

DOI: 10.7667/PSPC160587

输电线路故障层次化变步长 Tsallis 小波奇异熵诊断方法

黄南天¹, 李富青², 王文婷¹, 于志勇³, 聂永辉¹

(1. 东北电力大学电气工程学院, 吉林 吉林 132012; 2. 国网浙江宁波市奉化区供电公司, 浙江 宁波 315500;
3. 国网新疆电力公司经济技术研究院, 新疆 乌鲁木齐 830011)

摘要: 为提高熵方法输电线路故障信号时-频域的特征提取能力, 提出层次化变步长 Tsallis 小波奇异熵(Tsallis Wavelet Singular Entropy, TWSE)方法用于电力系统故障诊断。首先, 对采集到的电压信号进行小波分解与单支重构, 构建时-频矩阵; 之后, 将奇异值分解与 Tsallis 熵理论相结合, 对该时-频矩阵求滑动步长为 1 的 Tsallis 奇异熵, 确定故障发生时刻; 然后, 对故障发生后 1 周期内的三相电压重构系数求滑动步长为 1/4 周期的 TWSE, 构建用于故障诊断的特征向量; 最后, 将 TWSE 特征向量输入到极限学习机(Extremely Learning Machine, ELM)分类器中, 实现输电线路故障诊断。仿真结果表明, 新方法具有更好的故障暂态信号特征表现能力, 且分类结果不受故障时间、过渡电阻和故障位置等因素影响, 相较基于小波奇异熵的线路故障诊断方法具有更好的诊断效果。

关键词: 故障诊断; 小波变换; 奇异值分解; Tsallis 熵; 极限学习机

A method of transmission line faults diagnosis based on Tsallis wavelet singular entropy with hierarchical variable step size

HUANG Nantian¹, LI Fuqing², WANG Wenting¹, YU Zhiyong³, NIE Yonghui¹

(1. School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China; 2. State Grid Zhejiang Ningbo Fenghua Electric Power Supply Company, Ningbo 315500, China; 3. Economic and Technology Research Institute of State Grid Xinjiang Electric Power Company, Urumqi 830011, China)

Abstract: In order to improve the capability of entropy method in time-frequency feature presentation of fault signals of transmission lines, a new method is proposed for power system fault diagnosis based on Tsallis wavelet singular entropy (TWSE) with hierarchical variable step size. Firstly, the collected voltage signals are transformed by wavelet decomposition and single branch reconstruction, which is used to construct time-frequency matrix. Secondly, the singular value decomposition theory combines with the Tsallis entropy theory, and the time-frequency matrix processed by TWSE with 1 sliding step size is used to determine the fault occurrence time. Then, the method calculates TWSE with 1/4 period sliding step size to obtain the feature vector for fault diagnosis from the one period after the fault happened of the three-phase voltage reconstruction coefficient. Finally, the TWSE feature vector is input to the classifier based on the extreme learning machine (ELM) to realize fault diagnosis of transmission line. Simulation results show that the new method has better feature representation ability for fault transient signal, and classification result is not affected by fault time, transition resistance and fault location. Compared with the SWSE fault diagnosis method based on wavelet singular entropy, the method of TWSE has better diagnosis effect.

This work is supported by National Natural Science Foundation of China (No. 51307020).

Key words: fault diagnosis; wavelet transform; singular value decomposition; Tsallis entropy; extreme learning machine

0 引言

输电线路是电力输电和配电系统的重要元件,

基金项目: 国家自然科学基金项目(51307020); 2016年吉林省科技发展计划项目(20160411003XH, 20160204004GX); 吉林省教育厅“十三五”科技项目(吉教科合字[2016]第90号)

其可靠运行对继电保护控制与电力系统稳定性等具有重要影响。故障类型的识别是保护中自动重合闸控制的重要依据^[1]。因此, 快速和准确地识别故障类型对继电保护设备准确动作及故障排除等具有重要意义^[2-4]。

常用的故障信号处理方法有 S 变换(S-Transform, ST)^[5-6]、经验模态分解(Empirical Mode

Decomposition, EMD)^[7]和小波变换(Wavelet Transform, WT)^[8-10]等。ST作为一种时-频分析方法,具有频率分辨率高和特征表现好的优点;但计算量较大,对高采样率信号分析存在耗时较长的缺点。EMD具有较好的自适应性,适应于高采样率的故障暂态信号分析,由于计算过程中存在的过包络和欠包络而导致产生虚假模态和模态混叠现象,影响分类结果。WT采用Mallat快速算法时,处理速度快,具有良好的时-频局部化特性,在暂态信号分析中已大量应用。但小波变换后系数矩阵数据量大,直接作为特征,不利于线路故障诊断。

