

融合纹理与形状特征的 HEp-2 细胞分类

文登伟^① 张东波^{*①②} 汤红忠^{①②} 许海霞^{①②}

^①(湘潭大学信息工程学院 湘潭 411105)

^②(机器人视觉感知与控制国家工程实验室 长沙 410012)

摘 要: 间接免疫荧光(IIF)HEp-2 细胞图像分析是自身免疫疾病诊断的重要依据, 然而由于类内的变化与类间的相似性, HEp-2 细胞染色模式分类具有很大难度。该文提出一种结合纹理和形状信息的有效分类方法, 借鉴 CLBP 原理, 提出具有完整信息描述能力的局部三值模式 CLTP(Completed Local Triple Pattern)描述子来提取纹理信息, 同时采用 IFV(Improved Fisher Vector)模型和 Rootsift 特征来描绘形状信息, 通过纹理和形状信息的结合, 最终训练得到 SVM 分类器在 ICPR 2012 与 ICIP 2013 数据集上进行了对比试验。结果表明, 所提方法在细胞级测试中优于其它方法, 拥有竞争性的分类性能。

关键词: HEp-2; 局部三值模式; 改进的 Fisher 向量

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2017)07-1599-07

DOI: 10.11999/JEIT161090

HEp-2 Cell Classification by Fusing Texture and Shape Features

WEN Dengwei^① ZHANG Dongbo^{①②} TANG Hongzhong^{①②} XU Haixia^{①②}

^①(Institute of Information Engineering, Xiangtan University, Xiangtan 411105, China)

^②(Robotic Visual Perception and Control National Engineering Laboratory, Changsha 410012, China)

Abstract: Indirect Immuno Fluorescence (IIF) HEp-2 cell image analysis is an important basis for the diagnosis of autoimmune diseases. However, due to the great changes in the class and the similarity between the categories, HEp-2 cell staining pattern classification is a difficult problem. This paper presents an effective classification method based on the texture and shape information, learning from the principle of CLBP, a descriptor extracting texture information is proposed to describe the Complete information of the Local Triple Pattern (CLTP). Moreover, using Improved Fisher Vector (IFV) model and Rootsift feature, the shape information can be described. Through the combination of the texture and shape information, an SVM classifier is finally trained and an experiment is conducted in ICPR 2012 and ICIP 2013 data sets. Experiment results show that this method is superior over other methods in the cell level test and present competitive performance.

Key words: HEp-2; Local triple pattern; Improved Fisher Vector (IFV)

1 引言

间接免疫荧光(IIF)HEp-2 图像是自身免疫疾病诊断的重要依据, 通常免疫荧光图像由专业人员进行判读和分析, 但由于主观性的局限, 不同专家容易出现判断分歧, 从而影响结果的重现性。同时随着间接免疫荧光图像分析的推广, 对专业人员的需求增大, 极大地增加了专业人员的劳动强度。为了避免人为诊断的不确定性和主观局限性, 降低专家

的劳动强度, 近年来, 采用计算机视觉实现辅助诊断引起广泛关注。

免疫荧光 HEp-2 细胞图像分类任务中, 需要将荧光染色的细胞图像分为 6 类, 分别为 Homogeneous, Coarse-speckled, Nucleolar, Centromere, Fine-speckled, Cytoplasmatic。由于受成像环境影响, 同一染色模式的外观差异会有较大变化, 同时部分模式类具有非常相似的视觉特性, 且专家评判间的差异, 导致此任务是一个难度较高的识别问题。

在最近几年的 ICPR 2012, ICIP 2013 和 ICRP 2014 大会上, 专门组织的 HEp-2 细胞图像分类竞赛极大推动了 HEp-2 细胞图像分类技术的研究, 各种特征提取、特征学习^[1,2]和分类器设计^[3]方法都被有效应用于该问题。由于特征提取在该问题中起关键作用, 因此得到较充分的研究, 目前采用的特征主

收稿日期: 2016-10-17; 改回日期: 2017-04-06; 网络出版: 2017-05-11

*通信作者: 张东波 zhadonbo@163.com

基金项目: 国家自然科学基金(61602397), 湖南省自然科学基金(2017JJ2251, 2017JJ3315), 湖南省重点学科建设项目

Foundation Items: The National Natural Science Foundation of China (61602397), The Natural Science Foundation of Hunan Province (2017JJ2251, 2017JJ3315), The Key Discipline Construction Project of Hunan Province

