

## 基于 Light-BotNet 的激光点云分类研究\*

雷根华<sup>1</sup>, 王蕾<sup>1,2</sup>, 张志勇<sup>1</sup>

(1. 东华理工大学 信息工程学院, 江西 南昌 330013;

2. 江西省核地学数据科学与系统工程技术研究中心, 江西 南昌 330013)

**摘要:** 三维点云在机器人与自动驾驶中都有着普遍的应用, 深度学习在二维图像上的研究成果显著, 但是如何利用深度学习识别不规则的三维点云, 仍然是一个开放性的问题。目前大场景点云自身数据的复杂性, 点云扫描距离的变化造成点的分布不均匀, 噪声和异常点引起的挑战性依然存在。针对于现有的深度学习网络框架对于激光点云数据的分类效率不高以及分类精度低的问题, 提出一种基于激光点云特征图像与 Light-BotNet 相结合的 CNN-Transform 框架。该框架在于通过对点云数据进行特征提取, 以相邻的特征点构造点云特征图像作为网络框架的输入, 最后以 Light-BotNet 为网络框架模型进行点云分类训练。实验结果表明, 该方法与现有的多数点云分类方法相比, 能够较好地提升激光点云的分类效率以及分类精度。

**关键词:** 点云特征图像; BotNet; Transform; CNN; 激光点云分类

中图分类号: TP391

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.222725

中文引用格式: 雷根华, 王蕾, 张志勇. 基于 Light-BotNet 的激光点云分类研究[J]. 电子技术应用, 2022, 48(6): 84-88, 97.

英文引用格式: Lei Genhua, Wang Lei, Zhang Zhiyong. Research on laser point cloud classification based on Light-BotNet[J]. Application of Electronic Technique, 2022, 48(6): 84-88, 97.

## Research on laser point cloud classification based on Light-BotNet

Lei Genhua<sup>1</sup>, Wang Lei<sup>1,2</sup>, Zhang Zhiyong<sup>1</sup>

(1. School of Information Engineering, East China University of Technology, Nanchang 330013, China;

2. Jiangxi Engineering Technology Research Center of Nuclear Geoscience Data Science and System, Nanchang 330013, China)

**Abstract:** Three dimensional point clouds are widely used in robots and automatic driving. The research results of deep learning on two-dimensional images are remarkable, but how to use deep learning to identify irregular three-dimensional point clouds is still an open problem. At present, due to the complexity of the data of the scenic spot cloud itself, the uneven distribution of points caused by the change of the scanning distance of the point cloud, and the challenges caused by noise and abnormal points still exist. Aiming at the problems of low classification efficiency and low classification accuracy of the existing deep learning Network framework for laser point cloud data, a CNN Transform framework based on laser point cloud feature image and Light-BotNet is proposed. The framework is to extract the features of point cloud data, construct the point cloud feature image with adjacent feature points as the input of the network framework, and finally take Light-BotNet as the network framework model for point cloud classification training. The experimental results show that compared with most existing point cloud classification methods, this method can better improve the classification efficiency and accuracy of laser point cloud.

**Key words:** point cloud feature image; BotNet; Transform; CNN; laser point cloud classification

## 0 引言

大多数的深度学习点云分类方法都是采用卷积层与池化层交替实现的, 卷积层中的神经元仅与上一层的部分区域相连接, 学习局部特征, 在点云数据特征提取时容易丢失部分特征, 从而导致分类精度下降等问题。而 Transform 的提出则带来了一种新的思路, 主要利用自我注意机制提取内在特征<sup>[1-3]</sup>。Transform 最初应用在自然

语言处理(NLP)领域, 并且取得了重大的成功, 受到 NLP 中 Transformer 功能的启发, 研究人员开始将 Transformer 应用在计算机视觉(CV)任务。研究发现 CNN 曾是视觉应用的基本组件<sup>[4-5]</sup>, 但 Transformer 正在显示其作为 CNN 替代品的能力。Chen 等人<sup>[6]</sup>训练序列变换器, 以自回归预测像素, 并在图像分类任务上与 CNN 取得竞争性结果。卷积操作擅长提取细节, 但是在大数据量的大场景三维点云数据分类任务中, 要掌握三维点云的全局信息往往需要堆叠很多个卷积层, 而 Transform 中的注意力善

