

## 基于 K 型支持向量机的遥感图像分类新算法

王 静\*, 何建农

(福州大学 数学与计算机科学学院, 福州 350108)

(\* 通信作者电子邮箱 wangjing88527@126.com)

**摘 要:** 为了提高遥感图像的分类精度和识别速度, 提出了一种基于 K 型支持向量机(SVM)的遥感图像分类新算法, 该算法将灰度共生矩阵提取的纹理特征与光谱特征相结合进行分类。对两组 Landsat ETM+ 数据进行分类仿真实验, 结果表明, 在多光谱遥感图像的分类中, 新算法提高了分类效率、分类精度和泛化能力, K 型 SVM 是一种优于径向基函数 SVM 的分类器。

**关键词:** K 型核函数; 支持向量机; 纹理特征; 灰度共生矩阵; 遥感图像分类

**中图分类号:** TP751 **文献标志码:** A

### New algorithm of remote sensing image classification based on K-type support vector machine

WANG Jing\*, HE Jian-nong

(College of Mathematics and Computer Science, Fuzhou University, Fuzhou Fujian 350108, China)

**Abstract:** In order to improve the accuracy and recognition speed of the remote sensing image classification, this paper put forward a new algorithm of remote sensing image classification based on K-type Support Vector Machine (SVM), and this algorithm used texture features extracted by gray level co-occurrence matrix combined with the spectral ones for classification. The classification simulation tests were done with two groups of Landsat ETM+ data. The results show that the new algorithm can improve the accuracy and efficiency of the classification, raise generalization ability, and K-type SVM is a superior classifier to the Radial Basis Function (RBF) SVM.

**Key words:** K-type kernel function; Support Vector Machine (SVM); texture feature; Gray Level Co-occurrence Matrix (GLCM); remote sensing image classification

## 0 引言

20 世纪 90 年代以来, 随着模式识别和人工智能理论的迅速发展, 人工神经网络的理论日趋成熟, 算法日益完善, 并在遥感图像的分类中取得了较好的效果<sup>[1-2]</sup>。但由于其网络结构和参数的选择没有充足的理论依据, 易陷入局部极小点等问题使得对经验性因素依赖较大。

支持向量机(Support Vector Machine, SVM)算法的提出, 改善了传统神经网络学习方法的理论弱点, 它不仅结构简单, 而且泛化能力明显提高<sup>[3]</sup>。

基于光谱特征的分类难以解决异物同谱和同物异谱的问题, 所以研究利用其他技术手段辅助遥感图像分类的技术已经是发展的一个重要方向。纹理特征是应用较多的一种非光谱特征。

本文对遥感图像的第一主分量提取纹理特征, 与光谱特征一起组成特征向量, 并且用 K 型 SVM 分类器<sup>[4]</sup>对遥感图像分类。实验结果表明: 与径向基函数(Radial Basis Function, RBF) SVM 相比, K 型 SVM 可缩短训练时间, 提高分类精度; 纹理特征辅助光谱特征分类可以使分类效果更好。

## 1 支持向量机

### 1.1 支持向量机原理

20 世纪 60 年代俄国科学家 Vapnik 等在统计学习理论

(Statistical Learning Theory, SLT) 的基础上提出了 SVM 理论, 90 年代成功构造了 SVM 算法。SVM 方法是建立在 SLT 的 VC 维理论和结构风险最小原理基础上的, 根据有限的样本信息在模型的复杂性和学习能力之间寻求最佳折中, 以期获得最好的推广能力。SVM 分类器在遥感图像分类中也证实了它的可行性及高效性<sup>[3,5-8]</sup>。

SVM 是从线性可分情况下的最优分类面发展而来的, 它的基本思想是寻找一个两类之间的最优分类面  $H: \mathbf{w} \cdot \mathbf{x} + b = 0$  (图 1), 不仅能将两类准确地分开, 而且使得分类间隔  $2/\|\mathbf{w}\|$  最大。因此, 满足:

$$\begin{aligned} \text{Min } & \frac{\|\mathbf{w}\|^2}{2} \\ \text{s. t. } & y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 \end{aligned} \quad (1)$$

