

基于改进注意力门控循环单元的新型配电系统 继电保护故障诊断方法

黄振琳¹, 仲卫², 安然然¹, 吴巨豪¹, 张子涵¹

(1. 广东电网有限责任公司电力科学研究院, 广东 广州 510080; 2. 国电南瑞南京控制系统有限公司, 江苏 南京 215200)

摘要:为了解决高比例分布式电源接入的新型配电系统故障诊断准确率低、继电保护装置灵敏性和可靠性无法满足需求的问题,提出一种基于改进注意力门控循环单元的新型配电系统继电保护故障诊断方法。首先,对配电网三相电流进行小波包变换,提取故障电流时频能量谱。其次,把三相电流时频能量谱输入到门控循环单元中,将每个通道故障特征提取出来。然后,通过注意力机制分析不同时序故障特征关系和不同通道之间特征关系,经过 Softmax 分类器实现故障定位和分类。最后,通过搭建的配电网动模试验表明,所提方法对新型配电系统故障诊断具有较高的准确率。相比于无注意力门控循环单元、卷积神经网络、支持向量机,故障定位准确率分别提升了 1.6%、3.9%、5.5%,故障分类准确率分别提升了 2.3%、3.1%、9.8%。

关键词:新型配电系统;故障诊断;小波包变换;门控循环单元;注意力机制

中图分类号: TP277.2; TM73

文献标志码: A

文章编号: 1003-7241(2025)10-0036-07

New relay protection fault diagnosis method for distribution system based on improved attention gated recurrent unit

HUANG Zhenlin¹, ZHONG Wei², AN Ranran¹, WU Juhao¹, ZHANG Zihan¹

(1. Electric Power Research Institute of Guangdong Power Grid Co., Ltd., Guangzhou 510080, China;

2. NARI-TECH Nanjing Control Systems Ltd, Nanjing 215200, China)

Abstract: In order to solve the problem of low accuracy in fault diagnosis and insufficient sensitivity and reliability of relay protection devices in the new distribution system with high proportion of distributed power source access, a new distribution system relay protection fault diagnosis method based on improved attention gating loop unit is proposed. Firstly, it performs wavelet packet transform on the three-phase current of the distribution network to extract the time-frequency energy spectrum of the fault current. Secondly, the time-frequency energy spectrum of the three-phase current is input into the gate controlled loop unit to extract the fault characteristics of each channel. Then, the attention mechanism is used to analyze the relationship between different temporal fault features and the feature relationships between different channels, and the Softmax classifier is used to achieve fault localization and classification. Finally, the dynamic simulation test of the constructed distribution network shows that the proposed method has a high accuracy in fault diagnosis of the new distribution system. Compared with inattentive gated recurrent units, convolutional neural networks, and support vector machines, the fault localization accuracy increases by 1.6%, 3.9%, and 5.5%, respectively, and the fault classification accuracy increases by 2.3%, 3.1%, and 9.8%, respectively.

Keywords: new distribution system; fault diagnosis; wavelet packet transform; gated recurrent unit; attention mechanism

0 引言

随着新型配电系统建设的推进,分布式电源具有出力随机、间歇以及受周围环境影响大的特征,配电网潮流分布复杂、短路电流特征非线性程度加剧,传统故障诊断准确率低、继电保护装置灵敏性和可靠性无法满足需求的问题日益凸显^[1-2]。因此,研究高比例分布式新能源接入的新型配电系统故障诊断技术成为了当前的一个研究热点^[3-4]。

利用配电自动化遥信数据实现故障诊断的方法主要包括最优化法^[5]和矩阵法^[6]。利用遥测数据进行故障诊断具有通信性能好的优势,文献[7]根据配电网故障时电

压电流突变量之间的关系实现故障定位。文献[8]提出基于 GPRS 通信技术的配电网故障定位方法,利用 GPRS 通信方式进行配电自动化监控终端之间的信息共享,实现故障定位。