Shannon小波熵是小波变换和信息熵理论的结合,能有效表征信号稀疏程度,因此,能够从小波系数(或重构系数)中有效提取暂态信号时-频特征^[11-13],并降低小波系数矩阵数据量。近年来,采用WT结合信息熵进行电力系统暂态处理取得了较好的效果^[10-12]。文献[11]采用滑动步长为1的多分辨率信息熵(Multi-resolution Entropy, MRE)用于超高压输电线路故障监测与电力设备状态监测。文献[12]采用WSE描述故障电压变化,并以零序电压低频能量为特征,结合支持向量机进行故障识别。文献[13]通过Shannon小波熵(Shannon Wavelet Entropy, SWE)与Tsallis小波熵(Tsallis Wavelet Entropy, TWE)对比分析发现,由于复杂电力信号的小波分解系数(或重构系数)具有非广延性,采用广延性的SWE检测复杂暂态信号时存在局限性,TWE能够更好地提取具有非广延性的小波系数(或重构系数)特征。

当使用TWE方法提取线路故障暂态特征时,采用滑动步长为1的信息熵,能够同时实现故障检测并构成故障分类特征向量。但其特征维度过高,影响分类效率和准确率。相较单步长方法,改变滑动步长能够避免特征维度过高的缺点,更加适用于故障诊断。故本文拟采用滑动步长为1和步长为 δ ($\delta > 1$)的层次化变步长Tsallis小波奇异熵(Tsallis Wavelet Singular Entropy, TWSE)实现故障诊断。

除准确提取故障信号特征外,根据故障特征构建的故障分类器也是影响故障诊断效果的重要环节。神经网络(Neural Networks, NNs)具有良好的鲁棒性与自适应性,已广泛应用于暂态故障诊断^[14-16]。但需要优化的参数多,难以确定最优分类器结构;同时,NNs需要大量历史样本进行训练,限制了该类方法在电力系统暂态故障诊断中的应用。极限学习机(Extreme Learning Machine, ELM)^[17-18]是一种新型的单隐含层前馈神经网络(Single-Hidden Layer Feedforward Neural Network, SLFN),随机产生隐含层与输入层的连接权值及隐含层神经元阈值,且在

训练过程中无需调整;通过设置隐含层神经元个数,即可获得全局唯一解。比传统方法在学习速度上更快,泛化性能更好,适用于线路故障诊断工作。

针对现有研究的不足,提出采用层次化变步长TWSE-ELM的线路故障暂态信号特征提取与分类方法。首先,对故障暂态信号进行WT变换,获取时-频矩阵;之后,采用窗宽为60、滑动步长为1的TWSE进行故障时刻检测;然后,采用窗宽和滑动步长均为1/4周期的TWSE对故障发生后的一个周波信号提取特征向量;最后,将该特征向量作为ELM的输入,实现故障诊断。通过仿真实验,验证了新方法的有效性。

1 Tsallis小波奇异熵

1.1 Tsallis熵

Tsallis熵是广延熵的广义形式,属于非广延熵^[19]。其离散形式为

$$S_q^{(d)} = \frac{c}{q-1} \left(1 - \sum_{i=1}^n p(i)^q \right), \quad q \in R \quad (1)$$

式中: $\{p(i)\}$ 为概率密度的集合; c 为Boltzmann常数; n 为系统状态数; q 为非广延参数。

1.2 Tsallis小波奇异熵

暂态信号 $s(n)$ 经 h 层小波分解与单支重构,可表示为

$$s(n) = \sum_{j=1}^h d_j(n) + a_j(n) = \sum_{j=1}^{h+1} d_j(n) \quad (2)$$

式中: $d_j(n)$ 为细节信号; $a_j(n)$ 为近似信号。为简化表示,将 $a_j(n)$ 表示为 $d_{j+1}(n)$ 。

暂态信号重构时-频矩阵为 $\mathbf{D} = \{d_j(n)\}$,对该时-频矩阵建立一个滑动数据窗,设窗宽 $w \in N$,滑动步长 $\delta \in N$,则滑动窗可表示为

$$\mathbf{W}(m; w, \delta) = \begin{Bmatrix} d_1(1+m\delta) & d_1(2+m\delta) & \cdots & d_1(w+m\delta) \\ d_2(1+m\delta) & d_2(2+m\delta) & \cdots & d_2(w+m\delta) \\ \vdots & \vdots & & \vdots \\ d_{h+1}(1+m\delta) & d_{h+1}(2+m\delta) & \cdots & d_{h+1}(w+m\delta) \end{Bmatrix} \quad (3)$$

