

DOI: 10.7667/PSPC201860

非负约束自动编码器在电缆早期故障识别中的应用

邵宝珠¹, 李胜辉¹, 白雪¹, 黄旭龙², 杨晓梅²

(1. 国网辽宁省电力有限公司电力科学研究院, 辽宁 沈阳 110006; 2. 四川大学电气信息学院, 四川 成都 610065)

摘要: 电缆早期故障的准确识别有助于降低电力系统的故障停电率和提高供电可靠性。在传统模式识别方法中, 利于分类识别的有效特征通常难以选择, 从而影响识别的准确度。鉴于此, 将非负约束自动编码器(Non-negative Constrain Autoencoder, NCAE)堆叠形成的深度学习(Deep learning, DL)网络应用于电缆早期故障识别中。为了提高DL网络的学习效率, 首先对故障相电流进行平稳小波变换, 提取出一些具有相关性、冗余性的统计量、能量熵和信息熵等作为初级特征, 其次堆叠多个NCAE构建出DL网络, 通过预训练和微调机制, 从初级特征中获得更易于早期故障分类识别的有效特征, 最后利用Softmax分类器从正常状态和其他扰动信号中识别出早期故障。利用电缆电流仿真数据进行实验, 结果表明与传统模式识别方法相比, 所提方法识别准确率更高。

关键词: 电缆早期故障识别; SWT变换; 非负约束自动编码器; 深度学习网络

Application of nonnegative constraint autoencoder in cable incipient fault identification

SHAO Baozhu¹, LI Shenghui¹, BAI Xue¹, HUANG Xulong², YANG Xiaomei²

(1. Electric Power Research Institute of State Grid Liaoning Electric Power Co., Ltd, Shenyang 110006, China;

2. College of Electrical Engineering and Information, Sichuan University, Chengdu 610065, China)

Abstract: Accurate identification of cable incipient fault is helpful to reduce the failure rate of power system and improve the reliability of power supply. In the traditional pattern recognition method, it is difficult to select the efficient features, which are beneficial to classification, therefore, it would affect the accuracy of recognition. In view of this, this paper applies the Deep Learning (DL) network stacked from multiple non-negative constraint autoencoders to recognize cable incipient fault. In order to improve the learning efficiency of DL network, firstly, stationary wavelet transform of the fault phase current is used to extract the primary characteristics with correlation and redundancy, e. g. some statistics, energy entropy and information entropy. And then DL network is constructed by stacking multiple nonnegative constraint autoencoders. After preliminary training and fine-tuning training process, some effective features for recognition are learned from primary features. Finally, Softmax classifier is used to identify the cable incipient fault from normal state and other disturbances. Experiments on cable current simulation data are done, and the results show that the method is more accurate than the traditional pattern recognition method.

This work is supported by Science and Technology Project of State Grid Liaoning Electric Power Company (No. 5602/2018-28001B).

Key words: cable incipient fault identification; SWT transform; nonnegative constraint autoencoder; deep learning network

0 引言

若能在电缆发生早期故障时进行准确的检测识别, 将有效降低电力系统的故障停电率和提高供电

可靠性。电缆早期故障多发生在电压峰值时刻, 呈现过电流现象; 按照持续时间可分为半周波(1/4~1/2个周波)和多周波(1~4个周波)两种类型的早期故障, 且多为单相接地故障, 通常不会引起电力系统保护装置动作^[1-3]。此外, 电容投切、恒定阻抗故障和变压器激磁涌流发生时, 也表现为与电缆早期故障相类似的过电流现象, 因此, 有必要对电缆早期故障

基金项目: 国网辽宁省公司科技项目(5602/2018-28001B)
“电能质量监测数据分析与主动应用关键技术研究”

信号和这些过电流扰动信号进行准确的识别^[1-5]。

目前对电缆早期故障的识别主要有两大类:

(1) 电路分析方法。基于电缆早期故障和电缆结构的特点, 搭建对应的电路分析模型。文献[4]将电弧电压引入到对电缆早期故障的检测中, 基于早期故障为电弧故障的假设, 利用电弧电压畸变的特点, 通过计算故障电压的总谐波畸变率来判断电缆早期故障。文献[5]利用高压电缆具有金属护套的特点, 假设电缆护套为单端接合, 通过单端护套电流的总和来检测早期故障。(2) 信号分析与模式识别方法。文献[6]利用傅里叶变换和小波变换对电容投切信号和电缆早期故障信号进行谐波分析, 选取对应的特征向量, 再利用支持向量机(Support Vector Machine, SVM)和人工神经网络实现电容投切和电缆早期故障信号的分类识别。文献[7]利用小波变换对电流信号进行分解, 利用统计特征量, 采用阈值方法对电缆早期故障进行识别。但固定阈值法难以适应电流的变化, 导致误检测率较高。文献[8]结合小波变换与灰色关联分析方法, 通过计算灰色关联度来识别电缆早期故障。文献[9]利用卡尔曼滤波, 首先基于故障电流计算的基频零序电流分量来检测电缆早期故障, 再通过计算的方差信号来进一步确定是否为电缆早期故障。

