

DOI: 10.19783/j.cnki.pspc.190581

基于优化卷积神经网络的电缆早期故障分类识别

汪颖, 孙建风, 肖先勇, 卢宏, 杨晓梅

(四川大学电气工程学院, 四川 成都 610065)

摘要: 准确识别电缆早期故障是及时消除故障隐患的必要前提。提出基于卷积神经网络的电缆早期故障分类识别的方法, 可从含恒定阻抗故障、励磁涌流、电容投切扰动的过电流信号中准确识别电缆早期故障。通过小波变换提取过电流信号特征, 构建卷积神经网络, 进行训练调整网络参数形成输入特征与类别编码之间的映射关系。为解决训练过拟合和学习效率的问题, 通过修正损失函数和采用自适应学习率的方法优化卷积神经网络。仿真结果表明, 所提方法能对过电流信号进行有效分类, 准确识别电缆早期故障, 具有较高的工程应用价值。

关键词: 电缆早期故障; 卷积神经网络; 深度学习; 分类识别; 修正损失函数

Cable incipient fault classification and identification based on optimized convolution neural network

WANG Ying, SUN Jianfeng, XIAO Xianyong, LU Hong, YANG Xiaomei

(College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: It is necessary to identify the cable incipient faults in order to eliminate the hidden faults in time. This paper proposes a method for cable incipient fault classification and identification based on Convolution Neural Network (CNN). This method can identify the cable incipient fault from the over-current disturbance waveforms, including the waveforms of constant impedance fault, inrush current, capacitance switching disturbance waveform, and so on. The features of the over-current waveforms are extracted by wavelet transform, which are used as the input of CNN. By training the mapping relationship between input features and class coding, the parameter is chosen and the CNN is formed. CNN is optimized by modifying the loss function and adopting the method of adaptive learning rate, for solving the problem of over-fitting and learning efficiency. The simulation results show that the proposed method can classify the overcurrent signals effectively and identify cable incipient fault accurately, which is with high engineering application value.

This work is supported by National Natural Science Foundation of China (No. 51807126).

Key words: cable incipient fault; convolution neural network; deep learning; classification identification; modified loss function

0 引言

电缆早期故障是由于电缆绝缘存在局部缺陷而引发的一种间歇性电弧故障^[1-2]。除机械性损伤和外力破坏外, 多数电缆永久性故障均由电缆早期故障演化而来。实际运行中, 电缆早期故障放电持续时间短, 不能触发常规的过电流保护^[2-3], 但监测装置能够记录到扰动电流波形。从多种扰动波形中识别电缆早期故障, 为及时消除潜在故障隐患, 提高系统运行水平和供电可靠性等, 具有重要意义。

国内外对电缆早期故障已开展了探索性研究,

并取得了阶段性成果。已有研究表明, 湿气渗透是电缆绝缘损坏的主要原因, 因此电缆早期故障多发生在电缆接头位置。由于发生电缆早期故障时产生电弧, 积聚热量, 水汽蒸发产生的高压环境会使电弧自动熄灭, 电缆早期故障也被称为自清除故障^[3]。此外, 现场测试试验表明, 电缆早期故障通常发生在电压波形峰值附近, 持续 1/4 个到多个工频周期^[2]。

基于电缆早期故障时电压、电流信号的时、频域特征, 国内外学者提出了多种电缆早期故障分类识别方法^[1,4-8], 为及时消除故障隐患提供依据。文献[1]基于概率神经网络和支持向量机, 构建电缆电压、电流波形的谐波频域特征向量, 识别电容器投切扰动信号, 为电缆电流扰动信号的识别提供了创

新性的思路。文献[4]利用小波变换构成电缆电流信号的时频特征向量,基于灰色关联分析,从多种过电流信号中识别电缆早期故障。文献[5]基于小波分析的方法,对电流信号进行分解,考虑故障瞬态前后近似系数的均方根比值设定阈值,对信号进行分类识别。文献[6]提出了电缆多周期早期故障检测和定位的方法,利用电压畸变程度来判断是否有早期故障发生。文献[7]假设金属护套与电缆单端结合,利用发生早期故障时金属护套的感应电流总和及小波变换后模的极大值来检测早期故障,但实际中难以满足方法所需条件,工程应用困难。文献[8]对过电流进行S变换,提取变换后高、中、低频段的能量熵和奇异熵等特征量构成特征向量,利用SAE网络作为分类器识别电缆早期故障信号等过电流干扰信号。

在现有研究中,电缆早期故障分类识别算法主要有阈值法^[5-6]、推理法^[4,7]和分类器法^[1,8]。然而在实际电力系统中线路结构复杂,元件之间存在强关联耦合关系,运行条件具有不确定性。使用阈值法难以根据实际的电力系统确定合适的阈值,使用传统的分类器对扰动信号的分类识别能力表现较差。深度学习模型的深层网络包含多个隐藏层,能够深层次地发现数据中的隐藏特征,相比传统的模式识别方法具有更高的准确率^[9]。其中,卷积神经网络(Convolutional Neural Networks, CNN)相较于其他深度学习模型具有独特的结构,稀疏连接、权值共享降低了网络的复杂程度,一定程度上减少了训练时间,子采样操作减少数据维度,使其具有空间时不变性,因此考虑将CNN作为电缆早期故障的分类器。

基于以上分析,本文提出基于CNN的电缆早期故障分类识别方法。考虑了励磁涌流、电容投切等过电流扰动信号,结合小波变换提取样本集中每个过电流样本在时域、频域上的30个特征参数,构成特征向量,利用CNN实现各类信号的分类识别。针对收敛速度和过拟合等问题采用自适应学习率和正则化的方法优化CNN。在PSCAD/EMTDC中搭建25 kV电缆早期故障模型,生成仿真样本数据,验证所提方法的正确性,并将本文算法与传统的分类器进行比较,证明所提出方法具有更高的准确率。