式中: $m = 1, 2, \dots, M$; m 为窗滑动次数; M 为小波熵长度,由式(4)获得。

$$M = \frac{L-w}{\delta} \quad (4)$$

式中: L 为信号 $s(n)$ 的数据长度; w 为窗宽; δ 为步长。

数据窗 $\mathbf{W}(m; w, \delta)$ 构成矩阵 $\mathbf{D}_{(h+1) \times w}$,依据奇异

值分解理论^[20], 该矩阵可分解为

$$D_{(h+1) \times w} = P_{(h+1) \times g} A_{g \times g} Q_{g \times w} \quad (5)$$

式中: 对角矩阵 $A_{g \times g}$ 的主对角线元素为 λ_r ($r=1, 2, \dots, g; g \leq \min(h+1, w)$), 该元素为非负且按降序排列。奇异值 λ_r 中零值越少, 反映了重构信号所含频率成分越多; 反之, 越少。此刻, TWSE 可表示为

$$W_{TSE}^M(m) = \frac{1}{q-1} \left[1 - \sum_{j=1}^{h+1} (p_m(j))^q \right] \quad (6)$$

式中: $p_m(j) = \lambda_j / \sum_{r=1}^g \lambda_r$; q 为非广延参数。

2 TWSE 对故障暂态信号特征的提取

2.1 输电线路故障仿真模型

简化仿真模型如图 1 所示。模型采用 500 kV 的双端供电输电系统, 线路长度为 100 km, 线路参数参考文献[21]设置, 采用 PSCAD 软件进行仿真实验。

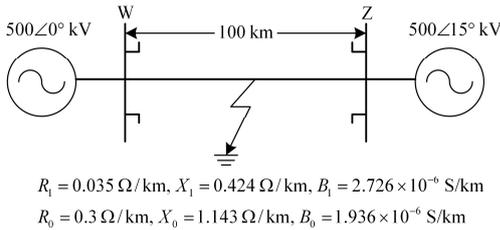


图 1 简化的输电线路模型图

Fig. 1 Simplified model of transmission line

共设置了 10 种故障类型, 包括: 单相接地故障 (AG、BG 和 CG)、两相接地故障 (ABG、BCG 和 CAG)、两相相间短路故障 (AB、BC 和 CA) 和三相短路故障 (ABC), W 端为信号采集端。

实验中以母线 W 端三相电压为研究对象, 采样频率为 100 kHz, 采用 db4 小波基, 信号分解 5 层, 信号样本长度为 2.5 周期。

仿真实验发现故障发生后的 1 周期信号含有最丰富的故障信息, 因此, 可在准确定位故障初始时刻的基础上, 对故障后 1 周期提取特征, 用于故障诊断。

新方法首先采用滑动步长为 1 的单步长 TWSE 定位故障初始时间, 之后采用滑动步长为 1/4 周期的 TWSE 针对故障开始后 1 周期内信号提取 TWSE 特征, 构建用于故障分类的特征向量。

2.2 基于单步长 TWSE 的故障时间定位

WTSE 参数设置为 $q=0.8$ 、 $w=60$ 、 $\delta=1$, AG 故障的三相信号、单支重构分量, TWSE 曲线如图 2—图 4 所示。

由图 2—图 4 可知, 在 2017 采样点(预设故障点), AG 故障引起三相电压信号扰动, 各频段暂态分量增大, 信号复杂度增大, 使熵值瞬间增大。由图 2 可知, TWSE 能够对故障相(A 相)信号实现准确定位。由图 3 和图 4 可知, TWSE 也能有效检测非故障相 B、C 的电压突变。综合三相检测结果, 说明 TWSE 能够对故障时刻进行准确时间定位。

