

粗糙集理论与神经网络在变压器故障诊断中的应用

俞晓冬¹, 马凤英¹, 臧宏志²

(1. 山东轻工业学院, 山东 济南 250061; 2 山东省电力研究院, 山东 济南 250061)

摘要: 粗糙集 (RS)理论是一门新兴的智能信息处理技术,它对各种不完整数据进行分析、推理,发现数据间的关系,提取有用特征,简化信息处理。人工神经网络 (ANN)具有本质的非线性特性、并行处理能力、以及自组织自学习的能力。但单独使用 ANN处理问题时,往往会存在一些缺陷。该文把粗糙集理论与人工神经网络结合起来,应用于变压器故障诊断,可以充分发挥两种方法的优势,取长补短。粗糙集理论可以有效地对样本集进行约简,从而简化了 ANN的网络结构,减少了网络的训练步数,提高了判断准确率。并用仿真实验验证了此方法的有效性。

关键词: 变压器; 故障诊断; 粗糙集; 人工神经网络

中图分类号: TM41; TM771 **文献标识码:** A **文章编号:** 1003-4897(2006)01-0010-05

0 引言

神经网络应用于变压器故障诊断时,主要存在以下问题:即如何选取输入矢量和训练样本集规模过大等问题。

输入矢量的选取是第一环节,也是特别重要的一个环节。但目前,还没有比较成熟有效的关于输入特征矢量的选取方法。大多数文献关于输入特征矢量的选取都是比较随机的。而且变压器故障是一个比较复杂的问题,其故障特征,故障现象,与故障类型之间的联系十分复杂。很难人为地判断究竟选取哪些特征作为输入矢量比较合适和准确。

另外,神经网络的训练样本集的选取直接影响到网络的分类能力。理论上,训练样本集的容量越大,所含有的信息就越丰富,训练的神经网络的判断准确率就越高。但过大的训练样本集往往含有较多的冗余信息,这些冗余样本的存在并不会提高神经网络的训练效果。而且,训练样本集越大,则网络学习越复杂,训练时间越长。

本文针对上述问题,提出一种新的方法,即将粗糙集理论与神经网络结合起来进行变压器的故障诊断。利用粗糙集方法对原始样本集进行约简,把约简后的样本集作为神经网络的输入样本集。这样,一方面对于输入特征矢量的选取有了理论上的指导,科学、客观地去除了那些与故障类型关系不大的输入矢量,避免了人为选取输入特征矢量的主观盲目性;另一方面又去除了冗余信息,减少了神经网络训练样本集的规模,有效地降低了网络复杂性,减少了网络训练时间,并提高了网络的判断准确率。

1 粗糙集理论^[1~3]

波兰学者 Z Pawlak于 1982年提出的粗糙集 (Rough Set)理论是一种研究不完整数据、不确定知识的表达、学习及归纳的数学方法。它为研究不精确数据的分析、推理,挖掘数据间的关系、发现潜在的知识提供了行之有效的工具。

决策表是一类特殊而重要的知识表达系统,可定义如下 $S = (U, A)$ 为一知识表达系统,且 $C, D \subset A$ 是两个属性子集,分别称为条件属性和决策属性。具有条件属性和决策属性的知识表达系统可表达为决策表,记作 $T = (U, A, C, D)$ 或简称为 CD决策表。

决策表的化简就是化简决策表中的条件属性,化简后的决策表具有化简前的决策表的功能,但是化简后的决策表具有更少的条件属性。因此,决策表的化简在工程应用中相当重要,同样的决策可以基于更少量的条件,通过一些更简单的手段就能获得同样要求的结果。

RS理论中应用决策表来描述论域中对象。它是一张二维表格,每一行描述一个对象,每一列描述对象的一种属性。属性分为条件属性和决策属性,论域中的对象根据条件属性的不同,被划分到具有不同决策属性的决策类。表 1为一张决策表,论域 U 有 8个对象,编号 1~8, $\{a, b, c\}$ 是条件属性集, d 为决策属性。对于分类来说,并非所有的条件属性都是必要的,有些是多余的,去除这些属性不会影响原来的分类效果。约简 (reduct)定义为不含多余属性并保证分类正确的最小条件属性集。一个决策表可能同时存在几个约简,这些约简的交集定义为决

策表的核 (core),核中的属性是影响分类的重要属性。

决策表约简步骤可简单表述如下:

1)从决策表中去除冗余条件属性列。若删除某条件属性列后,剩余规则发生冲突,则此条件属性列不可删除。如表 1中:删除 c 列后,第 6条规则与第 7条规则矛盾,第 5条规则与第 8条规则也矛盾,所以条件属性 c 不可省略。同理,条件属性 b 也不可省略。而条件属性 a 可省略。表 2为删除条件属性 a 后的约简 $\{b, c\}$ 。

表 1 原始决策表

Tab 1 Original decision table

U	a	b	c	d
1	1	0	0	$d1$
2	0	0	0	$d1$
3	0	0	1	$d1$
4	0	1	0	$d2$
5	1	2	0	$d2$
6	0	2	1	$d1$
7	0	2	0	$d2$
8	1	2	1	$d1$

表 2 消除冗余属性 a

Tab 2 Reduction after deleting redundancy

U	b	c	d
1	0	0	$d1$
2	0	0	$d1$
3	0	1	$d1$
4	1	0	$d2$
5	2	0	$d2$
6	2	1	$d1$
7	2	0	$d2$
8	2	1	$d1$

表 3 核值表

Tab 3 Nucleus table

U	b	c	d
1	0	*	$d1$
2	0	*	$d1$
3	*	*	$d1$
4	1	*	$d2$
5	2	0	$d2$
6	*	1	$d1$
7	2	0	$d2$
8	*	1	$d1$

表 4 最终决策表

Tab 4 Final reduction

U	b	c	d
2	0	*	$d1$
4	1	*	$d2$
5	2	0	$d2$
6	*	1	$d1$

2)计算条件属性核值。如表 2, b 的取值对于规则 1是必要的,所以保留;而 b 的取值对于规则 6则是不必要的,因此计为 *,以此方法得到 $core(b) =$

$\{1, 2, 4, 5, 7\}$ 。同理 c 的取值对于规则 1, 2, 3, 4是不必要的,因此 $core(c) = \{5, 6, 7, 8\}$ 。见表 3。

3)决策规则简化。将相同的规则合并,得到最终决策表 4。

2 粗糙集与神经网络结合进行变压器故障诊断

因为粗糙集理论无需对知识或数据的局部给予主观评价,因而利用粗糙集理论进行约简是一种定量、客观的简化,约简计算以严密的定理为基础。它显然要优于仿真验证而不是定理保证的其它一些人工智能的方法。

经过粗糙集方法约简后的决策表作为神经网络的训练样本集,一方面使输入矢量的选取有了理论上的依据,另一方面也有效地压缩了训练样本的规模。这样对于降低网络的复杂性,减少网络训练时间、提高网络诊断能力都具有非常重要的意义。

利用粗糙集方法与神经网络结合进行变压器故障诊断的步骤如下:

- 1)分析数据,选取原始样本集,形成原始决策表。本方法对于样本量多、输入量多的大样本集特别有效。因此,我们尽可能多选取一些输入特征矢量和样本数目。
- 2)对原始决策表进行连续数据的离散化。
- 3)利用粗糙集方法,对离散化后的决策表进行约简。形成最终决策表。
- 4)用 BP神经网络对约简后的最终决策表进行训练,直至取得满意效果。
- 5)用检验数据对已训练好的网络进行检验。
- 6)结果的统计分析。

故障诊断流程如图 1所示。

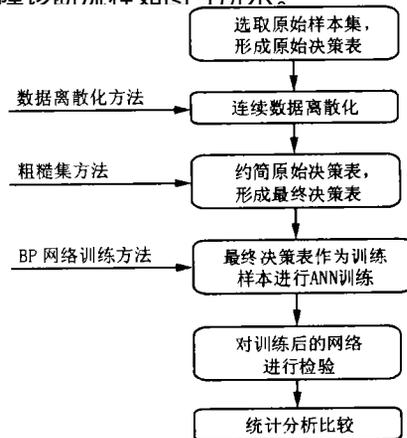


图 1 故障诊断流程

Fig 1 Flow chart of fault diagnosis

3 仿真算例^[4]

变压器油中各种气体的含量或者各种气体含量相互之间的比值与变压器各种故障之间的关系是紧密联系和非常复杂的,所以,为了尽可能准确,全面地找出各故障特征与各故障类型之间的关系,本文在原始样本集中选取近尽可能多的输入特征矢量。而且在选取样本时,要注意均匀涵盖各种故障类型。

本文选取 15 种气体含量的比值,作为输入特征矢量,分别为: C_2H_2/C_2H_4 , CH_4/H_2 , C_2H_4/C_2H_6 , C_2H_6/CH_4 , CH_4/C_2H_4 , C_2H_2/CH_4 , C_2H_2/C_2H_6 , C_2H_6/H_2 , C_2H_4/H_2 , C_2H_2/H_2 , $CH_4/总烃$ 、 $C_2H_4/总烃$ 、 $C_2H_6/总烃$ 、 $C_2H_2/总烃$ 、 $H_2/(总烃 + H_2)$ 。

