

基于深度学习的肺结节自动检测算法

李莉 乔璐 张浩洋

(东北林业大学软件工程系 黑龙江 哈尔滨 150000)

摘要 为实现肺结节在 CT 影像中的有效精准识别,降低因医生水平差异造成的漏检、错检现象,提出一种基于深度学习的肺结节自动检测算法。使用阈值法、区域增长算法及形态学处理的方法获得候选结节区域;设计多尺度卷积神经网络模型,自动提取不同大小的肺结节在 CT 影像中呈现出的征象信息,避免由于单一尺度学习不全面引发的漏检现象;将肺结节的平面信息与其空间信息共同作为判定结节的标准,有效排除由于肺内无关组织干扰造成的错检。实验结果表明,算法准确率达到 94.4%,敏感度可达 96.24%。

关键词 深度学习 多尺度卷积神经网络 CT 影像 肺结节检测

中图分类号 TP391.41

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2020.07.015

AUTOMATIC DETECTION ALGORITHM OF PULMONARY NODULES BASED ON DEEP LEARNING

Li Li Qiao Lu Zhang Haoyang

(Department of Software Engineering, Northeast Forestry University, Harbin 150000, Heilongjiang, China)

Abstract In order to realize the effective and accurate identification of pulmonary nodules in CT images and reduce the phenomenon of missed and wrong detection caused by the difference of doctors' level, this paper proposes an automatic detection algorithm of pulmonary nodules based on deep learning. We used threshold method, region growing algorithm and morphological processing method to obtain candidate nodule region; a multi-scale convolutional neural network model was designed to automatically extract the sign information of pulmonary nodules of different sizes in CT images, so as to avoid the phenomenon of missing detection caused by incomplete learning at a single scale; the plane information and spatial information of the pulmonary nodules were taken as the criteria to determine the nodules, effectively eliminating the false detection caused by the interference of unrelated tissues in the lung. The experiments results show that the accuracy (ACC) and sensitivity (SEN) of the algorithm can reach 94.4% and 96.24% respectively.

Keywords Deep learning Multiscale convolutional neural network CT image Pulmonary nodule detection

0 引言

据世界卫生组织 (WHO) 报道,肺癌是全球范围内发病率及死亡率最高的恶性肿瘤之一,近年来仍有逐渐上升的趋势,对人类健康及生命安全产生极大威胁。肺结节是肺癌的早期表现形式,在肺部低剂量胸部电子计算机断层扫描 (CT) 影像中大致呈现为直径在

3~30 mm 之间、边部多呈分叶状的类球形病灶,且肺结节具有形态复杂、分布位置不确定、易于其他组织粘连、临床中无特异性的特点,故临床中有时很难作出准确判断。肺癌计算机辅助诊断^[1-2] (Computer Aided Diagnosis, CAD) 系统的筛选结果可以辅助医生对肺癌早期病灶进行筛查,大幅度降低其发展成肺癌的可能性,从而有效降低患者的死亡率。但在一定程度上肺癌 CAD 系统存在误诊率和假阳率高的问题。因此,如

何使该系统具有较低的误诊率和假阳率一直是国内外研究的重点。

早期的肺结节检测方式主要是根据不同的组织设定不同的阈值来达到分割结节的目的^[3]。这种方式容易受如 CT 影像质量等因素的影响,很难达到准确分割。随后,研究人员手动构建肺结节的几何、纹理以及位置等各类征象信息,使用分类器来达到检测肺结节的目的^[4-5]。但医学影像中器官对射线的吸收程度是通过灰度加以反映,其特征提取操作十分困难^[6]。因此,特征的选择、人工构建征象、分类器的选择及训练工作量十分庞大,很难完成。随着深度学习的广泛应用,将神经网络应用到医学图像检测中使得特征的选择与提取变得容易^[7-8],但若仅依靠 CT 影像中的平面征象信息无法充分了解肺结节的整体结构,易与其他组织产生混淆导致检测结果并不理想。