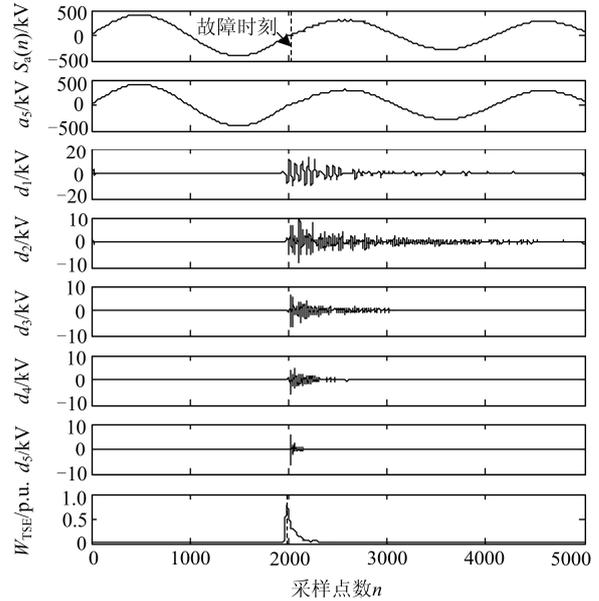


图 2 A 相信号的小波重构分量和 Tsallis 熵曲线 (AG 故障)
Fig. 2 Wavelet reconstruction components and Tsallis entropy curve of A phase signal (AG fault)

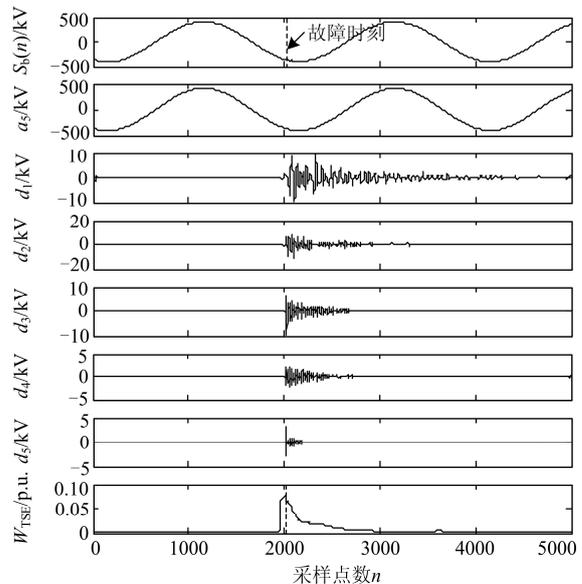


图 3 B 相信号的小波重构分量和 Tsallis 熵曲线 (AG 故障)
Fig. 3 Wavelet reconstruction components and Tsallis entropy curve of B phase signal (AG fault)

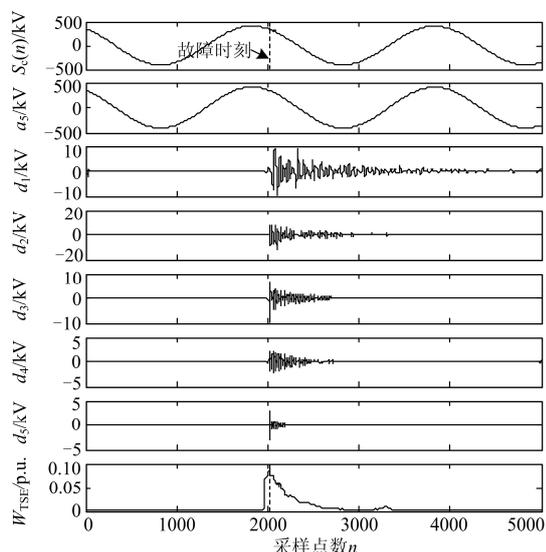


图 4 C 相信号的小波重构分量及 Tsallis 熵曲线(AG 故障)
Fig. 4 Wavelet reconstruction components and Tsallis entropy curve of C phase signal (AG fault)

2.3 滑动步长为 1/4 周期的 TWSE 的故障特征提取

对故障发生后的 1 周期内的各相信号小波重构系数矩阵计算滑动步长为 1/4 周期的 TWSE, 构建特征维度为 12(每相信号 4 维, 共 12 维)的故障样本特征向量。

现以 BG、BCG、BC、ABC 4 种故障为例进行分析, 4 种故障类型的三相电压波形如图 5 所示, 4 种故障类型故障后 1 个周期内三相电压信号的熵值曲线如图 6 所示。

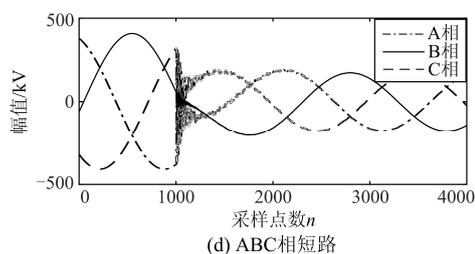
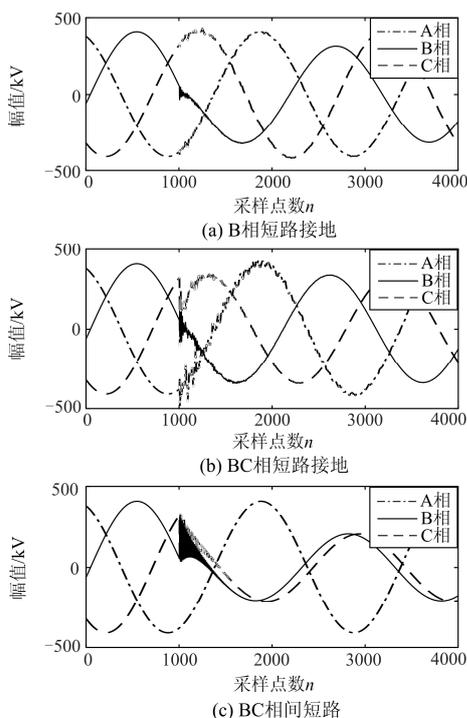