1 电缆早期故障机理

电缆接头渗入湿气后,绝缘材料会出现电场分布不均匀的情况。在水分和电场的共同作用下,绝缘材料电场较强处会出现水树。水树又会造成电缆的局部应力增高,继而产生电树,而且水树在高温作用下会发生氧化反应,造成电缆吸水性增强,导

电性增高,最终导致绝缘击穿^[10-11]。电缆的早期故障即是在电缆绝缘局部缺陷逐渐老化的过程中发生的间歇性电弧放电现象。

电缆早期故障是一种间歇性的电弧故障,在电压波形峰值附近发生,电流过零点时熄灭,可以用学术界普遍接受的工频熄弧理论解释。目前电缆早期故障尚无公认模型,因其具有电弧故障的基本特征,因此本文选用电弧模型进行后续分析。有效的电弧故障分析依赖于准确的电弧模型。现有的电弧通用物理模型有两种:第一种是基于流体动力学方程,结合麦克斯韦方程,遵循热力学定律;另一种主要用于电力系统瞬态模拟。常用的电弧模型有Cassie电弧模型、Mayr电弧模型、Schwarz电弧模型、控制论模型等,用于创建这些模型的通用方程为^[12]

$$\frac{1}{G(t)} \cdot \frac{dG(t)}{dt} = \frac{1}{F(t)} \cdot \frac{dF(t)}{dt} \cdot (P_{in}(t) - P_{out}(t)) \quad (1)$$

式中: $G(t)$ 为电弧电导; $P_{in}(t)$ 为传入电弧通道的能量; $P_{out}(t)$ 为传出电弧通道的能量; $F(t)$ 为放电过程中的控制方程。

基于通用电弧模型,选择不同假设条件得到不同的电弧模型。Kizicay的电弧模型从控制论的观点出发^[13],模型实现简单且能够很好地表现电弧非线性时变的特性^[14],因此本文选用此模型来对电缆早期故障进行模拟。

该电弧模型基于电弧通道能量平衡建立的,用通用电弧模型方程表述为

$$\frac{dG(t)}{dt} = \frac{1}{\tau} (G(t) - g) \quad (2)$$

式中: τ 为电弧时间常数; g 为瞬时电弧电导; $G(t)$ 表示固定电弧电导。

固定电弧电导定义为

$$G(t) = \frac{|i_{arc}|}{u_{st}} \quad (3)$$

$$u_{st} = u_0 + r_0 \cdot |i_{arc}| \quad (4)$$

式中: i_{arc} 为电弧电流; u_{st} 为静态电弧电压; u_0 为恒压参数; r_0 为电弧电阻。

2 特征提取

小波变换具有多分辨率的特点,可以同时体现电缆早期故障这种非平稳信号在时域、频域的特征^[15]。此外,小波变换也具有滤波器的效果,使得提取各类过电流信号特征时免受噪声的影响。

2.1 小波变换

给定一个函数,令

$$\psi_{(a,b)} = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (5)$$

式中, a 、 b 均为常数, 且 $a > 0$ 。若 a 、 b 不断变化, 则得到与之对应的一簇 $\psi_{(a,b)}(t)$ 。对于一个信号 $x(t) \in L^2(\mathbb{R})$, 定义其小波变换为

$$WT_{(x)} = \frac{1}{\sqrt{a}} \int x(t) \psi^*\left(\frac{t-b}{a}\right) dt = \int x(t) \psi_{a,b}^*(t) \langle x(t), \psi_{(a,b)}(t) \rangle \quad (6)$$

式中, a 、 b 和 t 均为连续变量, 则进行的是连续小波变换。将 a 、 b 离散化, 令 $a = 2^{-j}$ 、 $b = 2^{-j}k$, $j, k \in \mathbb{Z}$, 可得到 $x(t)$ 的离散小波变换为

$$(DW_{\psi}f)(j,k) = \langle f(t), \psi_{(j,k)}(t) \rangle \quad (7)$$

2.2 特征量的提取

针对采样得到的每个过电流样本, 本文选取 10 个统计参数作为特征量^[16-17]: 能量(En)、均值($Mean$)、有效值(Rms)、方差(Std)、峰值因数($Crest$)、斜度($Skew$)、陡度(Kur)、波形因数(FFa)、信息熵($Entrp$)、样本熵(SE), 构造特征向量 F_0 , 即

$$F_0 = [En, Rms, \dots, SE] \quad (8)$$

其中信息熵和样本熵的计算公式分别为

$$Entrop = \sum x_i \log x_i \quad (9)$$

$$SE = -\ln[A^m(r)/B^m(r)] \quad (10)$$

式中: x_i 表示一个样本中第 i 个元素; r 表示相似容限; $B^m(r)$ 为两个样本在相似容限下匹配 m 个点的概率; $A^m(r)$ 为两个样本在相似容限下匹配 $m+1$ 个点的概率。

对于小波分解得到的第 j 层小波系数, 选取 4 个统计参数作为特征: 最大值(Max)、最小值(Min)、均值($Mean$)、方差(Std), 构造第 j 层小波系数的特征向量 F_j , 即

$$F_j = [Max_j, Min_j, Mean_j, STD_j] \quad (11)$$

本文采用 dB.4 小波对每个电流样本进行 4 层小波分解, 并根据分解得到的 4 个细节分量(d_1, d_2, d_3, d_4)和一个近似分量 a_4 计算相应的特征向量 F_j ($j=1,2,\dots,5$), 进一步可得到用作分类识别的特征向量 F , 即

$$F = [F_0, F_1, \dots, F_5] \quad (12)$$

3 卷积神经网络

电缆早期故障的分类识别, 是要在多个扰动信号中识别出此类扰动信号。有效的特征选择是获得较高准确率的前提。小波变换提取的 30 个特征量之间或存在一定冗余, 或不能完全表征原始的电流信

