

DOI: 10.7667/PSPC150992

低压系统短路故障建模及电流预测技术

邱萍, 缪希仁, 吴晓梅

(福州大学电气工程与自动化学院, 福建 福州 350116)

摘要: 短路电流峰值对低压系统选择性保护及其断路器可靠分断十分重要, 迄今尚缺乏深入研究。利用短路故障早期检测技术, 在仿真分析短路故障早期参数的基础上, 采用灰色关联度, 得出对短路电流峰值的主要影响因素, 并采用极端学习机(ELM)实现短路电流峰值的预测。仿真结果表明, 灰色关联度可有效辨识短路电流主要因素, 降低了短路电流预测特征变量维数。基于短路故障早期检测及极端学习机的短路电流预测方法, 具有鲁棒性强且精度高的特点, 为低压选择性保护技术的实现奠定基础。

关键词: 低压配电系统; 故障早期检测; 短路电流峰值预测; 灰色关联度; 极端学习机

Low-voltage system short-circuit modeling and its current prediction technology

ZHI Ping, MIAO Xiren, WU Xiaomei

(School of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350116, China)

Abstract: The peak of short-circuit current is of great importance for selective protection of low-voltage distribution system and reliable breaking of circuit breaks. However, it is lack of intensive study now. Based on the early fault detection technology and the parameters analyzed by simulation, this paper concludes the main factors which influence the peak value by using grey correlation degree. Furthermore, the extreme learning machine (ELM) is used to forecast the peak value of fault current. Simulation results show that the grey correlation degree can identify the main factors of the short-circuit current effectively. And it can also reduce the dimensions of characteristic variable of short-circuit current. Finally, the short-circuit current prediction method based on the early fault detection and extreme learning machine shows strong robustness and high precision, which can lay the foundation for the realization of low-voltage selective protection technology.

This work is supported by National Natural Science Foundation of China (No. 51377023).

Key words: low-voltage distribution system; early fault detection; short-circuit current peak forecasting; grey correlation degree; extreme learning machine

0 引言

目前不论是传统的还是智能型的短路保护, 大多仍采用将决策函数值是否大于预先设置的门限值作为短路故障的判据, 当决策函数值小于门限值时则认为无故障发生, 反之则认为有故障发生, 并发出信号做出保护。但如果用此判据来判断是否发生短路故障, 则距故障发生的时刻已过了一定的时间。显然, 若可以在短路电流未达到峰值之前对其进行限制, 那么由短路故障对设备所造成的影响也会较小。所以, 为了可以快速而准确地分断短路电路,

短路故障早期检测作为短路故障辨识与快速切除的基础显得非常重要, 在此基础上实现短路电流峰值预测, 对选择性保护及其断路器可靠分断具有实际的工程价值^[1-4]。

现阶段低压配电系统短路故障的保护相对于故障发生时刻有一定的滞后, 在故障发生到故障切除的这段滞后时间内, 短路电流也会快速增长, 而断路器的开断能力是有限的, 所以对短路故障的电流峰值进行预测亦是十分重要的。

目前, 国内外对短路故障电流峰值预测研究极少, 主要有以下两个方法。遗传算法(Genetic Algorithm, GA)和支持向量机(Support Vector Machine, SVM)预测^[5]。其中, 基于GA和SVM预测方法以

短路故障发生后 0.2 ms 所检测到的故障信息为依据, 构建了基于 SVM 理论的短路电流峰值预测模型, 运用遗传算法对预测模型的有关关键参数进行优化以提高模型的预测准确度, 其编程实现复杂且循环寻优, 导致时间上延滞, 且对初始数据的选择有一定的依赖性; 基于灰色和 SVM 预测方法利用灰色关联度计算公式找出影响短路故障电流及其峰值的最主要因素, 提高预测的快速性, SVM 则解决了现实中小样本的问题, 使得对短路电流峰值的准确预测成为可能, 但其在求取支持向量过程中的二次优化运算的时间上较长。

本文在短路故障早期检测的基础上, 对短路电流峰值进行预测, 提出了基于灰色关联计算方法和极端学习机相结合的短路电流峰值预测模型。考虑到影响短路电流峰值的因素诸多且具备短路电流早期故障特征的因素, 如瞬时电流值、电压值、短路阻抗、故障初相角、电流变化率、电压变化率等, 通过灰色关联度计算确定影响短路电流峰值的主要因素, 并将其作为短路电流峰值预测模型的输入特征向量, 以提高短路电流峰值预测数学模型的预测精度与缩短预测模型计算时间; 利用极端学习机算

