

doi: 10.7690/bgzd.2025.10.005

基于混合深度学习的微电网检测模型

吴方权, 刘亦驰, 汤成佳

(贵州电网有限责任公司信息中心, 贵阳 550003)

摘要: 为解决目前微电网保护方案存在计算时间长、故障检测精度低的问题, 提出一种基于混合深度学习的微电网故障检测模型。通过特征提前器挖掘电力数据信号信息, 利用深度卷积神经网络有效提取电力故障数据特征信息, 并基于 AdaBoost 分类器对故障进行分类。实验结果表明: 与卷积神经网络 (convolutional neural network, CNN) 和 AlexNet 相反, 所提混合深度学习检测模型训练性能更高; 与 SVM、LR、CNN 和 AlexNet 模型相比, 所提混合深度学习模型综合指标性能更优, 故障检测准确率可达 98%。

关键词: 微电网; 故障检测; 深度学习; 特征提取; 分类器

中图分类号: TP389.1 **文献标志码:** A

Microgrid Detection Model Based on Hybrid Deep Learning

Wu Fangquan, Liu Yichi, Tang Chengjia

(Information Center of Guizhou Power Grid Company Limited, Guiyang 550003, China)

Abstract: In order to solve the problems of long computation time and low fault detection accuracy in current microgrid protection schemes, a microgrid fault detection model based on hybrid deep learning is proposed. The feature advancer is used to mine the signal information of power data, and the deep convolutional neural network is used to effectively extract the feature information of power fault data, and the AdaBoost classifier is used to classify the fault. Experimental results show that, contrary to the convolutional neural network (CNN) and AlexNet, the proposed hybrid deep learning detection model has higher training performance; Compared with SVM, LR, CNN and AlexNet models, the proposed hybrid deep learning model has better comprehensive index performance, and the fault detection accuracy can reach 98%.

Keywords: microgrid; fault detection; deep learning; feature extraction; classifier

0 引言

电力需求的指数级增长、传统资源的持续减少以及对绿色电力日益增长的需求已成为传统发电系统的核心问题^[1]。分布式能源 (distributed energy resources, DER)^[2]作为一种有效的解决方案, 可将能源集成在配电主网络, 并位于负载附近, 从而方便、快捷地为本地电力用户提供电力; 因此, DER 技术作为微电网重要一环, 在解决传统电力系统的问题方面发挥了关键作用^[3-5]。从本质上讲, 微电网是一个低压或中压分布式系统, 与一组低功率发电机组、负载和储能设备互连。微电网可以在预先计划的孤岛和并网模式下有效运行, 并通过在主电网停电期间利用孤岛运行模式来保持电力的稳定运行。微电网通过减少碳排放提供了卓越的电能质量, 并通过减少输电线路提供了较低的实施成本。简而言之, 微电网可显著提高电力系统工作的整体效率和经济调度。由于 DER 渗透到微电网中, 也面临着重大的技术问题, 如稳定性、频率和电压控制、保护装置故障和运行保护问题等。

为提高微电网安全问题, 许多学者对微电网保护策略进行了研究。文献[6]提出了一种基于相电流工频变化量极性的微电网纵联保护方案。该方案首先利用本地相电流的工频变化量极性确定本侧电流总极性, 然后通过两侧电流总极性识别故障区段。该方案只考虑了逆变器接口的分布式电源 (distributed generation, DG)。文献[7]基于 Matlab/Simulink 平台, 搭建含分布式光伏电站和储能电站的微电网系统模型, 并进行短路故障仿真分析。文献[8]使用 PSCAD 对故障进行仿真, 对交流微电网故障区间定位算法进行仿真验证。上述方案具有较高的故障检测时间。

为了克服上述问题, 笔者提出一种基于混合深度学习的微电网保护模型。该模型使用预处理器、特征提前器和 AdaBoost 分类器对故障数据进行分析并实现故障检测和分类。

1 模型建立

基于数据挖掘的电网链路检测模型结构如图 1

收稿日期: 2024-10-09; 修回日期: 2024-11-12

第一作者: 吴方权 (1986—), 男, 贵州人。

所示。




图 1 基于数据挖掘的电网链路检测模型结构

模型由数据预处理器、特征提取器和分类器构成。数据预处理器主要对电网敏感故障数据进行预处理，如去除已收集电力数据中的异常值，通过希尔伯特变换提取包含故障暂态重要信息的自相关函数 (autocorrelation function, ACF) 包络，计算电压和电流的总谐波失真 (total harmonic distortion, THD) 值、瞬态能量以及数据的归一化操作。需注意，微电网中敏感故障数据主要是通过模拟各种故障和无故障事件而获得。其中故障事件是通过改变故障类型和故障位置获得，且故障电阻变化很大。无故障情况是通过突然的负载变化和电容器切换获得。