\* 基金项目: 国家自然科学基金(61561003, 61761003); 江西省核地学数据科学与系统工程技术研究中心基金(JETRCNGDSS201902)

于把握整体信息,但又需要大量的数据进行训练。

BotNet<sup>[7]</sup>网络是伯克利与谷歌的研究人员在 Convolution+Transformer 组合方面一个探索,它采用混合方式同时利用了 CNN 的特征提取能力、Transformer 的内容自注意力与位置自注意力机制,取得了优于纯 CNN 或者自注意力的性能,在 ImageNet 中取得了 84.7% 的精度。将 CNN 与 Transform 结合起来,达到取长补短的效果。BoTNet 与 ResNet<sup>[8]</sup>网络框架的不同之处在于:ResNet<sup>[8]</sup>框架在最后 3 个 bottleneck blocks 中使用的是  $3 \times 3$  的空间卷积,而 BotNet 框架则是采用全局自我注意替代空间卷积。带自注意力模块的 Bottleneck 模块可以视作 Transformer 模块。

本文通过改进方法<sup>[7]</sup>,使用一种基于点的特征图像生成方法,将框架应用到三维点云任务中。对于特征提取方法中点云中的每个点,本文利用其相邻点的局部特征组成点云特征图像,然后使用点云特征图像输入到基于 CNN 的 Transform 的高效神经网络 Light-BotNet 网络模型并使用该模型做最后的激光点云分类任务。

## 1 框架

### 1.1 BotNet 网络框架

BotNet 网络框架是一种基于 Transformer 的架构,同时使用卷积和自我注意的混合模型,利用 CNN+Transformer 的方式提出一种 Bottleneck Transformer 来代替 ResNet Bottleneck,即仅在 ResNet 框架的最后 3 个 bottleneck blocks 中使用全局多头自注意力 (Multi-Head Self-Attention, MHSA) 替换  $3 \times 3$  空间卷积。该方法思想简单但是功能强大。由于引入 Self-Attention 会导致计算量大与内存占用过多,BotNet 在 ResNet 框架的最后 3 个 bottleneck blocks 添加自注意力模块。每个 bottleneck 包含一个  $3 \times 3$  卷积,采用 MHSA 替换该卷积,第一个 Bottleneck 中的  $3 \times 3$  卷积 stride=2,而 MHSA 模块并不支持 stride 操作,故而 BoTNet 采用  $2 \times 2$  均值池化进行下采样。传统的

Transformer 方法通常使用位置编码,考虑了不同位置特征之间的相对距离,从而能够有效地将对象之间的信息与位置感知关联起来,更适合视觉任务<sup>[9-11]</sup>。BotNet 采用了文献[9]、[12]中的 2D 相对位置自我注意机制。类似于 transformer block<sup>[13]</sup>或 None Local block<sup>[13]</sup>方法。

### 1.2 基于 Light-BotNet 的大场景点云分类框架

为了有效地从三维点云中挖掘有用的信息,采用了 CNN 和 Transform 结合的 BotNet 框架,首先,分别从三维点云中提取这些特征,将得到的特征计算成点云的特征图像<sup>[14]</sup>;然后将它们输入 Light-BotNet 网络框架,Light-BotNet 网络框架从点云特征图像中选择有用的信息来对三维点云进行分类。

整体的大场景点云分类网络框架如图 1 所示。首先是在三维和二维两个不同的层面上进行点云的特征提取,得到大小  $[N, 32, 32, 1]$  的点云特征图像,输入 Light-BotNet 网络框架,可以看出总共有 4 个网络层块(block),每一个 block 的大小为  $[1, 3, 1, 1]$ ,在 block\_1 中 Conv 参数为  $3 \times 3$  的卷积核和 Channel 大小为 64 的卷积层,block\_2 的 Conv 参数为  $3 \times 3$  和 Channel 为 64 的卷积层,block\_3 中 Conv 的参数为  $3 \times 3$  的卷积核和 Channel 为 64 的卷积层,block\_4 的 Conv 参数为  $3 \times 3$  和 Channel 为 128 的卷积层,通过这些卷积层可以提取点云特征图像的特征信息,得到一个  $[128, K]$  的一维向量,得出分数进而输出分类结果。

