



# 计算机科学

COMPUTER SCIENCE

## 基于卷积神经网络的虚拟现实视频帧内预测编码

刘月红, 牛少华, 神显豪

引用本文

刘月红, 牛少华, 神显豪. 基于卷积神经网络的虚拟现实视频帧内预测编码[J]. 计算机科学, 2022, 49(7): 127-131.

LIU Yue-hong, NIU Shao-hua, SHEN Xian-hao. [Virtual Reality Video Intraframe Prediction Coding Based on Convolutional Neural Network](#) [J]. Computer Science, 2022, 49(7): 127-131.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

### [全局信息引导的真实图像风格迁移](#)

Photorealistic Style Transfer Guided by Global Information

计算机科学, 2022, 49(7): 100-105. <https://doi.org/10.11896/jsjcx.210600036>

### [基于 DNGAN 的磁共振图像超分辨率重建算法](#)

Super-resolution Reconstruction of MRI Based on DNGAN

计算机科学, 2022, 49(7): 113-119. <https://doi.org/10.11896/jsjcx.210600105>

### [Head Fusion:一种提高语音情绪识别的准确性和鲁棒性的方法](#)

Head Fusion:A Method to Improve Accuracy and Robustness of Speech Emotion Recognition

计算机科学, 2022, 49(7): 132-141. <https://doi.org/10.11896/jsjcx.210100085>

### [融合 RACNN 和 BiLSTM 的金融领域事件隐式因果关系抽取](#)

Implicit Causality Extraction of Financial Events Integrating RACNN and BiLSTM

计算机科学, 2022, 49(7): 179-186. <https://doi.org/10.11896/jsjcx.210500190>

### [基于多尺度特征的脑肿瘤分割算法](#)

Brain Tumor Segmentation Algorithm Based on Multi-scale Features

计算机科学, 2022, 49(6A): 12-16. <https://doi.org/10.11896/jsjcx.210700217>

# 基于卷积神经网络的虚拟现实视频帧内预测编码

刘月红<sup>1</sup> 牛少华<sup>2</sup> 神显豪<sup>1</sup>

1 桂林理工大学信息科学与工程学院 广西 桂林 541004

2 北京理工大学机电学院 北京 100081

(9351747@qq.com)

**摘要** 为了提高虚拟现实视频帧内预测编码的性能,采用卷积神经网络算法进行视频帧编码单元(Coding Unit, CU)选择,从而降低视频图像编码复杂度。首先设置量化参数,获取虚拟现实视频帧样本,接着构建图像编码树,然后建立卷积神经网络(Convolutional Neural Network, CNN)帧编码单元优化模型,将帧样本的图像亮度作为 CNN 的输入,结合图像率失真成本阈值,通过训练获得帧编码单元的优化结果。采用 CNN 训练优化,能够根据图像不同纹理度模块的帧内编码需求,获得不同深度的编码树(Coding Tree Unit, CTU)结构及合适数量的 CU 模块。实验结果表明,通过合理设置卷积核尺寸和量化参数,相比常用视频帧内预测编码算法, CNN 算法能够获得更优的图像质量,在 Balboa 序列中的 BD 码率和编码时间分别为 56 483.76 kbps 和 3 209.24 s。

