邵琦峰, 赵文彬, 陈熙. 基于动态阈值的多尺度局部二值模式及其图像特征提取[J]. 智能计算机与应用,2026,16(7):26-33. DOI:10.20169/j.issn.2095-2163.24112701

基于动态阈值的多尺度局部二值模式及其图像特征提取

邵琦峰, 赵文彬, 陈 熙
(贵州师范大学 大数据与计算机科学学院, 贵阳 550025)

摘 要: 图像纹理特征提取在计算机视觉中具有重要作用,但传统的局部二值模式(LBP)方法在复杂环境中常受噪声干扰且缺乏全局信息。本文针对这些问题,提出了一种基于中位数的动态阈值增强多尺度块局部二值模式(Median-Based Dynamic Threshold Enhanced Multi-scale Block Local Binary Pattern,MBDT_EMB_LBP)。该方法通过引入基于中位数的动态阈值,使得算法能自适应调整以提高抗噪性,同时通过多尺度块处理增强了对多层次纹理变化的捕捉能力。实验结果表明,基于中位数的动态阈值增强多尺度块局部二值模式在多个公开数据集上均表现出优越的识别性能,特别是在高斯噪声和泊松噪声干扰下展现出显著的抗噪能力。

关键词: 图像纹理特征提取; 动态阈值; 多尺度块局部二值模式
中图分类号: TP391.4 **文献标志码**: A **文章编号**: 2095-2163(2026)07-0026-08

Image feature extraction based on multi-scale LBP with dynamic thresholds

SHAO Qifeng, ZHAO Wenbin, CHEN Xi
(School of Big Data and Computer Science, Guizhou Normal University, Guiyang 550025, China)

Abstract: Image texture feature extraction plays a crucial role in computer vision, but traditional Local Binary Pattern (LBP) methods often suffer from noise interference and lack global information in complex environments. To address these issues, the paper proposes a Median-Based Dynamic Threshold Enhanced Multi-scale Block Local Binary Pattern (MBDT_EMB_LBP). This method introduces a median-based dynamic threshold, allowing the algorithm to adaptively adjust to improve noise resistance. It also enhances the capture ability of multi-level texture variations through multi-scale block processing. Experimental results demonstrate that the MBDT_EMB_LBP exhibits superior recognition performance across several public datasets, showing significant noise resistance, particularly under Gaussian and Poisson noise interference.

Key words: image texture feature extraction; dynamic thresholds; local binary mode of multi-scale blocks

0 引 言

图像纹理特征提取是计算机视觉中的核心技术,广泛应用在工业、医疗和科研等领域[1-4]。经典方法包括基于统计模型、多尺度分析和深度学习等方法。例如,小波变换通过分解图像的多尺度和方向特性,提取不同频率的纹理信息[5-7];尺度不变特征变换(SIFT)主要用于寻找尺度不变特征点并生成其描述[8-10];自回归模型假设像素值由邻域像素的线性组合表示,适合规则性纹理分析[11-12];卷积神经网络(CNN)则通过自动学习复杂高维特征,实现了出色的纹理提取[13-15]。此外,局部二值模式(LBP)以计算简单、易于实现的特点,也成为纹理提取的经典方法之一[16-18]。

尽管这些方法在不同应用中取得了可观的进展,但也存在一定的局限性。小波变换计算复杂,特征提取时间较长;SIFT 尽管具有尺度、旋转和光照不变性,但计算开销高,主要用于特征点提取而非整体纹理分析;自回归模型仅适用于规则性强的纹理,对复杂纹理效果较差;深度学习虽然能够处理大规模数据,并具有极高的鲁棒性,但对数据量和硬件资源需求较高,在资源受限情况下应用受限[19]。LBP

基金项目: 国家自然科学基金(61762022)。
作者简介: 邵琦峰(1998—),男,硕士研究生。主要研究方向:图像处理,模式识别; 赵文彬(1999—),男,硕士研究生。主要研究方向:图像处理,机器学习。
通信作者: 陈 熙(1976—),男,博士,教授。主要研究方向:模式识别,生物特征识别。Email: biometrics@yeah.net。
收稿日期: 2024-11-27