近年来, 深度学习方法与传统模式识别方法相比, 通过深层次的网络结构和训练学习机制的改进, 能有效地挖掘出蕴含于数据中更深层次、有利于分类识别的特征, 已开始应用于一些电力设备和机械设备的故障识别中, 并取得了较好的效果。文献[10-11]分别利用多层感知机和深度置信网络实现变压器的故障诊断; 文献[12]利用去噪自编码器实现了机械装备的健康诊断。此外, 深度学习也应用于充电站容量规划^[13]和电能质量的扰动分类^[14]; 而在电缆早期故障识别方面的应用则处于初级起步阶段。

本文在对电缆早期故障及其他过电流扰动信号的研究^[5]基础上, 将非负约束自动编码器^[15-16](Nonnegativity Constraint Autoencoder, NCAE)构建的深度学习(Deep Learning, DL)网络应用于电缆的早期故障识别中。为改善 DL 网络的训练效率, 首先利用平稳小波变换^[17](Stationary Wavelet Transform, SWT)对电流信号进行正交分解, 得到电流信号在 SWT 各分解尺度上的低频信号成份和高频信号成份, 并从中提取出一些具有相关性、冗余性的初级特征, 作为深度学习网络的输入; 利用 NCAE 构建的 DL 网络提取出更深层次、有利于早期故障识别的特征, 最后利用 Softmax 分类器将电缆早期故障时的过电流信号从正常电流信号和过电流扰动信号

中识别出来。本文方法与传统的模式识别方法: K 近邻^[18](K-Nearest Neighbour, KNN)、SVM^[19]和随机森林^[20](Random Forest, RF)相比较, 结果表明, 文中所提出的方法具有更高的识别准确率。

1 基于平稳小波变换的初级特征提取

为改善 SAE 网络的训练效率, 本文对各类电流信号波形进行平稳小波变换(Stationary Wavelet Transform, SWT)分解, 利用分解得到的各细节高频分量和低频近似分量提取出用于电缆早期故障识别的初始特征量, 作为 SAE 的输入信号。

SWT 变换作为传统小波变换的一种修改, 同样具备有效分析非平稳信号的能力^[21-22]。不同于通常的正交小波变换, SWT 变换对低通和高通滤波器的输出系数不再进行下采样处理, 使得到的近似分量系数和细节分量系数与原信号长度相等, 具有平移不变性, 从而有效地避免了因采样所带来的时移信息丢失。电缆早期故障电流信号和其他过电流扰动信号均属于非平稳信号, 因而采用 SWT 变换对上述信号进行分析。

对于原始信号序列 f_k , 令 $a_0 = f_k$, 采用 SWT 变换可将信号分解为式(1)和式(2)。

$$\text{近似分量系数 } a_{j+1} = H_j * a_j \quad (1)$$

$$\text{细节分量系数 } d_{j+1} = G_j * a_j \quad (2)$$

式中: H_j 和 G_j 分别为第 j 层的低通滤波器和高通滤波器; “*” 代表卷积运算。其分解变换示意图如图 1 所示。

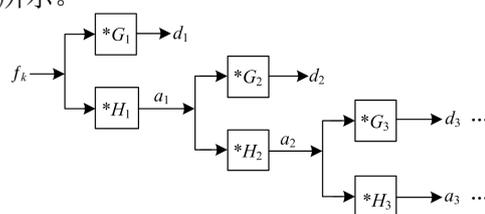


图 1 SWT 变换分解图

Fig. 1 Decomposition of stationary wavelet transform

对于采样频率为 10 kHz 的信号 f_k , 经 3 层 SWT 分解后, 可得到 3 个细节分量 d_1, d_2, d_3 和一个近似分量 a_3 , 其相应的频率范围为 2.50~5.00 kHz、1.25~2.50 kHz、0.75~1.25 kHz 和 0~0.75 kHz, 因而细节分量和近似分量也成为高频分量和低频分量。图 2 显示了利用 dB4 小波基, 对正常电流波形、电缆早期故障时的多周波过电流信号和恒定阻抗故障的干扰过电流信号作为示例, 进行 3 层 SWT 分解后的结果。从图 2 中可以看出, 3 种电流信号的低频近似分量和高频细节分量中蕴含着不同的特征。

