

基于金字塔分解和扇形局部均值二值模式的鲁棒纹理分类方法

宋铁成 罗林* 张刚 罗忠涛 张天骐
(重庆邮电大学信号与信息处理重庆市重点实验室 重庆 400065)

摘要: 针对传统局部二值模式(LBP)的特征鉴别力有限和噪声敏感性问题, 该文提出一种基于金字塔分解和扇形局部均值二值模式的纹理特征提取方法。首先, 将原始图像进行金字塔分解, 得到对应于不同分解级别的低频和高频(差分)图像。为提取兼具鉴别力和稳健性的特征, 进一步采用阈值化处理技术将高频图像转化为正、负高频图。然后, 基于局部均值操作提出一种扇形局部均值二值模式(SLMBP), 用于计算各级分解图像的纹理特征码。最后, 对纹理特征码进行跨频带的联合编码和跨级别的直方图加权, 从而获得最终的纹理特征。在公开的3个纹理数据库(Outex, Brodatz 和 UIUC)上进行分类实验, 结果表明该文所提方法能够有效地提高纹理图像在无噪声环境和含高斯噪声环境下的分类精度。

关键词: 纹理分类; 特征提取; 局部二值模式; 金字塔分解

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2018)06-1301-08

DOI: 10.11999/JEIT170884

Robust Texture Classification Method Based on Pyramid Decomposition and Sectored Local Mean Binary Pattern

SONG Tiecheng LUO Lin ZHANG Gang LUO Zhongtao ZHANG Tianqi
(Chongqing Key Laboratory of Signal and Information Processing (CQKLS&IP), Chongqing University of Posts and Telecommunications (CQUPT), Chongqing 400065, China)

Abstract: The traditional Local Binary Pattern (LBP) has limited feature discrimination and is sensitive to the noise. In order to alleviate these problems, this paper proposes a method to extract texture features based on pyramid decomposition and sectored local mean binary pattern. First, the pyramid decomposition is performed on the original image to obtain low-frequency and high-frequency (difference) images with different decomposition levels. To extract robust yet discriminative features, thresholding technique is further used to transform the high-frequency images into positive and negative high-frequency images. Then, based on local averaging operations, Sectored Local Mean Binary Pattern (SLMBP) is proposed and used to compute texture feature codes at different decomposition levels. Finally, the texture features are obtained by joint coding across frequency bands and by histogram weighting across decomposition levels. Experiments on three publicly available texture databases (Outex, Brodatz and UIUC) demonstrate that the proposed method can effectively improve the classification accuracy of texture images both in noise-free conditions and in the presence of different levels of Gaussian noise.

Key words: Texture classification; Feature extraction; Local Binary Pattern (LBP); Pyramid decomposition

1 引言

纹理是自然界中物体外观所呈现的一种基本属性, 对纹理的感知是人类辨别不同物体、认识外部世界的重要方式。如何有效地提取对旋转、光照和尺度等变化具有鲁棒性的纹理特征, 一直是图像处

理、计算机视觉和模式识别领域研究的重要内容^[1-5]。近些年来, 随着信息技术的发展, 人们获取的图像不仅数量越来越多, 而且成像条件多种多样, 这对纹理分类和人脸识别等应用进一步提出了要求。以局部二值模式(LBP)^[6,7]为代表的方法, 因具有旋转和光照不变性、计算复杂度低、无需训练学习等优点而备受国内外研究学者关注。

LBP^[7]的基本思想是对中心像素和近邻采样点进行差分、量化和编码, 然后统计整幅图像关于像素编码值的频率直方图。由于采用少量的近邻像素进行差分编码, 传统的LBP对噪声非常敏感, 并且具有有限的特征鉴别力。为此, 学者们提出了一系

收稿日期: 2017-09-20; 改回日期: 2018-02-01; 网络出版: 2018-03-23

*通信作者: 罗林 529837487@qq.com

基金项目: 国家自然科学基金(61702065, 61671095), 信号与信息处理重庆市市级重点实验室建设项目(CSTC2009CA2003)

Foundation Items: The National Natural Science Foundation of China (61702065, 61671095), The Project of Key Laboratory of Signal and Information Processing of Chongqing (CSTC2009CA2003)

