



基于自校准卷积的视网膜 血管分割

答辩人：熊宇

导师：范衡教授

2021/5/30

Contents



1

研究背景

2

相关工作

3

算法设计

4

实验结果

5

总结

6

参考文献


7

**研究生阶段
研究成果**


研究背景



- 糖尿病患病率呈现出增长的态势，而糖尿病引起的视网膜病变是典型的眼科疾病；
- 分析视网膜血管的**形态学特征**可以帮助诊断眼科疾病；
- 视网膜血管分割是提取视网膜血管形态学特征的重要步骤，在医学临床实践中具有重要意义。



视网膜血管分割




研究背景

研究难点



- 血管形态多样，粗细不一，算法对粗细血管的关注度之间的平衡难以寻找；
- 成像缺陷，血管区域像素与背景像素对比度低；
- 病灶图像及眼底周边结构对血管的影响；
- 视网膜眼底图像公开的数据集有限。

针对以上难点，本工作提出的SCCU-Net能较好解决一部分难题，特别是对粗细不一的血管都有良好的分割效果。




形态各异的视网膜血管

- 全卷积神经网络
- 基于编码器解码器的神经网络
 - SegNet
 - UNet
- 注意力机制

相关工作 全卷积神经网络




由于FCN^[1]可以对图像进行像素级的分类，从而作为一种框架被广泛用于语义分割（Semantic Segmentation）问题。



[1] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2015:3431–3440.

SegNet




2015年，剑桥大学团队提出了SegNet^[2]分割网络模型，用于自动驾驶或者智能机器人的图像语义分割。

SegNet在解码器中使用去池化对特征图进行上采样，并在分割中保持高频细节的完整性。编码器不使用全连接层（和FCN一样进行卷积），因此是拥有较少参数的轻量级网络。

- [2] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12):2481-2495.

UNet



U-Net简单地将编码器的特征图拼接至每个阶段解码器的上采样特征图，从而形成一个梯形结构。通过跳跃拼接连接的架构，在每个阶段都允许解码器学习在编码器池化中丢失的相关特征。被广泛应用于医学图像分割领域。

[3] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]// International Conference on *Medical Image Computing and Computer-Assisted Intervention*. Springer, Cham, 2015.

R2UNet





Fig. 4. Different variant of convolutional and recurrent convolutional units (a) Forward convolutional units, (b) Recurrent convolutional block (c) Residual convolutional unit, and (d) Recurrent Residual convolutional units (RRCU).

把RNN和ResNet的结构整合到了encoder-decoder结构里进一步提出循环残余卷积网络，用于医学图像分割，有以下三个特点：

1. 残余网络使得能够训练更深的网络
2. 循环残余卷积层能够使网络提取到更好的特征
3. 使得在拥有相同参数量的情况下，获得了更好的表现

[4]ALOM M Z, HASAN M, YAKOPCIC C, et al. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation[J]. *arXiv preprint arXiv:1802.06955*, 2018.

DEUNet






Fig. 1. Illustration of the Dual Encoding U-Net model-based retinal vessel segmentation. Components of the network architecture contains: Attention Skip Module(ASM), Feature Fusion Module (FFM) and Multiscale Predict Module (MPM).

- Spatial path: 连续四个卷积，采用大stride
- Context path: Inception模块
- ASM: 最简单的Attention方式
- FFM: 特征融合模块
- MPM: 主要做了pixel shuffle操作

[5]WANG B, QIU S, HE H. Dual encoding U-Net for retinal vessel segmentation[M]// *Medical Image Computing and Computer Assisted Intervention – MICCAI 2019*, 22nd International Conference, Shenzhen, China, October 13–17, 2019, Proceedings, Part I. Springer, Cham, 2019.

