

图像多尺度几何分析理论与应用 ——后小波分析理论与应用

焦李成 侯彪 王爽 刘芳 著

西安电子科技大学出版社

2008

内 容 简 介

本书从函数的非线性逼近出发,介绍了多尺度几何分析方法和理论,以及在图像处理领域中的应用。全书共13章,第1章系统地介绍了推动多尺度几何分析发展的数学和生理学背景,综述了图像的多尺度几何分析方法的历史沿革、最新成果及存在的问题;第2章从神经网络、统计估计、逼近论、调和分析等角度研究了多变量目标函数的逼近问题,并指出了这一领域研究的有关问题以及在信号和图像处理中的应用;第3章论述了基于脊波变换的直线特征检测方法;第4章介绍了脊波双框架系统;第5章介绍了自适应连续脊波网络;第6~13章分别介绍了曲线波、梳状波、子束波、楔形波、轮廓波、条带波、方向波和剪切波的基本理论及其应用,应用范围涉及图像压缩、去噪、融合、分割和分类等不同方面。本书从第3章起每一章都给出了相应的实验方法和实验结果。

本书可作为高校电子工程、信号与信息处理、应用数学等专业的高年级本科生或研究生的教材,也可作为从事多尺度几何分析和数字图像处理方面研究工作的科技工作者的参考资料。

图书在版编目(CIP)数据

图像多尺度几何分析理论与应用——后小波分析理论与应用/焦李成等著.

—西安:西安电子科技大学出版社,2008.7

ISBN 978-7-5606-2027-5

I. 图… II. 焦… III. 几何—尺度分析—应用—图像处理 IV. TP391.41

中国版本图书馆 CIP 数据核字(2008)第 052617 号

策 划 高维岳

责任编辑 张 玮 高维岳

出版发行 西安电子科技大学出版社(西安市太白南路2号)

电 话 (029)88242885 88201467 邮 编 710011

http://www.xduph.com E-mail: xdupfxb001@163.com

经 销 新华书店

印刷单位 陕西天意印务有限责任公司

版 次 2008年7月第1版 2008年7月第1次印刷

开 本 787毫米×1092毫米 1/16 印张 32.875

字 数 592千字

印 数 1~2500册

定 价 50.00元(精装版:60.00元)

ISBN 978-7-5606-2027-5/TP·1049

XDUP 2319001-1

如有印装问题可调换

本社图书封面为激光防伪覆膜,谨防盗版。

10.6.2 基于 SVM 和多层小波轮廓波分解的纹理图像分割

从上一节得到的结果中可以看到, 结合小波和 Contourlet 的方法对于纹理分割有一定的效果, 但是在区域上有一些错分。近年来, 支撑矢量机 (Support Vector Machine, SVM) 得到了飞速发展, 并且已经被证明在分类问题上有很好的效果, 因此考虑把 SVM 用在纹理分割问题中。但是考虑到计算复杂度, 在本节中, 首先利用 SVM 得到监督的初始纹理分割结果, 之后把这个结果利用到后面的分割中。对比实验结果可以看出, 该方法比上节中用到的方法提高了分割精确度。

算法中所使用的提取特征的方法仍然是 Laws 方法, 用到的 SVM 算法是序列最小优化算法 (Sequential Minimal Optimization, SMO)。分割算法如图 10.51 所示。

