

基于卷积神经网络算法的高压断路器故障诊断

黄新波, 胡潇文, 朱永灿, 魏雪倩, 周 岩, 高 华

(西安工程大学 电子信息学院, 陕西 西安 710048)

摘要:传统的高压断路器故障诊断方法太过于依赖经验,不能准确地反映特征量和故障模式之间的关系,诊断准确度不高。针对这个问题,采用卷积神经网络算法进行高压断路器故障诊断,结合高压断路器分合闸线圈电流特点建立诊断模型,通过输入零点故障特征参数进行学习训练,得到相应故障类型输出。仿真结果表明,所提算法的整体准确率高达93.68%,与其他基于神经网络的算法相比具有很大的优势。

关键词:断路器; 高压断路器; 卷积神经网络; 分/合闸线圈电流; 故障诊断

中图分类号: TM 56

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2018.05.020

0 引言

高压断路器是电力系统最主要的控制与保护装置,关系到输电、配电及用电的可靠性、安全性。高压断路器可以实现多种操作,在系统故障或者非故障情况下,高压断路器应能关合、开断、承载运行回路运行电流^[1]。高压断路器一旦发生故障,会对断路器所控制和保护的下一级电网造成损坏,也会引起上一级电网波动,可能造成大面积停电,甚至会发生爆炸等严重事故,对社会各行业造成巨大的损失;高压断路器故障主要包括拒动、误动、开断与关合故障、绝缘故障等。针对该故障已有的检测方法也有很多,其中包括超声检测技术、SF₆ 设备气体在线检测技术、动态回路电阻测试技术以及分合闸线圈电流波形分析技术。

高压断路器分合闸时的线圈电流含有丰富的运行状态信息,可作为高压断路器机械故障诊断的依据,但由于断路器故障与电流波形并不是简单的线性关系,无法直接通过阈值判断,需要通过人工智能算法,如模糊理论、径向基神经网络、BP 神经网络等进行故障诊断。但是基于 BP 神经网络算法的故障诊断存在一定程度的收敛速度慢、容易陷入局部极小值的缺点^[2];模糊控制的隶属函数和模糊规则的确定过程存在一定的人为因素^[3];径向基神经网络为断路器的故障诊断问题提供了较好的结构体系,但存在着无法解释自身推理过程和推理依据,以及数据不充分时神经网络无法正常工作的缺点^[4]。本文采用卷积神经网络 CNN(Convolutional Neural Net-

work)算法进行高压断路器故障诊断,该算法的自适应性好、运行速度快,具有良好的容错、并行处理和自学习能力,可以更好地处理信息复杂、背景知识模糊、推理规则不明确情况下的问题^[5-6],避免了传统算法中复杂的特征提取和数据重建过程。

1 基于分合闸线圈电流的高压断路器故障原理

从高压断路器开始动作一直到动作完全结束,机械操动机构的整个动作过程都反映在高压断路器直流控制回路的电流波形上,通过监测线圈电流可以了解高压断路器机械操动机构的变动情况。电流值 I_1 、 I_2 、 I_3 分别反映了电源电压、线圈电阻及电磁铁铁芯运动的速度信息,也可作为分析动作的参考。因此,通过实时记录每次高压断路器动作过程中线圈电流的波形,即可计算机械操动机构的启动时间、线圈通电时间等,并可根据高压断路器自身的参数范围,比较判断机械操动机构是否已有铁芯空行程、弹簧卡滞等故障。典型的分合闸线圈电流特性曲线如图 1 所示,通过 5 个关键时间节点将电流曲线分为 5 段,其中任何一段出现差异都表明高压断路器的动作发生异常^[7]。




图1 分合闸线圈电流的特性曲线

Fig.1 Characteristic curve of opening and closing coil currents

在时间段 t_0-t_5 内,高压断路器线圈电流的特性曲线分别表示了5种不同的状态: t_0-t_1 时间段的线圈电流特性曲线反映了线圈的状态; t_1-t_2 时间段的线圈电流的变化表征铁芯运动结构有无卡涩、脱扣、释能机械负载变动的情况; t_2 一般为动触头开始运动时刻,从 t_2 以后是机械操动机构通过传动系统带动动触头分、合闸的过程,即动触头运动的过

