

基于粗糙径向基神经网络的电网故障诊断新模型

李孝全, 庄德慧, 张强

(空军工程大学导弹学院, 陕西 三原 713800)

摘要: 在一种属性约简方法的基础上, 利用粗糙集和径向基网络的优势, 将二者充分融合, 构建了一种电网故障诊断新模型, 并对其进行了改造。通过对电网故障诊断算例的仿真实验比较表明, 该模型减少了识别的主观因素, 简化了网络结构, 并且识别效果明显, 分类能力强, 具有很强的容错性和解释性, 有很广阔的应用前景。

关键词: 电网; 粗糙集; 径向基; 故障诊断; 神经网络

A new fault diagnosis model of electric power grid based on rough radical basis function neural networks

LI Xiao-quan, ZHUANG De-hui, ZHANG Qiang

(The Missile Institute, Air Force Engineering University, Sanyuan 713800, China)

Abstract: On the basis of giving a new type of attribute reduction method, a coupling recognition model is established which combines rough set and neural network closely and rebuilt in this paper. The simulation results illustrate that the model reduces subject factors in signal recognition and improves network's structure, and its recognizing effects are obvious and its classifying ability is strong, as well as the model is very error permissible and explicable. It has very wide foreground.

Key words: electric power grid; rough sets (RS); radical basis function (RBF); fault diagnosis; neural networks

中图分类号: TM71 文献标识码: A 文章编号: 1674-3415(2009)18-0020-05

0 引言

当电力系统发生复杂故障或开关、保护存在较多误动、拒动以及因信息干扰发生信息丢失等诸多不确定因素时, 会使得故障后的系统响应复杂化, 给故障诊断工作造成很多困难, 如果调度员对故障发生误判、漏判, 可能会导致事故扩大等严重后果。因此, 有必要研究一种鲁棒性强、适应各种不利情况的电网故障诊断模型, 协助调度人员迅速识别故障, 保证电力系统的安全稳定运行。

电网故障诊断可以用一个模式分类问题来描述^[1], 很适合应用粗糙集理论^[2]的决策表方法。为此, 本文在前人研究的基础上^[3-5], 将粗糙集和径向基进行强、弱耦合并改造, 利用一种属性约简技术, 在此基础上提取规则, 构建了一种新的耦合模型—粗糙径向基神经网络融合模型RRBFIM (Rough Radial Basis Function Integrated Model) 来处理各种类型引起的电网故障, 它融合了粗糙集和神经网络各自的优点, 在容错性和速度方面都有很大的提高。通过对电网故障诊断的算例证明了此方法的正确性和优越性。

1 基于RRBFIM的故障诊断方法

1.1 诊断思想

系统状态与系统事件之间有一种相关关系, 倘若这种关系已知, 就可以对任意事件进行模式识别, 判断出系统处于何种状态。利用粗糙集技术提取事件类特征以及事件类与系统状态之间相关关系, 为系统的故障诊断提供基础信息。假设由粗糙集约简算法得到的条件属性约简集是 C^* , 条件属性和决策属性中相应的各个等价类为 $U/C^* = \{C_1, C_2, \dots, C_L\}$, $U/D = \{D_1, D_2, \dots, D_M\}$, 等价类相对于各自条件和决策属性的特定取值分别为 $des_C(C_i)$ 和 $des_D(D_j)$, 其中 $i=1, 2, \dots, L$; $j=1, 2, \dots, M$ 。提取的决策规则集如图1所示。 v_i 是等价类 C_i 或相应事件类在关系数据模型中的覆盖度, 它是根据推导出的规则计算而得; $\mu_{i,j}$ 是等价类 C_i 引起系统在第 j 状态的可信度, 它是由神经网络训练而得。

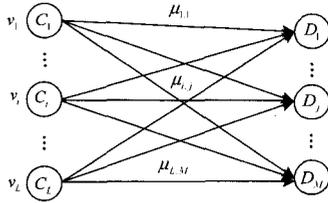


图1 决策规则示意图

Fig.1 Sketch map of decision rules

对于任意一个事件 $X_i = (x_{i1}, x_{i2}, \dots, x_{iq})$, 对应的状态变量 y_i 是待确定的。设事件 X_i 在 U 中的对象是 $u_i = (X_i, y_i)$, $u_i \in C_k$ ($k \leq L$), 则对象 u_i 关于条件属性 C^* 的特征是 $des_{C^*}(u_i) = des_{C^*}(C_k)$, 这时便可用决策规则集中等价类 C_k 与系统状态之间的信息对事件 X_i 进行识别, 从而确定出系统故障。

