit-Attention Mechanism) 的输电线路故障诊断方法, 在满足保护可靠性和速动性的前提下, 解决了高阻故障保护易拒动的问题。王等^[8]提出一种基于 PCNN (Parallel convolutional neural network) 的线路故障诊断方法, 兼顾了快速性与准确性。但是, 广泛应用的故障诊断方法侧重于特征提取后得到特征参数, 例如提取电气信号的能量、幅频特性等。然后, 利用特征参数配合人工智能模型实现故障诊断。因此识别效果的优劣非常依赖于特征提取的合理性, 这需要大量经验知识的配合, 并且在面对不同类型数据时, 相同类型的特征参数不能代表所有数据的共通特征。

针对以上问题, 本研究提出一种基于 RPM (Relative Position Matrix) 映射和 CNN-RF (Convolutional Neural Network-Random Forest) 的输电线路故障诊断方法。首先, 利用 RPM 将一维电气信号升维映射到二维, 采用 CNN 对二维图像进行自适应特征提取, 并和 RF 结合实现故障诊断。CNN 强大的特征提取能力和 RF 强大的分类能力结合, 能够有效地实现故障诊断任务。

1 模型方法

1.1 GAN 数据增强

GAN (Generative Adversarial Network) 是一种基于对抗学习的深度生成模型。由 Ian Goodfellow 等^[9]在 2014 年首次提出。

GAN 的结构如图 1 所示, 主要由生成器和判别器构成。生成器的输入为随机噪声, 输出为生成样本^[10]。判别器的输入为真实样本或生成器生成的样本, 其输出为一个概率值, 表示输入样本是真实样本的概率。判别器的目的是最小化 D, 尽可能准确

判断输入样本是真实样本还是生成样本。生成器的目的是最大化 G, 尽可能使生成样本达到欺骗判别器的效果。当生成器生成的样本达到了欺骗判别器的效果, 生成的样本就接近于可用的真实样本。通过这一原理, 在进行一些数据获取困难的研究时, GAN 可以帮助生成尽可能多的训练样本以提高训练效果。




图 1 GAN (生成对抗网络) 原理图

1.2 RPM

RPM 是一种分析和处理时间序列的算法。通过 RPM 方法, 可以将一个一维的时间序列映射为二维图像^[11]。

对于一个时间序列 $X = \{x_1, x_2, \dots, x_n\}$, 通过以下 z-分值标准化的方法得到一个标准正态分布 Z,

$$z_t = \frac{x_t - \mu}{\sigma}, t = 1, 2, \dots, n \quad (1)$$

其中 μ 表示 X 的平均值, σ 表示 X 的标准差。

选择一个合适的缩减因子 k, 生成一个新的平滑时间序列 $\tilde{X}$, 将维度从 N 减少到 m,

$$m = \left\lceil \frac{N}{k} \right\rceil \quad (2)$$

$$\tilde{x}_i = \begin{cases} \frac{1}{k} \sum_{j=k*(i-1)+1}^{k*i} z_j, i = 1, 2, \dots, m, \\ \left\lceil \frac{N}{k} \right\rceil - \left\lfloor \frac{N}{k} \right\rfloor = 0 \\ \frac{1}{k} \sum_{j=k*(i-1)+1}^{k*i} z_j, i = 1, 2, \dots, m-1 \\ \frac{1}{N - k*(m-1)} \sum_{j=k*(m-1)+1}^N z_j, i = m \\ \left\lceil \frac{N}{k} \right\rceil - \left\lfloor \frac{N}{k} \right\rfloor > 0 \end{cases} \quad (3)$$

其中, $\left\lceil \frac{N}{k} \right\rceil$ 表示 $\frac{N}{k}$ 向上取整, $\left\lfloor \frac{N}{k} \right\rfloor$ 表示 $\frac{N}{k}$ 向下取整。将预处理后的时间序列 X 转换为二维矩阵 M,

$$M = \begin{pmatrix} \tilde{x}_1 - \tilde{x}_1 & \cdots & \tilde{x}_m - \tilde{x}_1 \\ \tilde{x}_1 - \tilde{x}_2 & \cdots & \tilde{x}_m - \tilde{x}_2 \\ \vdots & \ddots & \vdots \\ \tilde{x}_1 - \tilde{x}_m & \cdots & \tilde{x}_m - \tilde{x}_m \end{pmatrix} \quad (4)$$

将该矩阵可视化, 即可得到故障信号的二维特征图像。

1.3 CNN-RF

CNN 主要用于处理如图像等网格化的输入^[12]。其核心层包括卷积层, 激活函数层, 池化层等^[13]。在实际应用中, CNN 具有强大的特征提取能力^[14]。局部感受野的特点使得 CNN 能够很好地捕捉图像的局部特征。并且通过多层堆叠, 在前层特征的基础上, 后层会提取更多更复杂的特征。本文使用的 CNN 结构如图 2 所示。