的分类面即最优分类面。




图 1 最优分类面示意图

收稿日期: 2012-04-17; 修回日期: 2012-06-04。

基金项目: 国家自然科学基金资助项目(50877010); 福建省杰出青年科学基金资助项目(2009J06024)。

作者简介: 王静(1988-), 女, 山东济南人, 硕士研究生, 主要研究方向: 遥感图像处理; 何建农(1960-), 女, 福建福州人, 副教授, 主要研究方向: 图像处理、信息安全、网格 GIS。

对于线性不可分问题,可以通过引入松弛变量  $\xi_i$  和误差惩罚系数  $C$  来改进,即求解如下的凸二次规划问题:

$$\text{Min } \frac{1}{2} \|w\|^2 + C \sum_i \xi_i$$

$$\text{s.t. } y_i(w \cdot x_i + b) \geq 1 - \xi_i \quad (2)$$

其中,  $\xi_i \geq 0$ ,  $C$  用来控制  $\xi_i$  边界的平衡。通过构造 Lagrange 函数,可把式(2)转化为 Wolfe 对偶问题来解决。

当输入空间不存在线性判别面时,应将输入空间经过某种非线性变换映射到高维特征空间,在这个空间中存在线性的分类规则,可以构造线性的最优分类超平面。

实际问题中需要构造多类 SVM 分类器,可以按照 1-v-r (one-versus-rest) 算法、1-v-1 (one-versus-one) 算法、多对多分类(如决策树算法)等算法来构造或组合多个两类分类器实现分类。

## 1.2 核函数

由低维空间向高维空间映射时带来的困难就是计算复杂度的增加,而核函数正好巧妙地解决了这个问题。这一过程是通过用核函数  $K(x_i, x_j) = \langle \varphi(x_i), \varphi(x_j) \rangle$  代替 Wolfe 对偶问题中  $x_i$  和  $x_j$  的点积来实现的。

不同形式的核函数可以生成不同的 SVM,常用的核函数有如下三种:

1) 多项式核函数:

$$K(x, y) = [\gamma(x \cdot y) + b]^d$$

2) RBF 核函数:

$$K(x, y) = e^{(-\gamma \|x - y\|^2)}$$

3) Sigmoid 核函数:

$$K(x, y) = \tanh[\gamma(x \cdot y) + b]$$

其中,  $\gamma, b, d$  是核函数参数。

在这三种核函数中, RBF 核函数具有较宽的收敛域,是较为理想的分类函数<sup>[9-10]</sup>,应用最广泛。

## 1.3 K 型 SVM

文献[4]提出了 K 型核函数:

$$K(x_i, x_j) = \prod_{i=1}^n \frac{1}{1 + k^2 (x_i^{(i)} - x_j^{(i)})^2} \quad (3)$$

其中  $k > 0$  反映 K 型核函数的宽度;证明了 K 型核函数满足核函数应当满足的条件,是可行的支持向量机核函数,它避免了 RBF 核函数复杂的指数运算,同时具有多项式核函数计算量少和 RBF 核函数逼近精度高与泛化能力强的优点,性能更加优越。利用 K 型核函数,可以构造出性能优越的 K 型 SVM。

## 2 灰度共生矩阵

传统的基于统计的分类方法由于单一地依靠地物的光谱特征难以解决异物同谱和同物异谱的问题,分类精度相对较低,不能适应中比例尺及更大比例尺的土地分类需要。所以研究利用纹理特征等技术手段辅助遥感影像自动分类的技术已经是未来发展的一个重要方向。

基于灰度共生矩阵 (Gray Level Co-occurrence Matrix, GLCM) 提取纹理特征的方法是应用最广泛的一种纹理统计分析方法。Haralick 等<sup>[11]</sup>于 1973 年首先提出灰度共生矩阵,它是图像中两个像素灰度级联合分布的统计形式,能较好地反映纹理灰度级相关性的规律。它从图像  $(x, y)$  灰度为  $i$  的像素出发,统计与距离为  $\delta = (\Delta x^2 + \Delta y^2)^{\frac{1}{2}}$ 、灰度为  $j$  的像素同时出现的概率<sup>[12]</sup>  $P(i, j, \delta, \theta)$ , 用数学式表示为:

$$P(i, j, \delta, \theta) = \{[(x, y), (x + \Delta x, y + \Delta y)] | f(x, y) = i, f(x + \Delta x, y + \Delta y) = j; x = 0, 1, \dots, N_x - 1; y = 0, 1, \dots, N_y - 1\} \quad (4)$$