本文把粗糙集与径向基网络进行强、弱耦合, 一是把粗糙集数据分析技术作为神经网络的数据预处理器, 对样本信息集 U 建立数据关系表 $S = (U, C \cup D)$, 用省却区分矩阵属性约简方法 (DMRM) [6] 在数据驱动下约简输入变量, 提炼学习样本; 二是用粗糙集对系统偶发事件分类, 获取类特征, 提取事件类与系统状态之间关系的规则集, 利用规则集及其规则的覆盖率、可信度构造RBF神经网络结构 (确定网络的层数、各层节点数及其连接权), 建立故障诊断的粗径向基融合模型 (RRBFIM); 三是将RBF网络结构较传统的方式进行了改进, 将核属性直接与输出神经元相接, 让其决定着网络的输出结果, 加强粗糙集理论对RBF网络结构的优化, 并用提炼后的学习样本学习训练网络, 实现了事件与系统状态之间的映射 $y = I_f(X)$ 。

1.2 RRBFIM及结构

由于单独使用粗糙集和径向基局限性很大[7], 为了克服它们各自单独技术的缺点, 本文将两者进行耦合。

假设条件属性集 C 的约简集 $C^* = \{x_{i_1}, x_{i_2}, \dots, x_{i_N}\}$

(其中, i_1, i_2, \dots, i_N 是 $1, 2, \dots, N$ 中某 N 个不同的取值), 等价类 $U/C^* = \{C_1, C_2, \dots, C_L\}$, 系统状态类集 $U/D = \{D_1, D_2, \dots, D_M\}$, 则提取的决策规则集为:

$$R = \{r_{ij} : des_{C^*}(C_i) \rightarrow des_D(D_j)(v_i, \mu_{ij}) \mid i=1, 2, \dots, L; j=1, 2, \dots, M\}$$

其中:

$$\sum_{i=1}^L v_i = 1 \quad (1)$$

$$\sum_{j=1}^M \mu_{ij} = 1, \quad i=1, 2, \dots, L \quad (2)$$

决策集 R 反映了事件类与系统状态之间的关系, 根据故障诊断原理, 建立在决策规则集上的粗径向基融合模型 (RRBFIM) 的结构如图 2 所示。

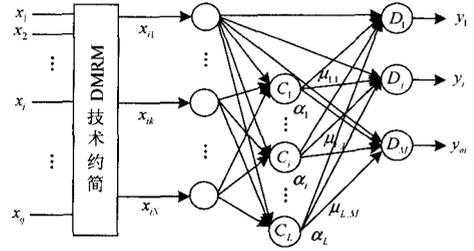


图2 粗径向基融合结构图

Fig.2 Integrated structure diagram of RS and RBF

这是一个带前端预处理器的三层前馈网络, 前端预处理器用粗糙集数据分析技术 (DMRM) 约简输入变量, 提炼学习样本, 输入变量是系统网络中 q 个元件的状态变量。

第一层是输入层, 输入变量是系统网络中部分元件的状态变量, 它由约简集 C^* 确定, 而神经元的个数 $N = \text{card}(C^*)$, 每个神经元的输入输出都相等。将属性约简集中的所有核属性调置输入的前列, 由于核属性在约简集中非常重要, 因此将第一个核属性直接与输出神经元相接, 让其决定着网络的输出结果, 这样可以大大提高判断故障的准确性。

