

基于卷积神经网络和随机森林的三相电压暂降分类

刘佳翰¹, 陈克绪², 马建², 徐春华¹, 吴建华¹

(1. 南昌大学信息工程学院, 江西 南昌 330031;

2. 国网江西省电力公司电力科学研究院, 江西 南昌 330096)

摘要: 特征提取是电能质量扰动识别的关键步骤, 然而传统的数学变换与浅层神经网络相结合的方法无法自动提取特征。为此, 提出了一种基于卷积神经网络(CNN)和随机森林(RF)的混合模型来对三相电压暂降数据进行自动特征提取及分类。首先, 将三相电压暂降数据转换为空间相量模型(SPM); 其次, 利用 CNN 对 SPM 进行特征提取; 最后, 将 RF 应用于分类。为了加快 CNN 训练速度并缓解过拟合, 引入了 Dropout、学习率指数衰减和自适应矩估计权值更新算法。实验结果表明, 与其他分类方法相比, 所提方法具有较好的泛化性能和较高的分类准确率, 这为电压暂降识别提供了一种客观、高效的辅助手段。

关键词: 空间相量模型; 卷积神经网络; 随机森林; 电压暂降; 电能质量

Classification of three-phase voltage dips based on CNN and random forest

LIU Jiahan¹, CHEN Kexu², MA Jian², XU Chunhua¹, WU Jianhua¹

(1. School of Information Engineering, Nanchang University, Nanchang 330031, China;

2. State Grid Jiangxi Electric Power Research Institute, Nanchang 330096, China)

Abstract: Feature extraction is the critical step in power quality disturbances recognition, while the traditional methods combining the mathematical manipulations and shallow neural networks cannot extract the features automatically. Therefore, the paper proposes a hybrid model based on the Convolutional Neural Network (CNN) and Random Forest (RF) to perform the automatic feature extraction and classification of the three phase voltage dip data. Firstly, the three phase voltage dip data is transformed to the Space Phasor Model (SPM). Secondly, CNN is used for extracting the features of the SPM. Finally, RF is applied for classification. For the acceleration of the training of CNN and the relief of over-fitting, the dropout, exponential decay of learning rate and update of weights by adaptive moment estimation are introduced. Experimental results demonstrate that the proposed method has a better generalization performance and higher classification accuracy compared to other classification methods, which provides an objective and efficient auxiliary method for voltage dip recognition.

This work is supported by National Natural Science Foundation of China (No. 61662047).

Key words: space phasor model; convolutional neural network; random forest; voltage dip; power quality

0 引言

电压暂降(voltage dip)为电力系统中一种电能质量扰动(Power Quality Disturbance, PQD)现象, 其持续时间通常为半个工频周期至 1 min^[1]。随着电力负荷复杂度与日俱增和精密仪器对电能系统稳定性要求的不断提高, 电压暂降问题逐渐引起了学术界和工业界的关注^[2]。电压暂降可能由电机启动、大

容量负载切换、变压器通电或电网中的短路所引起, 它可能会使工业生产设备发生故障, 甚至导致重大经济损失^[3]。精准的电压暂降类型识别有助于电力维护人员对电能质量进行评估并提出有效的电压暂降治理方案。因此, 加强电压暂降检测与识别方面的研究对于提升电能质量具有重要意义。

电能质量方面已有大量研究, 其中包括电压暂降识别分类^[4-5]。电压暂降分为 Ca、Cb、Cc、Da、Db 和 Dc 等六种三相不平衡电压暂降(three phase unbalanced voltage dip)以及 A——一种三相平衡电

压暂降(three phase balanced voltage dip)^[6]。

近年来, 聚类(clustering)、支持向量机(Support Vector Machine, SVM)和人工神经网络(Artificial Neural Network, ANN)等机器学习算法在 PQD 分类方面的研究和应用引起了广泛的关注, 并达到了较好的效果^[7-11]。文献[7]提出了基于小波变换(Wavelet Transform, WT)和 SVM 的 PQD 分类算法, 利用 WT 提取特征并将 SVM 用于分类。仿真结果表明, 该方法可以有效地对不同电能质量事件(power quality events)进行分类。文献[8]将 WT 与径向基函数神经网络(radial basis function neural network)应用于 PQD 的检测与分类, 与文献[7]的方法相比, 该方法需要较少的信号特征进行训练和分类。上述基于 WT 的方法虽然具有良好的时频域分辨率, 但其计算负担较重, 影响了识别系统的整体性能。文献[9]提出了基于改进型 WT 和随机森林(Random Forest, RF)的 PQD 分类方法, 降低了 WT 的计算复杂度并提高了分类准确率。文献[10]提出了一种基于改进形态滤波器和弧长差分序列的电能质量扰动定位与识别算法, 仿真试验表明该方法能准确定位并识别单一和复合型扰动信号。文献[11]将强跟踪滤波器和极限学习机应用于电能质量扰动分类, 与其他算法相比, 该方法具有较高的分类准确率且适用于实时检测。然而, 文献[7-11]中的方法均存在以下问题: 1) 仅对单相电压数据进行识别分类; 2) 仍采用数学变换的方法提取特征; 3) 对于不同的分类问题需要采用不同的特征提取方法。