其中  $i, j = 0, 1, \dots, L - 1$ ,  $(x, y)$  是图像中的像素坐标,  $L$  为灰度级数,  $N_x, N_y$  分别为图像的行列数。

武维等<sup>[13]</sup>通过对比实验结果表明:考虑了 GLCM 纹理信息的分类能更真实有效地反映遥感图像中地物目标的整体结构,为进一步有效的地物分类提供保障。

Haralick 等<sup>[11]</sup>由 GLCM 提取出 14 种特征,但是田艳琴等<sup>[14]</sup>的实验结果证明了以下四种统计量能比较精确地描述遥感图像纹理的定量信息:

1) 熵:

$$f_{\text{ENT}} = - \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p(i, j) \log p(i, j) \quad (5)$$

2) 角二阶矩:

$$f_{\text{ASM}} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} p^2(i, j) \quad (6)$$

3) 非相似性:

$$f_{\text{DIS}} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} |i - j| p(i, j) \quad (7)$$

4) 逆差矩:

$$f_{\text{HOM}} = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} \frac{p(i, j)}{1 + (i - j)^2} \quad (8)$$

式(5)~(8)中的  $p(i, j)$  为式(4)所得 GLCM 中对应元素的归一化值。

对于多光谱遥感图像而言,文献[15]验证了经主成分分析得到的第一主分量替代原图像进行纹理分析是合理的。

## 3 基于 K 型 SVM 的遥感图像分类

### 3.1 新算法的基本思想

利用光谱特征和由 GLCM 提取出的四个纹理特征,采用 K 型 SVM 以及 1-v-1 算法对遥感图像进行分类。

### 3.2 新算法的特点

K 型 SVM 具有较小的计算量和计算时间代价,比常用的 RBF SVM 具有更高的分类效率、更高的分类精度和更强的泛化能力。1-v-1 算法虽然需要用  $N(N-1)/2$  ( $N$  是类别数)个分类器对样本进行训练,但是每个分类器训练的样本数据仅仅来自两个类,所以整个训练的时间相对来说并不多,最适合解决多类问题。纹理特征参与遥感图像的分类可以提高一些易混分像元的分类精度,使分类更加精确。因此,新算法具有相对速度快、精度高、推广能力强的特点。

### 3.3 新算法的描述

分类的实现主要分三个阶段:1)把训练样本输入 SVM 分类器进行训练;2)用训练好的 SVM 分类器对测试样本进行分类,并对结果进行评价分析;3)对待分类图像进行分类。

新算法的实现步骤为:

步骤 1 数据预处理。设标记样本集为:

$$T = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l), (x_{l+1}, y_{l+1}), \dots, (x_{l+m}, y_{l+m})\}$$

其中,  $x_i \in \mathbf{R}^n$ ,  $y_i \in \{-1, 1\}$ ,  $n$  是光谱特征和纹理特征组合成的特征向量  $x_i$  的维数,  $y_i$  为对应的类别标签。对  $x_i$  进行 0-1 规范化处理分别得到训练样本集  $T_1 = \{(\overline{x_1}, y_1), (\overline{x_2}, y_2), \dots, (\overline{x_l}, y_l)\}$  和测试样本集  $T_2 = \{(\overline{x_{l+1}}, y_{l+1}), (\overline{x_{l+2}}, y_{l+2}), \dots, (\overline{x_{l+m}}, y_{l+m})\}$ 。

步骤 2 初始化惩罚系数  $C$  和 K 型 SVM 的核参数  $k$ , 取  $C_0 = 2^{-10}$ ,  $k_0 = 0.1$ 。

步骤 3 构造并求解最优化问题。

用 1-v-1 算法, 构造多个两类分类器。对其中任意两类样本, 解决如下的最优化问题:

$$\begin{aligned} \text{Min } & \frac{1}{2} \alpha^T Q \alpha - e^T \alpha \\ \text{s. t. } & y^T \alpha = 0 \end{aligned} \quad (9)$$

其中,  $0 \leq \alpha_i \leq C, i = 1, \dots, l; e$  是元素全为 1 的向量,  $Q$  为正定或半正定矩阵,  $Q_{ij} = y_i y_j K(\bar{x}_i, \bar{x}_j), K(\bar{x}_i, \bar{x}_j)$  为式(3)定义的 K 型核函数。