-
- Step 1 输入训练样本, 并且训练得到 SVM。
- Step 2 把原图 $f(k, l) (1 \leq k \leq I, 1 \leq l \leq J)$ 进行 N 层 Contourlet 分解, 并且利用已经训练好的 SVM 对第一层的分解结果进行纹理分类。
- Step 3 得到一个由 SVM 分类的初始分割结果, 作为监督的粗结果, 记为 seg_SVM 。
- Step 4 把原图 $f(k, l) (1 \leq k \leq I, 1 \leq l \leq J)$ 分别进行 N 层小波分解和 Contourlet 分解。
- Step 5 在一层的 Contourlet 分解之后, 我们可以得到一个低频子带 $c_1(x, y)$, 三个中频子带 $d_1^1(x, y)$ 、 $d_1^2(x, y)$ 、 $d_1^3(x, y)$ 。根据式 (10.60) 和式 (10.61), 便可以得到特征矢量, 这些矢量是对应于每一个子带的。因此, 在每一个像素点 (x, y) 都构造了一个四维的特征矢量。
- Step 6 对于每一个像素点上的四维特征矢量, 利用 k 均值聚类算法对特征矢量进行聚类, 之后就可以得到第一层分解后的分割结果 seg_1 , 作为非监督的粗结果。把 seg_1 和在 Step 3 中得到的 seg_SVM 相结合, 得到的是粗分割的结果, 记为 seg_rough 。
- Step 7 把 seg_rough 在水平和垂直方向上分别扩展为原来的两倍。就可以得到一个新的结果 seg_1' , 大小是 seg_rough 的四倍, 这个扩展后的结果将用在下面的步骤中。
- Step 8 循环 $n=2 \sim N$, 直到得到最后的结果 seg_N 。
- Step 8.1 执行 N 层小波变换, 得到三个高频子带 $d_n^1(x, y)$ 、 $d_n^2(x, y)$ 、 $d_n^3(x, y)$ 。
- Step 8.2 执行 N 层 Contourlet 变换, 得到 2^n 个方向子带 $s_n^1(x, y)$ 、 $s_n^2(x, y)$ 、 $\dots$ 、 $s_n^{2^n}(x, y)$, 以及在 Step 7 中得到的结果 seg_1' , 根据式 (10.60) 和式 (10.61), 在每个像素点 (x, y) 构造一个特征矢量。
- Step 8.3 利用 k 均值聚类算法, 便得到第 n 层分解之后的结果 seg_n 。
- Step 9 分别在水平和垂直方向扩展结果 seg_N , 便得到了最终的分割结果 seg 。图 10.52 是分割的过程。
-

图 10.51 基于 SVM 和多层小波 Contourlet 分解的纹理图像分割算法




图 10.52 算法框图

我们通过 4 组对比实验来测试本节提出的算法的有效性。其中，待分割图像为 4 幅合成纹理图像，均是来自于 Brodatz 纹理库。为了测试本节算法的有效性，把利用本节算法得到的结果和经典的 GLCP 方法、基于 Contourlet 的分割方法、上一节中基于多层小波和 Contourlet 分解的分割算法（简记为 CWCD）来进行比较，图 10.53 是实验结果，图 10.54 中给出了每幅纹理图像的错误率。通过实验结果和数据分析，都可以看出本节算法用于纹理分割的优势。




图 10.53 图像分割结果(每一行从左至右分别为原图、GLCP、Contourlet、CWCD 和本节方法)




图 10.54 不同方法的错误率比较

这些实验结果表明,本节的方法在边缘准确性和区域一致性上有一个较好的折中,得到了比较满意的结果。

由图 10.53 的结果可以看到,本节中的方法在区域一致性上要比 GLCP 结果好,并且在边缘准确性上比 Contourlet 和 CWCD 要好。与图 10.53(a) 的分割结果相似,图 10.53(b) 的分割结果虽然在第三类纹理上有一些错分率,但仍然要比其他的结果好,图 10.53(c) 也得到了类似的分割结果。图 10.53(d) 包含五类纹理,第二类和第三类纹理有错分,第四类纹理在边缘上有错分,但是从错分率上来看,还是要比其他方法的结果要好。

10.6.3 基于 WBCT 和克隆选择算法的纹理图像分类

1. 基于小波分解的轮廓波

在轮廓波变换的基础上,最近出现了基于小波分解的轮廓波构造方法 (Wavelet-Based Contourlet Transform, WBCT)^[86~88],文献[86~88]将它用于图像压缩,取得了较好的结果。不同于塔式滤波器对频域的划分, WBCT 首先使用小波分解将图像划分为四个子带,然后再将每个子带经过方向滤波器组,实现轮廓波对二维 Fourier 平面频域的划分。

