

航空图像中水面纹理的自动提取

汪海洋¹⁾ 潘德炉²⁾ 夏德深¹⁾

¹⁾ (南京理工大学计算机系, 南京 210094) ²⁾ (国家海洋局第二海洋研究所, 杭州 310012)

摘要 针对可见光航空遥感监测中, 耀斑和云阴影等强噪音的干扰使水中目标很难直接发现这一问题, 提出了一种基于 Gabor 滤波器和 BP 神经网络的尾迹纹理自动提取算法, 通过提取它们运动产生的尾迹实现对它们的准确识别。该方法分为两步: 第 1 步是选取等大小的含尾迹纹理的水面子图像和不含尾迹纹理的水面子图像, 通过一组 Gabor 滤波器得到它们的特征图像, 计算每个子图像特征图的均值和方差, 将它们作为神经网络的训练样本对 BP 网络进行训练得到用于识别的网络; 第 2 步是将待提取的整幅图像分成很多与第 1 步中子图像等大小的子图像, 分别计算它们的 Gabor 特征图像, 并得到它们的均值和方差, 把它们作为神经网络的输入, 得到它们是否是纹理区域, 由整幅子图像的分类结果得到一幅二值图像, 用 Hough 变换检测图像中的直线, 根据直线的长度判断尾迹是否存在。大量的实验结果表明, 该方法能够准确地提取运动目标产生的尾迹纹理。

关键词 Gabor 滤波器 BP 神经网络 Hough 变换 纹理提取

中图分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2008)02-0251-06

Water Texture Fetching of Airphotos

WANG Haiyang¹⁾, PAN De-lu²⁾, XIA De-shen¹⁾

¹⁾ (Nanjing University of Science and Technology, Nanjing 210094)

²⁾ (Second Institute of Oceanography of State Oceanic Administration, Hangzhou 310012)

Abstract To solve the problem that it is difficult to directly detect the object in the water due to flares and cloud shadows, this paper proposed a water wake recognition method based on Multi-Channel Gabor filters and BP neural network. First we select sample sub-images of same sizes with wake texture and without wake texture, then we obtain feature images using a group of Gabor filters and calculate the mean and variance of feature images to acquire the input vectors and train the BP network. Secondly we divide the whole image into sub-images with the same size as the first step, calculate mean and variance of Gabor feature images, calculate the input vector and judge whether the sub-image contain a wake texture by the trained BP network in the first step. We obtain a binary image by the classify results of the whole image, detect lines using Hough transform and judge whether there is a wake in the whole image. From experiment results, it is proved that the proposed algorithm can attain the wake texture precisely.

Keywords Gabor filters, BP neural network, Hough transform, texture fetching

1 引言

我国有一半以上的海域存有权益之争, 周边国家在有争议海域大肆掠夺资源, 每年的经济损失巨

大。传统的通过调查船对海域进行监测, 不仅耗时耗力而且由于我国海域很大, 很多时候无法起到有效的作用。同时由于外国的军舰, 船只等在我海域附近活动频繁, 对我国构成了很大威胁。通过遥感进行监测具有快速、全天候、实时等优点, 为维护我

基金项目: 国家高技术研究发展计划 863 项目 (2003AA131160)

收稿日期: 2006-03-20 改回日期: 2006-08-29

第一作者简介: 汪海洋 (1982~), 男, 南京理工大学模式识别与智能系统专业博士研究生。主要从事图像处理、计算机视觉和模式识别等。Email: why_haiyang@126.com

海洋权益和国家安全提供了重要保障。航空可见光遥感是遥感监测中一种非常重要的手段。但是由于耀斑, 云阴影等因素的干扰, 仅通过图像灰度很多时候很难直接得到有用的信息。为了解决这个问题, 通过大量的实验和研究, 提出了一种基于 Gabor 滤波器和 BP 神经网络的尾迹纹理自动提取算法, 通过提取它们运动产生的尾迹实现对它们的准确识别, 为可见光航空遥感自动监测提供了技术保障。

