

基于图谱分解和概率神经网络的图像分类

汤进 张春燕 罗斌

(安徽大学计算智能与信号处理教育部重点实验室, 合肥 230039)

摘要 为了准确地对不同学习样本数的图像进行分类, 首先讨论了对属于不同类别的图像序列如何进行正确有监督分类的问题, 由于解决这类问题首先要选取适合图像分类的图像特征作为分类的依据, 为此先用图像角点来构成 Delaunay 图, 然后将由 Delaunay 图的谱特征形成的分类特征矢量作为分类的依据; 其次, 由于分类器的选取也直接影响分类结果, 为此采用了学习效率高的概率神经网络分类器来进行分类。经过大量分类实验表明, 图谱特征很好地保持了图像的结构特征, 是理想的图像分类特征; 经过与其他相关分类器的分类比较实验表明, 基于概率神经网络的分类器可以准确地进行图像分类; 通过不同学习样本数的比较, 证实了概率神经网络在进行图像分类时, 对于学习样本数并不敏感, 并具有一定稳定性。

关键词 图谱 图像分类 概率神经网络

中图法分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2006)05-0630-05

Images Classification Based on Spectral Decomposition of Graphs Using Probabilistic Neural Networks

TANG Jin, ZHANG Chun-yan, LUO Bin

(Key laboratory of Intelligent Computing and Signal Processing of Anhui University, Hefei 230039)

Abstract This study applies graph spectra and probabilistic neural networks to the task of supervised images classification. At first, corners are extracted from images to construct Delaunay graphs. These relational graphs have proved alluring as structural representations for images. Then graph spectral decomposition method is adopted to get eigenvalues and eigenvectors of the adjacency matrix. Graph spectra can preserve the primary structure of graphs. The spectrum of these graphs will be used as feature vectors for classification. At last probabilistic neural networks will give the classification result according to the vectors. As for the classifier, PNN has high speed of learning because the learning rule is simple and new trainings patterns can be incorporated into a previously trained classifier quite easily, which might be important for a particular on-line application. Experimental results show that this method can achieve the best result of images classification.

Keywords graph spectra, images classification, probabilistic neural networks

1 引言

基于数字图像的模式识别与模式分类技术在近年来得到了快速发展, 并已经在许多场合得到了广泛的应用, 尤其是遥感领域^[1-4]和生命科学领域^[5]的图像分类技术具有很好的应用背景和应用成果。

如今如何构建一个高效率的分类识别系统, 已是图像处理 and 模式识别领域的热点课题。图像分类的研究任务, 一方面是研究从一幅图像分出所含的若干类成分, 遥感领域的图像分类大多是这种思路, 它是根据遥感图像的影像特征来把图像中对应的土地、山川和湖泊等分离出来^[2,3]; 而如何从多幅图像中区分出具有相似特征的图像(即可划分为一类的图

基金项目: 国家自然科学基金项目(60375010); 安徽省人才开发基金项目(2001Z021)

收稿日期: 2005-03-15; 改回日期: 2005-07-08

第一作者简介: 汤进(1976 ~), 男, 1999 年获安徽大学学士学位, 现为安徽大学计算机学院讲师, 安徽大学计算机应用专业博士研究生。主要研究方向为图像处理和模式识别。E-mail: ahtftang@mail.hf.ah.cn

像),并正确地对这些图像进行分类则是研究图像分类的另一个方面的任务^[6,7],但不论哪个方面的图像分类任务,都可以从分类特征的恰当选取和分类器的正确设计这两个方面入手。现有的图像分类方法的分类特征多是基于色彩、纹理、频域特征^[8],而分类器则多是神经网络或统计方法^[3]。综合这两个方面因素,本文提出一种基于图谱分解和概率神经网络的图像分类方法,该方法一方面先利用图像特征点来构成图,再用图的谱特征作为分类特征。这种由图像特征点构成的图既保留了图像的结构,而且由于图的谱特征保留了图的主要特征,因此图的谱特征适合代替图像进行分类运算;另一方面,分类器使用概率神经网络(probabilistic neural networks, PNN),概率神经网络具有学习效率高、结构简单等优点,其不仅在学习样本有限的场合具有很高的稳定性,而且这种方法对于多幅图像的分类也能得到较好的分类结果。

基于图谱分解和概率神经网络的图像分类系统是采用全程全自动无干预体系,图像特征是先采用Harris角点提取算法^[9]来提取角点,再由角点构成Delaunay图,接着对Delaunay图的邻接矩阵进行图的谱分解^[10],最后将谱特征作为概率神经网络分类器的输入,再由分类器决定分类结果,该分类系统结构如图1所示。