由于 DFB 可以很好地捕获输入图像的高频信息,但是对低频信息效果很差,因此必须和多尺度分解相结合,否则低频信息会“泄漏”到 DFB 的高频子带中。因为小波不能把频率空间划分为严格的低通和高通成分,所以并不是所有在 HL 子带中的方向是垂直的,也不是所有在 LH 子带中的方向是水

平的, 因此在小波分解的每个高通子带上都应用 DFB 来充分分解^[86]。分解的方向数必须是 2^N , $N=1, 2, 3, \dots$ 。为满足各向异性比例原则: $\text{length}^2 \approx \text{width}$, 在最细的尺度上分解的方向数应最多, 然后随着尺度变粗, 分解的方向数逐渐减少。由于纹理的低频部分不一定总是包含着重要信息, 因此 WBCT 较小波和 Contourlet 可以进一步挖掘方向纹理的特征。

图 10.55 给出了应用 3 层小波时的 WBCT 分解示意图。图 10.56 给出了 Barbara 图像的 WBCT 分解系数图, 为了视觉上的清晰, 进行了 2 层分解, 方向数分别为 4 和 8。




图 10.55 WBCT 的分解示意图(按尺度由粗到细, 分解方向数依次为 4、4、8)




图 10.56 Barbara 图像的 WBCT 分解系数图

2. 基于 WBCT 的纹理特征提取

本节将 WBCT 应用于纹理图像的分类与识别, 首先对图像进行 WBCT 分解, 然后对各分解子带提取特征。目前能量测度在时频分析中应用广泛, 因为变换域中的能量模式分布可以提供独特的信息, 这一点对纹理分类非常有用。而子带系数的方差和 Hu 不变矩也常使用, 因为它们也可以在一定程度上表示系数的统计特性。本节分别使用了能量、方差、Hu 不变矩^[113, 114]这三种子带特征提取方式。

1) 基于系数重排的特征维数缩减

用 DFB 对小波高频子带分解后可以得到许多矩形的方向子带, 对于分解 3 层, 每层分解方向数分别为 4、8 和 16 所得到的 WBCT 系数, 再取出其中的能量测度, 共可得到 85 维特征。在文献[86]中为了使用一种类似 SPHIT 编码对图像进行压缩, 提出了一种系数重排的方法。受该方法的启发, 本节提出了一种在 WBCT 域进行系数重排的降维方法, 并将它用于纹理图像分类。具体步骤如下: 首先, 用 WBCT 对图像进行分解; 其次, 在每一尺度上的相邻方向之间, 依次抽取近似水平方向子带的对应列(图 10.57 中的下半部分子带)和近似垂直方向子带的对应行(图 10.57 中的上半部分子带), 将 DFB 分解得到的相邻方向的矩形子带合并成使用 DFB 前该方向上的小波分解所得到的正方形子带大小; 然后, 计算重排后的每个子带的能量测度; 最后, 用 KNN 分类器对特征向量进行分类。进行这样的系数重排操作之后, 由上述 85 维的特征就可以得到只有 49 维的特征, 在很大程度上减少了特征维数。图 10.58 为对图 10.56 中的 Barbara 图像的 WBCT 分解系数图进行系数重排后的结果。




图 10.57 重排 WBCT 子带系数的示意图



图 10.58 图 10.56 的系数重排后的系数图

2) 基于克隆选择算法的特征选择

在模式识别中,特征提取和特征选择是两个关键的预处理环节,它们的基本任务是如何从许多特征中找出最有效的特征^[89],这对后续的分类精度、时间都有不可忽视的影响。在样本数目有限的情况下,通常提取的很多特征是有冗余的,这些冗余特征不仅会使运算量增大,还可能降低分类的精度。一种解决办法就是通过特征空间变换,即对特征向量做线性或非线性变换,将原始特征从高维空间变换到另一个低维空间来达到降低特征维数的目的。目前,较常用的特征变换方法有:K-L 变换^[90]、奇异值分解(SVD)^[91]、主分量分析(PCA)^[92]、核主分量分析^[93]、Fisher 变换^[94]等。但是利用这些变换抽取得到的特征没有明确的实际含义,难以理解。而对于很多实际应用问题来说,特征的可解释性往往非常重要。另一种降低特征维数的方法就是特征选择。特征选择是从一组特征中挑选出一部分特征,使它们所构成的新特征向量具有更好的辨识能力。通过特征选择得到的是从原始特征向量中选出的对分类最有利的特征子集,这不会破坏特征的可解释性,同时降低了输入空间维数,有助于提高分类精度,因而在图像处理中得到了成功的应用。

