

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

汪颖¹, 卢宏¹, 杨晓梅¹, 肖先勇¹, 张文海²

(1. 四川大学电气信息学院, 四川成都 610065; 2. 国网四川检修公司, 四川成都 610042)

摘要:将深度学习概念应用到电缆早期故障识别中,提出结合S变换与堆叠自动编码器(SAE)的电缆早期故障识别方法。通过对故障相电流进行S变换,将获得的S变换模时频矩阵分为低、中和高频段。求取对应频段的能量熵和奇异熵等特征量,并组成特征向量后,将时频域特征向量作为SAE网络的输入,经过预训练和参数微调,得到最优训练参数。利用构建好的网络从输入数据中挖掘有用信息,从大量扰动中识别电缆早期故障。仿真结果表明,与传统模式识别方法相比,所提方法的精度更高。

关键词:电缆;电缆早期故障;S变换;奇异熵;能量熵;深度学习;堆叠自动编码器

中图分类号:TM 247

文献标识码:A

DOI:10.16081/j.issn.1006-6047.2018.08.017

0 引言

电缆是电力系统输电线路中的重要设备,其故障过程为渐进过程,可分为电缆缺陷、电缆早期故障和电缆永久性故障3个阶段。电缆在安装后受到土壤、水分和机械应力的影响,随着运行时间的增加,会在电缆中形成缺陷,极易出现局部放电、水树枝和电树枝现象,使电缆绝缘水平逐渐降低,但并未造成绝缘击穿。随着局部放电的增强,电缆缺陷变为早期故障。电缆早期故障概念首先在文献[1]中被提出,也被称为自清除故障。本文在分析已有研究成果的基础上^[1-9],将电缆早期故障总结为:由于电缆绝缘水平的恶化产生局部放电,局部放电后期使电缆发生间歇性绝缘击穿,不能引起保护动作跳闸,但可能引起电缆永久性故障的一种重复性瞬时故障。准确检测和识别电缆早期故障,可以消除潜在故障隐患,在永久性故障发生前更换电缆,提高供电可靠性。因此,对电缆早期故障进行准确识别具有实际的意义。

对于电缆早期故障的特征,文献[2-4]进行了相关研究。由于电缆早期故障多发生在电缆接头,文献[2]通过电缆接头故障时记录的馈线电压和电流波形,对电缆早期故障特征进行分析。文献[3-4]同时记录了电缆早期故障和由早期故障导致的永久性故障波形,分析后发现在永久性故障前会重复出现早期故障。因此电缆早期故障的特征可归纳为:电缆中同一相发生永久性故障的先兆;通常发生在电压峰值时刻;按故障持续时间长短可分为半周期早期故障和多周期早期故障,前者持续时间约为1/4个周期,后者持续时间约为1~4个周期^[5];不会引起保护装置动作;多为单相接地故障。

电缆早期故障的特征决定了其电压和电流波形,故障多发生在电压峰值附近,是因为此时电缆绝缘体上的电压应力最大^[4],更容易造成绝缘击穿。

当电缆发生早期故障时,电缆中出现间歇性电弧,使故障相电流瞬时增大,同时使故障相电压迅速下降,非线性高奇次谐波的存在使得故障相电压波形类似于失真的方波^[3]。但电弧的持续时间很短,电弧电流会在交流电流过零点自动熄灭,早期故障被清除,电缆电流和电压重新恢复正常。

目前针对电缆早期故障的检测识别已有大量研究^[5-9]。文献[5]利用小波变换对电流信号进行分解,通过发生故障时的能量和均方根值检测过电流扰动,再利用设定的阈值识别电缆早期故障。但由于电缆中类似过电流扰动很多,误检测率高。文献[6]采用人工神经网络方法,对电容投切信号和电缆早期故障信号进行谐波分析,选取时域特征向量,通过构造人工神经网络分类器进行分类识别。文献[7]结合小波变换和灰色关联分析方法,利用小波判据对电缆中的过电流扰动进行检测,并构造了时域特征向量和参考样本,通过计算两者之间的灰色关联度,判定关联度最大的信号为电缆早期故障。文献[8]将电弧电压引入对电缆早期故障的检测中,假设早期故障为电弧故障,利用电弧电压畸变的特点,计算了故障电压总谐波畸变率,将故障电压总谐波畸变率与参考值进行比较,判断是否为电缆早期故障。文献[9]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。现有的分析方法中,小波变换容易受噪声影响,文献[8]和文献[9]分别以电弧故障和电缆护套单端接合假设为前提,在实际电力系统运行过程中,条件变化可能导致上述方法不再适用。

