文章编号:1001 - 9081(2005)09 - 2018 - 04

基于 Kohonen 神经网络的 B 样条曲面重构

范彦革,刘旭敏,陈　婧
(首都师范大学 信息工程学院,北京 100037)
(fanyange@126.com)

摘　要:探讨了三维散乱数据点的自由曲面自组织重构方法。建立了基于自组织特征映射神经网络的矩形网格重构模型及其训练算法。所建模型利用神经元对曲面散乱数据点的学习和训练来模拟曲面上点与点之间的内在关系,节点连接权向量集作为对散乱数据点集的工程近似化并重构曲面样本点的内在拓扑关系。通过该方法不仅能够对无规则散乱数据点进行逼近,并且通过该方法得到的曲面也可以作为后继曲面重构的初始曲面。仿真实验表明,所建神经网络模型可实现三维密集无规则数据点的曲面自组织重构集自压缩于一体。

关键词:曲面重构;B 样条曲面;Kohonen 神经网络;自组织特征映射
中图分类号: TP183　　**文献标识码**:A

B-spline surface reconstruction based on Kohonen neural network

FAN Yan-ge, LIU Xu-min, CHEN Jing
(*College of Information Engineering, Capital Normal University, Beijing* 100037, *China*)

Abstract: The approach to the freeform surface self-organizing reconstruction for the dense 3D scattered data was discussed. Based on the self-organizing feature map neural network, a rectangle mesh reconstruction approach and the training algorithm were developed. The inherent topologic relations between the scattered points on the surface were learned by the self-organizing feature map neural network. The weight vectors of the neurons on the output layer of the neural network were used to approximate the scattered data points. By this approach, not only to approximate the scattered data points and the surface which is reconstructed by this method can be as base surface for further process, but also the experiment indicates that by this approach, the reconstruction of the surface and the reduce of the dense scattered data points are combined into the same process. The computer simulation result shows that this method is effective.

Key words: surface reconstruction; B-spline surface; Kohonen neural network; Self-Organizing Feature Map (SOFM)

0　引言

逆向工程是指产品的设计制造过程来源于实物而并非来源于概念设计。例如,新型汽车的流线型外壳、人造假肢、艺术雕塑品等。在这种情况下,首先要对实物进行 CAD 模型重构,然后再进行后序操作,如模型修改、有限元分析、误差分析、数控加工指令的制造加工和产品检验等。将实物模型的扫描测量数据经过处理加工后,曲面重构就成为反向工程的关键技术。基于散乱数据点的曲面重构有多种方法。例如常见的方法有:隐式曲面重构方法[1,2]和参数曲面重构方法[3,4]。

不同曲面重构问题需要不同类型的曲面。本文采用的是 B 样条曲面(B-Spline surface)。这主要因为 B 样条曲面作为矩形域参数曲面的代表,B 样条具有统一、通用、有效的标准算法和强有力的配套技术,以及表示和设计自由曲线曲面的强大功能,在曲面重构中被广泛采用。

在逆向工程中,型值点数据具有大规模、散乱的特点,其 B 样条曲面主要由它的次数、节点值和控制点来形成矩形网格拓扑形状。在曲面重构问题中,已知的都是无规则散乱数据点,因此曲面的次数、节点值和控制点都是未知的。在 B 样条曲面中最重要的是数据点的参数化,也就是说如何给每个数据点分配参数值。数据点参数化的一种方法是通过最优化的方法来给数据点分配参数值,但是对于大量的数据点,这种方法将会导致具有未知量的复杂非线性状态[5]。另外,文献[6~8]中指出数据点参数化方法:首先根据边界构造初始曲面;然后将数据点(型值点)投影到该初始曲面上;根据投影位置算出相应数据点(型值点)的参数。对于特定类型的数据点来说,可以利用该方法进行数据点的参数化,但是在构造初始曲面时需要条件限制,即不允许曲面重叠,而且数据点映射时需要相应的映射函数。而且对于某些类型数据点来说很难找出满足所有这些限制条件的初始曲面。