收稿日期:2017-06-15;修回日期:2018-03-05

基金项目:国家自然科学基金资助项目(51177115);陕西省重点科技创新团队计划资助项目(2014KCT-16);西安工程大学控制科学与工程重点学科建设经费资助项目(107090811)
Project supported by the National Natural Science Foundation of China(51177115), Key Technology Innovation Team Project of Shaanxi Province(2014KCT-16) and Key Disciplines Science and Engineering Project of Xi'an Polytechnic University(107090811)

程; t_4 为断路器的辅助触点切断的时刻; t_0-t_4 时间段内线圈电流的变化可以反映机械操动机构传动系统的工作情况^[8-10]。上述对线圈电流特性曲线的分析可为基于卷积神经网络的高压断路器故障诊断模型提供大量的样本数据,同时也为实际的高压断路器故障在线监测提供参考理论知识。

2 基于卷积神经网络的断路器故障诊断方法

2.1 卷积神经网络

在模式分类领域,卷积神经网络可以避免复杂的特征量前期预处理,直接输入原始数据即可得到输出结果,因此得到了更为广泛的应用^[11]。卷积神经网络由输入层、卷积层、抽样层、全链接层和输出层组成,如图2所示。卷积层 C_1 对输入层所输入数据进行卷积后输出;同时,又作为抽样层 S_2 的输入,经过采样方法之后输出;依此类推,便可得到最后的输入。




图2 卷积神经网络的结构

Fig.2 Structure of CNN

卷积过程通过确定滤波器的大小,采用卷积核 K_{ij} 对上一层滤波器的一个特征进行加权得到 $x_i * K_{ij}$,然后对 $x_i * K_{ij}$ 进行求和后加偏置,如式(1)所示。

$$x_j^l = f(\sum_{i=M_j} x_i^{l-1} * K_{ij}^l + B^l) \quad (1)$$

其中, x_i^{l-1} 为上一层滤波器中的某个特征; $f(x)$ 为sigmoid函数; M_j 为神经元 j 对应的滤波器; K_{ij}^l 为第 l 层的神经元 i 的第 j 个对应权值; B^l 为第 l 层的唯一偏置。

抽样层采用 mean-pooling 对滤波器中的所有值求均值;然后将采样的信息乘以可训练参数,再加上可训练偏置,通过激活函数(采用 sigmoid 函数)计算得到的结果,即可得到神经元的输出^[12-13]。

$$x_j^l = f(\beta^l \sum_{i=M_j} x_i^{l-1} + B^l) \quad (2)$$

其中, β^l 为第 l 层的可训练参数。

对于全链接层,直接采用多层人工神经网络的方法进行计算:

$$x_j^l = f(\sum_{i \in l-1} w_{ji} x_i^{l-1} + B^l) \quad (3)$$

其中, w_{ji} 为第 l 层的节点 j 到第 $l+1$ 层的节点 i 的权值。

2.2 样本数据的确定

通过查阅文献、现场运行的在线监测装置及高压断路器实验平台获取机构正常、操作电压过低、合闸铁芯开始阶段有卡涩、机械操动机构有卡涩及合闸铁芯空行程过大这5种设备状态的样本数据^[14];以 t_0 为命令时间的零点提取高压断路器机械特性故障特征参数 $I_1, I_2, I_3, t_1, t_2, t_3, t_4, t_5$,如图1所示。

高压断路器状态的输出采用向量和序号来表示,具体如表1所示。

表1 故障类型输出表示

Table 1 Representation of fault type outputs

故障类型	状态表示方式	
	向量	序号
机构正常	10000	1
操作电压过低	01000	2
合闸铁芯开始阶段有卡涩	00100	3
机械操作机构有卡涩	00010	4
合闸铁芯空行程过大	00001	5