**关键词:** 帧内编码;虚拟现实;卷积神经网络;编码单元;卷积核尺寸

**中图法分类号** TP317.4

## Virtual Reality Video Intraframe Prediction Coding Based on Convolutional Neural Network

LIU Yue-hong<sup>1</sup>, NIU Shao-hua<sup>2</sup> and SHEN Xian-hao<sup>1</sup>

1 College of Information Science and Engineering, Guilin University of Technology, Guilin, Guangxi 541004, China

2. School of Mechanical and Electrical Engineering, Beijing Institute of Technology, Beijing 100081, China

**Abstract** In order to improve the performance of virtual reality video intraframe prediction coding, convolutional neural network algorithm is used to select video frame coding unit(CU) to reduce the complexity of video image coding. Firstly, quantization parameters are set to obtain the virtual reality video frame samples, then the image coding tree is constructed, and the convolutional neural network (CNN) frame coding unit optimization model is established. The image brightness of frame samples is taken as the CNN input, combined with the image rate distortion cost threshold, the optimization results of the frame coding unit are obtained through training. Using CNN training optimization, the coding tree(CTU) structure with different depths and an appropriate number of CU modules can be obtained according to the intraframe coding requirements of different texture modules of the image. Experiments show that, by reasonably setting the convolution kernel size and quantization parameters, CNN algorithm can obtain better image quality and less coding time than common video intraframe prediction coding algorithms.

**Keywords** Intraframe coding, Virtual reality, Convolutional neural network, Coding unit, Convolution kernel size

虚拟现实技术发展迅速,而虚拟现实视频对视频分辨率要求较高,这给虚拟现实视频编码提出了更严格的要求。视频图像数据的快速编码为虚拟现实视频的实时传输和通信提供技术支持,在视频帧通信的帧内外编码研究过程中,帧内编码的帧信号空间冗余去除效果优势明显,因此通过帧内预测,对相邻帧信号的数据进行预测分析,可以有效提高帧内编码效率。为了保证在提高通信编码效率的同时仍保持较低

的率失真成本,帧内编码优化策略显得尤为重要<sup>[1]</sup>。当前的帧内预测编码分析主要集中在编码单元优化和预测模型优化两个方面。本文的研究着重于编码单元的择优选取,以解决图像样本中因纹理分布不均造成的差异化编码需求问题,既考虑了平坦纹理模块的浅层编码树和少量编码单元的确定,又考虑了纹理复杂的深层编码数和大量编码单元的选取。

到稿日期:2021-11-17 返修日期:2022-03-15

基金项目:国家自然科学基金(61961010);广西自然科学基金(2018GXNSFBA050029, 2020GXNSFAA297255);广西科技重大专项(桂科AA19046004)

This work was supported by the National Natural Science Foundation of China(61961010), Science Foundation of Guangxi Province (2018GXNSFBA050029, 2020GXNSFAA297255) and Guangxi Science and Technology Major Special Project(Gui Ke AA19046004).

通信作者:神显豪(lj\_sxh@sina.com)

当前,关于帧内预测编码分析的研究较多,Zhu等<sup>[2]</sup>重点研究了复杂图像的快速帧内编码策略,并取得了一定的效果,而Yi等<sup>[3]</sup>则重点强调了帧内快速编码的优化效率,两者均提高了帧内编码效率,但率失真成本性能优势并不明显。本文从编码单元择优选取出发,将卷积神经网络(CNN)用于编码单元的优化选取,避免了原始方法因为多次迭代计算率失真成本而造成编码效率低的问题,通过CNN训练有效提高了虚拟现实视频图像的CTU模型确定及CU的获取。

## 1 帧内预测编码

帧内预测编码作为视频编码的一部分,有效去掉了图像的空间冗余问题,帧内编码最重要的环节是编码单元(CU)的划分和预测模式的选择<sup>[4]</sup>,两者共同决定了图像帧编码的准确率,通过对图像帧数据的合适编码和预测模式的选择,能够提高帧数据通信的效率,降低视频编码失真度。

图像一般采用编码树(CTU)来进行分割,CTU结构如图1所示<sup>[5]</sup>,然后对CTU进行CU确定,而CU也可以进一步细分为更多的子编码单元,从而确定预测单元的数量。




图1 CTU结构

Fig.1 CTU structure

根据CTU结构,可以将图像分成不同大小的CU,按照这个方法,生成的树结构可划分为0~3共4层深度,那么根据CTU结构,二维图像对应的平面图划分结构如图2所示<sup>[6]</sup>。