当对所有故障数据进行预处理后，则可基于卷积神经网络和 AdaBoost 建立特征提前器与分类器，从而实现微电网链路检测和分类。

1.1 数据预处理器

电力数据中的异常值表示与海量数据中其他测量值显著不同的值。这些异常值将会严重干扰分类模型的性能。该研究采用三西格玛经验法则去除电力数据中存在的异常值。三西格玛经验法则认为服从正态分布的数值分布在 $(\mu-3\sigma, \mu+3\sigma)$ 中的概率为 0.997 4，其中 σ 为标准差， μ 为均值。对于收集的原始电力数据集，某个测量值如果在三西格玛范围之外，则可将该数据看作异常值。

当剔除异常值后，可使用希尔伯特变换来确定每个相电流信号的包络。希尔伯特变换是一种在通信系统中用于信号分析的技术，目前也被广泛用于检测微电网故障检测。通过希尔伯特变换后可产生与原始信号 $x(t)$ 具有 90° 相移的虚信号 $\hat{x}(t)$ 。时域希尔伯特变换可以表示为：

$$H(t)=1/\pi t. \quad (1)$$

式中： $H(\bullet)$ 为希尔伯特变换算子； t 为时域变量。

由于希尔伯特变换算子不是一个可积函数，因此，可通过使用柯西积分计算如下：

$$\hat{x}(t)=x(t) \otimes \frac{1}{\pi t}=\frac{1}{\pi} p \int_{-\infty}^{+\infty} \frac{x(\tau)}{t-\tau} d\tau. \quad (2)$$

式中： p 为积分主值； $\otimes$ 为卷积操作符。

ACF 包络是微电网中故障敏感信息之一，主要可通过希尔伯特变换计算。当故障发生时，电力数据的 ACF 包络线发生显著变化，其值可计算如下：

$$r_k=\sum_{i=1}^{M-k}\left(x_i-\bar{x}\right)\left(x_{i+k}-\bar{x}\right) / \sum_{i=1}^M\left(x_i-\bar{x}\right)^2. \quad (3)$$

式中： r_k 为 2 个数据点之间的 ACF； x_i 为原始数据集的值； x_{i+k} 为移位数据集的数值； $\bar{x}$ 为原始数据集的平均值。

THD 是信号失真的指标，其增加了谐波，可有效表征故障的敏感信息。THD 定义为总谐波与基频的比率。电压和电流的 THD 计算如下：

$$\eta_v^{\text{THD}}=\sqrt{V_2^2+V_3^2+\cdots V_n^2} / V_1; \quad (4)$$

$$\eta_i^{\text{THD}}=\sqrt{I_2^2+I_3^2+\cdots I_n^2} / I_1. \quad (5)$$

式中： η_v^{THD} 为电压总谐波失真； η_i^{THD} 为电流总谐波失真； V 为基频电压； I 为基频电流； n 为收集的电压与电流数据的总数。

预处理中的瞬态能量分 3 步计算。

1) 将三相信号转换为模态信号。

2) 采用德尔塔滤波器提取叠加的模态电压和叠加的模态电流：

$$\Delta x(t)=x_{BF}(t)-x_{aF}(t). \quad (6)$$

式中： $\Delta x(t)$ 为电压或电流的叠加模态信号； $x_{aF}(t)$ 和 $x_{BF}(t)$ 分别为故障前和故障后信号。一旦获得叠加的模态电流和电压，则瞬态功率计算如下：

$$\Delta P=\Delta V \cdot \Delta I. \quad (7)$$

式中 ΔP 、 ΔV 和 ΔI 分别为瞬态功率、叠加模态电压和叠加模态电流。

3) 通过积分计算瞬态能量：

$$\Delta E=\int_0^{T_0} \Delta P d t. \quad (8)$$

式中： ΔE 为瞬态能量； T_0 为时域周期。

在对电力数据进行特征提取时，如不对数据进行归一化操作，大范围变动的数据将对特征学习过程产生负面影响，更为严重时将产生梯度爆炸问题。为此，该研究采用最小-最大归一化方法将数据缩放至 0~1 之间，具体定义如下：