随着近年来深度学习理论的快速发展,已经在自然语言、语音识别以及视觉感知领域取得了研究成果。卷积神经网络是典型的一个深度学习算法,具有很强的非线性特征学习能力^[9-11]。文献[12]提出基于卷积神经网络的故障诊断方法,实现故障准确定位。但是,配电网故障数据是时间序列数据,不同时间数据故障特征具有一定的差异性,卷积神经网络的特征学习过程中容易出现时序信息丢失的问题,影响故障诊断准确率。门控循环单元是循环神

* 基金项目:南方电网公司科技项目资助(036100KK52210030;GDKJXM20212068)

收稿日期:2024-01-25

2) 对输入矩阵赋予权重矩阵 W_1, W_2, W_3 , 得到矩阵 a, b, c 。计算表达式为

$$\begin{cases} a = \text{Linear}(X) = XW_1 \\ b = \text{Linear}(X) = XW_2 \\ c = \text{Linear}(X) = XW_3 \end{cases} \quad (9)$$

式中, Linear 为线性变换。

3) 求解所有输入向量注意力得分, 计算表达式为

$$s_i = a_i b_i^T \quad (10)$$

式中, s_i 为输入向量第 i 维得分。

对注意力得分归一化处理, 计算表达式为

$$\tilde{s}_i = \frac{a_i b_i^T}{\sqrt{d_k}} \quad (11)$$

式中, \tilde{s}_i 为输入向量第 i 维得分归一化后的值, d_k 为向量维度。

4) 计算自注意力结果为

$$Z_i = \frac{\sum_{j=1}^c e^{\tilde{s}_i v_j}}{\sum_{c=1}^c e^{\tilde{s}_c}} \quad (12)$$

式中, v_j 为第 j 维输入向量的值, Z_i 为第 i 维输入向量自注意力结果。

在自注意力机制基础上进行改进提出多头自注意力机制, 具有能够捕捉不同序列复杂子空间关系、提高配电网故障诊断准确率的优势, 基本思想为通过多个注意力头将不同注意力分布提取出来。对每个头赋予独立权重实现输入序列之间依赖关系的捕捉, 然后加权求和输入序列, 对加权结果进行拼接得出最终的结果。

多头自注意力机制将权重矩阵 W_1, W_2, W_3 , 看成一个整体, 用不同头表示不同特征相关性。表达式为

$$\begin{cases} Z_{h,i} = \frac{\sum_{j=1}^c e^{\tilde{s}_{h,i} v_{h,j}}}{\sum_{c=1}^c e^{\tilde{s}_{c,c}}} \\ Z = \text{Concat}(Z_1, Z_2, \dots, Z_h) \end{cases} \quad (13)$$

式中, $Z_{h,i}$ 为第 h 个头第 i 维自注意力结果, h 取值范围为 1 到 s ; $v_{h,i}$ 为第 h 个头第 i 维输入向量; $\tilde{s}_{h,i}$ 为第 h 个头第 i 维输入向量归一化处理后的权重; Z_h 为第 h 个头计算结果; Concat 为拼接函数; Z 为多头自注意力结果。

2.2.2 多通道注意力机制

多通道注意力主要包含特征提取和通道加权, 使用平均池化得到所有特征图通道信息, 所有通道的权重是通过神经网络自动获取, 将网络输出结果作为各个通道的权重。当权重值越大时, 说明和重要信息关系程度越大, 应该加强重视; 当权重值越小时, 说明和重要信息关系程度越小, 进而有利于将关键信息凸显出来。计算过程如下。

1) 压缩输入特征图

使用平均池化的方式压缩所有输入特征图通道, 通道

内所有点被压缩成一个实数来表示所有通道信息, 具体压缩计算表达式为

$$Z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_c(i, j) \quad (14)$$

式中, Z_c 为压缩后的输出; H, W 分别为通道的长、宽; c 为通道编号; X_c 为第 c 个通道的输入矩阵。

2) 激励操作

前面全局池化只能得到每个输入特征图的通道, 无法将这些通道之间的相关性体现出来, 因此需要使用全连接的方式得到各个通道之间的关系。第一层全连接网络使用 Relu 激活函数压缩通道数量, 第二层全连接网络将前面压缩的通道维度提升, 恢复到之前通道维度, 使用 Sigmoid 激活函数把特征映射至 0 到 1 之间, 提升网络的非线性拟合能力, 有利于更好表征通道之间相关性, 计算得出所有通道权值。最后将求得的权值加权至每个输入特征通道上, 对输入特征进行重新标定。整个计算过程为

$$\begin{cases} O_c = \sigma(W_1 \delta(W_0(Z_c))) \\ Y = X_c \cdot O_c \end{cases} \quad (15)$$