2.3 基于卷积神经网络的高压断路器故障诊断模型

基于卷积神经网络算法的高压断路器故障诊断流程如图3所示。该模型将100组故障样本数据输入为5类状态类型对应的样本数据,同时将这些样本数据分为2组,一组作为训练样本,另一组作为测试样本。具体流程如下。

a. 进行网络参数初始化,然后输入分类后的训练样本,进行卷积神经网络训练学习,初始化权值,




图3 基于卷积神经网络算法的高压断路器故障诊断流程

Fig.3 Flowchart of fault diagnose based on CNN algorithm for HV breaker

即将所有权值初始化为 1 个较小的随机数。

b. 提取样例,从训练集中提取 1 个样例 X ,并给出它的目标输出向量。

c. 从前层向后层依次计算得到卷积神经网络的输出;然后反向(即从后层向前层)依次计算各层的误差项,直至误差低于所设定的阈值,最后得到理想的预期输出^[15-16]。

对模型进行一系列的训练学习后,将另一组测试样本数据作为输入进行诊断监测,利用最终得到的仿真结果对模型的诊断效果进行校验。

3 实验与仿真分析

3.1 实验平台

为了更加准确地采集用于训练的高压断路器故障数据,本文搭建高压断路器智能化装置的实验平台,选用 VJY-12P/T630-25-210(Z) 型户内真空高压断路器作为被测设备(下文简称被测高压断路器)。通过智能化装置对被测高压断路器的运行状况进行监测与分析,并将所得结果上传至监控中心主机。

完成对实验平台的安装调试后,对被测高压断路器的各个机械特征进行采集,所采集的分/合闸线圈电流波形经处理后分别如图 4(a)、(b)所示。

对图 4 中所采集的电流波形进行特征提取后上传至智能化装置监控中心主机,得到更加直观的机械特性参数,以便对其进行进一步对其进行建模训练和验证。部分训练样本和测试样本分别如表 2、表 3 所示。

3.2 仿真分析

首先根据已有的故障分析方法得出实验监测数据所对应的故障类型,结合表 2 进行建模训练学习




图 4 分合闸线圈电流波形

Fig.4 Waveforms of opening and closing coil currents

直至系统完全达到预期目标;然后进一步将本文实验得到的 50 组故障数据进行仿真分析,其中的部分测试数据如表 3 所示。由图 5 所示的仿真数据可以看出:采用第 1 类状态,即机构正常状态下的 10 组样本数据时,模型准确率为 100%;采用第 2 类状态,即操作电压过低状态下的 11 组样本数据时,模型准确率为 90.9%;采用第 3 类状态,即合闸铁芯开始阶段有卡涩状态下的 8 组样本数据时,模型准确率为 87.5%;采用第 4 类状态,即机械操动机构有卡涩状态下的 10 组样本数据时,模型准确率为 90%;采用第 5 类状态,即合闸铁芯空行程过大状态下的 11 组样本数据时,模型准确率为 100%。

将卷积神经网络算法与其他智能算法的运算结

表 2 部分训练样本

Table 2 Partial training samples

样本序号	I_1/A	I_2/A	I_3/A	t_1/ms	t_2/ms	t_3/ms	t_4/ms	t_5/ms	故障类型序号
1	1.61	1.15	2.16	24.54	37.76	43.49	43.50	50.32	1
2	1.64	1.15	2.20	24.67	37.76	43.37	43.86	51.05	1
3	1.27	0.89	1.79	23.60	36.77	42.17	45.80	49.98	2
4	1.27	0.98	1.86	26.06	36.46	42.19	45.77	50.03	2
5	1.59	1.15	2.17	30.21	43.08	49.54	52.62	55.79	3
6	1.64	1.10	2.24	30.12	43.31	49.06	52.19	55.96	3
7	1.60	1.10	2.09	24.27	37.56	43.56	51.08	54.31	4
8	1.60	1.10	2.17	24.97	37.26	43.39	51.08	54.41	4
9	1.64	1.13	2.20	24.06	39.99	42.89	45.87	49.77	5
10	1.64	1.13	2.20	24.86	39.08	42.96	45.77	49.89	5