现代电力系统中信号采集装置的大量安装为实现录波数据分析、提取电缆早期故障信号提供了可能,如故障录波仪、电能质量监测仪等,可以准确地记录扰动波形,通过分析扰动波形数据和深度学习,可以识别电缆早期故障。深度学习网络是含有多个隐藏层的网络结构,相比传统模式识别方法^[10-14]可

以更深入地进行数据挖掘,发现隐藏特征,目前已经广泛应用于故障的检测中^[15-17],并取得了较好的效果。

本文基于对电缆过电流扰动的研究^[8],将深度学习引入早期故障识别中,提出一种堆叠自动编码器 SAE(Stacked AutoEncoder)与 S 变换相结合的电缆早期故障识别算法。由于早期故障信号经过 S 变换后空间维数高、数据量大,本文对 S 变换后求得的模时频矩阵进行进一步的处理,提取 S 变换能量熵 SEE(S-transform Energy Entropy)和 S 变换奇异熵 SSE(S-transform Singular Entropy)等特征量,利用 SAE 网络对特征量进行建模,将特征量作为网络的输入,最后完成对电缆早期故障和其他过电流扰动(如电容投切、恒定阻抗故障和变压器激磁涌流引起的过电流扰动)的分类识别。将本文算法与传统模式识别方法进行比较,结果证明本文算法具有更高的故障识别准确率。

1 基于 S 变换的特征提取

S 变换解决了短时傅里叶变换中窗口宽度和高度固定不变的问题,具有良好的频率和时间分辨率,且不易受噪声的干扰,非常适合对电缆早期故障和其他过电流扰动信号进行分析。

1.1 S 变换

Stockwel 在 1996 年将短时傅里叶变换与小波变换相结合,提出了 S 变换^[18]的思想。对于一个连续时间信号 $g(t)$,其对应的 S 变换为:

$$S(\tau, f) = \int_{-\infty}^{+\infty} g(t) \frac{|f|}{\sqrt{2\pi}} \exp\left[-\frac{1}{2}(\tau - t)^2 f^2\right] \times \exp(-j2\pi ft) dt \quad (1)$$

其中, τ 为时间,表示控制高斯窗口在时间轴上位置的参数; f 为频率。

S 变换函数与傅里叶变换函数具有一定的关系,这使得 S 变换可以利用 $g(t)$ 的傅里叶变换 $G(f)$ 来达到快速运算的目的。其关系式如下:

$$S(\tau, f) = \int_{-\infty}^{+\infty} G(\sigma + f) \exp\left(\frac{-2\pi^2 \sigma^2}{f^2}\right) \times \exp(j2\pi \sigma \tau) d\sigma \quad f \neq 0 \quad (2)$$

设 $g[iT]$ ($i=0, 1, \dots, S-1$) 表示以 T 为采样间隔对连续时间信号 $g(t)$ 采样得到的离散时间序列(其中, S 为总采样点数),则可以得到该序列的离散傅里叶变换为:

$$G[s_1/(ST)] = \frac{1}{S} \sum_{i=0}^{S-1} g[iT] \exp\left(\frac{-j2\pi s_1 i}{S}\right) \quad (3)$$

其中, s_1 为离散后的采样点, $s_1 \in [0, S)$ 。

令式(2)中的 $f=s_1/(ST)$ 、 $\tau=s_2 T$ (s_2 为离散后的采样点, $s_2 \in [0, S)$),可以得到离散时间序列 $g[iT]$ 的 S 变换为:

$$S[s_2 T, s_1/(ST)] = \begin{cases} \sum_{k=0}^{S-1} G\left[\frac{k+s_1}{ST}\right] \exp\left(\frac{-2k^2 \pi^2}{s_1^2}\right) \times \exp\left(\frac{j2\pi k s_2}{s}\right) & s_1 \neq 0 \\ \frac{1}{S} \sum_{k=0}^{S-1} g\left(\frac{k}{ST}\right) & s_1 = 0 \end{cases} \quad (4)$$

通过对信号进行 S 变换,可以得到 S 变换矩阵,它是一个复时频矩阵,矩阵的列表示时间、行表示频率。

1.2 特征的提取

对信号的 S 变换矩阵取模,获得模时频矩阵,但变换后的矩阵仍然具有很大数据量和信息量,在将其直接输入 SAE 网络的过程中,可能引起训练时间过长等问题,不利于进行分类识别,因此可对原始数据进行处理,提取初始特征向量。由于电缆早期故障信号在不同频段的信息不同,对选取的样本进行 S 变换后,令 S 变换模时频矩阵为 $M \times N$ 阶矩阵 $\mathbf{H}$,其中第 i 行第 j 个元素为 H_{ij} ,按照 $\mathbf{H}$ 的行数将矩阵分为低频段、中频段和高频段^[19]。本文基于熵的理论和奇异值分解理论,分别对不同频段的矩阵进行分析,提取用于识别电缆早期故障的初始特征向量,再利用 SAE 网络进一步挖掘初始特征向量中的隐藏信息。

