

# 基于PCNN和生成对抗网络的视网膜血管分割方法

罗耀

(广东机电职业技术学院 人工智能学院, 广东 广州 510550)

**摘要:** 视网膜血管分割能为高血压、糖尿病以及青光眼等眼科疾病的确诊和治疗提供支持。利用计算机辅助技术的视网膜血管分割相比人工诊断更容易减少漏诊和误诊的机会。为提高视网膜血管分割准确率,提出基于PCNN和生成对抗网络的视网膜分割的方法。将PCNN和生成对抗网络相结合,将生成对抗网络中的判别器嵌入PCNN为主体的循环结构中。生成对抗网络的博弈竞争机制赋予判别器不断自我升级的动力和活力,而不断改进的判别器为PCNN提供了分割的标准。最后对提出的方法进行定性和定量的分析,实验结果表明其在视网膜血管分割方面具有比较好的表现。

**关键词:** 血管分割;图像处理;PCNN;生成对抗网络

中图分类号: TP183; TP391.41 文献标识码: A 文章编号: 1003-7241(2025)01-0158-05

## Segmentation of Retinal Vessels Based on PCNN and GAN

LUO Yao

(Guangdong Mechanical & Electrical Polytechnic School of Computer Science and Design, Guangzhou 510550 China)

**Abstract:** Retinal vascular segmentation can provide support for the diagnosis and treatment of ocular diseases such as hypertension, diabetes and glaucoma. Compared with manual diagnosis, computer-aided retinal vascular segmentation is easier to reduce the chance of missed diagnosis and misdiagnosis. In order to improve the accuracy of retinal vascular segmentation, a method based on PCNN and GAN is proposed. It combines PCNN with GAN, and embedding the discriminant in the GAN into the loop structure with PCNN as the main body. The game competition mechanism against the network gives the discriminant the power and vitality of continuous self-upgrading, and the constantly improved discriminant provides the segmentation standard for PCNN. Finally, the experimental results show that the proposed method has a good performance in the segmentation of retinal vessels.

**Keywords:** vessels segmentation; image processing; PCNN; GAN

## 0 引言

视网膜血管分割技术已广泛应用于对高血压、糖尿病和一些眼科疾病的诊疗和评估中<sup>[1]</sup>。将机器学习融入图像处理的计算机视觉技术有助于提高图像的处理速度,加速医生临床决策,及时提供精准的治疗方案。

使用机器学习分割视网膜血管的方法从监督参与的程度可以分成三种,即非监督学习方法、监督学习方法及介于以上两者之间的半监督学习方法。非监督学习方法一般使用边缘检测法<sup>[2]</sup>、模型法<sup>[3-4]</sup>和域变换<sup>[5-6]</sup>等传统方法。监督学习方法多采用卷积神经网络的方法<sup>[7-8]</sup>,也有支持向量机<sup>[9-10]</sup>等传统方法的。非监督学习方法大多使用传统的方法<sup>[11-12]</sup>,优点是算法简单容易实现,而且不需要在训练阶段花费大量精力,缺点是较监督学习准确度稍低。监督学习方法比非监督学习方法算法复杂度高,需要的样本量以及在样本上的训练量也较多,但优点是准确度稍高。半监督学习方法主要应用于被标记的样本不

够充足的场景,它的优缺点介于非监督学习方法和监督学习之间。

为精准分割视网膜血管并尽量减少计算量,本文提出基于对脉冲耦合神经网络(Pulse Coupled Neural Network, PCNN)和生成对抗网络(generative adversarial network, GAN)的视网膜血管分割方法(以下简称“PCNN对抗分割”)。PCNN对抗分割创造性地将生成网络中的判别器引入PCNN构造的循环结构中,使它具有了PCNN非监督学习的优点和GAN在博弈对抗中寻求纳什平衡而不断自我升级的活力,并为PCNN对抗分割提供参考依据。另外PCNN对抗分割在传统的PCNN结构外添加其他模块,增强了分割能力。

## 1 PCNN对抗分割

图像预处理对特征的提取质量、图像分析的结果以及图像分割的最后结果有很大的影响。预处理除了对数据集进行归一化的处理外,还需要进行清除噪音和图像增强。

\*基金项目: 广东省特色创新项目(2022KTSCX236)