要分为纹理特征^[4-6]和形态(形状)特征^[7],其中纹理特征应用更为广泛,表现比较稳定,通常性能优于单纯的形状特征描述。其中用的最多的纹理描述特征是局部二值模式(LBP)及其改进特征,LBP特征实现简单,计算速度快,鲁棒性强,能较好地描述图像的微观结构信息。最早将LBP特征用于HEp-2分类的是Ojala等人^[8],为了获得旋转不变性,通常采用旋转不变二值模式 $LBP_{P,R}^{inv2}$,其中 P 为邻域采样点数目, R 是邻域半径,常用的邻域参数 (P,R) 有 $(8,1)$, $(16,2)$, $(24,3)$ 3组。采用 $LBP_{P,R}^{inv2}$ 特征,在ICPR2012数据集的细胞级测试中获得48.4%的分类准确率。基于此特征,提出许多改进的局部纹理特征,例如为了减少信息损失,CLBP(Completed LBP)^[9]结合了符号、大小和中心区域信息实现局部模式描述,获得了69.6%分类精度,但CLBP特征有高频噪声敏感的缺陷。为了更好的描述复杂的纹理结构,CoALBP(Co-occurrence of Adjacent LBP)^[10]特征使用了相邻的两个LBP值构成模式对,使分类精度达到68.7%,但是其缺点是对图像旋转非常敏感。针对图像的局部旋转和全局旋转做了特征改进,同时在考虑了边缘轮廓信息和颜色信息后,PRICoLBP(Pairwise Rotation Invariant Co-occurrence of LBP)^[11]特征进一步将分类精度提升到了73.7%。

除了局部纹理特征外,也有一些文献研究了全局纹理特征在HEp-2图像分类中的应用,如MR8(Maximum Response filter banks)^[12]主要应用滤波响应与K-means聚类方法生成特征。此外还有大家比较熟悉的灰度共生矩阵GLCM(Gray-Level Co-occurrence Matrices)^[13],边缘方向直方图EOH(Edge Orientation Histograms)^[14]。为了获得旋转、平移等不变性描述,ZERN矩特征(ZERNike moments)^[15]通过计算归一化的频谱空间Zernike矩特征,可以实现HEp-2图像的旋转、平移和尺度不变描述。此外,通过离散傅里叶变换后,旋转角度对应傅里叶空间的相位偏移,因此可以获得旋转不变的Gabor特征描述RIGF(Rotation-Invariant Gabor Features)^[16]等特征。上述全局纹理特征同样被用于HEp-2图像分类,但是由于辨别能力有限,从文献实验结果来看^[17],全局纹理特征分类性普遍要低于局部纹理特征。

除了纹理特征外,形状信息也是HEp-2图像分类的一个重要依据,例如Ponomarev等人^[18]提取ROI染色细胞区域的数量,大小,形状等共17种形态学特征,在MIVIA测试集上分辨率达到70.57%。Stoklasa等人^[19]则采用了简单表面形状描述子和颗

粒分析算法实现细胞图像的外观描述,在ICPR2012分类精度也达到64.4%。尽管形状特征在HEp-2分类任务能够取得一定效果,但相关报道较少,同时由于形状信息获取依赖于细胞分割的准确性,鲁棒性较差,在更大数据集的HEp-2细胞分类任务中,往往分类结果不够理想。

通过对现有文献的分析,我们了解到已有方法往往利用单一的纹理或形状信息,而很少将两者结合起来。现有基于LBP或改进原理的纹理特征在描述局部微观结构上有优势,但是不擅于描述全局的纹理信息,而实际上专家通常都是在对细胞整体形状、外貌进行最直接的观察基础上,再通过局部细节信息做精细划分。因此,局部纹理信息和整体形态信息具有很强的互补性,组合使用应该能获得更好的分类结果。基于这一观察,本文提出一种组合纹理和形状描述的HEp-2细胞荧光图像特征提取方法,为了保留更丰富的纹理结构信息,本文提出了一种三值描述的CLTP(Completed Local Triple Pattern)特征,该特征借鉴了完备LBP模式CLBP原理,其中一共可分为3个分量,其中两个分别包含大小、符号信息,剩余一个分量保留细胞中心区域信息。同时,我们采用基于Rootsift特征的Fisher Vector(FV)编码技术描述荧光细胞图像的整体形状信息,最后将两种特征进行拼接组合后,通过SVM进行训练并分类测试,实验表明,和ICPR 2012大赛的最好结果相比,本文的方法提高了约7.7%的精度。另外在ICIP2013训练集中也能达到79.5%的准确率。

2 CLTP 特征提取原理

2.1 基于自适应阈值的LTP模式

为了增强辨别能力,我们采用了基于自适应阈值的局部三值模式描述技术。假设局部纹理结构 T 由一定邻域的像素点构成,其包含灰度级为 $P+1$ ($P>0$)的图像像素点集合,任取一位为起始位,按顺时针排序,则纹理结构 T 可表示为

$$T = t(g_c, g_0, \dots, g_{p-1}) \quad (1)$$

其中, g_c 为局部图像中心像素, g_0, \dots, g_{p-1} 为中心像素的 P 邻域像素灰度值。

通过差分计算,可以实现相对于任何单调变换的灰度不变性,为了区别式(1),由 T_1 标识表示:

$$T_1 = t(s(g_0 - g_c), s(g_1 - g_c), \dots, s(g_{p-1} - g_c)) \quad (2)$$

LTP中 $s(x)$ 定义如下:

$$s(x) = \begin{cases} 2, & x \geq TH \\ 1, & 0 \leq x < TH \\ 0, & x < 0 \end{cases} \quad (3)$$