几十年来, 人们提出了许多纹理分析的方法^[1-9], 总的说来可以分为以下几类: 结构模型的方法、统计模型的方法、滤波器模型的方法、随机场的方法和分形模型的方法等等。在所有的方中, 多通道 Gabor 滤波器的方法被认为是最成功的纹理分析方法, 因为生物学实验表明^[5], Gabor 滤波器和人类视觉系统的纹理认知机制相一致。Gabor 滤波器能够很好地表达和提取纹理特征, 在过去的 30 年中, 很多学者对它进行了研究^[14-16]。本文提出的算法就是在这些基础上提出的。

2 多通道 Gabor 滤波器

Gabor 函数是由 Gabor 首先定义的^[10], 并由 Daugman 将它扩展成 2 维^[11]。2 维 Gabor 函数是一个纵横比为 λ 尺度参数为 δ 主轴与 x 轴角度为 φ 的高斯函数调制的复数正弦函数。它的一般形式为

$$h(x, y) = g(x', y') \exp[2\pi j(Ux + Vy)] \quad (1)$$

式中, (U, V) 为中心频率, $(x', y') = (x \cos\varphi + y \sin\varphi, -x \sin\varphi + y \cos\varphi)$ 为旋转坐标, 而 2 维高斯函数为

$$g(x, y) = \frac{1}{2\pi\lambda\sigma^2} \exp\left\{-\frac{(x/\lambda)^2 + y^2}{2\delta^2}\right\} \quad (2)$$

式中, λ 为纵横比。对式 (1) 作傅里叶变换, 可得 2 维 Gabor 函数的频域表达式:

$$H(u, v) = \exp\{-2\pi^2\delta^2[(u' - U')^2\lambda^2 + (v' - V')^2]\} \quad (3)$$

式中, $(u', v') = (u \cos\varphi + v \sin\varphi, -u \sin\varphi + v \cos\varphi)$; (U', V') 是中心频率 (U, V) 所作的相应旋转。 $H(u, v)$ 是一个主轴与 u 轴成 φ 角的带通高斯函数, 其纵横比为 $1/\lambda$ (本研究中取 1), 极向中心频率 $F = \sqrt{U^2 + V^2}$ (单位为 $C/image$ CPI), 方向为 $\theta = \arctg(V/U)$ 。2 维 Gabor 函数是一个位于空间域和频率域的带通滤波器函数, 一般情况下, 取 Gabor 函数中高斯函数部分的方向和复数调制部分函数的辐角相等 ($\varphi = \theta$)。此时 Gabor 函数的空域和频域的为

$$h(x, y) = g(x', y') \exp[2\pi jFx'] \quad (4)$$

$$H(u, v) = \exp\{-2\pi^2\delta^2[(u' - F)^2\lambda^2 + v'^2]\} \quad (5)$$

滤波器的带宽为 $B = \log_2[(\pi F\lambda\sigma + \alpha)/(\pi F\lambda\sigma - \alpha)]$, $\alpha = \sqrt{(h2)/2}$ 通常取 0.6~2.0 个倍频程, 本研究中取 1。

特征提取同时抽取频率信息和方向信息; 文献 [5] 指出就纹理特征提取的目的, 没有必要选择整个频域的滤波器参数空间。可以看出, 只要选定了 F, σ, θ 3 个参数, 即可确定 Gabor 滤波器。设图像大小为 $N \times N$, $m = \log_2 \frac{N}{4}$, 则 F 的取值依次为 $\sqrt{2} \{1, 2, 3, \dots, 2^m\}$, 这里取 4 个最高频率; 取定了 F 后, 根据 $B = 1, \delta$ 的值就可依次确定了; θ 的取值为 $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 。确定了滤波器各个参数后, 在计算各滤波器与图像卷积的能量值的基础上, 计算各个子图像滤波器能量值的均值与方差作为子图像的纹理特征, 这里共选取了 16 个滤波通道, 共 32 个滤波特征, 记为 $F = \{\mu_{00}, \sigma_{00}, \dots, \mu_{ij}, \sigma_{ij}, \dots, \mu_{33}, \sigma_{33}\}$, 设 $E_{ij}(x, y)$ 为第 (i, j) 个滤波能量值, 则子图像 (大小为 $N \times N$ 像素) 的能量均值和方差为

$$\mu_{ij} = \frac{\sum_{y=0}^{N-1} \sum_{x=0}^{N-1} E_{ij}(x, y)}{N \times N} \quad (6)$$

$$\sigma_{ij} = \frac{\sum_{y=0}^{N-1} \sum_{x=0}^{N-1} \sqrt{(E_{ij}(x, y) - \mu_{ij})^2}}{N \times N} \quad (7)$$