图 5 不同类型短路故障的线路三相电压
Fig. 5 Three phase voltage of line under different types of short circuit faults

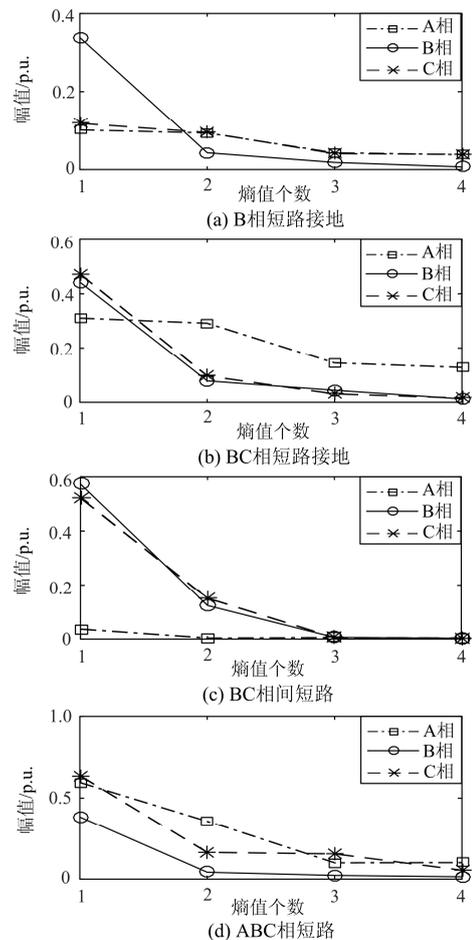


图 6 不同类型短路故障下线路三相电压的 WTSE 曲线
Fig. 6 WTSE curve of line three phase voltage under different types of short circuit faults

由图 5 和图 6 可以看出, 对于 B 相短路接地, 非故障相 A、C 的熵值曲线比较接近, 同时故障相 B 与非故障相 A、C 的熵值存在较大不同; BC 相间短路接地时, 故障相 B、C 的熵值曲线比较接近, 同时与非故障相 A 的熵值存在较大差异; BC 相间短路时, 故障相 B、C 熵值比较接近, 且与非故障相 A 差异较大; ABC 三相故障时, 三相熵值曲线

变换趋势基本一致。可见，不同类型故障其熵值具有各自特点，可在此特征向量基础上，开展故障诊断。

3 基于 WTSE-ELM 的线路故障诊断方法

3.1 ELM

极限学习机基本思想如下：对于 M 个样本 $(\mathbf{x}_k, \mathbf{t}_k)$ ， $\mathbf{x}_k \in R^U$ ， $\mathbf{t}_k \in R^V$ ， $k=1,2,\dots,N$ 。 N 为隐含层节点数，激活函数为 $G(x)$ ，ELM 输出为

$$\mathbf{y}_p = \sum_{k=1}^N \beta_k G(\mathbf{w}_k \mathbf{x}_p + b_k) \quad p=1,2,\dots,M \quad (7)$$

式中： $\mathbf{w}_k = [w_{k1}, w_{k2}, \dots, w_{ku}]^T$ 为连接第 k 个隐含层节点与输入节点间的权向量； $\beta_k = [\beta_{k1}, \beta_{k2}, \dots, \beta_{kv}]^T$ 为第 k 个隐含层神经元与输出节点间的权向量； b_k 为第 k 个隐含层神经元的阈值。在网络训练过程中，ELM 的输出无限接近训练样本，即存在这样的 $\hat{\beta}_k$ 、 $\hat{\mathbf{w}}_k$ 和 \hat{b}_k ，满足

$$\sum_{k=1}^N \hat{\beta}_k G(\hat{\mathbf{w}}_k \mathbf{x}_p + \hat{b}_k) = \mathbf{t}_p \quad p=1,2,\dots,M \quad (8)$$

