

混沌 RBF 神经网络异常检测算法

翁 鹤,皮德常

(南京航空航天大学 计算机科学与技术学院,江苏 南京 210016)

摘要:针对传统神经网络异常检测算法的准确率问题,文中将混沌和 RBF(Radial Basis Function)神经网络相结合,既可利用混沌的随机性、初值敏感性等特点,也可发挥 RBF 神经网络大规模并行处理、自组织自适应性等功能。文中对混沌时间序列进行相空间重构得到相空间向量,作为 RBF 神经网络的输入,通过 RBF 神经网络构建电力负荷序列的拟合函数,在此基础上进一步预测,比较预测值与真实值的偏差,从而判断检测信号是否为异常信号。实验结果表明,该方法相对于其他算法预测精度更高,具有较好的异常检测能力。

关键词:电力负荷;相空间重构;混沌时间序列;RBF 神经网络;异常检测

中图分类号:TP183

文献标识码:A

文章编号:1673-629X(2014)07-0029-05

doi:10.3969/j.issn.1673-629X.2014.07.008

Chaotic RBF Neural Network Anomaly Detection Algorithm

WENG He, PI De-chang

(College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics,
Nanjing 210016, China)

Abstract: For the accuracy problem of traditional neural network anomaly detection algorithm, propose a method of combining chaos and RBF (Radial Basis Function) neural network, not only can take advantages of the randomness and initial value sensitivity and others of chaos, but also make use of the large-scale parallel processing, self-organization and adaptive capability of RBF neural networks. Reconstruct the chaotic time sequence to obtain the phase space vector as the input of RBF neural network, by which build the electricity load sequence fitting function. Then use this function to take one-step prediction in the phase space reconstruction. At last, compare predicted value and true value of the deviation, in order to determine whether the abnormal signal or detection signal. Experimental results show that this method has better prediction accuracy and anomaly detection capabilities.

Key words: electricity load; phase space reconstruction; chaotic time series; RBF neural network; anomaly detection

0 引言

随着信息产业的高速发展,生产和生活事件中收集并存储的数据信息规模由 GB 向 TB、PB 级别发展,大数据中隐含着大量的异常数据或者异常点。异常检测的工作就是在大量数据中如何准确、快速地发现这些异常数据,防止由于异常数据所带来的不必要的问题或事故。异常检测应用领域广泛,因此一直是国内外的研究热点,并逐渐发展为数据挖掘的重要分支。

目前异常检测算法多种多样,文献[1]中提出了基于距离的异常检测算法 DOLPHIN,该算法具有线性的 CPU 和 I/O 成本,但是算法的距离函数和参数选择存在一定困难,实际应用难度较大。文献[2]提出了基于 AVF(Attribute Value Frequency)的并行异常检测

算法,该算法采用 MapReduce 模型,拥有良好的平衡和容错机制,降低了算法的运行时间,但是异常检测的准确度提升并不明显。文献[3]提出了一种混沌的异常数据动态检测方法,该算法引入混沌的思想,有效避免了屏蔽效应和异常数据识别等问题,但是其建立的异常探测模型缺乏良好的自适应性。文献[4]提出基于统计聚类 RBF 神经网络的异常检测方法(SCRBF)。该方法采用隐单元简化机制,降低了 RBF 神经网络的复杂性,但需预先设定标准化输出向量的所有分量的阈值以及初始聚类个数,算法准确度难以保证。为了克服以上算法的不足,降低异常检测算法的漏检率和误判率,文中提出了一种改进的基于混沌时间序列的 RBF 神经网络异常检测算法。该算法基于混沌时间

收稿日期:2013-09-10

修回日期:2013-12-20

网络出版时间:2014-04-24

基金项目:国家国防技术基础科研项目(Z201152010)

作者简介:翁 鹤(1988-),女,硕士,研究方向为数据挖掘;皮德常,博士,教授,CCF 会员,研究方向为数据挖掘、大数据管理和分析。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20140424.0818.057.html>

序列的短期可预测性,结合 RBF 神经网络对非线性数据的良好逼近性,实现基于 RBF 神经网络的混沌时间序列预测,并根据预测值与实际值的误差作为检测数据是否异常的判断依据。实验表明,改进的 RBF 神经网络混沌预测模型较 SCRBF 模型的误差更小,异常检测准确度更高。该算法在工业行业中具有很高的应用价值,特别是在电力负荷领域^[5],该领域数据具有明显的混沌时间序列属性。

