

## 结合微分特征和 Haar 小波分解的鲁棒纹理表达

刘望华, 刘光帅\*, 陈晓文, 李旭瑞

(西南交通大学 机械工程学院, 成都 610031)

(\* 通信作者电子邮箱 motorliu7810@swjtu.edu.cn)

**摘要:**针对传统的局部二值模式算子缺乏像素间深层次的相关性信息,且对图像中常见的模糊及旋转变化的鲁棒性较差的问题,提出了一种结合微分特征和 Haar 小波分解的鲁棒纹理表达算子。在微分特征通道上,通过各向同性的微分算子提取图像中的一阶和二阶微分特征,使图像的微分特征在本质上具有旋转不变性且对图像模糊具有较强的鲁棒性;基于小波变换在时域和频域同时具有良好的局部化的特点,在小波分解特征提取通道上采用多尺度的二维 Haar 小波分解提取图像中的模糊鲁棒特征;最后,串联两个通道上的特征直方图来描述图像的纹理特征。在特征判别性实验中,该算子在较复杂的 UMD、UIUC 和 KTH-TIPS 纹理库上的准确率分别达到了 98.86%、98.2% 和 99.05%,与中值稳健扩展局部二值模式(MRELBP)算子相比,准确率分别提高了 0.26%、1.32% 和 1.12%;在对旋转变化和图像模糊的鲁棒性分析实验中,该算子在仅存在旋转变化的 TC10 纹理库上的分类准确率达到 99.87%,在添加了不同程度高斯模糊的 TC11 纹理库上的分类准确率降幅仅为 6%;在计算复杂度实验中,该算子的特征维度仅为 324 维,在 TC10 纹理库上的平均特征提取时间为 30.9 ms。实验结果表明,结合微分特征和 Haar 小波分解的方法具有很强的特征判别性,对旋转和模糊的鲁棒性较强,同时具有较低的计算复杂度,在样本数据较少的场合具有很好的适用性。

**关键词:**微分特征;小波分解;抗模糊;旋转不变性;鲁棒纹理表达

**中图分类号:**TP391      **文献标志码:**A

## Robust texture representation by combining differential feature and Haar wavelet decomposition

LIU Wanghua, LIU Guangshuai\*, CHEN Xiaowen, LI Xurui

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu Sichuan 610031, China)

**Abstract:** Aiming at the problem that traditional local binary pattern operators lack deep-level correlation information between pixels and have poor robustness to common blurring and rotation changes in images, a robust texture expression operator combining differential features and Haar wavelet decomposition was proposed. In the differential feature channel, the first-order and second-order differential features in the image were extracted by the isotropic differential operators, so that the differential features of the image were essentially invariant to rotation and robust to image blur. In the wavelet decomposition feature extraction channel, based on the characteristic that the wavelet transform has good localization in the time domain and frequency domain at the same time, multi-scale two-dimensional Haar wavelet decomposition was used to extract blurring robustness features. Finally, the feature histograms on the two channels were concatenated to construct a texture description of the image. In the feature discrimination experiments, the accuracy of the proposed operator on the complex UMD, UIUC and KTH-TIPS texture databases reaches 98.86%, 98.2% and 99.05%, respectively, and compared with that of the MRELBP (Median Robust Extended Local Binary Pattern) operator, the accuracy increases by 0.26%, 1.32% and 1.12% respectively. In the robustness analysis experiments on rotation change and image blurring, the classification accuracy of the proposed operator on the TC10 texture database with only rotation changes reaches 99.87%, and the classification accuracy decrease of the proposed operator on the TC11 texture database with different levels of Gaussian blurs is only 6%. In the computational complexity experiments, the feature dimension of the proposed operator is only 324, and the average feature extraction time of the proposed operator on the TC10 texture database is 30.9 ms. Experimental results show that the method combining differential feature and Haar wavelet decomposition has strong feature discriminability and strong robustness to rotation and blurring, as well as has low computational complexity. It has good applicability in situations with small database.

**Key words:** differential feature; wavelet decomposition; anti-blurring; rotation invariance; robust texture representation

收稿日期: 2020-01-16; 修回日期: 2020-03-14; 录用日期: 2020-03-19。

基金项目: 国家自然科学基金资助项目(51275431); 四川省科技支撑计划项目(2018GZ0361)。

作者简介: 刘望华(1994—), 男, 湖北孝感人, 硕士研究生, 主要研究方向: 纹理分析、计算机视觉; 刘光帅(1978—), 男, 贵州天柱人, 副教授, 博士, 主要研究方向: 计算机视觉、图像处理; 陈晓文(1995—), 男, 湖北十堰人, 硕士研究生, 主要研究方向: 有限元分析、图像处理; 李旭瑞(1996—), 男, 山西曲沃人, 硕士研究生, 主要研究方向: 计算机视觉、三维点云处理。

## 0 引言

纹理是自然物体表面的基本特征。对纹理的分析是指通过对处理后图像的像素强度和空间分布进行数学分析,从而量化纹理参数。纹理分类作为纹理分析中的一个热点问题而备受关注,并在计算机视觉和图像分析领域得到广泛应用。

在过去的几十年里,图像纹理得到广泛研究,相继提出了一些有代表性的纹理分析方法,这些方法一般可分为统计方法、结构方法、基于模型的方法和信号处理方法<sup>[1]</sup>四种。纹理不同于其他特征,因大多数纹理存在较大变化使得对纹理的表达困难,所以统计方法是一种较合适的纹理分析方法。局部二值模式(Local Binary Pattern, LBP)<sup>[2]</sup>作为一种经典的统计方法纹理描述算子,因其计算简单、对单调光照变化不敏感和特征表达能力强的优点,在计算机视觉和模式识别领域得到广泛应用,如生物图像识别<sup>[3-4]</sup>、图像检索<sup>[5-6]</sup>、遥感<sup>[7]</sup>、视觉监测<sup>[8]</sup>等。受 LBP 算子的启发,许多研究者相继提出了大量的 LBP 变体算子来编码图像中的纹理信息。

