

文章编号:1001-9081(2010)06-1543-04

## 自组织特征映射网络在建筑工程分类中的应用

冯文峰<sup>1</sup>, 祝文娟<sup>1</sup>, 周宇光<sup>2</sup>

(1. 河南理工大学 计算机科学与技术学院, 河南 焦作 454002; 2. 中国海外集团 信息化部, 香港)

(cbfwq3006@163.com)

**摘要:**针对传统建筑工程造价估算方法耗时量大、计算繁琐、误差频出的问题,提出了一种用自组织特征映射(SOFM)网络对建筑工程量样本量化后的值进行聚类的方法。该方法不需要手动标识训练数据集就可以实现不同类型的建筑样本自动分类,有助于提高传统建筑工程造价估算的效率。最后,通过实例验证了该方法的实用性和有效性。实验结果表明,改进的方法用于建筑工程造价估算较传统方法而言具有更高的准确率和更低的误报率。

**关键词:**工程造价估算;神经网络;自组织特征映射;建筑施工;特征

**中图分类号:** TP391 **文献标志码:** A

## Application of SOFM network in building project classification

FENG Wen-feng<sup>1</sup>, ZHU Wen-juan<sup>1</sup>, ZHOU Yu-guang<sup>2</sup>

(1. College of Computer Science and Technology, Henan Polytechnic University, Jiaozuo Henan 454002, China;

2. Information Department, China Overseas Holdings Limited, Hongkong, China)

**Abstract:** The traditional project cost estimation in architecture has many problems such as huge time consumption, complicated calculation, and frequent measurement error. Therefore, a method of clustering which could deal with architecture samples by Self-Organizing Feature Map (SOFM) network was proposed. This method did not need to identify training data set manually to get classification from different sorts of samples, and it did help to improve the efficiency of the traditional architectural project cost estimation. Finally, the availability of the algorithm in this method was proved. Compared with the traditional methods, the experimental results demonstrate that the improved method has a higher accuracy rate and a lower false positive rate.

**Key words:** project cost estimation; neural network; Self-Organizing Feature Map (SOFM); building construction; feature

### 0 引言

随着我国建筑市场需求的持续增长和建筑行业建设的快速发展,工程造价估算由于其耗时量大、计算繁琐、误差频出成为当今研究的核心问题。特别是工程清单计价于2003年7月1日在全国范围内展开,对主要工程量的快速估算已成为客观需要。因此,面对不断增长的需求和竞争激烈的现实,在利用先进的技术和设备改善建筑施工条件的同时,针对不同种类和特征的工程量用自组织特征映射(Self-Organizing Feature Map, SOFM)神经网络进行分类<sup>[1]</sup>,把已建工程特征的量化数据作为输入,对SOFM网络进行训练,最终用训练好的网络实现建筑工程造价资料的分类,对建筑工程的决策具有指导性意义。本文应用SOFM神经网络对工程特征进行分类,并根据实际数据的计算和分析得出这一方案的可行性。

### 1 SOFM 网络的结构

SOFM<sup>[2]</sup>也可以被称为Kohonen模型或拓扑模型,它最早是由Malsburg提出,它现在的模式是由Kohonen发展而来的。SOFM网络是单层神经网络,分为输入层和自组织特征映射层,SOFM网络的结构类似于自组织竞争网络,不同的是它没有阈值。当输出获胜神经元时,竞争传递输出函数输出为

1,其他输出为0,在训练过程中获胜神经元邻近的神经元将被修正,竞争层神经元的拓扑结构函数以及确定获胜神经元邻域的距离函数可以任意选择。

根据Kohonen映射模型可得到的如下思想:自组织映射模型是一个神经元由 $L$ 维网格代表特征空间的竞争性神经网络,输出网格代表相关的激活神经元和其邻域,这就是说其拓扑属性重于精确的几何位置。在实际当中,特征空间的维数制约可视面的数量,所以通常用 $L=1,2$ ,或3表示。

接下来给出一个SOFM的原理如图1。输入空间是三维的( $P=3$ ),特征空间是二维( $L=2$ ),12个神经元由 $3 \times 4$ 的网格构成, $M=[3 \ 4]$ <sup>[3]</sup>。