列改进型 LBP 算法。在提高 LBP 的特征鉴别力方面,文献[8]提出了完整的 LBP(CLBP),即对中心像素、局部近邻差分的符号和幅度进行联合编码。文献[9]借鉴 CLBP 的思想对局部差分幅度的均值和方差信息进行编码,进而构建了 FbLBP 特征。在提高 LBP 的抗噪性方面,文献[10]基于有向和无向差分模板提出了抗噪的局部对比度模式(LCP)。文献[11]采用错误纠正机制对不确定位重新编码,并将“线模式”作为一类特殊的均匀模式,从而提出了扩展的抗噪局部二值模式(ENRLBP)。文献[12]基于“量化前求平均”的思想设计了对噪声鲁棒的 BRINT 描述符。尽管上述方法取得了一定效果,但是还存在以下问题:受存储空间和特征维度的限制,LBP 的变体 CLBP 难以通过增大采样半径(通常设置 $r \leq 3$)来捕获纹理的宏结构信息;ENRLBP 编码的信息单一,具有有限的抗噪性;BRINT 强调平滑滤波,所采用的大采样半径配置(比如 $r = 7, 8, 9$)容易损失判别性的信息,而且联合编码后的特征维度偏高(多尺度 BRINT 的特征维度为 1296),不利于后续处理。因此,现有的纹理特征提取方法缺乏一种有效的、统一的机制来保证特征的鉴别力和充分的抗噪性。

针对上述问题,本文提出一种新颖的基于金字塔分解和扇形局部均值二值模式(SLMBP)的纹理特征提取方法。本文方法通过图像金字塔分解来挖掘纹理的内在结构信息(包括跨频带编码和跨级别直方图加权),借助于图像下采样提取纹理的宏结构信息,并利用阈值操作和局部均值操作提高特征的稳健性,从而构建了一种低维的具有良好鉴别力和抗噪性的纹理描述符,即金字塔-扇形局部均值二值模式(Pyramid SLMBP, P-SLMBP)。实验表明,P-SLMBP 不仅对旋转、光照和尺度等变化具有鲁棒性,而且在高斯噪声环境下也表现出优良的纹理分类性能。

本文结构安排如下。第 2 节详细介绍本文所提出的金字塔-扇形局部均值二值模式;第 3 节是实验,

介绍测试数据库与实验设置,对比和分析各种特征提取方法的分类性能;第 4 节总结全文。

2 金字塔-扇形局部均值二值模式(P-SLMBP)

图 1 给出了本文提出的 P-SLMBP 特征的构建框架,包括图像金字塔分解与阈值化处理、SLMBP 特征码计算、联合特征编码与直方图加权三大模块。各模块的具体内容介绍如下。

2.1 图像金字塔分解与阈值化处理

图像金字塔是进行多尺度图像分析的一种有效结构。通过金字塔分解,可以获得一系列以金字塔形式排列的分辨率逐步降低的图像(包括高斯金字塔图像和拉普拉斯金字塔图像)。正如前文所述,受存储空间和特征维度的限制,现有的 LBP 变体难以通过增大采样半径来捕获较大尺度上的纹理结构信息。然而对于金字塔分解的(尤其是经下采样处理的)图像,可以很容易地利用较小的采样半径提取纹理的宏结构特征,而且维持较低的特征维度。此外,文献[13]指出,图像中的低频噪声(粗粒度噪声)在初始的分解级别上难以识别和消除,但随着图像的进一步分解,这类噪声逐渐变得细小而容易被消除。因此,图像金字塔分解也在一定程度上有利于提取抗噪的纹理特征。受此启发,本文采用两级图像金字塔分解来提取纹理特征。图 2 显示了该过程得到的一系列分解图像。

高斯金字塔的构建过程如下。首先,将原始图像 I 经过高斯低通滤波器 f 后再进行下采样($\downarrow$),得到高斯金字塔上的第 1 级图像 G_1 ;然后,再对 G_1 进行上述操作,得到高斯金字塔上的第 2 级图像 G_2 。记 $G_0 = I$,则高斯金字塔的构建过程可表示为

$$G_{i+1} = (G_i \otimes f) \downarrow \quad (1)$$

拉普拉斯金字塔的构建过程如下。首先,将原始图像 I (即 G_0) 减去高斯金字塔构建过程中生成的低频图像 l_i (见图 2),得到拉普拉斯金字塔上的第 1 级高频图像 h_1 (差分图像);然后,再对 G_1 重复上述




图 1 本文提出的 P-SLMBP 特征的构建框架




图2 图像金字塔分解

操作, 得到拉普拉斯金字塔上的第2级高频图像 h_2 。拉普拉斯金字塔的构建过程可表示为

$$l_{i+1} = G_i \otimes f \quad (2)$$

$$h_{i+1} = G_i - l_{i+1} \quad (3)$$

由图2可见, 每个分解级别上的高频图像是由原始图像减去低频图像得到的, 因此包含许多类似于噪声的小能量值像素。为从高频图像中提取稳健且具有鉴别力的特征, 本文采用自适应阈值法将小能量值像素置零, 从而减小这类像素对后续特征编码带来的干扰:

$$t_i = \text{median}(h_i) \times \omega_i \quad (4)$$

$$\tilde{h}_i(x) = \begin{cases} h_i(x), & |h_i(x)| > t_i \\ 0, & \text{其它} \end{cases} \quad (5)$$