法进行短路电流峰值的预测, 具有运算速度快, 泛化能力强的特点, 且具备短路故障峰值预测精度高特点。

1 低压配电系统短路故障模型

1.1 模型的建立

如图 1 所示为低压配电系统的配电线路及其参数。

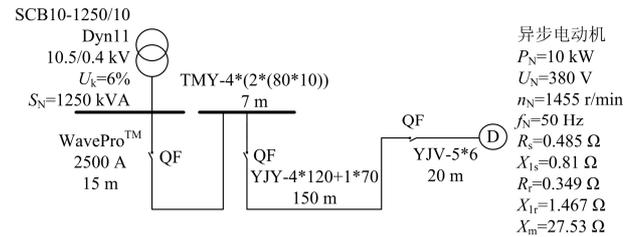


图 1 低压配电系统电路图

Fig. 1 Low voltage power distribution system circuit diagram

为明确故障相与非故障相的差别, 本文采用双支路来进行模拟仿真, 并基于 Matlab/Simulink 建立了如图 2 所示的单相低压短路故障仿真模型^[6-8]。

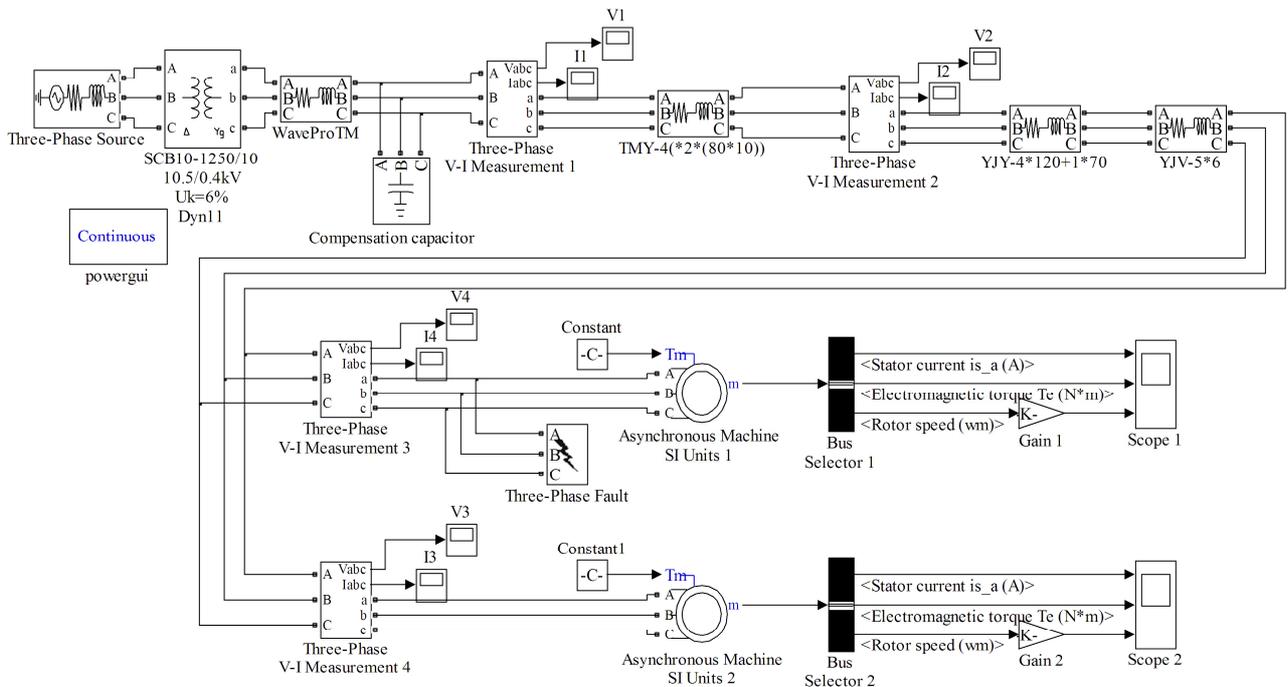


图 2 配电线路仿真模型

Fig. 2 Distribution circuit simulation model

1.2 短路电流波形分析

由图 3 所示的短路故障电流波形可知在不同的故障初相角下, 短路电流第一峰值也会随之变化,

即故障初相角的变化和短路电流峰值之间有密切的关系; 短路电流在故障后极短时间内是迅速上升的, 不及时且快速有效地分断会对电器设备产生严重危

害。图4为上述系统在故障初相角为108°时的短路故障波形及其故障放大图, 此时的短路故障特征最不明显。作者及课题组在短路故障早期检测方面, 已开展了大量研究与开发工作, 可在0.2 ms左右实现对低压短路故障的早期检测, 包括对故障特征不明显的故障相角^[9-14], 因此, 利用已有的短路早期检测技术, 侧重研究短路电流峰值预测。