$$x'=(x-\min) /(\max -\min) . \quad (9)$$

式中： x' 为归一化后的数据； x 为原始数据； $\min$ 为数据序列中的最小值； $\max$ 为数据序列中的最大值。

1.2 特征提取器

深度卷积神经网络 (deep convolution neural network, DCNN) 在挖掘复杂数据中的内部特征方

面具有优势。然而，由于电力数据维度高、特征复杂的特殊性，给特征提取带来了困难，且不利于模型对数据的学习。为此，设计了一种基于 DCNN

的特征提取器，从而提升微电网异常数据特征提取性能。

基于 DCNN 的特征提取器结构如图 2 所示。




图 2 基于 DCNN 的特征提取器结构

该特征提取器骨干网络包含 4 个密集特征模块。每个密集特征模块中包含 6 个合成层和 1 个 1×1 的卷积层。密集特征模块可在保持特征图大小不变的情况下大大增加网络的非线性度，从而使网络层数更深。同时，每个合成层由 1×1 卷积核和 3×3 卷积核并行执行卷积运算并拼接所有输出结果构成。不同的卷积运算可以获得关于输入特征的不同信息，而并行运算后的特征映射表现出更强的特征表示能力。单个密集特征模块利用 6 个合成层建立不同层间的直接连接，充分利用各层的特征映射，并结合各通道的特征，以缓解梯度消失问题。此外，在每一层中使用了批量归一化层和 ReLU 函数，从而防止了梯度消失和梯度爆炸，增加了网络的非线性程度。

一般情况下，DCNN 模型采用二元交叉熵函数作为损失函数：

$$\mathcal{L} = -\sum_{i=1}^N y^{(i)} \log \hat{y}^{(i)} + (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})。 \quad (10)$$

式中： $\mathcal{L}$ 为损失函数； $y^{(i)}$ 为第 i 个样本的标签记。如果电力数据存在异常，则 $y^{(i)}=1$ ，否则 $y^{(i)}=0$ ； $\hat{y}^{(i)}$ 为第 i 个样本的模型预测值。

由于电力数据的独特特性，正常用电数据的数量远远少于异常用电数据，从而导致负样本的数量远低于正样本的数量；因此，笔者将正样本下采样和修正损失函数相结合，从而解决电力异常检测任务中样本不均匀问题。修正后的损失函数计算如下：

$$\mathcal{L} = -\sum_{i=1}^N \omega^{(i)} \left[y^{(i)} \log \hat{y}^{(i)} + (1 - y^{(i)}) \log(1 - \hat{y}^{(i)}) \right]。 \quad (11)$$

式中 $\omega^{(i)}$ 为惩罚参数，主要由样本空间（即正样本和

负样本的比例）确定。通过将下采样与修改的损失函数相结合，所提集成密集特征的特征提取器可以更加重视负样本，并且可以相应地平衡样本空间。

为了避免过度拟合，可在损失函数中添加正则化项。该项由全连通层的卷积核权重 W_k 的 F 范数和权重 W_l 的 L_2 范数组成：

$$\mathcal{L}_{\text{reg}} = \|W_l\|_2 + \sum_k \|W_k\|_F^2。 \quad (12)$$

结合式(3)和(4)，总损失函数 $\mathcal{L}_t$ 定义如下：

$$\mathcal{L}_t = \mathcal{L} + \beta \mathcal{L}_{\text{reg}}。 \quad (13)$$

式中 β 为训练过程中确定的正则化项的权重。

1.3 分类器

该研究基于 AdaBoost 分类器实现微电网故障数据分类。AdaBoost 方法基于 boosting 方法，将高权重分配给弱学习者的错误预测，并传递给下一个弱学习者以进行更好的分类；因此，基于密集特征模块的特征提取器产生的特征将传递给 AdaBoost 分类器，该分类器使用集成方法来区分正常和异常用电。

令 x_i 为基于 DCNN 的特征提取器产生的特征标签， $i=1, 2, \dots, N$ 为样本的数量。AdaBoost 的目的是从特征数据中学习一系列弱分类器或基本分类器，然后将这些弱分类器组合成一个强分类器。AdaBoost 分类器执行过程描述如下：

首先，初始化特征数据的权值分布。每个样本最开始都赋予相同的权值：

$$w_i = 1/N。 \quad (14)$$

式中 w_i 为第 i 个样本的权值。此时，初始时刻权值

分布 $D_o(i)$ 可定义如下:

$$D_o(i) = (w_1, w_2, \dots, w_n) = (1/N, 1/N, \dots, 1/N). \quad (15)$$

在迭代步长 $t(t=1, 2, \dots, T)$ 时, 选取一个当前误差率最低的弱分类器 h 作为第 t 迭代的基本分类器 H_t , 其误差计算如下:

$$e_t = \sum_{i=1}^N w_{ti} I(H_t(x_i) \neq y_i). \quad (16)$$

式中: e_t 为分类器误差; w_{ti} 为第 t 迭代的第 i 个样本的权值; $I(\bullet)$ 为单位矩阵; y_i 为样本的真值标签。同时, 该弱分类器在最终分类时的权重计算如下:

$$\alpha_t = \ln((1 - e_t)/e_t)/2. \quad (17)$$

式中 α_t 为弱分类器在最终分类时的权重。此时, 更新训练样本的权值分布 D_{t+1} :

$$D_{t+1} = D_t(i) \exp(-\alpha_t y_i H_t(x_i))/Z_t; \quad (18)$$

$$Z_t = 2\sqrt{e_t(1 - e_t)}. \quad (19)$$

式中 Z_t 为归一化常数。

最后, 按弱分类器权重 α_t 组合各个弱分类器, 并通过符号函数 sign , 得到一个强分类器:

$$H_{fi} = \text{sign}\left(\sum_{t=1}^T \alpha_t H_t(x)\right). \quad (20)$$

式中: H_{fi} 为最终的强分类器; T 为最大迭代步长。

2 仿真与分析

2.1 仿真环境

基于 Matlab 中 Simulink 模块建立微电网测试系统, 测试系统结构如图 3 所示。




图3 微电网测试系统结构

微电网在通过开关与 25 kV、15 MVA 和 60 Hz 的电网连接, 从而切换并网和孤岛模式。系统数据采样频率设置为 3.6 kHz, 包括 2 个 3 MVA (DER₁ 和 DER₃) 和 1 个 2 MVA 逆变器型 DG (inverter

interfaced DGs, IIDG) (DGR2), 以及 1 个 7 MVA 同步型 DG (DER4)。同时, 使用断路器 C_{B1} 和 C_{B2} 使得微电网在环形和径向配置之间切换。此外, 微电网系统由 5 个分布式区段 (D_{L1} 、 D_{L2} 、 D_{L3} 、 D_{L4} 、 D_{L5}) 组成, 每个区段的线路长度为 20 km。微电网和主电网通过 120/25 kVDyn 变压器连接, 而所有 DG 电源通过 0.630/25 kV 变压器连接。系统中有 6 个负载 (L_1 – L_6) 连接到每条总线, 负载参数值如表 1 所示。

表1 负载参数值

负载	有功功率/ MW	无功功率/ MVAR	负载	有功功率/ MW	无功功率/ MVAR
L_1	3.0	1.00	L_4	1.0	0.75
L_2	3.0	1.00	L_5	1.0	0.75
L_3	4.0	1.50	L_6	1.0	0.50

2.2 指标与实验设置

为了进行性能验证, 实验时使用精度、准确性、召回率和 F_1 分数作为指数用于评估所提出的基于混合深度学习模型的微电网故障检测和分类模型的性能。各指标的定义如下:

$$\text{PRE} = \text{TP}/(\text{TP} + \text{FP}); \quad (21)$$

$$\text{ACC} = (\text{TN} + \text{TP})/(\text{TN} + \text{FP} + \text{FN} + \text{TP}); \quad (22)$$

$$\text{REC} = \text{TP}/(\text{TP} + \text{FN}); \quad (23)$$

$$F_1 = 2\text{TP}/(2\text{TP} + \text{FP} + \text{FN}). \quad (24)$$

式中: PRE 为精度, 表征预测标签为正类的样本中, 预测正确的比值; ACC 为准确率, 表示所有正确分类的样本数与总样本数的比值; REC 为召回率, 表征真值标签为正类的样本中, 预测正确的比例; F_1 为精度和召回率的调和平均值; TN 为预测值和实际值均为负样本的数量; FP 为预测值为正样本, 但实际为负样本的数量; FN 为预测为负样本, 实际为正样本的数量; TP 预测和实际均为正样本的数量。

仿真时硬件环境如下: 采用 Intel 奔腾 G4560 CPU, GTX1060GPU, 内存 64 GB, 操作系统为 Win10 64 位。深度神经网络模型由 Python3.6 和 Pytorch 1.14 编译。模型训练过程中参数设置如下: 初始学习率设置为 10^{-4} 、数据批量处理大小设置为 50、学习率衰减倍数设置为 0.2、正则化参数设置为 10^{-5} 、最大迭代次数为 15 000。

2.3 结果与分析

在训练故障检测模型时, 将获得的数据集分为训练集和测试集 2 部分, 所占比例分别为 7:3。本节将所提混合深度学习模型与卷积神经网络 (convolutional neural network, CNN)、AlexNe 模型在故障检测方面进行了比较。