式中, i 为图像金字塔的第 i 个分解级别; $\text{median}(\bullet)$ 为矩阵中值函数; ω_i 是调节因子, 用于调节中值的大小; t_i 为自适应的阈值, 即根据高频图像 h_i 的中值大小实现自我调节; $h_i(x)$ 和 $\tilde{h}_i(x)$ 分别表示像素为 x 的阈值处理前、后的图像灰度值。经上述处理的高频差分图像包含正、负值两类像素, 反映了图像在线、边缘、角、亮点或者暗点等处的纹理结构变化(见图2)。为编码这些结构性的纹理信息, 本文将高频图像进一步分解为正高频图像和负高频图像, 分解后的正、负高频图像分开处理(二者均为非负

值)。由此得到对应于分解级别 i 上的低频图像 LF_i 、正高频图像 HF_i^+ 和负高频图像 HF_i^- 。它们的具体定义和操作为

$$LF_i(x) = l_i(x) \quad (6)$$

$$HF_i^+(x) = \begin{cases} \tilde{h}_i(x), & \tilde{h}_i(x) > 0 \\ 0, & \text{其它} \end{cases} \quad (7)$$

$$HF_i^-(x) = \begin{cases} -\tilde{h}_i(x), & \tilde{h}_i(x) < 0 \\ 0, & \text{其它} \end{cases} \quad (8)$$

2.2 SLMBP 特征码计算

原始 LBP 将中心像素和近邻采样点进行差分、量化和编码。图3(a)显示了 LBP 的近邻采样点, 其中 g_c 为中心像素, $g_{r,p}$ ($p = 0, 1, \dots, P-1$) 为均匀分布在以 g_c 为中心、 r 为半径的圆周上的内插像素点。典型的 LBP 配置为 $P = 8r$, 比如 $(r, P) = \{(1, 8), (2, 16), (3, 24)\}$, 以此保证最大非冗余采样和充分的旋转不变性。可以看到, LBP 依赖于少量像素的交互进行编码, 因而对噪声十分敏感; 此外, 当 $r > 3$ 时, LBP 对 P 个采样点的编码值建立查找表需要大量的存储空间^[7]。针对上述问题, 本文基于局部均值操作提出一种新的 LBP 算子, 命名为扇形局部均值二值模式(SLMBP)。

SLMBP 将中心像素的近邻采样点(包括 $r =$




图3 LBP 与 SLMBP 近邻采样及其抗噪性能对比

1,2,...,R 的圆周上所有的 $8r$ 个采样点, R 是最大的采样半径)划分成 8 个扇形区域, 然后对每个扇形区域内采样点的灰度值求均值; 对中心像素及其 8 个最近邻(即 $r=1$ 的圆周上的采样点)也进行求均值操作, 从而形成一组新的局部采样模式: 新的近邻采样点 $x_{R,p}$ ($p=0,1,\dots,7$) 和中心像素 x_c 。图 3(b)给出了 SLMBP 的近邻采样示意图, 该过程可表示为

$$x_{R,p} = \frac{1}{(1+R)R/2} [g_{1,p} + (g_{2,2p} + g_{2,2p+1}) + \dots + (g_{R,Rp} + g_{R,Rp+1} + \dots + g_{R,Rp+R-1})] \quad (9)$$

$$x_c = \frac{1}{9} (g_c + g_{1,0} + g_{1,1} + \dots + g_{1,7}) \quad (10)$$

SLMBP 对扇形区域和中心像素的近邻进行局部均值处理, 一方面利用平滑滤波提高了算法的抗噪性能, 另一方面将近邻点个数降低为 8, 既捕获了纹理的宏结构信息, 又减少了建立查找表所需的存储空间。如图 3(c)所示, 对于受到高斯噪声干扰的图像, 采用传统的 LBP 编码容易产生偏差, 而采用 SLMBP 编码则对噪声表现出鲁棒性。