采用序列最小最优化 (Sequential Minimal Optimization, SMO) 算法<sup>[16]</sup>求得式(9)的最优解  $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_l^*)^T$ , 步骤如下:

① 给定工作集  $B \subset \{1, 2, \dots, l\}$  及精度要求  $\varepsilon$ , 且  $B$  的元素个数  $|B| = 2, N = \{1, 2, \dots, l\} / B$ , 初始值  $k = 1$ , 初始点  $\alpha^1 = \begin{bmatrix} \alpha_B \\ \alpha_N \end{bmatrix}$ 。

② 如果  $\alpha^k$  是问题的最优解, 则停止; 否则, 按 1) 重新取工作集  $B$ 。

③ 求解关于  $\alpha_B$  的二次式:

$$\begin{aligned} \text{Min } & \frac{1}{2} \alpha_B^T Q_{BB} \alpha_B - (e^B - Q_{BN} \alpha_N^k)^T \alpha_B \\ \text{s. t. } & y_B^T \alpha_B + y_N^T \alpha_N^k = 0 \end{aligned} \quad (10)$$

其中  $Q = \begin{bmatrix} Q_{BB} & Q_{BN} \\ Q_{NB} & Q_{NN} \end{bmatrix}, 0 \leq (\alpha_B)_i \leq C, i = 1, 2$ 。

④ 设  $\alpha_B^{k+1}$  为式(10)的最优解并使  $\alpha_N^{k+1} = \alpha_N^k$ , 设  $k \leftarrow k + 1$  并转过程 2)。

步骤 4 构造决策函数:

$$f(x) = \text{Sgn} \left[ \sum_i y_i \alpha_i^* K(\bar{x}_i, \bar{x}) + b^* \right]$$

其中,  $b^* = y_j - \sum_i y_i \alpha_i^* K(\bar{x}_i, \bar{x}_j)$ , 下标  $i \in \{i | \alpha_i^* > 0\}$ 。每个 K 型 SVM 都对相应样本的类别有一个判断, 采用投票策略, 得票最多的类即为该样本的最终判别类。

步骤 5 分类测试。用测试样本集  $T_2$  进行仿真实验, 记录分类精度  $\Omega$ 。分别在  $[2^{-10}, 2^{10}]$  和  $[0.1, 10]$  内取  $C$  和  $k$  的值, 步长分别为  $\delta_C = 1, \delta_k = 0.1$ , 用这些数值组成二维网格, 直至每一对网格顶点都测试完毕 (记最高分类精度为  $\Omega_{\max}$ , 它对应的参数组合即为最优), 否则转到步骤 3。

步骤 6 对待分类图像分类。利用最优参数组合的 K 型 SVM 进行分类, 将结果的数据矩阵显示出来。

## 4 仿真实验与结果分析

### 4.1 实验一

#### 4.1.1 数据准备

首先对美国 Lanier lake 湖区 Landsat ETM+ 遥感图像进行降噪、去条带等预处理, 选取大小为  $300 \times 300$  像元的图像作为待分类图像, 组合波段 5、4、3 成假彩色合成图<sup>[17]</sup> (图 2(a)), 并将待分类图像进行主成分分析得到图 2(b)。

参照土地利用图, 采用目视解译, 确定该地区地面覆盖类型为水域 (W)、草地 (G)、落叶林 (D)、针叶林 (P)、耕地 (A)、居民区 (U) 和裸地 (B), 七类共选取 1400 个 ( $200 \times 7$ ) 标注样本, 将其中的 700 个 (每类随机选取 100 个) 作为训练样本, 剩余样本作为测试样本。




图 2 遥感图像 1

将图 2(a) 的三个波段的光谱信息作为遥感图像的光谱特征。利用图 2(b) 的第一主分量提取图像的纹理特征, 即: 选取大小为  $3 \times 3$  的窗口, 距离  $\delta = 1$ , 分别计算由 GLCM 得出的 4 个特征值 (熵、角二阶矩、非相似性、逆差矩) 关于 4 个方向 ( $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$ ) 的平均值, 得到 4 个具有旋转不变特性的纹理特征, 并生成纹理图像 (图 3)。