针对上述问题并鉴于神经网络在医学图像检测领域的显著成效,本文提出一种基于深度学习的肺结节自动检测算法。一方面,设计多尺度卷积神经网络(Convolutional Neural Network, CNN)进行端到端的监督式训练,自动抽取并识别肺结节的各类医学特征及图像学特征,降低开发人员的工作量。CNN 是加强的神经网络,不仅可省去图像预处理、特征提取等复杂过程,在分类性能与效果上也远超过传统分类算法,在计算机视觉领域成效卓然^[9-12]。另一方面,将肺结节在 CT 影像中呈现的征象信息及其空间形状信息共同作为判定病灶的依据,避免了由于在某些横截面上结节与血管的形状均呈现类圆形、阈值类似产生无法准确判断的问题。通过肺结节检测实验证实,使用本文算法有效降低了假阳性,排除了血管的干扰,减少了计算量,达到了肺结节准确识别的目标,相比于以往的医学图像检测算法具有更高的效率和精度。

单个患者一次 CT 断层扫描影像序列可高达上百幅,单靠影像科医生肉眼观察工作量巨大,极易造成因医生水平差异、主观意愿导致的错检漏检。本文现构建肺结节自动检测算法,主要分为两个步骤。步骤一,候选结节区域获取。使用阈值法、区域增长算法及形态学处理的方式获得候选结节区域(Region Of Interest, ROI)。步骤二,假阳性去除。使用多尺度输入的 Inception 肺结节检测模型及 AIP 投影对候选结节进行综合判断从而确定病灶区域。算法流程图如图 1 所示。

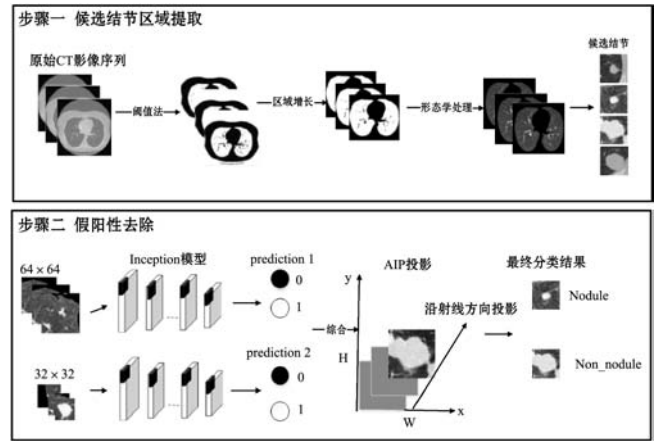


图 1 肺结节检测流程图

1 候选结节区域获取

肺结节检测的首要步骤是尽可能在保证高敏感度 (SEN) 的前提下获得候选结节区域,为后续检测打下良好基础。算法综合使用阈值法、区域增长算法、形态学运算等操作对原始输入图像进行处理。

1.1 基于区域的肺实质粗分割

肺实质主要包括与肺内空气组织接触的腔隙与管壁。从组织结构上看,肺部 CT 影像中绝大部分为气体组织,只有很小一部分由血管及肺结节等肺实质区域组成。从灰度角度看,CT 影像中气体组织与血管和肺结节等肺实质区域存在明显差异。肺部灰度分布如图 2 所示。现使用阈值法将气体组织与血管、气管、肺结节区等肺实质区域分开,获得肺实质区域的初始轮廓。




图 2 肺内灰度分布图

1.2 基于区域增长算法的肺实质精准分割

使用阈值分割法可将胸腔与肺实质区域进行有效分割,且操作简单。对肺部初始轮廓图使用区域增长算法可将肺部背景完全剔除实现肺实质的完整分割。区域增长算法操作简单,其核心问题是种子点的选取,算法采用的种子点选取思想为在肺部 CT 影像的左右肺中心点各选取一个种子点,实现中心点自动区域生

长^[13]。采用此种方式可以避免人工选取的不确定性,在提高算法速度的同时提升分割效率。算法流程如图3所示。

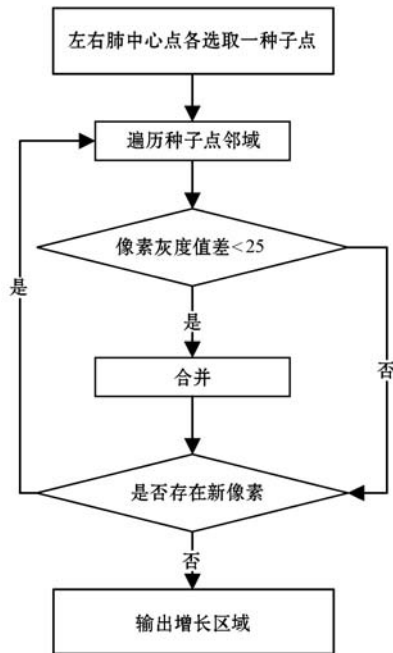


图3 中心点区域增长算法流程图

经上述处理后肺实质区域已被成功提取,但在区域内部出现很多由于肺结节和血管引起的空洞,肺部边缘区域出现了大量毛刺及间断,以及由于容积效应将原本分割的区域连接起来等问题。故随后采用形态学方法中的闭运算进行图像处理,填平肺实质区域中的小孔,弥合小裂缝,消除肺部边缘区域孤立的小点、毛刺及小桥。肺实质的准确提取初步剔除了肺部无关组织的干扰进而获得候选结节区域,为后续肺结节检测奠定了良好的基础。