图1 分类系统结构

Fig.1 Classification system diagram

2 基于图像特征点的图的谱分解

如何有效地构造保留图像所含主要信息的特征,而又不需要使用大量的矩阵描述是图像处理的一个重要问题,而通过一定的图像特征来用图去描述图像就是其中一个很好的方法^[10]。本文所使用的就是利用图的理论,并用较为稳定的图的谱特征作为分类器的输入特征。

角点是图像的一种重要的低层次局部特征,其在图像匹配、目标识别以及运动估计、目标跟踪等领域具有十分重要的意义。本文将基于灰度图像的点

检测方法——Harris算法,用于获得构成图的特征点。

对于 N 幅图像中的第 k 幅图像 F_k ,首先经过角点提取来得到第 k 幅图像的特征点集 V_k ,然后由 V_k 生成图 $G_k = (V_k, E_k)$,其中 $E_k \subseteq (V_k \times V_k)$ 为图 G_k 的邻边的集合,图 G_k 的邻接矩阵为 A_k , A_k 为 $|V_k| \times |V_k|$ 大小的矩阵, A_k 第 i 行第 j 列元素为

$$A_k(i, j) = \begin{cases} 1 & \text{如果}(i, j) \in E_k \\ 0 & \text{否则} \end{cases}$$

在得到邻接矩阵 A_k 的基础上,再引入 A_k 的特征值 $\lambda_k^{(m)}, m=1, 2, \dots, |V_k|$,并令 $|\lambda_k^{(1)}| > |\lambda_k^{(2)}| > \dots > |\lambda_k^{(|V_k|)}|$,其中 $\lambda_k^{(m)}$ 满足 $|A_k - \lambda_k^{(m)} I| = 0$,同时可以得到与 $\lambda_k^{(m)}$ 对应的特征矢量 $\varphi_k^{(m)}$, $\varphi_k^{(m)}$ 可由方程 $A_k \varphi_k^{(m)} = \lambda_k^{(m)} \varphi_k^{(m)}$ 解得。这样,图 G_k 的谱 $\lambda_k^{(1)}, \lambda_k^{(2)}, \dots, \lambda_k^{(|V_k|)}$ 即可作为原图像 F_k 的特征,这就保留了 F_k 的主要信息,然后就可选取 G_k 中的 $\lambda_k^{(1)}, \lambda_k^{(2)}, \dots, \lambda_k^{(d)}$ ($d \leq \min_{1 \leq i \leq N} |V_i|$)共 d 个特征值构成特征向量 $x_k = (\lambda_k^{(1)}, \lambda_k^{(2)}, \dots, \lambda_k^{(d)})^T$,用来对图像进行分类计算,经过这样变换,就可以使不同类型、不同分辨率的图像以统一方式进行分类计算。

3 利用PNN进行图像分类

PNN方法是由Specht等人于1990年给出的^[11],该分类器在手写字符识别等方面应用广泛^[12]。和其他概率分类器一样,PNN方法实现的关键也是如何在模式分布密度未知的情况下,由模式样本来估计出模式的第 i 类 ω_i 的条件概率密度 $p(x|\omega_i)$,而且PNN方法是基于Parzen窗函数估计的方法^[13,14],PNN方法的结构实现如图2所示。




图2 PNN方法实现结构

Fig.2 PNN configuration

对于有 n 个 d 维的样本,若都是随机地从 c 个类别中选取的,则图中有 d 个输入层单元, n 个模式层单元, c 个类别层单元,PNN的训练算法非常简单,只要使模式层单元的权重向量 w 和归一化的样

本向量 \mathbf{x} 满足 $\mathbf{w}_k = \mathbf{x}_k$ ($k = 1, 2, \dots, n$), 同时得到矩阵 C (当该样本属于第 i 类时, 矩阵元素 $c_{k,i} = 1$, 否则 $c_{k,i} = 0$), 训练即可完成。训练之后即可以计算 \mathbf{w} 和 \mathbf{x} 内积 $z = \mathbf{w}^T \mathbf{x}$, 若期望使用以 Parzen 窗函数 $\varphi(u)$ 为中心, 且在某个训练样本 \mathbf{x}_k ($\mathbf{w}_k = \mathbf{x}_k$) 处的高斯窗函数为

$$\varphi\left(\frac{\mathbf{x} - \mathbf{w}_k}{h_n}\right) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(\mathbf{x} - \mathbf{w}_k)^T (\mathbf{x} - \mathbf{w}_k)}{h_n^2 2\sigma^2}} \quad (1)$$

