

航拍图像区域多特征紧耦合多级分类算法

马 旭¹, 程咏梅¹, 郝 帅¹, 赵建涛¹, 王 涛²

(1 西北工业大学 自动化学院, 陕西 西安 710072;

2 中国航空工业集团 西安飞行自动控制研究所重点实验室, 陕西 西安 710065)

摘 要: 提出一种基于多特征紧耦合的航拍图像区域多级分类算法. 首先将样本图像从 RGB 空间转换到 HSV 空间, 分别提取颜色矩特征和 Gabor 纹理特征, 并对 Gabor 纹理特征进行 PCA 降维; 然后将两种特征相乘构成紧耦合矩阵, 进一步生成紧耦合特征向量, 并对生成的紧耦合特征向量再次进行 PCA 降维; 接着搭建了由 5 个概率神经网络分类器构成的多级分类器. 最后利用 Google Earth 软件截取不同时间、不同尺度的图像, 作为训练样本和测试样本, 进行多级分类器的训练和测试. 实验结果表明, 相比于单特征及多特征松耦合的分类方法, 提出的方法分类精度较高.

关键词: 多特征; 紧耦合; 航拍图像; 多级分类器; 概率神经网络

中图分类号: TP391

文献标识码: A

文章编号: 1000-7180(2014)10-0013-05

Multi-stage Classification Algorithm Based on Multi-feature Tightly Coupled for Aerial Image

MA Xu¹, CHENG Yong-mei¹, HAO Shuai¹, ZHAO Jian-tao¹, WANG Tao²

(1 College of Automation, Northwestern Polytechnical University, Xi'an 710072, China;

2 Key Laboratory of Xi'an Flight Automatic Control Research Institute,

Aviation Industry Corporation of China, Xi'an 710065, China)

Abstract: A multi-stage classification algorithm based on multi-feature tightly coupled for aerial image is proposed. Firstly, the sample images are transformed from RGB space to HSV space. Color moment feature and Gabor texture feature are extracted and PCA is used to reduce the feature dimensionality of Gabor texture. Secondly, tightly coupled matrix is gotten by multiplying the two characteristics and tightly coupled vector is generated. PCA is used again to reduce the feature dimensionality of tightly coupled vector. Then a multi-stage classifier is constructed by five probabilistic neural network classifiers. Lastly, images of Xi'an Qing Zhen Village with different time and scale are selected by Google Earth software. Grassland, lakes, trees, houses and land from the images are selected as training samples and test samples. And these samples are used for multi-stage classifier training and testing. Experimental results show that proposed method has higher classification accuracy compared with single feature classification method and the method of multi-feature loosely coupled.

Key words: multi-feature; tightly coupled; aerial image; multi-stage classifier; probabilistic neural network

1 引言

对航拍图像区域进行分类是基于视觉的无人机自主着陆技术中的一个关键问题. 现有的图像分类方法主要有 3 类: 专家系统分类法、统计学分类法以

及人工智能分类法等. 专家系统分类法主要依赖于专家的经验知识, 然而经验知识的获取是个反复而漫长的过程, 这在很大程度上限制了该方法的应用. 统计学分类方法虽然计算简单, 但是对训练样本要求较高, 其样本选取的好坏直接影响了分类的精度.

收稿日期: 2014-01-20; **修回日期:** 2014-03-02

基金项目: 西安市科技计划项目(CXY1350(2)); 国家自然科学基金重点项目(61135001)

人工智能分类法中的人工神经网络以其可以处理非线性映射能力,在分类和模式识别问题中具有较好的应用效果.文献[1]和文献[2]设计了由神经网络构成的多级分类器,并证明多级分类器相比于单级分类器具有更好的精度.为此,本文设计了一种基于概率神经网络(Probabilistic Neural Network, PNN)组成的多级分类器^[3].

2 紧耦合特征提取

2.1 颜色特征

相比于 RGB 颜色空间,HSV 颜色空间与人的视觉感知更为接近^[4-5],为此本文首先将图像从 RGB 空间转到 HSV 空间.设 $I_{\max}$ 和 $I_{\min}$ 分别表示 (R,G,B) 中像素值的最大值和最小值,则 RGB 空间到 HSV 颜色空间转换可以表示为

$$v = I_{\max} \quad (1)$$

$$s = \begin{cases} 0, & v = 0 \\ (I_{\max} - I_{\min})/I_{\max}, & v \neq 0 \end{cases} \quad (2)$$

$$h = \begin{cases} (G - B)/(I_{\max} - I_{\min}) \times 60, & \text{if } (R = I_{\max}) \text{ and } (s \neq 0) \\ 120 + (B - R)/(I_{\max} - I_{\min}) \times 60, & \text{if } (G = I_{\max}) \text{ and } (s \neq 0) \\ 240 + (R - G)/(I_{\max} - I_{\min}) \times 60, & \text{if } (B = I_{\max}) \text{ and } (s \neq 0) \\ h + 360, & \text{if } h < 0 \end{cases} \quad (3)$$