相关工作

注意力机制




- 注意力机制源于人类视觉系统，当人类在观察外界事物时，最先注意到的往往是人类最关心需要的部分，在计算机领域，为了帮助模型抽取出更加关键重要的信息，我们用**加权**的方式表征注意力机制。
- 按照注意力机制的类型来划分，可分为**硬注意力**（Hard Attention）（不可微分）与**软注意力**（Soft Attention）（可微分）。
- 按照注意力机制关注的域来划分，可以分为**空间域注意力**（Spatial domain attention）、**通道域注意力**（Channel domain attention）和**混合域注意力**（Mixed domain attention）。

相关工作

注意力机制



- 空间域注意力代表工作: Spatial Transformer Networks 2015 NIPS
- 通道域注意力代表工作: SENet 2017 TPAMI
- 混合域注意力代表工作: CBAM 2018 ECCV



SENet注意力机制分成三个部分：挤压(Squeeze)、激励(Excitation)、变换(Scale)。

- 挤压，采用全局平均池化对输入特征图进行处理，得到输出的通道数和输入的特征通道数相同的特征向量；
- 激励，采用包含两个全连接层的bottleneck结构，其中第一个FC层先压缩通道数，第二个的FC层恢复原始的维度，最后采用sigmoid激活函数得到0-1之间的注意力权重；
- 变换，将激励输出的注意力通过逐通道相乘到原始输入的特征上，完成在通道维度上的对原始特征的重标定。




[6] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017:99.

相关工作

注意力机制



Convolutional Block Attention Module



CBAM，混合域注意力：

- 在通道注意力上同时采用最大池化与平均池化得到两个不同描述的特征图，然后将一个隐藏层的多层感知器应用于两个通道，最后通过Sigmoid激活函数获得通道注意力权重图。
- 空间注意力首先在通道上对输入特征进行降维，并利用最大池化与平均池化获得两个的特征描述，然后将这两个特征图经过Concat操作拼接到一起，最后经过卷积操作和激活函数后，可以得到空间注意力权重图。


[7] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]//In Proceedings of the *European Conference on Computer Vision(ECCV)*. 2018:3-19.

相关工作


注意力机制



Self Attention



Non-Local Neural Network



自注意力有三个分支：Q（Query）、K（Key）和V（Value）。计算时通常分为三步：

1. 将Q和每个K进行相似度计算得到权重；
2. 一般使用一个softmax函数对这些权重进行归一化；
3. 将权重和相应的键值V进行加权求和得到最后的注意力权重图。

自注意力（Self Attention）思想最先出现在文本处理中，后来大量自注意力变种结构被广泛应用于图像处理领域。

[8] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Conference and Workshop on *Neural Information Processing Systems(NeurIPS)*. 2017.


[9] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C]//In Proceedings of the IEEE *Conference on Computer Vision and Pattern Recognition(CVPR)*. IEEE, 2018.

相关工作

注意力机制



DANet



应用于分割的双注意力网络，将通道域和空间域并联，并运用Self Attention的思想建立全局上下文关系，显著改善分割效果。


[10] FU J, LIU J, TIAN H, et al. Dual attention network for scene segmentation[C]//In Proceedings of the IEEE Conference on *Computer Vision and Pattern Recognition(CVPR)*. 2019:3146-3154.




- 网络结构设计
- 自校准卷积模块
- 空间注意力模块
- 损失函数

算法设计

网络结构设计



该网络主要由编码部分、改进的空间注意力模块、解码部分构成。



自校准卷积神经网络在两种不同的尺度下进行特征变换，一种是原始比例空间的特征映射，另一种则是使用下采样的空间映射（具有较大感受野），用下采样后的空间映射去指导原始空间的特征提取过程。

$$F'_1 = f_3[\sigma(Up(f_1(Down(F_1)))) \oplus F_1] \otimes f_2(F_1)$$


$$F'_2 = Conv4(F_2) = f_4(F_2)$$

$$F' = Concat\{F'_1, F'_2\}$$

[11] LIU J J, HOU Q, CHENG M M, et al. Improving convolutional networks with self-calibrated convolutions[C]//2020 IEEE/CVF *Conference on Computer Vision and Pattern Recognition(CVPR)*. IEEE, 2020.