1997 年, Kohavi 和 John 提出 Wrapper 模型^[95],它是直接通过分类器的性能来评价特征选择算法,并将特征选择方法分为滤波式(Filter)和封装式(Wrapper)两类。滤波式的方法是将特征选择作为单独的部分,其评价与分

类器无关,采用来源于数据本身的特性作为可分性判据。封装式方法采用分类器的识别率作为评价函数,即选择使分类器的错误概率最小的特征子集。由于将特征选择与识别作为一个整体完成,因此该方法得到的特征子集与后续的学习算法密切相关,能够得到较高的识别率。

特征选择的任务是从已知的特征集中选择一个子集使评价标准最优^[96]。实质上,特征选择就是一个求解组合优化问题的过程,因此可以用解决组合优化问题的方法来解决特征选择问题。按照搜索方式可以分为:穷举法、启发式搜索和随机搜索(如模拟退火算法^[97]、遗传算法(Genetic Algorithm, GA)^[98]、免疫克隆选择算法^[74])。

遗传算法是一种经典的优化算法,基于遗传算法的特征选择方法也已经得到了广泛应用^[98~100]。但是遗传算法中的交叉、变异算子都是在一定发生概率下随机的、没有指导性的迭代搜索,从而导致了算法收敛速度慢,容易陷入局部最优,往往不能在有限代数内找到问题的最优解。基于人工免疫系统的克隆选择算法在解决优化问题中表现出良好的性能,文献[101, 102]将该方法用于特征选择,表现出优于遗传算法的性能,并得到了优于 GA 的效果。但是该方法仍存在问题,如特征选择的收敛速度慢,每次迭代的用于运算巴氏距离的时间长,用于纹理图像分类时分类精度有所下降,且结果不稳定等。所以本文在文献[101]所采用的克隆选择算法中加入克隆死亡操作来加快算法收敛,并改用基于训练样本正确分类概率作为亲合度函数的 Wrapper 选择方法,该方法计算简单且避免了求巴氏距离带来的时间消耗。

从所做的大量实验中发现 WBCT 分解得到的低频子带信息对于分类来说非常重要。因此,在克隆选择的过程中,我们采用不对全部特征进行随机选择的策略,即只对高频方向信息进行特征选择,这样可以较好地提高分类精度,并使结果更加稳定。

迭代停止条件通常设置为最大进化代数。当进化过程结束时,当前种群中具有最大亲合度的个体即为最优解,合并该个体中对应比特位为 1 的特征即构成最佳的特征集合。

算法步骤如图 10.59 所示。

3. 实验结果与分析

为了说明本节特征提取方法的优越性与分类器无关,在分类阶段只使用了基本的 k 近邻分类器。为了便于比较,实验中小波、Contourlet 和 WBCT 均分解 3 层;Contourlet 和 WBCT 的分解方向数相同,由粗尺度到细尺度分别为 4、4、8; k 近邻分类器选 $k=3$ 。

实验一:基于能量测度的 Brodatz 纹理图像分类

本实验用来测试基于 WBCT 的能量测度对纹理分类的性能,其中能量

测度采用式(6.53)中所定义的 l^1 范数能量测度提取子带特征。实验结果如表 10.14 所示,可以看出基于 WBCT 能量测度的方法可以有效地提取图像中的纹理特征。