则当窗的宽度 h_n 为常数时, 利用归一化条件 $\mathbf{x}^T \mathbf{x} = \mathbf{w}_k^T \mathbf{w}_k = 1$, 即可得到

$$\varphi\left(\frac{\mathbf{x} - \mathbf{w}_k}{h_n}\right) \propto e^{-\frac{(\mathbf{x} - \mathbf{w}_k)^T (\mathbf{x} - \mathbf{w}_k)}{2\sigma^2}}$$

$$e^{-\frac{(\mathbf{x} - \mathbf{w}_k)^T (\mathbf{x} - \mathbf{w}_k)}{2\sigma^2}} = e^{-\frac{\mathbf{x}^T \mathbf{x} + \mathbf{w}_k^T \mathbf{w}_k - 2\mathbf{x}^T \mathbf{w}_k}{2\sigma^2}} = e^{-(z-1)/\sigma^2} \quad (2)$$

在得到上式后, 就可以通过图 3 算法进行分类。

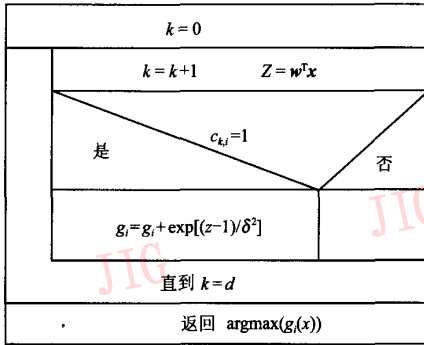


图 3 PNN 分类算法框图

Fig. 3 Flow chart of PNN classification

4 实验及结果

为了验证基于图的谱分解的图像特征和基于 PNN 分类器的分类方法在图像分类中的效果, 本文采用了 3 种分类方法对不同训练样本的相近图像序列进行了分类实验: 首先, 采用了一个思路简单的分类算法 (classification by min-error, CME), 即对测试样本与所有训练样本进行均方差累加, 当找出均方差和最小的, 就把测试样本归为该类, 这种方法虽容易实现, 但是分类时计算量较大; 然后, 为了与利用局部化的基函数 (如高斯函数) 来估计密度的 PNN 方法进行对比, 本文采用了反向传播算法的径向基函数网络算法 (radial basis function network, RBF_Network)。

CME 算法的时间复杂度为 $O(n^3)$, RBF_Network 算法和 PNN 算法具有相同的时间复杂度, 都为 $O(n)$ 。PNN 算法的空间复杂度为 $O((n+1)d)$, 在存储资源允许而又要求高计算速度时, 由于 PNN 可以采用并行机制实现算法, 因此此时算法的时间复杂度最低可以降为 $O(1)$ 。

实验中所用的图像序列为 obj80 (取自 coil100, 128 × 128 分辨率, 共 36 幅, 图示仅是序列中的一部分图像, 上角数字为该幅图像在序列中的位置, 下同, 见图 4) 和图像序列 obj41 (取自 coil100, 128 × 128 分辨率, 共 36 幅, 见图 5), 其分类结果如表 1 所示。对于图像序列 chalet^[15] (512 × 512 分辨率, 共 72 幅, 见图 6) 和图像序列 CMU (carnegie mellon university)^[15] (576 × 384 分辨率, 共 69 幅, 见图 7), 其分类结果如表 2 所示。

表 1 obj80 与 obj41 序列分类结果

Tab. 1 Classification result of obj80 and obj41


分类方法	训练样本数	测试样本数	错分样本数	准确率(%)
CME	20	52	4	92
	2	70	15	79
RBF_Network	20	52	3	94
	2	70	12	83
PNN	20	52	1	98
	2	70	3	96

表 2 Chalet 与 CMU 序列分类结果


Tab. 2 Classification result of chalet and CMU

分类方法	训练样本数	测试样本数	错分样本数	准确率(%)
CME	20	121	8	93
	2	139	41	66
RBF_Network	20	121	9	93
	2	139	36	70
PNN	20	121	0	100
	2	139	1	99

从分类实验结果来看, 将基于图像特征点构成的图的谱特征作为分类特征时, 可以正确地分类图像。从各种算法的分类准确率可以明显看出, 在图像分类中, PNN 方法比其他算法具有优势, 尤其在训练样本非常少 (每类只用 1 个训练样本) 的情况下, PNN 算法具有很好的稳定性。由于序列 obj80、obj41 与 CMU、chalet4 个序列组间图的谱特征差别较大, 因此, 即使把 4 个序列放在一起进行 4 类图像的分类时, PNN 方法也没有产生新的错分。




