

基于粗糙集和 BP 神经网络算法的网络故障诊断模型研究

尚志信, 周宇*, 叶庆卫, 王晓东

(宁波大学 信息科学与工程学院, 浙江 宁波 315211)

摘要: 针对计算机网络故障诊断知识库冗余性高、神经网络与 PCA、DS 证据等理论相结合诊断精度不高的难题, 提出了一种新的基于粗糙集和 BP 神经网络的计算机网络故障诊断模型. 首先利用粗糙集算法对网络故障特征进行约简处理、提取最小诊断规则; 其次利用最小规则训练 BP 神经网络, 建立基于粗糙集和 BP 神经网络的计算机网络故障诊断模型; 最后将模型运用于真实网络故障数据诊断. 结果表明: 该模型具有学习效率高、诊断速度快、准确率高的特点, 能够快速诊断网络故障类型.

关键词: 粗糙集; BP 神经网络; 网络故障诊断; 知识库

中图分类号: TP391

文献标志码: A

文章编号: 1001-5132 (2013) 02-0045-04

现代计算机网络规模日益庞大, 用户对网络的依赖性越来越高, 对网络的性能与功能都提出了更高的要求. 由于故障原因众多, 信息量大, 网络管理人员很难科学、迅速地找到网络故障的根源, 如何快速、智能化地定位网络故障类型及网络故障的部位是一个值得研究的课题.

神经网络具有良好的非线性映射能力及超强的学习能力, 可以通过网络故障特征智能地诊断出网络故障类型, 也可以通过其学习来完善网络故障诊断知识库, 所以, 神经网络在网络故障领域的应用研究成为了当今国内外网络故障领域研究的热点^[1]. 文献[2]提出一种基于减法聚类-自适应模糊神经网络(ANFIS)的网络故障诊断建模方法; 文献[3]提出一种基于支持向量机的网络故障诊断方法; 文献[4]提出一种基于局域网环境的 BP 神经网络故障诊断方法; 文献[5-6]提出了基于改进神经网络的故障诊断方法; 但这些方法都无法避免网络故障诊断知识库冗余性高、神经网络的输入维数较高、结构较复杂的难题^[7]. 文献[8-9]提出基于 PCA 和 DS 证据理论与神经网络结合的方法, 起到简化神经网络诊断模型的效果, 但 PCA 是以损失训练集的信息量为代价, 直接影响到神经网络的

故障诊断精度; 并且 D-S 证据理论的基本可信度分配需要综合有关专家领域的知识和经验, 这在实际应用中较难实现, 再者专家的经验具有一定的主观性同样影响神经网络的故障诊断精度.

针对网络故障知识库冗余性高^[10]、神经网络与 PCA、DS 证据理论等算法相结合诊断精度不高的难题, 笔者提出运用粗糙集理论^[11]对网络故障诊断知识库进行约简的思路. 由于粗糙集理论对论域的划分只依赖于所需处理的数据集合本身, 无需任何先验信息, 与 PCA 和 DS 证据理论相比, 具有不损失数据信息量和对数据客观处理的优点.

1 网络故障诊断模型

构建网络状态的数学模型, 对于一个复杂的计算机网络而言, 可通过多种方式采集网络的 m 种特征属性 $f_k(t)$, 故障特征向量集合如下:

$$F = [\bar{f}_1(t), \bar{f}_2(t), \dots, \bar{f}_m(t)]^T. \quad (1)$$

$S(t)$ 为当前网络状态, 将测量时间离散为 n , 即进行 n 次测量, 特征向量 $\bar{f}_k(t)$ 即是 1 个 n 维列向量, 那么 n 次测量后的 F 为 $n \times m$ 阶特的征向量矩阵 F_n , 每行表示每次测量的特征属性集合为:

$$\bar{f}_k(t) = [f_k(t_1), f_k(t_2), \dots, f_k(t_n)], \quad (2)$$

收稿日期: 2012-11-03.

宁波大学学报(理工版)网址: <http://nbdxlg.paperopen.com/>

基金项目: 国家自然科学基金(61141015); 浙江省自然科学基金(Y1110161); 宁波市自然科学基金(2011A610181).