其中，阈值 TH 由式(4)计算可得

$$TH = \frac{\sum_{i=1}^N \sum_{j=1}^P (g_j - g_i) \cdot \zeta(g_j - g_i)}{P \times N} \quad (4)$$

$$\zeta(g_j - g_i) = \begin{cases} 1, & g_j - g_i > 0 \\ 0, & g_j - g_i \leq 0 \end{cases} \quad (5)$$

式中， g_i 表示中心像素， g_j 表示邻域像素， P 为邻域像素点数目， N 为计算区域像素点个数。

将权重 3^P 分配给每个 $s(g_p - g_c)$ ，由此可得到一个唯一的 LTP 编码，用符号表示为 $LTP_{P,R}$ ：

$$LTP_{P,R} = \sum_{p=0}^{P-1} s(x)3^p \quad (6)$$

R 表示邻域半径，具体计算过程如图 1 所示。

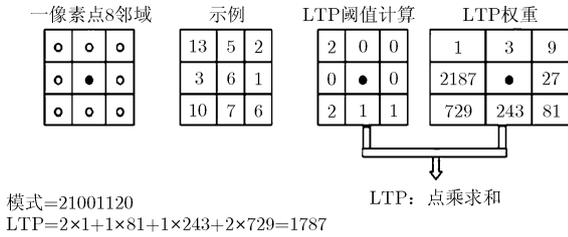


图1 LTP 编码值计算过程

2.2 旋转不变统一局部三值模式

2.2.1 旋转不变 LTP 类似于旋转不变 LBP 模式原理，旋转不变的 LTP 模式可以采用类似的方式生成。为达到旋转不变性，不断旋转圆形邻域得到一系列初始定义的 LTP 值，取其最小值作为该邻域的 LTP 值。用公式表示为

$$LTP_{P,R}^{ri} = \min \{ ROR(LTP_{P,R}, i) \mid i = 0, 1, \dots, P-1 \} \quad (7)$$

式中，上标 ri 代表“旋转不变性”。 $ROR(LTP_{P,R}, i)$ 为旋转函数，表示将 $LTP_{P,R}, i$ 循环右移 $i(i < P)$ 位。

2.2.2 “统一”LTP 如果 LTP 模式符合以下条件：

- (1) 当纹理 T_1 做一次循环运算时，它最多只包含 3 种转换(0 和 1 的转换，0 和 2 的转换，1 和 2 的转换)；
- (2) T_1 最多可发生 $u(u = 0, 2, 4, \dots)$ 次转换。则我们将此 LTP 模式称为“统一”模式并用 $LTP_{P,R}^{u2}$ 表示。上标 u2 表示最多发生 2 次转换，其余所有的非统一模式由一个单一标签标记。

2.2.3 旋转不变统一 LTP 结合旋转不变 LTP 和统一 LTP 原理，可以得到旋转不变统一 LTP 模式，表示为 $LTP_{P,R}^{riu2}$ ，定义为

$$LTP_{P,R}^{riu2} = \min \{ ROR(LTP_{P,R}^{u2}, i) \mid i = 0, 1, \dots, P-1 \} \quad (8)$$

图2给出部分旋转统一-LTP模式示例，第1行为

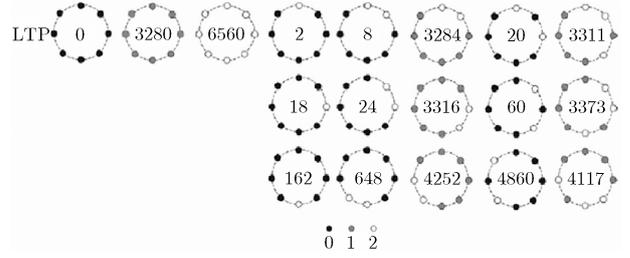


图2 “旋转不变统一”模式下的LTP

统一-LTP模式示例，第2和第3行是对应的旋转后的 LTP 模式。其中编码模式可作如下分配，示例圆环中的值表示对应情况下的 LTP 值(最上方的点作为初始位顺时针计算)，由“旋转不变统一”模式定义可知，除 7, 8 列外，每列的旋转不变统一 $LTP_{P,R}^{riu2}$ 值均等于第 1 排的值，均可编为不同模式类，而第 7, 8 两列模式均发生了两次以上的转换，即在 $LTP_{P,R}^{riu2}$ 中它们的 $u = 4$ ，因此均被归为其他模式类。

2.3 完备局部三值模式 CLTP

为了更好地利用编码时丢失的信息，受 CLBP 启发，我们提出完备局部三值模式 CLTP 描述方法，CLTP 同样包含了 3 种核心算子，称为中心描述子，符号描述子和大小描述子，分别用 $CLTP_C$ ， $CLTP_S$ ， $CLTP_M$ 表示，它们的计算过程如下： $CLTP_S$ 计算等同于式(6)，其编码值由 $CLTP_S^* = \sum_{p=0}^{P-1} s_1(x)3^p$ 计算，其中的 $s_1(x)$ 定义为

$$s_1(x) = \begin{cases} 2, & x \geq TH \\ 1, & 0 \leq x < TH \\ 0, & x < 0 \end{cases} \quad (9)$$