图 3 图 2 的纹理图像

#### 4.1.2 仿真实验及分析

为验证 K 型 SVM 的分类性能和采用纹理特征参与分类的效果, 在内存为 2 GB、CPU 为 T4400-2.20 GHz、操作系统为 XP 的笔记本电脑上进行仿真实验, 步骤如下:

- 1) 利用光谱特征, 采用 RBF SVM 进行分类。
- 2) 利用光谱和纹理组合特征, 采用 RBF SVM 进行分类。
- 3) 利用光谱特征, 采用 K 型 SVM 进行分类。
- 4) 利用光谱和纹理组合特征, 采用 K 型 SVM 进行分类。

将 4 次实验所得的分类混淆矩阵中的用户精度和生产精度、总体分类精度、Kappa 系数、分类时间作为评价标准, 比较见表 1。

由表 1 可以看出, 两种 SVM 分类器对水体和草地分类的生产精度都达到了 100%, 但 K 型 SVM 对其他五类地物的分类精度比 RBF SVM 都有显著提高。利用同一种 SVM 分类器时, 加入纹理特征对落叶林、针叶林、耕地的区分更有效, 这是因为这三类地物的光谱特征有很大的相似性, 而加入纹理特征后利于解决这种“异物同谱”问题。居民区和裸地的生产精度相对较低, 是因为这两种地物具有复杂的结构, 其像元多为混合像元, 从而易被混分。利用组合特征比单纯用光谱特征对裸地的识别效果好。此外, K 型 SVM 缩短了分类时间。因此, 这种结合纹理特征的 K 型 SVM 比 RBF SVM 具有更高的分类效率和更高的分类精度。利用学习结果对待分类图像进行分类, 得到分类结果图像 (图 4)。



表 1 分类评价对比 1

| 方法         | W   |     | G     |     | D     |     | P     |     | A     |     | U     |     | B     |     | 总体分类精度/% | Kappa 系数 | 分类时间/s |
|------------|-----|-----|-------|-----|-------|-----|-------|-----|-------|-----|-------|-----|-------|-----|----------|----------|--------|
|            | X/% | Y/% | X/%   | Y/% | X/%   | Y/% | X/%   | Y/% | X/%   | Y/% | X/%   | Y/% | X/%   | Y/% |          |          |        |
| 光谱特征 + RBF | 100 | 100 | 86.21 | 100 | 92.86 | 91  | 96.81 | 91  | 85.87 | 79  | 80.21 | 77  | 79.81 | 83  | 88.7143  | 0.8289   | 0.0676 |
| 组合特征 + RBF | 100 | 100 | 87.72 | 100 | 90.82 | 89  | 95.96 | 95  | 92.47 | 86  | 86.36 | 76  | 77.78 | 84  | 90.0000  | 0.8833   | 0.1019 |
| 光谱特征 + K 型 | 100 | 100 | 88.50 | 100 | 90.29 | 93  | 95.92 | 94  | 96.59 | 85  | 81.31 | 87  | 85.71 | 78  | 91.0000  | 0.8950   | 0.0460 |
| 组合特征 + K 型 | 100 | 100 | 87.72 | 100 | 88.79 | 95  | 96.91 | 94  | 97.73 | 86  | 90.22 | 83  | 84.31 | 86  | 92.0000  | 0.9067   | 0.0639 |

注: X 表示用户精度, Y 表示生产精度。




图 4 分类结果比较 1

#### 4.2 实验二

另取一幅遥感图像,仿照实验一,经预处理后得到的假色彩合成图和主成分变换图像如图 5 所示。该地区地面覆盖类型主要为水域(W)、森林(F)、草地(G)、城郊住宅区(C)四类,选取 800 个(200×4)标注样本。利用图 5(b)的第一主分量提取图像的纹理特征后,进行四次对照实验,得到实验的分类评价对比表(表 2)和分类效果对比图(图 6)。




图 5 遥感图像 2

表 2 分类评价对比 2

| 方法             | 总体分类精度/% | Kappa 系数 | 分类时间/s |
|----------------|----------|----------|--------|
| 光谱特征 + RBF SVM | 96.25    | 0.9500   | 0.0238 |
| 组合特征 + RBF SVM | 96.50    | 0.9533   | 0.0369 |
| 光谱特征 + K 型 SVM | 97.50    | 0.9667   | 0.0198 |
| 组合特征 + K 型 SVM | 98.25    | 0.9767   | 0.0274 |