本文采用了 ResNet50 和 BotNet50 网络框架来与 Light-BotNet 进行对比,如表 1 所示。

## 2 实验结果分析

本文在 Oakland 3D 大场景三维点云数据集上进行实验,以验证基于 Light-BotNet 大场景点云分类方法的有效性和鲁棒性,对 Oakland 3D 数据集中的实验分类结果进行分析。




图 1 基于 Light-BotNet 的大场景点云分类框架

表 1 几种不同神经网络框架设计表

卷积层	Light-BotNet	ResNet50	BotNet50
conv1_x		3×3, 64, stride 1 3×3 max pool, stride 2	
conv2_x	$\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 256 \end{bmatrix} \times 1$	$\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 256 \end{bmatrix} \times 3$
conv3_x	$\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1 & 128 \\ 3 \times 3 & 128 \\ 1 \times 1 & 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1 & 128 \\ 3 \times 3 & 128 \\ 1 \times 1 & 512 \end{bmatrix} \times 4$
conv4_x	$\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 64 \end{bmatrix} \times 1$	$\begin{bmatrix} 1 \times 1 & 256 \\ 3 \times 3 & 256 \\ 1 \times 1 & 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 & 256 \\ 3 \times 3 & 256 \\ 1 \times 1 & 1024 \end{bmatrix} \times 6$
conv5_x	$\begin{bmatrix} 1 \times 1 & 128 \\ \text{MSHA} & 128 \\ 1 \times 1 & 512 \end{bmatrix} \times 1$	$\begin{bmatrix} 1 \times 1 & 512 \\ 3 \times 3 & 512 \\ 1 \times 1 & 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1 & 512 \\ \text{MSHA} & 512 \\ 1 \times 1 & 2048 \end{bmatrix} \times 3$

在 Oakland 3D 三维大场景点云数据集上测试所提出的算法框架,该数据集来源于奥克兰卡耐基梅隆大学的校园周边场景,是使用最广泛的地面移动激光扫描(MLS)所获取的数据集。该数据集主要是城市大场景环境。该数据集包括电线(Wire)、杆(Pole)、建筑立面(Facade)、地面(Ground)和植物(Vegetation)这 5 个语义类别,其中每个类别的样本数量如表 2 所示。

表 2 Oakland 数据集

数据类别	训练数据集	测试数据集
Vegetation	14 441	9 278
Wire	2 571	481
Pole	1 086	368
Ground	4 713	71 863
Facade	14 121	7 821
总共	36 932	89 811


实验运行环境: Intel i7-4790、NVIDIA RTX 2070、8 GB 内存,在 Windows10 和 Python3.7 下搭建 CUDA 10.0、CUDNN7.6.4、PyTorch 0.6 的深度学习环境,初始学习率为  $1 \times 10^{-3}$ 。

本文在 Oakland 大场景三维点云数据集上分类任务的测试精度实验对比如表 3 所示,其中 OA 表示总体分类精度,在总体分类精度(OA)明显要好于其他文献的方法。实验结果表明,所提出的 Light-BotNet 方法在 Oakland 数据集上的总体分类精度达到了 98.1%,与文


表 3 Oakland 数据集对比精度 (%)

文献类别	Pole	Vegetation	Wire	Ground	Facade	OA
文献[15]	22.3	90.7	5.3	99.6	87.6	93.53
文献[16]	68.42	80.68	92.93	98.37	71.13	94.75
文献[17]	70.11	80.55	93.08	98.22	70.95	94.68
文献[18]	28.7	97.4	12.5	98.2	90.8	91.66
文献[19]	59.7	92.0	10.7	99.9	94.6	95.5
Light-BotNet	20.7	93.0	18.0	99.6	98.7	98.1

献[15]-[19]相比较,如图 2 所示的 Oakland 3D 大场景三维点云分类结果可视化对比,其中图 2(a)是测试集的 Ground Truth,图 2(b)是算法分类结果的可视化效果。