在图1的SOFM中, $Y_v$ 由指定的二维节点 $V=[V_1 \ V_2]$




图1 SOFM原理图

收稿日期:2009-12-03;修回日期:2010-03-10。 基金项目:国家“十一五”科技支撑计划项目(2007BAF23B0505)。

作者简介:冯文峰(1975-),男,河南焦作人,副教授,博士,主要研究方向:复杂网络; 祝文娟(1983-),女,河南焦作人,硕士研究生,主要研究方向:数据挖掘; 周宇光(1965-),男,香港人,教授级高级工程师,硕士,主要研究方向:数据挖掘。

和三维权重节点  $\mathbf{W}_v = [\mathbf{W}_{1v} \ \mathbf{W}_{2v} \ \mathbf{W}_{3v}]$  的位置决定。

作为竞争神经网络的 SOFM 由距离评估层和竞争层组成<sup>[4]</sup>,通过侧面抑制和局部自刺激连接来应用 MinNet 算法。在竞争阶段,从网络的所有神经元中挑选获胜神经元。SOFM 网络一般结构如图 2。




图2 SOFM 一般结构

该结构由如下参数构成:

$P$  为输入空间的维数;

$l$  为神经元空间的维数;

$m$  为总的神经元;

$\mathbf{W}$  为  $m \times P$  矩阵的突触权重;

$\mathbf{V}$  为  $m \times l$  矩阵神经元的拓扑位置。

在随后神经元仍然要以  $k = 1, 2, \dots, m$  或位置节点  $V_k = V(k, :)$  的要求排列。

SOFM 体现了  $P$  维输入空间到  $L$  维神经元空间的映射。

特征映射即自组织映射,由一块输入空间的突触权重与邻域权重准确相连得来<sup>[5]</sup>。由以上思想可得 SOFM 的结构,具体来说有两种。

结构1  $n$  维输入空间,一维特征空间。

试举例一个 SOFM 神经网络有 2 个输入 ( $P = 2$ ), 4 个输出排列于一维特征空间如图 3 所示。




图3 二维输入至一维空间图

在特征映射图中点代表着权重节点,  $\mathbf{W}_k$ 、 $\mathbf{W}_{k-1}$  和  $\mathbf{W}_{k+1}$  相连。

结构2  $n$  维输入空间,二维特征空间。试举例一个 SOFM 神经网络有 2 个输入 ( $P = 2$ ), 9 个输出排列于二维特征空间如图 4 所示。

神经元 5 位于  $3 \times 3$  神经元网格的中心点,这一神经元有 4 个邻居分别是 4、6、2、8。因此,在特征映射图中  $\mathbf{W}_4$ 、 $\mathbf{W}_6$ 、 $\mathbf{W}_2$ 、 $\mathbf{W}_8$  也会和  $\mathbf{W}_5$  相连。

## 2 SOFM 网络的训练算法

SOFM 网络的功能就是通过自组织方法用大量的样本训练来调整权值,使得网络的输出能够反映样本数据的分布情况。参考文献[6]的训练算法包括两个步骤,分别是相似度匹配和更新:

1) 初始化。对输出层各权向量赋予小随机数并进行归一化处理,得到  $\mathbf{W}_j (j = 1, 2, \dots, m)$ ; 建立初始优胜邻域

$N_{j*}(0)$ ; 学习率  $\eta$  赋初始值。

2) 接收输入。从训练集中随机选取一个输入模式并进行归一化处理,得到  $\mathbf{X}_n (n \in \mathbf{N}_+)$ 。

3) 寻找获胜节点。计算  $\mathbf{W}_j$  与  $\mathbf{X}_n$  的点积 ( $j = 1, 2, \dots, m$ ), 从中选出点积最大的获胜节点  $j^*$ ; 但是如果输入模式未经归一化,则应按式  $|\mathbf{X} - \hat{\mathbf{W}}_i^k| = \min_{1 \leq j \leq m} \{|\mathbf{X} - \hat{\mathbf{W}}_j^k|\}$  计算欧氏距离, 从中找出距离最小的获胜节点。