考虑到颜色矩特征相比于颜色直方图具有无需对颜色进行量化,且特征向量维数低的优点,本文通过分别求取 H、S、V 三个通道的颜色矩来构成颜色特征描述子 $F_c = [\mu_h, \sigma_h, S_h, \mu_s, \sigma_s, S_s, \mu_v, \sigma_v, S_v]$,下标 h, s 和 v 表示三个颜色通道, μ, σ 和 S 分别表示颜色的一阶矩 (mean), 二阶矩 (variance) 和三阶矩 (skewness),表示如下^[6]:

$$\mu_i = \frac{1}{N} \sum_{j=1}^N p_{i,j} \quad (4)$$

$$\sigma_i = \sqrt{\frac{1}{N} \sum_{j=1}^N (p_{i,j} - \mu_i)^2} \quad (5)$$

$$S_i = \sqrt[3]{\frac{1}{N} \sum_{j=1}^N (p_{i,j} - \mu_i)^3} \quad (6)$$

式中, $p_{i,j}$ 表示图像第 i 个颜色通道分量中灰度为 j 的像素出现的频率, N 表示图像中的像素个数.

2.2 纹理特征

纹理特征是图像分类识别中一种重要的特征,其提取方法主要有:统计法、几何法、模型法以及信号处理法.目前信号处理法中利用 Gabor 滤波器提

取的纹理特征的方法最为广泛,因为 Gabor 滤波器的频率和方向表示与人类的视觉感知系统相似,而且在景物识别中具有较好的效果.为此本文利用 Gabor 滤波器来提取图像的纹理特征.二维 Gabor 滤波器 $h(x, y)$ 表示为

$$h(x, y) = \frac{1}{2\pi\delta_x\delta_y} \exp\left\{-\frac{1}{2}\left[\frac{x^2}{\delta_x^2} + \frac{y^2}{\delta_y^2}\right] + 2\pi\omega xj\right\} \quad (7)$$

$$H(x, y) = \exp\left\{-\frac{1}{2}\left[\frac{(u-w)^2}{\delta_u^2} + \frac{v^2}{\delta_v^2}\right]\right\} \quad (8)$$

式中, δ_x 和 δ_y 分别为高斯函数在 x 和 y 方向上的标准差, ω 为高斯函数的复调制频率, $\delta_u = (1/2)\pi\delta_x$ 和 $\delta_v = (1/2)\pi\delta_y$. 以 $h(x, y)$ 为母小波,通过对 $h(x, y)$ 进行尺度和旋转变换,就可以得到一组滤波器:

$$h_{nm}(x, y) = A^{-m}h(x', y') \quad (9)$$

式中, A^{-m} 为尺度因子且 $A > 1$, m 和 n 分别表示尺度和方向, $x' = A^{-m}(x\cos\theta + y\sin\theta)$, $y' = A^{-m}(-x\sin\theta + y\cos\theta)$, $\theta = n\pi/k$ 表示滤波器主轴方向角, k 表示总的方向数目.通过改变 m 和 n 的值就可以获取一组尺度和方向不同的滤波器.

给定一幅图像 $I(x, y)$, 图像大小为 $M \times N$, 第 m 个尺度和第 n 个方向的 Gabor 滤波器为 $h_{nm}(x, y)$, 则图像滤波后的结果 $W_{nm}(x, y)$ 为

$$W_{nm}(x, y) = \sum_{x=1}^M \sum_{y=1}^N I(x, y) h_{nm}(x, y) \quad (10)$$

求取 $W_{nm}(x, y)$ 的均值 μ_{nm}^T 和方差 σ_{nm}^T 作为图像纹理特征,表示如下:

$$\mu_{nm}^{\text{Tex}} = \frac{1}{M \times N} \sum_{x=1}^M \sum_{y=1}^N |W_{nm}(x, y)| \quad (11)$$

$$\sigma_{nm}^{\text{Tex}} = \sqrt{\frac{1}{M \times N} \sum_{x=1}^M \sum_{y=1}^N (|W_{nm}(x, y)| - \mu_{nm}^{\text{Tex}})^2} \quad (12)$$

本文选取尺度 $m = 6$, 方向 $n = 4$, 构成 24 个子滤波器,通过求取滤波图像的均值和方差就可以得到一个 48 维的纹理特征向量 $F_{\text{Tex}} = [\mu_{41}, \sigma_{41}, \dots, \mu_{64}, \sigma_{64}]$.