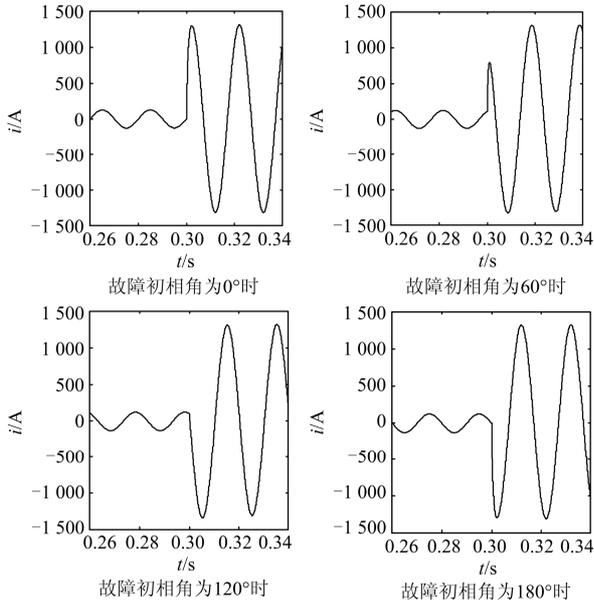


图3 不同故障初相角下的短路电流波形
Fig. 3 Short circuit current waveform under different fault initial angle

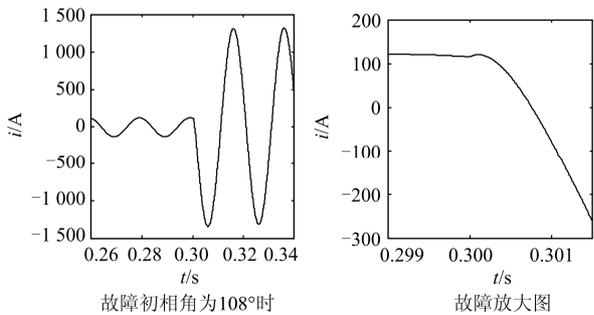


图4 故障初相角为108°时的短路电流波形
Fig. 4 Short circuit current waveform when the fault initial angle is 108°

2 基于灰色关联度的输入特征量确定

2.1 灰色关联度

灰色关联度通过对各因素的分析及对数据的处理, 在已知的因素序列中, 找出它们之间的连接关系, 发现其主要矛盾, 找到主要特性和主要影响因素。灰色关联度的步骤如下^[15-16]:

Step1 在已知的因素中确定出比较数列和参考数列;

Step2 计算每个参考数列中的每个元素与比较数列中相对应元素的关联系数;

Step3 将每列关联系数进行求平均值即为每个参考数列与比较数列的关联度;

Step4 对关联度进行比较并加以排序, 其中关联度最大的那项比较数列即是与参考数列最为紧密的数列。

设 $X_0 = \{X_0(k) / k = 1, 2, \dots, n\}$ 为参考数列, 即母数列, $X_i = \{X_i(k) / k = 1, 2, \dots, n\}$ 为比较数列, 即子数列, 则 $X_i(k)$ 与 $X_0(k)$ 的关联系数为

$$\xi_i(k) = \frac{\text{Min}_i \text{Min}_k |X_0(k) - X_i(k)| + \rho \text{Max}_i \text{Max}_k |X_0(k) - X_i(k)}{|X_0(k) - X_i(k)| + \rho \text{Max}_i \text{Max}_k |X_0(k) - X_i(k)|} \quad (1)$$

其中, $\rho \in (0, +\infty)$, 称为分辨系数, ρ 越小, 分辨能力越大, ρ 一般取为 0.5。 $|X_0(k) - X_i(k)|$ 称为第 k 个时刻(或指标、空间) X_0 与 X_i 的绝对差, $\text{Min}_i \text{Min}_k |X_0(k) - X_i(k)|$ 称为两级最小差, 其中 $\text{Min}_k |X_0(k) - X_i(k)|$ 为第一级最小差, 表示在 X_i 曲线上, 各相应点与 X_0 中各相应点的距离的最小值, $\text{Min}_i \text{Min}_k |X_0(k) - X_i(k)|$ 表示在各曲线找出的最小差的基础上, 再按 $i = 1, 2, \dots, m$, 找出所有曲线中最小差的最小差。