4) 定义优胜邻域  $N_{j*}(t)$ 。最初邻域  $N_{j*}(0)$  较大, 训练过程中  $N_{j*}(t)$  随训练时间以单位半径逐渐收缩。

5) 调整权值<sup>[7]</sup>。对获胜邻域  $N_{j*}(t)$  内的所有节点调整权值  $\hat{\mathbf{W}}_i^{k+1} = \hat{\mathbf{W}}_i^k + \eta^k (\mathbf{X} - \hat{\mathbf{W}}_i^k)$ 。其中  $\eta(t, N)$  是训练时间  $t$  和邻域内第  $j$  个神经元与获胜神经元  $j^*$  之间的拓扑距离的函数。

6) 结束检查。用新数据检测该 SOFM 网络是否符合分类的标准, 如果不满足则需重新设计 SOFM 网络。




图4 二维输入至二维空间图

## 3 SOFM 实例应用及分析

本研究选取建筑工程的工程特征为研究对象,拟利用 Matlab 实现分类功能。工程特征有不同的特征类目,根据中国计划出版社 2008 年 3 月出版的由张曦主编的《建筑施工技术》一书中的相关建筑工程分类标准选取基础类型、结构形式、层数、门窗、外墙装饰、墙体、平面组合这 7 个指标作为建筑工程分类的特征指标,其定量化描述如表 1 所示,现从香港某建筑施工企业的 20 个建筑楼盘数据中抽取这 7 个特征指标的数据作为工程样本数据。

### 3.1 建筑工程样本的定量化描述

从表 1 的资料得到了我国某地区的  $m$  个建筑工程样本, 每个样本用 7 个理化指标表示其特征, 确定网络的输入模式为:

$$\mathbf{P}_k = (P_1^k, P_2^k, \dots, P_n^k); k = 1, 2, \dots, m; n = 7$$

即一共有  $m$  组建筑工程样本向量, 每个样本中包括 7 个元素。

表1 建筑工程特征类目及量化表

量化值	基 础	结 构	层数	门窗	装 饰	墙 体	平面组合
1	砖条基	砖混	6	木门窗	清水墙	空心砖	一室一厅
2	钢筋砼条基	框架预制板	5,7	木门塑窗	干粘石	标准砖	二室一厅
3	粉喷桩加固地基钢筋砼条基	全现浇框架	8,9,10	木门铝合金窗	水刷石	砌块	二室二厅,二室一厅
4	片筏基础钢筋砼条基	框剪结构	11,12,13	铝合金窗	面砖	钢筋砼隔板	三室二厅,四室一厅
5	钢筋砼条基		14,15,16				四室二厅
6	钢筋砼满堂基		17,18,19				

依据表1,可给出任意一个建筑工程模式的量化描述,以  $T_i = (t_{i1}, t_{i2}, \dots, t_{ij})$  表示。其中,  $T_i$  表示第  $i$  ( $i = 1, 2, \dots$ ) 个工程的序列号;  $t_{ij}$  ( $j = 1, 2, \dots, 7$ ) 表示第  $i$  个工程的第  $j$  个特征的量化数值。如某工程(序列号设为  $i$ ) 是砖条基、砖混结构、5 层、木门铝合金窗、外墙干粘石、标准砖、三室一厅,则其量化描述为  $T_i = (1, 1, 2, 3, 2, 2, 3)$ 。

### 3.2 SOFM 的网络设计

#### 3.2.1 归一化

由于奇异矩阵的存在,需要对输入的数据归一化,以达到输出数据更加精确的目的。现从表2所示的20个已建工程样本中取18个样本,对数据做归一化处理<sup>[8]</sup>。代码如下:

```
load building.mat
data = building;
data = data(:,2:12);
size(data)
P1 = data(1:18,1:7);
P = P1';
[Pn,Ps] = mapminmax(P);
```