通过表 2 同样可以得出 K 型 SVM 分类器的分类性能优于 RBF SVM 分类器。观察图 6 可得:仅用光谱特征参与分类时大量的森林被划分为城郊住宅区,用 RBF SVM 分类器扩大了水域的覆盖面积;而利用本文的结合纹理特征的 K 型 SVM 使得分类更加精确。

#### 5 结语

本文首次将 K 型 SVM 应用到遥感图像分类中,提出了一

种基于 K 型 SVM 和 GLCM 的多光谱遥感图像分类新算法。实验结果表明,与 RBF SVM 分类器和单一的光谱特征参与分类相比,本文提出的算法不仅得到了更好的分类结果,而且缩短了分类时间,提高了效率。




图 6 分类结果比较 2

#### 参考文献:

- [1] 任军号, 吉沛琦, 耿跃. SOM 神经网络改进及在遥感图像分类中的应用[J]. 计算机应用研究, 2011, 28(3): 1170-1172.
- [2] 周义, 阮仁宗. LM-BP 神经网络在遥感影像分类中的应用研究[J]. 遥感信息, 2010(5): 80-86.
- [3] 朱海洲, 贾银山. 基于支持向量机的遥感图像分类研究[J]. 科学技术与工程, 2010, 10(15): 3659-3663.
- [4] 孙翠娟. 基于 K 型核函数的支持向量机[J]. 淮海工学院学报: 自然科学版, 2006, 15(2): 4-7.
- [5] 崔炳德. 支持向量机分类器遥感图像分类研究[J]. 计算机工程与应用, 2011, 47(27): 189-191.
- [6] WANG YU-JIAN, YUAN JIA-ZHENG, FAN LI-LI, *et al.* Application research of support vector machine in multi-spectra remote sensing image classification[C]// Proceedings of the 2th International Congress on Image and Signal Processing. [S. l.]: IEEE, 2009, 10: 1-5.
- [7] 陈伟, 余旭初, 张鹏强, 等. 基于一类支持向量机的高光谱影像地物识别[J]. 计算机应用, 2011, 31(8): 2092-2096.
- [8] LI C-H, KUO B-C, LIN C-T, *et al.* A spatial-contextual support vector machine for remotely sensed image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(3): 784-799.
- [9] 李盼池, 许少华. 支持向量在模式识别中的核函数特性分析[J]. 计算机工程与设计, 2005, 26(2): 302-304.
- [10] 王双亨, 艾泽天, 都伟冰, 等. 基于 SVM 不同核函数的多源遥感影像分类研究[J]. 河南理工大学学报: 自然科学版, 2011, 30(3): 304-309.

(下转第 2839 页)

### 3.2 实时性实验

文献[12]提出将亮度分量进行三级小波分解,然后丢掉所有高频子带,只保留低频子带,进行三级小波反变换得到重建图像,再对重建图像进行平滑滤波得到介质散射光图像。本文在三级小波变换的低频子带  $LL_3$  上进行高斯平滑,其大小为原始图像大小的  $1/64$ ,文献[12]则是对整幅图像进行平滑,对于大图像至少使用大小  $9 \times 9$  的高斯模板,高斯半径  $\sigma = 1.5$ ,才可以达到较好的平滑效果,大模板又进一步增加了时间消耗。

时间测试实验:计算机为主频 3.06 GHz,内存 512 MB;编程软件平台为 Microsoft Visual C++ 6.0,本文算法对  $384 \times 384$  分辨率的彩色图像进行处理,处理一幅图像的耗时为 63 ms,文献[12]中算法的时间:计算机为主频 2.80 GHz,内存 512 MB,算法对  $384 \times 384$  分辨率的彩色图像进行处理,处理一幅图像的耗时为 187 ms。即使计算机主频 3.06 GHz 要比主频 2.80 GHz 的运行速度稍微快些,本文算法实时性也较高,基本能够满足实时处理视频的要求。另外本文算法对其中两幅图像进行了处理,结果如图 3 所示。实验结果表明,本算法不仅实时性较高,而且清晰度也较高。