(a) 测试集可视化



(b) 结果可视化

图 2 可视化效果图

图 2 中 1 表示地面,2 表示电线,3 表示电线杆,4 表示墙面,5 表示植物。

可看到 Oakland 测试集上分类后可视化效果与测试集真实标签可视化效果对比。从表 3 对比数据以及图 2 展示的效果来看,电线杆类(Pole)和线(Wire)这两类别的分类精度分别为 20.7%和 18.0%,与其他的文献相比较差。因为这些类别的点本来就是数据量少,当对这些类别的点进行在  $x$ 、 $y$ 、 $z$  方向投影时,这一投影势必会造成部分不同类别的点的重合覆盖,从而影响计算该类点的二维特征精度的计算。但是对于类别的点比较有优势,类别多的覆盖了类别少的点,所以在最终的结果呈现出类别多的点准确率高,类别少的点准确率低。

由于对比方法中涉及 Oakland 大场景三维点云数据相关文献<sup>[15-19]</sup>,为了证明本文所提基于通道注意力机制的深度卷积神经网络在时间和效率上的优良性,针对在大场景三维点云的海量数据在训练过程中如何更好地平衡分类精度和实现效率问题,通过对比 Light-BotNet 与 ResNet50 和 BotNet50 网络框架在大场景三维点云数据集 Oakland 和测试分类的性能与时间复杂度作为评价指标来证明所提算法轻量级框架的优良性,图 3 展示的是 Light-BotNet 与 ResNet50 和 BotNet50 网络框架在大场景三维点云 Oakland 数据集上随着轮数(epoch)增加对点云分类精度(accuracy)的变化。

通过图 3 展示的效果可以看出,Backbone 分别为 ResNet50 和 BotNet50 的网络模型,在分类精度上对比 Light-BotNet 比较低,这在很大程度上是因为本文已经