号等, 这些问题将影响识别结果。CNN 具有多隐层的结构, 通过对初级特征学习, 能获得表示原始信号更本质的特征, 有利于模式识别, 其数学模型实质是一种映射关系。本文拟采用 CNN 对提取的初级特征进行学习, 训练好的 CNN 作为分类器识别各电流信号。

3.1 卷积神经网络的结构

卷积神经网络由卷积层、采样层和全连接层组成^[18], 其结构如图 1 所示。

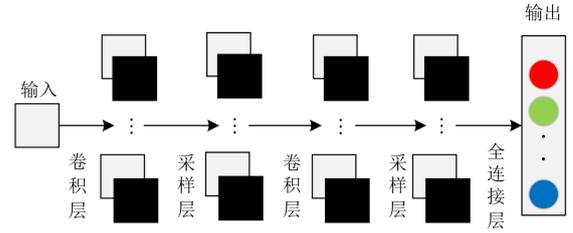


图 1 卷积神经网络的一般结构

Fig. 1 Structure of CNN

在进行前向传导过程中, 第 l 层卷积层的输出为

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j\right) \quad (13)$$

式中: M_j 表示选择的上一层输出组合; k_{ij}^l 表示第 i 个输入和第 j 个输出之间所用的卷积核; b_j 表示第 j 个输出所对应的偏置; f 为激活函数。典型的激活函数有 \tanh 函数、Sigmoid 函数和 Relu 函数等。

第 l 层采样层的输出为

$$x_j^l = f(\beta_j^l \text{down}(x_j^{l-1}) + b_j^l) \quad (14)$$

式中: $\text{down}()$ 表示降采样函数; β 表示权重。

将经过卷积采样得到的输出整理成为 $X = \{x_1, x_2, \dots, x_n\} \in \mathbb{R}^n$ 作为全连接层的输入, 下一层对应的输出为

$$Y = f(W_1 X + b_1) \quad (15)$$

式中, $W_1 \in \mathbb{R}^{m \times n}$ 、 $b_1 \in \mathbb{R}^{m \times 1}$ 分别为输入层到隐藏层的权重和偏置。

$Y \in \mathbb{R}^{m \times 1}$ 通过全连接层作为输出层的输入, 采用 Softmax 回归函数作为激活函数, 输出结果为

$$Z = S(W_2 Y + b_2) \quad (16)$$

式中, $W_2 \in \mathbb{R}^{k \times m}$ 、 $b_2 \in \mathbb{R}^{k \times 1}$ 分别为隐藏层到输出层的权重和偏置。对应的 Softmax 函数为

$$S_j = \frac{e^{a_j}}{\sum_{p=1}^k e^{a_p}} \quad (17)$$

式中: S_j 表示分类类别为第 j 种的概率; a_j 表示全连接层输出的第 j 个结果。

3.2 卷积神经网络的优化及训练

CNN 的训练是通过调整权重和偏置, 使得输出数据与期望数据之间的误差达到最小。常用的误差函数有平方差损失函数和交叉熵损失函数, 在训练过程中, 抑制隐藏层的神经元, 使隐藏层所有权值都比较小, 可在一定程度上防止过拟合的发生。因此, 引入 L2 范数构造新的损失函数, 使对数据分布影响较小的权重得到抑制, 有

$$\begin{aligned} \text{loss}(W, b) = \\ \lambda \sum W_f^2 - \frac{1}{n} \sum [y_- \cdot \ln y + (1 - y_-) \cdot \ln(1 - y)] \end{aligned} \quad (18)$$

式中: n 为样本数据的个数; y 为神经网络的输出; y_- 为神经网络的期望输出; W_f 为全连接层中隐藏层的权重; λ 为惩罚因子。

训练的目的是使构造好的损失函数的值不断减小, 为此需要更新模型中的参数。采用梯度下降法实现 CNN 中权值和偏置的更新, 即

$$W_{i,j}^{(l)} = W_{i,j}^{(l)} - \beta \frac{\partial}{\partial W_{i,j}^{(l)}} \text{loss}(W, b) \quad (19)$$

$$b_i^{(l)} = b_i^{(l)} - \beta \frac{\partial}{\partial b_i^{(l)}} \text{loss}(W, b) \quad (20)$$

式中: $W_{i,j}^{(l)}$ 表示第 l 层中第 i 个卷积核的第 j 个权值; $b_i^{(l)}$ 表示第 l 层中第 i 个卷积核所对应的偏置; β 表示学习率。

学习率 β 影响 CNN 的学习速率和收敛情况, 学习率过大易造成 CNN 的权值在最优点处振荡, 学习率过低则造成训练时间过长, 因此本文采用呈指数形式下降的学习率, 即

$$lr^{(l)} = lr^{(l-1)} \times dr^n \quad (21)$$

式中: $lr^{(l)}$ 表示第 l 轮的学习率; dr 表示学习衰减率; n 表示每轮学习的步数。

4 基于 CNN 的电缆早期故障识别方法

本文提出基于 CNN 的电缆早期故障识别方法, 从多种过电流扰动中, 识别电缆早期故障, 具体流程如图 2 所示。

(1) 生成过电流样本。采用 PSCAD/EMTDC 仿真恒定阻抗故障、电容投切、激磁涌流和半周波、多周波电缆早期故障, 将获得的各类过电流样本集合表示为 A_0 、 B_0 、 C_0 、 D_0 、 E_0 。

(2) 提取特征。结合小波变换, 对 A_0 — E_0 集合中各个样本提取 30 个特征量(形成一个特征向量)。各类过电流样本的多个特征向量构成新的集合 A 、 B 、 C 、 D 、 E 。

(3) 生成训练、测试样本。将 A — E 集合中的样本各自按比例随机分为训练样本 A_1 、 B_1 、 C_1 、 D_1 、 E_1 和测试样本 A_2 、 B_2 、 C_2 、 D_2 、 E_2 , 设置每类样本对应类型编码为 T_A 、 T_B 、 T_C 、 T_D 、 T_E 。