因此, 文献[12]将 X 均值聚类(x-means clustering)和竞争惩罚期望最大化(rival penalized expectation maximization)学习法应用于三相电压暂降分类, 实现了对电压暂降数据的信息采集与识别。然而, 文献[11]中的数据预处理仍然采用了 WT 进行特征提取。

为了给智能电网提供一种高效的 PQD 自动特征提取与识别方案, 文献[13]先将三相电压有效值转换成 RGB 图像, 再利用卷积神经网络(Convolutional Neural Network, CNN)进行自动特征提取与分类。文献[14]先将电能数据转换为空间相量模型(Space Phasor Model, SPM), 然后利用 CNN 进行特征提取并用 Softmax 进行分类。

然而, 文献[13]和文献[14]中的方法均存在以下不足: 1) Softmax 模型是一个带有独立变量的复杂函数, 并且其运作方式与黑盒模型相似, 因此它的独立变量的回归系数不容易被解释; 2) 由于 Softmax 模型复杂度较高, 整个模型易陷入过拟合; 3) 无论 CNN 的反向传播(Back Propagation, BP)算法寻找的第一个分类超平面解(separating hyperplane solution)

是否为全局最优, CNN 将停止训练且不再寻找分类超平面最优解; 4) CNN 仅通过训练一个全连接层分类器来拟合不同类别数据, 将 CNN 提取的所有特征用于全连接层分类可能会因冗余特征降低网络泛化性能^[15-18]。而 RF 具有较高的鲁棒性和易于实现的优点, 它构建的多个不同决策树(decision tree)都能对输入数据进行决策, 将 RF 替换 CNN 最后一层全连接层能最大程度地提升模型的泛化性能和分类准确率, 这为最终预测提供了一种可靠的方法^[16,19]。

因此, 本文设计了一种基于 CNN 和 RF 的混合模型对三相电压暂降数据进行分类。首先, 将三相电压暂降数据转换为 SPM, 然后利用 CNN-RF 进行分类。一方面, SPM 能更好地展现三相电压波形随时间变化的特性并降低数据维度; 另一方面, CNN-RF 混合模型能够自动提取显著特征并准确分类。此外, 为了加快 CNN 训练速度并缓解过拟合, 本文引入了 Dropout、学习率指数衰减(Learning Rate Exponential Decay, LRED)和自适应矩估计权重更新算法(Adaptive moment estimation, Adam)^[20-21]。实验结果表明, 与其他分类方法相比, 本文提出的基于卷积神经网络和随机森林的三相电压暂降分类方法具有较好的泛化性能和较高的分类准确率, 为电压暂降识别提供了一种客观、高效的辅助手段。

1 相关工作基础

1.1 三相电压的 SPM 变换

首先, 将三相电压向量 U_a 、 U_b 和 U_c 变换为复平面的 SPM。

$$V = \frac{2}{3} [U_a + \beta U_b + \beta^2 U_c] \quad (1)$$

式中: $\beta = e^{j2\pi/3}$; V 为复数向量^[5]。随后再将复数向量 V 重塑成大小为 $n \times 2$ 的矩阵 V' , 如式(2)。

$$V' = [V_R \quad V_I]_{n \times 2} \quad (2)$$

式中, V_R 和 V_I 分别为 V' 元素的实部和虚部向量, 向量长度为 n , 向量元素取值范围均为 $[-1, 1]$ 。最后, 将矩阵 V' 转换成大小为 $\Delta \times \Delta$ 的矩阵 S , 其元素为

$$s(x, y) = \sqrt{V_{R,i}^2 + V_{I,i}^2} \quad (3)$$

$$(x, y) = \begin{cases} \left(\left[\frac{\Delta}{2} \cdot (1 - V_{I,i}) \right], \left[\frac{\Delta}{2} \cdot V_{R,i} \right] + \Delta - 1 \right) & V_{I,i} > 0, V_{R,i} > 0 \\ \left(\left[\frac{\Delta}{2} \cdot |V_{I,i}| \right] + \Delta - 1, \left[\frac{\Delta}{2} \cdot V_{R,i} \right] + \Delta - 1 \right) & V_{I,i} < 0, V_{R,i} > 0 \\ \left(\left[\frac{\Delta}{2} \cdot |V_{I,i}| \right] + \Delta - 1, \left[\frac{\Delta}{2} \cdot |V_{R,i}| \right] \right) & V_{I,i} < 0, V_{R,i} < 0 \\ \left(\left[\frac{\Delta}{2} \cdot (1 - V_{I,i}) \right], \left[\frac{\Delta}{2} \cdot (1 - |V_{R,i}|) \right] \right) & V_{I,i} > 0, V_{R,i} < 0 \end{cases} \quad (4)$$