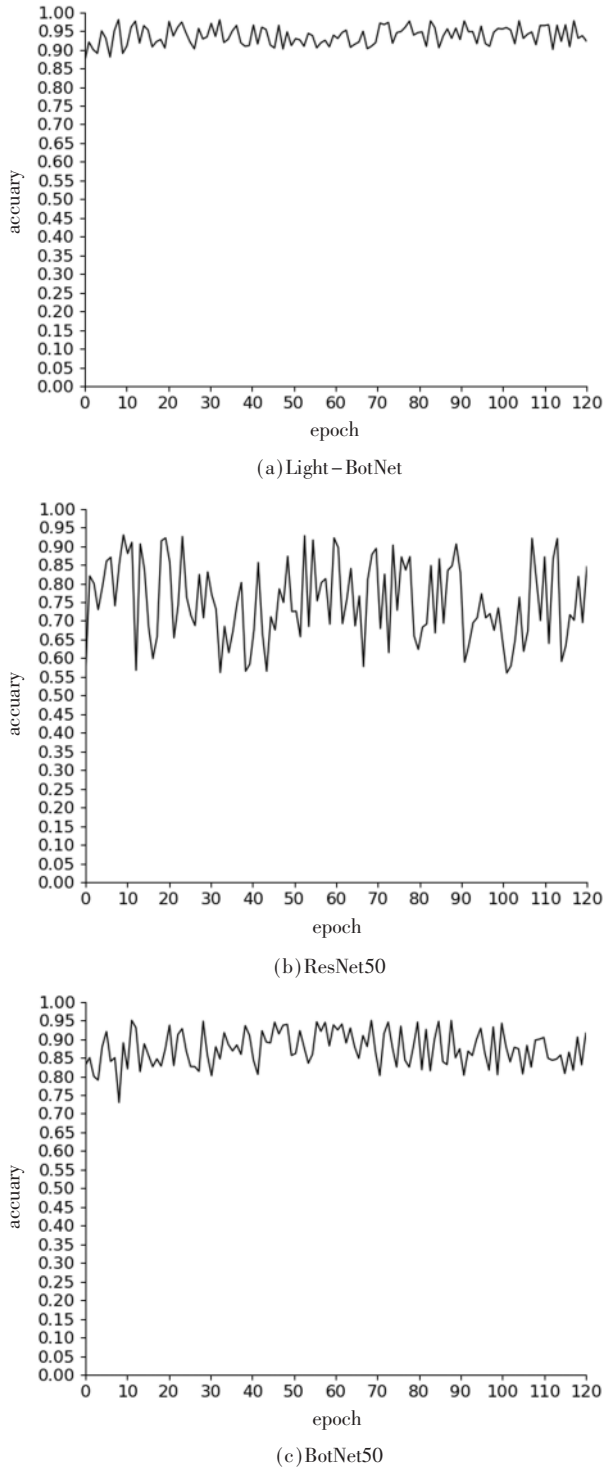


图3 Light-BotNet与Method\_1和Method\_2分类精度可视化

对激光点云已经进行了一遍处理,所以在后面使用的网络层模型应该偏向于轻量级的网络模型。本文也同在SVM和Random Forest方法上进行验证分类结果,发现在分类结果上能够达到90%左右的效果,在Backbone为轻量级的网络框架的效果<sup>[17]</sup>中,也能够取得比较好的效果,虽然ResNet网络层模型可以适用于在一些比较深的网络模型提取有效的特征,但是可能并不适用于本方

法中。从结果可以看出,整体的实验分类结果具有很大的波动性,虽然达到了一个比较好的效果,但是可能存在是研究结果出现过拟合的可能。BotNet50 Backbone同理可证,在Light-BotNet网络框架设计上如表1所示,在整体的网络框架上,相比于ResNet50和BotNet50网络框架,在网络层上进行了50%的删减,形成一个相对轻量级的基于CNN的Transform网络框架模型、在实验结果上,相比于ResNet50和BotNet50,整体的分类结果比较稳定,分类精度也高。

对比在Oakland 3D数据集下Light-BotNet与BotNet50、ResNet50 3种不同网络框架的分类精度,结果如表4所示。

表4 网络框架实验结果对比

网络框架	准确率/%
Light-BotNet	98.1
BotNet50	95.0
ResNet50	93.1

对比不同网络的参数,表5展示了使用的不同网络框架运行点云分类的Flops和Params对比。从中可以看出,Backbone BotNet50与ResNet50在Flops和Params对比上差距不是很大,但是结合表4来看,牺牲一部分的内存和效率,可以换取到准确率的提升。对比Light-BotNet,Light-BotNet在Flops和Params上都降低近50%的消耗,准确率也是达到了一个很好的效果,通过在同样硬件环境配置下在不同的Backbone的分类网络框架中进行实验,Light-BotNet的Flops消耗与Params与其他相比都处于最低的效果。

表5 不同网络框架的Flops和Params对比

网络框架	Flops/B	Params/B
Light-BotNet	23 068 672 000	10 808 773
BotNet50	41 799 385 088	23 513 285
ResNet50	40 596 406 272	18 799 301

由于对比方法中涉及Oakland大场景三维点云数据相关文献<sup>[15-19]</sup>,为了证明本文所提出基于Light-BotNet的激光点云分类方法,针对在大场景激光点云的海量数据在训练过程中Light-BotNet对本框架的影响,本文对比了在本框架和去除掉MSHA框架的实验结果,如图4所示,实验证明MHSA有利于点云分类精度的提高。

### 3 结论

针对大场景三维点云本身数据量巨大,存在计算量大、训练时间长的挑战,设计更为适合三维点云数据处理的轻量级卷积神经网络,在保证分类精度的同时尽可能减少了参数的数量和训练测试时间,使得网络进一步快速收敛以及减少计算量。本文提出一种基于Light-




图4 无MSHA的准确率变化曲线

BotNet 低复杂度、轻量级框架,在取到较好的分类精度的基础上减少了训练和测试时间,提升了整个网络框架的性能。但是从每个类别的分类精度来看,对于 Oakland 3D 数据集,本方法存在着一些不足之处,对一些数量占比少类别不友好,而对于一些数量多的类别来说,可以达到一个非常好的效果,这是本文存在的一个缺点,需要在以后工作中进行改进。这种问题的出现在很大程度上是因为本文在提取点云特征图像上存在着一些缺点,或许不应该在  $xoy$ 、 $yoZ$ 、 $xoz$  3 个直平面进行投影,或许应该从一个有利于类别数量少的点的角度进行投影,例如旋转到某一个角度,能够让类别数量少的点受到其他类别少的点的影响尽可能少,这将是未来将继续的工作。在未来工作内容中,也会继续探讨在三维大场景点云数据同等数据容量下,对数据特性分析与提升深度学习框架本身的计算性能。

## 参考文献

- [1] PARIKH A P, TÄCKSTRÖM O, DAS D, et al. A decomposable attention model for natural language inference[J]. arXiv Preprint arXiv : 1606.01933, 2016.
- [2] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[J]. arXiv Preprint arXiv : 1409.0473, 2014.
- [3] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017 : 6000–6010.
- [4] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016 : 770–778.
- [5] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6) : 1137–1149.
- [6] CHEN M, RADFORD A, CHILD R, et al. Generative pre-

training from pixels[C]//International Conference on Machine Learning. PMLR, 2020 : 1691–1703.