同样的 $\text{Max}_i \text{Max}_k |X_0(k) - X_i(k)|$ 为两级最大差, 其意义与两级最小差相同。则, 灰色关联度为

$$\gamma_i = \frac{1}{n} \sum_{k=1}^n \xi_i(k) \quad (2)$$

2.2 输入特征量提取

影响短路电流(峰值)的因素有很多, 如短路故障初相角 β 、故障 0.2 ms 后电流(基于 0.2 ms 实现短路故障早期检测)、故障相电压、电流变化率、电压变化率等等, 但是若把这些因素都作为输入特征量, 则可能会出现多余的干扰, 降低预测的准确率, 因此本文选用灰色关联算法来提取与短路电流峰值最为密切相关的输入特征量。

本文通过仿真获取样本数据, 并以短路电流峰值为参考数列, 其余各因素的数据(称为预输入特征量)为比较数列, 将数据导入灰色关联计算公式, 可得出每个比较数列与参考数列的密切程度(即关联度), 根据大小对关联度进行排序, 最大的则说明比

较数列与参考数列的发展趋势是最为一致的, 即此数列可作为输入特征量, 将提取的特征量输入 ELM 预测模型进行预测, 从而得到预测短路电流峰值。

2.3 样本数据

如前文所述, 本文所研究的短路电流峰值预测是在短路故障早期检测的基础上展开的, 越是较早地检测出短路故障, 越可以较早判断出短路电流峰值, 从而可以使断路器在未达到短路电流峰值之前即可开断故障线路, 保护其余支路正常运行。文献

[9]表明可以实现在 0.2 ms 时检测出短路故障, 因此, 将以故障发生后 0.2 ms 所检测到的故障信息作为依据, 实现对短路电流峰值的预测。

通过对上述单相短路故障模型进行仿真, 获取了 36 组不同故障初相角下的短路故障样本, 样本元素包括短路故障初相角、故障 0.2 ms 时的电流、故障相电压、电流变化率、电压变化率、短路电流峰值。36 组样本数据如表 1 所示。

表 1 样本数据

Table 1 Sample data

编号	故障初相角/ $^{\circ}$	故障电流/A	故障电压/V	电流变化率	电压变化率	短路电流峰值/A
1	5	426.61	0.83	1681 413.77	3 336.95	1 283.65
2	15	456.49	0.85	1 712 194.89	3 402.63	1 243.79
3	25	474.23	0.84	1 687 815.50	3 358.67	1 183.02
4	35	478.59	0.82	1 610 026.72	3 208.41	1 099.16
5	45	466.10	0.76	1 484 649.23	2 963.35	992.52
6	55	441.39	0.68	1 316 942.97	2 633.78	865.38
7	65	401.84	0.58	1 087 508.13	2 180.66	721.64
8	75	350.65	0.47	911 427.52	1 834.90	566.87
9	85	289.11	0.34	595 259.32	1 207.27	408.77
10	95	218.37	0.20	297 260.76	615.32	258.98
11	105	141.02	0.05	11 080.96	47.31	141.16
12	115	59.53	-0.10	286 077.83	543.10	-1 343.19
13	125	-23.93	-0.24	574 683.27	1 117.83	-1 342.04
14	135	-106.10	-0.38	855 438.28	1 677.47	-1 339.54
15	145	-185.66	-0.50	1 145 610.00	2 255.95	-1 335.47
16	155	-259.55	-0.62	1 343 039.56	2 651.96	-1 329.43
17	165	-325.80	-0.71	1 416 646.53	2 802.92	-1 320.52
18	175	-381.32	-0.78	1 601 880.38	3 174.57	-1 306.35
19	3	417.16	0.82	1 752 194.55	3 476.51	1 289.49
20	13	451.83	0.84	1 718 664.07	3 414.57	1 253.32
21	23	472.53	0.85	1 686 675.68	3 355.48	1 196.99
22	33	477.96	0.82	1 631 571.12	3 250.40	1 117.79
23	43	469.99	0.77	1 515 822.88	3 024.53	1 015.59
24	53	447.13	0.70	1 355 311.71	2 709.34	892.27
25	63	410.79	0.61	1 153 349.55	2 311.29	751.47
26	73	361.90	0.49	916 444.96	1 843.21	598.38
27	83	301.73	0.36	652 522.03	1 320.76	440.18
28	93	233.05	0.23	366 638.39	753.92	287.45
29	103	156.92	0.08	70 585.77	166.10	159.97
30	113	76.03	-0.07	227 034.72	425.62	-1 343.29
31	123	-7.33	-0.21	518 092.11	1 005.07	-1 342.38
32	133	-89.93	-0.35	793 597.20	1 554.37	-1 340.16
33	143	-170.77	-0.48	974 601.02	1 917.89	-1 336.42
34	153	-245.33	-0.59	1 263 570.42	2 493.87	-1 330.82
35	163	-313.80	-0.69	1 442 542.03	2 853.09	-1 322.61
36	173	-371.19	-0.76	1 579 978.92	3 130.21	-1 309.80