熵由香农在 1948 年引入信息论中,它利用统计的特征表示信号的不确定性。令矩阵 $\mathbf{H}$ 在不同频率 i 和不同时刻 j 下的信号能量为 $E_{ij} = |H_{ij}|^2$, $E_i = \sum_{j=1}^N E_{ij}$ 表示频率为 i 时所有时刻的能量之和。为了表示信号在低、中、高频段的能量分布情况,本文基于 S 变换模时频矩阵 $\mathbf{H}$ 分别计算 3 个频段上的 SEE,定义如式(5)所示。

$$E_{Ed} = - \sum_{i=M_1}^{M_2} \frac{E_i}{E} \ln \frac{E_i}{E} \quad d=1, m, h \quad (5)$$

$$M_1 = \begin{cases} 1 & d=1 \\ \lfloor M/3 \rfloor + 1 & d=m \\ \lfloor 2M/3 \rfloor + 1 & d=h \end{cases}$$

$$M_2 = \begin{cases} \lfloor M/3 \rfloor & d=1 \\ \lfloor 2M/3 \rfloor & d=m \\ M & d=h \end{cases}$$

其中, $E = \sum_{i=1}^M E_i$ 为信号的总能量; $d=1$ 、 $d=m$ 、 $d=h$ 分别对应低、中、高频段。

利用 SSE 衡量低、中、高频段信号的复杂程度。根据奇异值分解理论,可将低频段的矩阵 $\mathbf{H}_1 \in \mathbf{R}^{M_1 \times N}$ (其中, $M_1 = M_2 - M_1$) 转化为一个对角矩阵 $\mathbf{A}$, 其奇异值分解为:

$$\mathbf{H}_1 = \mathbf{U} \mathbf{A} \mathbf{V}^T \quad (6)$$

其中, $\mathbf{U}$ 和 $\mathbf{V}$ 分别为 $M_1 \times M_1$ 阶和 $N \times N$ 阶正交矩阵; $\mathbf{A}$ 的对角线元素为奇异值 λ_k ($k=1, 2, \dots, M_1$), 可以表示对应时间和频率上信息量的大小。相应地, 低频段的 SSE E_{Sl} 定义如下:

$$E_{Sl} = - \sum_{k=1}^{M_1} \lambda_k / \sum_{k=1}^{M_1} [\lambda_k \ln(\lambda_k / \sum_{k=1}^{M_1} \lambda_k)] \quad (7)$$

同理, 可以计算中、高频段的 SSE E_{Sm} 和 E_{Sh} 。

由于矩阵经过奇异值分解后获得的奇异值是衰减的, 利用式 (8)、(9) 分别表示不同频段的信息量大小。

$$L_1 = \lambda_{lmax} - \lambda_{lmax} \quad (8)$$

$$L_2 = \lambda_{mmax} - \lambda_{hmax} \quad (9)$$

其中, L_1 为低频段与中频段最大奇异值之差; L_2 为中频段与高频段最大奇异值之差。当信号越集中于某一频段时, 该频段有最大的奇异值。

同时选取矩阵 $\mathbf{H}$ 的低、中、高频段模最大值 H_{lmax} 、 H_{mmax} 、 H_{hmax} 作为特征量, 组成包含 11 个时频域特征量的向量 $\mathbf{X}$ 。

$$\mathbf{X} = \{E_{El}, E_{Em}, E_{Eh}, E_{Sl}, E_{Sm}, E_{Sh}, H_{lmax}, H_{mmax}, H_{hmax}, L_1, L_2\} \quad (10)$$

利用大量的扰动波形数据进行故障识别需要从原始数据中提取有效的初始特征量。因此本文拟采用 S 变换对信号进行处理, 提取初始特征量, 将提取出的这 11 个初始特征量作为 SAE 网络的输入, 通过深度学习, 获得更高层次和抽象的特征, 进而实现电缆早期故障的识别。

2 SAE 介绍

深度学习作为深层的神经网络^[20], 相对于传统的浅层网络, 可以无限堆叠, 通过增加网络的隐藏层数目, 以及逐层初始化和提取特征, 实现复杂高维函数的表示, 提高分类和预测的准确性。目前深度学习模型有深度置信网络、卷积神经网络和 SAE^[21] 等。本文主要研究 SAE 在电缆早期故障识别中的应用。