算法设计

空间注意力模块



(a) 原始空间注意力

(b) 改进的空间注意力

经过卷积运算后，部分特征图的空间信息将丢失。为了获得更完整的空间信息，我们在改进的空间注意模块中在**执行卷积操作前生成空间注意力图**。这样可以利用更完整的空间特征信息来提高分割性能。

交叉熵损失函数被广泛应用于深度学习网络中，用于处理图像的二分类问题，计算预测某一类或非某一类的概率。损失函数定义如下：

$$Loss = -\sum_i [t_i \log y_i + (1-t_i) \log(1-y_i)]$$

其中， t_i 表示金标准图像第*i*个像素对应的标签，用1表示血管像素，0表示背景像素。网络的输出为图像 y_i ，表示第*i*个像素被分类为1的概率。

实验结果



- 数据集
- 评价指标
- 实验参数设置
- 对比实验结果
- 详细实验结果
- 与先进方法对比

实验结果

数据集



表 4-1 本文选用的彩色视网膜图像公共数据库介绍

数据集	DRIVE	STARE	CHASE DB1
图像总数	40	20	20
训练集数/测试集数	20/20	19/1	20/8
训练集数/验证集数	234/26	162/9	247/13
原图像大小	565×584	700×605	999×960
调整图像后大小	592×592	704×704	1008×1008
数据增强方法	(1)(2)(3)(4)(5)	(2)(3)(4)	(1)(2)(3)(4)(5)

数据增强方法：

- (1) 随机旋转；
- (2) 添加高斯噪声；
- (3) 颜色增强(利用图像亮度，饱和度，对比度变化来增加数据量)；
- (4) 水平、垂直翻转；
- (5) 对角线翻转。

实验结果

评价指标



表 4-2 二分类问题的混淆矩阵

	金标准正类	金标准负类
算法预测正类	真阳性 (True Positive, TP)	假阳性 (False Positive, FP)
算法预测负类	假阴性 (False Negative, FN)	真阴性 (True Negative, TN)

根据得到的混淆矩阵，可以计算不同评价指标。

- 准确率 (Accuracy, ACC)
$$ACC = \frac{TP + TN}{TP + FN + TN + FP}$$
- 敏感度 (Sensitivity, SE)
$$SE = \frac{TP}{TP + FN}$$
- 特异性 (Specificity, SP)
$$SP = \frac{TN}{TN + FP}$$
- F1分数 (F1-score)
$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} = \frac{2 * TP}{2 * TP + FP + FN}$$
- AUC

实验结果

实验参数设置



表 4-4 网络主要参数设置

模块名称	输入尺寸(H×W×C) DRIVE/STARE/CHASE DB1	输出尺寸(H×W×C) DRIVE/STARE/CHASE DB1	网络结构
Encoder_layer1	592×592×3 /704×704×3 /1008×1008×3	296×296×16 /352×352×16 /504×504×16	$\begin{bmatrix} \text{SCC_block} \\ \text{BN + ReLU} \end{bmatrix} \times 2$ Max - Pooling, s = 2
Encoder_layer2	296×296×16 /352×352×16 /504×504×16	148×148×32 /176×176×32 /252×252×32	$\begin{bmatrix} \text{SCC_block} \\ \text{BN + ReLU} \end{bmatrix} \times 2$ Max - Pooling, s = 2
Encoder_layer3	148×148×32 /176×176×32 /252×252×32	74×74×64 /88×88×64 /126×126×64	$\begin{bmatrix} \text{SCC_block} \\ \text{BN + ReLU} \end{bmatrix} \times 2$ Max - Pooling, s = 2
SAM	74×74×64 /88×88×64 /126×126×64	74×74×128 /88×88×128 /126×126×128	SAM
Decoder_layer1	74×74×128 /88×88×128 /126×126×128	148×148×64 /176×176×64 /252×252×64	Transposed_Conv, s = 2 $\begin{bmatrix} \text{SCC_block} \\ \text{BN + ReLU} \end{bmatrix} \times 2$
Decoder_layer2	148×148×64 /176×176×64 /252×252×64	296×296×32 /352×352×32 /504×504×32	Transposed_Conv, s = 2 $\begin{bmatrix} \text{SCC_block} \\ \text{BN + ReLU} \end{bmatrix} \times 2$
Decoder_layer3	296×296×32 /352×352×32 /504×504×32	592×592×16 /704×704×16 /1008×1008×16	Transposed_Conv, s = 2 $\begin{bmatrix} \text{SCC_block} \\ \text{BN + ReLU} \end{bmatrix} \times 2$
Conv_layer1	592×592×16 /704×704×16 /1008×1008×16	592×592×1 /704×704×1 /1008×1008×1	Conv 3×3, s = 1 Sigmoid