样本之所以选择故障初相角在 $0^{\circ}\sim 180^{\circ}$ 内的数据, 是因为故障相角在 $180^{\circ}\sim 360^{\circ}$ 内的短路电流的幅值与故障相角在 $0^{\circ}\sim 180^{\circ}$ 内的电流幅值一样, 只

是极性相反。在表 1 中, 故障电流、故障电压是在短路故障发生后 0.2 ms 的故障相电流、电压; 电流、电压变化率是故障后 0.2 ms 故障相电流、电压分别

对时间的导数。

2.4 输入特征量

在多个输入特征量之中, 它们与输出量之间的关联密切程度总会不同, 而极端学习机是一种小样本的机器学习方法, 对于小样本的训练学习具有很好的效果, 因此, 输入特征量的确定对短路电流峰值预测的效果起着很重要的作用。对于样本的选取时要使样本与预测输出密切相关, 尽量降低输入空间维数, 增加准确率, 获得更好地决策函数。

基于上述原则, 确定预测模型的预输入基本特征量为: 故障 0.2 ms 后电流、故障相电压、电流变化率、电压变化率。预输入特征量与输出量(短路电流峰值)的相关性, 在仿真波形分析和数据分析中得到了结论: 每个预输入特征量都与输出量有一定的相关性, 只是相关程度有大有小。运用灰色关联度来进行分析预输入特征量与输出量的关联是否紧密。若两个因素间发展趋势一致, 则两者的关联程度较高; 反之则较低。本文相对于短路故障初相角的发展, 计算上述各种故障因素与短路电流峰值之间的关联程度, 通过比较关联度的大小获取 ELM 预测模型的输入特征量。各个故障因素的关联度分析结果如表 2 所示。

表 2 各因素的关联度

Table 2 Correlation of various factors

预输入特征量	故障电流	故障电压	电流变化率	电压变化率
关联度	0.806 916	0.865 281	0.677 706	0.680 404

从表 2 灰色关联度分析结果可知, 故障电流、故障电压、电流一次变化率、电压一次变化率均与短路电流峰值有一定的关联性, 其中关联性最高的是故障电压。文中短路故障发生点是固定的, 所以其短路阻抗是确定的, 无法单纯考虑它对短路电流峰值的影响, 故本文不考虑短路阻抗作为短路电流的影响因素。因此, 确定短路故障初相角和故障电压作为 ELM 预测模型的输入特征量。

3 基于极端学习机的短路电流峰值预测

3.1 极端学习机

单隐藏层前馈神经网络(Single-hidden Layer Feedforward Neural Network, SLFN)具有很强的学习能力, 能够逼近复杂非线性函数, 且能够解决传统参数方法无法解决的问题, 但缺乏快速学习方法, 也使其很多时候无法满足实际需要^[17-18]。因此, 在此基础上提出了极端学习机学习方法。

极端学习机(ELM)是一种简单易用、有效的单

隐层前馈神经网络的学习算法^[17]。在传统的神经网络学习算法中, 如 BP 算法, 需要人为设置大量的网络训练参数, 很容易产生局部最优; 运算过程需要多次迭代, 训练速度慢。而极端学习机只需要设置网络的隐层节点个数, 在算法执行过程中不需要调整网络的输入权值以及隐元的偏置, 并且能够产生唯一的最优解, 参数选择较为容易, 具有学习速度快且泛化性能好的优点^[19-21]。

3.2 极端学习机原理

设有 N 个不同样本 (x_i, y_i) , 其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$, $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in R^m$ 。

设一个隐藏层有 L 个节点, 输入节点与第 j 个隐节点的连接权值为 $w_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T$, 第 j 个隐节点与输出节点的连接权值为: $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jm}]^T$, b_j 是第 j 个隐层节点的阈值, 则激励函数为 $g(x)$ 的 ELM 模型为

$$\sum_{i=1}^L \beta_j g(x_i) = \sum_{i=1}^L \beta_j g(w_j \cdot x_i + b_j) = y_i \quad (3)$$