类似地， $CLTP_M^* = \sum_{p=0}^{P-1} s_2(x)3^p$ ，其中的 $s_2(x)$ 定义为

$$s_2(x) = \begin{cases} 2, & x \geq b \times TH \\ 1, & a \times TH \leq x < b \times TH \\ 0, & x < a \times TH \end{cases} \quad (10)$$

式中， a, b 为自定义常量，可取 $a = 0.3, b = 0.7$ 。

$$CLTP_C^* = \begin{cases} 1, & x \geq TH1 \\ 0, & x < TH1 \end{cases} \quad (11)$$

TH1 为图像像素均值，然后用 $LTP_{P,R}^{riu2}$ 模式分别转化编码值 $CLTP_S^*$ ， $CLTP_M^*$ 即为 $CLTP_S$ 跟 $CLTP_M$ ， $CLTP_C^*$ 的编码值则对应矩阵 $CLTP_C$ 。

首先将 $CLTP_S$ 与 $CLTP_M$ 组合，得到 $CLTP_{SM}$ ，表示为

$$CLTP_{SM} = [CLTP_{S_{n \times 1}}, CLTP_{M_{n \times 1}}] \quad (12)$$

其中， n 表示 $CLTP_S$ 的编码个数， $CLTP_{S_{n \times 1}}$ 表

示将 CLTP_S 展开为 $n \times 1$ 的列向量, 此时 CLTP_SM 可看成 n 个 2 维特征向量, 统计其直方图, 并用 CLTP_SMH 表示。

然后将 CLTP_M 做式(13)计算得 CLTP_MC :

$$\text{CLTP_MC} = (\text{CLTP_C} \cdot \text{CLTP_M} + \text{DIM})$$

$$+ (1 - \text{CLTP_C}) \cdot \text{CLTP_M} \quad (13)$$

其中, 符号 \cdot 表示矩阵点乘, DIM 表示 LTP 模式的维度, 用类似的方法组合 CLTP_S 与 CLTP_MC 得到 CLTP_MC ,

$$\text{CLTP_SMC} = [\text{CLTP_S}_{n \times 1}, \text{CLTP_MC}_{n \times 1}] \quad (14)$$

同样, 做直方图统计, 得到特征 CLTP_SMCH 。

最后结合 CLTP_MCH 和 CLTP_SMCH 得到 CLTP 特征。

$$\text{CLTP} = [\text{CLTP_SMH}, \text{CLTP_SMCH}] \quad (15)$$

此 CLTP 特征的维度和 LTP 模式有关, 例如使用 $\text{LTP}_{P,R}^{\text{inu}2}$ 模式时, 表示为 $\text{CLTP}_{P,R}^{\text{inu}2}$, 此时 $\text{DIM}(\text{LTP}_{P,R}^{\text{inu}2}) = 45$, 则 $\text{CLTP}_{P,R}^{\text{inu}2}$ 维度为 $45 \times 45 + 45 \times 45 \times 2 = 6075$ 维。

2.4 基于改进 Fisher 编码的 Rootsift 特征

改进的 Fisher 向量编码过程主要包括以下 3 个步骤:

(1)Rootsift 特征提取: 对每个图像提取 sift 特征点并计算相应的 sift 特征向量 x , 将其标准化后做开方运算, 如式(16)所示。

$$x = \sqrt{\frac{x}{\|x\|_1}} \quad (16)$$

(2)训练高斯混合模型(GMM): 将所有图片的 sift 特征组合到一起, 假设 X 为图像数, x^* 表示一幅图的所有 sift 特征, T_X 为第 X 图片的特征数, 其特征空间可表述为, $W = [x_1^* \ x_2^* \ \dots \ x_X^*] \in R^{d \times N}$, 其中 N 表示特征总数, $N = \sum_{X=1}^X T_X$, 随后利用 GMM 模型对所有图像的特征向量进行训练可得系列参数 $\lambda = \{\alpha_k, \mu_k, \Sigma_k\}, k = 1, 2, \dots, K$, $\alpha_k, \mu_k, \Sigma_k$ 分别代表着权重, 均值和协方差, K 为聚类数。

(3)通过求得的系列统计量形成 IFV 特征: 计算过程为

$$\tilde{G}_{\mu_k^d}^X = \frac{1}{T_X \sqrt{\omega_k}} \sum_{t=1}^{T_X} \gamma(k) \left[\frac{x_t^d - \mu_k^d}{(\sigma_k^d)^2} \right] \quad (17)$$

$$\tilde{G}_{\sigma_k^d}^X = \frac{1}{T_X \sqrt{\omega_k}} \sum_{t=1}^{T_X} \gamma(k) \left[\frac{1}{\sqrt{2}} \left[\frac{(x_t^d - \mu_k^d)^2}{(\sigma_k^d)^2} - 1 \right] \right] \quad (18)$$