- 优化算法：随机梯度下降算法（SGD）
- 学习率：0.001
- 迭代步数：40
- 批量训练数：4

实验结果

对比实验结果



表 4-5 对比实验详细信息


实验/模块	U-Net	SSC	SAM	ISAM	模型大小 (MB)
实验一	√				6.38
实验二	√	√			8.68
实验三	√		√		6.39
实验四	√			√	6.39
实验五	√	√		√	8.69

表 4-6 在 DRIVE 数据集和 CHASE DB1 上的对比实验结果

数据集	实验	ACC	SE	SP	F1	AUC
DRIVE	实验一	0.9646	0.7895	0.9814	0.7963	0.9791
	实验二	0.9665	0.8067	0.9818	0.8084	0.9810
	实验三	0.9659	0.7795	0.9838	0.8001	0.9780
	实验四	0.9663	0.8066	0.9820	0.8089	0.9815
	实验五	0.9680	0.8036	0.9840	0.8138	0.9840
CHASE DB1	实验一	0.9733	0.7817	0.9862	0.7870	0.9810
	实验二	0.9744	0.8158	0.9851	0.8006	0.9872
	实验三	0.9740	0.7933	0.9861	0.7934	0.9859
	实验四	0.9751	0.8052	0.9865	0.8029	0.9843
	实验五	0.9756	0.8118	0.9867	0.8068	0.9888

实验结果

对比实验结果




(d) 相比于U-Net, 加入SCC模块后, 能实现更精确的血管分割;


(e) 相比于U-Net, 加入SAM模块后, 产生了更少的噪声, 但存在对细小血管的漏检情况;

(f) 相对于U-Net+SAM, 加入ISAM后, 在减少噪声的同时能保持更多的细小血管信息;

(g) 相对于前面几组实验结果, 本文方法(SCCU-Net)检测的血管更为准确和连续。



**SCCU-Net是一种有效的
视网膜血管分割算法**




在DRIVE数据集的对比实验视网膜血管分割结果可视化:

- (a) 视网膜眼底图像
- (b) 金标准图像
- (c) 实验一 (U-Net) 算法分割结果可视化图像
- (d) 实验二 (U-Net+SCC) 算法分割结果可视化图像
- (e) 实验三 (U-Net+SAM) 算法分割结果可视化图像
- (f) 实验四 (U-Net+ISAM) 算法分割结果可视化图像
- (g) 实验五 (本文方法) 算法分割结果可视化图像


实验结果

对比实验结果




(a)

(b)




(c)

(d)




(e)

(f)



(g)

U-Net生成的分割结果图像里存在较多区域的血管丢失，而加入自校准卷积模块或改进的空间注意力模块后的分割结果图中，细小血管能较好的被检测出来，但同时也存在小部分区域的血管丢失。由于原眼底图像部分区域血管像素与背景像素的低对比度，导致算法不能很好的检测出细小血管像素。



总体上，SCCU-Net是一种有效的视网膜血管分割算法

在CHASE_DB1数据集的对比实验视网膜血管分割结果可视化：

- (a) 视网膜眼底图像
- (b) 金标准图像
- (c) 实验一（U-Net）算法分割结果可视化图像
- (d) 实验二（U-Net+SCC）算法分割结果可视化图像
- (e) 实验三（U-Net+SAM）算法分割结果可视化图像
- (f) 实验四（U-Net+ISAM）算法分割结果可视化图像
- (g) 实验五（本文方法）算法分割结果可视化图像