不同模型训练集和测试集损失对比如图 4 所示。




图 4 不同模型训练集和测试集损失对比

由图 4 可以看出，所提混合深度学习模型训练性能优于 CNN 和 AlexNet 模型。CNN 和 AlexNet 在训练集上的最低损失约为 18.43%和 16.69%。测试集中 CNN 的最低损失最大，约为 18.48%；其次为 AlexNet 模型，约为 17.58%。分析原因，CNN 学习了许多训练数据集的特征，然而存在过拟合问题，导致了在测试数据集中性能下降严重。AlexNet 模型较 CNN 模型有一定缓解，然而性能提升有限。与 CNN 和 AlexNet 相反，所提混合深度学习检测模型在训练集产生的损失约为 7.87%，但在测试集上的损失约为 11.13%。训练集和测试集之间的误差约为 3.26%。试验结果表明：所提混合深度学习检测模型在综合数据预处理器、特征提取器、AdaBoost 分类器后可更多关注电力数据高质量的特征，从而获得更优的训练性能。

接下来对经典机器学习模型支持向量机 (support vector machine, SVM) 和逻辑回归 (logistic regression, LR)，以及 CNN、AlexNet 等深度学习模型的综合性能进行对比。同时，为了比较所提数据预处理机制的有效性，实验时对原始数据以及所提预处理机制下的数据性能进行分析。

不同模型综合指标统计情况如表 2 所示。可以看出，SVM 和 LR 综合性能明显低于深度学习模型 (CNN 和 AlexNet)。分析原因，电力数据维度高，传统机器学习模型 (SVM 和 LR) 无法更深层次理解特征与特征之间的关系。同时，比较原始数据和数据预处理后，所提数据预处理后模型综合性能更优。最后，与 SVM、LR、CNN 和 AlexNet 模型相比，所提混合深度学习模型综合指标性能更优，故障检测准确率可达 98%。分析原因，所提基于混合深度学习的电力数据异常检测模型可更容易关注且有效学习包含关键事件的信息。实验结果验证了所提模型的可行性和有效性。

表 2 不同模型综合指标统计情况

模型	指标	原始数据	预处理数据
SVM	精度	0.39	0.65
	召回率	0.48	0.61
	准确率	0.43	0.60
	F_1	0.28	0.40
LR	精度	0.45	0.68
	召回率	0.38	0.64
	准确率	0.41	0.67
	F_1	0.29	0.42
CNN	精度	0.49	0.76
	召回率	0.51	0.78
	准确率	0.55	0.77
	F_1	0.55	0.79
AlexNet	精度	0.59	0.83
	召回率	0.68	0.84
	准确率	0.65	0.88
	F_1	0.63	0.88
所提模型	精度	0.65	0.93
	召回率	0.71	0.94
	准确率	0.69	0.98
	F_1	0.68	0.94

3 结论

笔者对智能电网中故障检测进行了研究与分析，建立了一种基于混合深度学习的故障检测模型。该模型可基于预处理器挖掘电力数据重要信息，基于 DCNN 模型提取电流数据特征，基于 AdaBoost 分类器实现高精度的故障检测过程。所提混合深度学习模型的故障检测模型可为电力数据分析以及电力领域安全发展提供一定借鉴作用。

参考文献：

[1] 于静梅, 张福生, 张世轩, 等. 太阳能与燃煤机组集成发电系统性能研究[J]. 热能动力工程, 2023, 38(2): 92-100.

[2] 冯平安, 刘江华, 罗西, 等. 基于双层优化的分布式能源系统能源调度和交易分层[J]. 西北水电, 2023(1): 68-79.

[3] 刘祖明, 李杰慧, 孙建平, 等. 新型风光抽水蓄能系统研究[J]. 云南师范大学学报(自然科学版), 2023, 43(2): 11-14.

[4] 陈辉, 李艳, 林思远. 大数据驱动下全接触渠道的电力客户精准画像[J]. 云南师范大学学报(自然科学版), 2023, 43(2): 34-38.

[5] 钟建棚, 余少锋, 廖崇阳, 等. 基于云计算的电力设备智能监测系统[J]. 云南师范大学学报(自然科学版), 2022, 42(3): 37-41.

[6] 武剑, 薛玉石, 山春风, 等. 基于相电流工频变化量极性的微电网纵联保护方案[J]. 微型电脑应用, 2022, 38(9): 117-120.

[7] 高建勋. 光储微电网中储能逆变器短路特性研究[J]. 环境技术, 2022, 40(6): 151-156.

[8] 王婉婷, 景柳铭. 基于电流测量信息的交流微电网保护方法研究[J]. 现代信息科技, 2022, 6(22): 42-46.