

# 一种基于函数联接网络的纹理分类方法

盛文 柳健

(华中理工大学图象识别与人工智能研究所, 教育部图象信息处理与智能控制开放实验室, 武汉 430074)

吴新建

(中船总公司第717研究所, 武汉 430074)

**摘要** 提出了一种基于函数联接的感知器神经网络的纹理分类方法. 它采用高斯-马尔柯夫随机场模型(GMRF)对纹理进行描述, 模型参数即为纹理特征, 参数估计采用最小平方误差方法获得. 将估计参数作为表达纹理的特征向量, 用感知器网络对特征进行分类, 并且采用函数联接的方式解决线性不可分问题. 对纹理图象进行的实验表明, 采用这种方法能够提高学习速度, 简化计算过程, 并取得较好的纹理分类效果.

**关键词** 纹理分析 马尔柯夫随机场 神经网络

**中图分类号:** TP391.4 **文献标识码:** A **文章编号:** 1006-8961(2000)04-0337-04

## A Texture Classification Approach Based on Function Link Network

SHENG Wen, LIU Jian

(State Education Department Laboratory for Image Processing and Intelligence Control  
Institute for Pattern Recognition and Artificial Intelligence, HUST, Wuhan 430074)

WU Xin-jian

(No. 717 Research Institute of CSSC, Wuhan 430074)

**Abstract** This paper presents a texture classification approach based on function link network. Image texture is characterized by the second order Gauss MRF model, and the least square error estimation is employed for the estimation of model parameters. However, these parameters are proved to be inefficient in texture classification. To solve this problem, we introduced a function link network to improve the classification performance. Experiment shows that better classification results can be obtained than traditional euclidean distance approach, and it has the advantage of simple processing procedure and fast convergence speed.

**Keywords** Texture analysis, Markov random field, Neural network

## 0 引言

图象纹理分析是计算机视觉研究的一个重要方面, 纹理是图象中一个非常重要的特征, 任何图象都可认为是由一种或多种不同纹理组成. 对于图象识别与理解而言, 不可避免地要涉及到纹理分析的研究.

一般认为纹理是由大量或多或少相似的纹理元或模式组成的一种结构, 这种结构即是组成纹理的基元及它们之间的相互关系, 这二者构成了纹理的两个

基本特征. 根据纹理的基本特征, 目前已出现了许多纹理分析的方法, 对此, M. Haralick 已作了较为全面的总结, 基本上可归纳为统计法、结构法、模型法和空间/频率域联合分析法等4类<sup>[1]</sup>, 它们有着各自不同的特点, 其中马尔柯夫随机场(MRF)模型是一种较好的描述纹理的方法. MRF模型反映了纹理的结构, 即纹理元之间的相互关系, 而模型参数则表达了纹理元的特性, 因此, MRF模型的特征反映了纹理的基本特性, 利用它可实现纹理图象的分类<sup>[2]</sup>.

由于自然纹理存在一定的不规则性, 利用MRF

模型提取的同一种纹理的特征也存在一定差别,因此采用传统的距离准则来实现特征分类会产生一定误差,而采用神经网络分类方法则能较好地解决这一问题,其中BP神经网络应用得最为广泛.然而,BP算法是一种非常耗时的算法,对于共有 $N$ 个连接权的网络,学习的计算量约为 $o(N^3)$ ,算法也相对复杂,而利用函数联接网络则可以克服上述问题.通过函数联接,线性不可分模式集有可能被映射为高维的线性可分模式集,从而可用较为简单的单层网络来实现模式分类,以简化算法,提高网络学习速度.本文利用MRF模型来获取图象的纹理特征,并采用函数联接网络和感知器算法对特征向量进行分类,较好地实现了纹理图象的分类.

### 1 图象纹理的GMRF模型

根据定义,一个MRF是在网格 $L$ 上所有点的可能灰度集 $Y$ 的概率密度函数<sup>[3]</sup>,它具有非负性、Markov性、一致性和平移不变性等特点.