基于上述的问题,本文中主要采用神经网络方法来对无规则散乱数据点集进行拟合。通过迭代方法 Kohonen 神经网络可以产生对原曲面不同逼近精度的 B 样条曲面。通过该方法得到的曲面可以对原始的散乱数据点集逼近,可以作为后继曲面重构的初始曲面,而且还可以对密集散乱数据点自组织压缩,并构建保持原数据点集的拓扑形状,这样降低原始数据点的数量,扩大了神经网络曲面重构方法的应用领域。

1　人工神经网络以及 Kohonen 神经网络

人工神经网络具有强大的泛函逼近能力,三层前向网络能以任意精度逼近任意连续函数及其各阶导数,神经网络将表示曲面的映射关系存储于网络的连接权值和阈值中,使模型具有较强的容错性能和联想能力,故利用神经网络进行对

收稿日期:2005 - 03 - 09;**修订日期**:2005 - 06 - 06　　**基金项目**:北京市教育委员会资助项目(KM200410028013)
作者简介:范彦革(1980 -),男,硕士研究生,主要研究方向:计算机辅助几何设计、数据挖掘;　刘旭敏,女,教授,博士研究生,主要研究方向:计算机辅助几何设计、数据挖掘;　陈婧,女,硕士研究生,主要研究方向:计算机辅助几何设计、数据挖掘.

重构的曲面能够局部修改和缺陷表面的局部修补。

1.1 Kohonen 神经网络

Kohonen 神经网络也称自组织特征映射(SOFM, Self-Organizing Feature Map)神经网络[9]是一种以无指导的方式进行网络训练,是具有自组织功能的神经网络,网络通过自身训练,自动对输入模式分类。在网络结构上,自组织竞争人工神经网络一般是由输入层和竞争层构成的两层网络,网络没有隐含层,两层之间各神经元实现双向连接,有时竞争层各神经元之间还存在横向连接。在学习算法上,它模拟生物神经系统依靠神经元之间的兴奋、协调与抑制、竞争的作用来进行信息处理的动力学原理,指导网络学习与工作。SOM 神经网络可以实现对输入模式的特征进行拓扑逻辑映射。

竞争层的拓扑结构有两种形状(图 1)。图 1 中的左图为矩形拓扑结构,其中每个网格节点(神经元)有四个直接邻节点。右图为三角形拓扑结构,其中每个网格节点(神经元)有 6 个直接邻节点。本文中竞争层拓扑结构采用的是矩形拓扑结构,主要因为 B 样条曲面利用的是矩形控制网格。

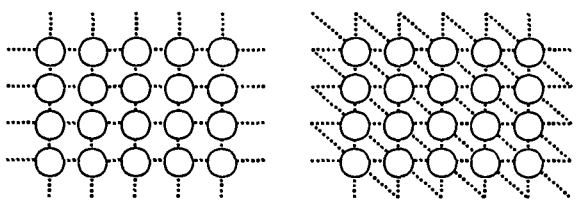


图 1　Kohonen 神经网络的竞争层的拓扑结构

1.2 Kohonen 神经网络的学习方法

设网络的输入模式 $X_k = [x_1^k, x_2^k, \cdots, x_n^k]^T, k = 1, \cdots, q$。对应的竞争层神经元的输出响应 $O_j, j = 1, \cdots, m$。竞争层中的神经元 j 与输入层神经元之间的权矢量 $W_j = [W_{j1}, W_{j2}, \cdots, W_{jn}]^T, j = 1, \cdots, m$。确定输入矢量 X_k 与连接权矢量 W_j 的最佳匹配,即决定竞争层中获胜神经元 g 的评价方法有:

(1) 利用输入矢量 X_k 与连接权矢量 W_j 的内积 $W_j^T X_k$。对所有的 $j = 1,2,\cdots,m$ 比较内积,其值最大者为对应的神经元,即为竞争层中的获胜神经元 g。即:

$$\begin{aligned} O_j &= W_j^T X_k \\ O_g &= \max[O_j] \end{aligned} \qquad j = 1,2,\cdots,m \quad (1)$$

(2) 利用输入矢量 X_k 与连接权矢量 W_j 的欧式距离,然后取欧式距离最小者对应的神经元即为竞争层中的获胜神经元 g。即:

$$\begin{aligned} d_j &= \| X_k - W_j \| \\ d_g &= \min[d_j] \end{aligned} \qquad j = 1,2,\cdots,m (2)$$

本文主要采用的第二种方法来进行评价竞争层中获胜的神经元。包含 n 个输入节点和 m 个输出节点的 Kohonen 网络的训练过程如图 2,训练过程的具体细节可以参考相关文献和书籍。

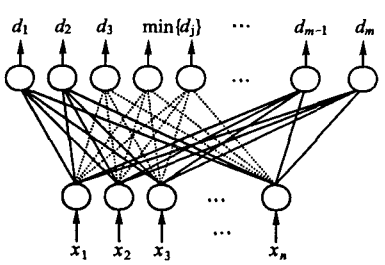


图 2　*Kohonen* 网络的训练过程

2　基于 Kohonen 网络的 B 样条曲面重构

B 样条曲面[10]的定义如下:

$$p(u,v) = \sum_{i=0}^{m} \sum_{j=0}^{n} d_{i,j} N_{i,k}(u) N_{j,l}(v),$$

$$u_k \leqslant u \leqslant u_{m+1}; v_l \leqslant v \leqslant v_{n+l} \quad (3)$$

该 B 样条曲面的次数为 (k, l)。其中,$N_{i,k}(u)(i = 0,1,\cdots,m)$ 与 $N_{j,l}(v)(j = 0,1,\cdots,n)$ 分别为 B 样条曲面的基函数。点 $d_{i,j}(i = 0,1,\cdots,m; j = 0,1,\cdots,n)$ 为控制点,构成一张控制网格。$U = [u_0, u_1, \cdots, u_{m+k+1}]$ 与 $V = [v_0, v_1, \cdots, v_{m+l+1}]$ 为两个节点矢量。

利用 Kohonen 网络进行 B 样条曲面重构时,网络的输入节点个数 $n = 3$,因此竞争层中每个节点与输入层中每个节点之间有三个相连接的权值,本文取竞争层每个节点对应的三个权值为三维空间的数据点 $O_j(w_j^i, w_j^i, w_j^i)$ 坐标分量,即网络输出。如图 3 所示。

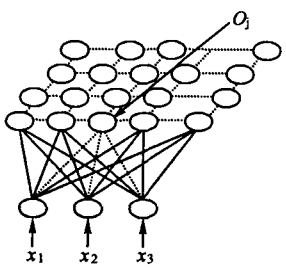


图 3　基于 Kohonen 网络的 B 样条曲面重构

输入节点的值为原散乱数据点集的坐标值,在训练过程竞争层中对应的网格节点将会向输入数据点位置移动,这是主要因为获胜的节点对应的坐标值与输入数据点的距离最近。训练过程重复进行至到网络训练完毕。最后,网络竞争层的拓扑结构符合原散乱数据点集的整体形状。

训练过程的详细算法如下:

输入:散乱的数据点 $X_k(x_{k1}, x_{k2}, x_{k3})(k = 1,2,\cdots,n)$ 的坐标值。

输出:网络输出节点 $O_j(w_j^i, w_j^i, w_j^i)(i = 1,2,3; j = 1,2,\cdots,m)$ 坐标值,以及符合散乱数据点集的网格拓扑结构。