2.3 主成分分析

经过 Gabor 滤波后得到 48 维的纹理特征向量,不仅维数高而且特征之间存在着冗余信息.为了提高计算的实时性以及消除特征之间的冗余信息,本文采用主成分分析法 (PCA) 对纹理特征进行降维,其实现过程如下:

(1) 计算样本的纹理特征向量协方差矩阵,假设 F_{Tex}^i 为第 i 个训练样本的纹理特征向量,则其协

方差矩阵表示为

$$\mathbf{S} = \frac{1}{M} \sum_{i=1}^M (\mathbf{F}_{\text{Tex}}^i - \bar{\mathbf{F}}) (\mathbf{F}_{\text{Tex}}^i - \bar{\mathbf{F}})^T = \frac{1}{M} \mathbf{A} \mathbf{A}^T \quad (13)$$

式中, M 为训练样本总数, $\bar{\mathbf{F}} = \frac{1}{M} \sum_{i=1}^M \mathbf{F}_{\text{Tex}}^i$, $\mathbf{A} = (\mathbf{F}_{\text{Tex}}^1 - \bar{\mathbf{F}}, \dots, \mathbf{F}_{\text{Tex}}^M - \bar{\mathbf{F}})$.

(2) 计算协方差矩阵的特征值及特征向量, 考虑到 $\mathbf{S}$ 矩阵较大, 本文采用奇异值分解 (Singular Value Decomposition, SVD) 方法来求解 $\mathbf{A} \mathbf{A}^T$ 的特征值 λ_i 和正交归一化特征向量 $\mathbf{p}_i$, $i = 1, \dots, 48$, 将求取的特征值从大到小排序.

(3) 计算主成分, 根据特征值的贡献率 φ 的大小选取前 num ($\text{num} \leq 48$) 个最大的特征值及其对应的特征向量, φ 的表示式如下:

$$\varphi = \sum_{i=1}^{\text{num}} \lambda_i / \sum_{i=1}^M \lambda_i \quad (14)$$

φ 越大说明主成分包含的信息越多, 本文选取 $\varphi = 90\%$ 所对应的主成分.

(4) 计算原协方差矩阵的特征向量:

$$\mathbf{u}_i = \frac{1}{\sqrt{\lambda_i}} \mathbf{A} \mathbf{p}_i \quad (15)$$

式中, $i = 1, \dots, \text{num}$. 则进一步得到纹理特征空间 W :

$$W = (\mathbf{u}_1, \dots, \mathbf{u}_{\text{num}}) \quad (16)$$

(5) 将每个样本的纹理特征与纹理特征均值之间的差值矢量投影到 W 空间有

$$\mathbf{y}_j = \mathbf{W}^T (\mathbf{F}_{\text{Tex}}^j - \bar{\mathbf{F}}) \quad (17)$$

式中, $j = 1, \dots, M$, 从而得到 num 维纹理特征矢量.

2.4 颜色矩特征与纹理特征紧耦合

假设颜色矩特征为 $\mathbf{F}_c = [\mu_h, \sigma_h, S_h, \mu_s, \sigma_s, S_s, \mu_v, \sigma_v, S_v]^T$, 降维后的纹理特征为 $\mathbf{F}_{\text{Tex}} = [\mu_1^{\text{Tex}}, \sigma_1^{\text{Tex}}, S_1^{\text{Tex}}, \dots, \mu_n^{\text{Tex}}, \sigma_n^{\text{Tex}}, S_n^{\text{Tex}}]^T$, n 为降维后纹理特征的维数. 两特征紧耦合策略如下: 将颜色矩特征 $\mathbf{F}_c$ 和 $\mathbf{F}_{\text{Tex}}$ 相乘, 得到 $9 \times 2n$ 维的融合矩阵 $\mathbf{F}_{cT}$, 然后以 $\mathbf{F}_{cT}$ 的每一列为一个单元, 对 $2n$ 个单元取并集构成一个 $19n \times 1$ 维列向量, 对其进行 PCA 降维, 最终得到紧耦合特征^[6]. 该算法具体计算步骤如下:

(1) 将两个特征向量相乘, 得到特征矩阵 $\mathbf{F}_{cT}$, 如式(18)所示;

$$\mathbf{F}_{cT} = \begin{bmatrix} \mu_h \mu_1^{\text{Tex}} & \dots & \mu_h \sigma_n^{\text{Tex}} \\ \vdots & \ddots & \vdots \\ S_v \mu_1^{\text{Tex}} & \dots & S_v \sigma_n^{\text{Tex}} \end{bmatrix}_{9 \times 2n} \quad (18)$$

(2) 将 $\mathbf{F}_{cT}$ 的每一列进行“并”运算, 得到列向量

$$\mathbf{F}_{cT}' = [\mu_h \mu_1^{\text{Tex}}, \dots, S_v \sigma_n^{\text{Tex}}]^T;$$

(3) 对 $\mathbf{F}_{cT}'$ 进行归一化并进行 PCA 降维, 最终得到紧耦合特征向量.