图2 CNN（卷积神经网络）结构




图3 CNN-RF（卷积神经网络-随机森林）结构

RF 是一种基于决策树的集成学习算法, 通过构建多个决策树并集成预测结果提高模型的准确性和稳定性^[15]。RF 能够处理大量的特征且能有效处理来自 CNN 提取的特征^[16]。在多分类任务中, 由于存在更多的类别, 数据复杂度更高^[17]。而 RF 通过多个决策树集成可以有效处理复杂数据。CNN-RF 模型结构如图 3 所示。CNN-RF 的参数如表 1 所示。

使用 CNN-RF 进行故障诊断的过程如图 4 所示。首先, 使用故障特征信号 U_x 对真实故障训练集进行扩充以丰富数据集。然后, 采用 RPM 方法将故障特征信号二维化得到二维特征图像, 使用 CNN 进行特征提取, 得到散点特征, 将散点特征输入到 RF 模型中, 经过数据训练和测试, 说明模型可以识别出输电线路的多种故障。

表 1 卷积神经网络-随机森林参数

卷积核大小	激活函数	池化层大小	树数量	树最大深度	最小样本分割数	最小样本叶子数
3×3	ReLU	2×2	100	30	2	1




图 4 故障识别流程

2 实验数据集

2.1 仿真数据集 A

本研究采用两个数据集来印证模型的准确率。数据集 A 由 Simulink 仿真得到，仿真模型如图 5 所示。通过修改故障点位置，负载功率，故障持续时间，得到共 2000 组数据。故障类型包括 A 相接地故障，B 相接地故障，C 相接地故障，AB 相间故障，BC 相间故障，CA 相间故障，AB 接地故障，BC 接

地故障，CA 接地故障，ABC 接地故障，每类各 200 个。每类数据按 8:2 划分训练集和测试集。数据集 A 的样本分组如表 2 所示。

2.2 真实数据集 B

为验证模型的有效性，采用中国华东地区某市某变电站的线路故障数据进行进一步的训练和测试。该变电站的部分拓扑结构如图 6 所示。样本分组如表 3 所示。




图 5 Simulink 仿真模型

表 2 数据集 A 样本分组 1

故障	训练集	测试集	故障	训练集	测试集
AN	160	40	CA	160	40
BN	160	40	ABN	160	40
CN	160	40	BCN	160	40
AB	160	40	CAN	160	40
BC	160	40	ABCN	160	40

¹ Simulink 仿真生成，按 8:2 划分训练集和测试集。




图 6 变电站部分拓扑图

表 3 数据集 B 样本分组 2

故障	训练集	测试集	故障	训练集	测试集
AN	59	14	CA	37	9
BN	71	17	ABN	42	11
CN	67	16	BCN	41	10
AB	35	9	CAN	38	9
BC	40	10	ABCN	17	4

3 实验分析

3.1 数据增强

由于真实故障难以获得，数据集 B 的大小仅为五百余组，因此，采用 GAN 模型对训练集部分进行扩充得到数据集 C。以 AN,AB,ABN,ABCN 为例，真实信号和生成信号对比如图 7 所示。

图中显示, 每类故障生成数据均保留了和真实数据相似的特征。这说明经过 GAN 生成的数据可以有效地用于模型的训练集扩充。

当生成器生成的数据足够逼真时，判别器会难以区分真实数据和生成数据，判别器对于真假数据的区分准确率接近 50%。

生成器 Loss 和判别器 Loss 如图 8 所示, 判别器损失 (D Loss) 接近 0.5 并且趋于稳定。并且生成器损失 (G Loss) 不再显著下降。说明生成器能够生成较为逼真的数据。

通过 GAN 对真实故障数据集 B 的训练集进行扩充得到数据集 C, 扩充后的样本分组如表 4 所示。




图7 GAN 数据扩充前后对比

² 真实数据, 按 8:2 划分训练集测试集。




图 8 (a)数据 AN 训练损失; (b) 数据 AB 训练损失; (c) 数据 ABN 训练损失; (d) 数据 ABCN 训练损失

表 4 数据集 C 样本分组 3

故障	训练集	测试集	故障	训练集	测试集
AN	100	14	CA	100	9
BN	100	17	ABN	100	11
CN	100	16	BCN	100	10
AB	100	9	CAN	100	9
BC	100	10	ABCN	100	4




图 9 二维映射

³ 真实数据, 按 8:2 划分训练集测试集, GAN 扩充训练集。

3.2 信号二维映射

使用 RPM 对故障特征波形二维映射。采用保护电压 U_x 作为故障特征信号。对 U_x 使用 RPM 进行二维化计算, 得到特征图像。以 A 相接地故障、AB 相间故障、AB 接地故障、ABC 接地故障等几种故障为例。 U_x 信号和处理得到的二维特征图像如图 9 所示。