式(8)可以改写为

$$\mathbf{H}\beta = \mathbf{T} \quad (9)$$

式(9)中：

$$\mathbf{H} = \begin{bmatrix} G(w_1 x_1 + b_1) & \cdots & G(w_N x_1 + b_N) \\ \vdots & & \vdots \\ G(w_1 x_M + b_1) & \cdots & G(w_N x_M + b_N) \end{bmatrix}_{M \times N};$$

$$\beta = [\beta_1^T, \dots, \beta_N^T]_{N \times v}; \mathbf{T} = [\mathbf{t}_1^T, \dots, \mathbf{t}_M^T]_{M \times v}。$$

\mathbf{H} 为 ELM 隐含层输出矩阵， \mathbf{H} 的第 p 列为第 p 个隐含层神经元对于 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M$ 的输出矩阵。

输出 β_i 可通过方程组(10)的最小二乘解来求取。

$$\min_{\beta} \|\mathbf{H}\beta - \mathbf{T}\| \quad (10)$$

解为

$$\hat{\beta} = \mathbf{H}^2 \mathbf{T} \quad (11)$$

式中， \mathbf{H}^2 为隐含层输出矩阵 \mathbf{H} 的 Moore-Penrose 广义逆。

3.2 基于 WTSE-ELM 故障诊断方法

故障诊断流程如图 7 所示。

首先，针对输电线路三相信号进行小波分解与单支重构，对重构分量构建时-频矩阵；其次，对该矩阵进行窗宽为 60、滑动步长为 1 的 WTSE 计算，从而定位故障时刻；最后，对故障后 1 个周期三相电压信号进行窗宽和滑动步长均为 1/4 周期的 WTSE 构建特征向量，输入到分类器 ELM 中，获得诊断结果。其中，ELM 参数设置如下：激活函数采用 sigmoid 函数，由统计实验取诊断结果较好的

隐含层节点数为 34。由 2.1 节可知，特征维度为 12，共 10 种故障，故分类器结构为 $12 \times 34 \times 10$ 。



图 7 线路故障诊断流程图

Fig. 7 Flow chart of line fault diagnosis

4 仿真验证

电压故障初始角设置为 0° 、 30° 、 45° 、 60° 、 90° ，故障过渡电阻设置为 0Ω 、 50Ω 、 100Ω 、 200Ω 、 300Ω ，故障距离设置为 10 km、30 km、70 km、90 km，获得每类 100 组，共 1000 组样本用于训练与测试 ELM。其中，随机选取 600 个样本（每类 60 个）训练网络，剩余样本用于测试。

为验证采用新方法后分类效率的改进效果，采用以下两种方法开展对比实验：

(a) 窗宽为 60、滑动步长为 1 的 TWSE 检测到故障后一个周期内三相信号 6000 个熵值；

(b) 窗宽、滑动步长均为 1/4 周期的 TWSE 计算获得三相信号 12 个熵值。

将两类特征输入到 ELM 分类器中，开展对比实验，其中方法(a)结合的 ELM 隐含层节点数为 98，此时诊断准确率最佳。对比实验如表 1 所示，实验平台采用 i3 处理器(2.3 GHz 主频)、4 G 内存。表 1 中“时间”指训练和测试分类器网络所用时间。

表 1 对比实验

Table 1 Comparison of experiment

方法	时间/s	准确率/%
(a)+ELM	24.3351	87.75
新方法(b)+ELM	0.021 98	99

由表 1 可知，窗宽与滑动步长均为 1/4 周期的新方法能够获得较高的识别准确率，有效避免了采用窗宽为 60、滑动步长为 1 时训练和测试网络时间过长和识别准确率不高的缺点。说明多步长 TWSE 能够快速实现故障类型诊断，避免了采用单步长 TWSE 时，故障检测与故障类型诊断不能同时达到

较好的效果且耗时较长的缺陷。

为进一步验证新方法的有效性, 采用窗宽与滑动步长均为 1/4 周期的 WSE 和 TWSE 两种算法分别从故障发生后 1 周期信号中获取特征, 并结合 ELM 和 SVM 分类器, 构成 4 类对比试验, 对比试验如表 2 所示, SVM 参数设置参考相关文献[22]。

表 2 对比实验

Table 2 Comparison of experiment

故障类型	准确率/%			
	WSE+SVM	WSE+ELM	TWSE+SVM	TWSE+ELM
AG	90	92.25	100	100
BG	92.5	95	100	100
CG	87.75	92.25	100	100
ABG	80	87.5	95	100
BCG	95	100	100	100
CAG	100	82.25	90	95
AB	95	100	92.5	100
BC	100	100	100	100
CA	100	100	100	100
ABC	75	87.5	97.5	95
平均	91.50	93.25	97.75	99.0