选取 5 种输出故障类型,分别表示为: 1,正常; 2,低能放电; 3,高能放电; 4,中低温过热; 5,高温过热。

根据上述输入、输出矢量的选取方法,本文收集历年电力系统有关技术刊物和各种参考文献中的故障数据共 29 条组成原始样本集。

然后对原始数据进行离散化,离散化方法是把自然算法和等频离散化方法结合起来,其中等频离散法中的频数取为 3^[5]。

3.1 原始样本集的约简

利用波兰华沙大学和挪威科技大学联合开发的粗糙集系统软件 Rosetta 软件对原始样本集进行约简。采用的约简方法是 Exhaustive caculation 法。约简后产生了多组约简表,本文选取 $\{ \frac{C_2H_2}{C_2H_4}, \frac{C_2H_4}{C_2H_6}, \frac{CH_4}{C_2H_4}, \frac{CH_4}{总烃}, \frac{H_2}{H_2 + 总烃} \}$ 一组,其约简结果如表 5。

从表 5 可以看出:约简后的输入特征属性由原始样本集中的 15 个减少为现在的 5 个,规则由原始样本集中的 29 条减少为现在的 20 条。可见样本集规模大大减小,这就为下一步的 ANN 训练做好了训练样本集的优化工作。

3.2 神经网络的训练与仿真

利用 MATLAB 进行神经网络的训练与仿真。采用改进 BP 算法。调用函数 trainbpx(),它采用动量法和学习率自适应调整两种策略,从而提高了学习时间并增加了算法的可靠性。动量法降低了网络

对于误差曲面局部细节的敏感性,有效地抑制网络限于局部极小;自适应调整学习率有利于缩短学习时间。

表 5 约简后的决策表

Tab 5 Final reduction

样本	$\frac{C_2H_2}{C_2H_4}$	$\frac{C_2H_4}{C_2H_6}$	$\frac{CH_4}{C_2H_4}$	$\frac{CH_4}{总烃}$	$\frac{H_2}{H_2 + 总烃}$	故障
1	1	0	1	0	2	1
2	0	0	2	2	2	2
3	0	0	2	2	1	4
4	1	1	0	1	0	5
5	2	2	1	0	1	3
6	2	2	0	0	1	3
7	1	1	0	0	0	1015
8	1	2	1	1	0	5
9	1	1	1	1	0	4
10	2	2	0	0	2	3
11	1	2	0	0	0	5
12	0	1	1	2	1	4015
13	0	0	2	1	2	2
14	0	1	0	0	0	5
15	1	1	1	2	1	4
16	2	1	2	1	2	2
17	2	2	1	1	1	3
18	2	0	2	1	1	1
19	0	0	1	1	0	4
20	1	2	0	1	0	5

ANN 网络结构采用:输入神经元 5 个,隐层神经元 20 个,输出神经元 5 个。训练结果(见图 2),可以看出,网络训练 303 步后误差即可小于目标误差 0.01。

将 12 组检验数据(如表 6)输入已训练好的网络,检验网络的判断准确率。

表 6 检验数据

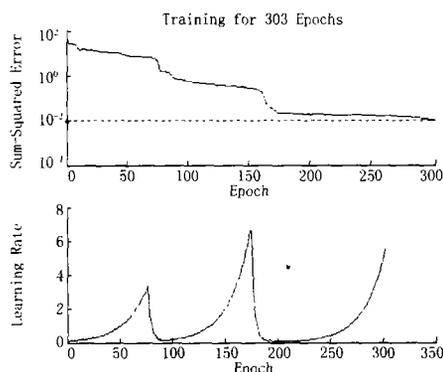
Tab 6 Test data

样本	$\frac{C_2H_2}{C_2H_4}$	$\frac{C_2H_4}{C_2H_6}$	$\frac{CH_4}{C_2H_4}$	$\frac{CH_4}{总烃}$	$\frac{H_2}{H_2 + 总烃}$	故障
1	0	1	1	2	1	5
2	0	1	2	2	1	4
3	2	1	2	1	2	2
4	1	1	0	0	1	5
5	1	0	2	2	1	4
6	1	1	2	2	2	4
7	1	1	1	1	1	2
8	0	2	2	2	2	2
9	1	2	0	1	0	5
10	1	2	0	0	0	5
11	2	1	0	0	1	3
12	2	2	0	0	1	3