收稿日期: 2023-09-13

### 1.1 预处理

一般情况下,使用直方图均衡化能较好突出图像细节,但是会付出对比度严重失真的后果。PCNN对抗分割使用对比度受限的自适应直方图均衡化(CLAHE),一方面提高了图像的局部对比度,另一方面避免了图像对比度的严重失真。在消除噪音方面,PCNN对抗分割采用二维旋转双边滤波。双边滤波的核函数将空间域核与像素范围域核相结合,相比高斯滤波,在去除噪音的同时尽量降低对边界的影响。

### 1.2 整体结构

PCNN对抗分割是PCNN和生成对抗网络两大技术的完美结合,训练完生成对抗网络后,将其中的判别器作为PCNN对抗分割的一部分。整体结构如图1所示。




图1 整体结构

传统PCNN已经可以取得较好的分割效果<sup>[13]</sup>,PCNN对抗分割是对传统PCNN的扩展,极大增强了传统PCNN对图像分割的能力。如图1所示,FPF用来检测目标区域,sobel进一步增强区域边界,峰值检测进一步锁定关注的区域,判别器判断是否找到需要的结果,图像生成器一方面修改PCNN的参数,另一方面将生成的中间图像与预处理后的图像相融合,并将结果作为PCNN的输入。

#### 1.2.1 PCNN网络模块

图1中的PCNN是所有神经元的集合。单个神经元模型如图2所示。

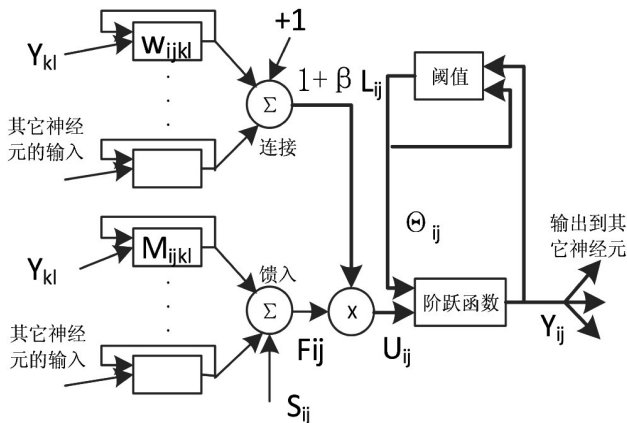


图2 PCNN神经元模型图

每个神经元主要由输入、调制和脉冲产生三个部分组成。其中输入包括连接L和馈入F两部分。馈入部分除了受与本神经元临近的神经元的刺激影响还同时受到

外部刺激S的影响。神经元模型用以下公式描述。

$$F_{ij}[n] = e^{\delta_f} F_{ij}[n-1] + S_{ij} + V_f \sum_{kl} M_{ijkl} Y_{kl}[n-1] \quad (1)$$

$$L_{ij}[n] = e^{\delta_l} L_{ij}[n-1] + V_l \sum_{kl} W_{ijkl} Y_{kl}[n-1] \quad (2)$$

$$U_{ij}[n] = F_{ij}[n](1 + \beta L_{ij}[n]) \quad (3)$$

$$\theta_{ij}[n] = e^{\delta_\theta} \theta_{ij}[n-1] + V_\theta Y_{ij}[n] \quad (4)$$

$$Y_{ij}[n] = \begin{cases} 1, & U_{ij} > \theta_{ij}[n-1] \\ 0, & otherwise \end{cases} \quad (5)$$

式中, $F_{ij}[n]$ 和 $L_{ij}[n]$ 分别表示 $[i,j]$ 神经元的馈入输入和连接输入。 $S_{ij}$ 表示外部刺激输入,其值为图像中 $[i,j]$ 位置灰度值的大小,它决定了 $[i,j]$ 神经元在一个循环周期内的点火时间。 $M_{ijkl}$ 和 $W_{ijkl}$ 分别表示馈入和连接的链接矩阵,其值大小表征了相邻神经元对当前神经元的影响程度。馈入和连接的状态值以二阶方式生成神经元内部状态 $U_{ij}[n]$ 。 $\theta_{ij}[n]$ 为动态阈值, $Y_{ij}[n]$ 为输出。

PCNN的优点明显,但是缺点也很明显,它没有明显的停止信号,不能自我终止。一般情况下PCNN需要人为配置循环次数作为最终结束条件,这种通过经验设置的参数带有很大的人为因素,具有较大的随意性,生成对抗网络由于具有特殊的结构,同时具有生成器和判别器,通过不断博弈可以得到一个不错的判别器。PCNN对抗分割的提出就是将生成对抗网络中的判别器作为PCNN是否结束的判别器。