(4) 训练过程。 $\{A_1, A_2, A_3, A_4, A_5\}$ 作为 CNN 的输入, 对应编码作为输出。反复调整网络参数, 使网络获得最优参数, 以建立输入输出之间的映射关系。

(5) 测试过程。训练好的 CNN 具有分类能力, 利用测试样本 $\{A_2, B_2, C_2, D_2, E_2\}$ 和对应编码可测试训练好的 CNN 的准确性。

利用训练测试完成的 CNN 可进行过电流信号识别。提取过电流信号的特征, 构成特征向量作为 CNN 的输入, CNN 进行前向传导输出类型编码, 即过电流信号类别。

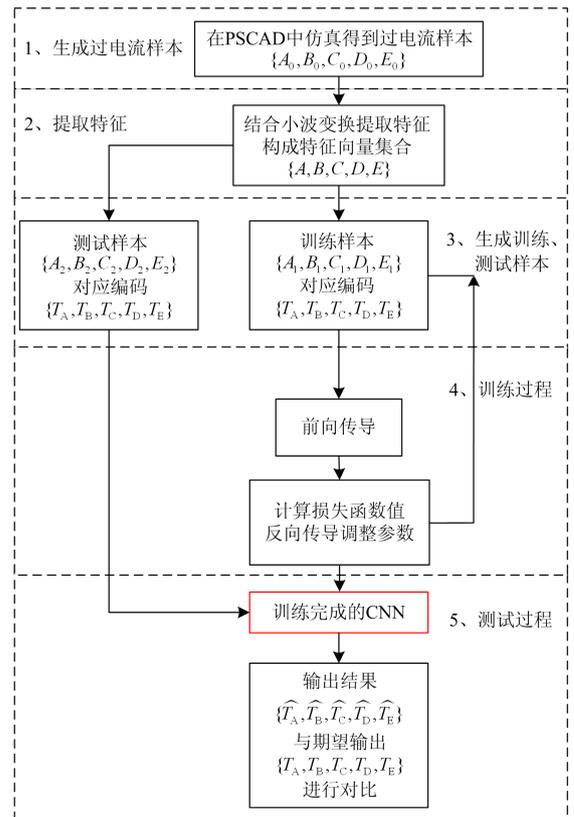


图 2 算法流程图

Fig. 2 Flow chart of the method presented in this paper

5 仿真结果分析

5.1 数据获取

为验证本文所提方法, 在 PSCAD/EMTDC 中搭建电缆早期故障的仿真模型, 如图 3 所示。

该模型为 25 kV 无支路电缆故障线路模型, 中性点直接接地。电缆早期故障采用第 1 节所述电弧模型进行模拟, 其中参数可取经验值^[13]: τ 为

0.2~0.4 ms, u_0 为 300~4 000 V, r_0 为 0.01~0.015 Ω 。仿真时通过控制电弧模型接入的时间实现电缆早期故障持续时间特征的模拟。

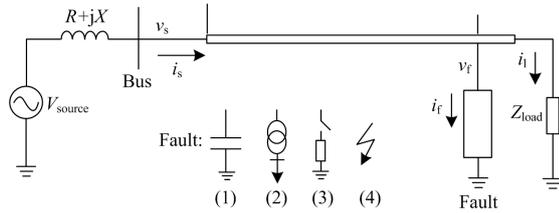


图 3 电缆早期故障仿真电路模型

Fig. 3 Simulation model of cable incipient fault

考虑了变压器励磁涌流、恒定阻抗故障、电容器投切等过电流扰动, 变压器容量为 2 MVA, 变比为 25 kV/0.4 kV, 恒定阻抗故障接地电阻在 1.5~5 Ω 之间均匀变化, 电容器额定容量为 1 Mvar。

馈线采用 π 型等值模型, 长度为 20 km, 在馈线上每隔 2 km 的位置进行一次仿真。每次仿真时采用 Multiple Run 元件在可变范围内按规定步长选择电弧模型参数, 详见表 1。以 10 kHz 的采样频率在馈线母线上采集电流信号作为样本数据, 如图 4 所示。

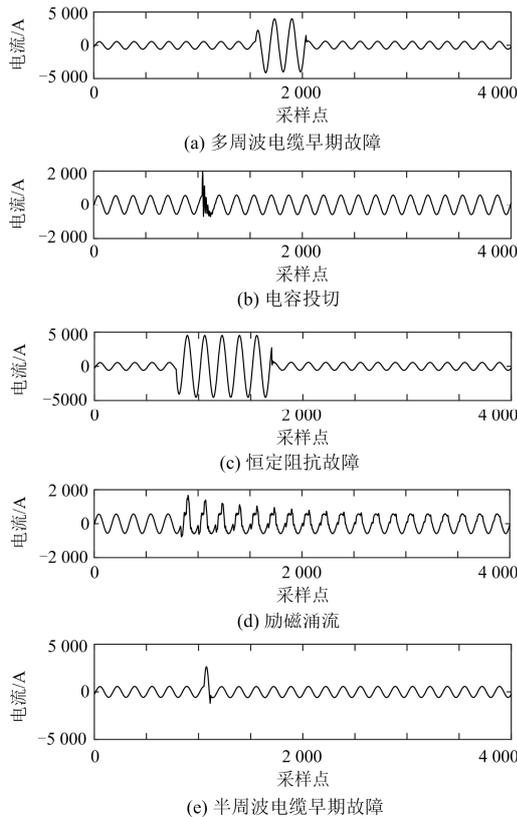


图 4 线电流波形图

Fig. 4 Line current waveform

对仿真得到的每一个样本, 利用小波变换提取 30 个特征构成一组特征向量。对每种过电流信号样本进行随机划分, 训练样本和测试样本比例大致为 2:1, 样本分布如表 2 所示。对应每种过电流类型设置标签, 如表 3 所示。