为增强特征判别性,一些学者通过结合互补特征,相继提出了大量的 LBP 变体算子:Guo 等<sup>[9]</sup>将中心像素和邻域像素的差异分解为符号和幅值两互补部分,并结合图像的全局灰度强度特征,提出了完整局部二值模式(Completed Local Binary Pattern, CLBP)算子;随后, Liu 等<sup>[10]</sup>基于邻域像素强度(Neighbors Intensity, NI)、全局像素强度描述子(Central Intensity, CI)以及邻域径向差异描述子(Radial-Difference, RD)提出了 CINIRD 算子;因 CLBP 和 CINIRD 对噪声敏感, Liu 等<sup>[11]</sup>提出了 BRINT (Binary Rotation Invariant and Noise Tolerant)算子, BRINT 算子采用“ri”的编码方式降低“riu2”编码带来的信息损失,并在量化前将圆形邻域上相邻的  $P/8$  个像素点的平均灰度值作为新的邻域点像素灰度值,在邻域像素点较多时仍能保证恒定的特征维度;而后, Liu 等<sup>[12]</sup>通过对采样点进行中值滤波,基于多尺度 CINIRD 算子提出了 MRELBP (Median Robust Extended Local Binary Pattern)算子,特征判别性较 CINIRD 算子更强,且增强了对椒盐噪声的鲁棒性; Ryu 等<sup>[13]</sup>参考 CLBP 算法,通过排序局部邻域中连续模式数量,将邻域二值模式表示为欧氏空间内的特征向量,提出了 scLBP (Sorted Consecutive Local Binary Pattern)算子; Cimpoi 等<sup>[14]</sup>在卷积层进行多尺度卷积神经网络(Convolutional Neural Network, CNN)特征提取,通过费舍尔向量池化计算图像特征,并通过改变卷积层的步长和接受域,分别提出了 FV-VGG-VD (Fisher Vector-Visual Geometry Group-Very Deep)和 FV-VGG-M (Fisher Vector-Visual Geometry Group - Medium)神经网络算子进行纹理识别; Chan 等<sup>[15]</sup>结合 PCA (Principal Component Analysis)级联、二值哈希编码和逐块直方图计算,提出了 PCANet (PCA Network)算子,并为降低计算量,将 PCANet 中 PCA 替换为随机滤波器,提出了 RandNet (Random Network)算子。

为实现特征的旋转不变性,许多 LBP 变体算子采用 Ojala 提出的旋转不变编码方式编码二值模式,如文献[16-17],但此方法仅对旋转角度为  $360/P$  倍数的旋转变化具有鲁棒性,具有一定的局限性。为增强特征的旋转不变性, Ahonen 等<sup>[18]</sup>利用傅里叶变换幅值谱具有旋转不变性的特点提取旋转不变图像特征; Duan 等<sup>[19]</sup>首先提取训练样本的有序局部像素差异向量,计算对应的旋转二值模式并学习旋转函数,将学习到的旋转函数应用到测试阶段增强特征对旋转变化的鲁棒性。

为增强对模糊的鲁棒性,因低频相位分量具有模糊鲁棒性, Ojansivu 等<sup>[20]</sup>通过量化局部邻域傅里叶变换的相位谱,提出了对模糊鲁棒的局部相位量化(Local Phase Quantization, LPQ)算子;而后, Ahonen 等<sup>[21]</sup>将 LPQ 方法应用于模糊人脸识别; Sun 等<sup>[22]</sup>提出了一种模糊核估计的抗模糊方法,对每个清晰的图像样本估计最佳模糊核,使训练样本与相应的模糊样本之间的距离最小,然后,应用模糊核来模糊清晰的图库样本,将所有这些模糊的样本组成自适应模糊样本集,在识别期间充当参考,增强算子对图像模糊的鲁棒性。

虽然 LBP 的研究取得了很大的成功,并相继提出了大量的 LBP 变体算子,但现有的 LBP 变体算子大多仍存在如下问题:

1) 现有 LBP 变体算子中对结合旋转变化和图像模糊鲁棒性的研究较少。

2) 多数 LBP 算子仅考虑了空间域特征或频域特征,未充分考虑空间特征与频域特征的结合。

3) 许多 LBP 变体算子的特征维度和特征的计算复杂度较高,不能满足实时性的要求。

针对上述问题,本文提出了一种结合微分特征和小波分解的鲁棒纹理表达方法。在微分特征通道上,通过各向同性微分算子提取图像中旋转不变的一阶和二阶微分特征,增强对模糊和旋转变化的鲁棒性;在小波分解通道上,采用多尺度的小波分解提取时频信息,并放大高频小波分解系数增强对模糊的鲁棒性。

## 1 局部二值模式

原始的 LBP 算子最早由 Ojala 等在 1994 年的模式识别国际会议上提出,随后发表于 1996 年的 Pattern Recognition 期刊,直到 2002 年在 IEEE 的模式分析和机器智能学报上发表后才受到人们的广泛关注。原始 LBP 算子通过比较中心像素和邻域像素灰度值大小进行二值量化,加权组合量化后模式值作为 LBP 特征值。LBP 的特征提取过程如图 1 所示,其数学表达式如下:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c)2^p; s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1)$$

其中:  $g_p$  为邻域像素灰度值,  $g_c$  为中心像素灰度值,  $P$  为邻域像素点数目,  $R$  为邻域半径。

式(1)表明, LBP 模式种类共有  $2^P$  种。LBP 算子首先计算纹理图像每个局部邻域所对应的 LBP 值,得到纹理图像的 LBP 模式图,如图 1(c)所示;然后,通过 LBP 模式图的直方图  $H$  来表示该纹理图像的纹理特征。直方图计算的数学表达式如式(2)所示:

$$H(k) = \sum_{m=1}^M \sum_{n=1}^N \delta(LBP(m, n) - k); \delta(x) = \begin{cases} 1, & x = 0 \\ 0, & \text{其他} \end{cases} \quad (2)$$