#### 1.2.2 FPF滤波器模块

图1中的FPF(Fractional Power Filter)是分数幂指数滤波器,它是一种可以在鉴别能力和泛化能力之间寻找平衡的合成滤波器,这种滤波器的合成特性使得滤波器在生成时就具有一定的不变性。FPF不仅能够适应目标形状不可预测,还能适应目标的尺度、变形。亮度等的变化。FPF甚至还能用来检测不同的目标。FPF是一个通过X矩阵创建的滤波器,X矩阵的列数据是多个训练图像样本通过傅里叶变换得来的。滤波器公式如下所示。

$$FPF = D^{-0.5} Y [Y^T Y]^{-1} c \quad (6)$$

$$Y = D^{-0.5} X \quad (7)$$

$$D_{ij} = \frac{\sigma_{ij}}{N} \sum_k |X_{ki}|^\alpha, \alpha = [0, 2] \quad (8)$$

式(6)中c为约束向量。式(8)中当 $\alpha=0$ 时,FPF成为了合成鉴别滤波器,此时其泛化能力最强;当 $\alpha=2$ 时,FPF成为了最小平均相关能量滤波器,此时鉴别能力最强;当 $\alpha$ 值在0到2之间变化的过程就是FPF在鉴别能力与泛化能力之间平衡的过程。PCNN对抗分割中的 $\alpha$ 设置为0.8。

#### 1.2.3 Sobel算子模块

在图1的循环结构中,FPF滤波器对目标进行边缘增强后,PCNN对抗分割继续使用Sobel对目标对象边缘

进行增强,公式如下所示。

$$G_x = \begin{pmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{pmatrix} \quad (9)$$

$$G_y = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix} \quad (10)$$

$$G = \sqrt{(I \otimes G_x)^2 + (I \otimes G_y)^2} \quad (11)$$

式中, $I$ 为输入图像, $\otimes$ 为卷积运算符, $G_x$ 为水平Sobel算子,用以增强水平方向的边缘, $G_y$ 为垂直Sobel算子,用以增强垂直方向的边缘。一般情况下,每次循环到这里都会在相应的位置产生一个较亮的峰值,同时其他位置也可能产生接近这个峰值的区域。为了排除不必要的干扰锁定正确的区域,PCNN对抗分割采用峰值-相关能量(PCE)进行峰值检测,排除非相关能量区域,如式(12)所示。

$$P_{ij} = \frac{C_{ij}}{\sum_{k=i-\delta}^{i+\delta} \sum_{l=j-\delta}^{j+\delta} |G_{kl}|^2} \quad (12)$$

式中, $C_{ij}$ 表示坐标为 $(i,j)$ 的点的值, $\delta$ 为一个很小的区域的半径。峰值检测锁定了本次循环关注的区域。

### 1.2.4 判别器模块

判别器是PCNN对抗分割结构中重要组成部分,它是从GAN(如图3)移植过来的,移植前需要训练GAN,训练的过程就是GAN的优化过程。




图3 GAN结构图

GAN优化问题就是一个极小化生成器极大化判别器的问题,目标函数如下式(13)所示。

$$\min_G \max_D \text{LOST}(\theta_D, \theta_G) = A + B \quad (13)$$

其中:

$$A = \frac{1}{2} E_{x \sim P_{data}(x)} (\log D(x)),$$

$$B = \frac{1}{2} E_{z \sim P_z(z)} (\log(1 - D(G(z))))$$

$G$ 表示生成器, $D$ 表示判别器, $x$ 表示数据, $z$ 表示噪声。在生成器中使用ResU-net,判别器中使用VGG16。

ResU-net是以Unet网络结构为基础,引进残差网络结构。残差网络结构的引进一方面简化了网络的训练,另一方面减少图像处理过程中梯度消失的现象。ResU-net采用交叉熵损失函数diceloss作为损失函数,公式如式(14)所示。

$$\text{LOSS} = C + D \quad (14)$$

式中: $C = -[y \log y^* + (1-y) \log(1-y^*)]$ ,  $D = (1-2(y \wedge y^*)) / (y + y^*)$ ,  $y$ 是图像标签值, $y^*$ 是预测结果。

VGG16是PCNN对抗分割中判别器的重要组成部分。它一共有13个卷积层,3个全连接层,还有5个最大值池化层。所有卷积层均采用3\*3的卷积核。判别器使得PCNN对抗分割具有了判别结果的能力。

