

基于注意力残差网络的重叠尖峰分类算法

余海翔, 汪曼青, 王录涛

(成都信息工程大学 计算机学院, 四川 成都 610225)

摘要: 在神经解码研究中, 多个神经元同时放电会产生尖峰重叠, 进而影响解码准确性, 因而分类重叠尖峰是解码神经元集群活动的关键步骤。提出一种基于格拉姆角和场与注意力残差网络(GASF-CBAM-ResNet)的重叠尖峰分类算法, 首先使用独立尖峰数据制作重叠尖峰模板训练集, 接着采用格拉姆角和场方法将一维尖峰序列转换成二维图像, 用于训练注意力残差网络模型, 最后对独立尖峰和重叠尖峰进行分类识别。该方法在“Wave_clus”数据集上的平均准确率达92.737%, 优于传统方法。结果表明, GASF-CBAM-ResNet不仅可以有效地区分重叠尖峰, 还节省了大量时间和人力成本, 能够为神经解码研究提供可靠支持。

关键词: 重叠尖峰; 格拉姆角和场; 卷积块注意力; 残差网络

DOI: 10.11907/rjdk.241041

中图分类号: TP18

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1672-7800(2025)004-0062-07



Overlapping Peak Classification Algorithm Based on Attention Residual Network

YU Haixiang, WANG Manqing, WANG Lutao

(School of Computer Science, Chengdu University of Information Technology, Chengdu 610225, China)

Abstract: In the study of neural decoding, simultaneous firing of multiple neurons creates spike overlap, which affects the accuracy of decoding. Therefore, the classification of overlapping spikes is critical in decoding the activity of neuronal clusters. This paper proposes an algorithm for overlapping spike classification based on Gramian Angular Summation Field and Attention Residual Network (GASF-CBAM-ResNet). First, the training set of overlapping spike templates is created using independent spikes. The Gramian angular summation field is then applied to convert the 1D spike signal into a 2D image, which is used as input to the attention residual network. Finally, both independent and overlapping spikes are classified and identified. The average accuracy of the proposed network reaches 92.737% on the "Wave_clus" data sets, and outperforms the traditional methods. The results show that GASF-CBAM-ResNet not only discriminates overlapping spikes efficiently, but also provides reliable support for neural decoding with significant time and labor savings.

Key Words: overlapping spikes; Gramian angular summation field; convolutional block attention module; residual network

0 引言

在神经科学研究中, 将电极放置在脑组织中可以记录电极附近的神经元电信号, 分析获取的神经元活动是其中的一项关键步骤。通常而言, 细胞外电信号呈现尖峰波形, 也称为尖峰(Spike), 而由于神经细胞类型、形态, 或者神经元与电极间的距离等影响, 神经元尖峰波形的形态有所差异。这种波形差异是区分不同神经元电活动的关键

因素, 这种对尖峰波形进行分类的过程也称为Spike Sorting^[1]。

常见的Spike Sorting步骤包括滤波、峰值检测、特征提取、分类。选择带通300~5 000滤波原始信号可提取到包含尖峰和背景信号的高频信号。峰值检测指通过阈值检测等方法将尖峰信号挑选出来, 然后对不同神经元峰电位特征进行提取, 分类得到神经元对应的峰电位发放。例如, Quiroga等^[1]通过小波包分对尖峰进行特征提取, 通过超顺磁聚类; Wouters等^[2]提出主成分分析法(Principal

收稿日期: 2024-01-12

扫描二维码阅读全文:



基金项目: 四川省科技厅重点研发计划项目(2023YFG0018)

作者简介: 余海翔(1998-), 男, 成都信息工程大学计算机学院硕士研究生, 研究方向为人工智能、脑机接口; 汪曼青(1989-), 女, 博士, 成都信息工程大学计算机学院讲师, 研究方向为人工智能、脑机接口; 王录涛(1979-), 男, 博士, 成都信息工程大学计算机学院副教授、硕士生导师, 研究方向为机器视觉与智能感知。本文通讯作者: 王录涛。