3.3 模型对比

在本研究中, 使用 CNN-RF, EfficientNet, AlexNet, LeNet 对数据集 A 进行训练和测试。准确率 Acc 、查准率 P 、召回率 R 、 $F_{1-score}$ 四个指标定义分别为

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$P = \frac{TP}{TP + FP} \quad (6)$$

$$R = \frac{TP}{TP + FN} \quad (7)$$

$$F_{1-score} = \frac{2 \times P \times R}{P + R} \quad (8)$$

其中 TP 指实际为正、预测为正的样本数; FN 指实际为正、预测为负的样本数; FP 指实际为负、预测为正的样本数; TN 指实际为负、预测为负的样本数。

使用数据集 A 对四种模型进行训练和测试。混淆矩阵如图 10 所示。图 10 (a) 为 CNN-RF 在数据集 A 上的混淆矩阵。图 10 (b) 为 EfficientNet 在数据集 A 上的混淆矩阵。图 10 (c) 为 AlexNet 在数据集 A 上的混淆矩阵。图 10 (d) 为 LeNet 在数据集 A 上的混淆矩阵。具体指标对比如表 5 所示。

使用数据集 C 对四种模型进行训练和测试。混淆矩阵如图 11 所示, 图 11 (a) 为 CNN-RF 在数据集 C 上的混淆矩阵。图 11 (b) 为 EfficientNet 在数据集 C 上的混淆矩阵。图 11 (c) 为 AlexNet 在数据集 C 上的混淆矩阵。图 11 (d) 为 LeNet 在数据集 C 上的混淆矩阵。具体指标对比如表 6 所示。




图 10 (a) CNN-RF 在数据集 A 上的混淆矩阵; (b) Efficient 在数据集 A 上的混淆矩阵; (c) AlexNet 在数据集 A 上的混淆矩阵; (d) LeNet 在数据集 A 上的混淆矩阵

表 5 数据集 A 上各模型性能对比

模型	准确率/%	最低查准率/%	最低召回率/%	最低 F1-score/%
CNN-RF	97.25	93.02	87.50	90.18
EfficientNet	94.75	90.91	75.00	82.19
AlexNet	89.25	83.72	72.50	77.71
LeNet	85.25	68.42	68.42	66.67

CNN-RF 在仿真和真实输电线路数据集上的准确率分别为 97.25%(389/400)和 95.41%(104/109)。且在四种评价指标上明显优于其他模型。说明本方法对于输电线路故障有很好的识别性。

为进一步验证训练集扩充的必要性, 在数据集 B 和数据集 C 上使用 CNN-RF 进行训练和测试, 在

数据集 C 上的混淆矩阵如图 12 (a) 所示, 在数据集 B 上的混淆矩阵如图 12 (b) 所示。由图中可知, 在原始的故障数据集上, 本模型识别准确率仅为 74.40%(81/109), 在使用了 GAN 扩充训练集后的故障数据集上, 本模型识别准确率为 95.41%(104/109)。说明 GAN 扩充数据能有效地提高训练效果。




图 11 (a) CNN-RF 在数据集 C 上的混淆矩阵; (b) Efficient 在数据集 C 上的混淆矩阵; (c) AlexNet 在数据集 C 上的混淆矩阵; (d) LeNet 在数据集 C 上的混淆矩阵

表 6 数据集 C 上各模型性能对比

模型	准确率/%	最低查准率/%	最低召回率/%	最低 F1-score/%
CNN-RF	95.41	84.62	78.57	81.48
EfficientNet	90.83	77.78	71.43	74.47
AlexNet	93.58	71.43	56.25	62.94
LeNet	85.32	57.14	52.94	54.96




图 12 (a) CNN-RF 在数据集 C 上的混淆矩阵; (b) CNN-RF 在数据集 B 上的混淆矩阵.

4 结论

本文采用 RPM 将电气信号二维化, 在保留了原始信号的信息的前提下避免了特征类型选择的主观性问题。然后, 利用 CNN 强大的特征提取能力, 提取二维特征图中的局部和全局特征, 生成有高度区分性的特征向量。结合多决策树的 RF 模块使得模型具有好的分类能力。CNN 和 RF 的组合能够高效地完成输电线路故障诊断任务, 为电力系统的稳定运行提供有效保障。