- Step 1 生成初始种群: 随机产生 N_p (种群规模)种特征组合作为初始抗体群体, 每个抗体表示一种特征组合, 采用二进制编码方式, 基因串长为特征向量长度减 1, 因为不包括低频信息。基因位为 1 表示相应的特征分量被选中, 为 0 表示相应的特征分量未被选中。
- Step 2 计算亲合度: 将每个抗体解码为对应的特征组合, 得到新的训练样本集, 用训练样本正确分类概率作为其亲合度。
- Step 3 克隆死亡: 将亲合度小的一部分抗体死亡, 取而代之的是亲合度大的抗体。
- Step 4 判断是否满足迭代终止条件: 如迭代次数已到达规定值, 则终止迭代, 当前种群中的最佳抗体作为克隆选择算法的最终解, 若不满足终止条件, 则继续。
- Step 5 克隆操作: 对当前的父代种群进行克隆, 克隆规模为 N_c 。
- Step 6 变异: 对克隆后的抗体以变异概率 p_m 进行变异操作。
- Step 7 计算亲合度: 将当前种群中的各个抗体解码为对应的特征组合, 计算每个抗体的亲合度。
- Step 8 克隆选择: 在变异后的抗体中如果亲合度最大的抗体其亲合度大于其父代亲合度, 则选择该抗体进入新的父代群体。
- Step 9 迭代次数加 1, 返回 Step2。

图 10.59 基于克隆选择的特征选择算法

表 10.14 基于 l_1 范数能量测度的 Brodatz 纹理图像分类结果比较

方 法	识别率/(%)
Wavelet	91.71
Brushlet	92.99
Contourlet	93.76
WBCT	94.53

实验二：基于特征降维的 Brodatz 纹理图像分类

本实验用来测试基于子带系数重排算法和基于克隆选择的特征选择算法这两种降低特征维数方法的性能。首先由 WBCT 能量测度得到的 49 维特征分别用子带系数重排的方法和基于克隆选择的特征选择方法获得新的分类特征, 再用 k 近邻分类器进行识别。

为了和文献[101]中的克隆选择方法进行比较, 本实验的特征选择参数

与文献[101]中相同,种群规模为 10,克隆规模为 5,变异概率 $p_m=1/d$, d 为特征选择前的特征维数,终止条件为最大进化代数 20 代,多次运行结果求平均值。表 10.15 给出了平均分类精度。

表 10.15 降维后的 Brodatz 纹理图像分类结果比较

项 目	维 数	平均识别率/(%)	特征选择时间/s
不降维	49	94.53	—
系数重排	37	93.93	—
巴氏距离	20.8	90.51	2961.8
本节方法	29.8	94.72	2658.7

由表 10.15 可以看出,基于克隆选择算法的特征选择较子带系数重排的方法可以更好地降低特征维数,但是基于 Bhattacharyya 距离的特征选择方法和系数重排的方法,它们的平均识别率均低于不降维时的识别率,而本节的基于训练样本正确分类概率的克隆选择方法可以得到高于不降维时的识别率,且特征选择所需的时间也远小于基于 Bhattacharyya 距离的克隆选择算法所需的时间。

实验三:基于特征选择的 Brodatz 纹理图像分类

本实验对 WBCT 分解得到的子带提取方差和 Hu 矩特征。分类结果如表 10.16 所示,可以看出在分类精度方面,能量测度的方法得到了较好的结果。

表 10.16 提取 WBCT 子带不同特征的分类结果比较

项 目	维 数	识别率/(%)
能量	49	94.53
方差	49	94.10
Hu 矩	343	93.76

表 10.17 给出了提取 WBCT 分解子带不同特征时的每类纹理错分样本个数,可以看出不同的特征提取方法对不同的纹理有效。例如,对于 D86 和 D109,基于能量测度的方法可以正确识别全部样本,而基于标准差和 Hu 矩的方法都有一定数量的错分;对于 D29、D75 和 D107,标准差是较适合的方法,尽管 Hu 矩的平均分类精度较低;但是对于 D19 和 D111,只有 Hu 矩方法可以正确识别全部样本。由此可得,结合不同的特征可以提高分类精度,但是通常所得的特征维数较大且存在冗余,因此有必要对其进行冗余信息的剔除。实验结果如表 10.18 和表 10.19 所示。