1 相空间重构

相空间重构是处理混沌时间序列的重要步骤,它通过时间序列能够反向创建原系统的相空间结构。起初采用相空间重构研究如何恢复高维相空间的混沌吸引子,现在相空间重构已发展为混沌时间序列预测和混沌判别中最重要的内容之一^[6]。相空间重构的基本思想是 Packard 等人提出的延迟坐标法,之后 Takens 给出了该方法的数学证明,Takens 嵌入定理说明,一维混沌时间序列可以重构出与原系统等价的相空间,只要延迟坐标维数 $m \geq 2d + 1$,其中 d 是动力系统的维数,有规律的吸引子便可以从这个嵌入维空间内恢复出来,原动力系统在重构的 R^m 空间中的轨线上保持微分同胚。

定义 1:在度量空间 (N, ρ) , (N_1, ρ_1) 中,假设存在映射 $\varphi: N \rightarrow N_1$ 满足如下条件:

(1) $\rho(x, y) = \rho_1(\varphi(x), \varphi(y))$, $\forall x, y \in N$, 则称 (N, ρ) , (N_1, ρ_1) 是等距同构的。

(2) φ 满映射。

定义 2:如果度量空间 (N_1, ρ_1) 与 (N_2, ρ_2) 的子空间 (N_0, ρ_0) 等距同构,则称度量空间 (N_1, ρ_1) 可以嵌入 (N_2, ρ_2) 。

Takens 定理:如果 $\varphi: M \rightarrow M$ 是一个光滑的微分同胚,其中 M 是 d 维流形, $y: M \rightarrow R$, y 有两阶连续导数, $\varphi(\varphi, y): M \rightarrow R^{2d+1}$, 其中 $\varphi(\varphi, y) = (y(x), y(\varphi(x)), y(\varphi^2(x)), \dots, y(\varphi^{2d}(x)))$, 则 $\varphi(\varphi, y)$ 是 M 到 R^{2d+1} 的一个嵌入。

现在常用的相空间重构方法为延迟矢量法, Takens 定律认为系统中与分量相互作用的其他分量决定该分量的演化。因此,重构系统相空间只需考察一个分量 $\{x(t) \mid t = 1, 2, \dots, N\}$, 通过不同延时点上的观测值找到 m 维的相空间矢量。

$$\{x(t), x(t + \tau), \dots, x(t + (m - 1)\tau)\}^T \quad (1)$$

式中, N 是时间序列长度; m 为嵌入维数; τ 为延迟时间; $t = 1, 2, \dots, M$, $M = N - (m - 1)\tau$ 为重构相空间变量个数。

其中, τ 的选取影响 $x(t)$ 和 $x(t + \tau)$ 的独立程度, 嵌入维 m 表示能够包容以状态转移构成的吸引子最

小相空间的维数,因此嵌入维数 m 和延迟时间 τ 的选取十分困难并且具有十分重要的意义。

2 径向基函数神经网络

RBF 神经网络^[7]是以径向基函数为核心构成的神经网络,该算法选择高斯函数作为 RBF 神经网络的核心函数,高斯函数具有单调递减性,具有良好的局部特性:仅在中心点附近的某一领域内相对显著,随着与中心点距离的增大,其值逐渐趋近于 0^[8]。因此,这类具有局部逼近能力的径向基函数又称为局部感知场神经网络,实际应用比较广泛。假设函数 $h \in L^2(R^d)$ 是径向的,则存在函数 $\varphi \in L^2(R)$, 对于 $v_x \in R^d$, 则式 (2) 成立。

$$h(x) = \Phi(\|x\|) \quad (2)$$

式中, $\|x\|$ 表示 x 的 Euclidean 范数, $\|x\|$ 的傅里叶变换同样也是径向的。

径向基函数的通用表达式为:

$$h(x) = \Phi((x - c)^T E^{-1}(x - c)) \quad (3)$$

式中, c 表示函数中心向量; h 表示径向函数; E 表示变化矩阵,一般为 Euclidean 矩阵; $(x - c)^T E^{-1}(x - c)$ 表示矩阵 E 确定的情况下输入向量 x 与中心 c 的距离衡量方法。