本文采用了 Simulink 仿真了 2000 组构成模拟数据集 A, 同时采集了五百余组真实故障数据构成了真实数据集 B, 为提升训练效果, 采用 GAN 以扩充数据集 B 的训练集, 构成数据集 C。使用数据集 A 和数据集 C 对 CNN-RF 进行训练和测试, 准确率分别为 97.25%和 95.41%。并且使用数据集 A 和数据集 C 对 EfficientNet、AlexNet 以及 LeNet 进行训练和测试, 结果显示, 在四种评价指标上, CNN-RF 的表现均为最优, 验证了模型的有效性。同时, 使用数据集 B 和数据集 C 对 CNN-RF 进行训练和测试, 结果显示, 在未经训练集扩充的数据集 B 上, CNN-RF 的准确率仅为 73.40%, 在经训练集扩充的数据集 C 上, CNN-RF 的准确率为 95.41%, 说明训练集扩充对提升训练性能效果显著。本方法适用于多类复杂故障模式的识别, 并且适合嵌入边缘计算设备进行在线诊断。未来研究将考虑引入时频联合特征并实现模型轻量化, 以提升部署效率和实时性。

参考文献

- [1] 王建, 吴昊, 张博, 等. 不平衡样本下基于迁移学习-AlexNet 的输电线路故障辨识方法 [J]. 电力系统自动化, 2022, 46 (22): 182-191.
- [2] Ren G, Zha X, Jiang B, et al. Location of Multiple Types of Faults in Active Distribution Networks Considering Synchronization of Power Supply Area Data. Applied Sciences. 2022 Oct 6;12(19):10024.
- [3] 张宇博, 郝治国, 林泽暄, 等. 基于深度字典学习的输电线路故障分类方法 [J]. 电力自动化设备, 2022, 42 (11): 159-166.
- [4] Chen X, Ji N, Qin X, et al. Transformer Fault Diagnosis Based on the Improved Sparrow Search Algorithm and Random Forest Feature Selection [C]. 2024 3rd International Conference on Energy and Electrical Power Systems (ICEEPS), Guangzhou, China, 2024, 1086-1091.
- [5] Ni Q, Luo H, Liu J, et al. A Feature Vector Learning-Based Method for Diagnosing Main Circuit Ground Faults in Electrical Traction Drive Systems. IEEE Transactions on Power Electronics. 2024;39(2):2537-45.
- [6] Wang J, Zhang B, Yin D, et al. Distribution network fault comprehensive identification method based on voltage-ampere curves and deep ensemble learning. International Journal of Electrical Power & Energy Systems. 2025;164.
- [7] 余波, 高学军, 王灿, 等. 基于行波特征与 KOA-CNN-BiGRU-AM 的柔直输电线路故障诊断 [J]. 电力工程技术, 2025, 44 (02): 185-196.
- [8] 王浩, 杨东升, 周博文, 等. 基于并联卷积神经网络的多端直流输电线路故障诊断 [J]. 电力系统自动化, 2020, 44 (12): 84-92.
- [9] Goodfellow IJ, Pouget-Abadie J, Mirza M, et al. Generative Adversarial Nets. [C]. 28th Conference on Neural Information Processing Systems (NIPS); 2014.
- [10] Bhandari V, Londhe ND, Kshirsagar GB. TL-P3GAN: An Efficient Temporal-Learning-Based Generative Adversarial Network for Precise P300 Signal Generation for P300 Spellers. Ieee Transactions on Cognitive and Developmental Systems. 2024;16(2):692-705.
- [11] Chen W, Shi K. A deep learning framework for time series classification using Relative Position Matrix and Convolutional Neural Network. Neurocomputing. 2019;359:384-94.
- [12] Tao K, Wang Q, Yue D. Data compression and damage evaluation of underground pipeline with musicalized sonar GMM. IEEE Transactions on Industrial Electronics. 2023 May 1;71(3):3093-102.
- [13] Tao K, Chen G, Wang Q, et al. Ultrasonic Curved Coordinate Transform-RAPID With Bayesian Method for the Damage Localization of Pipeline. IEEE Transactions on Industrial Electronics. 2024 Feb 27.
- [14] Zheng W, Tao K, Jiang W. Automatic pattern identification of rock moisture based on the Staff-RF model. Journal of Geophysics and Engineering, 2018;15(2), 438-448.
- [15] Zheng W, Jiang J, Tao K. A method based on musical-staff-

- inspired signal processing model for measuring rock moisture content. *Measurement*. 2018 Sep 1;125:577-85.
- [16] Zhang H, Zhao M, Liu L, Zhong H, Liang Z, Yang Y, et al. Deep Multimodel Cascade Method Based on CNN and Random Forest for Pharmaceutical Particle Detection. *Ieee Transactions on Instrumentation and Measurement*. 2020;69(9):7028-42.
- [17] 徐耀松,张原. 基于改进 VMD-MSE 方法的输电线路故

障特征分析及分类 [J]. *电子测量与仪器学报*, 2019, 33 (06): 89-95.

版权声明: ©2025 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

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



OPEN ACCESS