第二层是隐含层, 每个神经元的输入为第一层的输出, 神经元的个数 $L = \text{card}(U/C)$, 即为规则集 R 中事件类的个数, 也就是规则的条数, 各个神经元为事件类 C_i ($i=1, 2, \dots, L$), 中心为事件的类特征 $des_{C^*}(C_i)$, 网络隐层激活函数为Gauss型函数:

$$h_i = \exp\left(-\frac{\|x - des_{C^*}(C_i)\|^2}{\sigma^2}\right) \quad (i=1, 2, \dots, L; 0 < h_i \leq 1) \quad (3)$$

h_i 反映了事件 X 与事件类 C_i 的接近程度, 当 X 关于 C^* 的特征非常接近 $des_{C^*}(C_i)$ 时, h_i 就接近1; 当 X 关于 C^* 的特征是 $des_{C^*}(C_i)$ 时, $h_i = 1$; 当 X 关于 C^* 的特征与 $des_{C^*}(C_i)$ 相差很大时, $h_i = 0$ 。

隐含层与输出层之间的结构主要由决策规则集 R 确定, 其中,

$$\alpha_i = h_i v_i, \quad (i=1, 2, \dots, L) \quad (4)$$

它表示事件 X 属于事件类 C_i 的置信度。

隐含层 C_i 与输出层 D_j 之间的权系数为:

$$\omega_{ij} = \mu_{ij} \quad (i=1, 2, \dots, L; j=1, 2, \dots, M) \quad (5)$$

它表示如果事件 X 属于事件类 C_i , 则引起系统出现

状态 j 的可能性。

第三层是输出层，神经元的个数等于系统的状态类型数 M ，输出为

$$y_j = \sum_{i=1}^L \alpha_i \mu_{ij} \quad (j = 1, 2, \dots, M) \quad (6)$$

它表示事件 X 使系统处于第 j 种状态的可能性。

显而易见， $0 \leq y_j \leq 1$ ($j = 1, 2, \dots, M$)，且 $\sum_{j=1}^M y_j = 1$ 。

事件 X 的期望输出为：

$$f_j(X) = \begin{cases} 1, & X \text{使系统处于第} j \text{种运行状态;} \\ 0, & X \text{使系统不处于第} j \text{种运行状态。} \end{cases} \quad (j = 1, 2, \dots, M) \quad (7)$$

1.3 RRBIFIM故障诊断算法

RRBFIM故障诊断算法的主要步骤为：

Step1: 输入原始数据，即事件与系统状态的样本信息；

Step2: 建立系统关系数据模型，形成一张初始故障信息决策表；

Step3: 调用DMRM技术进行属性约简，提取模式识别概略化规则和典型学习样本；

Step4: 将RS和RBF强、弱耦合并进行结构改进；

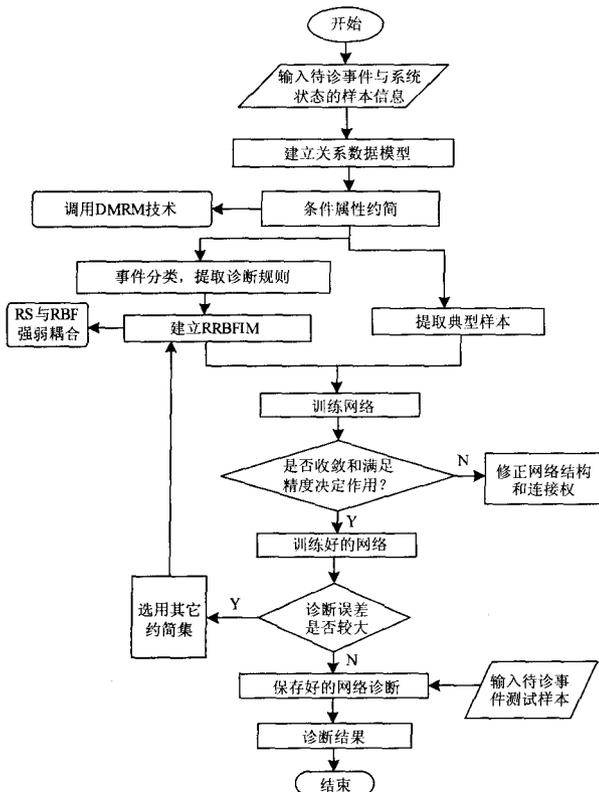


图3 基于RRBFIM的故障诊断工作流程图

Fig.3 Flow chart of fault diagnosis based on RRBIFIM

Step5: 训练RRBFIM;

Step6: 判断诊断误差是否满足要求，否则选用其它约简集，转向Step3;