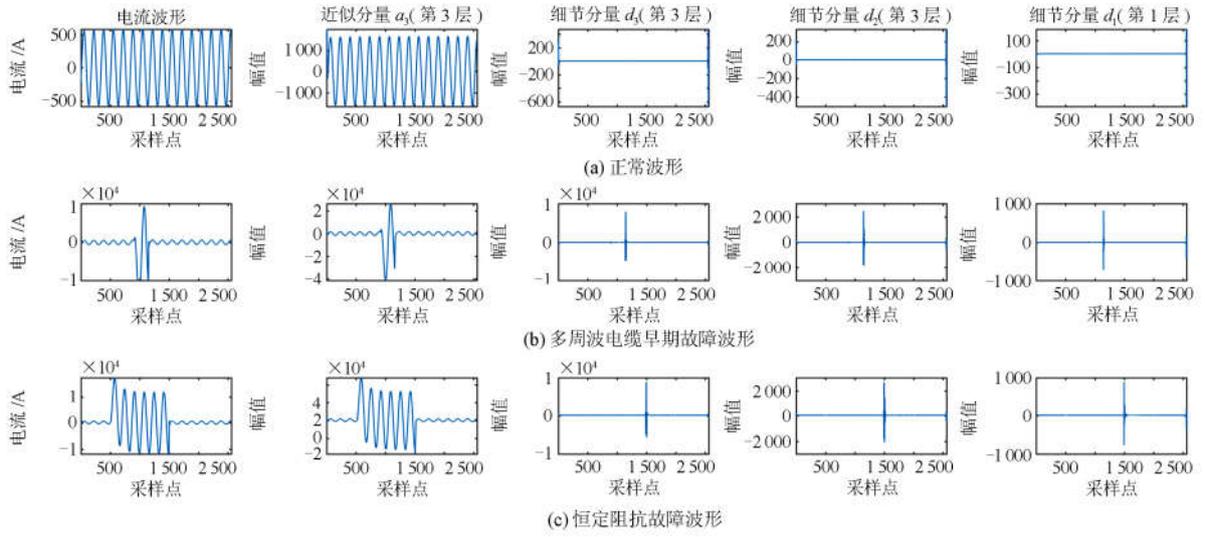


图 2 3 种电流波形经 3 层 SWT 分解的结果

Fig. 2 Results of three-level SWT decomposition for three current waveforms

对于 SWT 分解后的第 j 层小波系数 $s_j = [s_{1,j}, s_{2,j}, \dots, s_{N,j}]$ (即 a_j 或 d_j)，本文选取 5 个统计参数作为特征量：均值(μ)、标准差(σ)、能量(E)、能量熵(Ent)和奇异熵(SVE)，构造小波系数 s_j 的特征向量 F_j ，即

$$F_j = [\mu_j, \sigma_j, E_j, Ent_j, SVE_n_j] \quad (3)$$

式中：均值 μ_j 的计算如式(4)；标准差 σ_j 的计算如式(5)；能量 E_j 的计算如式(6)；能量熵 Ent_j 的计算如式(7)；奇异熵 SVE_n_j 的计算如式(8)。

$$\mu_j = \frac{1}{N} \sum_{i=1}^N s_{i,j} \quad (4)$$

$$\sigma_j = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_{i,j} - \mu_j)^2} \quad (5)$$

$$E_j = \sum_{i=1}^N s_{i,j}^2 \quad (6)$$

$$Ent_j = -\sum_{i=1}^N \frac{s_{i,j}^2}{E_j} \log_2 \left(\frac{s_{i,j}^2}{E_j} \right) \quad (7)$$

$$SVE_n_j = -\sum_{i=1}^{\sqrt{N}} \frac{\delta_{i,j}}{\sum_{i=1}^{\sqrt{N}} \delta_{i,j}} \log_2 \left(\frac{\delta_{i,j}}{\sum_{i=1}^{\sqrt{N}} \delta_{i,j}} \right) \quad (8)$$

式(8)中， $\delta_{i,j} (i=1, 2, \dots, \sqrt{N})$ 表示将小波系数向量 $s_j \in \mathbb{R}^{1 \times N}$ 转换为矩阵 $S_j \in \mathbb{R}^{\sqrt{N} \times \sqrt{N}}$ 后，通过奇异值分解得到的奇异值。

本文采用 dB4 小波对正常电流、电缆早期故障和其他过电流扰动信号进行 8 层的 SWT 小波分解，并对分解得到的 8 个细节分量(d_1, d_2, \dots, d_8)和 1 个近似分量 a_8 计算相应的特征向量 $F_j (j=1, 2, \dots, 9)$ ，进一步可得到 45 个特征值组成的特征集 X ，可表达为

$$X = [F_1, F_2, \dots, F_9] \quad (9)$$

2 堆叠非负约束自编码器实现电缆早期故障的识别

电缆早期故障的识别，本质上就是将早期故障引起的过电流信号与正常电流信号和其他过电流扰动信号相区别，属于 3 个模式的分类问题。若要获得较高的识别率，关键之一在于如何采用有效的特征向量。尽管利用 SWT 变换获得了 45 个特征量，但它们之间存在一定的冗余性，不利于分类的结果。为了从这些特征量中提取出更高层次的特征，以达到提高分类/识别的准确性的目的，采用堆叠的 NCAE 网络加以训练和识别电缆的早期故障。

NCAE 作为 AE 的一种扩展，能有效提升传统 AE 的稀疏性和减少 AE 的重建误差。NCAE 的结构与传统 AE 的结构相似，不同之处在于样本学习训练时使用了不同的代价函数。

2.1 非负约束自编码器(NCAE)的结构

NCAE^[15-16]是一种基于神经网络的无监督特征学习算法，由编码器与解码器所组成，如图 3 所示。已知 $X = \{x_1, x_2, \dots, x_n\} \in \mathbb{R}^n$ (实验中 X 为 SWT 分解后得到的特征向量， $n = 45$)，通过线性变换和激活