峰值检测锁定的目标区域进入判别器进行判断,如果是所需图像则结束整个过程。如果不是所需图像则循环继续,接下来需要通过图像发生器一方面修改PCNN的阈值,如式(15)所示。另一方面需要修改输入图像,即如式(16)所示将峰值图像与输入图像融合。

$$\theta[n:i, j] = \begin{cases} 0.9\theta[n-1:i, j], & K[i, j]=1 \\ \theta[n-1:i, j], & \text{otherwise} \end{cases} \quad (15)$$

$$J[n:i, j] = 0.9 * J[n-1:i, j] + 0.15 * K[i, j] \quad (16)$$

如前所述完成了一次循环,紧接着进入下一轮循环,一直到判别器判断出处理的图像满足要求则退出循环,满足判别器要求的图像就是最后的结果。

## 2 实验

### 2.1 数据集

为了验证PCNN对抗分割的有效性,使用DRIVE(digital retinal images for vessel extraction),数字视网膜图像血管提取)数据集进行试验,DRIVE数据集是Niemeijer团队在2004年根据荷兰糖尿病视网膜病变筛查工作建立的彩色眼底图像库,图像库共40张图片,每幅图像为565×584像素,而且除了各自都有自己专门的mask图外还分别被2组医生手工标注分割<sup>[5,18]</sup>。

为减少人为因素对实验的影响并解决数据过少带来的问题,本实验采用其中的一组数据,并将原始图融合mask图,然后经行镜像、旋转、平移等方法的综合运用得到更多的训练样本。

### 2.2 评价指标

实验中采用通用的几个指标评价实验结果:敏感性S(Sensitivity)、准确性A(Accuracy)和F1-Score)。指标定义如下式所示。

$$S = \frac{TP}{TP + FN} \quad (17)$$

$$A = \frac{TP + TN}{TP + FN + FP + TN} \quad (18)$$

$$F1-Score = \frac{2 * S * \frac{TP}{TP + FP}}{S + \frac{TP}{TP + FP}} \quad (19)$$

式中,TP(True Positive,真阳性)表示将血管正确分类的像素点数,FP(False Positive,假阳性)表示将背景错误分类的像素点数,TN(True Negative,真阴性)表示将背景

正确分类的像素点数, FN(False Negative, 假阴性)表示将血管错误分类的像素点。

### 2.3 实验过程

PCNN对抗分割在使用前需要首先训练出判别器。判别器的训练过程是生成对抗网络的训练过程。流程如下:(1)固定生成器,生成器以预处理后的图像为输入,生成图像分割结果。(2)以生成器生成的结果和医生们标注的结果输入判别器,以减少判别器损失函数为目标,优化判别器中 vgg16网络,不断提高判别器的判断能力。(3)重复前面两个步骤。(4)固定判别器,以ResUnet将预处理后的图像输入生成器,以医生们标注的结果为参照,以减少生成器损失函数为目标,优化生成器中的ResUnet网络,不断提高生成器的输出水平。(5)重复上述四个步骤直到生成对抗网络的损失函数降到满意值。将训练好的判别器与PCNN合成如图4所示的结构。




图4 测试结果

图4展示了测试效果。其中A列为原图, B列为原图经过CLAHE后的结果, C列为双边滤波结果, D列为医生手工分割图, E列是PCNN对抗分割最后结果。为了更加清晰观察对比PCNN对抗分割和医生手工分割的结果,将图4中的第一条样本的D列和E列图像放大如图5所示。从图5分割结果看(右边是PCNN对抗分割结果,左边是医生手工分割结果),PCNN对抗分割得到的分割图在某些细节上强于医生的手工分割图。




图5 细节比较

为进一步确定分割效果,表1比较了PCNN对抗分割和其他几种分割方法的敏感性、准确性和F1-Score这3个指标。可以看出,PCNN对抗分割在敏感性方面略弱于DEU-Net方法但强于表中的其它方法,而且PCNN对

抗分割在准确性和F1-Score方面均强于表1中列出的其它方法。

表1 对比表

方法	敏感性	准确性	F1-Score
U-Net <sup>[14]</sup>	0.784 9	0.955 4	0.817 5
DEU-Net <sup>[15]</sup>	0.807 4	0.966 1	0.803 7
DUNet <sup>[16]</sup>	0.796 3	0.956 6	0.823 7
RVSeg-Net <sup>[17]</sup>	0.806 9	0.972 6	N.A
PCNN <sup>[13]</sup>	0.703 9	0.939 6	N.A
GAN <sup>[18]</sup>	0.797 4	0.960 5	N.A
PCNN对抗分割	0.807 1	0.973 2	0.825 6