尽管适合实时应用，但对噪声敏感，缺乏全局信息，并且在复杂场景下难以捕捉多层次纹理特征。

局部二值模式因计算简单、局部纹理捕捉能力强、易于实现而广泛应用于工业和科研领域的实时任务中。然而，LBP 也存在对噪声敏感、缺乏全局信息以及对多尺度变化不够适应的不足。这些缺点限制了其在复杂场景中的表现，特别是在多种纹理结构和尺度变化下难以有效地捕捉不同层次特征，而在噪声环境中，纹理提取效果大幅降低，从而影响分类和识别的准确性。针对这些问题，本文提出了一种基于中位数的动态阈值增强多尺度块局部二值模式（Median－Based Dynamic Threshold Enhanced Multi-scale Block Local Binary Pattern，MBDT_EMB_LBP）。该方法通过动态阈值计算提高抗噪性能，并结合多尺度特征提取增强了对复杂纹理的捕捉能力，从而显著提升了图像分类的识别率和鲁棒性。

1　局部二值模式介绍

1.1　多尺度块局部二值模式

多尺度块局部二值模式（Multi－scale Block LBP，MB-LBP）是由 Liao 等学者[20]提出的一种在 LBP 基础上增强对图像局部纹理描述能力的方法，这种方法在处理复杂或者大尺度的纹理时更具有优势。MB-LBP 不直接使用每个像素作为计算单位，而是将图像划分为若干个大小相等的小块（blocks）。对于每一个图像块，计算该块内所有像素的平均灰度值，作为该块的代表值。然后与传统 LBP 类似，MB-LBP 将中心块的平均灰度值与周围邻域块的平均灰度值进行比较。将比较结果的二进制值转化为十进制数，作为该中心块的 MB－LBP 值。对整个图像进行 MB-LBP 特征提取后，构建直方图，将这些直方图组合成一个整体特征，用于图像描述和分类。图 1 给出了 MB-LBP 的实现过程。

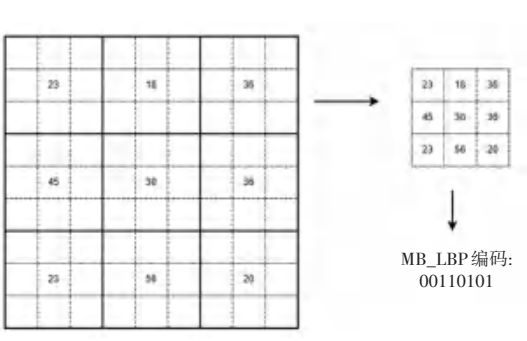


图 1　MB-LBP 的实现过程

Fig. 1　MB-LBP implementation process

MB-LBP 值的数学定义公式如下：

$$\mu(B_i)=\frac{1}{k^2}\sum_{(x,y)\in B_i} I(x,y) \tag{1}$$

式（1）假设有一个图像 I，将图像 I 划分为若干个大小为 $k\times k$ 的图像块。定义第 i 个图像块为 B_i，则 $\mu(B_i)$ 代表图像块 B_i 平均灰度值。接下来推得：

$$\mathrm{MB_LBP}(B_c)=\sum_{p=1}^{P} s(\mu(B_p)-\mu(B_c))\cdot 2^{P-1} \tag{2}$$

其中，P 表示中心像素周围邻域像素点个数。

1.2　增强型局部二值模式

增强型局部二值模式（Enhanced Local Binary Pattern，ELBP）算法是由申柯等学者[21]在 2023 年提出，其中融合了传统局部二值模式（Local Binary Pattern，LBP）与环式局部二值模式（Ring Local Binary Pattern，RLBP）的特征提取优势。LBP 侧重于中心像素与邻域像素的关系，而 RLBP 进一步引入了间隔像素的关系编码，通过特征直方图的融合，有效弥补了两种方法的局限性。该方法在多个公开数据集（如 ORL 人脸数据库、Extended Yale B 人脸数据库及 Poly U 掌纹数据库）上进行实验验证，结果表明该算法在特征表达丰富性、识别率和抗噪声鲁棒性方面均显著优于传统算法及其他融合方法，为图像纹理特征提取和生物特征识别提供了更强的技术支持。

2　算法改进工作

2.1　基于中位数的动态阈值模式

本文提出了一种基于中位数的动态阈值 LBP 算子。首先，需要对输入的灰度图像使用图像边缘像素值进行边界填充，从而避免在计算 LBP 值时出现越界问题。对于图像中的每个非边界像素提取其周围的 3×4 像素邻域块，该邻域块包含 12 个像素，每个像素点记为 $C_i(i=1,2,\cdots,11,12)$。将该邻域块分为 A 和 B 两个部分，其中 A 部分包括 C_1、C_2、C_3、C_4、C_5 和 C_7，B 部分包括 C_6、C_8、C_9、C_{10}、C_{11} 和 C_{12}。MBDT 算子邻域块拆分如图 2 所示，这种划分允许分别分析不同区域的局部信息，增强对不同方向纹理的敏感性。