表 10.17 提取 WBCT 分解子带不同特征的每类错样本数

类别	能量	Std	Hu	类别	能量	Std	Hu	类别	能量	Std	Hu
D1	0	0	0	D32	0	0	2	D71	0	0	0
D2	2	2	2	D33	0	0	0	D72	5	5	10
D3	0	0	0	D34	0	0	0	D73	7	5	9
D4	0	0	0	D35	0	0	0	D74	2	0	0
D6	0	0	0	D37	0	0	0	D75	4	0	4
D8	0	0	0	D39	7	5	2	D76	0	0	0
D9	0	0	0	D41	2	5	4	D77	0	0	0
D10	0	0	0	D46	0	0	0	D78	0	0	0
D11	0	0	0	D47	0	0	0	D81	0	0	0
D12	2	2	2	D48	0	0	0	D82	0	0	0
D14	0	0	0	D49	0	0	0	D83	0	0	0
D15	2	2	0	D50	0	0	2	D84	0	0	0
D16	0	0	0	D51	0	0	0	D85	0	0	0
D17	0	0	0	D52	0	0	0	D86	0	2	2
D18	0	0	0	D53	0	0	0	D87	0	0	0
D19	2	2	0	D55	0	0	0	D92	0	0	0
D20	0	0	0	D56	0	0	0	D93	2	2	2
D21	0	0	0	D57	0	0	0	D95	0	0	0
D22	0	0	0	D60	1	1	1	D101	0	6	0
D23	4	2	2	D62	0	0	1	D102	0	5	0
D24	0	0	0	D64	0	0	0	D104	0	0	0
D25	0	0	0	D65	0	0	0	D105	0	0	0
D26	0	0	0	D66	0	5	0	D107	5	0	7
D27	11	8	7	D67	2	2	2	D109	0	7	4
D28	0	0	0	D68	0	0	0	D111	2	1	0
D29	2	0	4	D70	0	0	4	D112	0	0	0

表 10.18 融合能量和方差特征后特征选择的分类结果比较

项 目	维数	平均识别率/(%)	特征选择时间/s
能量+方差	98	95.64	—
巴氏距离	46.5	94.02	8507.5
本节方法	50.4	96.43	3055.5

表 10.19 融合能量、方差和 Hu 矩特征后特征选择的分类结果比较

项 目	维数	平均识别率/(%)	特征选择时间/s
能量+方差+Hu	441	95.90	—
巴氏距离	218.3	95.96	158 543.2
本节方法	218.5	96.58	14 108.6

由表 10.17~表 10.19 可以看出,融合不同方法提取的特征后,识别率有了一定的提高,但是特征维数较大,应用了基于克隆选择算法的特征选择后,特征维数得到了有效的降低,识别率也有了一定的提高。尽管基于巴氏距离的方法得到了更低维数的特征,但是它的分类精度低于或只能略高于不进行降维时的精度,且特征选择耗时较长。而本节方法可以在一个较低的特征维数下获得更高的分类精度。由此可见,特征选择的必要性即对于分类来说,并不是特征越多越好。

10.6.4 基于 SWBCT 的纹理图像分类

Contourlet 在每一尺度上都可以分解为任意 2 的 N 次幂个方向,同时它还具有多尺度、各向异性等多尺度几何分析的优良特性。WBCT 采用正交小波和方向滤波器组,可以进一步挖掘图像的方向信息,但是正交小波使用的临界采样方式引起了频谱混叠,从而导致 WBCT 随着分解方向数和分解层数增多时,会出现识别率快速下降的现象,这一点 M. N. Do 和 M. Vetterli 也曾在文献[1]中提及过。本节提出了一种基于平稳小波的 Contourlet 变换,它保持了 Contourlet 的诸多优点,且其子带划分比 Contourlet 更细,本节将其应用于纹理图像分类,取得了优于小波和 Contourlet 的效果。

1. SWBCT 的实现

冗余信息在图像处理中有十分重要的作用,如边缘检测、去噪、图像重建等。因此我们通过引入具有高冗余的平稳小波变换来克服 WBCT 在图像分析中遇到的问题。基于平稳小波和方向滤波器组各自的优点,将平稳小波变换与方向滤波器组结合,提出了类似 Contourlet 双滤波器组的迭代结构的多尺度几何变换——基于平稳小波的 Contourlet 变换(Stationary Wavelet-