式中, O_c 为激励操作输出结果, σ 为 Sigmoid 激活函数; W_0, W_1 分别为第一层全连接网络减少的通道数量、第二层全连接网络增加的通道维度, Y 为多通道注意力加权特征输出。

3 故障诊断方案

3.1 故障诊断模型设计

基于新型配电网故障电流数据时序性、多样性, 本文提出的基于改进注意力门控循环单元的新型配电系统继电保护故障诊断方法, 模型结构如图 2 所示, 主要包含多通道输入、时序特征分析、注意力机制、特征融合以及故障诊断 5 个模块。

1) 多通道输入。包含数据采集和数据预处理两个方面, 采集配电网各个节点三相电流数据, 对采集的数据进行小波包变换提取故障电流时频能量谱。对时频能量谱进行归一化处理提升对网络的适应性。

2) 时序特征分析。使用门控循环单元对输入数据进行时序特征学习, 学习到的特征输入到注意力机制中。

3) 改进注意力机制。包含自注意力机制和多通道注意力机制。其中自注意力机制对门控循环单元学习到的时序特征进行分析, 考虑不同时刻时序点之间关系和不同子空间时序特征关系, 提升时序特征分析能力; 多通道注意力机制对自注意力机制输出进行分析, 考虑各个通道之间关系, 输出通道权重。

4) 特征融合。对各个通道权值乘上对应自注意力机制特征输出, 得出包含权重信息的输出, 展开有权多通道输出信息。

5) 故障诊断。展开有权多通道输出信息, 经过全连接层输出至 Softmax 分类器进行分类, 得出故障诊断结果, 主要包含故障定位和故障分类。

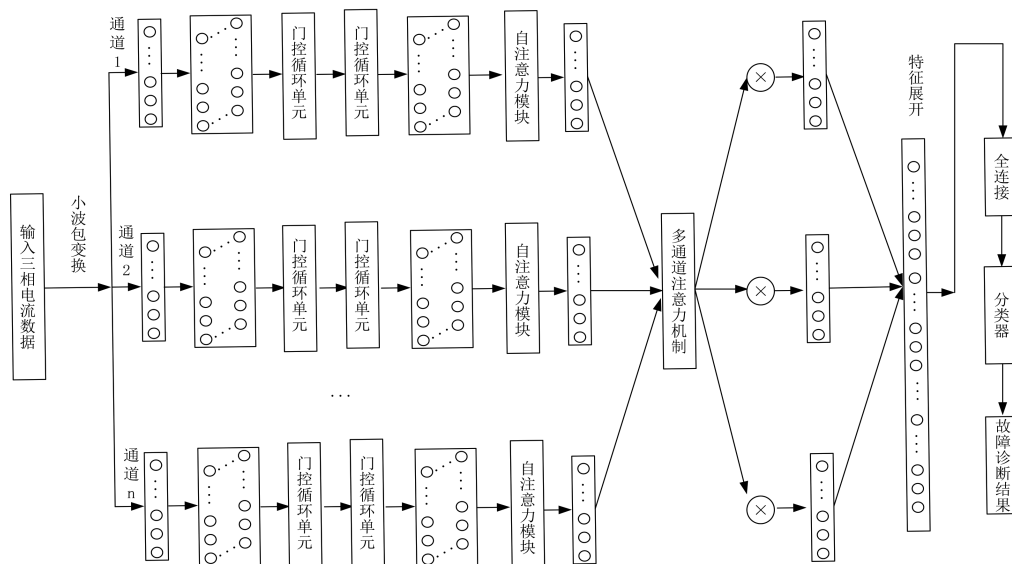


图2 故障诊断模型

3.2 故障诊断过程

本文所提模型使用多传感器采集配电网各个节点三相电流数据,构建多通道的一维电流数据,对多通道电流数据进行模型训练实现故障诊断,具体步骤如下:

步骤1 数据采集。采集配电网各个节点三相电流数据,构建多通道数据集;

步骤2 构建数据集。将配电网各个节点三相电流数据集分成训练集和测试集,对所有样本进行小波包变换,得出时频能量谱;

步骤3 数据预处理。归一化处理时频能量谱;

$$\hat{x}_i = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (16)$$

步骤4 初始化模型。对门控循环单元和注意力机制参数进行初始化;

步骤5 前向传播计算损失函数。训练集输入到模型中,前向传播模型,计算模型输出和实际输出之间的损失函数;

步骤6 反向传播更新参数。根据损失函数最小原则反向传播模型,更新各层参数;

步骤7 判断模型是否收敛或者达到最大迭代次数,如果满足条件,转到下一步,如果不满足条件,跳转至步骤5;

步骤8 测试集验证。将模型参数保存下来,利用测试集进行测试,来验证本文方法故障诊断效果。

故障诊断流程如图3所示。

4 仿真

4.1 仿真环境介绍

为了验证本文所提方法的有效性,基于RTDS搭建IEEE33节点配电网动模仿真试验,配电网模型结构如图4所示。光伏发电机额定容量550 kW,接入节点为11和

33;风力发电机额定容量600 kW,接入节点为18和25;储能设备参数如表1所示,接入节点为4。仿真环境软硬件参数见表2。

RTDS输出电平为10 V,然而配电网保护设备电压等级为10 kV,故需对RTDS输出量进行放大后输入至继电保护设备中。

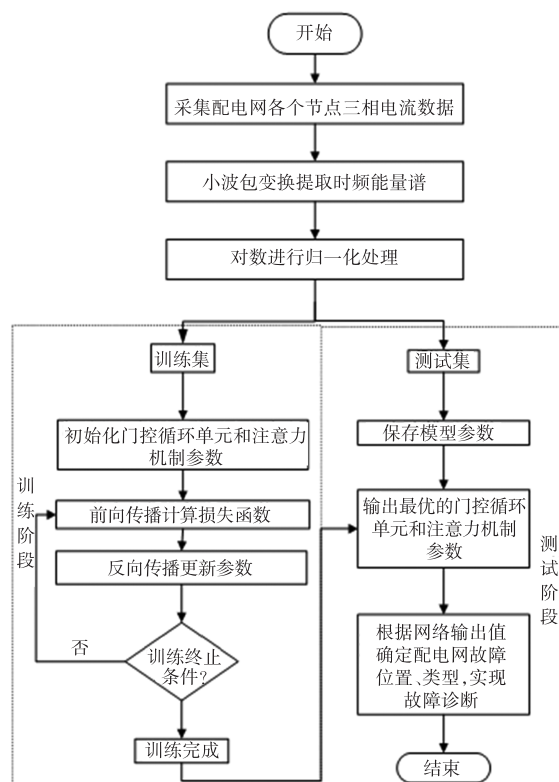


图3 故障诊断流程




图4 配电系统架构

表1 储能参数

| 名称 | 参数 |
|---------------------------|--------|
| 运行时间/a | 20 |
| 总容量/(kW·h ⁻¹) | 5 000 |
| 额定功率/kW | 500 |
| 最大支持充放电次数 | 10 000 |

表2 仿真环境软硬件参数

| 名称 | 参数 |
|--------|---------------------|
| 环境型号 | Pycharm |
| 代码语言 | Python |
| 显卡空间 | 32 G |
| 软件平台 | Ubuntu 16.04 |
| 硬盘空间 | 4 T |
| 代码框架 | Tensorflow |
| GPU 型号 | NVIDIA GTX1090Ti |
| CPU 型号 | i7-8700K,3.7 GHz 主频 |

