

一种利用自组织映射和径向基函数神经网络的 网络拥塞预测方法

葛彦强¹, 汪向征², 于江德¹

(1 安阳师范学院 计算机与信息工程学院, 河南 安阳 455002;

2 安阳师范学院 教育信息技术与传媒学院, 河南 安阳 455002)

摘 要: 文中提出了一种利用自组织映射(KSOM)和径向基函数(KR)神经网络进行网络拥塞预测的方法。目前的研究表明, 预测网络拥塞还存在一些问题, 尤其在数据集比较小的时候。因此, 为了使网络拥塞问题预测精度高, 在预测过程中有必要考虑原有的数据集中每个数据之间的关系。现在为了获得更多的有价值的位置信息, 采取了一系列的措施去满足不同数据的情况, 包括使用自组织映射神经网络和径向基函数神经网络算法。这一过程使网络能满足不同类型的数据。在本文网络拥塞预测中, 采用同一原始数据集, 分别对利用自组织映射和径向基函数神经网络的算法和另外两种算法的性能进行比较。实验结果表明, 利用自组织映射和径向基函数神经网络的算法具有更好的效果。

关键词: 网络拥塞预测; 自组织映射; 径向基函数

中图分类号: TP393.1

文献标识码: A

文章编号: 1000-7180(2012)12-0176-04

A Method of Network Blocking Forecasting about Kohonen Self-Organizing Maps and Radial Basis Function Network

GE Yan-qiang¹, WANG Xiang-zheng², YU Jiang-de¹

(1 School of Computer and Information Engineering, Anyang Normal University, Anyang 455002, China;

2 School of Educational Information Technology and Communication, Anyang Normal University, Anyang 455002, China)

Abstract: We propose an adaptive Kohonen Self-Organizing Maps and Radial Basis Function Network-based method (KR) for network blocking forecasting in the paper. It shows that there are some problems in the network blocking forecasting now, especially when the data set is just small. Therefore, for achieving high accuracy in the network blocking forecasting, it is necessary to consider the relationships between each data within the original data set in the forecasting process. Now to get more valuable position information, a series of processes including Kohonen neural network and RBF network is proposed to meet the types of different data. The process makes the network can meet the different kinds of data. In this application to a city's network blocking forecasting, we investigate KR's and two other algorithms' performance on a original data set. The comparison of experimental results shows that KR is better location performance than others.

Key words: network blocking forecasting; kohonen self-organizing maps; radial basis function

1 引言

随着 3G 网络的发展, 目前能够针对大规模交换机系统的实时数据采集和分析系统变成了可能。

然而, 普通基于逻辑判断的系统还不可能适应这个复杂、多变的环境^[1-3]。

早期的网络管理总是采取一种简单的网络监控系统。网络监控系统收集网络状态的相关信息, 并以

收稿日期: 2012-04-08; 修回日期: 2012-05-22

基金项目: 国家自然科学基金项目(60973051, 60875081)

一种易于理解的方式描述信息.当为了进行预测把现有的网络管理技术应用到基于知识发现中的时候,故障诊断的问题在一定程度上就解决了.

现在有许多学者在做这类研究,研究如何把知识发现和数据挖掘应用到网络故障的诊断中.但目前交换机还不能实现进行网络故障预测的技术.这样的话,在故障发生之前就将不能进行预测.

王建平^[4]已经提出了一种提高预测的策略,在仿真的神经网络中,通过增加算法的循环和向上或向下的数据量,去预测网络的特征,并且通过实验证明两种策略的正确性.然而,这项研究忽略了工作日与休息日的差异,使其性能在一定程度上受到限制.

王晓敏^[5]提出了一种新的改进 BP 神经网络的预测算法,该算法具有较强的非线性拟合能力,在实际应用和仿真中用来预测非线性时间序列数据的发展趋势.但在实际应用和仿真过程中,由于算法本身的限制和不足,对于仿真和计算都会带来很多问题,比如网络训练过程中程序异常中止、训练时间过长、仿真精度不高等.针对这样的情况,通过分析算法本身和训练仿真过程,找到了相应的原因和解决方法.研究了传统 BP 神经网络模型的缺陷并提出附加变量的方法来改进 BP 神经网络.然而,这个算法忽略了每一个样本的不同,这样每个样本间的干扰最终影响了算法的性能.