2 基于深度学习的肺结节检测

步骤一中完成了对候选结节区域的提取,随后对候选结节进行假阳性去除。主要分为两步:首先设计多尺度输入的 Inception 模型利用肺结节的征象信息进行预测并将结果进行平均;随后使用 AIP 投影利用肺结节的三维信息进行最终判断,确定病灶区域。

2.1 多尺度卷积神经网络肺结节检测模型设计

神经网络模仿人脑运行方式,一直是国内外各路学者研究的重点,在图像识别及分类领域上的效果远远超过传统算法。通过设定神经网络合理的输入、输出和隐藏层,可以使构建的网络具备很好的自动学习能力,自动提取和整合图像特征,为获得最优的效果进行不断的反馈优化。

本文使用由美国国家癌症研究会提供的公开肺部图像数据库(Lung Image Database Consortium, LIDC-IDRI)^[14]。目前,此数据库下共包含 1 018 个肺结节病人的 CT 影像,每个病人的 CT 影像切片都高达上百幅,切片均是大小为 512×512 的标准 DICOM 格式,且影像数据资料处于持续增加的状态。现选择 CT 层厚大于 2.5 mm 的病人影像序列,根据 LIDC-IDRI 数据集的 XML 注释文档中标注的肺结节位置信息解析出训练数据。由于肺结节在 CT 影像中呈现出大小为 3 ~ 30 mm 类球形病灶,CT 影像像素间距大致在 0.50 ~ 1.00 之间。因此,本节设计以 64×64 及 32×32 的包含肺结节影像块作为模型输入数据,如图 4 所示。采用这种方式具有两点优势:对于直径较大的肺结节可以保证其全部信息被充分提取;对于直径较小的肺结节则不会让模型学习到太多无用信息影响最终判断。




图4 输入图像样例

模型训练时使用图 4 所示的两种类型数据分别基于 Inception_v3 的权值及参数训练肺结节检测模型用于提取并识别肺结节的各种特征使其具备识别病灶区域及非病灶区域的能力,从而达到区分候选结节的的目的。模型中不需要手动确定卷积核大小以及决定是否建立卷积层及池化层,网络将自己学习它需要什么样的参数,使用何种卷积核及是否需要池化。模型中具有 1×1 、 3×3 及 5×5 的卷积核,通过使用不同尺度的卷积核提取图像不同尺度的特征并将其融合从而达到更好的图像表征。模型测试时以步骤一中候选结节区域质心为中心截取大小为 64×64 及 32×32 的固定区域,将其输入到检测模型中获得对应的概率输出,对概率结果求均值即为初始检测结果。

模型中的卷积层也称特征提取层,负责检测其输入图像的局部特征。一幅图像经过一次卷积操作并通过激活函数后即可得到一幅特征图。当输入图像大小为 64×64 时,某卷积层由 32 个 5×5 的滤波器组成,该输入图像将与每一个滤波器进行卷积计算,得到 32 幅大小为 60×60 的特征图。其卷积操作示意图见图 5,第 n 层的第 j 个特征图的计算公式如下:

$$x_j^n = f\left(\sum_{i \in M_j} x_i^{n-1} \times k_{ij}^n + b_j^n\right) \quad (1)$$