(a) obj80 序列部分图像



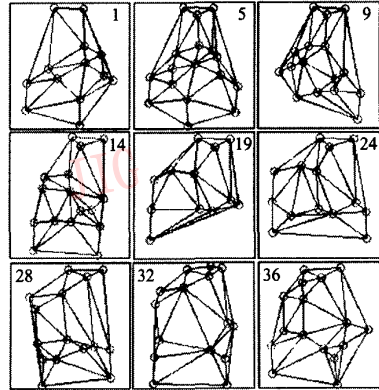
(b) obj80 序列部分 Delaunay 图

图 4 obj80 序列部分图像及其对应的 Delaunay 图

Fig. 4 The obj80 sequence and corresponding graphs




(a) obj41 序列部分图像



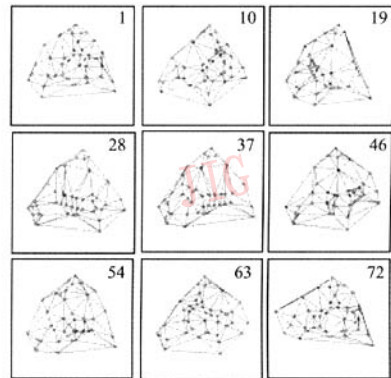
(b) obj41 序列部分 Delaunay 图

图 5 obj41 序列部分图像及其对应的 Delaunay 图

Fig. 5 The obj41 sequence and corresponding graphs




(a) chalet 序列部分图像




(b) chalet 序列部分 Delaunay 图

图 6 chalet 序列部分图像及其对应的 Delaunay 图

Fig. 6 The chalet sequence and corresponding graphs



(a) CMU 序列部分图像



(b) CMU 序列部分 Delaunay 图

图 7 CMU 序列部分图像及其对应的 Delaunay 图

Fig. 7 The CMU sequence and corresponding graphs

5 结 论

本文所使用的把图谱分解和概率神经网络分类器结合起来的方法不仅可以自动地对多类图像进行分类,而且其分类的结果准确。由于这种分类方法可以实现并行运算、在线学习,而且在进一步优化算法的基础上可以形成对复杂图像的实时分类,从而可进一步扩大它的应用范围。

参考文献 (References)

- Joseph P H , David A L. Classification of remote sensing Images having high spectral resolution [J]. Remote Sensing Environment, 1996, 57(3):119 ~ 126.
- Farid Melgani, Sebastiano B S. A statistical approach to the fusion of spectral and spatio-temporal contextual information for the classification of remote-sensing images [J]. Pattern Recognition Letters, 2002,23(9):1053 ~ 1061.
- Giorgio Giacinto, Fabio Roli, Lorenzo Bruzzone. Combination of neural and statistical algorithms for supervised classification of remote-sensing images [J]. Pattern Recognition Letters, 2000, 21 (5) : 385 ~ 397.
- James R C. Spectral and textural classification of single and multiple band digital images [J]. Computer&Geosciences, 1996, 22 (8) : 849 ~ 865.
- Dennis P C, Susan P M, Stanley M D. Machine classification of dental images with visual search [J]. Academic Radiology, 2001, 8(12):1239 ~ 1246.
- Smith Yoav, Gershom Zajicek, Micheal Werman, *et al.* Similarity measurement method for the classification of architecturally differentiated images[J]. Computer and Biomedical Research, 1999, 32(1):1 ~ 12.
- John R S, LI Chung-sheng. Image classification and querying using composite region templates [J]. Computer vision and image understanding, 1999,75(1):165 ~ 174.
- Soo B P, Jae W L, Sang K K. Content-based image classification using a neural network [J]. Pattern Recognition Letters, 2004, 25(3):287 ~ 300.
- Harris C G, Stephens M. A combined corner and edge detector[A]. In: Proceedings fourth Alvey Vision Conference (AVC88) [C], Manchester, UK, 1988:147 ~ 151.
- Luo Bin, Wilson R C, Hancock E R. Spectral embedding of graphs [J]. Pattern Recognition, 2003, 36(10):2213 ~ 2223.
- Specht D F. Probabilistic neural networks [J]. Neural Networks, 1990,3(1):109 ~ 118.
- Faruq A Al-Omari, Omar Al-Jarrah. Handwritten Indian numerals recognition system using probabilistic neural networks[J]. Advanced Engineering Informatics, 2004, 18(1):9 ~ 16.
- Emanuel Parzen. On estimation of a probability density function and mode [J]. Annals of Mathematical Statistics, 1962, 33 (3) : 1065 ~ 1076.
- Richard O D, Peter E H, David G S. Pattern Classification, Second Edition [M]. Etobicoke, Canada: John Wiley&Sons, 2001: 163 ~ 173.
- Luo Bin, Wilson R C, Hancock E R. Graph Spectral Approach for Learning View Structure[A]. In: Proceedings of 16th International Conference on Pattern Recognition (ICPR2002) [C], Quebec, Canada, 2002:785 ~ 788.