3 多级概率神经网络分类器设计

本文设计的多级 PNN 分类器结构如图 1 所示.




图 1 PNN 多级分类器

PNN 的主要思想是根据贝叶斯最优分类决策理论(错误率、风险最小化)实现分类. 假设 n 维紧耦合特征向量 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$, 属于 m 个分类 $\omega_1, \omega_2, \dots, \omega_m$ 之一, $p(\omega_i)$ 和 $p(\mathbf{X} | \omega_i)$ 分别为 ω_i 的先验概率和条件概率密度函数. 贝叶斯决策规则可以表示为

$$f(\mathbf{X}) = \underset{\omega_i}{\operatorname{argmax}} p(\mathbf{X} | \omega_i) p(\omega_i) \quad (19)$$

式中, $i = 1, \dots, m$, $f(\mathbf{X})$ 为决策, $p(\mathbf{X} | \omega_i)$ 的 Parzen 窗估计可以表示为

$$p(\mathbf{X} | \omega_i) = \frac{1}{N_i (2\pi)^{d/2} \sigma^d} \sum_{j=1}^{N_i} \exp \left[-\frac{(\mathbf{X} - \mathbf{X}_i^j)^T (\mathbf{X} - \mathbf{X}_i^j)}{2\sigma^2} \right] \quad (20)$$

式中, N_i 和 $\mathbf{X}_i^j$ 分别表示 ω_i 中的训练样本数和第 j 个训练样本, σ 为平滑因子.

PNN 主要由输入层、模式层、求和层以及竞争层(输出层)组成, 如图 2 所示.

图 2 中, 输入神经元个数与紧耦合特征向量维数相等, 用 $x_i (i = 1, \dots, n)$ 表示, n 为特征向量维数. 模式层 $z_{ij}(\mathbf{X})$ 表示为

$$z_{ij}(\mathbf{X}) = \frac{1}{(2\pi)^{d/2} \sigma^d} \exp \left[-\frac{(\mathbf{X} - \mathbf{X}_i^j)^T (\mathbf{X} - \mathbf{X}_i^j)}{2\sigma^2} \right] \quad (21)$$

式中, $i = 1, \dots, m$, m 为类的总数, $j = 1, \dots, N_i$. 求和层中将模式层中同类神经元的输出值求平均值, 本文用 $g_i(\mathbf{X})$ 来表示:




图 2 PNN 结构图

$$g_i(\mathbf{X}) = \frac{1}{N_i} \sum_{j=1}^{N_i} z_{ij}(\mathbf{X}) \quad (22)$$

式中, $i = 1, \dots, m$. 最后, 通过竞争层输出判决结果 y_i :

$$y_i = p(\omega_i) g_i(\mathbf{X}) \quad (23)$$

式中, $i = 1, \dots, m$. 求取 $k = \arg\max(y_i)$, 则认为 $\mathbf{X}$ 向量属于 ω_k 类.

4 算法流程

整个算法分为两个阶段: 训练阶段和测试阶段.

(1) 训练阶段

该阶段主要是从实验图像中扣取训练样本, 首先将训练样本从 RGB 空间转为 HSV 空间, 提取 HSV 颜色矩以及 Gabor 纹理特征; 然后将颜色矩特征与经过 PCA 降维的 Gabor 纹理特征进行融合生成紧耦合特征向量; 最后利用样本中的紧耦合特征向量训练生成多级 PNN 分类器.

(2) 测试阶段

该阶段同样先将训练样本数据提取紧耦合特征向量, 然后利用训练阶段中生成的多级 PNN 分类器对其进行分类, 验证所设计分类器的精度. 整个算法流程图如图 3 所示.

5 实验结果及分析

5.1 实验样本数据选取

本文实验主要分为两个部分:

(1) 利用 Google Earth 软件截取 2014 年 5 月 20 日西安市庆镇村的图像, 如图 4 所示. 从图中抠取土地、草地、树林、湖泊以及房屋共 220 个样本, 其中 150 个样本用来训练, 70 个样本用来测试, 验证本文算法的分类精度.