实验结果

SCCU-Net详细实验结果




表 4-7 SCCU-Net 在 DRIVE 数据集上的实验结果

	ACC	SE	SP	F1	AUC
最好(19)	0.9730	0.9191	0.9779	0.8497	0.9912
最坏(06)	0.9640	0.7280	0.9895	0.7976	0.9776
平均值	0.9680	0.8036	0.9840	0.8138	0.9840
标准差	0.0028	0.0547	0.0041	0.0172	0.0042

实验结果

SCCU-Net详细实验结果




表 4-8 SCCU-Net 在 STARE 数据集上的实验结果

	ACC	SE	SP	F1	AUC
最好(07)	0.9799	0.8866	0.9877	0.8722	0.9946
最坏(19)	0.9673	0.7071	0.9859	0.7428	0.9709
平均值	0.9728	0.8186	0.9856	0.8179	0.9870
标准差	0.0066	0.0718	0.0044	0.0424	0.0063

实验结果

SCCU-Net详细实验结果




表 4-9 SCCU-Net 在 CHASE DB1 数据集上的实验结果

	ACC	SE	SP	F1	AUC
最好(02)	0.9802	0.8636	0.9867	0.8228	0.9928
最坏(06)	0.9716	0.7334	0.9877	0.7658	0.9839
平均值	0.9756	0.8117	0.9867	0.8068	0.9888
标准差	0.0035	0.0404	0.0022	0.0220	0.0036

实验结果

与先进方法对比



表 4-7 SCCU-Net 与先进视网膜血管分割方法在 DRIVE 上的比较结果

Methods	Year	ACC	SE	SP	F1	AUC
Ricci et al. ^[2]	2007	0.9563	-	-	-	0.9558
Azzopardi et al. ^[35]	2015	0.9442	0.7655	0.9704	-	0.9614
Roychowdhury et al. ^[34]	2016	0.9520	0.7250	0.9830	-	0.9620
Liskowsk and Krawiec. ^[28]	2016	0.9495	0.7763	0.9768	-	0.9720
Li et al. ^[27]	2016	0.9527	0.7569	0.9816	-	0.9738
Fan et al. ^[38]	2016	0.9614	0.7191	0.9849	-	-
MS-NFN ^[64]	2018	0.9567	0.7844	0.9819	-	0.9807
R2U-Net ^[43]	2019	0.9556	0.7792	0.9813	0.8171	0.9784
DEU-Net ^[44]	2019	0.9567	0.7940	0.9816	0.8270	0.9772
SCCU-Net(Proposed)	2021	0.9680	0.8036	0.9840	0.8138	0.9840

实验结果

与先进方法对比



表 4-8 SCCU-Net 与先进视网膜血管分割方法在 STARE 上的比较结果

Methods	Year	ACC	SE	SP	F1	AUC
Ricci et al. ^[2]	2007	0.9584	-	-	-	0.9602
Azzopardi et al. ^[35]	2015	0.9497	0.7716	0.9701	-	0.9563
Roychowdhury et al. ^[34]	2016	0.9510	0.7720	0.9730	-	0.9690
Liskowsk and Krawiec. ^[28]	2016	0.9729	0.8554	0.9862	-	0.9928
Li et al. ^[27]	2016	0.9628	0.7726	0.9844	-	0.9879
Fan et al. ^[38]	2016	0.9588	0.6996	0.9787	-	-
R2U-Net ^[43]	2019	0.9712	0.8292	0.9862	0.8475	0.9914
SCCU-Net(Proposed)	2021	0.9728	0.8186	0.9856	0.8179	0.9870