(1) 取输入节点个数的值 $n = 3$,时间 $t = 1$,给定网络的拓扑结构和竞争层的输出节点个数 m。

(2) 选择散乱数据点集的中心点的坐标值加上一个小随机数来初始化网络的权值 $w_j^i(i = 1,2,3; j = 1,2,\cdots,m)$。

(3) 从散乱数据点集中随机地选择一个点 $X_k(x_{k1}, x_{k2}, x_{k3})(k = 1,2,\cdots,n)$ 作为网络的输入。

(4) 计算所有输出节点与输入节点之间的欧式距离:

$$d_g = \min\{d_j = \sum_{i=1}^{3} (x_{ki} - w_j^i)^2, j = 1,2,\cdots,m\} \quad (4)$$

(5) 通过邻域函数计算获胜节点 d_g 的邻域 $N_g(t)$,然后通过下面等式来更新获胜节点权值以及在 d_g 邻域内的节点权值:

$$w_j^i(t+1) = \begin{cases} w_j^i(t) + \eta(t)(x_{ki} - w_j^i(t)), & \forall j \in N_g(t) \\ w_j^i(t), & \forall j \notin N_g(t) \end{cases} \quad (5)$$

式中的 $\eta(t)$ 为增益项,$0 < \eta(t) < 1$,该函数值随着时间的增加而递减。

(6) $t = t + 1$,从原散乱数据点集中随机选择下一个点,重复执行步骤(4) ~ (6) 直到网络训练完毕。当竞争层的网格拓扑形状移动到一定状态下,即网络训练完毕。也就是增益

项 $\eta(t)$ 的值递减到一定值时。(通常取 $\eta(t) = 0.001$)

2.1 竞争层的拓扑结构和节点个数

在本文中,网络竞争层的拓扑结构采取矩形网格。主要是为了和 B 样条曲面所定义的网格结构相一致。在其他的应用[11]中,竞争层的拓扑结构采用三角形的网格。

竞争层中节点个数 m 的取值,在文献[12]中取 $m = 4 \times n$,这样就造成竞争层中的节点个数依赖于输入点的个数,如果当输入点的个数非常大时,网络的竞争层的节点数目会更大。本文主要根据数据点数目的大小来给节点个数赋值,如果 n 的取值较小时(小于 200),采用文献[12]中的方法。如果数据点的数目较大时,采用聚类方法对原始散乱数据点集进行聚类分析,产生不同的聚类,m 取值为聚类的个数。在训练过程中利用动态 Kohonen 神经网络(也称作增长元结构)[13]对竞争层中的节点个数 m 进行更新。基本思想是:在训练过程中对最活跃的竞争层节点附近添加节点,因此竞争层中的每个节点附加一个计数值,每当竞争层中节点获胜时,该节点的计数值加 1。在训练过程中,当节点的计数值大于指定阈值时,该节点(神经元)附近插入一列节点或者一行节点,这样不会影响竞争层网格的整体拓扑结构。

2.2 网络权值的初始化

网络权值的初始化是在网络训练开始阶段为网络输入节点和竞争层上节点之间的连接赋值,即为竞争层上节点指定坐标值,不同的应用情况需要不同的初始化方法。

最简单的初始化方法是:为网络中的每个权赋值为小随机数。这种情况会造成输出点与输入点之间的距离非常大。为了提高训练算法的效率可以用散乱数据点集的中心数据点附近的点值初始化网络的权值。

2.3 邻域函数和增益项

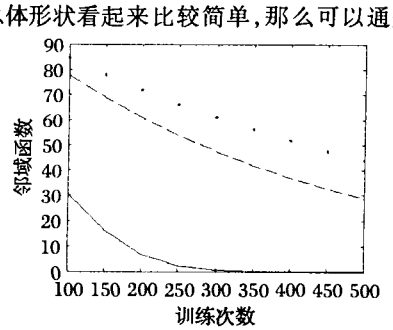
在网络训练的算法中涉及到两个隐函数:邻域函数和增益项。这两项直接影响网络对原散乱数据点集逼近的质量即最后得到曲面的好坏。文献[14]中提到获胜神经元的邻域大小和增益项对于训练时间的来说是一个重要的因素,并且这两项随着时间而递减。文献[15]中指出根据 Kohonen 神经网络的基本理论,除了高斯函数没有其他的原则来计算这两项。