图2 CU结构

Fig.2 CU structure

在对图像进行CU划分时,根据图像的纹理数据,像素平坦的CU划分块较大,而像素复杂的区域CU划分较小,以此避免因丢失重要的图像特征而造成编码后图像失真<sup>[7]</sup>,因此对图像数据的CU划分显得尤为重要。而视频流图像数据量大,对CU的快速且精准划分提出了更高要求,深度学习算法因此成为解决CU自动划分的重要手段。

在完成CU划分之后,接着进行每个CU的预测编码模式选择,帧内预测根据CU内当前像素值来生成下次编码的

像素值,而在色度和亮度上采用预测模式实现帧内预测,其模式结构如图3所示。

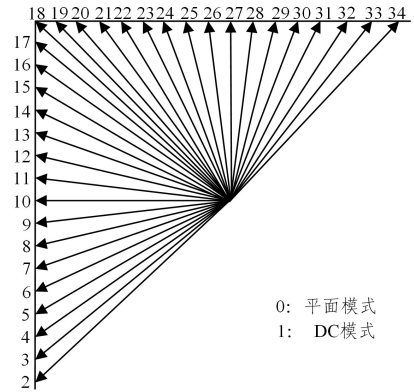


图3 帧内预测模式

Fig.3 Intraframe prediction mode

图3中,平面模式和DC模式分别用于渐变和平坦图像纹理,其他纹理均采用2~34的方向预测模式<sup>[8]</sup>。模式的选择一般采用遍历方式,分别选择不同模式计算图像率失真成本(RD-cost),根据RD-cost的正向排序,选择排名靠前的预测候选模式,并以最可能模式(Most Probable Mode, MPM)作为参照标准。

## 2 神经网络的帧内预测编码

帧内预测编码主要通过帧内的其他像素点预测帧内剩余像素点,在图像数据的预测中,卷积神经网络更具优势,因此本文采用卷积神经网络算法,用于帧内预测编码。

### 2.1 卷积神经网络算法

设文本样本集  $\mathbf{X} = (x_1, x_2, \dots, x_N)$ ,  $m$  个像素样本属性特征通过第  $l$  层卷积运算得<sup>[9]</sup>:

$$x_{lj} = f\left(\sum_{j \in m} x_{l-1} * k_{lj} + b_{lj}\right) \quad (1)$$

其中  $k_{lj}$  和  $b_{lj}$  分别表示第  $l$  层对特征  $j$  赋予的权重及偏置, \* 为卷积,  $f(\cdot)$  为:

$$f(z) = \frac{1}{1 + e^{-z}} \quad (2)$$

对  $N$  个样本的  $m$  个特征进行卷积,卷积核尺寸(Kernel Size)为  $h \times w$ ,按照式(3)进行<sup>[10]</sup>:

$$g(x) = \max_{1 \leq k \leq h \times w} (x_k) \quad (3)$$

令  $M = N / (h \times w)$ ,那么原样本  $\mathbf{X} = (x_1, x_2, \dots, x_N)$  经过卷积池化后重新得到的样本为  $\mathbf{X}' = (x_1, x_2, \dots, x_M)$ 。

然后对  $\mathbf{X}'$  进行转换运算<sup>[11]</sup>:

$$x_j^l = f\left(\sum_{i=1}^M a_{ij} (x_i^{l-1} * k_i^l) + b_j^l\right) \quad (4)$$

$$\text{s. t. } \sum a_{ij} = 1, \quad 0 \leq a_{ij} \leq 1$$

根据式(4)得到CNN的所有连接层,最后选择分类器预测样本类别。

设第  $k$  个节点的输出和实际值分别为  $y_k$  和  $d_k$ ,误差项  $\delta_k$  表示为:

$$\delta_k = (d_k - y_k) y_k (1 - y_k) \quad (5)$$

假设第  $l$  层和第  $l+1$  层分别包含  $L$  和  $P$  个节点,则第  $l$

层节点  $j$  的误差为<sup>[12]</sup>:

$$\delta_j = h_j(1-h_j) \sum_{k=1}^P \delta_k W_{jk} \quad (6)$$

其中,  $h_j$  为输出,  $W_{jk}$  为神经元  $j$  到第  $l+1$  层神经元  $k$  的权重,更新方法为:

$$\Delta w_{jk}(n) = \frac{\eta}{1+N} (\Delta w_{jk}(n-1) + 1) \delta_k h_j \quad (7)$$