对于每个邻域块的 A 区域，阈值记为 median_A，表示为：

$$\mathrm{median_}A=\phi(C_1,C_2,C_3) \tag{3}$$

式（3）中，取 C_1、C_2、C_3 这 3 个像素点灰度值的中位数作为 A 部分的阈值，即 median_A，同样地对于 B 区域，阈值记为 median_B：

$$\mathrm{median_}B=\phi(C_{10},C_{11},C_{12}) \tag{4}$$

在得到 A 部分和 B 部分的中位数阈值后，分别在每个部分比较邻域中的像素与对应区域的中位数，将结果二值化，生成局部二值模式。具体计算方法如下：

$$\mathrm{LBP}_{\mathrm{MBDT}} = \sum_{k=0}^{3} s(C_{p(k)} - \mathrm{median_}A) \cdot 2^k + \sum_{k=4}^{7} s(C_{q(k)} - \mathrm{median_}B) \cdot 2^k \quad (5)$$

其中，$\mathrm{LBP}_{\mathrm{MBDT}}$ 表示基于中位数的动态阈值的 LBP 值。

$p(k)$ 是 A 部分对应像素的索引关系，定义为 $p(0)=1, p(1)=4, p(2)=5, p(3)=7$，即对应 A 部分的 C_1, C_4, C_5, C_7。

$q(k)$ 是 B 部分对应像素的索引关系，定义为 $q(4)=6, q(5)=8, q(6)=9, q(7)=12$，即对应 B 部分的 C_6, C_8, C_9, C_{12}。

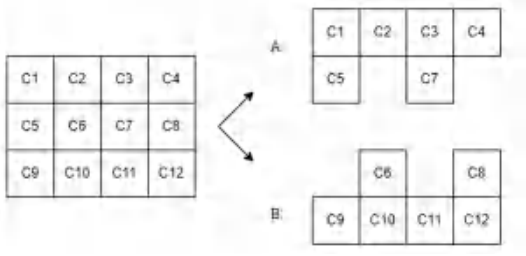


图 2 MBDT 算子邻域块拆分示意图

Fig. 2 Schematic diagram of MBDT operator neighborhood block splitting

$\mathrm{LBP}_{\mathrm{MBDT}}$ 算子通过区域划分和动态阈值计算，能够捕捉不同方向和复杂纹理变化的特征，同时有效抑制噪声对纹理提取的影响。相比于传统 LBP，使用中位数作为阈值具有更强的抗噪性和稳定性，在光照不均或对比变化较大的图像中表现尤为突出。

2.2 增强型多尺度块局部二值模式

在图像纹理特征提取中，MB-LBP 能够提取细粒度的纹理特征，但其单一尺度（如 9×9 块）难以全面描述复杂图像的多层次信息。为克服这一局限性，本文提出增强型多尺度块局部二值模式（Enhanced Multi-scale Block LBP，EMB_LBP），通过多个尺度的块操作同时提取局部和全局特征，提高对复杂纹理的表达能力。

EMB_LBP 通过引入 15×15、12×12 和 9×9 大小的块（scales = [15, 12, 9]），能够同时提取全局和局部特征，从而捕捉多层次纹理信息。这种多尺度处理的优势在于能够捕捉全局结构信息和增强鲁棒性。

EMB_LBP 采用不同块大小（如 15×15、12×12、9×9）提取多层次纹理特征，具体步骤如下：

（1）按输入图像的每个尺度分块，在各个尺度下提取块均值特征。

（2）使用邻域块的均值与中心块均值进行比较，生成二进制编码。

（3）不同尺度下的编码结果通过直方图拼接，形成综合特征。

假设输入的图像为 I，定义一个包含多个尺度信息的数组 $S = \{s_1, s_2, \cdots, s_n\}$，其中每个尺度 s_i 对应不同的图像块大小。对于每一个尺度 s_i，将图像划分为若干个大小为 $s_i \times s_i$ 的图像块。对于每个尺度下的第 i 个图像块 $B_i^{(s)}$，其均值计算公式为：