2.3.1 邻域函数

在训练过程中,最佳的情况是初始阶段网络拓扑结构移动的区域要大一些,而在训练的结束阶段网络拓扑结构移动的区域要小一点。邻域函数取高斯函数为:

$$N_g(t) = \frac{m}{2} e^{-\frac{1}{2}(\frac{t}{s})^2} \tag{6}$$

式(6)中 t 为训练算法的重复次数,m 为网络的神经元(输出节点)的个数(m 为原散乱数据点集通过聚类方法得到的聚类个数)。s 为预先指定的固定值。在邻域函数中加入 s 主要的原因是:它可以控制邻域函数的陡度状况(如图 4)。如果散乱数据点集总体形状看起来比较简单,那么可以通过 s 的值来控制邻域函数值使它降低得快一些。如果散乱数据点集总体形状看起来比较复杂,那么可以利用 s 来控制邻域函数值使它降低得缓慢一些。这样可以对散乱数据点集更精确地逼近。在图4中,固定网络竞争层的节点个数 $m = 100$,s 分别取值为 100、200、300 时,所得邻域函数(式 6)曲线。随着 s 取值的增大,邻域函数曲线的陡度变的平缓。



$m = 100$ $s = 100$(实线) $s = 200$(虚线) $s = 300$(点画线)

图4 邻域函数曲线

2.3.2 增益项

增益项主要控制网络拓扑结构中节点移动距离的规模大小。增益项的值越小,那么网络上的节点和它的邻域内的节点 O_g 向输入点 X_i 移动的距离就越小。增益项的范围处于[0,1]之间。如果增益项等于1,那么点 O_g 将会接近输入点 X_i。在训练过程中,最佳的情况是在训练初始阶段网络拓扑结构上节点移动的距离大一点。而在训练的最后阶段,网络拓扑结构上的节点移动距离要小一点。像邻域函数一样增益项也取高斯函数:

$$\eta(t) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(\frac{t}{q})^2} \tag{7}$$

式(7)中 t 为训练算法重复的次数。q 为预先指定的固定值,其含义与邻域函数中的 s 含义相同(如图 5)。随着 q 取值的增大,增益项曲线的陡度变的平缓。

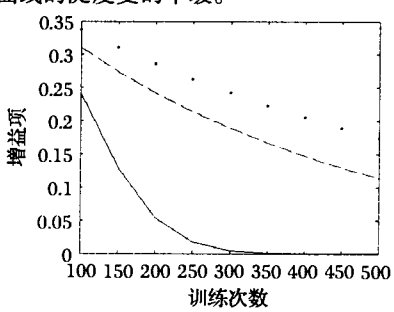


图5 $q = 100$(实线)、$q = 200$(虚线)、$q = 300$(点画线)时增益项曲线

3 仿真实验

Kohonen 网络拟合部分球面实验。

椭球面的参数方程表示如下:

$$\begin{cases} x = a\cos u\cos v \\ y = b\cos u\sin v \\ z = c\sin u \end{cases} \quad \begin{matrix} u \in [-\pi/2, \pi/2] \\ v \in [0, 2\pi] \end{matrix} \tag{8}$$

试验时,取 $a = 1, b = 1, c = 1, u \in [0, \pi/2], v \in [0, \pi/2]$。

仿真实验表明:本文所提出的基于迭代方法 Kohonen 神经网络可实现三维密集散乱数据点自组织压缩,生成期望疏密程度和逼近精度的矩形拓扑形状网络,并可有效保持原始数据点集的拓扑特征,从而实现了基于 B 样条的大规模散乱数据点的精确曲面重构,所得曲面可作为后继曲面重构的初始曲面。