其中,  $\eta$  为学习率。

偏置  $\Delta b_k(n)$  的更新方式为:

$$\Delta b_k(n) = \frac{\alpha}{1+N} (\Delta b_k(n-1) + 1) \delta_k \quad (8)$$

其中,  $\alpha$  为偏置更新步长,一般  $\alpha=1$ 。调整后的权重为:

$$w_{jk}(n+1) = w_{jk}(n) + \Delta w_{jk}(n) \quad (9)$$

调整后的偏置为:

$$b_k(n+1) = b_k(n) + \Delta b_k(n) \quad (10)$$

所有节点的误差  $E$  为:

$$E = \frac{1}{2} \sum_{k=1}^M (d_k - y_k)^2 \quad (11)$$

当  $E$  满足设定的阈值,迭代停止,获得稳定的 CNN 模型。

## 2.2 帧内编码流程

选择 CNN 算法对 CTU 进行 CU 划分,首先将图像帧的亮度作为 CNN 输入,通过 CNN 运算,输出 CTU 深度等级;其次根据不同的 CTU 深度分别计算 RD-cost;然后确定参与预测编码的 CU;最后进行预测编码。其主要流程如图 4 所示。

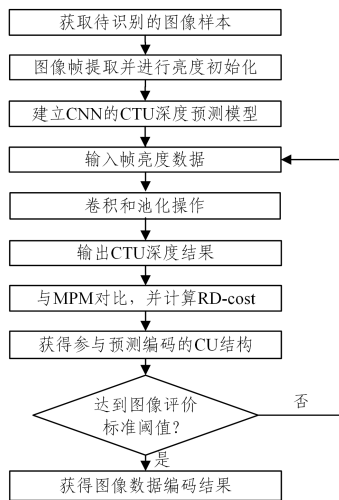


图 4 CNN 的帧内预测编码流程

Fig. 4 Intraframe prediction coding process of CNN

## 3 实例测试

为了验证虚拟现实视频的帧内预测编码性能,采用 CNN 算法对帧内编码预测性能进行测试。首先采用不同的卷积核尺寸对帧内预测编码的准确率进行测试,接着采用不同的帧内预测编码进行实例测试。实验数据集为 JVET 提供的标准测试序列,具体如表 1 所列。构造训练集的方法是将视频文件转换成图片文件,在加标签后把数据存储到 pkl 文件中。直接采用 HEVC 的 CTU 划分结果为 label。软件为 HM16.7 和 matlab2019。

表 1 测试序列

Table 1 Test sequence

编号	名称
1	DrivingInCity
2	AerialCity
3	Balboa
4	Broadway
5	Landing

在对测试图像进行帧提取时,选择的量化参数(Quantization Parameter, QP)值分别为[22, 27, 32, 37],图像质量评价标准为 PSNR 和 WS-PSNR,用  $\Delta T$  来表示相比 HM 软件原始算法的编码时间减少率。

### 3.1 不同卷积尺寸的预测性能

测试的分辨率为 4K,采用不同 kernel size 的 CNN 结构分别对表 1 中的 5 个样本进行测试,验证其视频编码质量和编码时间,结果如表 2—表 4 所列。

表 2 编码性能(卷积核  $2 \times 2$ )

Table 2 Coding performance (convolution kernel  $2 \times 2$ )