若 E 表示一个 Euclidean 矩阵,此时则有 $E = r^2 I$, 其中 r 表示径向基函数的半径,对式 (3) 简化得:

$$h(x) = \Phi((x - c)^T (x - c) / r^2) \quad (4)$$

进一步简化得到:

$$h(x) = \Phi(\|x - c\| / r^2) \quad (5)$$

式 (5) 即为算法中 RBF 神经网络的核心函数的表达式。一般 RBF 神经网络为三层结构,即输入层、隐含层和输出层。RBF 神经网络的输入层主要包含输入信号源节点,隐含层由径向基函数构成,输入层到隐含层的空间变化采用非线性的径向基函数完成;隐含层到输出层的空间变换为线性变换,即输出层节点的输出值由隐含层的输出信号线性加权获得。

3 改进 RBF 神经网络的异常检测算法

3.1 最佳延迟 τ 和嵌入维数 m 确定方法

在相空间重构中,延迟时间 τ 和嵌入维数 m 的选取具有十分重要的意义。在相空间重构时, Takens 嵌入定理并没有对延迟时间 τ 做出限定,而实际情况下, τ 的选取影响极大,若 τ 太小,则无法充分展开混沌吸引子,产生较大的冗余误差;若 τ 太大,则不相关误差变大。嵌入维 m 表示能够包容以状态转移构成的吸引子最小相空间的维数。在相空间重构中常用的方法就是 C-C 方法^[9],该方法是将 τ 和 m 联合起来的嵌入窗宽 $\tau_w = (m - 1)\tau$ 作为影响相空间重构的主要因素,

应用关联积分同时估计出时间延迟 τ 和嵌入窗宽 τ_w ,并以 τ_w 的值来通过公式计算嵌入维数 m 的值。C-C 方法中全局最小点和局部最小点均容易受到干扰。

文中最佳延迟时间 τ 的确定采用互信息函数^[10] 的极小值来确定,其表达式如下:

$$M(x_i, x_{i-\tau}) = \sum_{i,j} p_{i,j}(r) \ln \frac{p_{i,j}(r)}{p_i p_j} \tag{6}$$

其中, i 表示第 i 个时间间隔; p_i 表示第 i 个时间间隔中点 x_i 出现的概率; $p_{i,j}(r)$ 表示点 x_i 在 t 时刻出现在时间间隔 i 和在 $t + \tau$ 时刻出现在时间间隔 j 的联合概率。

文中采用伪近邻点法确定嵌入维数 m ,设吸引子的维数为 d ,则嵌入维数 m 取值选取使吸引子完全打开的最小维数,当 $m < d$ 时,在相空间中吸引子不能完全打开,此时吸引子会在相空间产生一些投影点,相空间中的其他点与投影点形成最近邻点,而两个点并非为真正的最近邻点,因为在原系统中这两个点非近邻点,因此称其为伪近邻点。设相空间中的任意一点 $y(t)$,则判断伪近邻点的方法如下:

$$\frac{|D_{m+1}^2(t) - D_m^2(t)|^{\frac{1}{2}}}{D_m(t)} = \frac{|x(t + m\tau) - x(t' + m\tau)|}{D_m(t)} > \rho_m \tag{7}$$

其中, $D_m(t)$ 为嵌入维数为 m 时相空间中任一点 $y(t)$ 与其最近邻点 $y^N(t)$ 之间的欧几里得距离。根据公式(7)计算 m 由小变大时的伪最近邻数 N ,再计算嵌入维数从 m 到 $m + 1$ 时 N 的变化量 ΔN ,作 $\frac{\Delta N}{N}$ 到 m 的曲线, $\Delta N = 0$ 时,即在 $\frac{\Delta N}{N}$ 降为 0 时,此时 m 的值就是所求的最佳嵌入维数 m 。

3.2 改进 RBF 神经网络混沌序列预测

混沌时间序列具有长期不可预测而短期可预测^[11] 的特点,所以,在检测混沌背景下的目标信号时,需先对混沌时间序列进行建模,然后对接收的信号进行预测。通过对接收信号的预测值与真实值的误差值的大小来检测该信号是否异常^[3] 。利用 RBF 神经网络对混沌信号进行预测与检测,是因为神经网络可以很好地拟合类似混沌系统这种非线性动力学系统。

文中经过对上述函数式简化后构造 RBF 神经网络,利用改进的 RBF 神经网络进一步预测,步骤如下:

(1) 对 x_1, x_2, \cdots, x_n 原始数据做归一化处理,将数据分为训练和预测两部分。再对训练部分进行相空间重构。一般归一化处理得到的时间序列均值为 0,方差为 1,然后利用上节描述的 C-C 方法进行相空间重构,计算嵌入维数 m 及延迟时间 τ ,重构相空间中的点数为 $N = n - (m - 1)\tau$ 。在对原始数据进行归一化处