表 1 电弧模型仿真参数

| Table 1 Simulation parameters of arc model | | | |
|--|------|-------|-------|
| 变量 | 最小值 | 最大值 | 变化步长 |
| τ | 0.2 | 0.4 | 0.1 |
| U_0 | 300 | 4 000 | 200 |
| r_0 | 0.01 | 0.015 | 0.004 |

表 2 仿真样本分布情况

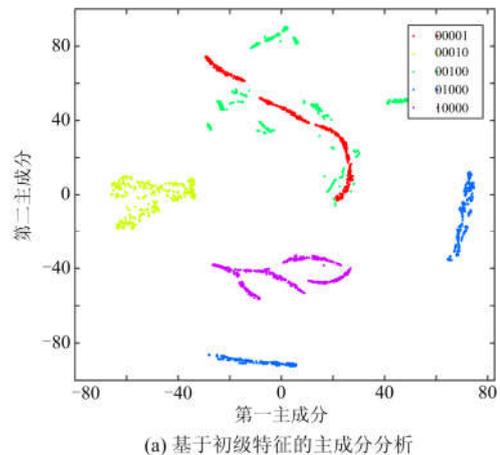
| Table 2 Distribution of samples obtained by simulation | | | |
|--|-------|-------|-------|
| 类型 | 样本数量 | 训练数量 | 测试数量 |
| 多周波早期故障 | 3 600 | 2 400 | 1 200 |
| 半周波早期故障 | 3 600 | 2 400 | 1 200 |
| 电容投切 | 2 920 | 2 000 | 920 |
| 恒定阻抗故障 | 3 200 | 2 000 | 1 200 |
| 激磁涌流 | 3 600 | 2 400 | 1 200 |

表 3 故障类型编码

| Table 3 Fault type coding | |
|---------------------------|-----------|
| 故障类型 | 编码 |
| 多周波早期故障 | 1 0 0 0 0 |
| 电容投切 | 0 1 0 0 0 |
| 恒定阻抗故障 | 0 0 1 0 0 |
| 激磁涌流 | 0 0 0 1 0 |
| 半周波早期故障 | 0 0 0 0 1 |

5.2 模型评价指标

结合小波变换提取样本数据的初级特征, CNN 结构中的卷积层和采样层挖掘初级特征中的隐藏特征。利用初级特征和挖掘后的特征对样本进行聚类, 样本聚类情况如图 5 所示。



(a) 基于初级特征的主成分分析

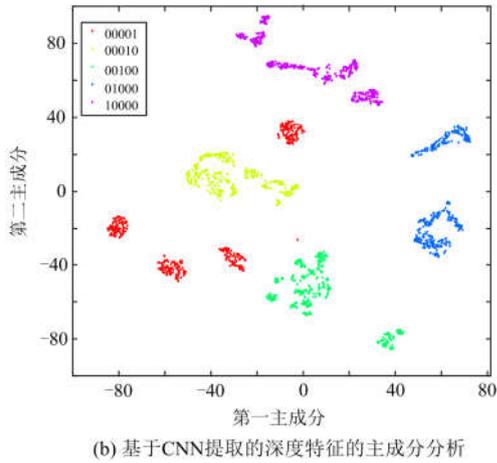


图5 主成分分析

Fig. 5 Principal component analysis

可见, 基于初级特征的聚类分析, 多周波早期故障与电容投切过电流的特征产生混淆。进行卷积采样操作, 提取隐藏特征, 各类过电流特征之间分类明确。

为评估文中所提方法的性能, 基于混淆矩阵采用准确率(accuracy)、精确率(precision)、召回率(recall)和 F_1 值指标^[21], 混淆矩阵的每一列代表预测的类别, 每一行代表的是实际的类别。它可以表明多个分类类别之间的混淆程度。

准确率: 分类类别和实际类别一致的样本占总样本的比例。

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (22)$$

精确率: 分类为电缆早期故障的样本中, 实际类别为电缆早期故障的样本所占的比例。

$$Precision = \frac{TP}{TP + FP} \quad (23)$$

召回率: 分类类别和实际类别均为电缆早期故障样本占有所有实际类别为电缆早期故障样本的比例。

$$Recall = \frac{TP}{TP + FN} \quad (24)$$

F_1 值指标: 表示精确率和召回率的调和均值。

$$F_1 = \frac{2TP}{2TP + FP + FN} \quad (25)$$

式中: TP 表示被分类为电缆早期故障且实际也是电缆早期故障的样本个数; FN 表示分类为其他过电流扰动但实际为电缆早期故障的样本个数; TN 表示分类为其他过电流扰动信号且实际也为其他过电流扰动信号的样本个数; FP 表示分类为其他过电流扰动信号但实际为电缆早期故障的样本个数; F_1 表示准确率和召回率的调和均值。

本文搭建的 CNN 由两层卷积采样层和一层全连接隐藏层组成, 第一层有 32 个大小为 1×5 的卷积核, 第二层有 64 个大小为 1×6 的卷积核, 隐藏层节点为 500。训练时关键参数设置为: $lr^{(0)} = 0.005$, $dr = 0.99$ 。

基于 CNN 的电缆早期故障分类识别的混淆矩阵如图 6 所示。测试样本中 1 200 个多周波早期故障样本被分类为多周波早期故障的有 1 175 个, 25 个被误分类为恒定阻抗投切, 1 200 个半周波早期故障均被正确分类为半周波早期故障。其中, 电容投切样本分类效果较差, 920 个样本中 92 个被误分类为半周波早期故障样本。可计算评价指标如表 4 所示。

| | | | | | |
|---------|---------|--------|---------|---------|---------|
| 多周波早期故障 | 1175.00 | 0.00 | 25.00 | 0.00 | 0.00 |
| 电容投切 | 0.00 | 828.00 | 0.00 | 0.00 | 92.00 |
| 恒定阻抗投切 | 0.00 | 0.00 | 1198.00 | 0.00 | 2.00 |
| 激磁涌流 | 0.00 | 0.00 | 0.00 | 1200.00 | 0.00 |
| 半周波早期故障 | 0.00 | 0.00 | 0.00 | 0.00 | 1200.00 |
| | 10000 | 01000 | 00100 | 00010 | 00001 |