表2 已建典型样本工程特征量化数据表

$N$	$t_{i1}$	$t_{i2}$	$t_{i3}$	$t_{i4}$	$t_{i5}$	$t_{i6}$	$t_{i7}$
1	1	1	2	1	1	2	2
2	3	1	2	3	3	2	4
3	2	1	1	1	2	2	2
4	1	1	1	1	1	1	2
5	1	1	1	3	2	2	3
6	2	1	2	3	3	2	4
7	3	1	1	1	2	2	4
8	4	1	2	3	3	2	5
9	2	2	4	3	3	3	4
10	3	2	5	3	3	3	3
11	4	2	6	3	3	3	4
12	5	2	4	2	4	3	4
13	5	4	6	3	4	2	4
14	5	2	4	3	3	3	4
15	6	2	3	3	3	3	4
16	6	3	4	3	3	3	3
17	6	2	4	3	4	3	4
18	6	4	6	3	4	2	3
19	2	1	1	3	2	2	2
20	5	4	6	3	4	3	4

#### 3.2.2 具有三维特征的 SOFM 网络设计

由于给定的表2中7维空间数据可视化具有局限性<sup>[9]</sup>,现仅以三维空间为例,即从7个特征中挑出前3个特征作为输入,用 Matlab 实现其分类功能并说明其工作流程。假设有如下5个主要参数:

样本总数  $P_n = 18$ ;

输入向量维数  $N = 3$ ;

初始学习率  $\eta_0 = 0.1$ ;

Kohonen 层神经元数由  $6 \times 6$  的网格构成;

最大学习次数  $Maxepoch = 1000$ 。

网络经过学习将18个样本分类<sup>[10]</sup>,在训练开始时 SOFM 网络和其他普通的竞争网络一样,其输入节点竞争的胜利者代表其类模式,然后定义获胜节点的邻域节点,即定义以获胜节点为中心的某一个半径内的所有节点,并对其相似的权值矩阵进行调整,随着训练的继续进行,获胜节点  $k$  的半径将逐渐减小,直到只包括获胜节点  $k$  本身为止。也就是说在训练的初始阶段不但对获胜的节点作权值的调整,而且对其周围较大范围内的几何邻域节点也作相应的调整。随着训练过程的进行,与获胜输出节点相连的权值矩阵就越来越接近其代表的模式类,然后对获胜节点进行细微的权值调整并对邻域也进行相应的调整。最后,拓扑结构上相近的输出节点所连接的权值向量既联系又相互区别,保证了对于某一类的输入模式。为了能清楚地说明 SOFM 的工作过程,具体说明步骤有以下6步。

1)设计一个二维 SOFM 网络,其神经元层有  $6 \times 6$  个神经元,样本数据分布如图5所示。用以下代码可观察到样本数据的分布图:

```
plot(Pn(1,:),Pn(2,:), '* ');
axis([-2 2 -2 2 -2 2]);
```




图5 样本数据分布图

2)建立自组织网络。利用函数 `newsom` 创建一36个神经元的 SOFM 网络对输入向量进行分类,因此网络的竞争层的组织结构由  $6 \times 6$  个二维分布的神经元构成,代码如下:

```
net = newsom(minmax(Pn),[6 6]);
plotsom(net.layers{1}.positions);
```

其中:  $P_n$  是输入向量,由表2得出。`minmax(Pn)` 指定了输入向量元素的最大值和最小值, `[6 6]` 表示创建网络的竞争层为  $6 \times 6$  的结构,网络结构是可以调整的,此处的样本量不是很大,所以选择这样的竞争层是合适的,神经元分布的拓扑结构如图6。

3)网络初始状态下神经元权值的分布如图7所示,未经

训练的网络权值位于向量空间中心。用以下代码可观测到初始神经元的状态:

```
figure;
plotsom(net.IW{1,1},net.layers{1}.distances);
```




图6 神经元拓扑结构图




图7 初始状态下神经元权值分布图

4) 网络训练。设置训练参数,应用 `train()` 函数对网络进行训练,训练过程中代码可表示为:

```
net.trainParam.epochs = 1000;
net = train(net, Pn);
```