理时,利用公式(8)进行优化,提高模型的预测能力。

$$x_i = \frac{0.1 * (x_i - x_{\max}) + 0.9 * (x_{\min} - x_i)}{x_{\min} - x_{\max}} \tag{8}$$

其中, x_i 为混沌时间序列的第 i 个观测值; x_{\min} 为时间序列的最小值; x_{\max} 为时间序列的最大值。

(2) 用训练样本训练 RBF 神经网络。使用 MATLAB 神经网络工具中提供的 newrbe 函数,采用高斯函数为径向基函数,径向基函数的中心位置选取为 c ,宽度为 r ,这些通过 newrbe 函数来确定,调用 newrbe 函数时只需提供取相空间重构中的状态点作为输入向量 P ,向量 P 为前 $N - 1$ 个 m 维点序列,输入层神经元个数为 N 个。 T 的取值为一步之后的下一个状态点,表示目标向量,即取相空间重构中的状态点的第 m 维,为 $N - 1$ 个一维点序列,可知输出层神经元为 1。SPREAD 表示隐含层的分布密度,SPREAD 的大小可调节隐含层的神经元数目。SPREAD 增大,函数拟合则更加平滑,与实际值的误差就更小;但 SPREAD 增大,同样会导致神经元数目增多,从而大幅增加运算量,因此需要选择合理的 SPREAD 值,缺省情况下 SPREAD 值取 1。

取中心向量:

$$X(N) = (x(n - (m - 1)\tau), x(n - (m - 2)\tau), \cdots, x(n))$$

作为 RBF 神经网络的输入值,一步预测可得到 $\hat{x}(n + 1)$ 。

若需要进行多步预测,可令 $x(n + 1) = \hat{x}(n + 1)$,得到新的时间序列 $x(2), x(3), \cdots, x(n + 1)$ 。

取中心向量:

$$X(N + 1) = (x(n - (m - 1)\tau), x(n - (m - 2)\tau), \cdots, x(n + 1))$$

作为神经网络输入,经一步预测得到 $\hat{x}(n + 2)$;依次类推,可得到时间序列的多步预测。

RBF 神经网络预测模型结构如图 1 所示。

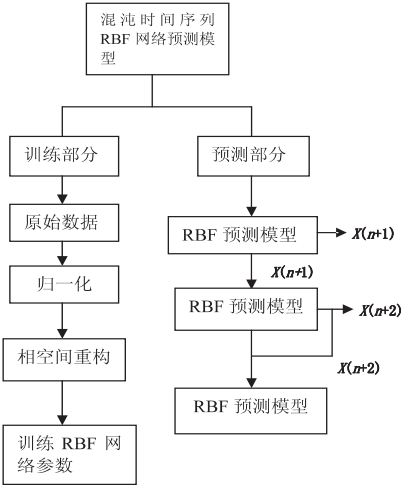


图 1 混沌时间序列 RBF 神经网络预测模型

3.3 改进 RBF 神经网络异常检测

传统的基于预测的异常检测算法^[12]通常存在着阈值选择困难的问题,而阈值的选择对于异常检测的准确度又尤为重要,因此,文中针对阈值选择设计了以下异常检测优化算法,算法步骤如下:

用 RBF 神经网络对混沌时间序列进行建模,将 RBF 神经网络作为一个预测器,使用数据样本中的正确数据对神经网络进行训练,使其预测误差较小,达到理想值,且对时间序列有较好的短期预测性能;否则,改变网络拓扑结构,重新训练,直到满足要求。

用建立好的预测模型对接收到的数据 $x(n)$ ($n = 1, 2, \dots, N_T$) 进行一步预测,得到预测值 $\hat{x}(n)$, 将预测值与真实值进行比较,得到一步预测绝对误差 $\varepsilon(n) = |x(n) - \hat{x}(n)|$ 。

根据训练样本的数据,计算 RBF 神经网络的样本的均方根差:

$$Perr = \frac{1}{n} \sum_{i=1}^n \varepsilon(i) / D(x)$$

(9)