数据集	QP	PSNR/dB	WS-PSNR/dB	$\Delta T/\%$
DrivingInCity	22	45.67	44.82	34.61
	27	42.34	41.75	38.35
	33	39.86	39.16	41.24
	37	35.62	34.98	44.17
AerialCity	22	43.31	42.77	25.44
	27	40.96	40.01	28.39
	33	38.24	37.62	32.27
	37	35.85	35.03	34.12
Balboa	22	46.97	46.22	35.13
	27	42.80	42.10	38.53
	33	39.47	39.11	41.67
	37	36.37	35.96	43.27
Broadway	22	46.52	46.06	35.91
	27	42.39	42.12	38.66
	33	39.11	38.75	41.85
	37	35.62	35.01	43.98
Landing	22	45.67	45.23	33.87
	27	42.23	41.89	35.94
	33	39.71	39.12	38.34
	37	36.52	36.07	40.12

表 3 编码性能(卷积核  $3 \times 3$ )

Table 3 Coding performance (convolution kernel  $3 \times 3$ )

数据集	QP	PSNR/dB	WS-PSNR/dB	$\Delta T/\%$
DrivingInCity	22	45.53	44.80	37.18
	27	42.31	41.73	39.12
	33	39.80	39.12	43.06
	37	35.62	34.93	46.22
AerialCity	22	43.30	42.75	27.31
	27	40.95	39.97	29.22
	33	38.22	37.60	33.58
	37	35.83	35.01	35.62
Balboa	22	46.96	46.17	35.83
	27	42.80	42.06	39.21
	33	39.45	39.10	42.24
	37	36.35	35.93	44.18
Broadway	22	46.50	46.03	36.31
	27	42.36	42.10	39.24
	33	39.08	38.72	42.56
	37	35.58	34.97	44.32
Landing	22	45.65	45.21	34.69
	27	42.20	41.86	37.11
	33	39.68	39.11	39.14
	37	36.50	36.03	41.24

表4 编码性能(卷积核 $4\times 4$ )Table 4 Coding performance (convolution kernel  $4\times 4$ )

数据集	QP	PSNR/dB	WS-PSNR/dB	$\Delta T/\%$
DrivingInCity	22	43.21	43.16	39.43
	27	40.07	39.25	40.86
	33	37.75	37.06	44.21
	37	32.62	32.03	46.93
AerialCity	22	40.83	39.77	29.48
	27	37.96	37.01	30.63
	33	35.38	34.79	34.77
	37	32.22	32.08	37.59
Balboa	22	43.38	43.12	36.24
	27	39.27	39.06	40.16
	33	34.62	34.21	43.75
	37	31.58	31.44	45.21
Broadway	22	41.78	41.31	37.19
	27	38.56	38.24	40.26
	33	35.83	35.12	43.05
	37	32.80	32.27	45.11
Landing	22	40.21	39.98	35.27
	27	37.93	37.85	37.96
	33	34.67	34.53	40.97
	37	32.47	32.15	42.15

从表2—表4可以看出,帧提取量化参数QP对图像编码性能影响较大,其原因是,QP越小,帧提取频次越高,因此可以获得更多的图像像素特征,编码粒度越小,对图像细节问题的编码更有效;但是编码时间和编码存储空间成本越高,而QP越小会导致编码的比特数越多,而且编码时间变长,不论CNN的卷积核尺寸大或小,QP对编码质量的影响较小。从表中还可以看出,在相同卷积核尺寸下,相比HM原始算法,不同的QP值对CNN的虚拟现实帧内预测编码时间的影响明显,QP越大,编码预测时间更短,这是因为更多的帧数据参与了预测编码运算,消耗了更多时间。

