

基于RBF神经网络与粗糙集的挖掘电力变压器故障诊断研究

粗糙集挖掘方法进行故障诊断的过程中,训练易陷入局部最优解,导致电力变压器故障挖掘诊断算法不适用于解决实际工程问题。提出基于RBF神经网络与粗糙集的挖掘电力变压器故障诊断方法,利用RBF神经网络收敛速度快、泛化能力强等特点,对故障数据进行训练。依据给出的训练样本特征获取所求概率密度函数的统计值,将改进后的数据发送至粗糙集。在保证系统分类能力的条件下,依据分类规范,实现电力变压器故障挖掘诊断,对采集到的100组电力变压器故障数据进行仿真分析。结果表明,所提方法的局部搜索能力明显优于传统方法,所提方法在变压器故障的诊断准确率上大大高于传统方法,保证了电力变压器运行的安全性与可靠性。

化希耀/塔里木大学信息工程学院 苏博妮/四川文理学院
蔡翠佳/大庆石化公司水气厂



化希耀/讲师

关键词/Keywords

RBF神经网络·
粗糙集·
故障诊断·

电力变压器是电力系统的核心枢纽设备,其能否正常运行直接影响了电网供电的安全性以及稳定性^[1-2]。因此,如何提高电力变压器运行的有效性以及可靠性,是相关行业研究的重点课题,受到国内外电力领域的广泛关注^[3-5]。本文提出一种基于RBF神经网络与粗糙集的挖掘电力变压器故障诊断算法,利用RBF神经网络收敛速度快、泛化能力强等特点,对数据进行训练。依据给出的训练样本特征,获取所求概率密度函数的统计值,将改进后的数据发送至粗糙集。在保证系统分类能力的条件下,实现电力变压器故障挖掘诊断。文中对采

新疆生产建设兵团普通高校人文社会科学重点研究基地塔里木大学西域文化研究院开放课题基金资助(XY1408),塔里木大学塔里木大学校长基金硕士项目资助(TDZKSS201414),塔里木大学高等教育研究项目(TDGJ1411)。

集到的100组电力变压器故障数据进行仿真分析,结果表明,所提方法的局部搜索能力明显优于传统方法。所提方法在电力变压器故障的诊断准确率上大大高于传统方法,保证了电力变压器运行的安全性与可靠性。

RBF神经网络的基本原理

径向基函数神经网络是在20世纪由J.Moody与C.Darken提出的,其是一种包含单隐层的三层前向网络。从隐含单元数量的角度分析,可将RBF神经网络划分成正规化网络和广义网络。因为广义网络对大数据的处理效果更佳,所以被广泛应用。

径向基函数神经网络的原理为:假设有 N 组训练样本,其中输入层存在 M 个神经元,隐含层存在 I 个神经元,将第 i 个隐单元的输出称为“基函数” $\varphi(X, t)$ 。其中, $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]$, $i = (1, 2, \dots, I)$, t_i 用于描述基函数的中心,输出层包括 J 个神经元。输出层和输入层之间的权值用 $\omega 1_{mi}$ ($m = 1, 2, \dots, M$; $i = 1, 2, \dots, I$) 进行描述;隐含层与输出层之间的权值用 $\omega 2_{ij}$ ($i = 1, 2, \dots, I$; $j = 1, 2, \dots, J$) 进行描述。于隐含层内构建一个阈值单元 φ_0 ,其输出是1,输出单元间的权值用 $\omega 2_{0j}$ 进行描述。

将 $X = [X_1, X_2, \dots, X_n, \dots, X_N]^T$ 看作是一个训练样本集。

可将其中所有列 $X_n = [X_{n1}, X_{n2}, \dots, X_{nm}, \dots, X_{nM}]^T$ ($n = 1, 2, \dots, N$) 看作是训练样本,则与其相应的实际输出可表示

成 $Y_n = [y_{n1}, y_{n2}, \dots, y_{nj}, \dots, y_{nJ}]^T$ ($n = 1, 2, \dots, N$)，目标矢量集用 D 描述，目标矢量用 D_k 描述。

假设输入一个训练样本 X_n ，则输出层中一个神经元的输出可表示成

$$y_{nj}(X_n) = \omega_{0j} + \sum_{i=1}^I \omega_{ij}(X_n, t_i) \quad j = 1, 2, \dots, J \quad (1)$$