从表 2 可知, 在采用相同分类器的情况下, 采用 TWSE 方法较 WSE 方法提取特征更有效; 在采用相同特征前提下, 采用 ELM 分类器的分类效率和准确率均较 SVM 高。验证了新方法的有效性。

5 结论

提出采用层次化变步长 TWSE 进行输电线路故障诊断的新方法。新方法在通过单步长 TWSE 实现故障时间定位的前提下, 利用窗宽与滑动步长均为 1/4 周期的 TWSE 实现线路故障信号特征提取, 结合 ELM 分类器能够快速和准确地实现故障类型诊断。在降低特征向量维度的同时, 提高了分类效率与准确率。

未来的工作将在非广延参数 δ 优化等方面开展研究, 以进一步提高该方法在电力系统故障诊断领域的可应用性。

参考文献

[1] 何正友, 符玲, 麦瑞坤, 等. 小波奇异熵及其在高压输电线路故障选相中的应用[J]. 中国电机工程学报, 2007, 27(1): 31-36.
HE Zhengyou, FU Ling, MAI Ruikun, et al. Study on wavelet singular entropy and its application to faulty phase selection in HV transmission lines[J]. Transactions of China Electrotechnical Society, 2007, 27(1): 31-36.

[2] 任晓侠, 罗四倍, 马守峰, 等. 一种提高单端暂态量保护内部故障正确判别率的方法[J]. 电力系统保护与控制, 2011, 39(8): 86-89.
REN Xiaoxia, LUO Sabei, MA Shoufeng, et al. A method to improve internal-fault right discriminating rate of non-unit transient based protection[J]. Power System Protection and Control, 2011, 39(8): 86-89.

[3] 李正红, 陈朝晖. 一起线路复故障变化量方向保护动作行为分析[J]. 电力系统保护与控制, 2014, 42(6): 129-134.
LI Zhenghong, CHEN Zhaohui. Behavior analysis of direction-protection based on power-frequency variation with complex fault on transmission line[J]. Power System Protection and Control, 2014, 42(6): 129-134.

[4] 刘谋海, 方涛, 姜运, 等. 基于暂态主频分量相关性分析的故障选线方法[J]. 电力系统保护与控制, 2016, 44(2): 74-79.
LIU Mouhai, FANG Tao, JIANG Yun, et al. A new correlation analysis approach to fault line selection based on transient main-frequency components[J]. Power System Protection and Control, 2016, 44(2): 74-79.

[5] MORAVEJ Z, PAZOKI M, KHEDERZADEH M. New pattern-recognition method for fault analysis in transmission line with UPFC[J]. IEEE Transactions on Power Delivery, 2015, 30(3): 1231-1242.

[6] KRISHNANAND K R, DASH P K, NAEEM M H. Detection, classification, and location of faults in power transmission lines[J]. International Journal of Electrical Power & Energy Systems, 2015, 67: 76-86.

[7] 高相铭, 杨世凤, 潘三博. 基于 EMD 和 ABC-SVM 的光伏并网系统输出功率预测研究[J]. 电力系统保护与控制, 2015, 43(21): 86-92.
GAO Xiangming, YANG Shifeng, PAN Sanbo. A forecasting model for output power of grid-connected photovoltaic generation system based on EMD and ABC-SVM[J]. Power System Protection and Control, 2015, 43(21): 86-92.

[8] 关维国, 姚清志, 高阳, 等. 基于 db4 小波的配电网暂态电能质量扰动的检测与定位[J]. 电力系统保护与控制, 2015, 43(8): 102-106.
GUAN Weiguo, YAO Qingzhi, GAO Yang, et al. Transient power quality detection and location of distribution network based on db4 wavelet transform[J]. Power System Protection and Control, 2015, 43(8): 102-106.