其中, $i=1, 2, \dots, N$, $j=1, 2, \dots, L$, 激励函数 $g(x)$ 可以是“Radbas”、“Tribas”、“Tansig”、“Sigmoid”、“Sine”函数等。

ELM 的工作原理图如图 5 所示。

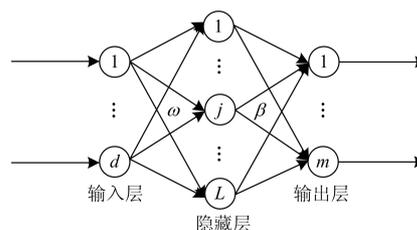


图 5 ELM 原理图

Fig. 5 Principle diagram of the ELM

3.3 峰值预测结果

本文选择隐藏神经元个数为 $N=10$, 而极端学习机的激励函数 $g(x)$ 选择较为常用的“Sigmoid”函数: $g(x)=1/(1+\exp(-x))$ 。

为了方便处理后面的数据, 避免奇异数据的出现, 也为了使程序在运行时加快收敛, 因此对实验的输入数据进行归一化处理, 即将输入数据一律归一化到 $[0, 1]$ 范围内。另外, 为了让输出的数量级与仿真中采取的短路电流峰值的数量级一致, 输出时再进行反归一化处理。在归一化处理中, 根据公式: $y=(x-MIN)/(MAX-MIN)$ 计算即可, 其中, x 为归一化处理之前的值, y 为归一化处理之后的值, MAX 和 MIN 分别是与 x 同组数据

内的最大值和最小值。ELM 短路电流峰值预测模型中的输入和输出数据如表 3、表 4 所示。

表 3 训练样本

Table 3 Training sample

编号	故障初相角/(°)	故障电压/V	短路电流峰值/A
1	5	0.83	1 283.65
2	15	0.85	1 243.79
3	25	0.84	1 183.02
4	35	0.82	1 099.16
5	45	0.76	992.52
6	55	0.68	865.38
7	65	0.58	721.64
8	75	0.47	566.87
9	85	0.34	408.77
10	95	0.20	2 58.98
11	105	0.05	141.16
12	115	-0.10	-1 343.19
13	125	-0.24	-1 342.04
14	135	-0.38	-1 339.54
15	145	-0.50	-1 335.47
16	155	-0.62	-1 329.43
17	165	-0.71	-1 320.52
18	175	-0.78	-1 306.35

表 4 测试样本及其测试精度

Table 4 Test sample and its accuracy

编号	故障初相角/(°)	故障电压/V	短路电流峰值/A	预测电流峰值/A	相对误差(%)
1	3	0.82	1 289.49	1289.16	0.025 76
2	13	0.84	1 253.32	1253.31	0.000 96
3	23	0.85	1 196.99	1196.85	0.011 70
4	33	0.82	1 117.79	1117.92	0.011 72
5	43	0.77	1 015.59	1015.61	0.002 74
6	53	0.70	892.27	892.17	0.011 73
7	63	0.61	751.47	751.52	0.006 39
8	73	0.49	598.38	598.54	0.025 93
9	83	0.36	440.18	439.24	0.213 59
10	93	0.23	287.45	287.07	0.131 51
11	103	0.08	159.97	160.66	0.435 47
12	113	-0.07	-1 343.29	-1 343.24	0.003 47
13	123	-0.21	-1 342.38	-1 342.37	0.001 07
14	133	-0.35	-1 340.16	-1 340.16	0.000 25
15	143	-0.48	-1 336.42	-1 336.44	0.001 22
16	153	-0.59	-1 330.82	-1 330.83	0.000 39
17	163	-0.69	-1 322.61	-1 322.72	0.008 43
18	173	-0.76	-1 309.80	-1 309.79	0.000 35

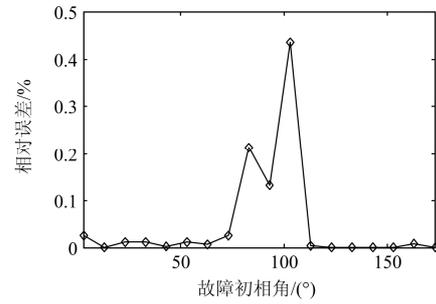


图 6 相对误差

Fig. 6 Relative error

将相对误差转化为图表，如图 6 所示，可以更加明确地看出，用 ELM 峰值预测模型预测出的短路电流峰值非常接近于仿真中采取的短路电流峰值，其相对误差均不超过 1%，表明 ELM 峰值预测模型的可行性，且说明基于故障早期检测及 ELM 的短路电流峰值预测的有效性。