第一作者: 尚志信(1986-), 男, 河南商丘人, 在读硕士研究生, 主要研究方向: 网络故障诊断. E-mail: xinzhihang2007@163.com

*通信作者: 周宇(1960-), 男, 山东威海人, 教授, 主要研究方向: 网络通信及计算机软件. E-mail: zhouyu@nbu.edu.cn

$$F_n = \begin{bmatrix} f_1(t_1) & f_2(t_1) & \cdots & f_m(t_1) \\ f_1(t_2) & f_2(t_2) & \cdots & f_m(t_2) \\ \vdots & \vdots & \ddots & \vdots \\ f_1(t_n) & f_2(t_n) & \cdots & f_m(t_n) \end{bmatrix}. \quad (3)$$

(4)式为 n 行状态向量, 其中, 每行对应每次测量的网络状态 $\bar{S}(t)$ 为:

$$\bar{S}(t) = [s(t_1), s(t_2), \cdots, s(t_n)]^T. \quad (4)$$

(3)式和(4)式之间存在一种多维的映射关系, 由于不同的网络故障类型 $\bar{S}(t)$ 对应于不同的特征向量集合 F , 将多种网络故障的特征向量集合整合在一起就是一个网络故障诊断的知识库 D :

$$D = \langle F_n, \bar{S}(t) \rangle. \quad (5)$$

当网络出现故障时, 提取网络故障特征, 利用(5)式中的信息进行一一映射, 就能确定网络的故障类型. 由于BP神经网络具有良好的容错性和鲁棒性, 且能充分逼近任意复杂的非线性关系^[12]. 笔者在 F_n 和 $\bar{S}(t)$ 之间构建BP神经网络模型 M , 其中, m 表示输入维数, F_n 表示训练信号, $\bar{S}(t)$ 表示教师机信号, 模型如图1所示.




图1 BP神经网络模型

$$M = BP_m(F_n, \bar{S}(t)). \quad (6)$$

将模型(6)进行仿真, 发现模型学习效率底下, 其主要原因是(3)式中存在大量冗余特征值 $f_k(t)$, 使得神经网络模型(6)的输入维数 m 较大、结构复杂. 针对以上难题, 笔者引入粗糙集理论, 由于粗糙集不能处理连续性数据, 首先对(3)式进行离散化处理得到 F_n^a , 然后对 F_n^a 进行约简去冗得式:

$$F_n^* = red(F_n^a, \bar{S}(t)), \quad (7)$$

其中, red 表示粗糙集约简算法.

把约简后 F_n^* 的带入BP神经网络进行学习, 得到基于粗糙集的诊断模型 M^* , 且 x 为 F_n^* 中故障特征的数量.

$$M^* = BP_x(F_n^* : \bar{S}(t)). \quad (8)$$

2 基于粗糙集的神经网络故障诊断模型

针对模型(6)的弊端, 利用粗糙集理论对知识库 D 进行约简处理, 得到最小诊断规则库 D^* :

$$D^* = \langle F_n^*, \bar{S}(t) \rangle. \quad (9)$$

原来的特征向量集合 F 约简为特征向量集 F^* , F^* 中特征属性数目为 x , 且 $x < m$. 利用最小诊断规则库 D^* 训练神经网络得到基于粗糙集的网络故障诊断模型 M^* . 笔者选择基于属性重要度的约简算法, 因此算法是一种启发式的算法^[13], 具有约简速度快、效率高特点, 满足网络故障快速定位网络故障类型及部位需要, 再结合神经网络的分层融合知识库优点, 可提高系统的性能, 降低误报率.

算法推理过程如下:

(1) 对(3)式进行离散化处理, 得到决策表 D^a :

$$D^a = \langle F_n^a, \bar{S}(t) \rangle. \quad (10)$$

令(11)式为决策表, 利用(12)式求决策表的核 $CORE(F, S(t))$. 如果(13)式成立, 由(14)式可知, F^* 即为决策表的属性约简结果.