为获得旋转不变的纹理特征码, 本文采用旋转不变性均匀模式^[7](即 *riu2*)编码每个中心像素, 即

$$\text{SLMBP}_R^{\text{riu2}} = \begin{cases} \sum_{p=0}^7 s(x_{R,p} - x_c), & U(\text{SLMBP}_R) \leq 2 \\ 9, & \text{其它} \end{cases} \quad (11)$$

$$U(\text{SLMBP}_R) = |s(x_{R,7} - x_c) - s(x_{R,0} - x_c)| + \sum_{p=1}^7 |s(x_{R,p} - x_c) - s(x_{R,p-1} - x_c)| \quad (12)$$

其中, $s(x)$ 是符号函数, 定义为

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (13)$$

将上述 $\text{SLMBP}_R^{\text{riu2}}$ 算子作用于金字塔分解的各级图像上, 得到对应于不同分解级别的 SLMBP 编码图, 包括低频编码图 $\text{LF-SLMBP}_{i,R}$ 、正高频编码图 $\text{HF-SLMBP}_{i,R}^+$ 和负高频编码图 $\text{HF-SLMBP}_{i,R}^-$ 。这里, i ($i=1,2$) 表示分解级别, 每种编码图有 10 种编码值(0~9)。

2.3 联合特征编码与直方图加权

对反映像素不同特性的信息进行联合编码能够提高特征的鉴别力^[4,8]。为全面有效地捕获和描述纹理的内在结构信息, 本文对同一分解级别上的高低频图像进行跨频带联合编码, 进而在每一级别上分别建立低频与正高频、低频与负高频的联合直方图。首先, 对像素 x 进行跨频带联合编码:

$$C_i^{h+}(x) = \text{LF-SLMBP}_{i,R}(x) \times 10 + \text{HF-SLMBP}_{i,R}^+(x) \quad (14)$$

$$C_i^{h-}(x) = \text{LF-SLMBP}_{i,R}(x) \times 10 + \text{HF-SLMBP}_{i,R}^-(x) \quad (15)$$

其中, $C_i^{h+}(x)$ 和 $C_i^{h-}(x)$ 的取值范围均为 0~99。然后, 在每级分解的图像上建立两个联合特征直方图:

$$H_i^{h+}(y) = \sum_x \delta(C_i^{h+}(x) == y) \quad (16)$$

$$H_i^{h-}(y) = \sum_x \delta(C_i^{h-}(x) == y) \quad (17)$$

$$\delta(z) = \begin{cases} 1, & z \text{ 为真} \\ 0, & \text{其它} \end{cases} \quad (18)$$

式中, y ($y=0,1,\dots,99$) 为直方图 H_i^{h+} 和 H_i^{h-} 的索引。最后, 将同一分解级别上的联合特征直方图级联, 得到 $H_1 = [H_1^{h+} \ H_1^{h-}]$ 和 $H_2 = [H_2^{h+} \ H_2^{h-}]$ 。

不同分解级别的图像反映了不同分辨率下的纹理信息, 它们对刻画图像内容和纹理分类具有不同的重要性。然而下一级分解图像的尺寸远低于上一级图像, 直接级联各级图像的直方图不利于反映图像特征之间的真实距离。为减小图像尺寸带来的影响, 本文采用跨分解级别的直方图加权, 即

$$H = [\alpha H_1 \ (1-\alpha) H_2] \quad (19)$$

式中, α 为直方图权重 ($0 \leq \alpha \leq 1$)。本文最终构造的纹理特征直方图 H 的维度为 400。

3 实验

本节综合评估本文所提出的 P-SLMBP 特征在无噪声和有噪声环境下的纹理分类性能。实验采用公开的 Outex^[7], Brodatz^[12] 和 UIUC^[14] 3 个纹理数据库, 对比方法包括局部二值模式(LBP)^[7]、完整的局部二值模式(CLB)^[8]、局部对比度模式(LCP)^[10]、扩展的抗噪局部二值模式(ENRLBP)^[11]、二值旋转不变和噪声容忍纹理特征(BRINT)^[12]、完整鲁棒的局部二值模式(CRLBP)^[14]、完整的局部二值计数(CLBC)^[15]、局部三值模式(LTP)^[16]、基于能量特征的局部剪切变换模式(LSEP)^[17]、主导近邻结构和局部二值模式(DNS+LBP)^[18]、基于熵特征的局部三值模式(LTP_ENT)^[19]。实验采用最近邻分类器和 χ^2 距离进行纹理分类^[7,8,10]。本文利用公开的实现 LBP, LTP, CLB, CLBC, ENRLBP 和 LCP(其中, 前 4 种方法设置 $R=3$, ENRLBP 设置 $R=2$, LCP 设置 $R=5$), 其它方法的结果均取自原文献。