网络权值此时开始向输入向量移动。画出网络神经元权值,也就是每类样本数据的聚类中心如图8所示。




图8 训练过程中权值移动图

5) 对网络进行训练。经过训练后,网络权值经过排序逐步缩小邻域范围,最后竞争层的神经元通过调整,每个神经元都代表一个输入区域,邻近神经元权值向量的定位也反映了输入向量的拓扑结构。训练代码为:

```
net.trainParam.epochs = 3000;
net = train(net, Pn);
figure;
plotsom(net.IW{1,1},net.layers{1}.distances);
```

画出再次训练后的神经元权值,如图9所示。

6) 网络测试。训练后的网络将输入向量自由排序分类,下面应用向量  $M$  通过 `sim()` 函数仿真对网络进行测试,利用一组新的数据  $M = [0.5, 0.5, 0.5]$  测试网络性能,测试代码为:

```
M = [0.5; 0.5; 0.5];
a = sim(net, M)
```

输出  $a$  为:

```
(29, 1) 1
```

输出的第1个参数“(29,1)”代表的是优胜神经元,第2个参数“1”代表所属类别神经元的输出。可见向量  $M$  归为第29个神经元的输入类别。




图9 再次训练后的神经元权值图

### 3.2.3 结果分析

聚类结果以7维特征参数为例,结果如表3所示,进行分析可得,当训练步数为10时,样本序号为1、3、4的分为一类,与表2进行对比,可知这3个样本都是造价低的工程;样本序号为2、5、6的分为一类,这些都属于造价适中的工程;样本序号为9、10、11、12、13、15、16、17的分为一类,这些属于造价较高的工程;样本序号为13、18的分为一类,这些都是属于造价高的工程;此外还有样本序号为7和样本序号为8的分别自成一类,属于造价较低和造价偏高的工程。由此可见,网络已经对样本进行了初步的分类,这种分类虽然准确但不够精确。

当训练步数为100时,序号为13和18的样本分为一类,序号为15和17的样本分为一类,其他的各成一类,这种分类结果更加细化了。

当训练步数为6000时,每一个样本都被划分为一类,这和实际情况也是吻合的。此时如果再提高训练步数,已经没有任何实际意义了。

表3 聚类结果

训练步数	聚类结果									
10	30	24	30	30	24	24	36	3	4	4
	4	4	1	4	4	4	4	1		
100	31	2	27	25	13	7	33	1	9	16
	17	36	30	11	12	18	12	30		
6000	2	26	3	1	13	19	4	31	15	28
	33	6	35	17	18	24	12	36		

## 4 结语

建筑工程分类是工程造价估算过程中的首要工作,利用SOFM网络方法进行实例分析,从计算的结果来看SOFM网络能够很好地解决分类这一问题,由于本文的主要目的在于验证该方法的有效性,所建立的样本只是为了说明问题,对解决实际问题还存在有一定的欠缺,需要在今后的研究当中不断完善。

### 参考文献:

- [1] DOHNAL V, KUČA K, JUN D. What are artificial neural networks and what they can do?[J]. Biomedical papers of the Medical Faculty of the University Palacky, Olomouc, Czechoslovakia, 2005, 149 (2): 221-224. (下转第1576页)



差,从图8中很容易看出,在第130帧发生完全遮挡时候,Mean-Shift算法已经完全不能跟踪目标,之后再也不能正确跟踪到目标。而改进的Mean-Shift算法误差较小,而且由于Kalman滤波的作用,在遮挡过程完成之后又正确跟踪到目标。




图7  $x$  坐标示意图




图8 MS算法和本文算法 $x$ 坐标残差示意图

对比两种算法的实验结果,可以看出本文提出的算法在处理遮挡方面比传统Mean-Shift算法更加有效,对运动目标跟踪的稳定性更好。

### 3 结语

本文提出一种自适应Kalman滤波和改进的Mean-Shift

跟踪算法。采用人工点选目标,再使用三帧差检测方法得出运动目标的信息,并提出了一种改进的Mean-Shift算法结合Kalman滤波进行有效的目标跟踪,即基于目标以前的位置信息,采用Kalman滤波预测目标在当前帧的可能位置,然后利用Mean-Shift算法在预测位置附近找到最佳的匹配位置,并在跟踪过程中根据遮挡率因子动态调整Kalman滤波器参数。实验结果表明,提出的算法在处理遮挡方面比传统Mean-Shift算法更加有效,能对运动目标实现检测和连续跟踪,具有较好的鲁棒性。