$$\mu(B_i^{(s)}) = \frac{1}{s^2} \sum_{(x,y) \in B_i^{(s)}} I(x,y) \quad (6)$$

其中，s 表示当前尺度下的块大小，$\mu(B_i^{(s)})$ 表示图像块 $B_i^{(s)}$ 的像素均值。

对于每个尺度 s，定义中心块为 $B_c^{(s)}$，其周围邻域的图像块为 $\{B_p^{(s)} \mid p = 1, 2, \cdots, P\}$。使用邻域块的均值与中心块的均值进行比较，生成二进制编码。对于每个尺度下的 MB_LBP 编码，定义为：

$$\mathrm{MB_LBP}(B_i^{(s)}) = \sum_{p=1}^{P} s(\mu(B_p^{(s)}) - \mu(B_c^{(s)})) \cdot 2^{P-1} \quad (7)$$

其中，P 表示邻域块的数量。

对图像的每个尺度 s，计算相应的 MB-LBP 编码后，将不同尺度的编码结果进行拼接，最终生成融合后的特征。假设在尺度 s 上的 MB-LBP 编码为 $h_s(c)$，表示第 c 个编码出现的频率，则最终多尺度的 MB-LBP 特征表示为：

$$H_{\mathrm{multi_scale}} = [h_{s1}(c), h_{s2}(c), \cdots, h_{sn}(c)] \quad (8)$$

每个尺度的直方图 $h_s(c)$ 经过归一化后进行拼接，从而形成多尺度特征向量。

2.3 算法融合

本文提出的 MBDT_EMB_LBP 算法结合了基于中位数的动态阈值模式（MBDT）和增强型多尺度块局部二值模式（EMB_LBP）的优势，能够有效捕捉图像的局部细节和多尺度纹理信息。在融合过程中，分别利用 MBDT 提升抗噪性和 EMB_LBP 捕捉全局纹理特征，从而提供更全面的特征表示。算法的具体流程如图 3 所示，具体步骤如下：

（1）输入图像 I 和尺度数组 $S = \{s_1, s_2, \cdots, s_n\}$，在每个指定尺度上将图像分割为多个块（block），计算每个块的 MB-LBP 编码。然后生成对应的直方

图，并进行归一化处理。最终，将所有尺度的直方图拼接为多尺度特征 $H_{\text{EMB_LBP}}$。

(2)对图像 I，提取每个像素的 3×4 邻域块，计算其中位数作为动态阈值，并生成对应的二进制编码(LBP 值)。编码值被记录到直方图中，归一化处理后得到特征 $H_{\text{MBDT_LBP}}$。

(3)将 $H_{\text{EMB_LBP}}$ 和 $H_{\text{MBDT_LBP}}$ 拼接成融合特征 $H_{\text{MBDT_EMB_LBP}}$。融合特征同时包含局部细节和多尺度纹理信息，为分类任务提供了更全面的特征表示，显著提升了分类的准确性和鲁棒性。

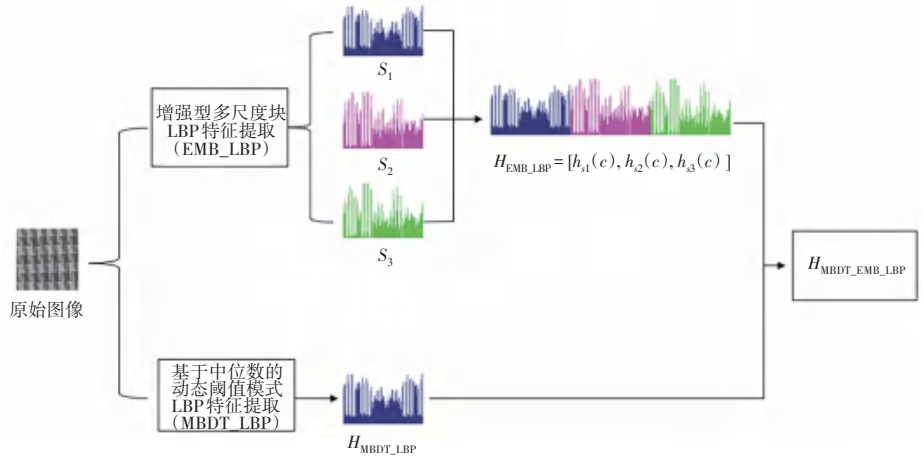


图 3　MBDT_EMB_LBP 特征提取流程示意图

Fig. 3　Schematic diagram of the MBDT_EMB_LBP feature extraction process

3　实验设置与结果分析

在本节，设计了一系列的实验来验证本文所提出的图像特征提取分类算法的准确性、抗噪性和稳定性。为了评估算法在处理复杂纹理情况下的图像分类准确性，本文使用了多种人脸数据集和纹理数据集。然后，为了测试算法抗噪声性能，本文在掌纹数据集上添加了高斯噪声和泊松噪声来进行实验验证。接下来为了保证实验结果的稳定性，本文通过多次实验的方法来测试算法的稳定性，所以在本文中针对每一次图像分类实验，所有实验次数均设置为 10 次。最终求得图像分类识别率的平均值和标准差。