3.1 数据库与实验设置

Outex 数据库有 24 类纹理图像, 每类有 20 个纹理样本, 分别成像于 3 种不同的光照条件(“inca”, “t184”和“horizon”)和 9 种不同的旋转角度($0^\circ, 5^\circ, 10^\circ, 15^\circ, 30^\circ, 45^\circ, 60^\circ, 75^\circ$ 和 90°)。实验选取 TC10、TC12_000 和 TC12_001 3 个常用的子库进行实验, TC10 子库用于测试图像的旋转变换, TC12_000

和 TC12_001 子库用于同时测试图像的旋转和光照变换。Brodatz 数据库有 24 种纹理类别。每幅图像被划分成 25 个大小为 128×128 的非重叠的子图。随机选择每类纹理中的 13 个样本用于训练, 其余 12 个样本用于测试。UIUC 数据库有 25 类纹理, 每类有 40 幅大小为 640×480 的图像。这些图像间存在着明显的视角和尺度变化。随机选取每类中的 20 个样本作为训练集, 其余作为测试集。由于 Brodatz 和 UIUC 数据库没有固定划分的训练集和测试集, 我们进行 50 次分类实验, 然后计算平均的分类精度。实验所加噪声均为加性高斯白噪声, 噪声级别用信噪比(Signal-to-Noise Ratio, SNR)表示。实验所加 SNRs 分别为 100, 30, 15, 10 和 5(对应 20 dB, 14.78 dB, 11.76 dB, 10 dB 和 7 dB)。

本文方法的具体参数设置如下:

(1)金字塔分解与阈值化处理: 金字塔分解级别设置为 2, 两级调节因子设置为 $\omega_1 = 0.2$ 和 $\omega_2 = 0.5$ 。

(2)SLMBP 特征码计算: 第 1 级分解图像采用 $SLMBP_{R=3}^{riu2}$, 第 2 级分解图像采用 $SLMBP_{R=4}^{riu2}$ 。

(3)联合特征编码与直方图加权: 直方图权重 $\alpha = 0.4$ 。

3.2 参数评估

本节评估本文方法中涉及的几个重要参数: 金字塔分解级别、采样半径、式(4)中的调节因子 ω_i 和式(19)中的直方图权重 α 。不同金字塔分解级别的图像包含不同尺度的纹理结构信息。随着分解级别的增加, 本文方法总体上能够进一步提高纹理分类的精度, 但是特征维度也随之增加。综合考虑分类精度和特征维度等因素, 本文设置金字塔的分解级别为 2。本文方法对扇形区域内的采样点求取均值, 获得旋转不变的对噪声鲁棒的采样结构。由于较小的采样半径使得算法对噪声比较敏感, 而较大的

采样半径使得算法的计算复杂度增加, 本文实验性地设置第 1 级和第 2 级的采样半径 R 分别为 3 和 4。此外, 本文对 3 个数据库进行综合实验来确定调节因子 ω_i 的取值。图 4(a)和图 4(b)显示了在 TC10 子库上两级调节因子 ω_1 和 ω_2 对纹理分类精度的影响。当 $\omega_1 = 0.2$ 和 $\omega_2 = 0.5$ 时, 本文方法的分类精度普遍高于其它参数下的分类结果。图 4(c)显示了在 TC10, Brodatz 和 UIUC 3 个纹理库上不同的直方图权重对分类精度的影响。可以看到, 当设置 $\alpha = 0.4$ 时, 本文方法在 3 个数据库上一致性地获得最高的分类精度; 当设置 $\alpha = 0$ 和 $\alpha = 1.0$ 时(即在单个分解级别上提取图像特征), 本文方法的分类精度呈现不同程度的下降; 对于 UIUC 数据库, 在低信噪比 SNR=5 时, 设置 $\alpha = 0.4$ 明显优于其他权重。这表明在不同分解级别上所提取的图像特征在纹理分类中具有不同的重要性, 赋予它们合适的权重有利于提高特征的健壮性。

3.3 分类性能评估

3.3.1 在 Outex 数据库上的分类结果 表 1, 表 2 和表 3 分别对比了不同方法在 TC10, TC12_000 和 TC12_001 3 个子库上的分类精度。从上述 3 个表中可以看出, 在有噪声和无噪声环境下, 本文方法的分类精度都明显高于 LBP 及其变体 LTP, CLBP 和 CLBC。随着信噪比的进一步降低, 这种优势表现得更为突出。与抗噪描述符 ENRLBP, LTP_ENT 和 LCP 相比, 本文方法在较高的信噪比下 (SNR>5 dB) 也获得了最佳的分类性能。这表明本文方法对图像的旋转、光照和噪声变化都具有鲁棒性。此外, 当 SNR=10 和 5 时, 高维度 BRINT(1296 维)的分类性能优于本文方法(400 维)。综上分析, LBP 利用少量的近邻像素进行差分编码, 其结果易受噪声的影响; CLBP 和 CLBC 对符号、幅度和中心像素 3 种信息进行联合编码,