式中: x 和 y 分别表示矩阵 \mathbf{S} 中元素对应的行和列; $V_{R,i}$ 和 $V_{I,i}$ 分别表示向量 V_R 和 V_I 的第 i 个元素值, $i \in [0, n-1]$; $\lceil \cdot \rceil$ 表示向上取整, $|\cdot|$ 表示取绝对值, $s(x, y)$ 的取值范围为 $[0, 1]$ 。图 1 展示了 Cc 型三相电压暂降的时域波形和复平面的可视化 SPM 灰度图。左侧图反映了三相电压幅值随时间(周波数)变化的情况; 右侧图实数和虚数轴的坐标值分别对应等式(4)中的 x 和 y 。

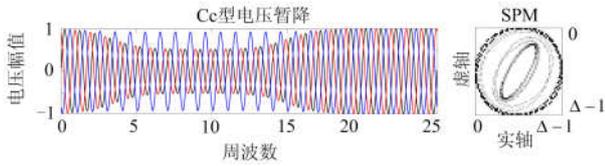


图 1 Cc 型电压暂降波形及 SPM

Fig. 1 Waveform and SPM of type Cc voltage dip

从图 1 的可视化 SPM 中可获知电压暂降的类型, 电压下降的方式、幅值大小、持续时间以及是否发生相位跳变。以原点为圆心的最外层圆环为理想正弦平衡电压的空间矢量, 内侧圆环为三相平衡电压暂降空间矢量, 椭圆为三相不平衡电压暂降的空间矢量。三相不平衡电压暂降类型可由椭圆长轴与 SPM 实轴的夹角表示^[6]。SPM 中椭圆个数可反映三相不平衡电压暂降期间幅值下降的速度, 椭圆数量越多, 电压下降越缓慢。椭圆的面积反映了三相不平衡电压下降的幅值, 面积越小则电压下降的幅值越大。在图 1 右侧 SPM 灰度图中, 环状像素点灰度值越低, 表明电压处于该种状态的时间越长。三相不平衡电压暂降发生时和传播过程中通常伴随着相位跳变, 若椭圆发生畸变则表明电压幅值有明显下降的电压相发生了相位跳变。

1.2 CNN

CNN 是一种基于有监督学习的多层级神经网络, 它主要由卷积层、池化层和全连接层构成, 它通常采用 Softmax 回归进行分类, 即其逻辑回归层采用 Softmax 函数输出概率化向量, 并基于 BP 算法来进行训练^[15-16, 19]。CNN 的局部连接(local connection)扩大了它的特征感受视野, 权值共享(weights sharing)为减少网络学习超参数量提供了一种高效的方法^[16]。

卷积层是 CNN 的重要组成部分, 其本质是将固定大小的输入图像映射至高维特征图。卷积层通过卷积核与输入图像各个区域卷积来提取特征矩阵。

$$\varphi_i = \sigma \left(\sum_{k=1}^N \omega_k \gamma_k + \theta_i \right) \quad (5)$$

式中: φ_i 为卷积层第 i 个神经元的输出特征值; ω_k 为卷积核的第 k 个值; γ_k 为输入矩阵的第 k 个值; N 为卷积核的元素个数; θ_i 为第 i 个偏置值; σ 为修正线性单元(rectified linear unit)激活函数, $\sigma(x) = \max(x, 0)$ 。

下采样层能在去除特征矩阵冗余信息的同时保留重要特征, 并采用最大值池化(maximum value pooling)计算特征矩阵各区域的输出, 从而减小后续卷积操作计算量并提高神经网络的训练速度。

全连接层将卷积和池化交替层输出的特征矩阵通过全连接操作转换成低维特征向量, 并经过 Softmax 函数概率化输出预测向量, 预测向量元素中的最大值即为输入数据对应的预测类别。CNN 采用 BP 算法最小化预测向量与真实向量的交叉熵损失函数来提高预测准确率。

1.3 RF

RF 是一种用来解决分类和回归问题的集成学习(ensemble learning)算法, 它由多个分类回归树(Classification and Regression Tree, CART)组成, 模型简单且不容易过拟合^[16, 19, 22]。RF 的 Bootstrap 和随机特征选择性使它在众多分类问题中得到成功应用^[19]。