图6 用 CNN 分类的混淆矩阵

Fig. 6 Confusion matrix based on CNN classification

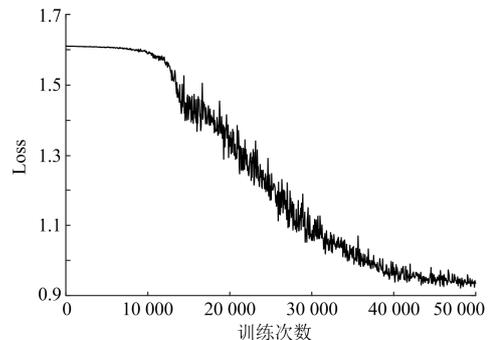
表4 CNN 分类指标

Table 4 Index of CNN classification

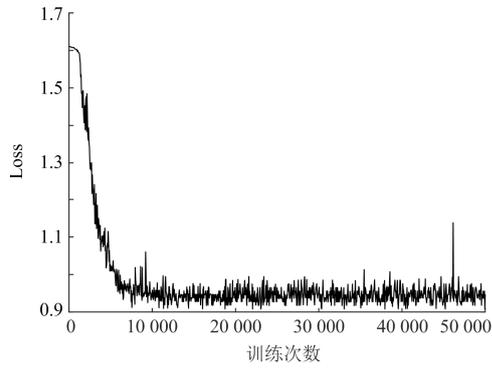
| Accuracy | Precision | Recall | F1 |
|----------|-----------|--------|-------|
| 97.9% | 96.2% | 98.9% | 97.5% |

5.3 模型优化效果

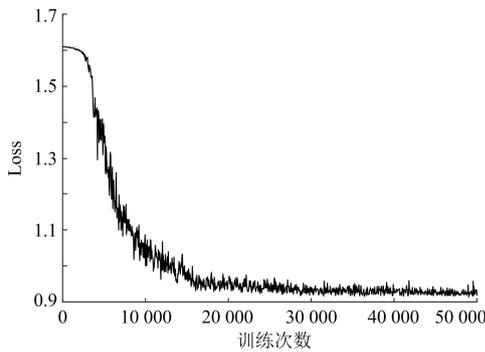
本文中, 为了提高训练速度采用自适应的学习率, 为了防止过拟合采用 L2 正则化的方法修正损失函数。将学习率分别固定为 0.001 和 0.01 对 CNN 进行训练, 将训练过程中损失函数值绘制成曲线如图 7 所示。



(a) 学习率为0.001的损失函数值收敛曲线



(b) 学习率为0.01的损失函数值收敛曲线



(c) 自适应学习率的损失函数值收敛曲线

图 7 不同学习率对应的损失函数值收敛曲线

Fig. 7 Error convergence curves corresponding to different learning rates

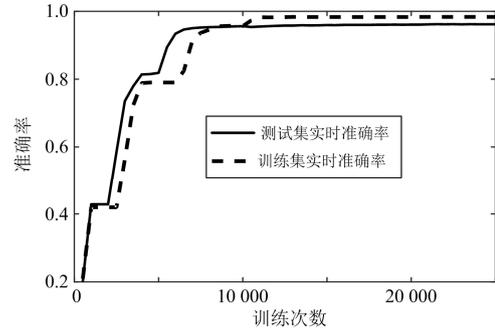
如图 7 所示，当学习率过小时误差收敛速度较慢，而学习率过大时误差将会产生振荡即对应的神经网络权值在最优解附近振荡。本文采用的自适应学习率的方法，既能保证较快的收敛速度，又能保证较好的收敛效果。

其次，为了防止过拟合，本文中对损失函数进行修正。引入 L2 范数使权重在训练过程中得到抑制，其中惩罚因子设置为 $\lambda = 0.0001$ 。对比修正前后训练过程中训练集、测试集的准确率实时变化曲线如图 8 所示。可见，在修正前训练集准确率明显高于测试集准确率，加入惩罚项后，测试集准确率得到提高，与训练集准确率相差无几。

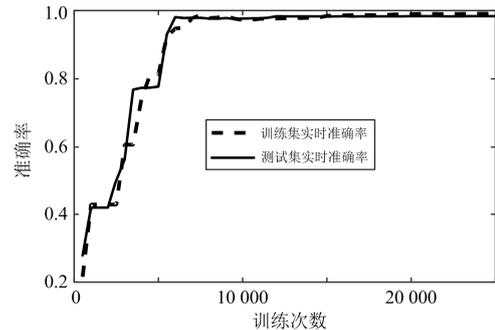
本文采用的自适应学习率和正则化很好地解决了过拟合和训练速度的问题，也证明了该方法的可行性。

5.4 与其他分类器比较

在相同样本的情况下，将本文所采用的方法与 K 近邻算法(K-Nearest Neighbor Algorithm, KNN)^[20]、集成学习算法(Ensemble Learning Algorithm, EL)^[21]和随机决策森林(Random Decision Forests, RF)^[22]作为分类器进行比较。各分类器的混淆矩阵如图 9 所示。



(a) 未修正损失函数的准确率变化曲线



(b) 修正损失函数后的准确率变化曲线

图 8 准确率变化曲线

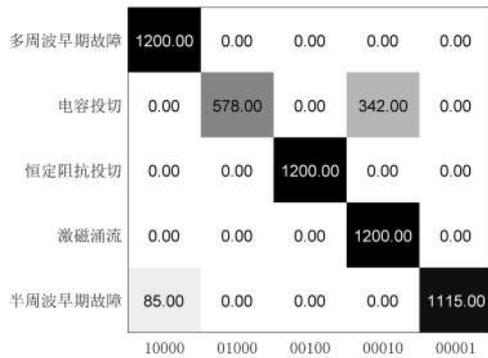
Fig. 8 Accuracy change curve

| | | | | | |
|---------|---------|--------|---------|---------|---------|
| 多周波早期故障 | 1200.00 | 0.00 | 0.00 | 0.00 | 0.00 |
| 电容投切 | 0.00 | 828.00 | 0.00 | 92.00 | 0.00 |
| 恒定阻抗投切 | 13.00 | 0.00 | 1187.00 | 0.00 | 0.00 |
| 激磁涌流 | 0.00 | 0.00 | 0.00 | 1200.00 | 0.00 |
| 半周波早期故障 | 137.00 | 0.00 | 0.00 | 0.00 | 1063.00 |
| | 10000 | 01000 | 00100 | 00010 | 00001 |