图 4 参数设置对本文方法分类精度的影响

表 1 不同分类方法在 TC10 子库上的分类精度(%)

	无噪声	SNR				
		100	30	15	10	5
本文方法	99.92	99.53	98.88	96.73	92.53	73.16
LBP	95.08	91.46	74.27	52.24	35.62	16.33
CLBP	99.14	96.90	87.94	66.95	47.50	20.57
CLBC	98.96	95.50	88.15	77.19	64.43	37.13
LTP	98.20	99.45	98.31	93.44	84.32	57.37
LCP	98.65	98.10	96.90	94.30	91.64	80.10
ENRLBP	93.31	87.40	85.73	80.16	72.42	51.02
BRINT	99.35	97.76	96.48	95.47	92.97	89.24
LSEP	97.52	—	90.26	82.05	—	50.00
LTP_ENT	98.36	—	—	—	88.75	53.78

表 2 不同分类方法在 TC12_000 子库上的分类精度(%)

	无噪声	SNR				
		100	30	15	10	5
本文方法	99.88	97.96	96.97	93.87	88.59	71.09
LBP	85.04	87.36	69.26	47.87	34.05	16.25
CLBP	95.32	93.31	82.59	63.40	45.76	21.39
CLBC	94.00	88.19	80.93	69.65	57.85	31.78
LTP	93.59	91.78	75.72	53.61	38.03	20.05
LCP	96.18	95.69	92.59	89.21	84.65	74.00
ENRLBP	86.13	84.49	81.16	77.52	70.16	50.88
BRINT	97.69	95.95	93.59	91.32	90.49	83.68
LTP_ENT	93.52	—	—	—	74.98	48.52

表 3 不同分类方法在 TC12_001 子库上的分类精度(%)

	无噪声	SNR				
		100	30	15	10	5
本文方法	99.70	97.94	97.15	94.50	89.96	71.93
LBP	80.78	86.41	67.64	47.06	34.51	17.18
CLBP	94.53	94.72	84.375	64.51	45.00	20.67
CLBC	93.24	88.68	82.36	72.48	59.98	34.07
LTP	89.42	90.86	76.39	55.02	39.54	19.24
LCP	97.34	96.85	93.50	90.07	86.57	75.07
ENRLBP	87.38	85.76	82.69	77.38	69.68	49.07
BRINT	98.56	96.92	95.14	93.66	92.29	84.77
LTP_ENT	93.15	—	—	—	79.95	51.00

在一定程度上提升了特征的鉴别力，但对噪声仍然较为敏感。LTP 利用三值量化提升了抗噪性能，但是未能捕获具有充分鉴别力的特征。BRINT 所采用的大采样半径和求均值操作具有良好的抗噪性能，但该算法强调平滑作用，在高信噪比和无噪环境下的分类精度有待进一步提高。本文方法所采用的阈值化处理和局部均值操作对噪声具有鲁棒性；同时利用金字塔分解捕获了不同尺度下的结构信息，并

通过跨频带编码进一步提升了特征的鉴别力，从而极大地提高了在有噪和无噪环境下的纹理分类性能。

3.3.2 在 Brodatz 数据库上的分类结果 表 4 对比了不同方法在 Brodatz 数据库上的分类结果。从表 4 中可以看到，在无噪声条件和给定的 SNR 条件下，本文方法具有最佳的分类结果，而且在无噪声和 SNR=100 时，本文方法实现了精度为 100%

表4 不同分类方法在 Brodatz 数据库上的分类精度(%)

	无噪声	SNR				
		100	30	15	10	5
本文方法	100.00	100.00	99.98	99.94	99.77	99.54
LBP	99.68	99.20	98.56	96.63	96.31	91.67
CLBP	99.84	99.52	99.52	99.52	99.36	96.79
CLBC	97.40	99.10	99.04	98.94	98.30	95.13
LTP	99.84	99.52	99.20	98.72	97.60	95.83
LCP	100.00	99.98	99.70	99.52	99.41	99.20
ENRLBP	100.00	99.97	99.74	99.70	99.53	98.44
BRINT	100.00	98.60	97.68	96.55	94.50	89.65
LSEP	98.29	—	99.84	99.81	—	98.95
CRLBP	99.78	99.29	98.68	97.44	96.81	92.66
DNS+LBP	100.00	99.90	99.86	99.86	99.58	99.45