本文搭建的基于RTDS搭建IEEE33节点配电网动模仿真试验结构如图5所示。从图中可知,动模试验包含RTDS、继电保护装置以及功率放大器。在RTDS中模拟故障控制系统、图4所示的配电网模型、开关控制系统以及输入输出系统。继电保护设备需要的电流信号通过输入输出系统和功率放大器配合得来,如果诊断出配电网发生故障,二次量会导致设备告警或动作,并且将故障信号通过输入输出系统反馈至RTDS中,形成配电网继电保护实时闭环控制。




图5 动模试验架构

4.2 模型参数

深度学习参数较多,不同的参数对诊断准确率影响差距较大,选择不当会造成模型收敛速度慢、精度低的问题,本文设计的配电网故障诊断模型经过反复调试与训练,得到的模型参数如表3所示,确定各个模块关键参数、输入输出大小。

使用交叉熵损失函数作为网络参数调整依据,有利于防止出现过拟合现象,损失函数表达式为

$$LOSS = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C y_{i,j} \log(p_{i,j}) \quad (17)$$

式中,LOSS为损失函数大小;N为总的样本数量;C为故障诊断类型数量; $y_{i,j}$ 为第*i*个真实样本标签第*j*类大小,取值为0或1; $p_{i,j}$ 为第*i*个真实样本标签被预测成第*j*类的概率,取值范围为0到1之间。

表3 模型参数

| 模型层 | 参数 | 输入大小 | 输出大小 |
|----------|-------------------------|-------------|-------------|
| 门控循环单元 | 层数:2;输入维度:32;隐层状态大小:128 | 128×128×32 | 128×128×128 |
| 自注意力机制 | 输入维度:128;注意力头数:8 | 128×128×128 | 128×128 |
| 多通道注意力机制 | 通道数:8;压缩比:0.4 | 128×8×128 | 128×8×128 |
| 特征展开 | — | 128×8×128 | 1 024×128 |
| Relu | — | 1 024×128 | 1 024×128 |
| Dropout | — | 1 024×128 | 1 024×128 |
| 全连接 | — | 1 024×128 | 1 024×128 |

故障诊断包括故障定位和故障分类两个部分,门控循环单元层数和故障定位准确率、故障分类准确率之间关系分别如图6、图7所示。从图中可知,当层数分别达到2和3时,故障定位准确率、故障分类准确率最高,如果继续增加层数,出现过拟合现象,因此故障定位和故障分类的门控循环单元层数分别设置为2和3。

4.3 算法对比

为了验证所提方法的优越性,将本文方法和无注意力门控循环单元、卷积神经网络、支持向量机进行对比,结果如图8-图11、表4所示,从图中可知,本文方法损失函数最低、准确率最高,支持向量机损失函数最高、准确率最低。从表中可知,相比于无注意力门控循环单元、卷积神经网络、支持向量机,本文方法故障定位准确率分别提升了1.6%、3.9%以及5.5%,故障分类准确率分别提升了2.3%、3.1%以及9.8%,整体故障诊断准确率分别提升了2.1%、4%以及9.6%,验证了所提方法的有效性。




图6 故障定位准确率和门控循环单元层数关系




图7 故障分类准确率和门控循环单元层数关系




图8 故障定位损失函数变化曲线




图9 故障定位准确率变化曲线




图10 故障分类损失函数变化曲线




图11 故障分类准确率变化曲线

表4 不同方法故障诊断结果对比

| 方法 | 故障诊断准确率 | | 故障定位准确率 | | 故障分类准确率 | |
|------------|---------|------|---------|------|---------|------|
| | 训练集 | 测试集 | 训练集 | 测试集 | 训练集 | 测试集 |
| 本文方法 | 99.5 | 99.0 | 99.6 | 99.1 | 99.8 | 99.6 |
| 无注意力门控循环单元 | 98.4 | 96.9 | 98.8 | 97.5 | 98.5 | 97.3 |
| 卷积神经网络 | 97.1 | 95.0 | 97.3 | 95.2 | 98.3 | 96.5 |
| 支持向量机 | 96.5 | 89.4 | 96.9 | 93.6 | 95.7 | 89.8 |