函数 $\sigma(\cdot)$ (通常选择 Sigmoid 函数), 映射到隐含层得编码结果 $Y = \{y_1, y_2, \dots, y_m\} \in \mathbb{R}^m$, (m 为隐含层的神经元个数, 即结点), 有

$$Y = \sigma(W_1 X + b_1) = \frac{1}{1 + \exp[-(W_1 X + b_1)]} \quad (10)$$

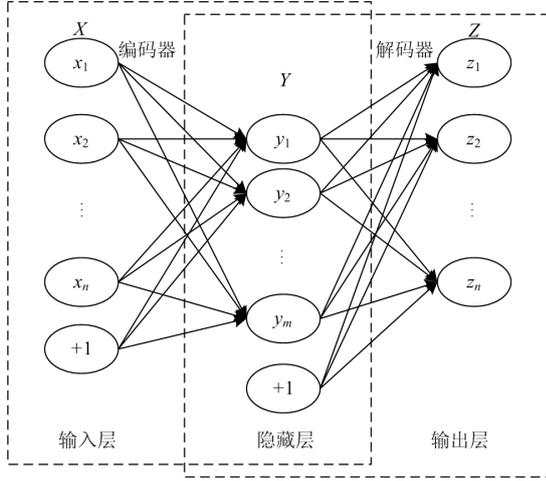


图 3 NCAE/AE 的结构图

Fig. 3 NCAE/AE structure

由此实现从输入的初级特征中获取更深层次的特征提取的目的。而解码器则是编码器的逆过程, 通过同样的过程将 Y 映射到重构层 $Z = \{z_1, z_2, \dots, z_n\} \in \mathbb{R}^n$, 有

$$Z = \sigma(W_2 Y + b_2) = \frac{1}{1 + \exp[-(W_2 Y + b_2)]} \quad (11)$$

式中: Z 为 X 的重构数据; $W_1 \in \mathbb{R}^{m \times n}$ 、 $W_2 \in \mathbb{R}^{n \times m}$; $b_1 \in \mathbb{R}^{m \times 1}$ 、 $b_2 \in \mathbb{R}^{n \times 1}$ 分别为输入层到隐含层、隐含层到重构层的权重及偏移系数。

2.2 NCAE 的训练

NCAE 网络的训练是通过调整 W_1 、 W_2 、 b_1 、 b_2 , 使得重构数据 Z 与输入数据 X 之间的误差达到最小。并希望在训练过程中, 大多数隐藏层的神经元处于抑制状态, 从而引入稀疏表示的限制条件, 由此构造代价函数, 即

$$L(W, b) = \frac{1}{K} \sum_{k=1}^K \|Z(k) - X(k)\|^2 + \mu \sum_{j=1}^m KL(\rho \| \rho_j) \quad (12)$$

式中: K 为样本数据个数; 等式右边的第一项表示 Z 与 X 之间的均方误差; 第二项为稀疏惩罚项, μ 为稀疏惩罚项权重稀疏。稀疏惩罚项中的 KL 代表 Kullback-Leibler(KL)散度, 可表示为

$$KL(\rho \| \rho_j) = \rho \log_2 \frac{\rho}{\rho_j} + (1 - \rho) \log_2 \frac{1 - \rho}{1 - \rho_j} \quad (13)$$

式中: ρ 为设定的一个接近于零的参数; ρ_j 为隐藏

层的平均激活量, 有

$$\hat{\rho}_j = \frac{1}{K} \sum_{k=1}^K y_j(x_k) \quad (14)$$

当 $\rho = \rho_j$ 的时候, $KL(\rho \| \rho_j) = 0$, 如果 $\rho \neq \rho_j$, 则 KL 散度会随两者差异的增大而增大。

在传统的自编码器中, 为了避免过拟合问题, 通常还在代价函数中引入对权重系数 (W_1 、 W_2) 的衰变约束项, 则传统自编码器的代价函数表示为

$$L_{SAE}(W, b) = L(W, b) + \frac{\lambda}{2} \sum_{l=1}^2 \sum_{i=1}^{S_l} \sum_{j=1}^{S_{l+1}} (\omega_{i,j}^{(l)})^2 \quad (15)$$

式中, λ 表示权重约束项的系数。研究表明, 将部分输入分解到自动编码器的每层中, 设定权重系数 (W_1 、 W_2) 为非负值, 将有助于提升自编码器的稀疏性, 并减少重构误差, 从而引入非负约束的自编码器, 其代价函数为

$$L_{NCAE}(W, b) = L(W, b) + \frac{\lambda}{2} \sum_{l=1}^2 \sum_{i=1}^{S_l} \sum_{j=1}^{S_{l+1}} g(\omega_{i,j}^{(l)}) \quad (16)$$

式中

$$g(\omega_{i,j}) = \begin{cases} \omega_{i,j}^2 & \omega_{i,j} < 0 \\ 0 & \omega_{i,j} \geq 0 \end{cases}$$