3 BP 神经网络

Rumelhart 等人在 1986 年提出了前向多层网络的反向传播学习算法 (BP 算法)^[12] 和前馈网路模型 (BP 模型)。BP 神经网络一般由输入层、隐含层和输出层组成。它采用反向传播算法 (BP 算法) 为学习算法, 因为 BP 算法功能强大, 易于实现, 易于理解, 并且其他学习算法都可看作是对它的一种变形和修改。BP 神经网络的性能与其输入、层数、每层中的神经元数、传递函数、学习算法、初始权值及期望误差都有着密切的联系^[12-13]。图 1 是一个典型的 3 层 BP 网络结构模型, 这里使用的就是这种结构模型。

(1) 学习样本数据的归一化 训练集各个样本数据的数值范围直接关系到网络学习的结果, 由于航空图像的成像受外界光线的影响, 当图像处于阴影之中时数值的变化范围很小, 直接用 Gabor 滤波




图 1 BP网络

Fig 1 BP network

器组提取它们的纹理特征并不能有效地对网络权值进行修正,所以在对图像进行纹理特征提取前必须进行图像均衡化处理。同时为了让纹理提取算法具有旋转不变性,每个样本将按照 4 个方向 (0° , 45° , 90° , 135°) 旋得到 4 个样本。

(2) 网络层数的选取 理论上已经证明:具有偏差和至少一个 S 型 (Sigmoid 函数) 隐含层加上一个线性输入层的网络,能够逼近任何有理函数。增加层数可以进一步地降低误差,提高精度,但同时也使网络复杂化。另外不能用仅具有非线性激活函数的单层网络来解决问题。因为能用单层网络完美解决的问题,用自适应线性网络也一定能解决,而且自适应线性网络的运算速度还要快。而对于只能用非线性函数解决的问题,单层精度又不够高,也只有增加层数才能达到期望的结果。根据前人的研究成果和实际应用经验,BP 神经网络在模式识别/分类中具有良好的性能,而且一个具有无限隐含层节点的 3 层 BP 网络可以实现任意从输入到输出的非线性映射,所以这里采用 3 层 BP 网络。

(3) 隐含层单元数 尽管输入和输出单元数分别由输入向量的维数和类别数决定,但是隐单元个数并不简单地与此类问题的外在特性相关。隐单元个数决定了网络的表达能力,从而决定了边界的复杂度。如果模式较易分开或线性可分,那么仅需要较少的隐单元;相反,如果从具有较高分散性的复杂概率密度中抽取的,则需要更多的隐单元。过多的隐单元可以精细地调节到特定的训练集上,但对测试样本的误差率会高得令人无法接受。过少的隐单元将不具备足够的自由度以较好地拟和训练样本,测试误差率依然很高。

一个基本的方法是根据训练数据相应地调节网络的复杂程度。比如,先从一个较大的隐单元个数开

始,然后衰减权值。由试验可知,输入层节点数为 32 隐含层节点数为 32 输出层节点数为 2 时,可以取得很好的效果。

(4) 传递函数及学习算法的选取 隐含层和输出层的传递函数,均选用非线性 S 型函数,以完成输入模式到输出模式的非线性映射。标准的 BP 学习算法通常具有收敛速度慢,易陷入局部极小等缺点,因此出现了许多改进的算法。快速 BP 算法从改进途径上可分为两大类:一类是启发式学习方法,如引入动量因子的学习算法、变学习速率学习算法和“弹性”学习算法等;另一类则是更有效的数值优化方法,如共轭梯度学习算法,quasiNewton 算法等。

采用引入动量因子的学习算法来加速网络的收敛速度,试验结果表明,该方法取得了很好的结果。


(5) 初始权值选取和期望误差选取 初始权值为 $(-0.5, 0.5)$ 之间的随机数,误差为 0.01。

4 算法的流程和结果


(1) 训练网络 选取训练样本(大小为 64×64 像素的子图像) 60 个,含有尾迹纹理图像和不含尾迹纹理图像各 30 个,并按照 4 个方向 (0° , 45° , 90° , 135°) 进行旋转得到 240 个样本图像。图 2 是两种样本的 12 个例子。