网络输出结果如下:

0.002 4	0.005 2	0.004 8	0.047 6	0.038 0	0.005 4	0.002 0	0.001 2	0.002 4	0.002 5	0.001 3	0.206 8
0.023 1	0.014 4	0.973 9	0.000 1	0.043 9	0.986 5	0.478 5	0.970 0	0.000 0	0.000 0	0.001 0	0.000 0
0.000 1	0.000 0	0.018 4	0.620 6	0.000 0	0.002 1	0.003 9	0.015 2	0.006 5	0.023 0	0.990 6	0.918 6
0.499 4	0.944 8	0.002 2	0.000 0	0.976 9	0.004 8	0.020 8	0.002 3	0.001 0	0.000 6	0.000 0	0.000 0
0.502 6	0.009 1	0.000 5	0.003 7	0.000 2	0.000 8	0.008 1	0.004 2	0.993 1	0.985 3	0.002 3	0.000 8

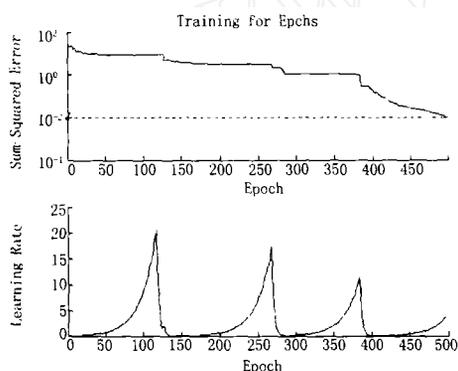
由上述输出结果可知:网络判断故障为 5, 4, 2, 3, 4, 2, 2, 2, 5, 5, 3, 3。与表 6 中实际故障相比较,可知第四组、第六组判断错误,其余正确。故网络判断准确率为: $(12 - 2) / 12 = 83.3\%$ 。



303/3000 epochs, lr = 5.61296, SSE = 0.00997734

图 2 采用粗糙集方法后的 ANN 训练结果

Fig 2 ANN training results by adopting RS



497/3000 epochs, lr = 3.84389, SSE = 0.00972933

(lr 为学习率; SSE 为训练误差;)

图 3 未采用粗糙集方法的 ANN 训练结果

Fig 3 ANN training results without RS

3.3 与其他方法的比较

若不采用粗糙集方法对训练样本进行约简,而是直接采用未约简的原始样本集进行 ANN 训练。则网络结构采用 15 个输入神经元, 50 个隐层神经元, 5 个输出神经元。网络需训练 497 步后误差方可小于目标误差 0.01 (见图 3)。

同样用检验数据对此 ANN 进行检验,结果表明此网络判断的准确率为 75%。

比较经粗糙集方法约简后的样本集来作为训练样本,与直接用原始样本集作为训练样本的神经网络,发现,前者的网络结构比后者要简单得多、前者的训练步数少于后者,前者的网络判断准确率也高于后者。这是因为用粗糙集方法约简后的输入特征矢量是有理论指导的,是科学的,因而它们能更加准

确的反映故障类型。而原始样本集中的 15 个输入特征矢量与故障类型之间的联系程度则是不明确的。

比较一下上述两种方法,结果如表 7 所示。

表 7 两种方法的比较

	ANN 网络结构		训练步数	判断准确率
	输入神经元	隐层神经元		
原始样本集作为训练样本	15	50	497	75%
经粗糙集约简后的样本作为训练样本	5	20	303	82.3%

4 结束语

本文将粗糙集理论与神经网络结合起来进行电力变压器的故障诊断,并用 MATLAB 对一故障样本集进行了试验仿真,结果表明:

1) 粗糙集理论中的决策表约简方法可对大样本集进行科学地有效地约简,可以客观地筛选出与故障类型关系最为紧密的几种输入特征向量,从而避免了人为选取输入特征向量的主观性与盲目性。

2) 用经过粗糙集约简后的样本集作为神经网络的训练样本集,有效地压缩了神经网络输入空间的规模,降低了网络的复杂性,减少了训练步数与训练时间,并提高了网络的判断准确率。

3) 另外需要注意的是:本文的试验与仿真所选取的样本集规模较小。而粗糙集方法的优势在于处理大样本集问题。若训练样本集更加完备,数据更多,则网络的结构、训练步数、判断准确率都将会更加良好,此种方法的优越性将会更加明显。

参考文献:

- [1] 束洪春,孙向飞,司大军. 电力变压故障诊断专家系统知识库建立和维护的粗糙集方法 [J]. 中国电机工程学报, 2002, 22 (2): 31-35.
SHU Hong-chun, SUN Xiang-fei, SI Da-jun A RS Approach to Founding and Maintaining ES Knowledge Base for Fault Diagnosis of Power Transformer [J]. Proceedings of the CSEE, 2002, 22 (2): 31-35.
- [2] Jekneč J, et al Rough Set Reduction of Attributes and Their Domains for Neural Networks [J]. Computational Intelligence, 1995, 11 (2): 339-347.
- [3] 曾黄麟. 粗糙集理论及其应用 [M]. 重庆:重庆大学出版社, 1998.
ZENG Huang-lin Rough Set Theory and Its Application [M]. Chongqing: Chongqing University Press, 1998.

- [4] 操敦奎. 变压器油中气体分析与诊断 [Z]. 中国水利电力企业管理协会, 1987.
CAO Dun-kui Gas Analysis and Diagnosis of Transformer [Z]. China Association of Irrigation and Electric Power Enterprises, 1987.
- [5] 侯利娟, 王国胤, 等. 粗糙集理论中的离散化问题 [J]. 计算机科学, 2000, 27(12).
HOU Li-juan, WANG Guo-yin, et al Discretization in Rough Set Theory [J]. Computer Science, 2000, 27(12).

收稿日期: 2005-04-25; 修回日期: 2005-07-08

作者简介:

俞晓冬 (1974 -), 女, 讲师, 主要研究方向是电力系统的运行与控制; E-mail: xiaodongyu2001@163.com

马凤英 (1971 -), 女, 讲师, 主要研究方向是自动控制领域;

臧宏志 (1971 -), 男, 主要研究方向是电力系统的运行与控制。

Rough sets theory and artificial neural networks applied in the transformer fault diagnosis

YU Xiao-dong¹, MA Feng-ying¹, ZANG Hong-zhi²

(1. Shandong Light Industry College, Jinan 250061, China; 2. Shandong Electric Power Research Institute, Jinan 250061, China)

Abstract: Rough set theory is a new intelligent information process technology. It can analyse and deduce all kinds of incomplete data, find the relationship between the data, pick up the useful characters and reduce the information process. Artificial neural networks has the essential nonlinear character, parallel processing ability, and the ability of self organization and self-learning. But when only using ANN to solve a problem, it often has some shortcomings. This paper combines rough set theory with artificial neural networks, applying it in the transformer fault diagnosis. It can fully develop the two methods' advantages, learn from other's strong points to offset one's weakness. Rough set theory can efficiently process the reduction of stylebook collection, so it simplifies the networks' structure, reduces the networks' training epochs and improves the judgement accuracy. Simulation experiment verifies the validity of this method.

Key words: transformer; fault diagnosis; rough sets(RS); artificial neural networks(ANN)

(上接第 4 页 continued from page 4)

Transient energy fault phase selecting scheme on the weak feed backside of transmission line based on wavelet analysis

LI Feng, JIAO Yan-jun, MA Jing

(Key Laboratory of Power System Protection and Dynamic Security Monitoring and Control under Ministry of Education, North China Electric Power University, Baoding 071003, China)

Abstract: This paper is to solve problem of fault phase selecting on the weak feed backside of transmission line. Based on the results of various model component analysis, it analyzes different short faults of transmission line and proposes an efficient principle and algorithm to determine the fault phase on weak feed side. The principle is based on model component analysis. The ATP simulation calculation and the data certification show that the principle is correct and can meet the requirement of phase-selection on the weak feed backside to effectively resolve problem of fault phase selecting.

Key words: wavelet analysis; weak feed backside of transmission line; fault phase selecting; transient energy

(上接第 9 页 continued from page 9)

(Tsinghua University, Beijing 100084, China)

Abstract: After an external fault of transformer is cleared, the transient flux may enter into the saturation region, and a recovery inrush may be produced. At the same time, the aperiodic component in the fault current usually has a high value during the fault, so that the CT may also enter into the saturation region. Both of them may cause the maloperation of the differential protection. In this paper, the flux of the transformer is obtained by theoretical derivation, then models of transformer and CT are built for simulation, and an experiment is done to prove the results. The factors that affect the inrush are analyzed. The influence on the inrush of the differential protection is investigated and the saturation of CT is studied as well. At last, considering the inrush and the saturation of CT together, the main cause of the maloperation is discussed.

Key words: external fault; recovery inrush; saturation of CT; transformer differential protection; maloperation