如果图象中某一点 $s$ 的灰度 $y(s)$ 是 $s$ 所有方向邻域点集灰度的函数,则马尔柯夫随机场模型可用下面的条件概率形式来表达

$$p(y(s) | \text{all } y(s+r), r \in N) \quad (1)$$

其中 $N$ 为以 $s$ 为中心,但不包括 $s$ 的对称邻域,MRF模型阶数与邻域关系见图1.




图1 GMRF模型结构  
(图中数字代表相对于点 $x$ 的阶数)

对于一阶MRF模型, $N = \{(0, 1), (0, -1), (-1, 0), (1, 0)\}$ ;对于二阶MRF模型,则 $N = \{(0, 1), (0, -1), (-1, 0), (1, 0), (1, -1), (-1, 1), (-1, -1), (1, 1)\}$ .

设 $\Omega$ 为 $M \times M$ 网格上的点集, $\Omega = \{(i, j), 1 \leq i, j \leq M\}$ ,假定给定的纹理像元灰度 $[y(s), s \in \Omega, \Omega = \{s = (i, j) : 1 \leq i, j \leq M\}]$ 是零均值的高斯随机过程,则GMRF模型可通过下式来表示:

$$y(s) = \sum_{r \in N_s} \theta_r [y(s+r) + y(s-r)] + e(s) \quad (2)$$

其中 $N_s$ 为点 $s$ 的GMRF邻域, $\theta$ 为系数, $e(s)$ 是均值为零的高斯噪声序列,它满足

$$E|e(s)e(r)| = \begin{cases} \theta_{-r}, & (s-r) \in N \\ v, & s=r \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

式中 $v$ 为方差, $N$ 与 $N_s$ 相关, $N = \{s : s \in N_s\} \cup \{-s : s \in N_s\}$ .

根据式(2)、(3)可证明,图象 $\{y(\cdot)\}$ 在邻域 $N$ 上是严格意义下的Markov过程, $\{\theta, r \in N_s\}$ 和 $v$ 是模型的特征参数.

考虑一个包含单一纹理的 $N \times N$ 区域, $\Omega$ 是 $\Omega$ 的内部区域,且

$$\begin{aligned} \Omega &= \Omega - \Omega_b \\ \Omega_b &= \{s = (i, j), s \in \Omega \text{ 且 } s \pm r \notin \Omega, \forall r \in N^*\} \\ N^* &= \{r_1, r_2, r_3, r_4\} = \\ &= \{(0, 1), (1, 0), (1, 1), (-1, 1)\} \end{aligned} \quad (4)$$

采用二阶GMRF模型,令

$$Q_s = [y_{s+r_1} + y_{s-r_1}, \dots, y_{s+r_4} + y_{s-r_4}]^T \quad (5)$$

$\theta = \{\theta, r \in N_s\}$ 为系数向量,采用最小平方误差估计,则

$$\hat{\theta} = \left| \sum_{s \in \Omega} Q_s Q_s^T \right|^{-1} \sum_{s \in \Omega} Q_s y_s \quad (6)$$

$$\hat{v} = \frac{1}{N^2} \sum_{s \in \Omega} |y_s - \hat{\theta}^T Q_s|^2 \quad (7)$$

式(6)、(7)给出了GMRF模型参数的估计式和参数估计的平方误差,参数 $\theta$ 反映了图象的纹理特征,因此可将它们作为纹理的特征向量来进行纹理分析.

图2给出了10幅标准的Brodatz纹理图象,通过式(6)计算得到的GMRF参数见表1.由表中可以看出,不同纹理的GMRF系数不同,这些参数反映了相应纹理的特征.

表1 对应于图2的GMRF参数 $\theta$

$\theta$	D1	D12	D17	D24	D3	D5	D51	D9	D92	D77
$\theta_1$	0.067 7	0.504 7	0.474 7	0.476 6	0.451 1	0.397 2	0.474 9	0.456 2	0.381 0	0.421 2
$\theta_2$	0.017 7	0.297 1	0.438 2	0.333 6	0.470 0	0.438 7	0.479 6	0.338 6	0.443 3	0.473 0
$\theta_3$	0.235 0	-0.190 9	-0.210 3	-0.121 2	-0.173 9	-0.149 7	-0.222 0	-0.114 6	-0.169 3	-0.277 9
$\theta_4$	0.184 6	0.109 9	-0.199 9	-0.187 5	-0.246 9	-0.185 4	-0.232 3	-0.178 5	-0.154 2	-0.116 3