3.1　数据集和实验设置

研究中，将本文提出的 MBDT_EMB_LBP 与其他较为先进的 LBP 变体在以下 3 个数据集上进行图像分类实验，分别是：ORL 人脸数据集[22]、Extended Yale B 人脸数据集[23]和香港理工大学 poly U 掌纹数据集[24]。

ORL 数据集包含 40 个类别，每类 10 张人脸图像，总计 400 张，图像在光照、角度和表情上存在变化。Extended Yale B 数据集扩展自 Yale 数据集，包含 38 个类别，共 2 432 张人脸图像，涵盖不同光照、表情和姿态条件(预处理为 64×64 像素)。从香港理工大学 poly U 掌纹数据集中取出部分样本，其中包含 100 个类别，每类 6 张掌纹图像(将其预处理为 128×128 像素)。各数据集部分截图如图 4 所示。

本文所使用的分类器是最近邻分类器，样本之间的距离为直方图交叉距离。对于每个测试样本，具体计算其与所有训练样本的距离，选取距离最小的样本作为预测依据。分类器的距离计算公式如下：

$$\text{Dist}=\sum_{k=1}^{n}\frac{(x_k-y_k)^2}{x_k+y_k+\varepsilon} \tag{9}$$

其中，x_k 和 y_k 是特征值，ε 是一个小的常数，用于避免分母为零。

分类器通过比较每类中最近样本的距离，确定测试样本的类别。如果 2 个最小距离相等，则分类结果被视为正确。最终，该分类器根据测试集的平均识别率评估性能，适合处理特征差异显著的分类问题。

3.2　各算法在不同数据集上的对比性能

为了验证本文算法的优越性，将其与 LBP[25]、CSLBP[26]、CSLDP[27]、ELBP[21]、2DECoLBP[28]以及本文的 EMB 和 MBDT 等方法进行了对比实验。

在 ORL 数据集上，测试了本文算法与其他 LBP 改进算法的图像识别效果。实验将所有图像样本分块为 2×2，每个类别的 10 个样本中随机选取 $N=4$，5，6，7 个作为训练样本，其余为测试样本。为了确保实验结果的稳定性，每种算法在相同训练样本数量下重复进行 10 次，计算平均识别率及其标准差。



(a) ORL数据集部分截图



(b) Extended Yale B数据集部分截图



(c) poly U掌纹数据集部分截图

图 4 实验数据集部分截图

Fig. 4 Partial screenshots of the experimental datasets

实验结果表明,本文提出的 MBDT_EMB_LBP 算法在所有训练样本数量下均表现最优(见表 1)。具体地,当 N = 4 时,本文所提算法识别率为 94.96(±2.32%),显著高于传统 LBP 的 88.54(±3.07%)以及 CSLBP 和 CSLDP 等其他算法。随着训练样本数量不断增加,本文算法识别率进一步提升,在 N = 7 时达到 97.92(±1.43%),仍明显优于传统 LBP 的 94.42(±1.67%)。

Extended Yale B 人脸数据集提供了更多样化的光照条件和更大的数据规模,能够更全面地测试算法在不同环境下的鲁棒性和泛化能力。特别是在人脸识别实际应用中,光照的变化是常见挑战,因此在扩展数据集上进行实验,可以确保模型在复杂光照条件下的表现更具现实性和可靠性,从而提升模型的实用性和稳健性。

实验在 N = 16,24,32,40,48 的条件下测试了算法性能(见表 2)。本文算法在所有训练样本数量下均表现最佳,例如在 N = 16 时,本文算法的识别率为 88.36(±2.37%),远高于传统 LBP 的 67.31(±3.77%)。随着训练样本数量增加,本文算法识别率提升至 96.51(±2.46%)、此时 N = 48,继续领先其他算法。