横向对比卷积核尺寸,在相同的QP条件下,卷积核尺寸与视频编码的PSNR和WS-PSNR值成反比,其原因是,卷积核尺寸小,参与CU划分的图像亮度像素更多,图像编码失真度低;而尺寸增大后,卷积粒度也增大,减少了图像重要特征属性参与卷积及转换运算的机会。卷积核尺寸为 $3\times 3$ 时的PSNR和WS-PSNR比 $2\times 2$ 时略微减小,但是其 $\Delta T$ 性能却得到了较大提升;而相比卷积核尺寸为 $3\times 3$ 时, $4\times 4$ 时的PSNR和WS-PSNR值明显减小,因此本文选择卷积核尺寸 $3\times 3$ 进行CNN的帧内预测编码。

### 3.2 不同算法的编码质量对比

为了进一步验证CNN算法的CU划分及其对整个帧内预测编码质量的影响,分别采用决策树<sup>[13]</sup>、随机森林<sup>[14]</sup>、神经网络<sup>[15]</sup>和CNN算法进行性能测试,所有算法均取QP=22,其帧内编码测试性能结果分别如表5和表6所列。

从表5可知,对于5种测试序列,CNN的帧内编码性能均表现出了最优的PSNR和WS-PSNR性能,其中在Balboa序列中的帧内编码PSNR和WS-PSNR值最高,分别为46.97dB和46.22dB;在相同测试序列中,经过CNN帧内编码后的质量最佳,神经网络和随机森林次之,决策树算法最差,在AerialCity和Landing测试序列中,两者的编码质量非常接近。

表5 4种算法的PSNR和WS-PSNR值

Table 5 PSNR and WS-PSNR values of four algorithms

数据集	算法	PSNR/dB	WS-PSNR/dB
DrivingInCity	决策树	33.95	31.56
	随机深林	41.81	39.62
	神经网络	42.12	40.86
	CNN	45.67	44.82
AerialCity	决策树	34.25	32.44
	随机深林	39.78	38.67
	神经网络	39.61	38.61
	CNN	43.31	42.77
Balboa	决策树	38.56	37.38
	随机深林	41.26	40.67
	神经网络	43.32	42.19
	CNN	46.97	46.22
Broadway	决策树	39.51	39.16
	随机深林	42.83	42.09
	神经网络	44.01	43.25
	CNN	46.52	46.06
Landing	决策树	37.34	36.83
	随机深林	42.55	41.98
	神经网络	42.82	42.27
	CNN	45.67	45.23

表6 BD码率和编码时间

Table 6 BD bitrate and coding time

数据集	算法	BD码率/kbps	编码时间/s
DrivingInCity	决策树	49231.83	2821.03
	随机深林	56317.32	3301.17
	神经网络	55617.35	3125.78
	CNN	56483.76	3209.24
AerialCity	决策树	69347.25	3021.56
	随机深林	85167.85	3582.32
	神经网络	85395.33	3527.46
	CNN	86010.82	3608.73
Balboa	决策树	121413.82	3523.02
	随机深林	182311.34	4172.55
	神经网络	178356.98	4280.21
	CNN	183723.56	4322.67
Broadway	决策树	176624.09	4623.18
	随机深林	211079.47	5379.66
	神经网络	210835.21	5400.93
	CNN	211214.05	5423.85
Landing	决策树	89324.56	4609.37
	随机深林	101234.72	5307.49
	神经网络	100060.38	5200.83
	CNN	101190.92	5221.68

### 3.3 不同算法的编码效率对比


以WS-PSNR为基准,进一步对比4种算法的帧内编码效率,对BD码率和编码时间进行测试,其统计结果如表6所列。从表6可知,在相同条件下即QP=22时,本文算法与随机森林、神经网络算法的BD码率和编码时间非常接近,决策树算法最少,表明决策树算法最节省编码空间与时间,但是其视频质量最差。综合而言,在QP相同的条件下,在BD码率和编码时间相差不大时,CNN算法的视频编码质量最好。