图 2 10 幅标准的 Brodatz 纹理图象  
(从左至右, 由上到下依次为 D1, D12, D17, D24, D3, D5, D51, D77, D9 和 D92)

## 2 函数联接的感知器网络

感知器首先是由 Rosenblatt 提出的, 它是一个具有单层计算单元的神经网络, 并由线性阈值元件组成, 对于网络中某一个结点, 其输出为  $y = g \left| \sum_i w_i x_i - \theta \right|$ , 其中  $w_i$  为与输入模式分量  $x_i$  对应的权值,  $\theta$  为阈值,  $g$  为符号函数, 且

$$g(x) = \begin{cases} 1, & x \geq 0 \\ -1, & x < 0 \end{cases}$$

假设感知器网络的输入模式为  $N$  维向量, 输出有  $K$  个结点, 则对于网络的第  $k$  个结点, 其输出为

$$y_k = g \left| \sum_{i=1}^N w_{k,i} x_i - \theta_k \right| \quad (8)$$

令  $w_{k,N+1} = -\theta_k, x_{N+1} = 1$ , 将上式写成矩阵形式, 有

$$Y = g(WX) \quad (9)$$

式中  $Y$  为  $K$  维输出向量,  $W$  为  $K \times (N+1)$  维权值矩阵,  $X$  为  $N+1$  维输入向量, 利用式(9)所表达的感知器网络可以解决模式线性可分问题, 网络的权值可通过迭代训练方式获得。

由表 1 可以看出, 尽管表中给出的不同纹理的 GMRF 参数不同, 但由于参数值的差异较小, 采用普通的距离准则来对它们进行分类会产生一定的误差; 如果采用感知器网络对由 GMRF 参数表达的纹理进行分类, 则往往因为模式集线性不可分, 而难以得到满意的结果; 采用多层前馈网络和 BP 算法, 一般来说, 能解决比较复杂的非线性分类问题, 但其训练所需要的迭代次数太多, 网络收敛速度很慢, 而利用函数联接的感知器网络能够解决上述矛盾。

函数联接通过产生一组线性独立的函数  $F$  作

用于模式的一个元素或整个模式, 然后计算模式对应的函数值. 图 3 给出了这种方式的原理框图. 图中, 联接函数  $F$  作用于输入矢量的每一个分量, 并产生矢量  $f_1(V), f_2(V), \dots, f_n(V), f_i(V)$  表示对  $V$  中每个元素进行  $f_i$  函数变换而形成的矢量, 由这些矢量组成一个新的矢量  $W = \{f_1(V), f_2(V), \dots, f_n(V)\}$ . 可以证明, 总能找到一种联接函数<sup>[4]</sup>将线性不可分的模式集映射到更高维空间上, 形成线性可分模式集, 从而可利用线性网络来对该模式集进行分类。




图 3 函数联接原理框图

设输入模式为  $X = \{x_i, i = 1, \dots, n\}$ , 联接函数为  $F = \{f_i, i = 1, \dots, m\}$ , 则增强模式  $W$  为:

$$W = X \otimes F \quad (10)$$

式中  $\otimes$  表示两个矢量的张积。

本文中, 联接函数取为正交基函数完备集的子集,

$$F = \{f_1, f_2, \dots, f_m\} = \{\sin \pi x, \cos \pi x, \sin 2\pi x, \cos 2\pi x, \dots, \sin m\pi x, \cos m\pi x\} \quad (11)$$

$W$  张成  $m \times n$  维表达空间. 如果  $X = \{x_1, x_2\}$ , 则

$$W = \{\sin \pi x_1, \cos \pi x_1, \sin \pi x_2, \cos \pi x_2, \dots, \sin m\pi x_1, \cos m\pi x_1, \sin m\pi x_2, \cos m\pi x_2\} \quad (12)$$

图 4 给出了用于对图 2 所示的 10 幅图象进行分类的函数联接感知器网络系统框图, 利用函数联接方式将线性不可分的输入模式张成一个线性可分空间的模式集, 然后利用感知器网络对其进行分类。