表 1 各算法在 ORL 数据集上的平均识别率

Table 1 Average recognition rate of each algorithm on the ORL dataset %

算法	N			
	4	5	6	7
LBP[25]	88.54(±3.07)	92.05(±2.30)	93.69(±1.00)	94.42(±1.67)
CSLBP[26]	80.54(±2.97)	84.80(±2.32)	87.19(±2.09)	89.33(±1.75)
CSLDP[27]	73.04(±3.35)	78.75(±2.88)	81.44(±3.41)	83.67(±2.05)
ELBP[21]	93.33(±2.26)	95.90(±1.60)	97.63(±0.57)	97.33(±0.79)
2DECoLBP[28]	94.51(±3.35)	95.34(±2.10)	96.32(±1.78)	96.98(±4.12)
EMB	93.75(±2.27)	95.75(±1.80)	96.88(±1.51)	96.92(±1.63)
MBDT	89.33(±2.41)	93.10(±2.07)	94.69(±1.59)	95.08(±1.59)
本文算法	94.96(±2.32)	96.95(±1.80)	98.12(±1.06)	97.92(±1.43)

表 2　各算法在 Extended Yale B 人脸数据集上的平均识别率

Table 2　Average recognition rate of each algorithm on the Extended Yale B face dataset　%

算法	*N*				
	16	24	32	40	48
LBP[25]	67.31(±3.77)	71.82(±3.85)	76.38(±3.36)	79.00(±3.50)	81.83(±3.79)
CSLBP[26]	50.32(±3.14)	55.85(±3.33)	60.69(±3.71)	63.85(±3.38)	67.40(±4.88)
CSLDP[27]	36.73(±2.47)	41.01(±2.59)	43.90(±3.54)	45.32(±5.28)	47.85(±4.32)
ELBP[21]	86.37(±2.14)	89.38(±2.49)	91.36(±3.32)	92.54(±1.35)	93.56(±3.56)
2DECoLBP[28]	84.56(±1.29)	86.75(±4.31)	89.32(±1.24)	90.21(±1.98)	91.23(±2.11)
EMB	86.71(±2.28)	89.57(±2.20)	92.97(±1.09)	93.90(±1.73)	94.37(±2.64)
MBDT	68.40(±3.71)	72.72(±3.77)	77.25(±3.24)	79.89(±3.57)	82.68(±3.69)
本文算法	88.36(±2.33)	91.23(±2.29)	94.79(±1.03)	95.93(±1.73)	96.51(±2.46)

3.3　抗噪性能测试

实际应用中，图像识别系统往往受到传感器噪声、环境噪声或传输失真等干扰，这些噪声会降低图像质量，从而影响算法的识别效果。因此，评估算法在噪声环境下的鲁棒性是确保其实用性的关键。本文通过在掌纹数据集上添加高斯噪声和泊松噪声，模拟复杂环境中的干扰场景，测试算法的抗噪性能。

3.3.1　实验设计

高斯分布的随机噪声，用于模拟摄像头或传感器的采集误差。设置高斯噪声的均值 $\mu = 2$，标准差 $\sigma = 25$。泊松噪声是信号强度相关噪声，常见于低光照条件下的图像采集。模拟信号光子计数过程中随机性，噪声强度随图像亮度变化。实验将图像分块为 4×4，在每个训练样本数量 $N = 2,3,4$ 条件下，分别对无噪声、高斯噪声和泊松噪声环境进行测试，每种算法重复实验 10 次，计算平均识别率及标准差。

3.3.2　实验结果

抗噪性能实验结果见表 3。

表 3　不同噪声条件下各算法在掌纹数据集上的平均识别率

Table 3　Average recognition rates of various algorithms on the palmprint datasets under different noise conditions　%