RF 首先利用 Bootstrap 算法从训练数据集 D 中抽取 N 组样本, 每个样本的最大特征维数为 M ; 其次, 从 M 中随机选取 m 个特征分别作为 K 棵 CART 内部节点(inner node) t 的待选分裂条件, 分别计算 m 个特征的基尼系数增益(gini coefficient gain), 将最大基尼系数增益对应的特征作为 t 的最佳分裂条件, 每棵 CART 都尽可能地生长而不进行剪枝(pruning); 节点 t 的基尼系数 $G(t)$ 计算公式为

$$G(t) = 1 - \sum_{i=1}^k [p(c_i | t)]^2 \quad (6)$$

式中: k 为节点 t 中数据的类别总数; $p(c_i | t)$ 为节点 t 中数据类别为 c_i 的比例。最后, 每颗 CART 将作为一个决策单元对输入数据进行投票, 得票数最多的类别即为输入数据的预测类别^[16]。

节点 t 以特征值 $R (R \in m)$ 作为分裂条件, 其分裂后的基尼系数 $G_R(t)$ 为

$$G_R(t) = \frac{x_1}{x_0} G(t_1) + \frac{x_2}{x_0} G(t_2) \quad (7)$$

式中: x_0 为节点 t 中的数据个数, 节点 t 分裂成节点 t_1 和节点 t_2 , t_1 和 t_2 中的数据个数分别为 x_1 和 x_2 ; $G(t_1)$ 和 $G(t_2)$ 分别为节点 t_1 和 t_2 的基尼系数。

节点 t 以特征值 R 分裂后的基尼系数增益 $\Delta G_R(t)$ 为

$$\Delta G_R(t) = G(t) - G_R(t) \quad (8)$$

2 本文算法

本文提出的基于 SPM 和 CNN-RF 的三相电压暂降分类算法如图 2 所示, 它由数据处理、特征提取与分类两部分组成。

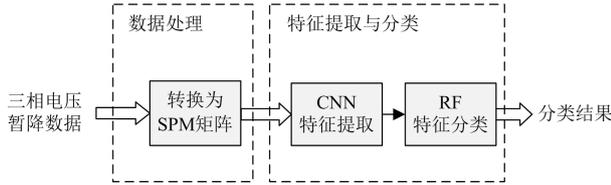


图 2 分类算法流程图

Fig. 2 Classification algorithm flowchart

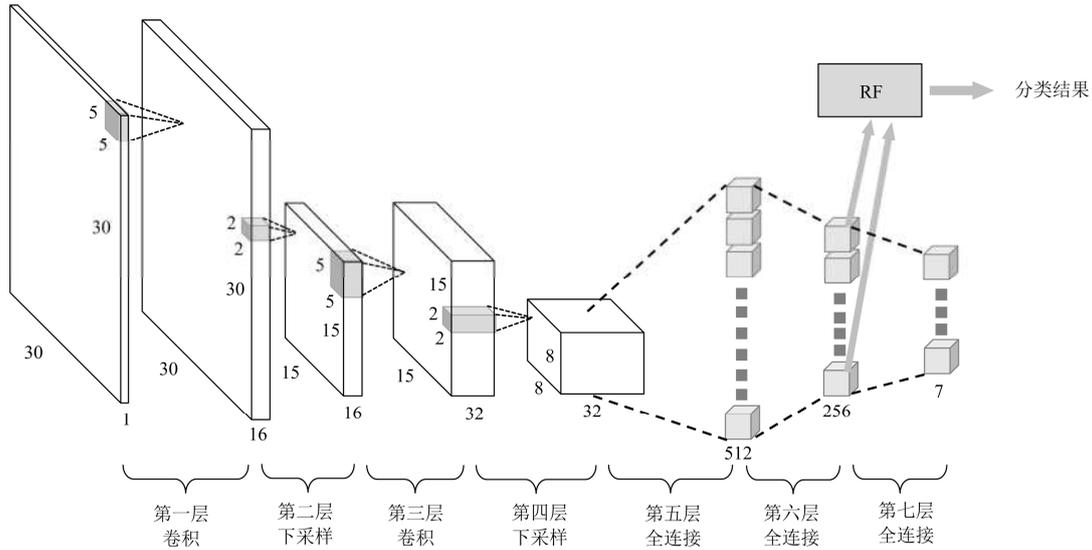


图 3 CNN-RF 混合模型架构

Fig. 3 Architecture of CNN-RF hybrid model

为了加快 CNN 训练速度并缓解过拟合, 本文引入了 Dropout、LRED 和 Adam。在第五层和第六层全连接层中加入 Dropout 以缓解过拟合的影响。学习率指数衰减通过改变学习率更新速度来提升网络性能, 学习率更新公式为

$$\alpha' = \alpha \cdot dr^{(gs/ds)} \quad (9)$$

式中: α' 为每一轮优化时使用的学习率; α 为初始学习率, 大小为 0.001; dr 为衰减系数, 大小为 0.96; ds 为训练完所有数据所需的迭代轮数; gs 为当前迭代轮数。