(a) EL 分类结果的混淆矩阵

| | | | | | |
|---------|--------|--------|---------|---------|---------|
| 多周波早期故障 | 759.00 | 0.00 | 441.00 | 0.00 | 0.00 |
| 电容投切 | 92.00 | 405.00 | 0.00 | 423.00 | 0.00 |
| 恒定阻抗投切 | 0.00 | 0.00 | 1200.00 | 0.00 | 0.00 |
| 激磁涌流 | 0.00 | 0.00 | 0.00 | 1200.00 | 0.00 |
| 半周波早期故障 | 0.00 | 0.00 | 0.00 | 0.00 | 1200.00 |
| | 10000 | 01000 | 00100 | 00010 | 00001 |

(b) KNN 分类结果的混淆矩阵



(c) RF 分类结果的混淆矩阵

图 9 分类结果混淆矩阵

Fig. 9 Confusion matrix of classification results

基于得到的混淆矩阵, 可以计算各分类器的指标, 如表 5 所示。

表 5 不同分类器的比较结果

Table 5 Comparison results of different classifiers

| 分类器 | Accuracy | Precision | Recall | F1 |
|-----|----------|-----------|--------|-------|
| CNN | 97.9% | 96.2% | 98.9% | 97.5% |
| EL | 95.7% | 95.5% | 94.3% | 94.9% |
| KNN | 82.4% | 77.2% | 83.1% | 80.4% |
| RF | 92.5% | 87.1% | 96.4% | 91.5% |

通过表 5、图 9 可以看出, 基于提取的特征分类识别电缆早期故障和过电流扰动, CNN 的准确率、精准率、召回率和 F1 指标均优于其他模式识别的方法, KNN 分类指标最差, 准确率仅为 82.4%, 分类指标总体上最接近 CNN 的 EL 分类器在 Recall 指标上稍显不足。其中, EL 将 92 个电容投切样本分类为激磁涌流样本, 将 137 个半周波早期故障样本分类为多周波早期故障样本; KNN 和 RF 将近一半的电容投切样本分类为激磁涌流样本, 基本不具备对电容投切过电流的分类识别能力。以上结果表明文中所提方法具有更好的电缆早期故障分类识别能力。

5.5 模型参数的影响

考虑 CNN 的特征图个数对模型性能的影响, 理论上 CNN 的特征图个数和对特征的刻画程度呈正相关性。但随着个数增加, 网络复杂程度增加, 训练时间也会增长, 而且过分地刻画训练样本容易造成模型过拟合, 从而降低测试样本时的准确率。考虑卷积核个数为 [24, 48]、[28, 56] 和 [48, 96], 指标参数如表 6 所示。

根据检测结果, 卷积核个数设置为 [32, 64], 相较于卷积核设置为 [24, 48] 和 [28, 56] 具有更高的准确率。但随着 CNN 学习得更加深刻, 过拟合现象就不能被修正的损失函数完全抑制。如卷积核个数

设置为 [48, 96] 时比卷积核个数设置为 [32, 64] 时具有更低的分类准确率。

表 6 不同卷积核个数对应的指标

Table 6 Indicators corresponding to the number of different convolution kernels

| 卷积核个数 | Accuracy | Precision | Recall | F1 |
|---------|----------|-----------|--------|-------|
| [24,48] | 79.0% | 66.6% | 100% | 80.0% |
| [28,56] | 96.6% | 100% | 92.5% | 96.1% |
| [32,64] | 97.9% | 96.2% | 98.9% | 97.5% |
| [48,96] | 96.6% | 100% | 92.6% | 96.1% |

6 结论

本文提出一种基于小波变换结合 CNN 的电缆早期故障分类识别的方法, 利用 PSCAD/EMTDC 仿真得到电缆早期故障过电流及其他三种过电流的样本, 对所提方法进行验证。证明所提方法可用于识别电缆早期故障, 并得出以下结论:

1) 文中所提方法用于识别电缆早期故障, 准确率可达 97.9%, 相较其他方法, 分类能力更加突出, 对不同类型的故障, 分类识别更加准确, 克服了传统分类器易产生混淆、分类准确率不高的缺点。

2) 通过对 CNN 的损失函数进行修正, 添加惩罚项, 抑制权重的变化; 训练过程中采用自适应的学习率可以有效地改善 CNN 的训练速度和防止过拟合现象的发生。

3) CNN 自身参数的设置对其分类性能有重要影响, 使用 CNN 进行分类识别时应该根据使用条件合理调整网络参数, 以达到最优的分类性能。

本文研究证明了 CNN 在电缆早期故障分类识别中得到应用的可能性。为了使所提方法在实际中得到运用, 还需使用大量实测波形数据进行分析验证。

参考文献

- [1] 戴铭. 10 kV 地下电缆早期故障检测与识别方法探讨 [D]. 成都: 西南交通大学, 2012.
DAI Ming. Discussion methods of incipient fault detection and identification in 10 kV underground cables[D]. Chengdu: Southwest Jiaotong University, 2012.
- [2] SIDHU T S, XU Z. Detection of incipient faults in distribution underground cables[J]. IEEE Transactions on Power Delivery, 2010, 25(3): 1363-1371.
- [3] KULKARNI S, SANTOSO S, SHORT T A. Incipient fault location algorithm for underground cables[J]. IEEE Transactions on Smart Grid, 2014, 5(3): 1165-1174.
- [4] 姚海燕, 张静, 留毅, 等. 基于多尺度小波判据和时频特征关联的电缆早期故障检测和识别方法[J]. 电力系统保护与控制, 2015, 43(9): 115-123.