NCAE 训练的目标就是使代价函数式(16)最小化, 从而减少每一层中非负权值的数量和整体的平均重建误差。训练 NCAE 时, 与传统的 AE 训练方法一样, 采用随机梯度下降法实现对参数 W 和 b 的更新, 即

$$W_{i,j}^{(l)} = W_{i,j}^{(l)} - \beta \frac{\partial}{\partial W_{i,j}^{(l)}} L_{NCAE}(W, b) \quad (17)$$

$$b_i^{(l)} = b_i^{(l)} - \beta \frac{\partial}{\partial b_i^{(l)}} L_{NCAE}(W, b) \quad (18)$$

式中, β 表示学习率, 它决定了参数更新的速度; 上标 l 表示网络层数; $W_{ij}^{(l)}$ 表示第 l 层的第 j 个单元与第 $l+1$ 层第 i 个单元之间的权重参数; $b_i^{(l)}$ 表示第 $(l+1)$ 层第 i 个单元的偏置项。式(17)中代价函数 $L_{NCAE}(W, b)$ 对权重参数 W 的偏导数可由式(19)计算得到。

$$\frac{\partial}{\partial W_{i,j}^{(l)}} L_{NCAE}(W, b) = \frac{\partial}{\partial W_{i,j}^{(l)}} L(W, b) + \lambda f(W_{i,j}^{(l)}) \quad (19)$$

式中:

$$f(\omega_{i,j}) = \begin{cases} \omega_{i,j} & \omega_{i,j} < 0 \\ 0 & \omega_{i,j} \geq 0 \end{cases}$$

由于式(16)中代价函数 $L_{NCAE}(W, b)$ 的第二项与偏置参数 b 无关, 因而 $L_{NCAE}(W, b)$ 对 b 的偏导数与

传统 AE 的求法一致, 有

$$\frac{\partial}{\partial b^{(l)}} L_{\text{NCAE}}(W, b) = \frac{\partial}{\partial b^{(l)}} L(W, b) \quad (20)$$

2.3 基于 NCAE 的深度学习网络

为了获得有利于电缆早期故障识别的有效特征, 本文利用多个 NCAE 堆叠形成一个深度学习 (Deep learning, DL) 网络, 它由一个输入层、多个隐藏层和一个输出层构成。DL 网络的输入来自于第一个 NCAE 的输入 X_1 , 并将 NCAE 训练完所获得的隐藏层输出 Y_1 用作第二个 NCAE 的输入, 且 Y_1 也为 DL 网络的第一个隐藏层。依据前一个 NCAE 的隐藏层输出作为 NCAE 输入的规则, 以此类推形成了一个多层的神经网络。最后一个 NCAE 的输出将作为 softmax 分类器的输入, 实现正常运行、电缆早期故障和过电流扰动这 3 种类别的识别。图 4 表示了一个由 3 个 NCAE 堆叠形成的 DL 网络。

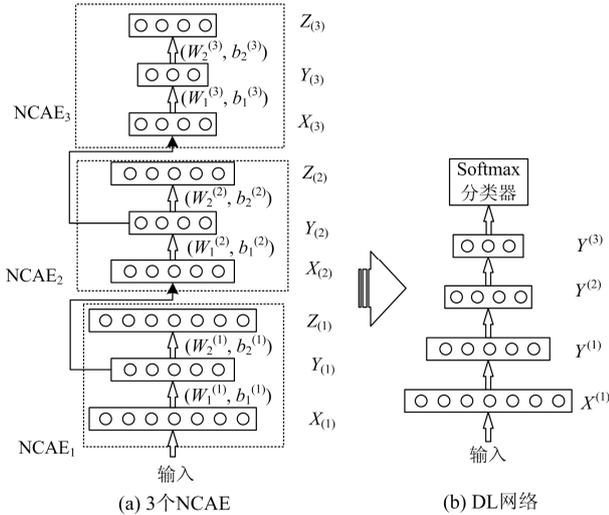


图 4 3 个 NCAE 堆叠形成的 DL 网络
Fig. 4 DL network by stacking three NCAEs

DL 网络的训练过程包括无监督的预训练和有监督的微调两个过程。无监督的预训练, 采用逐层贪婪学习方法, 利用无标记的数据逐次独立地训练各个 NCAE, 从而获得 DL 网络中各层网络的权重和偏置参数 $(W_1^{(l)}, b_1^{(l)})$ 的初始值; 在有监督的微调阶段, 利用预训练获得 $(W_1^{(l)}, b_1^{(l)})$ 的初始值和有标记的数据, 采用反向传播算法来实现参数的微调。

利用 DL 网络来实现电缆早期故障识别的算法流程如图 5 所示。基于 SWT 变换提取出初级的原始特征, 再利用 NCAE 堆叠形成的 DL 网络来从学习样本中获得更高级、更深层次的特征, 进而对测试样本进行分类识别, 已达到提高电缆早期故障识别性能的目的。