其中, $d = 1, 2, \dots, 128, k = 1, 2, \dots, K, \sigma_k = \text{diag}(\Sigma_k), \omega_k$ 满足 $\sum_{k=1}^K \omega_k = 1, \gamma(k)$ 表示特征 x_t 属于第 k 个混合模型的概率:

$$\gamma_t(k) = \frac{\omega_k P(k/x_t, \lambda)}{\sum_{t=1}^{T_X} P(k/x_t, \lambda)} \quad (19)$$

Fisher 特征由 $F = [\tilde{G}_{\mu_k^d}^X \ \tilde{G}_{\sigma_k^d}^X]$ 构成, 可知 F 维

度为 $2 \times d \times K$, 最终对 F 进行直方图统计, 其直方图特征表示为 IFV 。将 CLTP 特征与 IFV 特征组合起来, 得到 $H = [\text{CLTP} \ \text{IFV}]$, 将此特征作为最终特征实现对 HEP-2 细胞图像的描述, 并使用线性 SVM 进行训练和测试。

3 实验

3.1 数据集与评价准则

本文试验中使用的数据集有 ICPR2012 和 ICIP2013。其中 ICPR2012 数据集中图片来源于 28 张原始的 ANA HEP-2 切片图片, 每张图片包含多个同类的细胞, 通过手工分割后构成了训练图片集(721 张)与测试图片集(734 张)。Coarse-speckled 和 Fine-speckled 这两类合并成 Speckled 类, 并另外划分了 Nuclear Membrane 类, 其中 Glogi 类则相当于 ICPR 数据集中 Cytoplasmatic 类, 其他类不变。ICIP2013 是一个样本规模更大的数据集, 其中包含了 13596 张训练图片, 另外有 54833 张测试图片没有公开。

在 HEP-2 竞赛和文献报道中, 广为采用评价准则有两种, 一种类似于 ICPR2012 竞赛, 将数据集分成独立的训练集和测试集, 训练集训练后根据测试集的检测结果进行评价, 该测试得到的是细胞级测试结果。此外, 还有一种图像级测试准则, 也即采用 leave-one-out 方法测试, 例如 ICPR2012 数据集来自 28 张样本切片图像, 每次选其中 27 幅的细胞图像作为训练集, 剩下一张的细胞图像作为测试集, 重复 28 次, 整幅切片图像的染色模式类别由分类结果中的多数类别决定。

3.2 实验分析

本文实验均为在 MATLAB2014 中测试运行, 电脑系统为 WIN10, 处理器参数为 Intel(R) Core(TM) i7-6700HQ CPU @2.60 GHz, RAM 为 8.00 GB。

首先, 我们比较 CLTP 特征和传统的 LTP 特征的性能。将原图像转变为灰度图像后进行特征提取, 考虑到特征维度的大小与运算速度原因, 我们采用的邻域参数为 $P = 8, R = 1$ 。考虑到计算 $\text{CLTP}_{P,R}^{\text{inu}2}$ 以外的模式时, 特征维度急剧增大($\text{CLTP}_{P,R}^{\text{inu}2}$ 维度为 39675), 容易造成计算机内存溢出, 同时运行速度过慢, 而分类效果无明显提升, 因此实验比较中只

提取了 $CLTP_{P,R}^{riu2}$ 这一种特征模式。表 1 给出了传统 LTP 的统一模式，旋转不变模式，旋转不变统一模式和本文提出的 CLTP 旋转不变统一模式的细胞级测试结果，本文算法单幅图片运行时间均在 10 ms

以下，这在 HEp-2 分类算法中是极快的。显然传统 LTP 模式分类准确率均低于 60%，其中最好分类准确率是 $LTP_{P,R}^{u4}$ (59.8%)，最差的是 $LTP_{P,R}^{riu2}$ (51.9%)。而 $CLTP_{P,R}^{riu2}$ 的准确率有很大的提升，达到了 71.3%。

表 1 不同 LTP 模式和 CLTP 模式的准确率对比

模式	$LTP_{8,1}^{u2}$	$LTP_{8,1}^{u4}$	$LTP_{8,1}^{ri}$	$LTP_{8,1}^{riu2}$	$LTP_{8,1}^{riu4}$	$CLTP_{8,1}^{riu2}$
准确率(%)	54.6	59.8	59.5	51.9	59.3	71.3
时间(ms)	3.7	3.9	3.8	3.6	3.7	9.4
特征维度	172	1768	834	45	346	6075

其次，我们比较了采用形态学特征^[20]，IFV 特征，CLTP 特征以及 IFV 特征结合 CLTP 纹理特征后的测试结果。本文 IFV 特征中参数取 $K = 128$ ，在 $(-1.5, 2)$ 区间内 15 等分来进行 IFV 统计(此处 3 个参数选取参考文献[21]，与区间选择和等分数综合考虑，通常 K 取 2 的某个幂，目的是为不浪费无谓的计算机空间，区间选取由 Fisher 特征的范围决定，本文的取值为多次调整后的较优数值)，表 2~表 5 是相关方法在 ICPR2012 测试数据集上混淆矩阵，实验结果表明，如果单纯只利用形状信息分类性能欠佳，实验采用的两种反映形状信息的特征分别只能达到 52.2%和 46.1%的准确率，在 Homogeneous, Fine-speckled 和 Centromere 几类外观非常相似的染色模式类间，相互误判的情况较多，个别类别甚至只能达到 11.4%的准确率，说明形状特征对染色模式图象描述的鉴别力不够强。而本文提出的 CLTP 纹理特征分类准确率能够达到 71.3%，进一步结合 IFV 特征后，准确率提升到 76.4%。这一方面验证了 CLTP 纹理特征具有较强的辨别能力，同时也充分验证了 IFV 形状特征和 CLTP 特征有较强的互补性。