式中: f 为激励函数, M 代表输入特征图的集合, n 代表当前网络的层数, k 为卷积核, b 为偏置值。




图5 卷积操作

模型中的池化层也称降采样层,负责降低网络的复杂度、减少计算量。通常在卷积层后使用,池化操作后特征图的数目不变,维度缩减。输出 32 幅 60×60 的特征图,经过降采样层 1 后将会获得 32 幅 30×30 的特征图。池化操作如图 6 所示,池化计算公式如下:

$$x_j^n = f(\beta_j^n \text{down}(x_j^{n-1}) + b_j^n) \quad (2)$$

式中:down()代表降采样函数,其将输入图像不同 $m \times m$ 的所有像素求和使得输出图像在两个维度上均缩小 m 倍。




图6 池化操作

全连接层通常位于模型的尾部用于整合最后的所有特征图,判定图像的所属类别。模型通过 Softmax 分类器获得预测结果。将两种尺度的肺结节图像输入到模型中即可获得 prediction 1、prediction 2 及对应的概率,将预测概率求均值为该步骤的预测结果,用 0(非病灶)和 1(病灶)表示。在 CT 影像中,肺结节特征主要为边缘形状及边缘周长,但是若仅根据肺结节在 CT 影像中呈现的征象信息进行检测,仍会存一些血管与肺结节难以区分的问题^[15],如在单幅 CT 中存在血管、支气管等组织的征象信息与肺结节征象信息十分类似,很容易对检测结果产生干扰,下一阶段将针对此问题进行研究。

2.2 基于 AIP 投影的肺结节精准检测

AIP 是将连续多帧断层扫描影像序列沿射线方向上所得的所有灰度平均值作为 AIP 投影图像上对应点的灰度值^[16]。AIP 的公式如下:

$$AIP(x,y) = \frac{\sum_{k=1}^N I_k(x,y)}{N} \quad 1 \leq x \leq H, 1 \leq y \leq W \quad (3)$$

式中:AIP(x,y)代表经 AIP 投影后得到的图像中点

(x,y)处的灰度值,N代表进行投影的总层数, $I_k(x,y)$ 代表原始 CT 影像序列图像中第 k 层图像上点(x,y)处的灰度值,H、W 分别代表 CT 影像的横纵像素点数。CT 影像序列进行 AIP 投影的原理如图 7 所示。

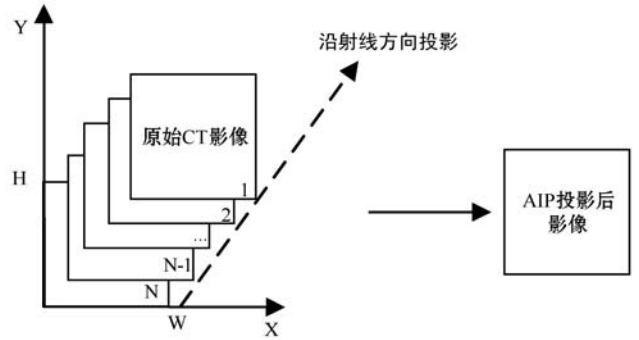



图7 AIP 投影原理图

使用 AIP 投影进行病灶确定时需要处理多幅相邻 CT 影像。其时间复杂度为 $O(uw)$,其中 u 为该区域所占 CT 影像帧数, v 为疑似结节个数。不同区域所占 CT 帧数不同,处理影像的数量不同。肺结节多为 $3 \sim 30$ mm 的类球形病灶,本文采用的 CT 扫描间距均为 2.5 mm。故 AIP 投影只需处理 2 ~ 12 幅连续影像即可,影像数量由肺结节直径决定,其计算公式如下:

$$Num = \lceil r/\beta \rceil \quad (4)$$

式中: r 为肺结节直径, β 为选用的 CT 扫描间距。若肺结节直径为 6 mm,则该区域所占图像帧数应为 3,即仅需处理相邻的三幅图像。图 8 所示为肺结节与血管的空间示意图。由图可知,肺结节在空间中呈现为类球形病灶,而血管等组织为延伸态。在单幅 CT 影像中,血管的某些横截面与肺结节的横截面均呈现类原型。因此,若仅依据影像特征进行判断,会出现一些血管与肺结节在单幅 CT 中无法准确判断的现象。即单使用上述方法无法去除如血管、气管在内的全部干扰。本节利用二者的空间形态特征,对上述步骤检测结果为 1 的区域使用 AIP 投影最终确定该区域是否为病灶。



(a) 肺结节 (b) 血管

图8 肺结节及血管示意图

使用 AIP 投影可以弱化血管的灰度信息,恢复血管的延伸状,从而达到在形状上区分血管和结节的的目的。经处理后可恢复该区域原始空间形状,若为类球形则判定为病灶区域,否则为非病灶区域。

3 实验结果与分析

实验随机抽取 40 套该数据库下的病人 CT 影像数据,以 4 名专业影像科医生的肺结节标记结果作为检测依据。实验中,通过步骤一对 40 个病人进行处理得到 768 个候选结节区域,其中正样本 426 个,负样本 342 个。