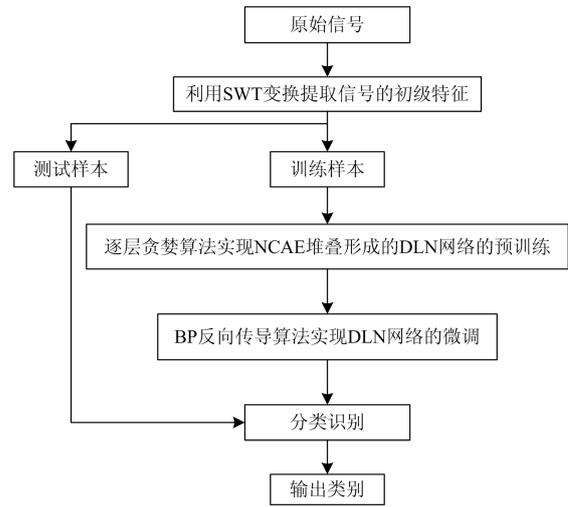


图 5 算法流程图
Fig. 5 Method flowchart

3 实验结果分析

3.1 实验数据的获取

根据电缆早期故障的故障形态, 在 PSCAD/EMTDC 中搭建电缆早期故障的仿真模型, 如图 6 所示。该模型为 25 kV 无支路电缆故障线路模型, 在模型中考虑了变压器激磁涌流、恒定负荷故障、电容器投切等过电流扰动, 并以 10 kHz 的采样频率采集馈线电流作为原始样本数据, 如图 7 所示。利用图 6 的仿真模型共采集了 3 240 个样本仿真数据, 即每一类别各 1 080 个样本数据, 其中半周波和多周期电缆早期故障数据各 540 个, 变压器激磁涌流、恒定负荷故障、电容器投切 3 种过电流扰动各 360 个样本。为了模拟实际数据采集中的随机不确定性, 各过电流现象出现在样本数据中的时刻点是随机的。此外, 对于多周波的过电流信号, 并非截取完整的多周波过电流信号进行 SWT 变换提取初级特征。DL 网络识别方法中, 从三类样本数据中随机选择 90% 的数据作为训练样本, 剩余的 10% 数据作为测试样本。

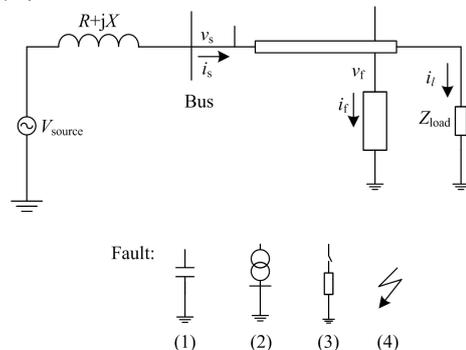


图 6 电缆早期故障仿真电路模型
Fig. 6 Simulation circuit model for cable incipient fault

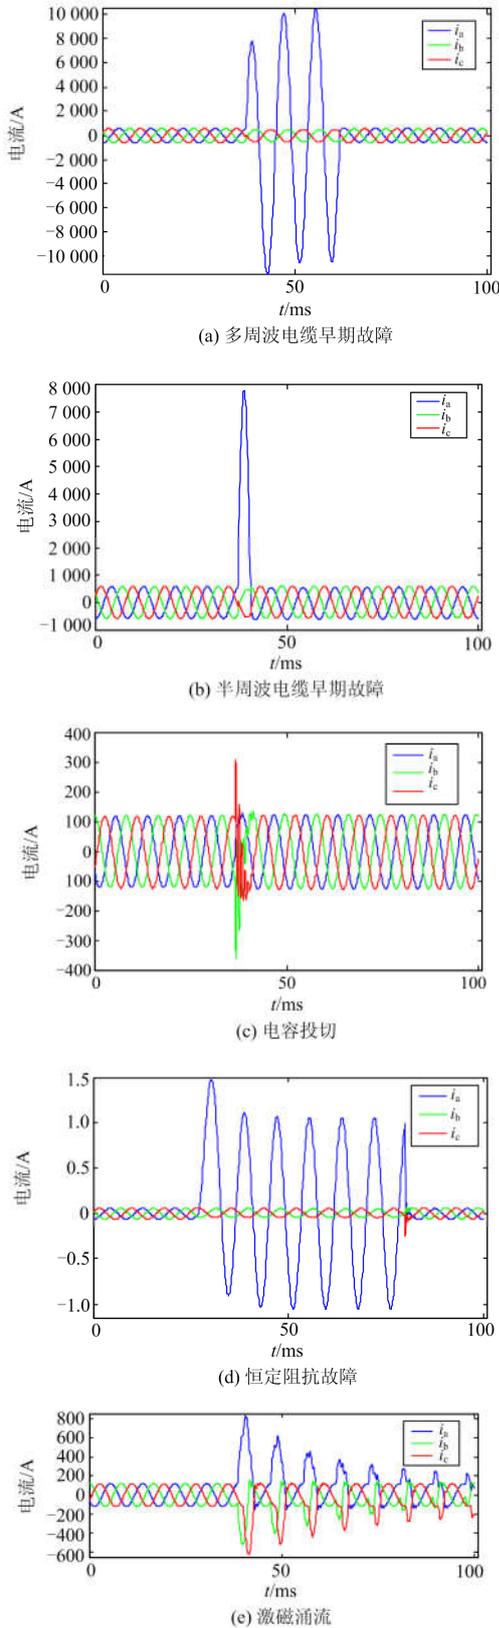


图7 馈线电流波形图

Fig. 7 Feeder current waveform

3.2 评估模型性能的指标

为了评估文中识别模型的性能, 采用了准确率 (Accuracy)、精确率 (precision)、召回率 (recall) 和 F_1 值指标, 相应的计算公式为