4.4 高阻接地故障诊断结果

配电网故障多数为高阻接地故障,验证本文方法对高阻接地故障诊断效果更有实际意义,各种方法结果对比如表5所示。从表中可知,本文方法对高阻接地故障仍具有较高的诊断准确率。

表5 高阻接地故障诊断结果对比

| 电阻/ Ω | 故障诊断准确率/% | | | |
|--------------|-----------|------------|--------|-------|
| | 本文方法 | 无注意力门控循环单元 | 卷积神经网络 | 支持向量机 |
| 10 | 98.9 | 96.5 | 95.3 | 89.5 |
| 20 | 98.5 | 96.3 | 94.8 | 89.4 |
| 30 | 98.6 | 97.5 | 95.2 | 89.6 |
| 40 | 98.7 | 96.5 | 94.5 | 89.2 |
| 50 | 99.2 | 96.2 | 94.6 | 89.7 |
| 60 | 99.5 | 96.4 | 94.7 | 89.6 |
| 70 | 98.3 | 95.6 | 95.4 | 90.1 |
| 80 | 98.7 | 97.3 | 95.2 | 89.2 |
| 90 | 99.5 | 96.8 | 95.1 | 89.7 |
| 100 | 98.1 | 96.4 | 95.3 | 89.8 |

5 结束语

本文提出一种基于改进注意力门控循环单元的新型配电网系统继电保护故障诊断方法,具体结论如下:

1) 本文通过对配电网三相电流进行小波包变换,提取故障电流时频能量谱输入到门控循环单元中,可以突出异常或故障的特征频率和能量,有助于更准确地识别和定位故障。

2) 本文通过注意力机制分析不同时序故障特征关系和不同通道之间特征关系。经过试验表明,所提方法对新型配电网系统故障诊断在面对不同故障诊断场景下都具有较高的准确率,提升继电保护系统的性能和可靠性。

参考文献

[1] LI Canbing, TANG Shengwei, CAO Yijia, et al. A new stepwise power tariff model and its application for residential consumers in regulated electricity markets [J]. IEEE Transactions on Power Systems, 2013, 28(1): 300-308.

[2] 李有荣, 潘嘉琪, 夏志乐, 等. 分布光伏并网在配网继电保护中的影响作用分析[J]. 自动化技术与应用, 2023, 42(6): 54-57.

[3] 陈思源, 景巍巍, 史明明, 等. 新能源接入背景下的谐波源建模方法综述[J]. 电力系统保护与控制, 2022, 50(7): 162-175.

[4] 张建雨, 姜睿智, 李俊刚, 等. 基于5G通信的配电网差动保护技术研究[J]. 电力系统保护与控制, 2021, 49(7): 17-23.

[5] 宫璇, 任欣旭, 王秋杰, 等. 具有高容错稳定性的含DG配电网区段定位方法[J]. 高电压技术, 2021, 47(11): 3992-4006.

[6] 徐彪, 尹项根, 张哲, 等. 矩阵算法和优化算法相结合的配电网故障定位[J]. 电力系统自动化, 2019, 43(5): 152-158.

[7] 常仲学, 宋国兵, 黄炜, 等. 基于相电压电流突变量特征的配电网单相接地故障区段定位方法[J]. 电网技术, 2017, 41(7): 2363-2370.

[8] 任庭昊, 覃禹铭, 毛杰, 等. 基于GPRS的配电网馈线自动化故障定位技术[J]. 自动化技术与应用, 2023, 42(8): 42-45.

[9] SONG Y, DU J, LI S, et al. Multi-scale feature fusion convolutional neural networks for fault diagnosis of electromechanical actuator[J]. Applied Sciences, 2023, 13(15): 86-89.

[10] WANG J Y, ZHANG Y J, LUO C, et al. Deep learning domain adaptation for electro-mechanical actuator fault diagnosis under variable driving waveforms[J]. IEEE Sensors Journal, 2022, 22(11): 10783-10793.

(下转第83页)