采用 Adam 后的权值更新公式如式(10)。

$$\omega_i = \omega_{i-1} - \alpha \cdot m'_i / (\sqrt{n'_i} + \varepsilon) \quad (10)$$

式中: ω_i 为更新后的权值; ω_{i-1} 为更新前的权值; α 为初始学习率, 大小为 0.001; m'_i 为偏置矫正后

的一阶矩估计; n'_i 为偏置矫正后的二阶矩估计; ε 为大小为 10^{-8} 的常数。

首先, 将三相电压转换为复平面的 SPM 二维矩阵; 其次, 利用 CNN 对 SPM 矩阵数据进行自动特征提取; 最后将 RF 替换 CNN 最后一层全连接层进行分类。

CNN-RF 的架构及每层参数设置如图 3 所示。CNN 可视为由包含 2 个卷积层、2 个池化层、2 个全连接层的特征提取器和 1 个全连接层分类器组成。第一层和第三层卷积层的卷积核大小均为 5×5 , 步长为 1; 第二层和第四层池化层的池化窗口大小均为 2×2 , 步长为 2; 第五层和第六层全连接层输出的特征向量大小分别为 1×512 和 1×256 ; 第七层全连接层将输出向量经过 Softmax 函数输出大小为 1×7 的概率向量。本文算法即在第 7 层以 RF 替代了 Softmax。

CNN 的特征提取能力较浅层神经网络强, 但将 CNN 提取的所有特征用于全连接层进行分类并不是最佳选择, 因为特征向量中的部分冗余特征会降低模型的泛化性能^[17-18]。

本文将 CNN 最后一层全连接层替换为 RF, 当基于 CNN 的特征提取器完成训练时, 第六层全连接层输出的特征向量将作为新的训练数据集传递给 RF 进行学习和分类。

本文将 CNN 最后一层全连接层替换为 RF, 当基于 CNN 的特征提取器完成训练时, 第六层全连接层输出的特征向量将作为新的训练数据集传递给 RF 进行学习和分类。

3 实验结果

实验系统环境为基于 Ubuntu 16.04 64 位操作系统和 TensorFlow 1.3 GPU 版本框架; 处理器为 i5-7500@3.40 GHz×4; 图像处理单元为 GeForce

GTX 1050Ti/PCIe/SSE2; 运行内存为 8 GB。

3.1 实验数据

采用 Matlab 仿真出 Ca、Cb、Cc、Da、Db、Dc 和 A 七种类型的单阶三相电压暂降(single stage voltage dip)样本 7 000 个, 每类 1 000 个样本, 基波频率为 50 Hz, 信号采样频率为 5 kHz, 采样时长为 1 s。本文将样本分为训练集(5 040)、验证集(560)和测试集(1 400)。三相电压仿真数据的生成公式为

$$\begin{cases} U_a = \sin(100\pi \cdot t + \varphi_a(t)) \cdot \mu_0 \cdot \delta_a(t) \\ U_b = \sin(100\pi \cdot t + \varphi_b(t) + 2\pi/3) \cdot \mu_1 \cdot \delta_b(t) \\ U_c = \sin(100\pi \cdot t + \varphi_c(t) + 4\pi/3) \cdot \mu_2 \cdot \delta_c(t) \end{cases} \quad (11)$$

式中: U_a 、 U_b 和 U_c 分别为三相电压; $\varphi_a(t)$ 、 $\varphi_b(t)$ 和 $\varphi_c(t)$ 分别为相位跳变函数, 电压幅值有明显下降时的跳变相角取值范围为 $(-40^\circ, 0^\circ)$; $\delta_a(t)$ 、 $\delta_b(t)$ 和 $\delta_c(t)$ 为三相电压暂降函数, 用于控制电压下降的速度和持续时间, 下降方式为陡峭下降或缓慢下降, 持续时间的取值范围为 $(0.01 \text{ s}, 0.6 \text{ s})$, 即半个周波至 30 个周波; μ_0 、 μ_1 和 μ_2 分别为不同电压暂降类型各个相位的幅值下降比率, 有明显电压暂降时的取值范围为 $(0.1, 0.9)$, 无明显电压暂降时的取值范围为 $(0, 0.1)$ 。图 4 展示了 A、Ca 和 Da 型电压暂降波形, 图中横坐标为周波个数, 纵坐标为电压幅值。