2.1 自动编码器

自动编码器^[22] (AE) 的结构是一个 3 层神经网络, 包括输入层、隐藏层和输出层, 如图 1 所示。AE 的训练过程由编码过程和解码过程构成, 当数据输入 AE 网络后, 该网络就自动进行编码操作, 将输入数据 $\mathbf{X} \in \mathbf{R}^{n \times 1}$ 编码成 $\mathbf{Y} \in \mathbf{R}^{m \times 1}$, $\mathbf{Y}$ 再经过解码操作变




图 1 AE 结构图

Fig.1 Structure of AE

成 $\mathbf{Z} \in \mathbf{R}^{n \times 1}$ 。在实际训练中, 输出相当于是输入的复现, AE 的编码和解码过程可分别用式 (11) 和式 (12) 表示。

$$\mathbf{Y} = f_1(\mathbf{W}_1 \mathbf{X} + \mathbf{b}_1) \quad (11)$$

$$\mathbf{Z} = f_2(\mathbf{W}_2 \mathbf{Y} + \mathbf{b}_2) \quad (12)$$

其中, f_1 和 f_2 为激活函数, 本文采用的是 sigmoid 函数; $\mathbf{Y}$ 为隐藏层; $\mathbf{Z}$ 为输出层; $\mathbf{W}_1$ 和 $\mathbf{W}_2$ 分别为编码矩阵和解码矩阵; $\mathbf{b}_1$ 和 $\mathbf{b}_2$ 为偏置向量。

2.2 代价函数

在网络的训练过程中, 要选择一个目标函数体现模型性能的优劣, 其中涉及对目标函数的优化。在深度学习过程中, AE 的训练目标是尽可能地使输出 $\mathbf{Z}$ 等于输入 $\mathbf{X}$, 通常采用均方误差构造代价函数, 即:

$$\mathcal{L}(\mathbf{W}, \mathbf{b}) = \frac{1}{2} \|\mathbf{Z} - \mathbf{X}\|_2^2 \quad (13)$$

求解该代价函数, 获得表征输入信号特征 $\mathbf{Y}$ 的参数 $(\mathbf{W}, \mathbf{b})$ 。

选择的激活函数为 sigmoid 函数时, 由于其输出映射在 0~1 之间, 因此在训练过程中, 当神经元输出为 1 时, 表示被激活; 当神经元输出为 0 时, 表示未被激活。当隐藏层数目较多时, 为了使大多数情况下隐藏层神经元不被激活, 可以采用稀疏性限制。假设 $y_j(x_i)$ 表示隐藏层第 j 个单元的激活量, 则隐藏层第 j 个单元的平均激活量为:

$$\hat{\rho}_j = \frac{1}{n} \sum_{i=1}^n y_j(x_i) \quad (14)$$

在对 AE 网络进行训练的过程中, 希望大多数隐藏层神经元处于抑制状态, 因此平均激活量 $\hat{\rho}_j$ 应该接近于一个为 0 的常数 ρ (稀疏性参数)。为了实现这一约束, 考虑在神经网络的代价函数中加入稀疏惩罚项。考虑稀疏性约束的代价函数如式 (15) 所示。

$$\mathcal{L}_{\text{sparse}}(\mathbf{W}, \mathbf{b}) = \mathcal{L}(\mathbf{W}, \mathbf{b}) + \alpha \sum_{j=1}^m \text{KL}(\rho \parallel \hat{\rho}_j) \quad (15)$$

$$\text{KL}(\rho \parallel \hat{\rho}_j) = \rho \log_2 \frac{\rho}{\hat{\rho}_j} + (1-\rho) \log_2 \frac{1-\rho}{1-\hat{\rho}_j} \quad (16)$$

其中, α 为稀疏性参数; m 为隐藏层神经元总数目; KL 表示 KL (Kullback-Leibler) 散度, 当 $\rho = \hat{\rho}_j$ 时, 有 $\text{KL}(\rho \parallel \hat{\rho}_j) = 0$, 当 $\rho \neq \hat{\rho}_j$ 时, 则 KL 散度会随两者差异的增大而增大。

2.3 SAE 的构建和训练

SAE 是由多个 AE 堆叠形成的深度学习网络, 由 1 个输入层、多个隐藏层和 1 个输出层构成。SAE 的输入层来自于第 1 层 AE 的输入层 X_1 , 第 1 层 AE 训练完后获得的隐藏层输出 Y_1 用作第 2 层 AE 的输入层, 也构成 SAE 的第 1 个隐藏层; 第 2 层 AE 训练完后获得的隐藏层输出 Y_2 用作第 3 层 AE 的输入层, 也构成 SAE 的第 2 个隐藏层。依此类推, 最后一层的 AE 的输出层作为 SAE 的输出层, 从而构建出 SAE 深度网络。图 2 为一个由 3 个 AE 堆叠形成的 SAE 网络。