噪声种类	算法	*N*		
		2	3	4
无噪声	LBP[25]	95.50(±7.22)	99.90(±0.16)	99.95(±0.16)
	CSLBP[26]	95.32(±7.07)	99.60(±0.38)	99.80(±0.35)
	CSLDP[27]	89.07(±13.03)	97.57(±1.07)	97.95(±1.42)
	ELBP[21]	98.33(±2.67)	99.87(±0.17)	99.90(±0.21)
	2DECoLBP[28]	96.94(±1.14)	97.12(±1.46)	97.23(±1.23)
	本文算法	99.98(±0.08)	100.00(±0.00)	100.00(±0.00)
高斯噪声	LBP[25]	14.22(±3.42)	15.90(±2.04)	16.60(±4.36)
	CSLBP[26]	42.85(±5.39)	48.83(±2.29)	50.60(±4.12)
	CSLDP[27]	13.45(±4.21)	15.70(±0.78)	16.50(±2.99)
	ELBP[21]	75.21(±1.32)	78.36(±2.11)	80.30(±2.23)
	2DECoLBP[28]	87.89(±1.98)	89.22(±1.20)	90.12(±0.56)
	本文算法	98.60(±1.85)	99.93(±0.14)	99.95(±0.16)
泊松噪声	LBP[25]	49.83(±6.27)	56.47(±2.12)	59.15(±6.26)
	CSLBP[26]	42.85(±5.39)	48.83(±2.29)	50.60(±4.12)
	CSLDP[27]	13.45(±4.21)	15.70(±0.78)	16.50(±2.99)
	ELBP[21]	32.20(±1.03)	35.74(±3.98)	39.67(±2.35)
	2DECoLBP[28]	51.23(±0.45)	54.37(±1.01)	56.00(±0.17)
	本文算法	99.95(±0.16)	100.00(±0.00)	100.00(±0.00)

(1)无噪声条件：本文算法识别率接近 100%，优于其他所有方法。LBP 和 CSLBP 表现较好，ELBP 和 2DECoLBP 的表现也非常出色，但稍逊于本文算法；CSLDP 的识别率相对较低且波动较大。

(2)高斯噪声条件:本文算法在添加高斯噪声后识别率仍保持在 98%以上,显示了较强的抗噪性能。ELBP 和 2DECoLBP 在高斯噪声条件下表现稳定,远高于传统的 LBP、CSLBP 和 CSLDP,但仍不及本文算法。相比之下,LBP 和 CSLDP 的识别率在 $N = 2$ 时降至 20%以下,表现出较差的鲁棒性;CSLBP 的表现稍优,但同样不及本文算法。

(3)泊松噪声条件:本文算法识别率接近 100%,展示了极佳的鲁棒性。其他算法识别率下降明显,表明其抗噪性能有限。

4 结束语

本文提出的基于中位数的动态阈值增强多尺度块局部二值模式算法有效解决了传统 LBP 算法在复杂环境下的不足,特别是在噪声干扰和多尺度特征提取方面展现了显著优势。通过引入动态阈值和多尺度块处理,该方法在不同噪声条件下均能保持较高的识别率和稳定性,证明了其在实际应用中的鲁棒性和实用性。此外,与其他 LBP 变体相比,本文算法在多个公开数据集上的识别效果均表现优异,充分验证了其适应性和泛化能力。

然而,本方法在处理更高分辨率图像或特殊纹理场景时可能仍存在优化空间,且算法复杂度的增加带来了计算成本的提升,这对实时应用提出了挑战。因此,未来的研究可以尝试进一步优化算法以降低计算成本,同时引入深度学习模型进行融合,以提升识别性能。此外,可以在更大规模、更复杂的图像数据集上进行验证,以进一步扩展算法的应用范围。

参考文献

[1] Chen M L, Yu X H, Su S J, et al. Image texture analysis based on gray level co-occurrence matrix[C]// Proceedings of 2023 13th International Conference on Information Technology in Medicine and Education (ITME). Piscataway, NJ: IEEE, 2023: 451-455.

[2] Suttapakti U, Srikamdd S, Onpans J. Multi-directional texture feature extraction for glaucoma classification from color retinal images [C]// Proccedings of 2022 19th International Joint Conference on Computer Science and Software Engineering (JCSSE). Piscataway, NJ: IEEE, 2022:1-5.

[3] Feng K, Zhang R. Realization technology of texture feature extraction algorithm of remote sensing satellite image based on FPGA [C]// Proceedings of 2022 IEEE 2nd International Conference on Data Science and Computer Application (ICDSCA). Piscataway, NJ: IEEE, 2022: 110-114.

[4] Tong L L. Edge extraction of ceramic micro-image based on texture feature[C]// Proceedings of 2021 International Conference on Communications, Information System and Computer Engineering (CISCE). Piscataway, NJ: IEEE, 2021:298-302.

[5] Chen X L. Improvement and experimental analysis of remote sensing image edge detection algorithm based on Wavelet Transform and feature extraction[C]// Proceedings of 2024 IEEE 4th International Conference on Electronic Technology, Communication and Information (ICETCI). Piscataway, NJ: IEEE, 2024:587-590.

[6] Chen C. Moving image feature extraction method based on wavelet Transform[C]// Proceedings of 2022 International Conference on Intelligent Transportation, Big Data & Smart City. Piscataway, NJ: IEEE, 2022:166-169.