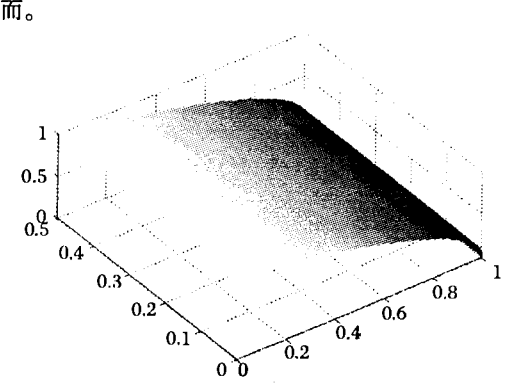


图6 取 500 个数据点所得原始曲面

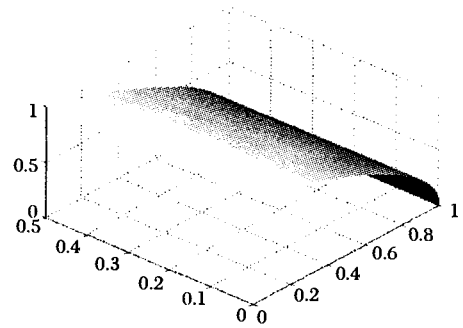


图 7　网络竞争层取 512 个节点训练后所得曲面

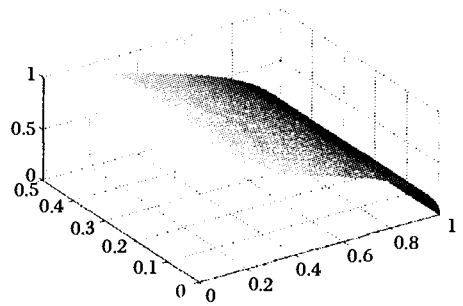


图 8　网络竞争层取 216 个节点训练后所得曲面

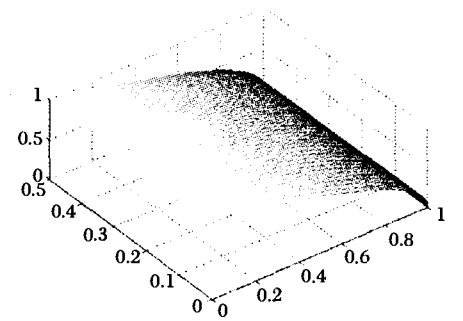


图 9　取 250 个数据点经网络训练以后所得曲面

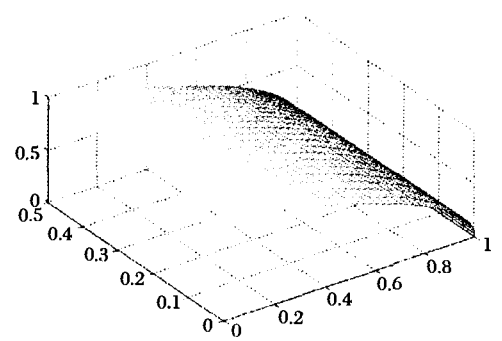


图 10　取 50 个数据点经网络训练后所得曲面

4　结语

逆向工程是目前国际国内 CAD/CAM 领域的前沿热点课题之一,自由曲面重构是其中的关键技术。由于 B 样条具有统一、通用、有效的标准算法和强有力的配套技术,以及表示和设计自由曲线曲面的强大功能,在曲面重构中被广泛采用。