图 2 SAE 生成过程

Fig.2 Process of constructing SAE

SAE 的训练过程包括有监督训练和无监督训练 2 个过程。无监督训练过程为预训练过程, 通过无标记数据从第 1 层开始训练整个网络, 得到各层网络的参数; 无监督训练过程为从输出层到输入层的有监督训练, 通过有标记数据对第 1 步获得的参数进行微调, 提高网络的识别性能。在 SAE 的训练过程中, 采用随机梯度下降法, 通过式 (17) 和式 (18) 完成对参数 $\theta = (W, b)$ 的更新。

$$w'_{ij}{}^{(l)} = w_{ij}^{(l)} - \beta \frac{\partial}{\partial w_{ij}^{(l)}} \mathcal{L}_{\text{sparse}}(W, b) \quad (17)$$

$$b'_i{}^{(l)} = b_i^{(l)} - \beta \frac{\partial}{\partial b_i^{(l)}} \mathcal{L}_{\text{sparse}}(W, b) \quad (18)$$

其中, β 为训练过程中的学习率, 它决定了参数更新的速度; 上标 l 表示 SAE 网络层数; $w_{ij}^{(l)}$ 为第 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; $b_i^{(l)}$ 为第 $l+1$ 层第 i 个单元的偏置项。

2.4 基于 softmax 的分类识别

在本文中, 输出类别只包含 2 类, 即电缆早期故障和非电缆早期故障 (其他过电流扰动), 是一个二元分类问题。训练完 SAE 网络后, 采用 softmax 回归对输出结果进行分类识别。训练集由 $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ 组成, x_i 为输入样本; y_i 为对应输入样本 x_i 的标签, 取值为 0 或 1, $y_i = 1$ 表示电缆早期故障, $y_i = 0$ 表示非电缆早期故障。对于输入的测试集数据 x_i , 可利用函数计算它属于每种类别 $y_i = j (j=0, 1)$ 的概率值 $p(y_i = j | x_i)$, 此时假设函数为:

$$h(x_i) = \frac{1}{e^{\theta_1^T x_i} + e^{\theta_2^T x_i}} \begin{bmatrix} e^{\theta_1^T x_i} \\ e^{\theta_2^T x_i} \end{bmatrix} \quad (19)$$

其中, θ_1 和 θ_2 分别为 softmax 回归模型中第 1 种和第 2 种类别对应的输入参数。

3 基于 SAE 网络的电缆早期故障识别

本文基于 SAE 和 S 变换提出一种深度学习的方法, 利用 SAE 网络, 从电缆众多的过电流扰动中, 识别电缆早期故障, 具体流程如图 3 所示。




图 3 基于 S 变换和 SAE 的算法流程图

Fig.3 Flowchart of proposed method based on S transform and SAE

a. 在 PSCAD/EMTDC 中搭建仿真模型,获得不同扰动的样本数据。由于在设备发生故障时,电流波形的变化更为明显。在实际运行中,选择变电站端馈线测量电流作为原始数据。样本数据包括半周期电缆早期故障和多周期电缆早期故障,及其他不属于电缆早期故障的过电流扰动,如变压器激磁涌流、恒定阻抗故障、电容器投切引起的过电流扰动等。

b. 对获得的样本数据在 MATLAB 中进行 S 变换,求得各种情况下的 S 变换模时频矩阵,计算对应的 11 个特征量。

c. 通过无监督的预训练和有监督的微调完成 SAE 网络的搭建。预训练可以学习到输入信号的复杂非线性变换,微调过程可提高网络的识别精度,这 2 个过程保证了 SAE 网络可以从原始输入信号中挖掘有效特征,并且建立输入信号与实际类别的非线性映射关系。

d. 利用测试样本和 softmax 回归来测试训练好的 SAE 网络的性能,输出分类识别结果。

4 算例分析

4.1 实验和数据样本构造

本文用于验证所提出方法的数据集在 PSCAD/EMTDC 系统中获得,搭建了 25 kV 无支路电缆故障线路模型如图 4 所示(图中, D 为设置的故障距离),采样频率为 10 kHz。




图 4 电缆线路故障模型

Fig.4 Model of cable line with fault

在电网中,除电缆早期故障外,还存在其他过电流扰动类别,在仿真中考虑了变压器激磁涌流、恒定阻抗故障、电容器投切。仿真样本分布情况如表 1 所示。不同早期电缆故障和过电流干扰下的馈线电流波形图如图 5 所示,其与文献[2-4]中现场记录的电缆早期故障波形一致。由于图 5 中的所有故障或干扰类型都会造成电流增大,因此采用第 1 节所提出的基于 S 变换的特征提取方法,提取波形的 11 个初始特征量,并对它们全部进行归一化处理,限制在 $[0,1]$ 范围内。