当基函数为高斯函数时，可将其描述成

$$\begin{aligned} \varphi(X_n, t_i) &= G(\|X_n - t_i\|) \\ &= \exp\left(-\frac{1}{2\sigma_i^2} \|X_n - t_i\|^2\right) \\ &= \exp\left(-\frac{1}{2\sigma_i^2} \sum_{m=1}^M (x_{km} - t_{im})^2\right) \end{aligned} \quad (2)$$

式中， σ_i 为高斯函数方差，通常采用一个扩展常数 C_i ， $\sigma_i = 0.8497C_i$ 。

RBF神经网络的训练通常包括无监督学习阶段和有监督学习阶段。

无监督学习阶段即依据网络的输入完成对权值和阈值的调整。

有监督学习的具体实现过程是：首先通过一组能够反映网络行为的训练样本集获取学习规则，再依据获取的学习规则对网络的权值和阈值进行调整。

在对神经网络进行训练前，应给出训练样本集 X 、与训练样本集 X 相应的目标矢量集 D 和径向基函数的扩展常数 C 。对神经网络进行训练的目的是获取两个层之间的阈值以及最终的权值 ω_1, ω_2 。

一般情况下，可依据给出的训练样本特征获取所求概率密度函数的统计值，也就是Parzen窗概率密度函数估计法，其估计式可表示成

$$p(X) = \frac{1}{(2\pi)^{d/2} \sigma^d} \frac{1}{N} \sum_{n=1}^N \exp\left[-\frac{(X - X^n)^T (X - X^n)}{2\sigma^2}\right] \quad (3)$$

式中， d 为所需分类向量的维数； N 为训练样本数； X_n 为某一训练样本； σ 为平滑因子。

通常条件下，传统神经网络的平滑因子仅取一个 σ 值，在实际应用中，无法准确体现每一个输入变量对准确分类结果的真实作用。因为训练样本是一个有限的样本集， σ 值不可能是 0。所以，为了塑造 RBF 神经网络，同时保证网络的整体性

能，必须使不同类别网络的平滑因子 σ 取不一样的值。一般采用智能改进算法，使得其基于给出的训练样本找到 σ 的最优值，从而增强实际问题中的网络判断性能。

粗糙集理论

粗糙集理论的基本思想是在保证信息系统分类能力的条件下，依据知识约简，得到问题的决策以及分类规范。

粗糙集的几个基本定义如下：

1) 信息表。粗糙集中的信息表主要负责反映域中全部数据集合。信息表和关系数据库中的数据模型较为相似，可将其看作是一张二维表，将信息表中的各行称作对象，将信息表中的各列称作属性。所有对象均有很多属性，可通过上述属性值的大小完成对对象的表达。一组含有由多种属性描述的对象集合即为信息表。

2) 信息系统。信息系统为信息表的理论化描述方式，其中的四元组 $S = (U, A, V, f)$ 为一个知识表达系统。其中， U 为对象的非空有限集合，即论域； A 为属性的非空有限集合，通常情况下由条件属性 C 和决策属性 D 组成； $V = \bigcup_{a \in A} V_a$ ； $f = U \times A \rightarrow V$ ，为信息函数，其可对所有对象任意属性的信息值进行赋值，也就是 $\forall a \in A, x \in U, f(x, a) \in V_a$ 。

3) 属性约简。属性约简即在保持原有信息的同时，对信息表中的杂乱信息进行删除，使得各属性之间的关系更加明朗。

假设属性集合为 $R, P \subseteq Q, R \subset P, \mathcal{E}$ 用于没描述粗糙集的分割，若 $r_R(\mathcal{E}) = r_P(\mathcal{E})$ ，同时没有一个属性集合 $R' \subset R$ 能够使 $r_{R'}(\mathcal{E}) = r_P(\mathcal{E})$ ，则将 R 称作是 P 的 $\mathcal{E}$ 约简，用 $RED_{\mathcal{E}}(P)$ 描述。