Step7: 用训练好的网络进行待诊事件的故障诊断。

基于RRBFIM的故障诊断工作流程如图3所示。

2 实例分析

图4所示为一个简单的电网^[8]，该系统有三个区域 $Sec1$ ， $Sec2$ 和 $Sec3$ ，分别配有过流保护 $CO1$ ， $CO2$ 和 $CO3$ 。 $Sec1$ 配有距离保护 $RR1$ ，为 $Sec2$ 和 $Sec3$ 提供后备保护。 $CB1$ ， $CB2$ 和 $CB3$ 是断路器。

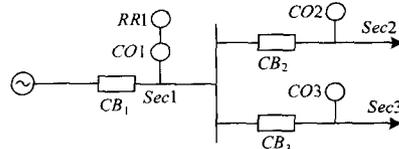


图4 简单电网结构图

Fig.4 Structure of a simple electric power grid

根据保护动作原理，考虑单一故障列出决策表，如表1所示，共7个故障样本。其条件属性分别为断路器 $CB1$ 、 $CB2$ 和 $CB3$ ，过流保护 $CO1$ 、 $CO2$ 和 $CO3$ ，距离保护 $RR1$ ，条件属性取值为“0”或“1”，其中“1”表示断路器由闭合变位为断开或保护动作，“0”表示断路器未变位或保护未动作。决策属性为故障区域，分别为区域 $Sec1$ 、 $Sec2$ 、 $Sec3$ 、 $Sec2/3$ 和 No 。其中， $Sec2/3$ 表示故障发生在 $Sec2$ 或 $Sec3$ ， No 表示无故障。

表1 电网故障诊断决策表

Tab.1 Decision table of electric power grid fault diagnosis

样本	条件属性 (故障信息)							故障区域
	$CB1$	$CB2$	$CB3$	$CO1$	$CO2$	$CO3$	$CO4$	
1	1	0	0	1	0	0	0	$Sec1$
2	0	1	0	0	1	0	0	$Sec2$
3	0	0	1	0	0	1	0	$Sec3$
4	1	0	0	0	1	0	1	$Sec2$
5	1	0	0	0	0	1	1	$Sec3$
6	1	0	0	0	0	0	1	$Sec2/3$
7	0	0	0	0	0	0	0	NO

2.1 知识约简和规则提取

用文献[6]的属性约简方法，可以得到系统有3种属性约简组合： $CB1 \wedge CO1 \wedge CO2 \wedge CO3$ 、 $CB1 \wedge CO2 \wedge CO3 \wedge RR1$ 和 $CO1 \wedge CO2 \wedge CO3 \wedge RR1$ ，其中核属性为 $CO2$ 和 $CO3$ ，此结果与文献[8]完全相同。选第1种约简组合进行详细分析，并把核属性调整到前列，消去重复规则得到最终的故障约简决策表，

如表2所示。

表2 最终故障信息约简决策表

Tab.2 Finally reduced decision table of fault diagnosis

样本	条件属性 (故障信息)				故障区域
	CO2	CO3	CB1	CO1	
1	*	*	*	1	Sec1
2	1	*	*	*	Sec2
3	*	1	*	*	Sec3
6	0	0	1	0	Sec2/3
7	0	0	0	*	No

由表2可以得到5条故障诊断规则:

$CO1(1) \rightarrow Sec1$; $CO2(1) \rightarrow Sec2$; $CO3(1) \rightarrow Sec3$;

$CO2(0)CO3(0)CB1(1)CO1(0) \rightarrow Sec2/3$;

$CO2(0)CO3(0)CB1(0) \rightarrow No$ 。

从最终的约简结果可以看出, 约简后的决策表要比初始的决策表简单得多。由于冗余数据的大大减少, 从而可以大大提高运算速度。另外, 约简后

的决策表具有一定的容错性能。

2.2 构建RRBF耦合结构

由表2的约简结果和图2的模型构建方法, 可以得到 $N=4, L=5, M=5$, 所以构建一个4-5-5的RRBF模型。

2.3 仿真实验

对网络进行训练, 然后再用样本2对其验证。

其中的网络权值为:

$$v = [0.1428 \quad 0.2858 \quad 0.2858 \quad 0.1428 \quad 0.1428]^T$$

$$\mu = \begin{bmatrix} 0.9950 & 0.0011 & 0.0009 & 0.0014 & 0.0016 \\ 0.0006 & 0.9995 & 0.0004 & 0.0003 & 0.0002 \\ 0.0010 & 0.0007 & 0.9969 & 0.0011 & 0.0003 \\ 0.0012 & 0.0016 & 0.0021 & 0.9942 & 0.0009 \\ 0.0011 & 0.0010 & 0.0007 & 0.0008 & 0.9964 \end{bmatrix}$$