以上实验结果表明,不论从单个样本分割结果,还是从敏感性、准确性和F1-Score这3个指标来看,PCNN对抗分割在视网膜血管分割方面具有比较好的优势。

### 3 结束语

为准确分割视网膜血管,本文提出了基于PCNN对抗网络的分割方法,将PCNN网络与对抗网络相结合,将对抗网络中的判别器嫁接到以PCNN为主体的反复循环的结构中。其中,判别器为PCNN对抗分割指定了学习的标准,减少低效的垃圾数据学习时间,让它具有判断的“智能”。实验表明PCNN对抗分割在视网膜血管分割方面具有比较好的表现。

#### 参考文献:

- [1] Fraz M M, Remagnino P, Hoppe A, et al. Blood vessel segmentation methodologies in retinal images—a survey [J]. Computer Methods & Programs in Biomedicine, 2012, 108(1): 407–433.
- [2] Saha Tchinda Beaudelaire, Tchiotsop Daniel, Noubom Michel, Louis-Dorr Valerie, Wolf Didier. Retinal blood vessels segmentation using classical edge detection filters and the neural network [J]. Informatics in Medicine Unlocked, 2021(23) (prepublish): 135–159.
- [3] Escorcia-Gutierrez Jos é, Torrents-Barrena Jordina, Gamarra Margarita, Romero-Aroca Pedro, Valls Aida, Puig Domenec. Convexity shape constraints for retinal blood vessel segmentation and foveal avascular zone detection [J]. Computers in Biology and Medicine, 2020(127): 104–153.
- [4] Ahsan Khawaja, Tariq M. Khan, Mohammad A. U. Khan, Syed Junaid Nawaz. A Multi-Scale Directional Line Detector for Retinal Vessel Segmentation [J]. Sensors, 2019, 19(22): 4949–4961.
- [5] Ramos-Soto Oscar, Rodríguez-Esparza Erick, Balcera-Mata Sandra E., Oliva Diego, Hassanien Aboul Ella, Meleppat Ratheesh K., Zawadzki Robert J. An efficient retinal blood vessel segmentation in eye fundus images by using optimized top-hat and homomorphic filtering [J]. Computer Methods and Programs in Biomedicine, 2021(201): 1014–1045.
- [6] Nogol Memari, Abd Rahman Ramli, M. Iqbal Bin Sar-

ipan, Syamsiah Mashohor, Mehrdad Moghbel. Retinal Blood Vessel Segmentation by Using Matched Filtering and Fuzzy C-means Clustering with Integrated Level Set Method for Diabetic Retinopathy Assessment[J]. Journal of Medical and Biological Engineering, 2019, 39(5): 784-805.

[7] Nasser Tamim, M. Elshrkawey, Gamil Abdel Azim, Hamed Nassar. Retinal Blood Vessel Segmentation Using Hybrid Features and Multi-Layer Perceptron Neural Networks [J]. Symmetry, 2020, 12(6): 894-919.

[8] Toufique Ahmed Soomro, Ahmed J. Afifi, Junbin Gao, Olaf Hellwich, Lihong Zheng, Manoranjan Paul. Strided fully convolutional neural network for boosting the sensitivity of retinal blood vessels segmentation[J]. Expert Systems With Applications, 2019(134): 735-767.

[9] T. Jemima Jebaseeli, C. Anand Deva Durai, J. Dinesh Peter. Retinal blood vessel segmentation from diabetic retinopathy images using tandem PCNN model and deep learning based SVM[J]. Optik, 2019(199): 1241-1275.

[10] Sukhpreet Kaur, Kulwinder Singh Mann. Retinal Vessel Segmentation Using an Entropy-Based Optimization Algorithm[J]. International Journal of Healthcare Information Systems and Informatics (IJHISI), 2020, 15(2): 698-719.

[11] Sayed Md. Abu, Saha Sajib, Rahaman G. M. Atiqur, Ghosh Tanmai K., Kanagasingham Yogesan. An innovate approach for retinal blood vessel segmentation using mixture of supervised and unsupervised methods[J]. IET Image Processing, 2020, 15(1): 546-571.

[12] 贾洪, 郑楚君, 李灿标, 王文斌, 许言兵. 基于局部线结构约束的FCM聚类视网膜血管分割[J]. 光学学报, 2020, 40(9): 40-49.