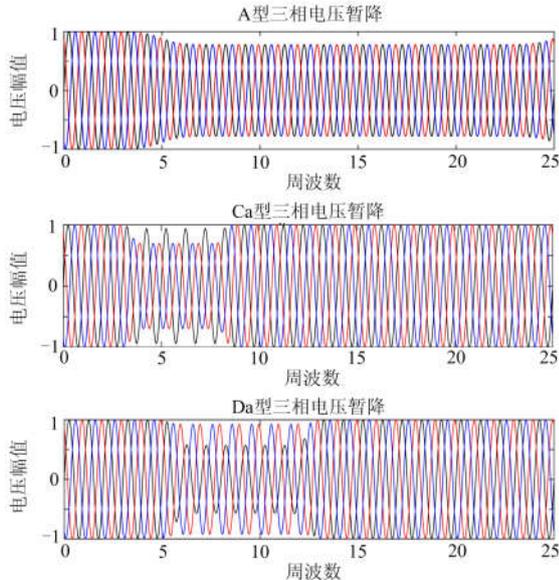


图 4 单阶电压暂降波形

Fig. 4 Waveform of single stage voltage dip

3.2 参数寻优

为了提高模型的性能, 本文在最大特征数目 M 、RF 的 CART 个数 K 和 SPM 的行(列)数 Δ 的

不同取值下, 通过比较模型的性能和计算时间来确定参数值的最佳组合。不同参数值组合的分类效果如图 5 所示。

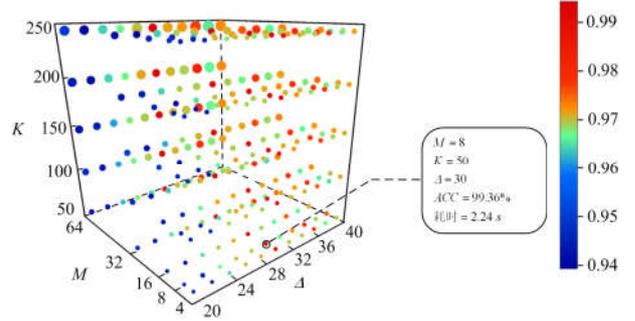


图 5 参数寻优

Fig. 5 Parameter optimization

图 5 中 M 轴为最大特征数, K 轴为 CART 个数, Δ 轴为 SPM 矩阵的行(列)数; 球形颜色代表模型的性能, 颜色越接近深红色, 准确率越高; 球形大小表示模型的计算速度, 球形越小计算速度越快。实验结果表明, 当 $M=8$ 、 $K=50$ 和 $\Delta=30$ 时分类准确率最高且计算时间最短。

3.3 不同分类算法比较

本文利用 SVM^[15]、RF^[16]、PCANet-SVM、PCANet-RF^[23]、LeNet^[15] 和 CNN-RF 对三相电压的 SPM 进行分类。通过对比不同算法的平均查准率(mean-P)、平均查全率(mean-R)、平均 F1 值(mean-F1)和准确率来评价其分类性能。mean-P、mean-R、mean-F1 和 accuracy 的计算公式为

$$\text{mean-P} = \frac{\overline{TP}}{\overline{TP} + \overline{FP}} \quad (12)$$

$$\text{mean-R} = \frac{\overline{TP}}{\overline{TP} + \overline{FN}} \quad (13)$$

$$\text{mean-F1} = \frac{2 \times \text{mean-P} \times \text{mean-R}}{\text{mean-P} + \text{mean-R}} \quad (14)$$

$$\text{accuracy} = \frac{\overline{TP} + \overline{TN}}{\overline{TP} + \overline{FP} + \overline{TN} + \overline{FN}} \quad (15)$$

式中, \overline{TP} 、 \overline{FP} 、 \overline{TN} 和 \overline{FN} 分别为所有样本类别真阳率、假阳率、真阴率和假阴率的平均值。

图 6 展示了 CNN-RF 在单阶电压暂降测试数据集上的混淆矩阵(confusion matrix)。图中混淆矩阵的纵坐标为数据真实类型, 横坐标为预测类型, 对角线上的数值表示正确分类个数, 而非对角线上的数值表示误分类个数。