3.1 评价标准

为证明肺结节检测的准确性,避免在医学诊断中单从准确率一方面进行算法性能评价的片面性,现从以下角度综合评价算法性能。使用表 1 所示的肺结节检测评价标准,并使用这 4 个标准定义灵敏度 (SEN)、特异度 (SPE)、准确率 (ACC) 及误诊率 (FPF),其公式定义如下:

$$SEN = \frac{TP}{TP + FN} \times 100\% \quad (5)$$

$$SPE = \frac{TN}{TN + FP} \times 100\% \quad (6)$$

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (7)$$

$$FPF = 1 - ACC \quad (8)$$

表 1 肺结节检测评价标准

| 检测结果 | 金标准 | |
|------|-----|----|
| | 阳性 | 阴性 |
| 阳性 | TP | FP |
| 阴性 | FN | TN |

此外使用 AUC 评价模型分类效果,AUC 为 ROC 曲线下的面积,AUC 值越大代表模型分类效果越好(0 < AUC < 1)。

3.2 肺结节识别检测

模型的训练次数与其准确率有着密切关系。图 9 为样本测试的准确率随着训练次数不断变化的曲线,通过观察图像可知,随着迭代次数的不断增加,测试样本的准确率在不断提升,当训练一定次数时,准确率基本稳定在 0.940 左右。




图 9 准确率图

现将经步骤一获得的 768 个候选结节作为测试样本,将其输入对肺结节病灶区域进行初步检测。经模型检测后获得 437 个疑似结节区域。检测结果输出示例如图 10 所示。




图 10 检测结果示例

本节选择文献[3]以及文献[4]与本文算法进行对比,结果如表 2 所示。

表 2 肺结节检测结果比对

| 算法 | 检测结果/% | | | |
|-------|--------|-------|-------|-------|
| | SEN | SPE | ACC | FPF |
| 文献[3] | 85.00 | 40.10 | 68.97 | 31.03 |
| 文献[4] | 92.37 | 73.24 | 85.20 | 14.80 |
| 本文 | 96.24 | 92.11 | 94.40 | 5.60 |

由数据对比可知,使用本文算法可有效提高检测特异度,降低肺结节误诊率。算法不仅依靠 CT 影像中呈现出的征象信息充分了解肺结节的内部结构,还利用肺结节的空间信息获取其整体结构,将其充分区别于其他组织从而获得较好的检测结果。根据表 2 的数据比对,本文算法准确率与误诊率明显优于其他算法,敏感度仅低于文献[4],但算法在保证准确率最高的情况下使得敏感度达到最大。实验结果表明,综合利用肺结节的平面特征与空间特征是一种检测肺结节极为有效的方式。通过实验,有一疑似肺结节区域,轴位图像满足肺结节的征象特征,医生观察该名患者 CT 影像诊断其为肺结节,但算法诊断该名患者并未患病,后经过多名影像科医生反复确认证实该区域确实不是肺结节。有一疑似肺结节区域,处于与肺壁粘连的位置且结节体积较小算法并未检测出。综上,对于孤立性结节及血管与结节在单幅 CT 上极易混淆的,算法具有很好的性能,但对于体积较小的粘连型结节仍会出现漏检的风险。综合考虑,本文算法在敏感度、特异度、准确率和误诊率 4 个指标上均取得了较好的效果,符合临床使用的要求。

4 结 语

针对肺结节假阳性高、血管与肺结节难以区分的问题,本文提出了基于深度学习的肺结节自动检测算法。算法在提取到候选结节的基础上设计多尺度卷积神经网络,基于肺结节的内部结构与整体结构的双重角度综合其平面特征信息与空间形状信息对肺结节进行检测,将非病灶区域充分剔除。实验中,一方面充分发挥神经网络的优势,使其具备自动提取和整合特征的能力、检测效率得以提升;另一方面使用 AIP 投影恢复结节的空间形状,充分剔除肺内无关组织干扰。实验结果表明,采用本文算法进行肺结节病灶检测可以有效降低假阳率,然而对于体积较小的粘连型结节识别率有待提高,仍需进一步研究。