上述工作表明本文所提出的基于迭代方法 Kohonen 神经网络的曲面自组织重构模型具有对测量的散乱数据点的自组织压缩和保持拓扑特征的映射能力,利用网络神经元对曲面空间样本点的学习和训练来模拟曲面上点与点之间的内在关系,可重构曲面样本点的内在拓扑关系,并可不必求出曲面具体的数学参数方程(有时候也是无法求出),可以产生对原曲面不同的逼近精度 B 样条曲面。通过该方法得到的曲面可以对原始的散乱数据点集进行逼近,或作为后继曲面重构的初始曲面,而且也可以对密集散乱数据点自组织压缩并构建保持原数据点集的拓扑形状,从而降低了原始数据点的数量。

此外,与传统曲面重构方法相比,本文所采样的迭代方法 Kohonen 神经网络的曲面重构具有以下特点:重构精度较高,可根据实际重构精度的需要,构造相应规模的神经网络;适合重构曲面的局部人工编辑与修改,迭代方法 Kohonen 神经网络经过重新训练,实现局部区域的数据重新拟合,使得局部编辑和修改成为可能;适合缺陷表面的局部修补,采用神经网络重构时,可将磨损区域数据和其周围的数据作为训练样本来训练网络,然后插值,则可在一定程度上修复磨损表面。

目前,在数据量的急剧增大和对网络传输要求越来越高的情况下。基于点的造型与基于点的绘制在图形中成为一个新的研究热点。下一步的工作设想是对于人工神经网络应用于测量几何造型方面继续进行探索和尝试,如何把神经网络所具有的优点应用到基于点的造型和基于点的绘制中的问题还需要进一步研究解决。人工神经网络所具有的许多优良特性,必将为几何造型的智能化开辟广阔的前景。

参考文献:

[1] MOORE D, WARREN J. Approximation of dense scattered data using algebraic surface[Z]. TR 90-135, Rice University, October 1990.

[2] MURAKI S. Volumetric shape description of range data using "blobby model"[J]. Computer Graphics (SIGGRAPH '91 Proceedings), 1991, 25(4): 227 - 235.

[3] SCLAROFF S, PENTLAND A. Generalized implicit functions for computer graphics[J]. Computer Graphics (SIGGRAPH'91 Proceedings), 1991, 25(4): 247 - 250.

[4] VEMURI BC. Representation and Recognition of Objects From Dens Range Maps[D]. Department of Electrical and Computer Engineering, University of Texas at Austin, 1987.

[5] VARADY T, MARTIN RR, COX J. Reverse engineering of geometric models - an introduction[J]. Computer-Aided Design, 1997, 29(4): 255 - 168.

[6] MA W, KRUTH JP. Parameterization of randomly measured points for least squares fitting of B-spline curves and surfaces[J]. CAD, 1995, 27(9): 663 - 675.

[7] MA W, HE P. B-spline surface local updating with unorganized points[J]. Computer-Aided Design, 1998, 30(11): 853 - 862.

[8] PIEGL L, TILLER W. Parametrization for surface fitting in reverse engineering[J]. Computer-Aided Design, 2001, 33(8): 593 - 603.

[9] KOHONEN T. Self-organization and associative memory[M]. 3rd edition, Springer Verlag, 1989.

[10] 施法中. 计算机辅助几何设计与非均匀有理B样条(CAGD&NURBS)[M]. 北京: 高等教育出版社, 2001.

[11] YU Y. Surface reconstruction from unorganized points using self-organizing neural network[A]. Proc of IEEE Visualization 99[C], 1999. 61 - 64.

[12] HOFFMANN M, VARADY L. Free-form surface for scattered data by neural networks[J]. Journal for Geometry and Graphics, 1998, 2(1): 1 - 6.

[13] FRITZKE B. Growing cell structures - a self-organizing network for unsupervised and supervised learning[J]. Neural Networks, 1994, 7(9): 1441 - 1460.

[14] HOFFMANN M. Modified Kohonen neural network for surface reconstruction[J]. Publ. Math, 1999, 54(Suppl.): 857 - 864.

[15] ROJAS R. Neural Networks — A Systematics Introduction[M]. Springer-Verlag, 1996.