其中:  $k$  为 LBP 模式值,  $0 \leq k < 2^P$ 。

为增加 LBP 的旋转不变性,减小特征维度, Ojala 分别提出了一致 LBP (LBP<sup>uni2</sup>)、旋转不变 LBP (LBP<sup>ri</sup>) 和旋转不变一致 LBP (LBP<sup>riu2</sup>) 三种纹理描述子。在 LBP<sup>ri</sup> 中,提出采用一致性度量  $U$  来计算模式中 0/1 的跳变次数,并将跳变次数小于或等于 2 的模式定义为一模式,共  $P(P-1)+3$  种。在 LBP<sup>ri</sup> 中,将旋转后相同的模式归为一类,并将最小模式值作为该类模式

的旋转不变 LBP 值。LBP<sup>riu2</sup>结合了 LBP<sup>ri2</sup>和 LBP<sup>ri</sup>的思想,使最终的 LBP 模式具有旋转不变性且特征维度大幅降低,其模式种类共  $P+2$  种。LBP<sup>ri</sup>算子、LBP<sup>ri2</sup>中的一致性度量  $U$  和 LBP<sup>riu2</sup>算子的数学表达式如下:

$$LBP_{P,R}^{\text{ri}} = \min \{ ROR(LBP_{P,R}, i); i = 0, 1, \dots, P-1 \} \quad (3)$$

$$U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (4)$$

$$LBP_{P,R}^{\text{riu2}} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c), & U(LBP_{P,R}) \leq 2 \\ P+1, & \text{其他} \end{cases} \quad (5)$$




图1 原始LBP算子的特征提取流程

Fig. 1 Feature extraction process of original LBP operator

## 2 微分通道特征提取

在计算机视觉任务中,相机对焦不准和图像去噪等问题会给图像造成一定的模糊,不利于图像特征的提取。由于微分特征信息可锐化图像,突出灰度的过渡部分,从而增强对图像模糊的鲁棒性,因此,本文利用图像的一阶和二阶微分特征表达局部结构信息。此外,对图像进行归一化预处理,消除全局光照的影响。

### 2.1 一阶微分特征

一阶微分梯度算子是一种常用的图像锐化算子。因梯度向量的幅值具非线性及各向同性,故梯度幅值具有旋转不变性。梯度幅值的数学表达式为:

$$M(x, y) = \text{mag}(\nabla f) = \sqrt{(\mathbf{I} \otimes \mathbf{g}_x)^2 + (\mathbf{I} \otimes \mathbf{g}_y)^2} \quad (6)$$

其中:  $\mathbf{I}$  为归一化后图像,  $\mathbf{g}_x$  和  $\mathbf{g}_y$  分别为  $x$  和  $y$  方向的梯度算子,  $\otimes$  为卷积符号。

为尽可能多地提取图像轮廓信息,首先,利用不同尺度  $\sigma_i$  ( $i=1, 2, 3$ ) 的高斯梯度幅值算子计算梯度幅值特征,记为  $M_i$  ( $i=1, 2, 3$ ); 然后,三值量化不同尺度下的高斯梯度幅值特征  $M_i$  得到量化后的特征  $Mcode_i$ , 如式(7)所示,其中  $\bar{M}_i$  为矩阵  $M_i$  中所有元素的均值; 最后,加权组合量化后特征  $Mcode_i$  得到图像的一阶微分特征  $Mcode$ , 如式(8)所示。图2为三个不同尺度下的高斯梯度幅值算子,图3为一阶微分特征的详细计算流程。

$$Mcode_i(x, y) = \begin{cases} 0, & M_i(x, y) < 0.6 \bar{M}_i \\ 1, & 0.6 \bar{M}_i \leq M_i(x, y) \leq 1.4 \bar{M}_i \\ 2, & M_i(x, y) > 1.4 \bar{M}_i \end{cases} \quad (7)$$

$$Mcode(x, y) = \sum_{i=1}^3 3^{3-i} Mcode_i(x, y) \quad (8)$$




图2 三个不同尺度下的高斯梯度幅值算子

Fig. 2 Gaussian gradient amplitude operators at three different scales




图3 一阶微分特征计算流程

Fig. 3 First-order differential feature calculation process

### 2.2 二阶微分特征

高斯-拉普拉斯(Laplacian of Gaussian, LoG)作为一种常用的各向同性二阶微分算子,对旋转变化和图像模糊具有鲁棒性;此外,高斯函数可平滑图像,产生振铃现象的可能性小。又因高斯差分(Difference of Gaussian, DoG)算子和LoG算子具有类似的波形,仅幅度略有不同,而DoG算子的计算量明显低于LoG算子,故本文采用各向同性的DoG算子提取图像二阶微分特征。DoG算子图像如图4所示,其数学表达式如式(9)所示:

$$DoG(x, y) = \frac{1}{2\pi\sigma_1^2} e^{-\frac{x^2+y^2}{2\sigma_1^2}} - \frac{1}{2\pi\sigma_2^2} e^{-\frac{x^2+y^2}{2\sigma_2^2}} \quad (9)$$

$$\sigma^2 = \frac{\sigma_1^2 \sigma_2^2}{\sigma_1^2 - \sigma_2^2} \ln \left[ \frac{\sigma_1^2}{\sigma_2^2} \right] \quad (10)$$