- YAO Haiyan, ZHANG Jing, LIU Yi, et al. A method of Incipient cable fault detection and identification based on multi-scale wavelet criterion and time-frequency feature correlation[J]. Power System Protection and Control, 2015, 43(9): 115-123.
- [5] DJURIC M B, TERZIJA V V. A new approach to the arcing faults detection for fast autoreclosure in transmission systems[J]. IEEE Transactions on Power Delivery, 1995, 10(4): 1793-1798.
- [6] ZHANG Wenhai, XIAO Xianyong, ZHOU Kai, et al. Multi-cycle incipient fault detection and location for medium voltage underground cable[J]. IEEE Transactions on Power Delivery, 2017, 32(3): 1450-1459.
- [7] ZHANG Chao, KANG Xiaoning, MA Xiuda, et al. On-line incipient faults detection in underground cables based on single-end sheath currents[C] // IEEE PES-Pacific Power and Energy Engineering Conference, October 25-28, 2016, Xi'an, China: 795-799.
- [8] 汪颖, 卢宏, 杨晓梅, 等. 堆叠自动编码器与 S 变换相结合的电缆早期故障识别方法[J]. 电力自动化设备, 2018, 38(8): 124-131.
- WANG Ying, LU Hong, YANG Xiaomei, et al. Cable incipient fault identification based on stacked autoencoder and S-transform[J]. Electric Power Automation Equipment, 2018, 38(8): 124-131.
- [9] 任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域中的研究现状与挑战[J]. 控制与决策, 2017, 32(8): 1345-1358.
- REN Hao, QU Jianfeng, CHAI Yi, et al. Deep learning for fault diagnosis: the state of the art and challenge[J]. Control and Decision, 2017, 32(8): 1345-1358.
- [10] 林木松, 郭坤, 张晟, 等. 电缆绝缘聚合物材料的老化成因机理及其研究现状[J]. 高分子材料科学与工程, 2017, 33(12): 149-155.
- LIN Musong, GUO Kun, ZHANG Sheng, et al. Progress in flexible conductive stress-strain materials[J]. Polymer Materials Science & Engineering, 2017, 33(12): 149-155.
- [11] MA Z, HUANG X, JIANG P, et al. Effect of silane-grafting on water-tree resistance of XLPE cable insulation[J]. Journal of Applied Polymer Science, 2010, 115(6): 3168-3176.
- [12] LITOVSKI V, BLOND S L, ROSS B P, et al. Transient circuit implementation of arc models with particular focus on arcs in low-voltage power cables[J]. Electric Power Systems Research, 2017, 147: 105-114.
- [13] KIZILCAY M, PNIOK T. Digital simulation of fault arcs in power systems[J]. European Transactions on Electrical Power, 2007, 1(1): 55-60.
- [14] 许晔, 郭谋发, 陈彬, 等. 配电网单相接地电弧建模及仿真分析研究[J]. 电力系统保护与控制, 2015, 43(7): 57-64.
- XU Ye, GUO Moufa, CHEN Bin, et al. Modeling and simulation analysis of arc in distribution network[J]. Power System Protection and Control, 2015, 43(7): 57-64.
- [15] 覃剑, 彭莉萍, 王和春. 基于小波变换技术的输电线路单端行波故障测距[J]. 电力系统自动化, 2005, 29(19): 62-65.
- QIN Jian, PENG Liping, WANG Hechun. An improved scheme for DCS communication interface[J]. Electric Power Automation Equipment, 2005, 29(19): 62-65.
- [16] 杨帆, 王干军, 彭小圣, 等. 基于卷积神经网络的高压电缆局部放电模式识别[J]. 电力自动化设备, 2018, 38(5): 123-128.
- YANG Fan, WANG Ganjun, PENG Xiaosheng, et al. Partial discharge pattern recognition of high-voltage cables based on convolution neural network[J]. Electric Power Automation Equipment, 2018, 38(5): 123-128.
- [17] 邵宝珠, 李胜辉, 白雪, 等. 非负约束自动编码器在电缆早期故障识别中的应用[J]. 电力系统保护与控制, 2019, 47(2): 22-29.
- SHAO Baozhu, LI Shenghui, BAI Xue, et al. Application of nonnegative constraint autoencoder in cable incipient fault identification[J]. Power System Protection and Control, 2019, 47(2): 22-29.
- [18] 陈伟, 何家欢, 裴喜平. 基于相空间重构和卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2018, 46(14): 93-99.
- CHEN Wei, HE Jiahuan, PEI Xiping. Classification for power quality disturbance based on phase-space reconstruction and convolution neural network[J]. Power System Protection and Control, 2018, 46(14): 87-93.
- [19] PIAO M, SHON H S, LEE J Y, et al. Subspace projection method based clustering analysis in load profilin[J]. IEEE Transaction on Power Systems, 2014, 29(6): 2628-2635.
- [20] COVER T M, HART P E. Nearest neighbor pattern classification[J]. IEEE Transactions on Information Theory, 1967, 13(1): 21-27.
- [21] DASARATHY B V, SHEELA B V. A composite classifier system design: concepts and methodology[J]. Proceeding of the IEEE, 1979, 67(5): 708-713.
- [22] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5-32.

收稿日期: 2019-05-22; 修回日期: 2019-08-22

作者简介:

汪颖(1981—), 女, 博士, 副教授, 研究生导师, 主要研究方向为电能质量与优质供电; E-mail: 20312028@qq.com

孙建风(1996—), 男, 硕士研究生, 主要研究方向为配电网故障的识别与定位。E-mail: 1342606556@qq.com

(编辑 魏小丽)