从上述介绍的定义可以看出，约简之前和约简之后系统包含的信息总数没有发生改变。信息系统约简通常有很多个，约简的交集被称作 P 的 $\mathcal{E}$ 核，用式 (4) 进行描述

$$CORE_{\mathcal{E}}(P) = \bigcap RED_{\mathcal{E}}(P) \quad (4)$$

综上所述，信息系统最关键的属性在核内。假设 $R, P \subseteq Q$ ，若 P 形成的所有等价类均包含在

R 形成的某一等价类中,则称 R 依赖于 P ,用 $P \rightarrow R$ 表示。

基于RBF神经网络和粗糙集理论的挖掘思想与算法设计

基于上述分析,提出一种基本思想:首先利用RBF神经网络对给出的预测机制以及初始属性进行估测,同时与实际决策属性进行对比,找到并过滤其中的干扰数据。然后依据属性的离散化特性,把数据转换为满足粗糙集挖掘规则的数据,将其传输给粗糙集,从而对属性进行约简,对规则进行确定。算法详细实现步骤为:

1) 首先对概念层属性对象进行泛化操作,完成对表中条件属性和决策属性的分析,塑造一个具有不可分辨关系的属性表。

2) 将和步骤1)得到的属性表对应的数据传输给RBF神经网络,从而实现训练与预测,不断对传输的数据值进行修正,直至获取最佳预测效果,得到所传输的数据值。

3) 对REF神经网络的估测曲线与误差曲线进行研究,找到其中误差相对较大的值,并将其清除。

4) 完成经由RBF神经网络改进后数据的离散化处理。

5) 依据粗糙集理论,完成上一步获取的经离散化处理数据属性的约简操作,找到不可分辨关系中的分辨矩阵,同时对其核进行计算。

6) 依据上下近似集理论求出上下近似集,边界域以及负域。

7) 形成规则,同时依据准确度设置采集规则。

实例诊断仿真与分析

基于RBF神经网络与粗糙集的挖掘电力变压器故障诊断仿真,将油中溶解气体分析数据中的 H_2 以及 CH_4 两种油中溶解气体的相对百分含量作为RBF神经网络的输入矢量;以正常(10000)、低温过热(01000)、中温过热(00100)、高温过热(00010)以及局部放电(00001)5种故障编码为输出矢量。

本文从相关文献中找出100组经吊心检测后故

障类型相对准确的故障数据,将其中的75组作为RBF神经网络的训练样本,将剩余的25组作为检验样本。在Matlab7.0编程环境下对基于RBF神经网络与粗糙集的网络训练情况和检验结果进行分析。

采用本文方法和传统方法对网络进行训练的结果比较如表1所示。

表1 本文方法和传统方法的训练结果比较

平滑因子	故障1	故障2	故障3	故障4	故障5
1	0/13	0/10	0/12	0/8	9/14
0.9	0/13	0/10	0/12	0/8	9/14
0.8	0/13	0/10	0/12	0/8	9/14
0.7	0/13	0/10	1/12	0/8	9/14
0.6	1/13	0/10	1/12	1/8	9/14
0.5	2/13	0/10	0/12	3/8	9/14
0.4	7/13	0/10	5/12	3/8	9/14
0.3	8/13	7/10	7/12	5/8	11/14
0.2	8/13	9/10	7/12	6/8	11/14
0.1	9/13	9/10	10/12	7/8	13/14
本文方法改进	12/13	9/9	11/12	8/8	14/14

分析表1可以看出,当统一的平滑因子 σ 值逐渐降低时,对各种类型故障的检测率逐渐增强,然而由于统一平滑因子 σ 的理论基础有限,同时其值不可过小,一般情况下需大于0.05,因此采用统一平滑因子 σ 不能正确匹配其最佳值,无法准确实现电力变压器故障的检测。采用本文方法改进的平滑因子 σ ,可按照训练样本直接塑造网络,其样本整体识别率可达98.6%,远远高于传统方法,验证了本文方法的有效性。

在本文基于RBF神经网络与粗糙集的数据挖掘电力变压器故障诊断算法中,在最终权值 ω_2 逐渐减小的过程中,前期较大的权值使本文方法拥有较强的全局搜索能力,而后期较小的权值使本文方法拥有较强的局部搜索能力,提高算法的收敛性,符合自适应的思想。下图为本文方法和传统方法训练最优适应度值变化曲线。从图中可以看出,与传统方法相比,尽管本文方法减缓了算法的收敛速度,但同时也防止了算法早熟现象的产生,从而避免算法陷入局部最优解,使其在全局范围内收敛于全局最优解的能力大大增强。