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + FP + TN} \quad (21)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (22)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (23)$$

$$F_1 = \frac{2TP}{2TP + FP + FN} \quad (24)$$

式中: TP 表示实际为早期故障的样本, 且模型估计也为早期故障的样本数量; FN 则为被错误分类为其他类别的样本数量; FP 实际为其他类别的样本, 被正确分类的样本数; TN 则为被错误分类的样本数。准确率反映的是实验预测类别和实际类别一致的样本占总样本的比例; 精确率反映的是实验预测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数; 召回率则反映实验预测且实际类别为电缆早期故障样本数占所有实际类别为电缆早期故障样本的比例; F_1 值则表示精确率和召回率的调和均值。

3.3 与其他分类器的比较

本节采用相同的训练和测试样本, 将提出的方法与传统的 KNN^[18]、SVM^[19]和 RF^[20]进行比较。KNN 算法是当输入样本的 K 个最相邻样本的大多数属于某种类别, 则判断该样本属于这个类别; SVM 是通过寻找超平面, 使边际最大, 来进行分类识别的; RF 是利用了多个决策树的投票机制, 分类的结果由决策树投票得出。基于训练效率和计算量的考虑, 文本算法采用了 3 层 NCAE 所堆叠形成的 DL 网络, 其深度为 5 的网络, 即包含 1 个输入层、3 个隐藏层和 1 个输出层, 其中输入层和输出层的节点数分别为 45 和 3, 隐藏层的节点为 [20, 10, 5], 训练时所采用的关键参数设置为: $\rho=0.05$, $\mu=1$, $\lambda=3 \times 10^{-3}$ 。

表 1 显示了 KNN、SVM、RF 和本文算法对测试样本分类后的统计结果, 可以看出尽管 RF 方法相比较于 KNN 和 SVM 具有较好的性能, 但文中所提识别方法在准确率、精确率、召回率以及 F_1 值这几个方面都更优于 RF 等其他识别方法, 表明文中所提方法在采集的数据中过电流发生时刻呈随机不确定性和过电流数据不完整时, 也具有提高电缆早期故障识别准确率的潜质。

表 1 不同分类器的比较结果

方法	Accuracy	precision	Recall	F_1
KNN	0.644	0.483	0.730	0.581
SVM	0.918	0.903	0.874	0.897
RF	0.938	0.940	0.914	0.926
本文方法	0.968	0.988	0.927	0.957

3.4 网络节点数和深度的影响

从理论上讲, DL 网络的深度和各隐藏层结点个数的设置会对分类效果产生一定的影响, 这一节将通过设置网络深度为 4、5、6, 且随机改变隐藏层结点的个数来讨论两个参数的影响。表 2 显示了采用不同的深度和结点的 DL 网络对训练样本进行网络学习后, 再采用测试样本进行识别后的统计结果。各 DL 网络中的输入层和输出层是相同的, 对应于相同的初级特征个数和需要分类的类别数(即正常电流、电缆早期故障和引起过电流的其他扰动), 训练时各 DL 网络均采用如 3.3 节所述的参数, 表中加黑字体为表 2 中所得深度网络分类结果。

表 2 不同分类器的比较结果

深度	方法	Accuracy	Precision	Recall	F_1
4	[45,30,10,3]	0.942	0.996	0.832	0.906
	[45,20,5,3]	0.941	0.988	0.835	0.905
	[45,50,20,3]	0.963	0.941	0.950	0.946
	[45,100,20,3]	0.944	1.000	0.835	0.910
5	[45,30,20,10,3]	0.902	0.903	0.796	0.846
	[45,30,10,5,3]	0.826	0.750	0.730	0.740
	[45,20,10,5,3]	0.968	0.988	0.927	0.957
	[45,100,50,10,3]	0.953	0.985	0.875	0.926
6	[45,100,50,30,10,3]	0.925	0.899	0.878	0.888
	[45,50,30,20,10,3]	0.598	0.454	0.944	0.613
	[45,40,30,20,10,3]	0.935	0.930	0.875	0.901
	[45,20,15,10,5,3]	0.637	0.479	0.861	0.616

从表 2 的结果可以看出, 对于相同深度的网络, 设置不同的隐藏层结点, 获得分类效果差别会很大, 如 5 层网络中的[45, 30, 10, 5, 3]和[45, 20, 10, 5, 3], 前一个网络的各项指标都较差; 比较不同深度的网络可以看出, 采用 5 层的网络可以获得较为满意的分类性能, 但进一步地增加网络的深度, 如 6 层网络时, 并不一定会提升网络的分类识别性能, 还会带来训练效率低下, 训练时间长的缺陷。