由于 ELM 的隐含层神经元的参数是随机产生的，所以 ELM 每次的输出结果都会略有不同，现按上述 ELM 短路电流峰值预测模型，在同一故障初相角下，对输入特征量分别为故障电压、故障电流各测试 50 次，得到每一次的相对误差，找出各个故障初相角下在这 50 次中最大的相对误差并记录，如表 5 所示。

表 5 各故障初相角下的最大相对误差

Table 5 Maximum relative error under different fault

故障初相角/(°)	initial angle	
	50 次测试中最大的相对误差(%)	
	输入特征量: 故障电压	输入特征量: 故障电流
3	2.584 73	3.679 61
13	0.295 06	0.475 96
23	0.296 25	0.741 66
33	0.104 98	0.426 15
43	0.039 55	0.117 58
53	0.048 87	0.285 88
63	0.053 51	0.077 97
73	0.083 83	0.382 89
83	0.901 88	2.009 63
93	0.463 78	0.957 12
103	0.829 24	2.679 47
113	0.020 26	0.020 27
123	0.002 39	0.002 01
133	0.003 31	0.005 04
143	0.012 59	0.022 47
153	0.000 71	0.000 68
163	0.022 30	0.019 93
173	0.005 47	0.006 93

根据表 5 可知, 以故障电压为输入特征量时, 在故障初相角为 3° 时存在最大相对误差: 2.58473%, 其余初相角下的误差甚至小于 1%; 而以故障电流为输入特征量时, 其最大相对误差虽然略大于故障电压, 但也在工程误差范围之内(5%), 由此可见, ELM 短路电流峰值预测模型具有鲁棒性强、准确度高的特点。

4 结论

本文基于短路故障早期检测技术, 对低压配电系统开展单相短路电流峰值预测研究, 得出以下研究结果。

(1) 建立了低压配电系统短路故障仿真模型, 分析了短路故障波形特征。

(2) 鉴于初相角对故障短路影响的重要性, 对故障初相角以外的短路早期故障电气参数如故障电流、故障电压、电流变化率、电压变化率等加以灰色关联度分析, 得出早期短路故障检测瞬间的故障电压与短路电流峰值关联度密切。

(3) 以故障初相角和故障电压为特征量输入, 利用 ELM 建立了短路峰值预测模型, 仿真结果表明, 早期故障检测的 ELM 短路电流峰值预测方法, 不仅输入量少, 且预测精度较高, 具备实时在线预测的可行性。

参考文献

- [1] 陈德桂. 智能电网与低压电器智能化的发展[J]. 低压电器, 2010(5): 1-6.
CHEN Degui. Smart grid and recent development of intelligent low voltage electrical apparatus[J]. Low Voltage Apparatus, 2010(5): 1-6.
- [2] 张毅威, 丁超杰, 闵勇, 等. 欧洲电网发展中的研究与创新方向[J]. 电网与清洁能源, 2014, 30(3): 5-11.
ZHANG Yiwei, DING Chaojie, MIN Yong, et al. Direction of research and innovation in the development of European power grid[J]. Power System and Clean Energy, 2014, 30(3): 5-11.
- [3] 许偲轩, 陆于平. 分布式发电智能电网的充分式保护原理与方法[J]. 电力系统保护与控制, 2014, 42(22): 18-23.
XU Sixuan, LU Yuping. Sufficient criterion protection theory and method for distributed generating smart grid[J]. Power System Protection and Control, 2014, 42(22): 18-23.
- [4] 董开松, 谢永涛, 贾嵘, 等. 面向主动式配网的微电网技术探究[J]. 高压电器, 2015, 51(6): 97-100.
DONG Kaisong, XIE Yongtao, JIA Rong, et al. Research on microgrid technology for active distribution network[J]. High Voltage Apparatus, 2015, 51(6): 97-100.
- [5] 王进超. 低压配电系统短路故障电流峰值预测方法的研究[D]. 福州: 福州大学, 2012.
WANG Jinchao. Research on prediction method for short-circuit fault current peak value[D]. Fuzhou: Fuzhou University, 2012.
- [6] 中国航空工业规划设计研究院. 工业与民用配电设计手册[M]. 北京: 中国电力出版社, 2005.
- [7] 王晶, 翁国庆, 张有兵. 电力系统的 MATLAB/SIMULINK 仿真与应用[M]. 西安: 西安电子科技大学出版社, 2008.
- [8] 王希平, 李文才, 李燕, 等. 基于 Simulink 配电变压器模型的建立及仿真[J]. 自动化技术与应用, 2009, 28(9): 124-126, 132.
WANG Xiping, LI Wencai, LI Yan, et al. The building and emulation of distribution transformer model based on Simulink[J]. Techniques of Automation and Applications, 2009, 28(9): 124-126, 132.
- [9] 陈丽安, 张培铭, 缪希仁. 基于小波变换的低压系统短路故障的早期预测[J]. 电工技术学报, 2003, 18(2): 91-94.
CHEN Li'an, ZHANG Peiming, MIAO Xiren. Prediction for the short-circuited fault based on wavelet transform[J]. Transactions of China Electrotechnical Society, 2003, 18(2): 91-94.
- [10] 龙虹毓, 张晓勇, 胡晓锐, 等. 蚁群优化小波阈值算法用于变电设备状态信号提取[J]. 电工技术学报, 2015, 30(12): 422-428.
LONG Hongyu, ZHANG Xiaoyong, HU Xiaorui, et al. Extraction of condition signals of electrical plants by ACO wavelet threshold estimation[J]. Transactions of China Electrotechnical Society, 2015, 30(12): 422-428.
- [11] 田小静, 冯雨, 郭英杰, 等. 基于小波变换和形态学细化算法的真空电弧形态检测[J]. 电工技术学报, 2015, 30(11): 110-114.
TIAN Xiaojing, FENG Yu, GUO Yingjie, et al. Morphological detection of vacuum switching arc based on wavelet transform and morphology edge thinning[J]. Transactions of China Electrotechnical Society, 2015, 30(11): 110-114.
- [12] 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. Method of cable incipient faults detection and identification based on multiscale wavelet criterions and time-frequency feature association[J]. Power System Protection and