的完美分类。对于抗噪的图像描述符, DNS+LBP 基于局部图像块之间的相似度计算抗噪的 DNS 特征, LSEP 通过 Shearlet 变换和均值操作提取多尺度的局部能量特征, 这两种抗噪方法对空域结构的描述能力较为欠缺。本文方法则基于 LBP 算子和局部均值操作充分提取了纹理的空域结构信息, 从而获得一种更为有效和鲁棒的纹理特征表达。BRINT 在此数据库的分类性能不具有明显优势, 特别是在 SNR=5 时其分类精度比本文方法低出大约 10%。这表明本文方法中金字塔分解与基于均值操作的 SLMBP 算子能够有效提升特征的鉴别力和抗噪性。

3.3.3 在 UIUC 数据库上的分类结果 如表 5 所示, 在无噪声条件下, 各对比方法的分类性能远低于在此前各数据库中报道的结果, 这表明 LBP, CLBP, CLBC 等方法在 UIUC 数据库上受视角和尺度变化的影响较大。在这种条件下, 本文方法在该库上依然实现了最高的分类准确率 95.2%。表明本文方法对图像的视角和尺度变化具有较高的鲁棒性。对比在不同信噪比下其他方法的分类性能, 本

文方法表现最佳, 其次是 CRLBP, LCP 和 LTP_NET。在 SNR=5 时, 本文方法的分类精度比 CRLBP 和 LCP 高出 10.5%。在上述方法中, CRLBP, LCP 和 LTP_NET 仅提取单一尺度下的纹理特征, 并且忽视了不同尺度之间的相关信息表达。本文方法采用多级金字塔分解在一定程度上减少了尺度变化带来的影响, 采用扇形局部均值操作则进一步减小了视角变化和噪声的影响, 因而在 UIUC 数据库上表现出良好的分类性能。

4 结束语

为提高传统 LBP 的特征鉴别力和抗噪性, 本文提出一种基于金字塔分解和扇形局部均值二值模式(SLMBP)的纹理特征提取方法。该方法利用金字塔分解计算对应于不同分解级别的高低频图像, 并运用自适应阈值方法将高频图像转化为正、负高频图像; 然后利用提出的 SLMBP 算子对分解的图像进行二值编码; 最后进行跨频带的联合特征编码和跨分解级别的直方图加权, 从而获得图像的纹理特征。实验表明, 该方法不仅对无噪声环境下的纹

表5 不同分类方法在 UIUC 数据库上的分类精度(%)

	无噪声	SNR				
		100	30	15	10	5
本文方法	95.20	95.00	94.80	92.80	90.40	89.70
LBP	65.20	78.90	74.80	69.30	65.40	55.80
CLBP	91.19	90.20	86.40	81.10	80.80	74.60
CLBC	91.39	89.20	84.86	81.80	79.00	72.86
LTP	83.00	81.00	81.80	77.80	72.00	67.10
LCP	90.50	89.20	85.40	83.80	82.20	79.40
ENRLBP	63.59	62.42	62.05	60.07	58.96	55.46
CRLBP	93.31	93.49	93.08	92.74	88.57	79.20
LTP_ENT	92.44	—	—	—	83.18	75.87