- [7] SRINIVAS A, LIN T Y, PARMAR N, et al. Bottleneck transformers for visual recognition[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021 : 16519–16529.
- [8] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016 : 770–778.
- [9] BELLO I, ZOPH B, VASWANI A, et al. Attention augmented convolutional networks[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019 : 3286–3295.
- [10] RAMACHANDRAN P, PARMAR N, VASWANI A, et al. Stand-alone self-attention in vision models[C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems, 2019 : 68–80.
- [11] ZHAO H, JIA J, KOLTUN V. Exploring self-attention for image recognition[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020 : 10076–10085.
- [12] SHAW P, USZKOREIT J, VASWANI A. Self-attention with relative position representations[J]. arXiv Preprint arXiv : 1803.02155, 2018.
- [13] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018 : 7794–7803.
- [14] 张志勇. 基于卷积神经网络的大场景点云分类研究[D]. 南昌 : 东华理工大学, 2021.
- [15] WEINMANN M, JUTZI B, MALLET C. Feature relevance assessment for the semantic interpretation of 3D point cloud data[J]. Isprs Annals of Photogrammetry, 2013, II-5/W2 : 313–318.
- [16] WANG L, MENG W, XI R, et al. Large-scale 3D point cloud classification based on feature description matrix by CNN[C]//Proceedings of the 31st International Conference on Computer Animation and Social Agents, 2018 : 43–47.
- [17] WANG L, MENG W, XI R, et al. 3D point cloud analysis and classification in large-scale scene based on deep learning[J]. IEEE Access, 2019, 7 : 55649–55658.
- [18] MUNOZ D, VANDAPEL N, HEBERT M. Directional associative markov network for 3-D point cloud classification[J/OL]. International Symposium on 3-D Data Processing, Visualization, and Transmission, 2018, https://doi.org/10.1184/R1/6552644.v1.
- [19] WEINMANN M, SCHMIDT A, MALLET C, et al. Contextual classification of point cloud data by exploiting individual 3D neighbourhoods[J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences II-3

(下转第 97 页)

and stimulation frequency on rate of fatigue development[J]. J Electromyogr Kinesiol, 2017, 38: 67-72.

- [12] POPOVIC M R, KELLER T, PAPAS I P I, et al. Surface-stimulation technology for grasping and walking neuroprostheses[J]. IEEE Engineering in Medicine and Biology Magazine, 2001, 20(1): 82-93.
- [13] 丁建华. 可实时调整刺激参数的功能性电刺激仪的研制[J]. 福州大学学报(自然科学版), 2019, 47(6): 6.
- [14] 陈小宇, 邱静, 堵刚刚. 新型肌电刺激脉冲仪设计与实现[J]. 电子科学技术, 2016(3): 4.
- [15] WATANABE K, AKIMA H. Validity of surface electromyography for vastus intermedius muscle assessed by needle electromyography[J]. J Neurosci Methods, 2011, 198(2): 332-

(上接第 88 页)

(2015), Nr. W4, 2015, 2(W4): 271-278.