在本文中,首先对数据集进行预处理,然后把它作为输入去训练 Kohonen 神经网络.然后用分类好的数据把径向基函数神经网络作为最终的预测模型给训练出来.实验结果表明其性能优于其他两种算法.

2 Kohonen 神经网络

Kohonen 神经网络和其他神经网络相比有一个很大的不同.它的第二层,也被称为竞争层,有一维或者二维的网络矩阵,并且修改过的重心策略也有所不同.此外,在竞争层中,每个神经元都有它自己的相邻点.如图 1 所示,主要的神经元有其不同半径的区域.一个 Kohonen 网络的训练过程中大概包括 n 个输入节点和 m 个输出节点,步骤如下:

(1)Kohonen 网络像其他竞争神经网络一样,把输入节点的胜出者作为一个特定类型的模型.

(2)定义胜出者节点集合,包括在胜出者节点范围内的所有节点.

(3)随着训练过程的进行,胜出者的范围将逐渐变得越来越小,直到它只包含胜出者本身.




图1 神经元的二维图层

3 径向基函数神经网络

径向基函数(RBF)神经网络有一个输入层、一个隐藏层和一个输出层.隐藏层的神经元中含有高斯传递函数,能够从神经元的中心向周围成反比输出.

RBF 网络与 K-Means 聚类 and 概率神经网络(PNN)和一般回归神经网络(GRNN)类似,尽管实现起来大不相同,但在概念上是类似的.主要的区别是, PNN /GRNN 网络训练文件中的每一个点有一个神经元,而 RBF 网络具有一个可变数目的神经元,通常远小于训练点的数量.在针对中小型训练集的问题上, PNN/GRNN 网络通常比 RBF 网络更准确些,但 PNN/GRNN 网络对大的训练集并不适合^[7].

一个径向基函数神经网络在空间中可以定位一个或多个 RBF 神经元描述的预测变量 (x, y) . 在这个空间有多个与预测变量相同的值.其欧氏距离是从评估点(如图中的三角)到每个神经元的中心.径向基函数(RBF)被应用于判断距离对于计算每一个神经元影响的重要性^[7].

$$\text{Weight} = \text{RBF}(\text{distance})$$

如果有多个预测因子变量,那么径向基函数就有像变量一样多的值.图 2 所示三个神经元在一个有两个变量 X 和 Y 的空间, Z 是 RBF 函数计算出来的值.一个神经元的最好预测值是通过 RBF 函数输出值的和乘以每个神经元的计算权重得来的.




图2 神经元空间

径向基函数神经元有一个中心和一个半径. 对于每个神经元半径可能是不同的, 在由建模工具产生的 RBF 网络里, 每一个维度半径都可能是不同的. 随着传播范围的扩大, 距离点比较远的神经元影响力越大.

4 自组映射图和径向基函数网络算法

如何正确认识差异和避免每个样本之间的干扰, 样本是在网络拥塞预测中影响性能的一个关键问题. 我们打算使用的自组映射图和径向基函数网络算法(KR)就是针对网络拥塞进行预测^[8-9]. KR 算法的主要步骤如下:

(1) 预处理数据集, 并且初始化所有必要的参数. 对于神经网络应该有许多参数 (如径向基函数的类型、输入层神经元的数量、隐藏层神经元的数量、输出层神经元的数量等).

(2) 为了培养 Kohonen 神经网络, 需要把数据集作为输入, 因此把数据进行分类. 通过对 Kohonen 神经网络进行训练以后, 该数据集被划分为 n 种类型.

(3) 利用分类好的数据, 对径向基函数(RBF)神经网络进行训练;

对于通过第二步得到的每一种类型, 训练一个相应的 RBF 神经网络.

(4) 把 RBF 神经网络作为最终的预测模型.

使用第三步得到的 RBF 神经网络, 预测接下来的几小时的网络阻塞.

5 实验结果

为了评价算法的性能, 这部分比较了 KR 算法和另外两个算法. 这两个算法分别为: (1) 不分类数据集, 并使用原始数据集作为输入去训练径向基函数神经网络得到最终的预测模型; (2) 把每一个样本作为输入训练 RBF 作为最终的预测模型. 在这里, 我们把这两个算法作为算法 1 和算法 2.