Based Contourlet Transform, SWBCT)。DFB 是一个严格的采样滤波器组，可以把图像分解到 2 的任意幂次个方向。由于 DFB 能够捕获图像中的高频信息，但是对低频信息的处理能力较差，因此在应用之前，需要将其与多分辨率分析相结合。平稳小波分解和 DFB 都具有完全重构特性，所以由其结合而成的 SWBCT 也满足完全重构特性。SWBCT 保持了 Contourlet 的主要特性：多方向、多尺度、各向异性。

SWBCT 算法的主要步骤如下：首先对图像进行平稳小波变换，然后对得到的 LH、HL、HH 三个高频子带分别用 DFB 分解为 2^n 个方向子带，再对低频子带重复上面的步骤，直到满足分解层数为止。SWBCT 的分解结构如图 10.60 所示。与小波和 Contourlet 相比，SWBCT 可以进一步挖掘纹理特征。




图 10.60 SWBCT 分解示意图

由于平稳小波分解的冗余性，对图像进行平稳小波变换后得到的各个高频子带大小和原图相同，当使用 DFB 对其各高频子带进行方向细分的时候，不会出现分解子带随分解层数增多而变小的情况，因此它可以克服小波、脊波、Brushlet、WBCT 等变换在分解层数较大时性能快速下降的问题，并能够得到更高的识别率。后续实验结果也证明了基于 SWBCT 的方法可以更好地表征纹理信息。

SWBCT 在保留了 Contourlet 的几乎所有优点的同时，克服了 WBCT 的缺点，但是由于 SWBCT 引入了平稳小波变换，因此代价是具有和平稳小波变换一样的冗余度。

2. 基于 SWBCT 的纹理特征提取

本实验中，在子带特征提取阶段分别使用了能量测度、Hu 不变矩和系数共生矩阵的方法，并对这三种方法进行了实验比较。

图像的分解子带所携带的能量信息可以很好地描述子带特征，并且较其他的子带系数统计特征更加稳定。本节采用式(6.53)中所定义的 l_1 范数能量测度提取 SWBCT 的分解子带特征，即计算 SWBCT 分解得到的每个尺度上每个高频子带的能量测度和最粗尺度上的低频能量测度，特征维数等于分解得到的子带个数。不变矩具有位移、尺度、旋转不变性的特征，本节采用文献[113]提出的 7 个 Hu 不变矩。由该方法得到的特征维数等于子带个数 $\times$ 7。实验中还使用基于系数共生矩阵的纹理特征进行对比实验，首先对纹理图像分别进行小波、平稳小波、Brushlet、Contourlet、WBCT、SWBCT 变换，之后应用系数共生矩阵的方法分别求得各分解子带的角二阶矩、熵、对比度和相关性作为纹理特征值，参见式(6.49)~式(6.52)，然后由最近邻分类器进行分类，利用该方法得到的特征维数等于子带个数 $\times$ 4。

完整纹理分类过程如图 10.61 所示。分解后的特征提取部分分别使用了上述三种方法进行比较实验。实验中所用的分类器均为 k 近邻分类器。为了和我们提出的 SWBCT 作比较，对比实验中还使用了小波、平稳小波、Contourlet、WBCT 和 Brushlet 等方法，由此来说明 SWBCT 在纹理分析方面的优越性。




图 10.61 纹理分类过程

3. 实验结果与分析

实验一：基于 SWBCT 能量测度的 Brodatz 纹理分类

本实验用来测试 SWBCT 的能量测度对纹理分类的性能，实验中用到的测试集和 10.6.3 节相同。实验中，随机选取每类中的 10 个作为训练样本，余下的 15 个作为测试样本，多次运行结果求平均值。Contourlet 分解 1 层

时，分解方向数为 4；分解 2 层时，方向数分别为 4、8；分解 3 层时，方向数分别为 4、4、8；分解 4 层时，方向数分别为 4、4、8、8；分解 5 层时，方向数分别为 4、4、8、8、16。WBCT 和 SWBCT 的方向选择与 Contourlet 相同。