$$D^a = \begin{bmatrix} f_1(t_1) & f_2(t_1) & \cdots & f_m(t_1), S(t_1) \\ f_1(t_2) & f_2(t_2) & \cdots & f_m(t_2), S(t_2) \\ \vdots & \vdots & \ddots & \vdots \\ f_1(t_n) & f_2(t_n) & \cdots & f_m(t_n), S(t_n) \end{bmatrix}, \quad (11)$$

$$CORE(F, S(t)) = \cap red(F, \bar{S}(t)), \quad (12)$$

$$pos(S(t), F^*) = pos(S(t), F), \quad (13)$$

$$F^* = CORE(F, S(t)). \quad (14)$$

(2) 如果(13)式不成立, 则 $\forall F_i \in F \setminus F^*$, 并通过计算(15)式属性重要度的值以求取 f_m ,

$$f_m = \arg \max sig(f_i F^*), \quad (15)$$

其中, $\forall f_i \in F \setminus F^*$, 如果存在多个属性满足最大值, 则随机选取任意属性作为 f_m , 令 $F^* \leftarrow F^* \cup \{f_m\}$, 再次计算(13)式; 如果(13)式成立, 则 F^* 为约简结果. 否则, 循环计算式(15), 直至式(13)成立, 即为决策表属性约简结果.

(3) 利用最小规则集合 D^* 训练神经网络, F_n^* 为神经网络输入信号, $\bar{S}(t)$ 为教师机信号. 得到基于粗糙集的神经网络故障诊断模型 M^* (如(8)式).

3 系统实验仿真

3.1 实验设计

文中模型的流程如图2所示, 其基本原理是将

粗糙集理论作为神经网络输入数据的预处理工具, 将预处理过的训练样本进行降维去冗, 通过提取训练样本中的潜在诊断规则, 以组成故障诊断知识库训练神经网络, 最后用测试样本来进行故障诊断.




图 2 系统流程

采用美国国防部高级研究计划局(DARPA)提供的 KDD'99 数据集. 该数据集模拟真实网络环境, 包含 4 大类网络攻击, 即 DoS、Probe、R2L 和 U2R 下 7 个星期的网络流量, 每条记录均有 41 个特征属性. 笔者选择 6 种不同网络故障类型的 120 条数据, 其中, 100 条训练数据, 20 条测试数据, 每条数据选择 9 个特征属性. 由于网络故障诊断知识库属性包括多种类型的 MIB 变量, 其中有字符型、离散型、连续性. 因此选择其中的 9 种 MIB 变量属性, 用 C 表示, 其中 3 种字符型属性, 6 种连续型属性; 3 种以字符表征的属性进行数值化处理, 6 种连续型的属性用 K 均值进行聚类离散化处理.

选取了 6 种故障类型 120 条的故障样本, 并对每种故障类型进行编码, 对应的神经网络教师信号编码如图 3 所示, 其中 100 个作为网络训练样本, 20 个作为测试样本. 首先用训练数据训练模型 M , 记作 Net1, 得到如图 4 所示的误差曲线图. 然后用模型 M^* 处理训练样本数据, 得到表 1 的 11 条最小规则, 用约简后的规则训练神经网络, 记作 Net2, 得到如图 5 的网络曲线图.

3.2 数据分析

对比图 4 和图 5, 可见笔者提出的算法在实际应用中明显地提高了神经网络的学习效率, 算法误差也得到了很大的改善. 将测试数据分别带入训练好的网络中, 改进算法的故障诊断率为 100%, 部分诊断结果见表 2. 由表 2 的实验结果表明, Net2 的故障诊断准精度及学习效率明显优于 Net1, 证实了提出的故障诊断模型的优越性.

A: normal	B: smurf	C: snmpgetattack
00000	00001	00010
D: guess_passwd	E: warezmaster	F: xterm
00100	01000	10000

图 3 故障类型编码




图 4 BP 神经网络仿真

表 1 部分最小约简规则

最小规则	C2	C3	C4	故障类型
1	3	1	3	A
2	2	1	3	A
3	2	1	2	B
4	4	1	1	C
9	6	3	3	E
10	7	3	3	F
11	9	1	3	F




图 5 粗糙集 BP 神经网络模型仿真

4 结论

针对计算机网络故障诊断中知识库冗余性高、神经网络学习低下的特点, 提出了基于粗糙集神经网络的故障诊断模型, 并运用经典数据集验证了提出模型的可行性. 由实验结果表明, 本模型简化了网络故障的状态特征, 使得神经网络的结