其中,  $\sigma_1 > \sigma_2$ 。为使LoG算子和DoG算子有相同的零交叉,LoG算子的方差  $\sigma$  和DoG算子的方差  $\sigma_1$  及  $\sigma_2$  需满足式(10)。本文中  $\sigma_1$  和  $\sigma_2$  分别取为 1.6 和 1。




图4 DoG算子图像

Fig. 4 Images of DoG operator

为提取图像中旋转不变的高阶微分信息,首先,利用各向同性的DoG算子与原图像卷积,得到DoG特征,记为  $D$ ; 然后,对DoG特征进行三值量化,得到二阶微分特征  $Dcode$ , 其数学表达式如式(11)所示,其中,  $\bar{D}$  为矩阵  $D$  中所有元素的均值。图5为二阶微分特征计算流程。




图5 二阶微分特征计算流程

Fig. 5 Second-order differential feature calculation process

### 2.3 微分通道特征直方图

由式(7)和式(8)可知一阶微分特征  $Mcode$  的取值范围为  $[0, 26]$ , 由式(11)可知二阶微分特征  $Dcode$  的取值范围为  $[0, 2]$ 。为增强一阶微分特征和二阶微分特征间的相关性, 本文采用并联的方式计算微分特征直方图  $H_{diff}$ , 即  $H_{diff} = H_{Mcode}/H_{Dcode}$ , 故微分通道特征直方图维度为  $27 \times 3 = 81$ 。

### 3 小波分解通道特征提取

空间滤波方法仅可提取图像在空间域上的局部纹理结构信息。因小波变换在时域、频域都能很好地表征信号的局部特征, 且具有多分辨率分析特点, 与人类视觉机理相似, 因此, 本文从多尺度、多分辨率的角度出发, 利用多尺度小波分解获得像素间更深层次的相关性信息、图像的时频信息以及多尺度信息。图像的小波分解及各子带图像标号如图6所示。




图6 三尺度小波分解及各子带图像标号

Fig. 6 Three-scale wavelet decomposition and image labels of different sub-bands

为增强小波分解特征对图像模糊的鲁棒性, 对小波分解的高频系数进行放大处理并抑制低频系数。为更好地描述图像特征信息, 对小波分解后各子带图像进行三值量化编码, 量化函数如式(12)所示, 得到量化后的特征  $Wcode_i^j$ , 其中下标  $i$  为分解尺度, 上标  $j$  代表小波分解的4个子带,  $j=1$  时为近似图像子带,  $j=2, 3, 4$  则为细节图像子带。

$$s_{wavelet}(x, y) = \begin{cases} 2, & W(x, y) > m + \sigma \\ 1, & \text{其他} \\ 0, & W(x, y) < m - \sigma \end{cases} \quad (12)$$

其中:  $W$  为子带图像,  $m$  为对应子带图像元素均值,  $\sigma$  为对应子带图像元素标准差。

$$Wdetail_i(x, y) = \sum_{j=2}^4 3^{4-j} Wcode_i^j(x, y) \quad (13)$$

因小波分解各细节图像的信息量相对较小, 同时, 为增强细节分量信息之间的相关性, 加权组合每个尺度下的3个量化后细节特征  $Wcode_i^j, j = \{2, 3, 4\}$ , 得到不同尺度下的组合细

节特征, 记为  $Wdetail_i$ , 其数学表达式如式(13)所示; 然后, 为增强特征的相关性, 对每个尺度下的组合细节特征  $Wdetail_i$  和近似图像特征  $Wcode_i^1$  进行并联直方图计算, 每个尺度下特征维度为81维; 最后, 为避免特征维度过高, 串联各尺度的特征直方图作为最终的小波分解通道特征直方图  $H_{wavelet}$ , 当小波分解尺度为  $N$  时, 小波分解通道特征维度为  $81N$ 。

为合理确定小波基函数和分解层数, 在TC10纹理库<sup>[23]</sup>上, 比较分析采用不同小波基函数和不同分解层数下时的分类准确率, 实验结果如表1所示。

表1 不同小波基函数和分解层数时小波分解通道特征在

TC10纹理库上的分类准确率

单位: %

Tab. 1 Classification accuracy of wavelet decomposition channel features on TC10 texture database with

different wavelet basis functions and decomposition levels unit: %

| 分解层数 | 小波基函数  |        |        |          |        |
|------|--------|--------|--------|----------|--------|
|      | db8    | Haar   | sym4   | bior2. 4 | coif3  |
| 1    | 75. 03 | 96. 01 | 94. 32 | 95. 13   | 76. 57 |
| 2    | 84. 01 | 97. 19 | 97. 52 | 97. 54   | 85. 90 |
| 3    | 86. 65 | 98. 53 | 98. 29 | 98. 06   | 88. 20 |
| 4    | 86. 67 | 98. 58 | 98. 49 | 98. 55   | 88. 30 |

从表1数据可以明显看出: 对于常用的五种小波基函数, 当从一尺度分解到三尺度分解, 本节的小波分解特征在TC10上的准确率均大幅增加, 而四尺度分解时的分类准确率较三尺度分解差异不大; 因此, 本文中小波分解层数选择为3。此外, 考虑到Haar小波作为最简单的小波基函数, 可以大幅降低算子的计算复杂度; 因此, 本文选择3尺度的Haar小波分解计算小波分解通道特征。三尺度Haar小波分解通道特征提取的详细计算流程如图7所示。




图7 小波分解特征提取

Fig. 7 Wavelet decomposition feature extraction

### 4 鲁棒纹理表达

在微分通道和小波分解通道上的特征维度分别为81维和243维, 为避免维度过高, 串联微分通道和小波分解通道特征直方图构建本文鲁棒纹理特征, 即  $H = H_{diff} \cdot H_{wavelet}$ , 最终特征直方图维度为324维。在微分特征通道上, 通过各向同性的微分算子提取旋转不变的微分特征, 并对图像模糊具有一定的鲁棒性; 在小波分解通道上, 利用小波分解时频特性以及多尺度特性, 增强特征判别性, 并适当放大高频小波分解系数增强对模糊的鲁棒性。本文算子的总体计算流程如图8所示。