为了进一步验证本文的性能，我们和传统 LBP 方法，以及近年来若干代表性工作进行了对比，其中有经典的 LBP, CLBP 方法，还有 ICPR2012 的胜出者 CoALBP 方法，近年来最新的 PRICoLBP^[11]，PRICoLGBP^[21]，GoC-LBPs+sift^[22]，LC-KSVD^[23]，

表 2 形态学特征在 ICPR2012 细胞集中的混淆矩阵(52.2%)

	Hom	C.Sp	Nuc	Cen	F.Sp	Cyt
Homogeneous	40.0	6.1	1.7	16.7	33.3	2.2
Coarse-speckled	10.9	70.3	1.0	1.0	14.9	2.0
Nucleolar	4.3	43.2	41.7	7.2	0.7	2.9
Centromere	0.0	21.5	18.1	59.7	0.0	0.7
Fine-speckled	29.8	3.5	1.8	21.1	43.9	0.0
Cytoplasmatic	0.0	3.9	7.8	3.9	0.0	84.3

表 3 IFV 特征在 ICPR2012 细胞集中的混淆矩阵(46.1%)

	Hom	C.Sp	Nuc	Cen	F.Sp	Cyt
Homogeneous	63.3	4.4	12.8	6.7	12.8	0
Coarse-speckled	4.9	17.8	7.9	56.4	3.0	10.0
Nucleolar	38.1	2.9	37.4	13.0	8.6	0
Centromere	2.0	16.7	12.8	61.1	2.7	4.7
Fine-speckled	17.5	15.8	13.2	39.5	11.4	2.6
Cytoplasmatic	0	0	0	2.0	0	98.0

表 4 $CLTP_{8,1}^{riu2}$ 特征在 ICPR2012 细胞集中的混淆矩阵(71.3%)

	Hom	C.Sp	Nuc	Cen	F.Sp	Cyt
Homogeneous	73.3	2.2	5.6	8.9	10.0	0.0
Coarse-speckled	2.0	63.4	5.0	3.0	14.8	11.8
Nucleolar	2.9	46.0	50.4	0.0	0.7	0.0
Centromere	0.0	2.0	2.7	93.3	2.0	0.0
Fine-speckled	29.8	2.6	0.9	6.1	59.7	0.9
Cytoplasmatic	0.0	3.9	0.0	0.0	0.0	96.1

表 5 IFV + $CLTP_{8,1}^{riu2}$ 在 ICPR2012 细胞集中的混淆矩阵(76.4%)

	Hom	C.Sp	Nuc	Cen	F.Sp	Cyt
Homogeneous	78.3	1.1	4.4	7.8	8.3	0.0
Coarse-speckled	2.0	68.3	4.0	3.0	1.8	5.0
Nucleolar	2.8	8.6	62.6	0.0	0.7	0.0
Centromere	0.0	2.7	2.7	94.0	0.7	0.0
Fine-speckled	20.1	0.9	1.8	10.5	65.8	0.9
Cytoplasmatic	0.0	2.0	0.0	2.0	0.0	96.1

RIC-LBP^[24]方法，其中分类性能最好的是 GoC-LBPs+sift 方法以及 2015 最新报道的 rootsift+PRICoLGBP^[21]，两者均能达到 75%以上的准确率，测试同样是在 ICPR2012 测试集和竞赛准则上进行的。实验结果给如表 6 所示。其列出了各种方法的 ICPR2012 准确率，可以观察到，由于 CLBP 考虑了更多地信息，其分类性能比 LBP 有较大改善，准

准确率从 48.4%提升到 69.6%。而本文方法远远优于经典的 LBP 和 CLBP 方法,比 PRICoLBP 和 PRICoLGBP 比 ICPR2012 优胜者 CoALBP 高出约 8%以上,和最新的 rootsift+PRICoLGBP 相比,准确率也有 0.8%的提升。同时可以观察到, rootsift 特征融合 PRICoLGBP 后也能有接近 2% 的提升。

为了降低训练样本和测试样本的相关性,通常还需要进行图像级测试。表 7 中包含本文方法以及文献报道的用形态学(图像中颗粒数,面积等)特征^[20]和 GoC-LBPs^[22], LC-SVD^[23]、RIC-LBP^[24]特征的图像级测试结果。LC-SVD 特征和 RIC-LBP 特征在图像级测试的结果要好于其它方法,分别达到 71.4% 和 85.7%,其中 RIC-LBP 特征的 85.7%的准确率也是目前图像级测试最好结果,但是值得注意的是,这两种方法在细胞级测试的结果却并不理想,只有 66.76%和 68.53%, 低于表 6 中大部分其它方法。