(收稿日期: 2022-03-09)

作者简介:

雷根华(1996-), 女, 硕士, 主要研究方向: 大场景点云

(上接第 91 页)

## 5 结论

本文针对煤炭开采冲击问题提出基于隐马尔可夫模型分析煤炭井下开采安全预测机制, 通过监测煤炭开采现场状态进行试验, 先收集数据提取特征信号, 再利用隐马尔可夫模型对其进行训练, 在最大似然度下学习得出其最大概率, 通过匹配得到煤炭开采现场当前运行状态。结果显示, 该系统能够有效监测煤炭开采现场安全, 同时通过模型训练能够有效提高安全评估精度。

参考文献

- [1] 杨光宇, 姜福兴, 曲效成, 等. 特厚煤层掘进工作面冲击地压综合监测预警技术研究[J]. 岩土工程学报, 2019, 41(10): 1949-1958.
- [2] 温廷新, 李洋子. 基于预处理的 AFOA-ELM 冲击地压危险预测模型[J]. 中国安全科学学报, 2019, 29(8): 29-34.
- [3] 朱丽媛, 潘一山, 李忠华, 等. 深部矿井冲击地压、瓦斯突出复合灾害发生机理[J]. 煤炭学报, 2018, 43(11): 3042-3050.
- [4] 刘少虹, 潘俊锋, 夏永学. 巨厚坚硬岩浆岩床破裂运动诱发冲击地压机制研究[J]. 岩石力学与工程学报, 2019, 38(3): 499-510.
- [5] 鞠文君, 郑建伟, 魏东, 等. 急倾斜特厚煤层多分层同采巷道冲击地压成因及控制技术[J]. 采矿与安全工程学报, 2019, 36(2): 280-289.
- [6] 宋杰, 王健, 柳尚, 等. 基于改进 PSO-BP 模型的电磁辐射法冲击地压预测[J]. 煤矿安全, 2019, 50(6): 205-208.
- [7] 李振雷, 何学秋, 窦林名, 等. 煤冲击破坏过程规律及同源声电响应特征[J]. 岩石力学与工程学报, 2019, 38(10):

335.

- [16] 袁勇. 康复机器人系统腕部功能性电刺激阵列研究[D]. 武汉: 华中科技大学, 2015.

(收稿日期: 2022-01-05)

作者简介:

苏栋楠(1996-), 男, 硕士研究生, 主要研究方向: 生物医疗仪器。

尚鹏(1969-), 博士, 研究员, 主要研究方向: 康复医疗机器人。

胡志刚(1972-), 通信作者, 男, 博士, 教授, 主要研究方向: 智能交互医用机器人, E-mail: hu.robert@126.com。



扫码下载电子文档

分类。

王蕾(1979-), 女, 博士, 副教授, 硕士生导师, 主要研究方向: 视觉信息获取与处理、计算机视觉、计算机图形图像技术等。

张志勇(1997-), 男, 硕士研究生, 主要研究方向: 大场景点云分类。



扫码下载电子文档

2057-2068.

- [8] 梁冰, 袁欣鹏, 孙福玉, 等. 钻屑法测定煤层 H<sub>2</sub>S 含量[J]. 中国安全科学学报, 2015, 25(2): 101-105.
- [9] 窦林名, 姜耀东, 曹安业, 等. 煤矿冲击矿压动静载的“应力场-震动波场”监测预警技术[J]. 岩石力学与工程学报, 2017, 36(4): 803-811.
- [10] 姜超, 靳添絮, 罗维东, 等. 基于工况识别和马尔可夫链的混合动力地下铲运机功率预测[J]. 煤炭学报, 2019, 44(S1): 8.
- [11] 楼振凯, 侯福均, 楼旭明. 基于极大似然的马尔可夫链初始状态估计的数学规划[J]. 南京师大学报(自然科学版), 2019, 42(2): 50-56, 60.
- [12] 刘益维, 陈国明, 朱渊, 等. 基于马尔可夫的地面控制井下安全阀可靠性评估[J]. 中国安全生产科学技术, 2019, 15(1): 139-144.
- [13] 叶飞, 盛昭瀚, 徐峰. 基于二阶隐马尔可夫模型的桥梁健康状况分析与评定[J]. 系统管理学报, 2018, 27(4): 694-703.
- [14] 张新生, 赵梦旭. 改进 Grey-Markov 模型在油气管道腐蚀深度预测中的应用[J]. 地质科技情报, 2017, 36(6): 286-291.

(收稿日期: 2021-10-28)

作者简介:

李卫龙(1985-), 男, 硕士研究生, 助理研究员, 主要研究方向: 煤矿安全与智能化。

汪青(1986-), 通信作者, 女, 硕士研究生, 主要研究方向: 信号及信息处理, E-mail: xiaoqing5921@126.com。



扫码下载电子文档

## 版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所