图8 本文算子总体流程

Fig. 8 Overall flowchart of the proposed operator

## 5 实验评估

本节在5个常见数据库(Outex\_TC10、Outex\_TC11<sup>[23]</sup>、KTH-TIPS<sup>[24]</sup>、UMD<sup>[25]</sup>和UIUC<sup>[26]</sup>)上,验证本文算子特征的判别性、对旋转变化和图像模糊的鲁棒性以及本文算子的计算复杂度。

在特征判别性实验中,在3个较新且较复杂的纹理库(KTH-TIPS、UMD和UIUC)上,将本文算子与目前较先进的LBP变体算子以及计算复杂度较低的神经网络算子比较。为

验证本文算子对旋转和图像模糊的鲁棒性,分别在仅具有旋转变化的TC10纹理库和添加了高斯模糊的TC11纹理库上与各实验算子对比。同时,为对比算子的计算复杂度,在TC10纹理库上,将本文算子的特征维度和平均特征提取时间与其他实验算子进行比较。文中所用实验对比算子简单介绍如表2所示,实验数据库介绍如表3所示,各数据库中典型图像样本如图9所示。实验中,所有算子均采用支持向量机(Support Vector Machine, SVM)进行分类,实验电脑CPU为i5-4570, Matlab版本为R2014a。

表2 实验对比算子介绍

Tab. 2 Description of comparison operators used in experiments

| 实验算子                                                                                     | 简单说明                                                                                             |
|------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------|
| LBP                                                                                      | 采用旋转不变一致模式编码,邻域半径为1,邻域采样点数目为8,特征维度为10                                                            |
| LTP(Local Ternary Pattern) <sup>[27]</sup>                                               | 将三值量化特征分解为两个二值模式特征,邻域采样半径为1,邻域采样点数目为8,阈值 $t$ 取为5                                                 |
| CINIRD                                                                                   | 提取图像中 $(P, R)$ 分别为(1, 8)、(2, 16)和(3, 24)时的CI、NI和RD特征,并采用“riu2”编码方式编码,最后,串联三个不同尺度下特征使最终特征维度为2200维 |
| BRINT                                                                                    | 采用量化前平均的思想,使经过平均操作后邻域点数目恒为8,并选择BRINT_CS <sup>riu2</sup> _CM <sup>riu2</sup> 的直方图联合方式             |
| PRICoLBP(Pairwise Rotation Invariant Co-occurrence Local Binary Pattern) <sup>[28]</sup> | 利用切向和法向计算图像中某点的共生点,并计算共生点对在3个尺度下的LBP特征。其中,中心点为“riu2”编码方式,共生点为“u2”编码方式                            |
| LCP(Local Contrast Patterns) <sup>[29]</sup>                                             | 以全局度量的方式分别量化不同方向上的一阶和二阶最大响应以及无方向响应。实验中取 $R=5$                                                    |
| SFC(Space-Frequency Co-occurrences) <sup>[30]</sup>                                      | 在梯度和LOG两个通道上,分别提取空间和频域上旋转不变特征,实验中选 $G_3$ 和 $L_1$ 计算频域特征                                          |
| AHP(Adaptive Hybrid Pattern) <sup>[31]</sup>                                             | 提取图像全局和局部特征,采用自适应量化方式提取更精细结构特征且增加算子鲁棒性。取 $R=1, P=8$ ,量化等级为5                                      |
| AECLBP(Adjacent Evaluation of Completed Local Binary Pattern) <sup>[32]</sup>            | 计算以局部邻域像素点为中心的局部窗口内像素均值,并将其作为新的邻域像素值计算CLBP特征。实验中取 $R=2, P=16$                                    |
| SSLBP(Scale Selective Local Binary Patterns) <sup>[33]</sup>                             | 利用高斯滤波器计算纹理图像的尺度空间,并在尺度空间中为每幅图像建立一个主导LBP直方图,选取不同尺度上的最大值作为模式的尺度不变特征                               |
| FV-VGG-VD                                                                                | FV-VGG-VD为一个深度神经网络算子,其在卷积层进行多尺度的CNN特征提取,并进行无序的费舍尔向量池化计算图像特征                                      |
| FV-VGG-M                                                                                 | 降低了第一个卷积层的步长且有更小的接受域,而增加第二层的步长,兼顾性能和计算复杂度,为一个中等结构网络                                              |
| PCANet                                                                                   | 采用多级PCA学习卷积神经网络的卷积核,对输出矩阵进行二值哈希编码,并基于图像块进行直方图处理                                                  |
| RandNet                                                                                  | RandNet和PCANet有相同的拓扑结构,但其级联滤波器为随机选取,简化了PCANet中滤波器的学习过程                                           |

表 3 实验纹理库介绍

Tab. 3 Description of texture databases used in experiments

| 数据库      | 数据库介绍                                                                                          |
|----------|------------------------------------------------------------------------------------------------|
| Outex    | TC10 24类共4320张仅存在旋转变化的纹理图像,图像大小为128×128;每类选20张作为训练集                                            |
|          | TC11 24类共960张旋转角度为0,光照为“inca”,大小为128×128的纹理图像;每类选20张作为训练集                                      |
| KTH-TIPS | 10类共810张存在旋转、光照、尺度以及图像大小变化的纹理图像;每类选40张作为训练集                                                    |
| UMD      | 包含25类共1000张大小为1280×960纹理图像,且存在较大的旋转、视角、尺度变化及少量的光照变化,为降低计算机负担,将每张图像缩小为320×240;每类选一半构成训练集,其余为测试集 |
| UIUC     | 包含25类共1000张大小为640×480的纹理图像,且存在较大的尺度、旋转、视角变化以及非刚性变形;每类选一半构成训练集,其余为测试集                           |