由于 ICIP2013 的测试集没有公开,因此很多报道结果都是采用各自的数据划分方式和准则进行测试,本文方法测试的结果也只能做一定的参照。该数据集中训练集共有 13596 幅单通道图片,由于训练样本集偏小,本文方法采用交叉校验的方式进行测试,我们分别选用 2 倍, 5 倍与 10 倍交叉验证方式,分别获得 79%, 79.5%, 78.3%的准确率,如表 8 所示。表 9 中 rootsift+PRICoLGBP^[21]方法,其将

训练集分成两部分,大致选用 8000 幅图片用于训练, 4000 幅用测试,最终测试准确率为 79.5%。其余两种是 ICIP2013 竞赛后报道的结果,它们用到了全部的 13596 张训练图片和 54833 张测试图片,我们选择了其中有代表性的两种方法的结果,其中一个是采用形态学特征的测试结果,其提取了颗粒数量,颗粒面积,空洞数量,目标形状等共 21 个形态学特征信息^[25],准确率为 75%。另一种方法为 ICIP2013 竞赛优胜者的结果,该方法使用了 BoW(sift)模型+CoLBP 特征^[25],准确率达到 83%。

4 总结

本文提出了一种结合纹理和形态学特征的 HEp-2 分类算法。为了获取像素变化的更多信息,本文提出完备局部三值模式(CLTP)算子,而在形状特征选取上,选择了更能与纹理特征相互补充的 IFV 特征,本文方法在 ICPR2012 数据集上做了充分的测试,实验结果表明,在细胞级测试中,本文方法在分类准确率上优于单纯的形状特征和传统的 LBP, CLBP 纹理特征描述方法,相比 CoALBP,最新的 PRICoLBP, PRICoLGBP 准确率也有明显的提升。在图像级测试中,虽然 LC-SVD 和 RIC-LBP 方法有优势,但是其在细胞级测试中性能远低于本文方法。

表 6 ICPR2012 中其他方法与本文方法的对比

方法	LBP _{8,1} ^{rin2}	CLBP _{8,1} ^{rin2}	CoALBP	PRICoLBP	PRICoLGBP	GoC-LBPs + sift
准确率(%)	48.4	69.6	68.7	73.7	73.3	75.1
方法	LC-KSVD	RIC-LBP	CLTP _{8,1} ^{rin2}	rootsift + PRICoLGBP	IFV + CLTP _{8,1} ^{rin2}	
准确率(%)	66.76	68.53	71.1	75.6	76.4	

表 7 图像集测试结果对比

方法	形态学	GoC-LBPs	LC-SVD	RIC-LBP	IFV + CLTP _{8,1} ^{rin2}
准确率(%)	64.3	64.3	71.4	85.7	67.9

表 8 ICIP2013 训练集采用 n 倍交叉验证

n	2	5	10
准确率(%)	79.0	79.5	78.3

表 9 ICIP2013 相关方法结果对比

方法	rootsift + PRICoLGBP	形态学特征	BoW(sift)+CoLBP
准确率(%)	79.5	75.0	83.0

参考文献

- [1] TAALIMI A, ENSAFI S, QI Hairong, *et al.* Multimodal dictionary learning and joint sparse representation for HEp-2 cell classification[C]. 18th International Conference, Munich, Germany, 2015, 9351: 308-315. doi: 10.1007/978-3-319-24574-4_37.
- [2] ENSAFI S, LU Shijian, KASSIM A A, *et al.* Accurate HEp-2 cell classification based on sparse bag of words coding[J]. *Computerized Medical Imaging and Graphics*, 2016. doi:

- 10.1016/j.compmedimag.2016.08.002.
- [3] HOBSON P, LOVELL B C, PERCANNELLA G, *et al.* HEp-2 staining pattern recognition at cell and specimen levels: Datasets, algorithms and results[J]. *Pattern Recognition Letters*, 2016, 82: 12–15. doi: 10.1016/j.patrec.2016.07.013.
- [4] KUSHWAHA AKS, SRIVASTAVA S, and SRIVASTAVA R. Multi-view human activity recognition based on silhouette and uniform rotation invariant local binary patterns[J]. *Multimedia Systems*, 2016: 1–17. doi: 10.1007/s00530-016-0505-x.
- [5] QI Xianbiao, ZHAO Guoying, CHEN Jie, *et al.* HEp-2 cell classification: The role of Gaussian scale space theory as a pre-processing approach[J]. *Pattern Recognition Letters*, 2016, 82(1): 36–43. doi: 10.1016/j.patrec.2015.12.011.
- [6] LIU Anan, LU Yao, SU Yuting, *et al.* HEp-2 cells classification via clustered multi-task learning[J]. *Neurocomputing*, 2016, 195(26): 195–201. doi: 10.1016/j.neucom.2015.06.108.
- [7] PONOMAREV G V and KAZANOV M D. Classification of ANA HEp-2 slide images using morphological features of stained patterns[J]. *Pattern Recognition Letters*, 2016, 82: 79–84. doi: 10.1016/j.patrec.2016.03.010.
- [8] OJALA T, PIETIKAINEN M, and HARWOOD D. A comparative study of texture measures with classification based on featured distributions[J]. *Pattern Recognition*, 1996, 29(1): 51–59. doi: 10.1016/0031-3203(95)00067-4.
- [9] GUO Zhenhua and ZHANG Lei. 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.
- [10] NOSAKA R, OHKAWA Y, and FUKUI K. Feature extraction based on co-occurrence of adjacent local binary patterns[J]. *Advances in Image & Video Technology-Pacific Rim Symposium*, 2011, 7088: 82–91. doi: 10.1007/978-3-642-25346-1_8.
- [11] QI Xianbiao, XIAO Rong, LI Chunguang, *et al.* Pairwise rotation invariant co-occurrence local binary pattern[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 36(11): 2199–2213. doi: 10.1109/TPAMI.2014.2316826.
- [12] VARMA M and ZISSERMAN A. A statistical approach to texture classification from single images[J]. *International Journal of Computer Vision*, 2005, 62(1): 61–81. doi: 10.1007/s11263-005-4635-4.
- [13] HARALICK RM, SHANMUGAM K, and DINSTEN I. Textural features for image classification[J]. *IEEE Transactions on Systems, Man & Cybernetics*, 1973, 3(6): 610–621. doi: 10.1109/TSMC.1973.4309314.
- [14] PINHEIRO A M G. Image descriptors based on the edge orientation[C]. The Fourth International Workshop on Semantic Media Adaptation and Personalization, San Sebastain, Spain, 2009: 73–78. doi: 10.1109/SMAP.2009.27.
- [15] SIM D G, KIM H K, and PARK R H. Invariant texture retrieval using modified Zernike moments[J]. *Image and Vision Computing*, 2004, 22(4): 331–342. doi: 10.1016/j.imavis.2003.11.003.
- [16] BIANCONI F, FERNANDEZ A, and MANCINI A. Assessment of rotation-invariant texture classification through Gabor filters and discrete Fourier transform [C]. Proceedings of 20th International Congress on Graphical Engineering, Valencia, Spain, 2008.
- [17] CATALDO S D, BOTTINO A, ISLAM I U, *et al.* Subclass discriminant analysis of morphological and textural features for HEp-2 staining pattern classification[J]. *Pattern Recognition*, 2014, 47(7): 2389–2399. doi: 10.1016/j.patcog.2013.09.024.
- [18] PONOMAREV G V, ARLAZAROV V L, GELFAND M S, *et al.* ANA HEp-2 cells image classification using number, size, shape and localization of targeted cell regions[J]. *Pattern Recognition*, 2014, 47(7): 2360–2366. doi: 10.1016/j.patcog.2013.09.027.
- [19] STOKLASA R, MAJTNER T, and SVOBODA D. Efficient k-NN based HEp-2 cells classifier[J]. *Pattern Recognition*, 2014, 47(7): 2409–2418. doi: 10.1016/j.patcog.2013.09.021.
- [20] SNELL V, CHRISTMAS W, and KITTLER J. HEp-2 fluorescence pattern classification[J]. *Pattern Recognition*, 2014, 47(7): 2338–2347. doi: 10.1016/j.patcog.2013.10.012.
- [21] QI Xianbiao, XIAO Rong, LI Chunguang, *et al.* HEp-2 cell classification via fusing texture and shape information[OL]. <https://arxiv.org/pdf/1502.04658v1.pdf>.
- [22] THEODORAKOPOULOS I, KASTANIOTIS D, *et al.* HEp-2 cells classification via sparse representation of textural features fused into dissimilarity space[J]. *Pattern Recognition*, 2013, 47(7): 2367–2378. doi: 10.1016/j.patcog.2013.09.026.
- [23] KONG Xiangfei, LI Kuan, CAO Jingjing, *et al.* HEp-2 cell pattern classification with discriminative dictionary learning [J]. *Pattern Recognition*, 2014, 47(7): 2379–2388. doi: 10.1016/j.patcog.2013.09.025.
- [24] NOSAKA R and FUKUI K. HEp-2 cell classification using rotation invariant co-occurrence among local binary patterns[J]. *Pattern Recognition*, 2014, 47(7): 2428–2436. doi: 10.1016/j.patcog.2013.09.018.
- [25] HOBSON P, PERCANNELLA G, VENTO M, *et al.* Competition on cells classification by fluorescent image analysis[OL]. <http://nerone.diiiie.unisa.it/contest-icp-2013-test>, 2013.
- 文登伟: 男, 1990年生, 博士生, 研究方向为图像处理与模式识别。
- 张东波: 男, 1973年生, 博士, 教授, 研究方向为计算机视觉、模式识别。
- 汤红忠: 女, 1979年生, 博士生, 副教授, 研究方向为机器学习、模式识别。
- 许海霞: 女, 1978年生, 博士, 副教授, 研究方向为计算机视觉、机器学习、模式识别。