实验结果

与先进方法对比



表 4-9 SCCU-Net 与先进视网膜血管分割方法在 CHASE DB1 上的比较结果

Methods	Year	ACC	SE	SP	F1	AUC
Azzopardi et al. ^[35]	2015	0.9387	0.7585	0.9587	-	0.9487
Roychowdhury et al. ^[34]	2016	0.9530	0.7201	0.9824	-	0.9532
Li et al. ^[27]	2016	0.9581	0.7507	0.9793	-	0.9793
MS-NFN ^[64]	2018	0.9637	0.7538	0.9847	-	0.9825
R2U-Net ^[43]	2019	0.9634	0.7756	0.9820	0.7928	0.9815
DEU-Net ^[44]	2019	0.9661	0.8074	0.9821	0.8037	0.9812
SCCU-Net(Proposed)	2021	0.9756	0.8117	0.9867	0.8068	0.9888

本文基于端到端的深度学习方法，提出了自校准卷积U-Net（SCCU-Net）算法，在视网膜血管分割任务中实现了较好的结果。本文的贡献点主要包括：

- 针对单一传统卷积操作无法获得不同尺度的感受野，在不显著增加参数量与计算量的情况下，我们将自校准卷积模块结合到U-Net网络中，并提出一种新的端到端的深度神经网络SCCU-Net。
- 我们在CBAM的基础上设计了一种改进的空间注意力模块，该模块通过在卷积操作前计算空间注意力权值图，可以保留更加完整的空间特征信息。
- 本文通过丰富的对比实验验证了所采用方法在视网膜血管分割任务中的有效性。性能评价指标结果说明了我们提出方法的优势，可以实现更好的或可与最先进的视网膜血管分割方法相媲美的结果。

- 在未来，或许可以利用生成对抗网络（GAN）去生成眼底图像训练数据，从而扩大训练所需的数据。
- 本文提出的算法虽然可以检测分割出大部分血管像素，但是针对某些血管与背景像素对比度低的区域、血管较细的像素点，我们提出的算法表现的还不够好，存在一定范围的血管漏检，需要深入研究。
- 在今后的工作中，本文提出的算法模型可以尝试加入模型剪枝技术，减少网络模型参数，以便于移植到移动设备中，开发出集数据提取、数据处理、结果显示一体的移动端视网膜血管检测设备，这将会产生深远的医疗工业应用价值。

参考文献



- [1] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the *IEEE conference on computer vision and pattern recognition*. 2015:3431–3440.
- [2] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12):2481-2495.
- [3] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]// *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, Cham, 2015.
- [4] ALOM M Z, HASAN M, YAKOPCIC C, et al. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation[J]. *arXiv preprint arXiv:1802.06955*, 2018.
- [5] [5]WANG B, QIU S, HE H. Dual encoding U-Net for retinal vessel segmentation[M]// *Medical Image Computing and Computer Assisted Intervention – MICCAI 2019*, 22nd International Conference, Shenzhen, China, October 13–17, 2019, Proceedings, Part I. Springer, Cham, 2019.
- [6] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017:99.
- [7] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]//In Proceedings of the *European Conference on Computer Vision(ECCV)*. 2018:3-19.
- [8] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Conference and Workshop on *Neural Information Processing Systems(NeurIPS)*. 2017.
- [9] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C]//In Proceedings of the *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*. IEEE, 2018.
- [10] FU J, LIU J, TIAN H, et al. Dual attention network for scene segmentation[C]//In Proceedings of the *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*. 2019:3146-3154.
- [11] LIU J J, HOU Q, CHENG M M, et al. Improving convolutional networks with self-calibrated convolutions[C]//2020 IEEE/CVF *Conference on Computer Vision and Pattern Recognition(CVPR)*. IEEE, 2020.

研究生阶段研究成果



一、论文

- 电厂集控室智能监盘机器人软件系统设计与研发[J]. 广东电力, doi:10.3969/j.issn.1007-290X.2020.S1.037

二、专利

- 一种手眼触屏机械臂, 专利号: ZL201921899215.6

三、奖项

- 第十五届中国研究生电子设计竞赛华南赛区二等奖



汕头大学
SHANTOU UNIVERSITY



Thanks!



欢迎各位老师批评指正！