以某一个城市 15 天的网络堵塞数据集作为原始的数据集, 把三天的数据作为样本, 如图 3~图 5, 很容易发现三天的趋势是不同的.

Kohonen 神经网络进行训练后, 数据被 KSOM 分为五种类型. 当 RBF 神经网络进行训练后, 这种神经网络视为最后的预测模型. 与其他算法进行比较我们得到了图 6 和表 1.




图 3 第 1 天的拥塞值




图 4 第 4 天的拥塞值




图 5 第 6 天的拥塞值

表 1 算法性能比较

time	Ratio		time	Ratio	
	Strategy1	Strategy2		Strategy1	Strategy2
1	1.103326	1	20	9.24E-06	0.892561
2	3.048842	1	21	1.48E-06	9.86E-07
3	9.189905	1	22	2.50E-06	0.484629
4	6.949086	1	23	3.20E-06	13.40708
5	6.487304	1	24	4.87E-06	1.703338
6	3.839856	1	25	9.23E-06	0.481356
7	3.877447	1	26	0.000254	56.10913
8	9.293391	1	27	1.70E-05	4.264499
9	3.438204	1	28	3.52E-06	0.045864
10	7.732415	1	29	8.50E-07	0.261096
11	4.433561	1	30	3.77E-05	1.397313
12	4.55989	1	31	3.36E-05	6.256821
13	3.800938	1	32	1.41E-06	0.210171
14	8.89E-06	4.81E-06	33	3.36E-06	0.064483
15	1.84E-06	1.550398	34	8.13E-07	1.57E-06

表 1 描述偏离度的值. 第一栏显示时间,第二列显示偏离度,它等于算法 1 的偏差除以 KR,第三栏显示的偏离度等于算法 2 的偏差除以 KR. 很容易发现无论是算法 1 或算法 2 大多数时候比率大于 1,这意味着 KR 比其他算法具有较高的准确率.

图 6 显示准确度随时间不断变化的. 很明显, KR 算法比其他两种算法更接近零,它表明 KR 算法具有更高的精度.




图 6 算法比较

6 结束语

KR 算法比其他算法在精度上更好. 虽然传统的算法在一定程度上可以解决这个问题,但都忽视了不同的数据集之间的关系. 因此,文中提出了 KR 算法去满足所需的精度. 网络拥塞预测实验是针对的城市历史数据集合,表明该方法有能力解决这个问题. 必须指出, KR 算法只是一个静态方法,不能使用历史的数据. 但是研究结构方程模型,利用潜在的变量分析测量结果之间的关系能解决这个问题的有关历史元素.

参考文献:

[1] Gonzalez M C, Hidalgo C A, Barabasi A L. Under-

standing individual human mobility patterns[J]. Nature, 2008,453(7196):779-782.

[2] El Barachi, Glitho M, Dssouli R. Control-level call differentiation in IMS-based 3G core networks[J]. Network, IEEE , 2011, 25 (1): 20-28.

[3] Paul, U, Subramanian, A. P, Buddhikot, M. M, Das, S. R. Understanding traffic dynamics in cellular data networks[J]. INFOCOM, 2011 Proceedings IEEE, 2011, 4(10-15): 882-890.

[4] 王建平,郭尚. BP 神经网络预测算法性能的改进策略[J]. 微电子学与计算机,2007,24(10):144-149.

[5] 王晓敏,刘希玉,戴芬. BP 神经网络预测算法的改进及应用[J]. 计算机技术与发展,2009,19(11):64-67.


[6] Staley, Justin. Neural networks[J]. Proceedings of the International Joint Conference on Neural Networks, 1999(6):4432-4434.

[7] DTREG(Software For Predictive Modeling and Forecasting), RBF Neural Networks[EB/OL]. [2012-02-08]. <http://www.dtreg.com/rbf.htm>.

[8] Miklós Hoffmann. Numerical control of Kohonen neural network for scattered data approximation[J]. Numerical Algorithms ,2005(39): 175-186.

[9] Kumar, Swagat , Behera, Laxmidhar; McGinnity, T. M. Kinematic control of a redundant manipulator using an inverse-forward adaptive scheme with a KSOM based hint generator[J]. Robotics and Autonomous Systems, 2010,58(5):622-633.

作者简介:



葛彦强 男,(1980—),硕士,讲师. 研究方向为中文信息处理、神经网络.