### 参考文献:

- [1] 王江涛,杨静宇. 遮挡情况下基于Kalman均值偏移的目标跟踪[J]. 系统仿真学报, 2007, 19(18): 4216-4220.
- [2] 左军毅,梁彦,赵春晖,等. Mean-Shift跟踪算法中尺度自适应策略的研究[J]. 中国图象图形学报, 2008, 13(9): 1750-1757.
- [3] LIU P R, MENG M Q H, LIU P X, *et al.* Optical flow and active contour for moving object segmentation and detection in monocular robot [C]// Proceedings 2006 IEEE International Conference on Robotics and Automation. Washington, DC: IEEE, 2006: 4075-4080.
- [4] 曾伟,朱桂斌,李瑶. 基于Kalman点匹配估计的运动目标跟踪[J]. 计算机应用, 2009, 29(6): 1677-1682.
- [5] 罗嘉,韦志辉. 基于几何活动轮廓模型的目标跟踪与快速运动估计[J]. 中国图象图形学报, 2009, 14(7): 1361-1368.
- [6] COMANICIU D, RAMESH V, MEER P. Real-time tracking of non-rigid objects using Mean-Shift [C]// IEEE Computer Vision and Pattern Recognition. Washington, DC: IEEE, 2000: 142-149.
- [7] PARK D K, YOON H S, WON C S. Fast object tracking in digital video[J]. IEEE Transactions on Consumer Electronics, 2000, 46(3): 785-790.
- [8] WENG S K, KUO C M, TU S K. Video object tracking using adaptive Kalman filter[J]. Journal of Visual Communication and Image Representation, 2006, 17(6): 1190-1208.
- [9] KIM C, HWANG J-N. Fast and automatic video object segmentation and tracking for content-based applications [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2002, 12(2): 122-129.
- [10] 付梦印,邓志红,张继伟. Kalman滤波理论及其在导航系统中的应用[M]. 北京: 科学出版社, 2003: 20-25.

(上接第1546页)

- [2] KOHONEN T. Self-organizing neural projections [J]. Neural Networks, 2006, 19(6/7): 723-755.
- [3] ROJAS I, GONZALEZ J, POMARES H, *et al.* Multidimensional and multideme genetic algorithms for the construction of fuzzy systems [J]. International Journal of Approximate Reasoning, 2001, 26(3): 179-210.
- [4] SHAPIRO A F. The merging of neural networks, fuzzy logic, and genetic algorithms [J]. Insurance: Mathematics and Economics, 2002, 31(1): 115-131.
- [5] LIN C T, LEE C S G. Neural-network-based fuzzy logic control and decision system [J]. IEEE Transactions on Computers, 1991, 40(12): 1320-1336.
- [6] YU W D, SKIBNIEWSK M J. A neuro-fuzzy computational approach to constructability knowledge acquisition for construction technology evaluation [J]. Automation in Construction, 1999, 8(5): 539-552.
- [7] KAWAKAMI J, HOSHI K, ISHIYAMA A, *et al.* Application of a self-organizing map to quantitative structure-activity relationship analysis of carboquinone and benzodiazepine [J]. Chemical and Pharmaceutical Bulletin, 2004, 52(6): 751-756.
- [8] FABRY-ASZTALOS L, ANDONIE R, COLLAR C J, *et al.* A genetic algorithm optimized fuzzy neural network analysis of the affinity of inhibitors for HIV-1 protease [J]. Bioorganic & Medicinal Chemistry, 2008, 16(6): 2903-2911.
- [9] KOHONEN T, SOMERVUO P. How to make large self-organizing maps for nonvectorial data [J]. Neural Networks, 2002, 15(8/9): 945-996.
- [10] SAMECKA-CYMERMAN A, STANKIEWICZ A, KOLON K, *et al.* Self-organizing feature map (neural networks) as a tool in classification of the relations between chemical composition of aquatic bryophytes and types of streambeds in the Tatra national park in Poland [J]. Chemosphere, 2007, 67(5): 954-1013.