表 3 部分测试样本

Table 3 Partial testing samples

样本序号	I_1/A	I_2/A	I_3/A	t_1/ms	t_2/ms	t_3/ms	t_4/ms	t_5/ms	故障类型序号
1	1.63	1.15	2.20	24.59	37.76	43.57	43.57	50.35	1
2	1.29	0.92	1.82	23.76	36.59	42.26	45.81	49.98	2
3	1.59	1.05	2.27	30.12	43.55	49.21	52.33	55.87	3
4	1.60	1.13	2.17	24.28	37.43	43.36	51.11	54.39	4
5	1.64	1.13	2.20	24.15	39.73	42.82	45.94	49.82	5




图5 卷积神经网络模型测试结果

Fig.5 Testing results of CNN model


果进行比较,结果如表4所示。由表4可见,卷积神经网络的高压断路器故障监测结果相对实际预期结果的准确率达93.68%,相对其他神经网络具有很大的优势。

表4 算法对比结果

Table 4 Results of comparison among algorithms

故障类型 编号	测试 样本数	准确率/%		
		DAG-SVM 算法	BP 神经网络	卷积神经网络算法
1	10	80.00	90.00	100
2	11	81.80	90.90	90.90
3	8	87.50	100	87.50
4	10	90.00	90.00	90.00
5	11	90.90	81.80	100
准确率 平均值	—	86.04	90.54	93.68

卷积神经网络故障诊断训练校验以及测试时的均方误差曲线如图6所示,由图6可以看出在卷积神经网络的训练过程中,整个网络的误差曲线快速下降,卷积神经网络的训练学习具有良好的收敛性。



①训练,②校验,③测试,④最优

图6 均方值误差曲线

Fig.6 Curve of mean square error

4 实验结果分析


为进一步证明本文基于卷积神经网络的高压断路器故障诊断模型性能,将本文算法与BP神经网络及DAG-SVM算法的高压断路器故障监测模型^[17-18]进行对比。对同一组数据进行测试,所得结果见表4。

由表4可见:本文算法的准确率较高,在高压断路器故障诊断方面相比较其他神经网络具有很大的优势;同时,在各个模型运行中,DAG-SVM算法时间最短,但准确率较低,本文算法运行时间高于BP神经网络算法,且准确率较高;故障类型3的诊断结果相比较于其他故障类型的准确率比较低,主要原因是因为所分组的训练故障数据和测试故障数据极为


接近,卷积神经网络不能在这2组数据中进行很好的比较分析,误差不能完全达到要求。

5 现场运行分析

通过上述验证可以看出本文方法在高压断路器故障检测中得到了有效的应用,且与其他算法相比具有一定的优越性。本文算法已经升级应用到笔者前期研发的智能变电站在线监测技术中^[19],在一次断路器动作过程中得到的断路器分合闸线圈电流,如图7所示。



(a) 合闸线圈电流



(b) 分闸线圈电流

图7 现场实时监测分合闸线圈电流波形

Fig.7 Waveforms of opening and closing coil currents obtained by field monitoring

运行在监控中心的专家软件对实时分合闸线圈电流进行特征提取,得到重要参数见表5。利用本文提出的基于卷积神经网络算法的高压断路器故障诊断模型,发现该高压断路器存在合闸铁芯空行程太大的情况,如图8所示。

表5 分合闸线圈电流特征参数

Table 5 Parameters of opening and closing coil currents

过程	时间/ms	电流/A	速度/ (m·s ⁻¹)	行程/ mm	开距/ mm	超程/ mm
分闸	24.53	1.13	6.23	208.0	191.19	16.81
合闸	49.69	2.20	3.18	208.0	177.80	30.19