参 考 文 献

- [1] 陈诗慧,刘维湘,秦璟,等. 基于深度学习和医学图像的癌症计算机辅助诊断研究进展[J]. 生物医学工程学杂志, 2017,34(2):314-319.
- [2] 郑光远,刘峡壁,韩光辉. 医学影像计算机辅助检测与诊断系统综述[J]. 软件学报,2018,29(5):1471-1514.
- [3] 石羽,曾晓光,张弘,等. 肺结节自动检测算法研究[J]. 仪器仪表学报,2006,27(6):2265-2267.
- [4] 陈树越,晁亚,邹凌. 基于几何特征的孤立性肺结节检测[J]. 生物医学工程学杂志,2016,33(4):680-685.
- [5] 陈侃,李彬,田联房. 基于局部阈值和聚类中心迭代的肺结节检测算法[J]. 计算机科学,2012,39(2):302-304.
- [6] 梁蒙蒙,周涛,张飞飞,等. 卷积神经网络及其在医学图像分析中的应用研究[J]. 生物医学工程学杂志,2018,36(6):977-985.
- [7] 田娟秀,刘国才,谷珊珊,等. 医学图像分析深度学习方法与挑战[J]. 自动化学报,2018,44(3):401-424.
- [8] 谢志勇,周翔. 基于机器学习的医学影像分析在药物研发和精准医疗方面的应用[J]. 中国生物工程杂志,2019,39(2):90-100.
- [9] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计算机学报,2017,40(6):1229-1251.
- [10] 杨真真,匡楠,范露. 基于卷积神经网络的图像分类算法综述[J]. 信号处理,2018,34(12):1474-1489.
- [11] 李坤成. 加强人工智能深度学习在医学影像学临床应用领域的研究[J]. 中国医学影像技术,2019,35(12):1769-1770.
- [12] 常亮,邓小明,周明全,等. 图像理解中的卷积神经网络[J]. 自动化学报,2016,42(9):1300-1312.
- [13] 陈庆麟. 肺结节计算机辅助诊断系统关键技术研究[D]. 广州:华南理工大学,2016.
- [14] Lii S G A, McLennan G, Bidaut L, et al. The lung image database consortium(LIDC) and image database resource initiative (IDRI): a completed reference databased of lung nodules on CT scans[J]. Medical Physics, 2011, 38(2): 915-931.
- [15] 王彬,赵海,朱宏博,等. 基于CT图像3D特征的肺结节检测[J]. 东北大学学报(自然科学版),2018,39(2):181-185.
- [16] 邱实,汶德胜,冯筠,等. 基于格式塔理论多体位协同的肺结节检测算法[J]. 仪器仪表学报,2015,36(11):2579-2585.

(上接第94页)

- [6] Xiong J, Li H, Meng F, et al. Fast HEVC inter CU decision based on latent SAD estimation[J]. IEEE Transactions on Multimedia,2015,17(12),2147-2159.
- [7] Nalluri P, Alves L N, Navarro A. Complexity reduction methods for fast motion estimation in HEVC[J]. Signal Processing: Image Communication,2015,39:280-292.
- [8] Olivares J, Hormigo J, Villalba J, et al. SAD computation based on online arithmetic for motion estimation[J]. Microprocessors and Microsystems,2006,30(5), 250-258.
- [9] Nalluri P, Alves L N, Navarro A. A novel SAD architecture for variable block size motion estimation in HEVC video coding[C]//International Symposium on System on Chip. IEEE, 2013.
- [10] Nalluri P, Alves L N, Navarro A. High speed SAD architectures for variable block size motion estimation in HEVC video coding[C]//2014 IEEE International Conference on Image Processing(ICIP), Paris. IEEE,2014:1233-1237.
- [11] Tang X L, Dai S K, Cai C H. An analysis of TZSearch algorithm in JMVC[C]//International Conference on Green Circuits & Systems. IEEE, 2010.
- [12] 唐浩漾,程颖涛,郭娜,等. HEVC的异构钻石模板快速搜索算法[J]. 计算机工程与应用,2018,54(18):208-222.
- [13] 刘海华,雷奕,谢长生. 双十字搜索算法的快速块匹配运动估计[J]. 计算机研究与发展,2006,43(9):1666-1673.
- [14] Medhat A, Shalaby A, Sayed M S, et al. A highly parallel SAD architecture for motion estimation in HEVC encoder [C]//IEEE Asia Pacific Conference on Circuits & Systems. IEEE, 2014.
- [15] Alcocer E, Gutierrez R, Lopez-Granado O, et al. Design and implementation of an efficient hardware integer-motion estimator for an HEVC video encoder[J]. Journal of Real-Time Image Processing, 2019,16(2): 547-557.