表 2 真实样本测试

样本 1	Net1	Net2	样本 2	Net1	Net2	样本 3	Net1	Net2	样本 4	Net1	Net2
0	0.0000	0.0000	0	0.0000	0.0002	0	0.0000	0.0000	0	0.0000	0.0000
0	0.0009	0.0000	0	0.0000	0.0000	0	0.0006	0.0006	0	0.3580	0.0000
0	0.0000	0.0001	0	0.0253	0.0000	0	0.0000	0.0000	1	0.0000	0.9916
0	0.7983	0.0000	0	0.1346	0.0000	1	0.1110	0.9999	0	0.0000	0.0000
0	0.00000	0.00003	1	1.0000	0.9998	0	0.0000	0.0000	0	0.0091	0.0000
A	B (错误)	A (正确)	B	B (正确)	B (正确)	C	C (正确)	C (正确)	D	D (错误)	D (正确)

构得以简化,系统的成本降低,加快了诊断速度,实时性得到了增强,提高了系统诊断的精度及准确率,并且具有良好的扩展性和容错性,对故障诊断中的误报现象有很好的改进。

参考文献:

- [1] Wang Shengwei, Jiang Zhiming. Valve fault detection and diagnosis based on CMAC neural networks[J]. Energy and Buildings, 2004, 36:599-610.
- [2] 蒋静芝, 孟相如, 李欢. 减法聚类 ANFIS 在网络故障诊断的应用研究[J]. 计算机工程与应用, 2011, 47(8): 76-78
- [3] 朱长成. 支持向量机在网络故障诊断中的应用[J]. 计算机仿真, 2011, 28(10):103-105.
- [4] Shang Zhixin, Zhou Yu, Ye Qingwei, et al. Fault diagnosis of computer network based on rough sets and BP neural network[C]. 7th International Conference on Wireless Communications, Networking and Mobile, 2012.
- [5] 刘小丽, 王申涛, 代睿. 基于改进的粒子群优化的神经网络故障诊断方法研究[J]. 计算机应用与软件, 2011, 28(1):207-209.
- [6] 宋玉琴, 章卫国. 基于混合粒子群算法的小波神经网络故障诊断[J]. 测控技术, 2011, 30(1):112-116.
- [7] Awadallah M M. Application of AI tools in fault diagnosis of electrical machines and drives-an overview [J]. IEEE Transactions on Energy Conversion, 2003, 18: 245-251.
- [8] 汪蔚, 王荣杰, 胡清. 基于 PCA 和神经网络的故障诊断技术[J]. 计算机工程, 2008, 34(7):184-185.
- [9] 张捍东, 王翠华. 基于改进证据理论和神经网络故障诊断模型[J]. 计算机应用研究, 2010, 27(4):1277-1279.
- [10] Castro R G, Miranda V. Knowledge discovery in neural networks with application to transformer failure diagnosis [J]. IEEE Transactions on Power Systems, 2005, 20(1): 717-724.
- [11] Pawlak Z. Rough set theory and its application to data analysis[J]. Cybernetics and Systems, 1998, 29(7):661-668.
- [12] 韩力群. 人工神经网络教程[M]. 北京: 北京邮电学院出版社, 2006.
- [13] 苗夺谦, 李道国. 粗糙集理论、算法与应用[M]. 北京: 清华大学出版社, 2008.

Network Fault Diagnosis Based on Rough Sets and BP Neural Network

SHANG Zhi-xin, ZHOU Yu*, YE Qing-wei, WANG Xiao-dong

(Faculty of Information Science and Technology, Ningbo University, Ningbo 315211, China)

Abstract: To deal with the problems of redundancy of network fault diagnosis, the knowledge base and Low Accuracy of neural network model combined with PCA and DS evidence theory are presented in this paper. A new fault diagnosis model of computer network based on rough set and BP neural network is engineered, in which many fault features of computer network are retrieved. These features are then reduced to the minimum diagnosis rules using rough set. The minimum diagnosis rules are trained by BP neural network. The simulation results indicate that the new fault diagnosis model has higher learning efficiency, faster speed of diagnosis and higher detection accuracy.

Key words: rough set; BP neural network; network fault diagnosis; knowledge base

(责任编辑 章践立)