图8 专家软件结果显示界面

Fig.8 Interface of results display by expert software

经过工作人员分析,判断造成该高压断路器存在合闸铁芯空行程太大的原因是高压断路器热风幕

损坏,使储能变速箱内的润滑脂凝固。随后检修人员更换了热风幕,经再次监测发现数据合格,且该高压断路器机构性能恢复正常。


6 结语

本文提出了一种基于卷积神经网络的高压断路器故障检测算法。实验仿真结果表明,卷积神经网络算法的训练学习具有良好的收敛性,以及自学习能力、并行处理能力和容错能力,可更加快速准确地应用在故障识别方面,整体准确率达93.68%,相比较于其他神经网络算法具有很大的优势。但是,卷积神经网络对实际应用中的高压断路器的故障类型监测仍存在着不太理想的结果,主要原因是实际应用中高压断路器存在着严重的人为因素,而且在实验中所得到的数据非常少。随着高压断路器故障知识的逐渐积累,卷积神经网络一直能够扩张学习,增加故障类型样本训练,通过网络的深度学习,逐步提高故障识别准确率,可为高压断路器故障在线监测提供很好的方法。但是根据当前高压断路器的运行状态和对下一步运行状态的诊断,使高压断路器始终保持最佳运行状态尤其需要进一步的研究。

参考文献:

- [1] 杜凌艳,王振浩,王刚,等. 高压断路器运行状态实时监测系统[J]. 电力自动化设备,2006,26(1):58-61.
DU Lingyan, WANG Zhenhao, WANG Gang, et al. Design of real-time operating state monitoring system for HV breaker[J]. Electric Power Automation Equipment, 2006, 26(1): 58-61.
- [2] 陈莉,田书. 基于BP和RBF神经网络在高压断路器故障诊断中的应用[J]. 煤矿机电,2013(3):8-11.
CHEN Li, TIAN Shu. Application of fault diagnosis in high voltage circuit breaker based on BP and RBF neural network[J]. Colliery Mechanical & Electrical Technology, 2013(3): 8-11.
- [3] 国连玉,李可军,梁永亮,等. 基于灰色模糊综合评判的高压断路器状态评估[J]. 电力自动化设备,2014,34(11):161-167.
GUO Lianyu, LI Kejun, LIANG Yongliang, et al. HV circuit breaker state assessment based on gray-fuzzy comprehensive evaluation[J]. Electric Power Automation Equipment, 2014, 34(11): 161-167.
- [4] 胡晓光,齐明,纪延超,等. 基于径向基函数网络的高压断路器在线监测和故障诊断[J]. 电网技术,2001,25(8):41-44.
HU Xiaoguang, QI Ming, JI Yanchao, et al. On-line monitoring and fault diagnosis in high voltage circuit breakers based on radial basis function networks[J]. Power System Technology, 2001, 25(8): 41-44.
- [5] IJINA E P, CHALAVADI K M. Human action recognition using genetic algorithms and convolutional neural networks[J]. Pattern Recognition, 2016, 59(11):199-212.
- [6] TOMÈ D, MONTI F, BAROFFIO L, et al. Deep convolutional neural networks for pedestrian detection[J]. Image Communication, 2015, 47(C):482-489.
- [7] 杨凌霄,朱亚丽. 基于概率神经网络的高压断路器故障诊断[J]. 电力系统保护与控制,2015,43(10):62-67.
YANG Lingxiao, ZHU Yali. High voltage circuit breaker fault diagnosis of probabilistic neural network[J]. Power System Protection and Control, 2015, 43(10): 62-67.
- [8] 黄新波,陶晨,刘斌. 智能断路器机械特性在线监测技术和状态评估[J]. 高压电器,2015,51(3):129-134,139.