本实验中提取的特征是各分解子带的 l_1 范数能量特征；k 近邻分类器的 k 分别取 1、3、5；各种分解方法均分别分解 1~5 层。实验结果如表 10.20~表 10.24 所示。

表 10.20 提取能量特征的识别率($L=1$)

l_1 范数能量特征	$k=1$	$k=3$	$k=5$
小波	0.8783	0.8051	0.7687
平稳小波	0.8814	0.8156	0.7786
Brushlet	0.5696	0.3875	0.3766
Contourlet	0.8730	0.8494	0.8342
WBCT	0.9033	0.8675	0.8554
SWBCT	0.9580	0.9248	0.9121

表 10.21 提取能量特征的识别率($L=2$)

l_1 范数能量特征	$k=1$	$k=3$	$k=5$
小波	0.9421	0.8925	0.8651
平稳小波	0.9415	0.9086	0.8863
Brushlet	0.8583	0.7810	0.7600
Contourlet	0.9523	0.9258	0.9074
WBCT	0.9568	0.9272	0.9050
SWBCT	0.9711	0.9470	0.9330

表 10.22 提取能量特征的识别率($L=3$)

l_1 范数能量特征	$k=1$	$k=3$	$k=5$
小波	0.9487	0.9221	0.9036
平稳小波	0.9650	0.9373	0.9265
Brushlet	0.9578	0.9359	0.9197
Contourlet	0.9612	0.9405	0.9284
WBCT	0.9585	0.9318	0.9205
SWBCT	0.9786	0.9588	0.9429

表 10.23 提取能量特征的识别率($L=4$)

l_1 范数能量特征	$k=1$	$k=3$	$k=5$
小波	0.9410	0.9058	0.8886
平稳小波	0.9728	0.9472	0.9398
Brushlet	0.9521	0.9368	0.9188
Contourlet	0.9651	0.9549	0.9491
WBCT	0.9468	0.9212	0.9168
SWBCT	0.9730	0.9564	0.9438

表 10.24 提取能量特征的识别率($L=5$)

l_1 范数能量特征	$k=1$	$k=3$	$k=5$
小波	0.9200	0.8850	0.8706
平稳小波	0.9610	0.9429	0.9325
Brushlet	0.9400	0.8945	0.8819
Contourlet	0.9720	0.9547	0.9463
WBCT	0.9038	0.8667	0.8605
SWBCT	0.9723	0.9499	0.9371

注：表中 L 表示分解层数。

由表 10.20~表 10.24 可以看出：只分解 1 层时，Brushlet 的效果较差，WBCT 与小波、平稳小波、Contourlet 相比较好，达到 90%，SWBCT 识别率最高，达到 95% 以上；分解 2 层时，Contourlet 和 WBCT 较好，而 SWBCT 识别率仍然最高，达到 97% 以上；分解 3 层时，小波、Brushlet、WBCT 和 SWBCT 都达到了各自识别率的最高点，Brushlet 较小波效果要好，和 WBCT 接近；分解 4 层时，WBCT 识别率下降较多，低于 Brushlet；分解 5 层时，WBCT 识别率降为最低，而 Contourlet 识别率较高，仅次于 SWBCT。由此可见，大部分分解方法都是在分解 3 层时识别率最高。

结果分析：WBCT 只分解 1 层时，其优势较小波、平稳小波、Brushlet 和 Contourlet 明显很多，原因是其方向划分比小波、平稳小波、Brushlet、Conoutlet 更细，而当分解层数大于 3 时，Contourlet 和平稳小波的优势越来越明显，原因在于它们是有冗余的变换，而小波、Brushlet、WBCT 是非冗余的变换；当分解层数增加时，WBCT 的各个子带划分过细，造成所得特征不稳定，所以层数的增加将导致 WBCT 的分类性能的下降；另一方面，虽然平稳小波、Contourlet 和 SWBCT 都是冗余的变换，但是 SWBCT 对方向的划分更细致，所以其分类精度较 Contourlet 和平稳小波更高。