对 240 个样本图像进行直方图均衡化处理,用 Gabor 滤波器组卷积得到特征能量图并计算它们的均值和方差,得到神经网络的输入向量。当含有尾迹纹理时输出向量为 $[1, 0]$; 当不含尾迹纹理时输出向量为 $[0, 1]$ 。训练图 1 所示的神经网络,得到用于识别尾迹纹理子图像的网络。为了验证生成的神经网络性能,选取测试样本 80 个,其中含有尾迹纹理图像和不含尾迹纹理图像各 40 幅,并按照 4 个方向进行旋转得到 320 个测试样本图像。表 1 给出了网络对训练样本和测试样本的识别率。

(2) 将待处理的整幅图像按照图 3 所示的 4 种方式分别分割为 64×64 的子图像,并同时生成一幅与整幅图像大小相同的结果图像并将它赋值为 255 (即背景色),对每个子图像直方图均衡化并用多通道 Gabor 滤波器组求得特征能量图并计算它们的均值和方差,得到神经网络的输入向量。将神经网络的输入向量输入步骤 1 中训练好的网络,如果输出向量的第 1 个分量大于第 2 个分量,将结果图像中



(a) 含尾迹的样本子图像



(b) 不含尾迹的样本子图像

图 2 样本图

Fig 2 Sample images

表 1 BP神经网络识别率

Tab 1 Recognition percentage of BPNN

	训练样本	测试样本
正确识别率 (%)	96.7	87.5

对应的点赋值为 0。

(3) 用 Hough 提取结果图像中的线段, 计算线段的长度, 如果大于阈值 T (这里 T 取 200), 认为尾迹存在, 否则认为是噪音点。

为了说明整个纹理提取算法的有效性, 对 100

幅图像进行纹理提取, 其中含有尾迹 80 幅、不含尾迹 20 幅。图 4 给出了算法实验结果的 4 个例子, 其中, (a)、(c)、(e)、(g) 为原始图像; (b)、(d)、(f)、(h) 为提取的纹理区域图像 (黑色表示尾迹区域)。图像的大小为 448×448 像素, 子图像的大小为 64×64 像素。从图 (b)、(d)、(h) 可以看出, 包含尾迹纹理的区域基本都能够正确识别出来, 即使被错分为背景区域, 通过它周围正确识别为尾迹区域的子图像, 利用算法的第 3 步仍然能够正确地提取尾迹。同理如图 4(f) 即使有个别背景子图像错分为




图 3 划分示意图
Fig. 3 Partition map




图 4 试验图
Fig. 4 Experimental pictures

尾迹区域, 通过算法的第 3 步也能够将它排除。尾迹的正确检测率为 95%、误检率为 0%: 80 幅含有尾迹的图像有 76 幅能够被准确地提取出来, 20 幅不含尾迹的图像全部识别为不含尾迹, 4 幅没有被检测尾迹图像是由于尾迹纹理信息太弱。实验结果表明, 水面尾迹纹理自动提取算法能够准确地获取尾迹区域, 具有很强的实用性。

5 与同类纹理分类方法的性能比较

为了说明本文方法对尾迹纹理分类的有效性, 分别用灰度共生矩阵^[17, 18]、小波变换^[19]两种常用的方法对尾迹纹理分类, 并将它们的分类结果和本文

方法进行性能比较。将图像的灰度量化成 16 等级, 求得它的灰度共生矩阵, 采用灰度共生矩阵的角二阶距、对比度、相关和熵 4 个统计量作为特征量, 与 4 个方向 (0°, 45°, 90°, 135°) 的灰度共生矩阵共得到 16 个纹理分类特征量。采用广泛使用的 Daubechies-4 型小波, 对图像进行 3 层分解, 分别计算低频通道, 水平方向的 3 个高频通道, 垂直方向的 3 个高频通道共 7 个通道的均值和方差作为纹理分类特征量, 共 14 个。分类器采用第 3 节描述的 BP 神经网络: 灰度共生矩阵隐含层的节点数为 16, 小波变换隐含层的节点数为 14。训练样本和测试样本与第 4 节 (1) 中的训练样本和测试样本相同。表 2 给出了不同方法对训练样本和测试样本的正确