HUANG Xinbo, TAO Chen, LIU Bin. On-line monitoring technology of mechanical properties and state evaluation method for intelligent circuit breaker[J]. High Voltage Apparatus, 2015, 51(3): 129-134, 139.
- [9] CHAO Fu, JING Hao. On-line monitoring system based on vibration signal of high voltage circuit breaker[J]. Journal of Multimedia, 2014, 9(4):34-41.
- [10] 胡晓光,孙来军,纪延超. 基于线圈电流和触点状态的断路器故障分析[J]. 电力自动化设备,2006,26(8):5-7,11.
HU Xiaoguang, SUN Laijun, JI Yanchao. Circuit breaker fault analysis based on coil currents and contact states[J]. Electric Power Automation Equipment, 2006, 26(8): 5-7, 11.
- [11] 李旭冬,叶茂,李涛. 基于卷积神经网络的目标检测研究综述[J]. 计算机应用研究,2017,34(10):1-9.
LI Xudong, YE Mao, LI Tao. Review of object detection based on convolutional neural networks[J]. Application Research of Computers, 2017, 34(10): 1-9.
- [12] 胡正平,陈俊岭,王蒙,等. 卷积神经网络分类模型在模式识别中的新进展[J]. 燕山大学学报,2015,39(4):283-291.
HU Zhengping, CHEN Junling, WANG Meng, et al. Recent progress on convolutional neural network in pattern recognition[J]. Journal of Yanshan University, 2015, 39(4): 283-291.
- [13] 李彦冬,郝宗波,雷航. 卷积神经网络研究综述[J]. 计算机应用,2016,40(9):2508-2515.
LI Yandong, HAO Zongbo, LEI Hang. Survey of convolutional neural network[J]. Journal of Computer Applications, 2016, 40(9): 2508-2515.
- [14] 黄新波. 变电设备在线监测与故障诊断[M]. 北京:中国电力出版社,2013:9-27.
- [15] DENG L, YU D. Deep learning methods and applications[J]. Foundations & Trends in Signal Processing, 2014, 7(3):197-387.
- [16] 彭雅琴,成孝刚. 一种优化的卷积神经网络深度学习算法[J]. 现代电子技术,2016,39(23):1-3.
PENG Yaqin, CHENG Xiaogang. An optimized deep learning algorithm of convolutional neural network[J]. Modern Electronics Technique, 2016, 39(23): 1-3.
- [17] 黄新波,李文君子,宋桐,等. 基于DGA技术和SAMME的变压器故障诊断[J]. 高压电器,2016,52(2):13-18.
HUANG Xinbo, LI Wen Junzi, SONG Tong, et al. Fault diagnosis of transformer based on SAMME and DGA method[J]. High Voltage Apparatus, 2016, 52(2): 13-18.
- [18] 李东敏,刘志刚,苏玉香,等. 基于多小波包和人工神经网络的电力系统故障类型识别[J]. 电力自动化设备,2009,29(1):99-103.
LI Dongmin, LIU Zhigang, SU Yuxiang, et al. Multi-objective economic load dispatching based on chaos genetic algorithm and fuzzy decision[J]. Electric Power Automation Equipment, 2009, 29(1): 99-103.
- [19] 黄新波. 智能变电站原理与应用[M]. 北京:中国电力出版社,2012:246-268.