将样本的均方根误差作为阈值与得到的预测误差的平方值进行比较,大于样本均方根误差的值即为检测数据中的异常点。

该方法既可以提高神经网络预测的准确性,也可以根据不同的数据集进行动态阈值的调整,无需进行多次试验,根据经验调整阈值,方便快捷,准确性高,具备推广价值。

4 数据实验

实验选取一个电力负荷的数据集^[13]作为训练样本和检测样本,因为电力负荷数据看似杂乱无章,其实是混沌的。传统的电力负荷异常检测方法^[14]是将电力负荷当作随机过程,根据时间序列的统计函数做出模型进行预测与检测,这样会存在高误报率和高漏检率的问题。将电力负荷看作混沌时间序列,根据混沌的特性与规律性,利用 RBF 神经网络的良好非线性逼近能力来对电力负荷进行预测和检测,可以更好地保证检测系统的准确性及工作效率。

实验选取洛伦兹方程 x 坐标作为时间序列绘制图像,使用相同的数据集分别对 SCRBF 神经网络一步预测和改进的 RBF 神经网络一步预测进行仿真计算并绘制图像,来比对算法的改进是否有效。图 2 为 SCRBF 神经网络一步预测法的样本真实值与预测值对比图和样本绝对误差图,图 3 为改进的 RBF 神经网络一步预测法的样本真实值与误差值对比图和样本绝对误差图。从图中可以看出,改进后算法中样本预测值曲线与真实值曲线更接近,二者贴合更紧密,且预测值更精确。由表 1 可知,改进后的 RBF 神经网络预测

算法的预测更加准确,其平方误差,均方误差,以及根均方误差等性能指标提升幅度均超过一个数量级。因此改进的 RBF 神经网络预测算法性能优于 SCRBF 预测算法,表现出其在混沌时间序列预测中的优越性。




图 2 改进前训练样本对比图和误差图




图 3 改进后训练样本对比图和误差图

表 1 改进 RBF 和 SCRBF 预测性能对比结果

时间序列	性能指标	SCRBF	改进 RBF
NSW	平方误差	0.017 3	$7.475\ 3 \times 10^{-3}$
	均方误差	1.627×10^{-5}	$6.811\ 7 \times 10^{-6}$
	根均方误差	0.003 1	$8.130\ 5 \times 10^{-4}$

神经网络训练成功后,可以对检测样本进行预测并检测,异常检测的阈值设定为训练样本的均方根误差 $8.130\ 5 \times 10^{-3}$ 。利用训练好的 RBF 神经网络对 500 个数据值的样本进行预测和检测,利用绝对误差的平方值与阈值进行比较,大于该阈值的点即为异常点。同样以洛伦兹方程 x 坐标作为时间序列绘图,图 4 为检测样本的预测值与样本值对比图,图 5 为检测样本误差的平方值。由图中可知,曲线变化异常点,样本误差平方值也大于阈值,因此可以通过图像判断这些曲线变化异常点即为检测样本中的数据异常点。将检测的异常点编号输出并在数据集中查找,发现通过图像判断的异常点与实际检测出的异常值即为实际检测

样本中的异常值。

5 结束语

文中提出的基于改进 RBF 神经网络的异常检测算法克服了传统算法泛化能力弱,容易过拟合等问题,提高了混度预测的精确度,从而保证了异常检测的准确性。实验结果表明,改进的 RBF 神经网络模型与 RBF 神经网络模型相比,预测误差更小,利用 RBF 神经网络对具备混沌特性的电力负荷数据集进行异常检测是可行的。




图4 检测样本值与预测值对比图




图5 检测样本误差平方值

参考文献:

[1] Angiulli F,Fassetti F. Very efficient mining of distance-based outliers[C]//Proc of the 16th ACM conference on information and knowledge management. New York, NY, USA: ACM Press,2007:791-800.

[2] Koufakou A,Secretan J,Reeder J,et al. Fast parallel outlier detection for categorical datasets using MapReduce[C]//Proc of IEEE international joint conference on neural network. Hong Kong, China: IEEE,2008.

[3] 王建州,马志新,李 廉. 基于混沌的异常数据的动态识别与挖掘[J]. 清华大学学报(自然科学版),2005,45(S1): 1753-1756.

[4] 张军峰,胡寿松. 基于一种新型聚类算法的 RBF 神经网络混沌时间序列预测[J]. 物理学报,2007,56(2):713-719.

[5] 谢忠玉. 电力短期负荷时间序列混沌特性分析及预测研究[D]. 哈尔滨:哈尔滨工程大学,2010.

[6] 张淑清,贾 健,高 敏,等. 混沌时间序列重构相空间参数选取研究[J]. 物理学报,2010,59(3):1576-1582.

[7] Liu Jinhai,Feng Jian,Guan Fusheng. Research on RBF neural network method of singularity detection in chaotic time series [C]//Proc of 2010 2nd international conference on signal processing systems. Dalian: IEEE,2010.