为了验证本文方法的正确性和优越性, 本文将训练的结果和文献[9]的粗糙集朴素贝叶斯方法进行比较。比较结果如表3所示。

表3 故障诊断结果比较

Tab.3 Comparison of fault diagnosis results

序号	故障信息				故障诊断结果 (加粗的值对应的区域即为诊断结果, “?”表示未知)									
					Sec1		Sec2		Sec3		Sec2/3		No	
	CO2	CO3	CB1	CO1	文献[9]	本文	文献[9]	本文	文献[9]	本文	文献[9]	本文	文献[9]	本文
1	1	0	0	0	0.0008	0.0002	0.8863	0.9341	0.0050	0.0036	0.0098	0.0036	0.0985	0.0584
2	1	1	0	0	0.0014	0.0001	0.45	0.4839	0.45	0.4839	0.0089	0.0019	0.089	0.0302
3	1	0	1	0	?	0.0294	?	0.8803	?	0.0018	?	0.4697	?	0.0294
4	1	0	0	1	?	0.0552	?	0.8828	?	0.0034	?	0.0034	?	0.0552
5	1	*	0	0	0.0007	0.0002	0.8176	0.8856	0.0818	0.0554	0.0091	0.0035	0.0908	0.0554
6	*	0	0	0	0.0036	0.0018	0.4629	0.4697	0.0244	0.0294	0.0463	0.0294	0.4629	0.4697
7	1	0	*	0	0.0038	0.0034	0.8923	0.8828	0.0047	0.0034	0.0496	0.0552	0.0496	0.0552
8	1	0	0	*	0.0098	0.0036	0.8783	0.9309	0.0046	0.0036	0.0098	0.0036	0.0976	0.0582

本文共给了8组故障信息进行故障诊断, 其中, 第1组为正确故障信息, 第2~4组含有错误故障信息 (2组的CO3、3组的CB1和4组的CO1故障信息本应该是“0”, 而错误地给成了“1”), 第5~8组为不完备故障信息 (其中“*”表示未知故障信息)。

由表3诊断结果的整体看, 本文的故障诊断正确率不低于文献[9] (因为文献[9]没给出3、4组的诊断结果), 但是本文的方法比文献[9]的方法更具解释性, 并且故障诊断效果更明显。

实验结果表明:

(1) 当故障信息完整且正确 (第1组) 时, 本文和文献[9]一样, 得到的诊断结果完全正确, 但效果明显;

(2) 当故障信息有错误 (第2~4组) 时, 第2组诊断结果不唯一, 但故障区域在输出结果中, 这是因为CO2和CO3都是核信息, 第2组的故障信息蕴含了两条故障诊断规则, 所以自然会有两种诊断结果, 而第3、4组得到的诊断结果仍然正确, 这说明本文方法的容错性较强;

(3) 当故障信息不完备或有丢失 (第5~8组) 时, 只有第6组诊断结果不唯一, 其余都完全正确。因为对于样本2, 核属性CO2是至关重要, 如丢失, 结果肯定有出入, 但是诊断结果也在输出结果中。

因此, 本文的电网故障诊断方法是正确和可行的, 并且在处理不确定性和含有错误信息的故障信息时具有一定优势和很强的解释性。

3 结束语

本文将粗糙集和径向基网络进行强、弱耦合,在一种属性约简的基础上构建了一种新的故障诊断模型。通过对电网的仿真实验并与文献[9]的比较,表明此方法分类正确率较高,并且在处理不确定性和含有错误信息的故障信息时具有一定优势和很强的解释性。