各个算法分类结果如表 1 所示。从表 1 的数据可知, 与其他算法相比, 本文方法的分类效果最佳。

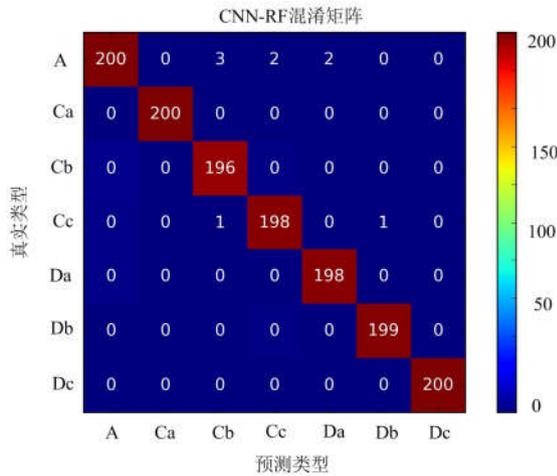


图 6 CNN-RF 混淆矩阵

Fig. 6 Confusion matrix of CNN-RF

表 1 不同分类方法比较

Table 1 Comparison of different classification methods

方法	accuracy	mean-P	mean-R	mean-F1
SVM	91.79%	91.79%	91.79%	91.79%
RF	95.86%	96.11%	95.86%	95.98%
PCANet-SVM	96.48%	96.43%	96.48%	96.45%
PCANet-RF	96.86%	96.99%	96.86%	96.92%
LeNet	89.64%	89.78%	89.64%	89.71%
CNN-RF	99.36%	99.37%	99.36%	99.36%

4 结论

本文为电压暂降识别的研究提供了一种有效的分类算法, 通过将 CNN 与 RF 进行优势互补, 实现了对三相电压暂降的自动特征提取和分类。本文所做的主要工作和相关结论如下:

1) 将三相电压暂降数据转换为复平面 SPM 矩阵, 不仅可减少模型的计算量, 而且能展示出信号的时域波形特性及扰动信息。

2) CNN 的卷积与池化交替层具有较好的特征提取能力, 它能自动提取 SPM 的显著特征, 并为 RF 提供训练数据集。

3) RF 的 Bootstrap 和随机特征选取方法减少了基学习器之间的相关性, 增强了模型的泛化性能并提高了分类准确率。

4) 当最大特征维数为 8, CART 个数为 50 且 SPM 矩阵大小为 30×30 时, CNN-RF 具有最高的分类准确率和最快的计算速度。

实际电压暂降检测中, 电压暂降检测速度以及幅值、持续时间和相位跳变等参数的精准测量都备受关注。本文只对电压暂降作了类型识别, 且 RF 计算速度较 CNN 最后一层全连接层稍慢。因此下

阶段的工作可着重于提高 RF 计算速度和探求新的电压暂降参数测量方法。

参考文献

- [1] LI Zhengming, LI Wenwen, PAN Tianhong. An optimized compensation strategy of DVR for micro-grid voltage sag[J]. Protection and Control of Modern Power Systems, 2016, 1(1): 78-85. DOI: 10.1186/s41601-016-0018-9.
- [2] 李夏林, 刘雅娟, 朱武. 基于配电网的复合电压暂降源分类与识别新方法[J]. 电力系统保护与控制, 2017, 45(2): 131-139.
LI Xialin, LIU Yajuan, ZHU Wu. A new method to classify and identify composite voltage sag sources in distribution network[J]. Power System Protection and Control, 2017, 45(2): 131-139.
- [3] 李升, 姜程程, 赵之瑜, 等. 分布式光伏电站接入低压配电网系统暂态电压稳定性研究[J]. 电力系统保护与控制, 2017, 45(8): 67-72.
LI Sheng, JIANG Chengcheng, ZHAO Zhiyu, et al. Study of transient voltage stability for distributed photovoltaic power plant integration into low voltage distribution network[J]. Power System Protection and Control, 2017, 45(8): 67-72.
- [4] MAJD A A, SAMET H, GHANBARI T. K-NN based fault detection and classification methods for power transmission systems[J]. Protection and Control of Modern Power Systems, 2017, 2(2): 359-369. DOI: 10.1186/s41601-017-0063-z.
- [5] MAHELA O P, SHAIK A G, GUPTA N. A critical review of detection and classification of power quality events[J]. Renewable & Sustainable Energy Reviews, 2015, 41: 495-505.
- [6] BEGHERI A, BOLLEN M, GU I. Improved characterization of multi-stage voltage dips based on the space phasor model[J]. Electric Power Systems Research, 2018, 154: 319-328.
- [7] KARTHIKEYAN M, MALATHI V. Wavelet-support vector machine approach for classification of power quality disturbances[J]. International Journal of Recent Trends in Engineering, 2013, 1(3): 290-293.
- [8] KANIRAJAN P, KUMAR S V. Power quality disturbance detection and classification using wavelet and RBFNN[J]. Applied Soft Computing, 2015, 35: 470-481.
- [9] MARKOVSKA M, TASKOVSKI D. Optimal wavelet based feature extraction and classification of power quality disturbances using random forest[C] // 17th International Conference on Smart Technologies, July 6-8, 2017, Ohrid, Macedonia: 855-859.