**结束语** 采用CNN算法进行虚拟现实视频图像帧内预测编码单元的选取,可以有效缩短因频繁计算率失真成本的时间,并且获得更优的帧内编码单元,为帧内预测编码提供更有价值的编码模块,提高预测编码的有效性。相比常用图像预测编码算法,本文算法的PSNR和WS-PSNR性能更优。后续研究将着力于解决预测模式优化问题,通过深度学习


算法,选择更优的编码单元预测方向模式,以进一步提高虚拟现实视频的帧内编码预测性能。

### 参 考 文 献

- [1] MA S Q, CHE X P, YU Q, et al. Research on event-based virtual reality user experience evaluation method [J]. Computer Science, 2021, 48(2): 167-174.
- [2] ZHU W, YI Y, WANG T Q, et al. A fast division algorithm of depth image intra coding unit [J]. Computer Science, 2019, 46(10): 286-294.
- [3] YI Q M, XIE Z H, SHI M. a fast decision combination algorithm for hevc intra coding [J]. Small Microcomputer System, 2019, 40(1): 199-204.
- [4] JIN Z P, AN P, YANG C, et al. Post-processing for intra coding through perceptual adversarial learning and progressive refinement[J]. Neurocomputing, 2020, 394: 158-167.
- [5] ZHANG R, JIA K, LIU P, et al. Fast intra-mode decision for depth map coding in 3D-HEVC[J]. Journal of Real-Time Image Processing, 2020, 17(5): 1637-1646.
- [6] JIANG X, XU Q, SUN T, et al. Detection of HEVC Double Compression with the Same Coding Parameters Based on Analysis of Intra Coding Quality Degradation Process [J]. IEEE Transactions on Information Forensics and Security, 2020, 15: 250-263.
- [7] PARASCHIV E G, RUIZ-COLL D, PANTOJA M, et al. Parallelization and improvement of the MDV-SW algorithm for HEVC intra-prediction coding[J]. Journal of Supercomputing, 2019, 75(3): 1150-1162.
- [8] TAI K H, CHEN M J, LIN J R, et al. Acceleration for HEVC Encoder by Bimodal Segmentation of Rate-Distortion Cost and Accurate Determination of Early Termination and Early Split [J]. IEEE Access, 2019, 7: 45259-45273.
- [9] SHARMA A K, CHAURASIA S, SRIVASTAVA D K. Sentimental Short Sentences Classification by Using CNN Deep Learning Model with Fine Tuned Word2Vec[J]. Procedia Computer Science, 2020, 167: 1139-1147.
- [10] ZHOU C, ZHOU J, CAI Y U, et al. Multi-channel Sliced Deep RCNN with Residual Network for Text Classification[J]. Chinese Journal of Electronics, 2020, 29(5): 92-98.
- [11] LIU Y, SUEN C Y, LIU Y, et al. Scene Classification Using Hierarchical Wasserstein CNN[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(5): 2494-2509.
- [12] GUO B, ZHANG C, LIU J, et al. Improving text classification with weighted word embeddings via a multi-channel TextCNN model[J]. Neurocomputing, 2019, 363(21): 366-374.
- [13] HUANG S, SI PT, ZHANG Q Y, et al. Fast intra coding algorithm of hevc SCC based on decision tree [J]. Journal of Optoelectronics • Laser, 2019, 30(4): 420-427.
- [14] REN Y, PENG Z J, CUI X, et al. Fast division of FVC intra coding units combined with random forest [J]. Chinese Journal of Image and Graphics, 2019, 24(5): 724-733.
- [15] ZHAO J, WANG Y, ZHANG Q. Adaptive CU Split Decision Based on Deep Learning and Multifeature Fusion for H. 266/VVC[J]. Scientific Programming, 2020, 2020: 1-11.



**LIU Yue-hong**, born in 1980, master. Her main research interests include fiber optic communication and intelligent hardware and virtual reality.



**SHEN Xian-hao**, born in 1980, Ph. D, professor. His main research interests include deep learning and virtual testing.

(责任编辑:喻黎)