感知器网络的输出集取{1, - 1}, 对于 10 种待分模式, 只需 4 个感知器结点即可完成, 这 4 个结点不同的输出组合即表示一种分类结果。




图4 函数联接的感知器网络

感知器网络的权值可通过反复训练迭代获得, 给定一个系统误差容限  $E$ , 当训练误差小于该容限时即停止迭代, 训练具体算法如下:

(1) 给定初始值  $W(0)$ , 一般地,  $W$  中各元素取较小的非 0 随机值,  $W(t)$  表示  $t$  时刻网络的权值;

(2) 给定一输入模式  $S$  以及期望的输出  $Y$ , 按式(12)计算其经函数连接后张成的向量  $X$ , 计算网络的实际输出  $\hat{Y}(t)$  和系统误差  $E(t)$ :

$$\hat{Y}(t) = g[\mathbf{W}(t)\mathbf{X}],$$

$$E(t) = [\hat{Y}(t) - \mathbf{Y}]^T \cdot [\hat{Y}(t) - \mathbf{Y}]$$

(3) 如果  $E(t) < E$ , 迭代停止, 并且得到网络权值  $W = W(t)$ , 反之, 采用下式来调整权值:

$$\mathbf{W}(t + 1) = \mathbf{W}(t) + \eta[\mathbf{Y} - \hat{\mathbf{Y}}(t)]\mathbf{X}^T$$

(4) 转到步骤(2), 直到系统误差  $E(t)$  小于容限  $E$  为止。

图 5 给出了分别采用感知器算法和函数联接网络对一组模式进行训练的系统误差曲线, 进行训练的模式为对应于图 2 各幅图象的 Markov 随机场模型参数. 显然, 对于线性不可分模式, 采用感知器算法进行学习得不到收敛结果, 而经过函数联接处理后, 系统误差能够很快降为 0.




图 5 采用两种方式训练的系统误差曲线 (其中虚线为采用感知器算法的结果, 实线为采用函数联接网络训练的结果)

### 3 分类实验与总结

由前面的分析可以看出, 利用函数联接将输入模式映射到更高维的模式空间, 可将线性不可分的模式集转化成线性可分模式集, 从而可采用较为简单的感知器算法来实现模式分类. 本文对图 2 所示 10 幅纹理图象采用 Markov 随机场模型提取纹理特征, 并利用函数联接网络和感知器算法进行了分类实验. 为了将 10 类纹理图象正确区分开, 采用了 4 个神经元的单层线性分类器, 联接函数按式(12)给出, 且  $m = 8$ . 分类实验结果见表 2. 为了对比, 表中还列出了采用归一化欧氏距离准则的分类结果。

表 2 分类实验为分类精度表

分类方法	D1	D12	D17	D24	D3	D5	D51	D9	D92	D77
欧氏距离	1.0	0.88	1.0	0.94	1.0	0.94	0.94	0.88	1.0	1.0
联接网络	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0

实验表明, GMRF 模型参数能够较好地反映纹理特征, 但如果采用普通距离准则进行分类难以取得较好的分类效果, 而采用函数联接网络和感知器算法则能很好地完成这一任务. 采用这种方法既具有一般多层前馈网络对模式集的分类能力, 又同时具备线性分类器计算过程简单, 训练收敛速度快的优点, 因而是一种比较实用的纹理分类方法。

### 参 考 文 献

- 1 Haralick R M. Statistical and structural approaches to texture. Proc. IEEE. 1979. 67(5): 786~ 804.
- 2 Krishnamachari S, Chellappa R. Multiresolution Gauss-Markov random field models for texture segmentation. IEEE Trans. IP, 1997, 6(2): 251~ 267.
- 3 Povlow B R, Dunn S M. Texture classification using noncausal hidden Markov models. IEEE Trans. PAMI, 1995, 17(10): 1101~ 1014.
- 4 殷勤业, 杨宗凯等. 模式识别与神经网络. 北京: 机械工业出版社, 1992.



盛文 1966年生, 1991年获华中理工大学通信与电子系统专业硕士学位, 1999年于华中理工大学获模式识别与智能系统专业博士学位. 主要研究方向为图象分析、目标检测、专家系统等。