图 9 实验数据库中典型图像样本

Fig. 9 Typical image samples of the databases used in experiments

5.1 特征判别性分析

为评估本文算子在纹理分类应用上的特征判别性,在KTH-TIPS、UMD和UIUC这3个常用纹理库上,将本文算子和目前一些常见的LBP变体算子以及一些计算量相对较小的神经网络算子进行比较。实验纹理库中典型图像样本如图9(c)~(e)所示。各实验算子分类准确率和特征维度如表4所示。

对于LBP变体算子,在UMD纹理库上,虽然基于结合多尺度特征的CINIRD算子取得最高分类准确率,但较本文算子的准确率仅高出0.07个百分点,而特征维度却较本文算子高出了1876维。在图像尺寸最大的UIUC纹理库上,本文算子的分类准确率在所有LBP变体算子中居于领先地位;准确率较位于第2的SFC算子高0.2个百分点,且特征维度较SFC低1404维;准确率较位于第3的SSLBP算子高2.8个百分点,且特征维度较SSLBP低2076维。在KTH-TIPS纹理库上,本文算子的分类准确率在所有LBP变体算子中仍处于领先地位;准确率较位于第2的MRELBP算子高出了1.12个百分点,而特征维度约为MRELBP的2/5。此外,在3个纹理库中,仅本文算子的分类准确率均位于98%以上。上述数据表明,在存在复杂变化的图像中,本文算子仍能稳定地以较低的维度提取出图像中具有判别性的特征。

表 4 不同纹理库上各算子分类准确率和特征维度比较

Tab. 4 Classification accuracy and feature dimension comparison of different operators on different texture databases

| 实验比较算子    | 不同纹理库分类准确率/% |              |              | 特征维度  |
|-----------|--------------|--------------|--------------|-------|
|           | UMD          | UIUC         | KTH-TIPS     |       |
| 本文算子      | 98.86        | <b>98.20</b> | <b>99.05</b> | 324   |
| CINIRD    | <b>98.93</b> | 94.61        | 93.93        | 2200  |
| SFC       | 97.80        | 98.00        | <b>97.80</b> | 1728  |
| MRELBP    | 98.60        | 96.88        | <b>97.93</b> | 800   |
| SSLBP     | 98.40        | 95.40        | 65.57        | 2400  |
| AHP       | 98.66        | 93.52        | 96.41        | 120   |
| AECLBP    | 98.20        | 95.20        | 96.59        | 648   |
| PRICoLBP  | 95.69        | 85.41        | 94.21        | 3540  |
| LCP       | 95.40        | 94.74        | 96.34        | 171   |
| BRINT     | 96.60        | 94.60        | 90.51        | 40    |
| LBP       | 87.80        | 56.08        | 73.95        | 10    |
| FV-VGG-VD | <b>99.90</b> | <b>99.00</b> | 88.20        | 65536 |
| FV-VGG-M  | <b>99.90</b> | <b>98.70</b> | 79.90        | 65536 |
| PCANet    | 85.67        | 57.70        | 59.43        | 2048  |
| RandNet   | 90.87        | 56.57        | 60.67        | 2048  |

对于神经网络算子,仅FV-VGG-VD和FV-VGG-M算子在图像尺寸较大的UMD和UIUC纹理库上取得了较高的分类准确率,在KTH-TIPS纹理库上的分类准确率急剧下降;而特征维度相对较小的PCANet和RandNet在三个纹理库上的分类准确率均未达到理想水平。说明对于训练样本较小的场合,本文算子较实验中的神经网络算子更具优越性。

本文方法中不同通道特征的分类准确率如表5所示。从实验数据可以看出,除KTH-TIPS数据库上的结果外,微分通道特征判别略强于小波分解通道特征。而结合两个通道上特征后,参考表4的实验数据,算子分类准确率均位于领先水平,说明本文中两个通道特征具有互补性。

表5 不同通道上本文方法分类准确率 单位:%  
Tab. 5 Classification accuracy of the proposed method on different channels unit:%

| 数据库      | 微分通道  | 小波分解通道 | 本文算子  |
|----------|-------|--------|-------|
| TC10     | 99.49 | 98.58  | 99.87 |
| UMD      | 97.70 | 97.38  | 98.86 |
| UIUC     | 96.72 | 95.26  | 98.20 |
| KTH-TIPS | 95.85 | 96.78  | 99.05 |

## 5.2 鲁棒性分析

### 5.2.1 旋转鲁棒性分析

本节在仅存在旋转变化的Outex\_TC10纹理库上验证本文算子对旋转变化的鲁棒性,Outex\_TC10纹理库上典型图像样本如图9(a)所示,各算子分类准确率如表6所示。

表6 TC10纹理库上各算子分类准确率 单位:%  
Tab. 6 Classification accuracy of different operators on TC10 database unit:%

| 算子        | 分类准确率 |
|-----------|-------|
| FV-VGG-VD | 72.80 |
| FV-VGG-M  | 80.00 |
| LBP       | 75.81 |
| BRINT     | 98.35 |
| LCP       | 98.04 |
| PRICoLBP  | 94.48 |
| AECLBP    | 97.58 |
| AHP       | 98.98 |
| SSLBP     | 98.82 |
| MRELBP    | 99.85 |
| SFC       | 99.94 |
| CINIRD    | 99.51 |
| 本文算子      | 99.87 |

在仅存在旋转变化的Outex\_TC10纹理库上,本文算子、SFC算子和MRELBP算子的分类准确率位于前三,且分类准确率十分接近,分别为99.87%、99.94%和99.85%,说明本文算子对旋转变化的鲁棒性。对于实验中四个神经网络算子,网络层数较多的FV-VGG算子的分类准确率仅为72.8%和80%,而另外两个神经网络算子的准确率不足50%,说明对于训练样本不足的场合,神经网络算子并不能很好地提取图像中有代表性的旋转不变信息。