[7] Kou C, Zu Y X. WaveRFN-Nest: A multi-scale feature fusion method based on wavelet Transform and deep learning [C]// Proceedings of 2023 6th International Conference on Software Engineering and Computer Science. Piscataway, NJ: IEEE, 2023: 1-5.

[8] Wu Z H, Wu H Y. Improved SIFT image feature matching algorithm[C]// Proceedings of 2022 2nd International Conference on Computer Graphics, Image and Virtualization (ICCGIV). Piscataway, NJ: IEEE,2022:223-226.

[9] Aslam M A, Salik M N, Chughtai F. Image classification based on mid-level feature fusion [C]// Proceedings of 2019 15th International Conference on Emerging Technologies (ICET). Piscataway, NJ: IEEE, 2019:1-6.

[10] Li D. Classification and application of sports venue monitoring images using SIFT algorithm [C]// Proceedings of 2022 International Conference on Artificial Intelligence and Autonomous Robot Systems (AIARS). Piscataway, NJ: IEEE, 2022:118-121.

[11] Kashyap R, Chellappa R. Estimation and choice of neighbors in spatial-interaction models of images[J]. IEEE Transactions on Information Theory, 1983,29(1):60-72.

[12] Grenander U. Probabilities on algebraic structures[M]. New York:Wiley,1963.

[13] Sharma H, Jain J S, Bansal P. Feature extraction and classification of chest X-ray images using CNN to detect pneumonia [C]// Proceedings of 2020 10th International Conference on Cloud Computing, Data Science & Engineering. Piscataway, NJ: IEEE,2020: 227-231.

[14] Kale A, Altun O. Age, gender and ethnicity classification from face images with CNN-based features[C]// Proceedings of 2021 Innovations in Intelligent Systems and Applications Conference. Piscataway, NJ: IEEE,2021:1-6.

[15] Kamepalli S, Ketepalli G, Yadav M S. Customized deep CNN for foliar disease prediction based on features extracted from apple tree leaves images [C]//Proceedings of 2022 International Interdisciplinary Humanitarian Conference for Sustainability. Piscataway, NJ: IEEE,2022:193-197.

[16] Yang T, He Y Z. Face recognition based on LBP algorithm [C]// Proceedings of 2020 International Conference on Computer Network, Electronic and Automation (ICCNEA). Piscataway, NJ: IEEE, 2020:21-25.

[17] Xu Q T, Zhao N J. A facial expression recognition algorithm based on CNN and LBP Feature[C]// Proceedings of 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference. Piscataway, NJ: IEEE,2020: 2304-2308.

[18] Ai H Z, Xia H W, Chen W X. Face tracking sign-in system based on LBP feature algorithm [C]// Proceedings of 2020 Chinese Automation Congress (CAC). Piscataway, NJ: IEEE,

2020：2257-2262.
[19] Lecun Y，Bengio Y，Hinton G E. Deep learning[J]. Nature，2015，521：436-444.
[20] Liao S C，Zhu X X，Lei Z. Learning multi-scale block local binary patterns for face recognition[C]// Proceedings of Advances in Biometrics. Cham：Springer，2007：828-837.
[21] 申柯，陈熙. 增强型局部二值模式及其图像纹理特征提取[J]. 计算机仿真，2023，6(6)：260-267.
[22] Cambridge Vision Group. ORL face database[DB/OL]. (1994-01-01). https://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html.
[23] Yale Computer Vision Group. Extended Yale Face Database B[DB/OL]. (2005-01-01). https：vision.ucsd.edu/~leekc/ExtYaleDatabase/ExtYaleB.html.
[24] Biometric Research Center. PolyU Palmprint Database[DB/OL]. (2009-01-01). https://www4.comp.polyu.edu.hk/~biometrics.
[25] Ojala T，Pietikainen M，Harwood D. Performance evaluation of texture measures with classification based on Kullback discrimination of distributions[C]// Proceedings of the 12th IAPR International Conference on Pattern Recognition. Piscataway，NJ：IEEE，1994：582-585.
[26] Guo Z H，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.
[27] Murala S，Maheshwari R P，Balasubramanian R. Local tetra patterns：A new feature descriptor for content-based image retrieval[J]. IEEE Transactions on Image Processing，2012，21(5)：2874-2886.
[28] 张云飞，李江美，陈熙. 基于信息熵的二维局部二值模式静脉识别[J]. 现代计算机，2024，30(8)：9-16.