Control, 2015, 43(9): 115-123.

[13] 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.

[14] 吴晓梅, 缪希仁. 短路故障早期检测及其趋势预测研究[D]. 福州: 福州大学, 2015.

WU Xiaomei, MIAO Xiren. Research on early detection and trend prediction for short-circuit fault[D]. Fuzhou: Fuzhou University, 2015.

[15] 刘思峰, 党耀国, 方志耕, 等. 灰色系统理论及其应用[M]. 北京: 科学出版社, 2010.

[16] 陈金强, 李群湛. 基于灰色 TOPSIS 和 DGA 的变压器状态预测[J]. 高压电器, 2015, 51(9): 39-43.

CHEN Jinqiang, LI Qunzhan. Transformer condition prediction model based on gray-TOPSIS and DGA[J]. High Voltage Apparatus, 2015, 51(9): 39-43.

[17] 赖大虎, 黄宴委. 基于极端学习机的胶囊缺陷检测[J]. 福州大学学报(自然科学版), 2012, 40(4): 489-494.

LAI Dahu, HUANG Yanwei. Inspection for defected capsules based on extreme learning machine[J]. Journal of Fuzhou University (Natural Science Edition), 2012, 40(4): 489-494.

[18] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: a new learning scheme of feedforward neural networks[J]. Neural Networks, 2004(2): 985-990.

[19] 武峰雨, 乐秀璠, 南东亮. 相空间重构的极端学习机短期风速预测模型[J]. 电力系统及其自动化学报, 2013, 25(1): 136-141.

WU Fengyu, LE Xiufan, NAN Dongliang. A short-term wind speed prediction model using phase-space reconstructed extreme learning machine[J]. Proceedings of the CSU-EPSCA, 2013, 25(1): 136-141.

[20] 刘念, 张清鑫, 刘海涛. 基于核函数极限学习机的微电网短期负荷预测方法[J]. 电工技术学报, 2015, 30(8): 218-224.

LIU Nian, ZHANG Qingxin, LIU Haitao. Online short-term load forecasting based on ELM with kernel algorithm in microgrid environment[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 218-224.

[21] 邓万字, 郑庆华, 陈琳, 等. 神经网络极速学习方法研究[J]. 计算机学报, 2010, 33(2): 279-287.

DENG Wanyu, ZHENG Qinghua, CHEN Lin, et al. Research on extreme learning of neural networks[J]. Chinese Journal of Computers, 2010, 33(2): 279-287.

收稿日期: 2015-06-14; 修回日期: 2015-11-23

作者简介:

邗萍(1992-), 女, 硕士研究生, 研究方向为电器及其系统智能化技术; E-mail: 1540049048@qq.com

缪希仁(1965-), 男, 博士, 教授, 主要研究方向为电器及其系统智能化技术、电气设备在线监测与诊断、新型电器技术;

吴晓梅(1990-), 女, 硕士研究生, 主要研究方向为智能电器及在线监测技术。

(编辑 姜新丽)