### 5.2.2 模糊鲁棒性分析

为验证本文算子对图像高斯模糊的鲁棒性,在添加不同标准差( $\sigma$ )高斯模糊的Outex\_TC11纹理库上,将本文算子的

分类准确率与和实验对比算子比较。TC11纹理库中典型图像样本如图9(b)所示,实验结果如图10所示。

从图10可以看出,在仅存在高斯模糊的TC11纹理库上,本文算子较其他实验算子对图像的高斯模糊具有更强的鲁棒性。当标准差 $\sigma$ 为0.5时,因TC11纹理库图像变化较小,大多数算子均取得较高的准确率。当高斯PSF函数标准差从0.5增加到1.25,大多实验算子的准确率分类准确率均急剧下降,如最近提出的MRELBP算子和AECLBP算子的准确率下降约20个百分点,AHP算子下降约40个百分点,仅本文算子和SFC算子的准确率下降平缓,且本文算子的降幅最低,降幅仅为6个百分点。说明本文算子中通过提取模糊鲁棒微分特征和放大高频小波分解系数的方法,有效增强了对图像高斯模糊的鲁棒性。




图10 TC11纹理库上添加不同标准差高斯模糊时各算子分类准确率

Fig. 10 Classification accuracy of different operators on TC11 texture database with different standard deviation Gaussian blurs

## 5.3 计算复杂度分析

算子的特征提取时间和特征维度是衡量算子计算复杂度的两个重要指标,TC10纹理库上各算子的特征提取时间和特征维度如表7所示。

表7 TC10纹理库上各算子平均特征提取时间和特征维度比较

Tab. 7 Comparison of feature extraction time and feature dimension of different operators on TC10 texture database

| 实验算子      | 特征提取时间/ms | 维度    |
|-----------|-----------|-------|
| 本文算子      | 30.90     | 324   |
| CINIRD    | 114.60    | 2200  |
| SFC       | 60.55     | 1728  |
| MRELBP    | 199.33    | 800   |
| SSLBP     | 180.10    | 2400  |
| AHP       | 31.70     | 120   |
| AECLBP    | 42.20     | 648   |
| PRICoLBP  | 380.40    | 3540  |
| LCP       | 47.90     | 171   |
| BRINT     | 19.50     | 40    |
| LBP       | 7.50      | 10    |
| FV-VGG-VD | 2655.40   | 65536 |
| FV-VGG-M  | 358.80    | 65536 |
| PCANet    | 711.80    | 2048  |
| RandNet   | 725.60    | 2048  |

在所有的LBP变体算子中,在特征提取时间方面,平均特征提取时间最高的为PRICoLBP算子,其次为MRELBP算子和SSLBP算子,其中,相较于PRICoLBP、MRELBP和SSLBP算子,本文算子的特征提取时间分别减小了91.88%、84.5%和82.84%;在特征维度方面,本文算子特征维度仅324维,不足CINIRD算子的1/6,不足SFC算子的1/5,约为MRELBP算子的2/5。对于神经网络算子,四个算子的特征提取时间和特征维度均大幅高于本文算子,相较于两个FV-VGG算子,本文算子的特征维度减小了99.5%,与特征提取时间相对较小的FV-VGG-M算子相比,本文算子的特征提取时间减小了91.39%;与PCANet和RandNet算子相比,本文算子的特征维度减小了84.18%,特征提取时间分别减小了95.66%和95.74%。因此,本文算子相较于实验对比算子有着更低的计算复杂度,更能满足实时性的要求。

## 6 结语

为充分提取图像时频信息和像素间深层次的相关性信息,增强算子对模糊和旋转变化的鲁棒性,本文在微分特征和小波分解两个通道上提取鲁棒的图像特征。为增强特征对旋转变化的鲁棒性,本文通过各向同性的一阶和二阶微分算子提取图像微分特征;为增强特征对模糊的鲁棒性,除采用多阶微分特征外,通过适当放大高频小波分解系数,提取图像细节信息。实验表明,本文算子可用较低维度的特征向量表达图像中有判别性的信息,且对图像旋转和图像模糊具有较强的鲁棒性。在未来的工作中,计划将本文算子扩展到包含其他种类模糊的应用场合,进一步扩大算子的使用范围。