4.2 评估模型性能的指标

为了评估模型的性能,对于本文中出现的二元分类问题,以混淆矩阵的形式表示按照实际类别和通过实验分类得到的类别结果。表 2 是电缆早期故

表 1 仿真样本分布情况

Table 1 Distribution of simulation samples

类型	样本数量	训练集数量	测试集数量
多周期早期故障	600	450	150
半周期早期故障	600	450	150
电容投切	400	300	100
恒定阻抗故障	400	300	100
激磁涌流	400	300	100




图 5 不同电缆早期故障和过电流干扰下的馈线电流波形图

Fig.5 Feeder current waveforms under different cable incipient faults and over-current interferences

表 2 电缆早期故障识别混淆矩阵

Table 2 Mixing matrix of incipient cable fault detection

实际类别	实验分类类别	
	电缆早期故障	非电缆早期故障
电缆早期故障	T_P	F_N
非电缆早期故障	F_P	T_N

障类型识别的混淆矩阵,表中 T_P 、 T_N 和 F_P 、 F_N 分别为电缆早期故障和非电缆早期故障样本分类正确和分类错误的数量。

通过表 2 可以得到以下评估模型性能的指标。

a. 准确率 $P_{accuracy}$: 实验分类类别和实际类别一致的样本占总样本的比例。

$$P_{accuracy} = \frac{T_P + T_N}{T_P + F_N + F_P + T_N} \quad (20)$$

b. 精确率 $P_{precision}$: 实验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。

$$P_{\text{precision}} = \frac{T_p}{T_p + F_p} \quad (21)$$

c. 召回率 P_{recall} : 实验分类且实际类别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。

$$P_{\text{recall}} = \frac{T_p}{T_p + F_N} \quad (22)$$

d. F_1 评价指标: 由于实际情况中要进行分类的类别可能存在不平衡的问题, 仅靠准确率评估是不行的, 于是引入 F_1 评价指标^[23], 它表示精确率和召回率的调和均值, 如式 (23) 所示。

$$\frac{2}{F_1} = \frac{1}{P_{\text{precision}}} + \frac{1}{P_{\text{recall}}} \quad (23)$$

$$F_1 = \frac{2T_p}{2T_p + F_p + F_N}$$

e. ROC 曲线是利用分类的真正率 TPR (True Positive Rate) 和假正率 FPR (False Positive Rate) 作为坐标轴, 利用图形化的形式来表示分类方法的准确率的高低, 曲线与坐标轴的面积 (AUC) 可以用于表示分类模型准确率的高低。

4.3 与其他分类器的比较

本节采用相同的训练和测试样本, 将本文方法与支持向量机 (SVM)^[10] 法、K 近邻 (KNN) 算法^[11]、集成学习 (JC) 法^[12] 和随机森林 (RF) 算法^[13] 进行比较。

图 6 为本文方法、SVM 法、KNN 算法、JC 法^[12] 和 RF 算法^[13] 的 ROC 曲线。从图 6 可以看出, 本文方法的曲线与坐标轴的面积最大, 准确率更高, 分类效果比其他方法更好。




图 6 不同方法的 ROC 曲线

Fig.6 ROC curves of different methods

表 3 为具体的比较结果, 从表中可以得出本文方法的 P_{accuracy} 可达到 98.8%, 比 JC 法、SVM 法、KNN 法分别高出 12.1%、25.5%、31.3%; RF 利用了多个

决策树投票得出最后的分类结果, 比其他 3 种模式识别方法更好, 但与本文的方法相比, 仍有一定的差距。本文方法还具有更高的 F_1 (98.5%)、 $P_{\text{precision}}$ (98.7%)、 P_{recall} (98.9%) 和 AUC (0.974), 比其他 4 种传统模式识别方法更优越。这是因为 SAE 可以通过多特征的变换自动地从初始特征向量中学习到有价值的信息, 能在众多过电流扰动中准确识别出电缆早期故障。

表 3 不同方法的比较结果

Table 3 Comparison among different methods

方法	$P_{\text{accuracy}}/\%$	$P_{\text{precision}}/\%$	$P_{\text{recall}}/\%$	$F_1/\%$	AUC
本文方法	98.8	98.7	98.9	98.5	0.974
SVM	73.3	50.0	92.6	64.9	0.636
KNN	67.5	51.7	75.6	61.4	0.461
JC	86.7	69.1	98.2	84.2	0.733
RF	95.2	92.3	97.8	95.0	0.947