图 3 实时性比较结果

## 4 结语

本文提出了一种新的水下图像清晰化算法,将水下图像光学成像模型应用于小波域,在低频子带上同时去除了图像

模糊和光照不均问题,在高频子带上设计高通滤波器的非线性变换进一步增强了图像的细节,实现了水下图像的清晰化处理,并且算法具有较高的实时性。

### 参考文献:

- [1] 王彬. 水下图像增强算法的研究[D]. 青岛: 中国海洋大学, 2009.
- [2] 李庆忠, 王文锦. 甚低比特率水下视频图像压缩编码方法[J]. 光电子·激光, 2009, 20(10): 1371-1375.
- [3] GARCIA R, NICOSEVICI T, CUFI X. On the way to solve lighting problems in underwater imaging[C]// Proceedings of the IEEE OCEANS Conference. [S. l.]: IEEE, 2002: 1018-1024.
- [4] ARNOLG-BOS A, MALKASSET J, KERVERN G. Towards a model-free denoising of underwater optical images[C]// Proceedings of the Oceans 2005-Europe. Brest, France: IEEE Computer Society, 2005: 527-532.
- [5] 汪荣贵, 朱静, 杨万挺, 等. 基于照度分割的局部多尺度 Retinex 算法[J]. 电子学报, 2010, 38(5): 1181-1186.
- [6] PADMAVATHI G, SUBASHINI P, KUMAR M M, et al. Comparison of filters used for underwater image pre-processing[J]. International Journal of Computer Science and Network Security, 2010, 10(1): 58-65.
- [7] HASSAN N Y, AAKAMATSU N. Contrast enhancement technique of dark blurred image[J]. International Journal of Computer Science and Network Security, 2006, 6(2A): 223-226.
- [8] IQBAL K, SALAM R A, OSMAN A, et al. Underwater image enhancement using an integrated colour model[J]. International Journal of Computer Science, 2007, 34(2): 529-534.
- [9] LI TAO, ASARI V K. Adaptive and integrated neighborhood-dependent approach for nonlinear enhancement of color images[J]. Journal of Electronic Imaging, 2005, 14(4): 1-14.
- [10] 王彬. 基于改进等功率谱法的水下图像增强[J]. 中国科技信息, 2009(19): 46-47.
- [11] 王猛, 白洪亮. 同态滤波器在水下图像对比度增强中的应用[J]. 应用科技, 2003, 30(7): 15-17.
- [12] 李庆忠, 李长顺, 王中琦. 基于小波变换的水下降质图像复原算法[J]. 计算机工程, 2011, 37(22): 202-203, 206.
- [13] SCHETTINI R, CORCHS S. Underwater image processing: State of the art of restoration and image enhancement methods[J]. EURASIP Journal on Advances in Signal Processing, 2010, 2010(1): 1-14.
- [14] NASCIMENTO E, CAMPOS M, BARROS W. Stereo based structure recovery of underwater scenes from automatically restored images[C]// Proceedings of SIBGRAPI 2009-22nd Brazilian Symposium on Computer Graphics and Image Processing. Rio de Janeiro, Brazil: IEEE Computer Society, 2009: 330-337.
- [15] 朱虹. 数字图像处理基础[M]. 北京: 科学出版社, 2005: 32-33.

(上接第 2835 页)

- [11] HARALICK R M, SHANMUGAM K, DINSTEN I. Textural features for image classification[J]. IEEE Transactions on System, Man and Cybernetics, 1973, 3(6): 610-621.
- [12] 贾永红. 计算机图像处理与分析[M]. 武汉: 武汉大学出版社, 2001: 165-168.
- [13] 武维, 李玉霞, 童玲, 等. 基于共生矩阵的遥感图像面向对象分割[J]. 计算机工程与设计, 2011, 32(2): 596-598.
- [14] 田艳琴, 郭平, 卢汉清. 基于灰度共生矩阵的多波段遥感图像纹理特征的提取[J]. 计算机科学, 2004, 31(12): 162-163.

- [15] 邓锴, 常庆瑞, 纪娜. 基于多源信息的 TM 遥感图像计算机分类[J]. 微计算机信息, 2008, 24(21): 277-279.
- [16] 丁世伟, 齐丙娟, 谭红艳. 支持向量机理论与算法研究综述[J]. 电子科技大学学报, 2011, 40(1): 2-10.
- [17] 郭斌, 任志远. 陆地卫星影像用于土地利用覆被变化中的波段组合研究[J]. 陕西师范大学学报: 自然科学版, 2007, 35(2): 112-116.