但是本文方法应用在更大规模的电网中可能存在一定的问题,最大的困难就是决策表的建立问题,计算工作量和复杂程度都会很大。另外,随着网络规模的扩大,各层神经元数量也会增加,网络计算速度会降低,甚至会影响到神经网络训练的收敛性。

参考文献

- [1] 赵冬梅, 韩月, 高曙. 电网故障诊断的决策表约简新算法[J]. 电力系统自动化, 2004,28(4):63-64.
ZHAO Dong-mei, HAN Yue, GAO Shu. New Reduct Algorithm of Decision Table for Electric Power Grid Fault Diagnosis[J]. Automation of Electric Power Systems, 2004, 28(4): 63-64.
- [2] 张文修, 吴伟志, 等. 粗糙集理论与方法[M]. 北京: 科学出版社, 2001.
ZHANG Wen-xiu, WU Wen-zhi, et al. Rough Sets Theory and Method[M]. Beijing: Science Press, 2001.
- [3] HU Xiao-hua, Gercone N. A Rough Sets Approach [J]. Computational Intelligence, 1995,(11):323-355.
- [4] 王学武, 谭得健. 神经网络的应用与发展趋势[J]. 计算机工程与应用, 2003,39(3):33-37.
WANG Xue-wu, TAN De-jian. The Application of Neural Network and Its Development[J]. Computer Engineering and Applications, 2003, 39(3):33-37.
- [5] 梁吉业, 曲开社, 徐宗本. 信息系统的属性约简[J]. 系统工程理论与实践, 2001,21(12):76-80.
LIANG Ji-ye, QU Kai-she, XU Zong-ben. Attribution Reduction of Information System[J]. System Engineering Theory and Practice, 2001, 21(12):76-80.
- [6] 庄德慧, 李孝全, 薛鹏. 发动机故障诊断属性约简算法[J]. 航天发射技术, 2008,(4):12-15.
ZHUANG De-hui, LI Xiao-quan, XUE Peng. An Algorithm for Attribute Reduction in Fault Diagnosis of Engine[J]. Space Launch Technology, 2008,(4):12-15.
- [7] 陈婷, 罗景青. 粗集-神经网络在雷达故障诊断中的应用研究[J]. 计算机工程与应用, 2008,44(10):28-30.
CHEN Ting, LUO Jing-qing. Research on Rough Set-neural Network and Its Application in Radar Signal Recognition[J]. Computer Engineering and Applications, 2008, 44(10):28-30.
- [8] 王林先, 李乃永. 基于粗糙集理论和故障信息网的电网故障诊断方法[J]. 继电器, 2008,36(8):60-63.
WANG Lin-xian, LI Nai-yong. A Method of Electric Power Grid Fault Diagnosis Based on Rough Set Theory and Fault Information Networks[J]. Relay, 2008,36(8): 60-63.
- [9] 张耀天. 基于粗糙集和朴素贝叶斯的电网故障诊断方法研究[D]. 成都: 西南交通大学, 2007.31-38.
ZHANG Yao-tian. Study on a Power Grid Method Based on Rough Set Theory and Naive Bayesian Networks[D]. Chengdu: Southwest Jiaotong University, 2007.31-38.

收稿日期: 2008-10-10; 修回日期: 2008-12-11

作者简介:

李孝全(1968-), 男, 副教授, 硕士生导师, 博士在读, 研究方向为电力系统及其自动化, 兵器发射理论与技术, 军事人工智能方法; E-mail: lxq389@163.com

庄德慧(1981-), 男, 硕士在读, 研究方向为电力系统及其自动化, 军事人工智能方法。

向上工程首批换流阀设备正式发往奉贤换流站

2009年8月30日, 由许继柔性输电系统公司研制的向上特高压直流工程首批电控换流阀设备正式运往上海奉贤换流站工程现场。

按照国家电网公司的要求, 向家坝-上海特高压直流输电示范工程将于今年12月实现奉贤换流站极I 800 kV设备和直流输电线路带电; 2010年4月实现极I直流系统全压功率输送。许继集团作为向上特高压直流工程上海奉贤换流站控制保护和换流阀成套设备的供应商, 严格按照合同和工程进度要求, 认真做好控制保护和换流阀设备的设计、生产和试验各项工作, 积极为特高压直流输电示范工程提供一流的产品和服务, 确保工程顺利投运。