[13] 徐光柱, 王亚文, 胡松, 陈鹏, 周军, 雷帮军. PCNN与形态匹配增强相结合的视网膜血管分割[J]. 光电工程, 2019, 46(4): 74-85.

[14] 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. Munich: Springer, 2015: 234-241.

[15] Wang B, Qiu S, He H. Dual Encoding U-Net for Retinal Vessel Segmentation[C]. // LNCS 11764: Proceedings of the 22nd International Conference on Medical Image Computing and Computer-Assisted Intervention, Shen-zhen, China, Oct 13-17, 2019. Springer, 2019: 84-92.

[16] Qiangguo Jin, Zhaopeng Meng, Tuan D. Pham, Qi Chen, Leyi Wei, Ran Su. DUNet: A deformable network for retinal vessel segmentation[J]. Knowledge-Based Systems, 2019(178): 149-162.

[17] Wang W, Zhong J, Wu H, et al. RVSeg-Net: An Efficient Feature Pyramid Cascade Network for Retinal Vessel Segmentation[C]. // LNCS 12265: Proceedings of the 23rd International Conference on Medical Image Computing and Computer-Assisted Intervention, Lima, Peru, Oct 4-8, 2020. Springer, 2020: 796-805.

[18] 李孟歆, 徐睿, 张天慧, 陈莉, 郝佳丽. 一种基于超像素和生成对抗网络的视网膜血管分割方法[J]. 集成技术, 2020, 9(6): 21-28.

作者简介: 罗耀(1972-), 男, 硕士, 讲师, 研究方向: 图像处理和人工智能。

(上接第118页)

研究[J]. 电力系统保护与控制, 2020, 5(42): 98-112.

[4] 张思彤, 梁纪峰, 马燕峰, 赵书强, 李铁成. 直驱风电场经柔性直流输电并网的宽频振荡特性分析[J]. 电力系统保护与控制, 2022, 50(14): 34-46.

[5] 卢晓光, 李风格. 基于数字孪生的风机实时载荷预估研究[J]. 机械与电子, 2021(6): 24-28.

[6] 黄云辉, 王凌云, 喻恒凝, 王栋, 朱国荣, 黄云虹. 弱电网下双馈风力发电系统的稳定性极限研究[J]. 电力工程技术, 2022, 41(4): 9-17.

[7] 彭技礼, 贾祺, 严干贵, 等. 面向低频振荡分析的直驱风电机组阻尼转矩建模[J]. 电力自动化设备, 2022, 42(8): 39-46.

[8] 徐询, 谢丽蓉, 叶林, 等. 基于非参数核密度估计的风电场有功功率双层优化模型[J]. 电力系统自动化, 2022, 46(2): 43-55.

[9] 万书亭, 程侃如, 绳晓玲, 等. 基于风速时空分布的双馈风力发电机组叶轮质量不平衡故障特性分析[J]. 太阳能学报, 2021, 46(9): 236-243.

[10] 陈振宇, 刘吉臻, 林忠伟, 等. 风电机组动态尾流频域特性分析与建模[J]. 智慧电力, 2020, 48(7): 1-7, 37.

作者简介: 卢晓光(1983-), 男, 硕士, 高级工程师, 研究方向: 机电一体化方向设计与研发。

(上接第131页)

市建设三维模型快速创建[J]. 中国给水排水, 2020, 36(12): 111-116.

[11] 祝兵, 张云鹤, 赵雨佳, 等. 基于BIM技术的桥梁工程参数化智能建模技术[J]. 桥梁建设, 2022, 52(2): 18-23.

[12] 方博, 岳晓峰, 袁晓磊, 等. 基于自适应分辨率的点对特征点云配准算法[J]. 机械制造与自动化, 2022, 51(3): 113-116.

[13] 李科. 基于PSO-KNN的变电站设备三维点云识别方法研究[J]. 电力系统保护与控制, 2021, 49(18): 182-187.

[14] 周圣栋, 解蕾, 宋若晨, 等. 基于BIM的变电站数字化建设

管控平台构建及应用[J]. 中国电力, 2019, 52(5): 142-147.

[15] 朱德利, 杨德刚, 万辉, 等. 用于低照度图像增强的自适应颜色保持算法[J]. 计算机工程与应用, 2019, 55(24): 190-195, 213.

作者简介: 陈楚炼(1992-), 男, 本科, 工程师, 研究方向: 牵引供电。