- [10] 卓金宝, 施伟锋, 兰莹, 等. 基于改进形态滤波器和弧长差分序列的微电网电能质量扰动定位与识别[J]. 电工技术学报, 2017, 32(17): 21-34.
ZHUO Jinbao, SHI Weifeng, LAN Ying, et al. Location and identification of micro-grid power quality disturbances based on modified morphological filter and arc length differential sequence[J]. Transactions of China Electrotechnical Society, 2017, 32(17): 21-34.
- [11] 陈晓静, 李开成, 肖剑, 等. 一种实时电能质量扰动分类方法[J]. 电工技术学报, 2017, 32(3): 45-55.
CHEN Xiaojing, LI Kaicheng, XIAO Jian, et al. A method of real-time power quality disturbance classification[J]. Transactions of China Electrotechnical Society, 2017, 32(3): 45-55.
- [12] LAZZARETTI A E, FERREIRA V H, NETO H V. New trends in power quality event analysis: novelty detection and unsupervised classification[J]. Journal of Control Automation & Electrical Systems, 2016, 27(6): 718-727.
- [13] BALOUJI E, SALOR O. Classification of power quality events using deep learning on event images[C] // 3rd International Conference on Pattern Recognition and Image Analysis (IPRIA), April 19-20, 2017, Shahrekord, Iran: 216-221.
- [14] BAGHERI A, GU I, BOLLEN M, et al. A robust transform-domain deep convolutional network for voltage dip classification[J]. IEEE Transactions on Power Delivery, 2018, 33(6): 1-9.
- [15] NIU X X, SUEN C Y. A novel hybrid CNN-SVM classifier for recognizing handwritten digits[J]. Pattern Recognition, 2012, 45(4): 1318-1325.
- [16] CAO G, WANG S, WEI B, et al. A hybrid CNN-RF method for electron microscopy images segmentation[J]. Journal of Biomimetics Biomaterials & Tissue Engineering, 2013, 18(2): 1-6.
- [17] MERENTITIS A, DEBES C. Automatic fusion and classification using random forests and features extracted with deep learning[C] // Geoscience and Remote Sensing Symposium, July 26-31, 2015, Milan, Italy: 2943-2946.
- [18] BASATINI F M, CHINIPARDAZ R. Softmax model as generalization upon logistic discrimination suffers from overfitting[J]. Journal of Data Science, 2014, 12(4): 563-574.
- [19] WANG J, HUANG P, HUANG Q, et al. Dialogue act recognition for Chinese out-of-domain utterances using hybrid CNN-RF[C] // International Conference on Asian Language Processing, November 21-23, 2016, Tainan, China: 14-17.
- [20] PHAISANGITTISAGUL E. An analysis of the regularization between l2 and dropout in single hidden layer neural network[C] // 7th International Conference on Intelligent Systems, Modelling and Simulation (ISMS), January 25-27, 2016, Bangkok, Thailand: 174-179.
- [21] WANG Z, WANG Z, ZHANG H, et al. A novel fire detection approach based on CNN-SVM using tensorflow[C] // 13th International Conference on Intelligent Computing (ICIC), August 7-10, 2017, Liverpool, UK: 682-693.
- [22] 瞿合祚, 刘恒, 李晓明, 等. 基于多标签随机森林的电能质量复合扰动分类方法[J]. 电力系统保护与控制, 2017, 45(11): 1-7.
QU Hezuo, LIU Heng, LI Xiaoming, et al. Recognition of multiple power quality disturbances using multi-label random forest[J]. Power System Protection and Control, 2017, 45(11): 1-7.
- [23] CHAN T H, JIA K, GAO S, et al. PCANet: a simple deep learning baseline for image classification[J]. IEEE Transactions on Image Processing, 2015, 24(12): 5017-5032.

收稿日期: 2018-10-26; 修回日期: 2018-12-28

作者简介:

刘佳翰(1994—), 男, 硕士研究生, 研究方向为电能质量、深度学习; E-mail: 406130716118@email.ncu.edu.cn

陈克绪(1979—), 男, 高级工程师, 主要研究方向为电力测量、嵌入式硬件; E-mail: chenhexud@163.com

吴建华(1956—), 男, 通信作者, 博士, 教授, 研究方向为数字图像处理、电能质量信号分析、模式识别。E-mail: jhww@ncu.edu.cn

(编辑 魏小丽)