作者简介:



黄新波

黄新波(1975—),男,山东海阳人,教授,博士研究生导师,博士后,从事智能电网输变电设备在线监测理论与关键技术、无线网络传感器等方面的研究(E-mail: huan-gxb1975@163.com);

胡潇文(1994—),男,甘肃庆阳人,硕士(下转第147页 continued on page 147)

表3 故障特征关联因素分析

Table 3 Correlation factor analysis of fault characteristics

类型	最优故障特征子集	剔除故障特征	类型	最优故障特征子集	剔除故障特征
故障因素	f_1-f_6	—	自身因素	$f_{15}-f_{17}$	$f_{18}-f_{20}$
外部因素	f_7-f_{14}	—	运行因素	$f_{21}-f_{25}$	$f_{26}-f_{28}$

采用 Relief 算法可以计算得到所有特征值的权重大小,如图2所示。本文作为特征筛选阈值的设定遵循统计学计算的经验,即将这些权重值归一化为 $[0,1]$ 的值。基于统计的置信区间的概念,通常95%的置信水平是大概率事件,因此,可以假设特征的权重值大小表示该特征所包含整个特征集中信息量的多少,那么,如果信息的累积比例达到95%,则可以认为这些特征包含了全体特征集合的大部分信息量,同时,这些特征可以被认为是最重要的。根据这一假设,门槛值 τ 的设定规则如下:归一化权重值已经按照降序进行排序并累加计算,当计算停止时,该累积值达到95%;上述假设中所提到的通过 Relief 算法计算的权重值表示特征的重要程度,因此,当累加计算停止时,所对应的归一化的权重值就可以设定为特征筛选阈值 τ 。图2中的虚线即为通过计算得到的阈值 τ ,因此,这里被筛选剔除的关联度较低的特征为 $\{f_{18}, f_{19}, f_{20}, f_{26}, f_{27}, f_{28}\}$ 。




图2 特征权重值

Fig.2 Weighted values of characteristics

从特征选择的结果来看,与馈线故障直接相关的故障特征全部得以保留,它们代表了故障的时间特征、地域特征、故障自相关因素等,它们与故障强相关且相互独立。而在自身和运行因素2类故障特征中均存在一些冗余因素得以有效的剔除,说明了本文所提方法的选择性和有效性。从关联因素分析结果还可看出,馈线的故障情况不仅与馈线长度和负荷情况有关,还与温度、降雨、大风和雷击等环境因素密切相关。所以本文旨在提出一种基于大数据的配电网故障关联因素分析和故障预警的模型与方法,针对不同地区的配电网必须从当地配电系统中获取运行与故障数据,所得到的故障关联因素也可能是不一样的。

4.2 风险预警

由于不同馈线的故障风险是随时间变化的,考虑到这种时变因素,本文选取120条馈线的2014年4月至2015年3月的一整年数据作为训练样本数据,2015年4月的数据作为测试样本数据,2015年

5、6月的样本作为预测样本。其中,训练样本用于训练获取模型,测试样本用于模型的优化,预测样本用于验证模型的实际预警效果。

各风险等级的馈线样本数量如表4所示。

表4 各风险等级样本数量

Table 4 Sample quantity of each risk level

数据类型	样本数量			总数
	风险等级1	风险等级2	风险等级3	
训练样本	1 078	290	72	1 440
测试样本	101	15	4	120
预测样本	198	36	6	240

采用基于 RBF 的 SVM 方法和22个最优故障特征子集,对预测样本中120条馈线在2015年5、6月的月风险等级进行预警,具体的馈线预警结果如表5所示,表中月预测准确率为当月准确预测的样本数与当月馈线样本总数的比值。

表5 配电网故障风险等级预警结果

Table 5 Early warning results of fault risk level for distribution network

预测月	馈线实际故障等级	馈线样本数			等级预测准确率/%	月预测准确率/%
		预测为故障等级1	预测为故障等级2	预测为故障等级3		
5月	1	96	4	0	96	93.33
	2	3	14	0	82.35	
	3	0	1	2	66.70	
6月	1	94	4	0	95.92	94.17
	2	2	15	0	88.24	
	3	0	1	4	80	

由表5可见,每个月的预警准确率都在90%以上,2个月的平均预警准确率为93.75%,说明本文提取的故障特征子集和预警方法具有较高的准确性和实用性;预警失误的样本最多只偏差一个等级,不会跨越2个等级,说明本文方法的鲁棒性较强;5月份等级2和3的样本预测精度较低,是因为这2个等级的原始样本太少。在原始样本中,风险等级1的样本占74%,等级2和3的样本分别只占20%和6%,这也符合配电网故障的实际情况。若能在训练样本中增加高风险等级的样本数量,还能进一步提高预警的准确率。由于各特征变量的时变性,导致配电网的风险也是随时间变化的,而本文提出的方法可以很好地适应这种时变特征,为风险防控提供及时的技术支持。

为了验证本文采用的基于 RBF 的 SVM 进行风险预警的优越性,还与人工神经网络(ANN)、C4.5 决策树和基于线性核函数的 SVM 这3种常用的预测方法进行了对比,其准确率和 Kappa 指标如表6所示。

由表6可见,本文采用的基于 RBF 的 SVM 预警方法,不论是在预警准确率还是 Kappa 统计指标上,都优于其他3种方法。