(2) 利用 Google Earth 软件截取 2013 年 8 月 29 日以及 2012 年 11 月 23 日不同尺度下西安市庆镇村的图像, 分别如图 5(a) 和图 5(b) 所示. 从图 5




图 3 算法流程图



图 4 实验图像

可以看出由于时间的不一致性及尺度差异, 图 5 与图 4 的景物具有明显的颜色差异及尺度变化. 将图 4 中抠取的图像作为训练样本, 选取其中 150 个样本进行训练. 图 5 中抠取的图像作为测试样本, 分别从图 5(a) 和 (b) 中各选取 35 个测试样本, 验证本文算法的鲁棒性以及精度.

5.2 实验结果及分析

为了验证本文所提出算法 (记为 Ours) 的精度及鲁棒性, 与基于颜色特征的分类方法 (记为 M1)、基于 Gabor 纹理特征的分类方法 (记为 M2) 以及将颜色特征与 Gabor 纹理特征进行松耦合的分类方法 (记为 M3) 对比其分类精度. 其中分类精度 Precision 的定义如下:

$$\text{Precision} = \text{Right} / \text{Total} \times 100\% \quad (24)$$

式中, Right 表示正确分类数, Total 表示测试样本总数. 所描述的实验结果如表 1 和表 2 所示.

表 1 实验 1 分类精度

方法	分类精度/%
M1	95.71
M2	97.14
M3	98.00
Ours	99.43



(a) 2013年图像



(b) 2012年图像

图5 不同时间及尺度下的实验图像

表2 实验2 分类精度

方法	分类精度/%
M1	85.71
M2	91.42
M3	94.29
Ours	97.14

从表1的结果可以看出采用多特征融合方式的分类精度明显高于单特征的分类精度,而且从结果可以看出本文提出的特征紧耦合方法分类精度最高。

从表2的结果可以看出由于景物颜色发生变化加上图像中存在一定的尺度变化,利用颜色特征进行分类的精度明显降低,利用纹理特征的分类精度也受到较大的影响。采用多特征融合的方式相比于前面两种方法精度较高,而本文提出的基于紧耦合

的特征融合方法精度最高,具有较强的鲁棒性。

6 结束语

本文提出一种基于多特征紧耦合的航拍图像区域多级分类算法来解决航拍图像区域利用单特征或是采用多特征松耦合方式分类精度低的问题。利用Google Earth软件截取不同时间、尺度下的训练样本和测试样本进行实验,结果表明相比于单特征的分类方法以及采用松耦合特征融合的方法,本文提出的方法精度较高。

参考文献:

- [1] 赵锋,薛惠峰,王伟,等.采用多级分类器的手写数字识别技术研究[J].微电子学与计算机,2006,23(12):30-32.
- [2] Fitzgerald D, Walker R, Campbell D. A vision based forced landing site selection system for an autonomous UAV[C]// Proceedings of the 2005 International Conference on Intelligent Sensors, Sensor Networks and Information Processing. Australia, Sydney, 2005: 397-402.
- [3] 贺金鑫,陈圣波,王阳,等.一种基于朴素贝叶斯分类模型的高光谱矿物精确识别方法[J].光谱学与光谱分析,2014,34(2):505-509.
- [4] Khan F S, Van D W J, Ali S, et al. Evaluating the impact of color on texture recognition[C]// Computer Analysis of Images and Patterns. UK: York, 2013: 154-162.
- [5] Smeulders A W M, Worring M, Santini S, et al. Content-based image retrieval at the end of the early years[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(12): 1349-1380.
- [6] 史变霞,张明新,乔小妮,等.基于颜色特征的图像检索方法[J].微电子学与计算机,2010,27(4):158-161.

作者简介:

马旭女(1985-),博士研究生.研究方向为视觉导航、模式识别及图像处理。

(上接第12页)

- [5] Lee H Y, Lee K O, Lee H L, et al. CBERP: Cluster based energy efficient routing protocol for wireless sensor network[C]// Proc. 12th Int. l. Conf. Networking, VLSI and Signal Processing. University of Cambridge, UK, 2010: 24-28.
- [6] Tang F, You I, Guo S, et al. A chain-cluster based routing algorithm for wireless sensor networks[J]. Journal of intelligent manufacturing, 2012, 23(4):

1305-1313.

作者简介:

王鑫男,(1976-),副教授,硕士生导师.研究方向为网络与信息安全。

王梦莹女,(1990-),硕士研究生.研究方向为无线传感器网络。

蒋华男,(1963-),教授,硕士生导师.研究方向为数据库系统、信息安全。