[8] Zhou P,Li D. A non-orthogonal and multi-width RBF neural network for chaotic time series prediction[M]//Green Communications and Networks. Netherlands: Springer,2012.

[9] 陆振波,蔡志明,姜可宇. 基于改进的 CC 方法的相空间重构参数选择[J]. 系统仿真学报,2007,19(11):2527-2529.

[10] 郭 伟. 基于互信息的 RBF 神经网络结构优化设计[J]. 计算机科学,2013,40(6):252-255.

[11] 杨 虎,王会琦,程代杰. 基于预测的序列异常数据挖掘[J]. 计算机科学,2004,31(4):117-119.

[12] 陶运信,皮德常. 基于邻域和密度的异常点检测算法[J]. 吉林大学学报:信息科学版,2008,26(4):398-403.

[13] 曹安照,田 丽. 基于 RBF 神经网络的短期电力负荷预测[J]. 电子科技大学学报,2006,35(4):507-509.

[14] 胡迎松,陈 明,范志明. 一种电力系统短期负荷预测的 RBF 优化算法[J]. 华中科技大学学报(城市科学版),2003,20(3):8-10.

[15] Goldfeather J,Interrante V. A novel cubic-order algorithm for approximating principal direction vectors[J]. ACM Transactions on Graphics,2004,23(3):609-612.

[16] 李 晔,王映辉,刘 晶. 基于脊谷特征提取的三维人脸识别[J]. 计算机工程与应用,2011,47(12):7-11.

[17] 谭一鸣. 网格模型上脊线与谷线的提取[D]. 杭州:浙江大学,2010.

(上接 28 第页)

[J]. 计算机工程,2007,33(12):12-15.

[10] Decarlo D,Finkelstein A,Rusinkiewicz S,et al. Suggestive contours for conveying shape[J]. ACM Trans on Graphics,2003, 22(3):848-855.

[11] 沈映泉. 基于文物三维模型的考古绘图自动绘制方法研究与实现[D]. 西安:西北大学,2011.

[12] Ohtake Y,Belyaev A,Seidel H P. Ridge-valley lines on meshes via implicit surface fitting [J]. ACM Transactions on

作者：翁鹤， 皮德常， WENG He， PI De-chang
作者单位：南京航空航天大学 计算机科学与技术学院, 江苏 南京, 210016
刊名：[计算机技术与发展](#) 
英文刊名：[Computer Technology and Development](#)
年，卷(期)：2014(7)

参考文献(14条)

1. [Angiulli F;Fassetti F](#) [Very efficient mining of distance-based outliers](#) 2007
2. [Koufakou A;Secretan J;Reeder J](#) [Fast parallel outlier detection for categorical datasets using MapReduce](#) 2008
3. [王建州;马志新;李廉](#) [基于混沌的异常数据的动态识别与挖掘](#) 2005(z1)
4. [张军峰;胡寿松](#) [基于一种新型聚类算法的RBF神经网络混沌时间序列预测](#) 2007(02)
5. [谢忠玉](#) [电力短期负荷时间序列混沌特性分析及预测研究](#) 2010
6. [张淑清;贾健;高敏](#) [混沌时间序列重构相空间参数选取研究](#) 2010(03)
7. [Liu Jinhai;Feng Jian;Guan Fusheng](#) [Research on RBF neural network method of singularity detection in chaotic time series](#) 2010
8. [Zhou P;Li D](#) [A non-orthogonal and multi-width RBF neural network for chaotic time series prediction](#) 2012
9. [陆振波;蔡志明;姜可宇](#) [基于改进的CC方法的相空间重构参数选择](#) 2007(11)
10. [郭伟](#) [基于互信息的RBF神经网络结构优化设计](#) 2013(06)
11. [杨虎;王会琦;程代杰](#) [基于预测的序列异常数据挖掘](#) 2004(04)
12. [陶运信;皮德常](#) [基于邻域和密度的异常点检测算法](#) 2008(04)
13. [曹安照;田丽](#) [基于 RBF 神经网络的短期电力负荷预测](#) 2006(04)
14. [胡迎松;陈明;范志明](#) [一种电力系统短期负荷预测的RBF优化算法](#) 2003(03)

引用本文格式：翁鹤. 皮德常. WENG He. PI De-chang 混沌RBF神经网络异常检测算法[期刊论文]-计算机技术与发展 2014(7)