4.4 网络参数的影响

理论上, 训练 SAE 网络时, 迭代次数越多, 最后得到的误差会更小, 因此本节考虑了深度学习模型训练过程中迭代次数的影响, 如图 7 所示。由图可见, 当迭代次数小于 2 000 次时, 准确率很低, 只有 58.3%; 此后随着迭代次数增加, 准确率上升, 当次数为 6 000 时, 准确率已经为 91.7%, 当次数大于 10 000 时, 准确率为 98.8%, 之后不再变化, 因此本文取迭代次数为 10 000 次。




图 7 迭代次数对结果的影响

Fig.7 Impact of iterations number on results

4.5 利用 S 变换提取特征的优点

与直接利用原始数据作为 SAE 网络的输入相比, 本文方法基于 S 变换与熵理论, 提取了初始时频域特征向量, 最大的优点是使输入数据的维数和 SAE 网络的复杂程度降低, 减少了仿真时间。采用相同的 SAE 网络测试基于 S 变换提取的特征和原始数据, 结果如表 4 所示。

表 4 提取特征向量与原始时域数据的比较结果

Table 4 Comparison between extracted eigenvector and original time-domain data

方法	$P_{\text{accuracy}}/\%$	仿真时间/s
本文方法	98.8	215.416
利用原始数据处理	90.2	2 203.932

从表 4 中可见, 本文提出的先提取初始特征向量的方法在仿真时间和准确率方面都优于直接对原

始数据进行处理的方法,证明了本文方法的有效性和可行性。

5 结论

本文将S变换与SAE相结合,提出一种深度学习识别方法识别电缆早期故障。在PSCAD/EMTDC系统中搭建25 kV无支路电缆故障线路模型进行仿真研究,结论如下:

a. 本文所提电缆早期故障识别的特征提取方法,结合S变换模时频矩阵与熵理论,获得了11个时频域特征量,解决了电缆早期故障信号维数大和信息量复杂的问题,更有利于SAE网络的分类;

b. 本文提出了一种SAE和S变换相结合的电缆早期故障识别方法,与传统模式识别方法相比,其准确率可达98.8%;

c. 本文方法与直接运用原始数据作为SAE网络输入的方法相比,仿真时间仅需后者的10%,准确率较后者高8.6%。

本文研究证明了深度学习方法在电缆早期故障识别中应用的可能性,为该领域的相关研究提供了新思路。本文基于仿真信号进行分析,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] KOJOVIC L A, WILLIAMS C W. Sub-cycle detection of incipient cable splice faults to prevent cable damage[C]// 2000 Power Engineering Society Summer Meeting. Seattle, WA, USA; IEEE, 2000: 1175-1180.
- [2] STRINGER N T, KOJOVIC L A. Prevention of underground cable splice failures[J]. IEEE Transactions on Industry Applications, 2001, 37(1): 230-239.
- [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] MOGHE R, MOUSAVI M J, STOUPIS J, et al. Field investigation and analysis of incipient faults leading to a catastrophic failure in an underground distribution feeder[C]// IEEE/PES Power Systems Conference and Exposition. Seattle, WA, USA; IEEE, 2009: 1-6.
- [5] SIDHU T S, XU Zhihan. Detection of incipient faults in distribution underground cables[J]. IEEE Transactions on Power Delivery, 2010, 25(3): 1363-1371.
- [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] 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.
- [8] ZHANG Wenhai, XIAO Xianrong, 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.
- [9] 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. Xi'an, China; IEEE, 2016: 795-799.
- [10] 徐志超, 杨玲君, 李晓明. 基于聚类改进S变换与直接支持向量机的电能质量扰动识别[J]. 电力自动化设备, 2015, 35(7): 50-58.
XU Zhichao, YANG Lingjun, LI Xiaoming. Power quality disturbance identification based on clustering-modified S-transform and direct support vector machine[J]. Electric Power Automation Equipment, 2015, 35(7): 50-58.
- [11] 刘凡, 张昀, 姚晓, 等. 基于K近邻算法的换流变压器局部放电模式识别[J]. 电力自动化设备, 2013, 33(5): 89-93.
LIU Fan, ZHANG Yun, YAO Xiao, et al. Recognition of PD mode based on KNN algorithm for converter transformer[J]. Electric Power Automation Equipment, 2013, 33(5): 89-93.
- [12] 王丽丽. 集成学习算法研究[D]. 南宁: 广西大学, 2006.
WANG Lili. Research on ensemble learning algorithm[D]. Nanning: Guangxi University, 2006.
- [13] 王守相, 周凯, 苏运. 基于随机森林算法的台区合理线损率估计方法[J]. 电力自动化设备, 2017, 37(11): 39-45.
WANG Shouxiang, ZHOU Kai, SU Yun. Line loss rate estimation method of transformer district based on random forest algorithm[J]. Electric Power Automation Equipment, 2017, 37(11): 39-45.
- [14] 石少伟, 王可, 陈力, 等. 基于模糊综合评价和贝叶斯判别的电力变压器状态判别和预警[J]. 电力自动化设备, 2016, 36(9): 60-66.
SHI Shaowei, WANG Ke, CHEN Li, et al. Power transformer status evaluation and warning based on fuzzy comprehensive evaluation and Bayes discrimination[J]. Electric Power Automation Equipment, 2016, 36(9): 60-66.
- [15] 赵洪山, 刘辉海. 基于性能改善深度置信网络的风电机组主轴承状态分析[J]. 电力自动化设备, 2018, 38(2): 44-49.
ZHAO Hongshan, LIU Huihai. Condition analysis of wind turbine main bearing based on deep belief network with improved performance[J]. Electric Power Automation Equipment, 2018, 38(2): 44-49.
- [16] 朱乔木, 陈金富, 李弘毅, 等. 基于堆叠自动编码器的电力系统暂态稳定评估[J]. 中国电机工程学报, 2018, 38(10): 2937-2946.
ZHU Qiaomu, CHEN Jinfu, LI Hongyi, et al. Transient stability assessment based on stacked autoencoder[J]. Proceedings of the CSEE, 2018, 38(10): 2937-2946.
- [17] SUN Jiedi, YAN Changhong, WEN Jiangtao. Intelligent bearing fault diagnosis method combining compressed data acquisition and deep learning[J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(1): 185-195.
- [18] STOCKWELL R G, MANSINHA L, LOWE R P. Localization of the complex spectrum; the S transform[J]. IEEE Transactions on Signal Processing, 1996, 44(4): 998-1001.
- [19] 陶维青, 夏熠, 陆鼎堃. S变换熵理论及其在电力系统故障检测中的应用研究[J]. 合肥工业大学学报(自然科学版), 2016, 39(1): 40-45.