## 参考文献 (References)

- [1] CHEN C H. Handbook of Pattern Recognition and Computer Vision [M]. Hackensack, NJ: World Scientific Publishing, 1998: 235-276.
- [2] OJALA T, PIETIKAINEN M, MAENPAA 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.
- [3] 刘文婷,卢新明. 基于LBP和HOG特征分层融合的步态识别[J]. 计算机工程与应用, 2018, 54(24): 168-175. (LIU W T, LU X M. Gait recognition based on layered fusion of LBP and HOG features [J]. Computer Engineering and Applications, 2018, 54(24): 168-175.)
- [4] 甘俊英,翟懿奎,项俐,等. 面向活体人脸检测的时空纹理特征级联方法[J]. 模式识别与人工智能, 2019, 32(2): 117-123. (GAN J Y, ZHAI Y K, XIANG L, et al. Spatial-temporal texture cascaded feature method for face liveness detection [J]. Pattern Recognition and Artificial Intelligence, 2019, 32(2): 117-123.)
- [5] VERMA M, RAMAN B. Local neighborhood difference pattern: a new feature descriptor for natural and texture image retrieval [J]. Multimedia Tools and Applications, 2018, 77(10): 11843-11866.
- [6] 张美玲,吴俊峰,于红,等. 基于颜色四通道及空间金字塔的鱼类图像检索[J]. 计算机应用, 2019, 39(5): 1466-1472. (ZHANG M L, WU J F, YU H, et al. Fish image retrieval algorithm based on color four channels and spatial pyramid [J]. Journal of Computer Applications, 2019, 39(5): 1466-1472.)
- [7] LI K, CHENG G, BU S, et al. Rotation-insensitive and context-augmented object detection in remote sensing images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(4): 2337-2348.
- [8] HANZAEI S H, AFSHAR A, BARAZANDEH F. Automatic detection and classification of the ceramic tiles' surface defects [J]. Pattern Recognition, 2017, 66: 174-189.
- [9] GUO Z, ZHANG L, ZHANG D. A completed modeling of local binary pattern operator for texture classification [J]. IEEE Transactions on Image Processing, 2010, 19(6): 1657-1663.
- [10] LIU L, ZHAO L, LONG Y, et al. Extended local binary patterns for texture classification [J]. Image and Vision Computing, 2012, 30(2): 86-99.
- [11] 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.
- [12] LIU L, LAO S, FIEGUTH P W, et al. Median robust extended local binary pattern for texture classification [J]. IEEE Transactions on Image Processing, 2016, 25(3): 1368-1381.
- [13] RYU J, HONG S, YANG H S. Sorted consecutive local binary pattern for texture classification [J]. IEEE Transactions on Image Processing, 2015, 24(7): 2254-2265.
- [14] CIMPOI M, MAJI S, VEDALDI A. Deep filter banks for texture recognition and segmentation [C]// Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2015: 3828-3836.
- [15] CHAN T H, JIA K, GAO S, et al. PCANet: a simple deep learning baseline for image classification? [J]. IEEE Transactions on Image Processing, 2015, 24(12): 5017-5032.
- [16] PAN Z, LI Z, FAN H, et al. Feature based local binary pattern for rotation invariant texture classification [J]. Expert Systems with Applications, 2017, 88: 238-248.
- [17] NGUYEN T P, VU N S, MANZANERA A. Statistical binary patterns for rotational invariant texture classification [J]. Neurocomputing, 2016, 173 (Pt 3): 1565-1577.
- [18] AHONEN T, MATAS J, HE C, et al. Rotation invariant image description with local binary pattern histogram Fourier features [C]// Proceedings of the 2009 Scandinavian Conference on Image Analysis, LNCS 5575. Berlin: Springer, 2009: 61-70.
- [19] DUAN Y, LU J, FENG J, et al. Learning rotation-invariant local binary descriptor [J]. IEEE Transactions on Image Processing, 2017, 26(8): 3636-3651.
- [20] OJANSIVU V, HEIKKILÄ J. Blur insensitive texture classification using local phase quantization [C]// Proceedings of the 3rd International Conference on Image and Signal Processing, LNCS 5099. Berlin: Springer, 2008: 236-243.
- [21] AHONEN T, RAHTU E, OJANSIVU V, et al. Recognition of blurred faces using local phase quantization [C]// Proceedings of the 19th International Conference on Pattern Recognition. Piscataway: IEEE, 2009: 1-4.
- [22] SUN G, LIU Z. Robust blurred face recognition using sample-wise kernel estimation and random compressed multi-scale local binary

- pattern histograms [C]// Proceedings of the 2014 International Conference on Image Processing. Piscataway: IEEE, 2014: 333-337.
- [23] OJALA T, MAENPAA T, PIETIKAINEN M, et al. Outex — new framework for empirical evaluation of texture analysis algorithms [C]// Proceedings of the 2002 International Conference on Pattern Recognition. Piscataway: IEEE, 2002: 701-706.
- [24] HAYMAN E, CAPUTO B, FRITZ M, et al. On the significance of real-world conditions for material classification [C]// Proceedings of the 2004 European Conference on Computer Vision, LNCS 3024. Berlin: Springer, 2004: 253-266.
- [25] XU Y, YANG X, LING H, et al. A new texture descriptor using multifractal analysis in multi-orientation wavelet pyramid [C]// Proceedings of the 2010 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2010: 161-168.
- [26] LAZEBNIKS, SCHMIDC, PONCE J. A sparse texture representation using local affine regions[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(8): 1265-1278.
- [27] TAN X, 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.
- [28] QI X, XIAO R, LI C, et al. Pairwise rotation invariant co-occurrence local binary pattern[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(11): 2199-2213.
- [29] SONG T, LI H, MENG F, et al. Noise-robust texture description using local contrast patterns via global measures[J]. IEEE Signal Processing Letters, 2014, 21(1): 93-96.
- [30] SONG T, LI H, MENG F, et al. Exploring space-frequency co-occurrences via local quantized patterns for texture representation [J]. Pattern Recognition, 2015, 48(8): 2621-2632.
- [31] ZHU Z, YOU X, CHEN C L P, et al. An adaptive hybrid pattern for noise-robust texture analysis [J]. Pattern Recognition, 2015, 48(8): 2592-2608.
- [32] SONG K, YAN Y, ZHAO Y, et al. Adjacent evaluation of local binary pattern for texture classification [J]. Journal of Visual Communication and Image Representation, 2015, 33: 323-339.
- [33] GUO Z, WANG X, ZHOU J, et al. Robust texture image representation by scale selective local binary patterns [J]. IEEE Transactions on Image Processing, 2016, 25(2): 687-699.
- This work is partially supported by the National Natural Science Foundation of China (51275431), the Sichuan Science and Technology Support Program (2018GZ0361).
- LIU Wanghua**, born in 1994, M. S. candidate. His research interests include texture analysis, computer vision.
- LIU Guangshuai**, born in 1978, Ph. D., associate professor. His research interests include computer vision, image processing.
- CHEN Xiaowen**, born in 1995, M. S. candidate. His research interests include finite element analysis, image processing.
- LI Xurui**, born in 1996, M. S. candidate. His research interests include computer vision, 3D point cloud processing.