[9] 刘红柳, 杨茂. 基于小波变换和支持向量机的风电功率爬坡事件识别与预测[J]. 东北电力大学学报, 2016, 36(06): 30-35.
LIU Hongliu, YANG Mao. An approach for wind power

- climbing event identification and prediction based on wavelet and SVM[J]. Journal of Northeast China Institute of Electric Power Engineering, 2016, 36(6): 30-35.
- [10] 朱艳, 王渝红, 李兴源, 等. 基于 PSCAD/EMTDC 的呼辽±500 kV 直流输电工程主设备故障仿真分析[J]. 高压电器, 2015, 51(8): 80-85.
ZHU Yan, WANG Yuhong, LI Xingyuan, et al. Fault simulation analysis on primary devices of ±500 kV DC transmission project from Hulun Beier to Liaoning based on PSCAD/EMTDC[J]. High Voltage Apparatus, 2015, 51(8): 80-85.
- [11] 何正友, 钱清泉. 多分辨信息熵的计算及在故障检测中的应用[J]. 电力自动化设备, 2001, 21(5): 9-11, 28.
HE Zhengyou, QIAN Qingquan. The computation of multi-resolution entropy and its application in EHV transmission line fault detection[J]. Electric Power Automation Equipment, 2001, 21(5): 9-11, 28.
- [12] 王艳松, 谭志勇, 刘学民. 基于小波奇异熵和支持向量机的配电网故障类型识别[J]. 电力系统保护与控制, 2011, 39(23): 16-20.
WANG Yansong, TAN Zhiyong, LIU Xuemin. Fault type recognition for distribution network based on wavelet singular entropy and support vector machine[J]. Power System Protection and Control, 2011, 39(23): 16-20.
- [13] 陈继开, 李浩昱, 吴建强, 等. 非广延小波熵在电力系统暂态信号特征提取中的应用[J]. 中国电机工程学报, 2010, 30(28): 25-32.
CHEN Jikai, LI Haoyu, WU Jianqiang, et al. Application of non-extensive wavelet entropy to feature extraction of transient signals in power system[J]. Proceedings of the CSEE, 2010, 30(28): 25-32.
- [14] 史丽萍, 汤家升, 王攀攀, 等. 采用最优小波树和改进 BP 神经网络的感应电动机定子故障诊断[J]. 电工技术学报, 2015, 30(24): 38-45.
SHI Liping, TANG Jiasheng, WANG Panpan, et al. Stator Fault diagnosis of induction motors using the optimal wavelet tree and improved BP neural network[J]. Transactions of China Electrotechnical Society, 2015, 30(24): 38-45.
- [15] 李练兵, 张秀云, 王志华, 等. 故障树和 BAM 神经网络在光伏并网故障诊断中的应用[J]. 电工技术学报, 2015, 30(2): 248-254.
LI Lianbing, ZHANG Xiuyun, WANG Zhihua, et al. Fault diagnosis in solar photovoltaic grid-connected power system based on fault tree and BAM neural network[J]. Transactions of China Electrotechnical Society, 2015, 30(2): 248-254.
- [16] 钱国超, 邹德旭, 颜冰, 等. 集成证据推理与多神经网络的电力变压器故障综合诊断[J]. 高压电器, 2015, 51(9): 71-76.
QIAN Guochao, ZOU Dexu, YAN Bing, et al. Synthetic fault diagnosis for power transformers based on integration of evidence reasoning and neural network[J]. High Voltage Apparatus, 2015, 51(9): 71-76.
- [17] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70: 489-501.
- [18] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: a new learning scheme of feedforward neural networks[J]. Proc Int Joint Conf Neural Netw, 2006, 70: 489-501.
- [19] CHEN J, LI G. Tsallis wavelet entropy and its application in power signal analysis[J]. Entropy, 2014, 16(6): 3009-3025.
- [20] 阮玲, 李成华, 宿磊, 等. 基于奇异值分解的局部放电模式识别方法[J]. 电工技术学报, 2015, 30(18): 223-228.
RUAN Ling, LI Chenghua, SU Lei, et al. Pattern recognition for partial discharging using singular value decomposition[J]. Transactions of China Electrotechnical Society, 2015, 30(18): 223-228.
- [21] LIU Z G, HAN Z W, ZHANG Y, et al. Multiwavelet packet entropy and its application in transmission line fault recognition and classification[J]. IEEE Transactions on Neural Networks & Learning Systems, 2014, 25(11): 2043-2052.
- [22] FATHABADI H. Novel filter based ANN approach for short-circuit faults detection, classification and location in power transmission lines[J]. International Journal of Electrical Power & Energy Systems, 2016, 74: 374-383.

收稿日期: 2016-04-25; 修回日期: 2016-06-21

作者简介:

黄南天(1980—), 男, 博士, 副教授, 研究方向为电能质量分析与控制、电力设备状态检测与电网故障诊断等;

E-mail: huangnantian@126.com

李富青(1990—), 男, 硕士研究生, 研究方向为电力系统故障仿真与分析;

王文婷(1994—), 女, 本科, 研究方向为电能质量分析。

(编辑 魏小丽)