TAO Weiqing, XIA Yi, LU Dingkun. Study of S-transform entropy theory and its application in fault detection of electric power system [J]. Journal of Hefei University of Technology (Natural Science Edition), 2016, 39(1): 40-45.

- [20] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7): 1527-1554.


- [21] 刘建伟, 刘媛, 罗雄麟. 深度学习研究进展 [J]. 计算机应用研究, 2016, 31(7): 1921-1930.

LIU Jianwei, LIU Yuan, LUO Xionglin. Research progress on deep learning [J]. Application Research of Computers, 2016, 31(7): 1921-1930.

- [22] KONG Xiangrui, XU Xiaoyuan, YAN Zheng, et al. Deep learning hybrid method for islanding detection in distributed generation [J]. Applied Energy, 2017, 210: 776-785.

- [23] PIAO M, SHON H S, LEE J Y, et al. Subspace projection method based clustering analysis in load profiling [J]. IEEE Transaction on Power Systems, 2014, 29(6): 2628-2635.

作者简介:



汪颖

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

卢宏(1995—),男,四川遂宁人,硕士研究生,主要研究方向为电能质量与配电网故障的识别 (E-mail: 571082642@qq.com);

杨晓梅(1973—),女,四川乐山人,副教授,博士,通信作者,主要研究方向为模式识别、电能质量与优质供电、磁共振快速成像、图像处理 (E-mail: yangxiaomei@scu.edu.cn);

肖先勇(1968—),男,四川宜宾人,教授,博士研究生导师,博士,主要研究方向为电能质量与优质供电等;

张文海(1989—),男,四川简阳人,博士,主要研究方向为配电网故障检测定位、超高压电网设备状态检修。

Cable incipient fault identification based on stacked autoencoder and S-transform

WANG Ying¹, LU Hong¹, YANG Xiaomei¹, XIAO Xianyong¹, ZHANG Wenhai²

(1. School of Electrical Engineering and Information, Sichuan University, Chengdu 610065, China;

2. State Grid Sichuan Maintenance Company, Chengdu 610042, China)

Abstract: A cable incipient fault identification method based on S-transform and SAE (Stacked AutoEncoder) is proposed applying the concept of deep learning. The S-transform of fault phase current is carried out to obtain S-transform time-frequency matrix in low-, medium- and high-frequency bands. The energy entropy and singular entropy in the corresponding frequency band are calculated and then combined as the eigenvector. Taking the eigenvector as the input, the SAE network are pre-trained and its parameters are adjusted, and the optimal training parameters are obtained. The useful information extracted from the input data using the constructed network is employed to identify the cable incipient fault from lots of disturbances. Simulative results show that the proposed method has higher accuracy compared with the traditional pattern recognition method.

Key words: electric cables; cable incipient fault; S-transform; singular entropy; energy entropy; deep learning; stack autoencoder