4 结论

本文提出利用多层 NCAE 堆叠构建的 DL 网络实现从正常电流波形和过电流扰动中识别出电缆早

期故障的方法, 为了克服将大量的原始电流波形送入 DL 网络造成训练效率低的缺陷, 首先利用小波变换提取出给类电流信号的初级特征, 其次, 利用多层 NCAE 堆叠构建的 DL 网络从这些相关、冗余的初级特征中学习出有利于分类识别的特征, 最后通过 SoftMax 分类器实现电缆早期故障的识别。利用仿真数据进行识别的实验结果表明, 本文所提出的方法相比于其他传统的模式识别方法, 即便采集的数据中过电流发生时刻呈随机不确定性和过电流数据存在不完整时, 也能更准确地识别出电缆早期故障。

参考文献

- [1] KULKARNI S, SANTOSO S, SHORT T A. Incipient fault location algorithm for underground cables[J]. IEEE Transaction on Smart Grid, 2014, 5(3): 1165-1174.
- [2] 孙仲民, 何正友, 戴铭. 基于灰色预测的电力电缆老化过程预警仿真研究[J]. 电力系统保护与控制, 2012, 40(13): 55-60.
SUN Zhongmin, HE Zhengyou, DAI Ming. Simulation study on pre-alarm of power cable aging process based on grey prediction[J]. Power System Protection and Control, 2012, 40(13): 55-60.
- [3] SIDHU T S, XU Zhihan. Detection of incipient faults in distribution underground cables[J]. IEEE Transactions on Power Delivery, 2010, 25(3): 1363-1371.
- [4] ZHANG Wenhai, XIAO Xiaoyong, 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.
- [5] 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.
- [6] 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.
- [7] SIDHU T S, XU Zhihan. Detection of incipient faults in distribution underground cables[J]. IEEE Transactions on Power Delivery, 2010, 25(3): 1363-1371.
- [8] 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.
- [9] GHANBARI T. Kalman filter based incipient fault detection method for underground cables[J]. *IET Generation, Transmission & Distribution*, 2015, 9(14): 1988-1997.
- [10] 杨涛, 黄军凯, 许逵, 等. 基于深度学习的变压器故障诊断方法研究[J]. *电力大数据*, 2018, 21(6): 23-30.
YANG Tao, HUANG Junkai, XU Kui, et al. Diagnosis method of power transformer fault based on deep learning[J]. *Power system and Big Data*, 2018, 21(6): 23-30.
- [11] 姜有泉, 黄良, 王波, 等. 基于 DGA 和深度置信网络的变压器内部故障诊断[J]. *武汉大学学报(工学版)*, 2017, 50(5): 749-753.
JIANG Youquan, HUANG Liang, WANG Bo, et al. Transformer internal fault diagnosis based on DGA and deep belief network[J]. *Engineering Journal of Wuhan University*, 2017, 50(5): 749-753.
- [12] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. *机械工程学报*, 2015, 51(21): 49-56.
LEI Yaguo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data[J]. *Journal of Mechanical Engineering*, 2015, 51(21): 49-56.
- [13] 李智, 侯兴哲, 刘永相, 等. 基于深度学习的充电站容量规划方法[J]. *电力系统保护与控制*, 2017, 45(21): 67-73.
LI Zhi, HOU Xingzhe, LIU Yongxiang, et al. A capacity planning method of charging station based on depth learning[J]. *Power System Protection and Control*, 2017, 45(21): 67-73.
- [14] 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): 87-93.
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.
- [15] HOSSEINI-AS E, ZURADA J M, NASRAOUI O. Deep learning of part-based representation of data using sparse autoencoders with nonnegativity constraints[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27(12): 2486-2498.
- [16] AYINDE B O, ZURADA J M. Deep learning of constrained autoencoders for enhanced understanding of data[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(9): 3969-3979.
- [17] NASON G P, SILVERMAN B W. The stationary wavelet transform and some statistical applications[J]. *Wavelets and Statistics*, 1995, 103: 281-299.
- [18] COVER T M, HART P E. Nearest neighbor pattern classification[J]. *IEEE Transactions on Information Theory*, 1967, 13(1): 21-27.
- [19] HEARST M A, DUMAIS S T, OSUNA E, et al. Support vector machines[J]. *IEEE Intelligent Systems and their Applications*, 1998, 13(4): 18-28.
- [20] BREIMAN L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5-32.
- [21] BESSEC M, FOUQUAN J. Short-run electricity load forecasting with combinations of stationary wavelet transforms[J]. *European Journal of Operational Research*, 2018, 264(1): 149-164.
- [22] SHARMA L D, SUNKARIA R K. Stationary wavelet transform based technique for automated external defibrillator using optimally selected classifiers[J]. *Measurement*, 2018, 125: 29-36.

收稿日期: 2018-07-20

作者简介:

邵宝珠(1980—), 男, 高级工程师, 从事电能质量技术、电力系统分析和继电保护技术研究;

李胜辉(1982—), 男, 高级工程师, 从事电能质量技术和新能源并网技术研究;

白雪(1988—), 女, 工程师, 从事电能质量技术和新能源并网技术研究。

(编辑 周金梅)