理分类(包括旋转、光照和尺度变化等)具有优良的性能,而且对不同级别高斯噪声下的纹理分类也表现出很强的鲁棒性。

参 考 文 献

- [1] 文登伟, 张东波, 汤红忠, 等. 融合纹理与形状特征的 HEp-2 细胞分类[J]. 电子与信息学报, 2017, 39(7): 1599–1605. doi: 10.11999/JEIT161090.
WEN Dengwei, ZHANG Dongbo, TANG Hongzhong, et al. HEp-2 cell classification by fusing texture and shape features [J]. *Journal of Electronics & Information Technology*, 2017, 39(7): 1599–1605. doi: 10.11999/JEIT161090.
- [2] AL-SAHAF H, AL-SAHAF A, XUE B, et al. Automatically evolving rotation-invariant texture image descriptors by genetic programming[J]. *IEEE Transactions on Evolutionary Computation*, 2017, 21(1): 83–101. doi: 10.1109/TEVC.2016.2577548.
- [3] JIA S, HU J, ZHU J S, et al. Three-dimensional local binary patterns for hyperspectral imagery classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(4): 2399–2413. doi: 10.1109/TGRS.2016.2642951.
- [4] SONG T C, LI H L, MENG F M, et al. Exploring space-frequency co-occurrences via local quantized patterns for texture representation[J]. *Pattern Recognition*, 2015, 48(8): 2621–2632. doi: 10.1016/j.patcog.2015.03.003.
- [5] WANG H, SANG M Y, HAN D K, et al. A feature descriptor based on the local patch clustering distribution for illumination-robust image matching[J]. *Pattern Recognition Letters*, 2017, 94: 46–54. doi: 10.1016/j.patrec.2017.05.010.
- [6] LIU L, FIEGUTH P W, GUO Y L, et al. Local binary features for texture classification: Taxonomy and experimental study[J]. *Pattern Recognition*, 2017, 62: 135–160. doi: 10.1016/j.patcog.2016.08.032.
- [7] OJALA T, PIETIKÄINEN M, and MÄENPÄÄ T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 24(7): 971–987. doi: 10.1109/TPAMI.2002.1017623.
- [8] GUO Z H and ZHANG L. A completed modeling of local binary pattern operator for texture classification[J]. *IEEE Transactions on Image Processing*, 2010, 19(6): 1657–1663. doi: 10.1109/TIP.2010.2044957.
- [9] PAN Z B, LI Z Y, FAN H C, et al. Feature based local binary pattern for rotation invariant texture classification[J]. *Expert Systems with Applications*, 2017, 88(12): 238–248. doi: 10.1016/j.eswa.2017.07.007.
- [10] SONG T C, LI H L, MENG F M, et al. Noise-robust texture description using local contrast patterns via global measures[J]. *IEEE Signal Processing Letters*, 2014, 21(1): 93–96. doi: 10.1109/LSP.2013.2293335.
- [11] REN J F, JIANG X D, and YUAN J S. Noise-resistant local binary pattern with an embedded error-correction mechanism [J]. *IEEE Transactions on Image Processing*, 2013, 22(10): 4049–4060. doi: 10.1109/TIP.2013.2268976.
- [12] LIU L, LONG Y, FIEGUTH P W, et al. BRINT: Binary rotation invariant and noise tolerant texture classification[J]. *IEEE Transactions on Image Processing*, 2014, 23(7): 3071–3084. doi: 10.1109/TIP.2014.2325777.
- [13] ZHANG M and GUNTURK B K. Multiresolution bilateral filtering for image denoising[J]. *IEEE Transactions on Image Processing*, 2008, 17(12): 2324–2333. doi: 10.1109/TIP.2008.2006658.
- [14] ZHAO Y, JIA W, HU R X, et al. Completed robust local binary pattern for texture classification[J]. *Neurocomputing*, 2013, 106(4): 68–76. doi: 10.1016/j.neucom.2012.10.017.
- [15] ZHAO Y, HUANG D S, and JIA W. Completed local binary count for rotation invariant texture classification[J]. *IEEE Transactions on Image Processing*, 2012, 21(10): 4492–4497. doi: 10.1109/TIP.2012.2204271.
- [16] TAN X Y and TRIGGS B. Enhanced local texture feature sets for face recognition under difficult lighting conditions[J]. *IEEE Transactions on Image Processing*, 2010, 19(6): 1635–1650. doi: 10.1109/TIP.2010.2042645.
- [17] HE J, JI H, and YANG X. Rotation invariant texture descriptor using local shearlet-based energy histograms[J]. *IEEE Signal Processing Letters*, 2013, 20(9): 905–908. doi: 10.1109/LSP.2013.2267730.
- [18] KHELLAH F M. Texture classification using dominant neighborhood structure[J]. *IEEE Transactions on Image Processing*, 2011, 20(11): 3270–3279. doi: 10.1109/TIP.2011.2143422.
- [19] SHAKOOR M H and TAJERIPOUR F. Noise robust and rotation invariant entropy features for texture classification [J]. *Multimedia Tools and Applications*, 2017, 76(6): 8031–8066. doi: 10.1007/s11042-016-3455-6.

宋铁成: 男, 1984 年生, 博士, 讲师, 研究方向为图像处理、计算机视觉和模式识别。

罗 林: 男, 1992 年生, 硕士生, 研究方向为图像的特征提取和分类。

张 刚: 男, 1976 年生, 博士, 副教授, 研究方向为混沌通信和微弱信号检测。

罗忠涛: 男, 1984 年生, 博士, 讲师, 研究方向为通信、雷达和图像信号处理。

张天骐: 男, 1971 年生, 博士后, 教授, 研究方向为通信信号的调制解调、盲信号处理和多媒体信息处理。