表 2 3种方法的识别率

Tab 2 Recognition percentage of three methods

单位: %

	训练样本	测试样本
灰度共生矩阵	83.3	75
小波变换	93.3	82.5
本文方法	96.7	87.5

分类率。

从表 2 可以看出, 相对于灰度共生矩阵和小波变换, 本文算法能够更有效地提取尾迹纹理特征, 这主要是因为不同波长的尾迹纹理一定会在傅里叶变换的某个频率产生很强的响应, 本文采用的 Gabor 滤波器组能够有效地覆盖这些响应。

6 结 论

以多通道 Gabor 滤波器和 BP 神经网络理论为基础, 提出了一种水中目标运动尾迹的自动提取算法, 解决了由于信号弱, 噪音强而造成的水中目标难以识别的问题, 为可见光航空遥感监测提供了技术支撑, 对民用和军用都有着重大的意义。大量的实验结果表明, 本文算法能够准确地提取水中运动物体产生的尾迹。

参考文献 (References)

- 1 Sklansky Jack. Image segmentation and feature extraction [J]. IEEE Transactions on Systems, Man, and Cybernetics Society, 1978, 8(4): 237~247.
- 2 Haralick R M. Statistical and structural approaches to texture [J]. Proceeding of the IEEE, 1979, 67(5): 786~804.
- 3 Gool L Van, Dewaele P, Oosterlinck A. Texture analysis anno 1983 [J]. Computer Vision Graphics Image Process, 1985, 29: 336~357.
- 4 Jain A K, Farrokhnia F. Unsupervised texture segmentation using Gabor filters [J]. Pattern Recognition, 1991, 24(12): 1167~1186.
- 5 Tan T N. Texture edge detection by modeling visual cortical channels [J]. Pattern Recognition, 1995, 28(9): 1283~1298.
- 6 Bovik A C, Clark M, Geisler W S. Multichannel texture analysis using localized spatial filters [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990, 12(1): 55~73.
- 7 Tenenier A, Pichler O, Hosticka B J. Unsupervised texture segmentation of images using tuned matched Gabor filters [J]. IEEE Transactions on Image Process, 1995, 4(11): 1549~1560.
- 8 Jin X C, Ong S H. A practical method for estimating fractal dimension [J]. Pattern Recognition Letters, 1994, 16(5): 457~464.
- 9 Pentland A P. Fractal based description of natural scenes [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1984, 6(6): 661~674.
- 10 Daugman J G. Uncertainty relation for resolution in space, spatial frequency and optimized by two-dimensional visual cortical filters [J]. Journal of the Optical Society of America A, 1985, 2(7): 1160~1169.
- 11 Pollen D A, Ronner S E. Visual cortical neurons as localized spatial frequency filters [J]. IEEE Transactions on System, Man and Cybernetics, 1983, 13(5): 907~916.
- 12 Lichard Lippmann. An introduction to computing with neural nets [J]. IEEE ASSP Magazine, 1987, 4(2): 4~22.
- 13 Richard O Duda, Peter E Hart, David G Stork. Pattern Classification (Second Edition) [M]. Brisbane Queensland Australia, John Wiley and Sons, 2001. [Richard O Duda, Peter E Hart, David G Stork 著. 模式分类 (第二版) [M]. 李宏东, 姚天翔等译. 北京: 机械工业出版社, 2003.]
- 14 David A Clausi, Jemigan M Ed. Designing Gabor filters for optimal texture separability [J]. Pattern Recognition, 2000, 33(11): 1835~1849.
- 15 Mahamadou Idrissa, Marc Achery. Texture classification using Gabor filters [J]. Pattern Recognition Letters, 2002, 23(9): 1095~1102.
- 16 Ramchandra Manthalkar, Biswas P K, Chatterji B N. Rotation invariant texture classification using even symmetric Gabor filters [J]. Pattern Recognition Letters, 2003, 24(12): 2061~2068.
- 17 Strand J, Taxt T. Local frequency features for texture classification [J]. Pattern Recognition, 1994, 27(10): 397~406.
- 18 Ohanian P P, Dubes R C. Performance evaluation for four classes of textural features [J]. Pattern Recognition, 1992, 25(8): 819~833.
- 19 Arivazhagan S, Ganesan L. Texture classification using wavelet transform [J]. Pattern Recognition Letters, 2003, 24(9): 1513~1521.