Components Analysis, PCA)提取尖峰特征,并按照顺序进行K均值聚类(K-means Clustering)等。

近年来,深度学习方法逐渐应用于尖峰分类过程^[3]。Saif-ur-Rehman等^[4]采用卷积神经网络将尖峰和背景噪音进行分离,将背景噪音从数据中移除后,聚类平均准确率达92.3%;Eom等^[5]采用深度学习方法进行特征提取,在“Wave_Clus”提供的模拟数据集上,其平均准确率达99.81%;Wang等^[6]通过一维卷积神经网络进行尖峰聚类,在“Wave_Clus”提供的模拟数据集上,其平均准确率达99.42%;Racz等^[7]将卷积神经网络(Convolutional Neural Networks, CNN)和长短期记忆网络(Long Short-Term Memory, LSTM)相结合,实现了单独的尖峰检测和尖峰排序网络,首次利用了电极放置位置的空间信息;Wu等^[8]使用深度压缩自动编码器从检测到的峰值中提取特征,并且实现了小样本学习通过专门方法在图形处理器(Graphics Processing Unit, GPU)上的显著加速;Marie等^[9]开发了一种依赖于尖峰时间的可塑性(Spike-Timing-Dependent Plasticity, STDP)脉冲神经网络(Spiking Neural Network, SNN)实现端到端的尖峰分类问题解决方法,开辟了低功耗的神经数据处理前景;Qian等^[10]采用基于对比学习的深度聚类方法实现了对尖峰的聚类,并改进了尖峰分类算法,在模拟数据集上准确率达99%。

虽然深度学习使得尖峰排序能够获得更好的分类结果,但某些应用,比如对重叠尖峰进行分类,仍然需作进一步研究。近年来,微电子和芯片技术的发展使得多电极阵列性能提升,当多个神经元在微电极周围同时进行放电时,电极阵列最多会记录到上千个神经元的尖峰发放^[11]。然而,这种情况下记录的尖峰可能是数个神经元锋电位的叠加,出现重叠尖峰波形。因此,处理重叠尖峰分类问题对于解码神经元集群活动变得尤为重要。

重叠尖峰的形状与单独神经元的尖峰形状不同,波幅和波宽等传统时域特征的高度可变性常常导致尖峰排序偏差并降低尖峰排序性能^[12-13]。模板匹配方法^[14-15]、稀疏优化方法^[16]、最大后验估计法^[17]是解决重叠尖峰问题相对有效的方法。模板匹配方法通过构造多个重叠的尖峰模板,对重叠的尖峰进行匹配。然而,当由相似波形组成的神经元重叠时,自动尖峰分类器仍然容易出错。稀疏优化方法为连续值尖峰的时间估计提供了统一过程,即使过程中存在重叠尖峰,也可以进行尖峰排序,从而从侧面解决了重叠尖峰问题。然而,它很难解决稀疏线性逆问题,因此该方法很少被使用^[6]。最大后验估计方法是将尖峰排序过程表述为统计估计问题,还可以通过将测量值与估计量相关联,并指定相邻神经元的线性叠加以识别重叠尖峰^[8]。

目前,深度学习方法应用于重叠尖峰问题上较少。其中一个主要原因是在对深度学习模型进行训练时,需要训练样本尽可能丰富,且不同种类样本应尽可能地分布均匀。然而,在尖峰数据集中,非重叠尖峰数量通常远远多

于重叠尖峰数量,这样不利于重叠尖峰分类模型训练。因此,受模板匹配法启发,本文提出了一种服从均匀分布的重叠尖峰训练模板构建方法。该方法基于单神经元尖峰波形的线性叠加,构建重叠尖峰波形,解决训练样本少和样本分布不均的问题。

在分类模型相关研究中,Liu等^[18]通过一维CNN+LSTM的模型对重叠尖峰进行分类,在模拟数据集中分类准确率达到良好效果。然而,一维CNN模型部分随着网络的加深出现梯度弥散、梯度消失问题,且模型泛化性和适用性也有待进一步提高。同时,LSTM模型存在消耗大量计算资源、难以进行并行化处理、依赖性可能会被忽略或丢失等问题。

由此,本文提出了基于格拉姆角和场(Gramian Angular Summation Field, GASF)和注意力残差网络的重叠尖峰分类模型GASF-CBAM-ResNet。该模型首先利用格拉姆角和场将尖峰这种一维的时序信号转变成二维图像作为模型输入。格拉姆角和场是一种将时序信号转换为图像的技术,该方法增强了时间序列的可视化表达,又保留了时间序列的原始信息,对于噪声和异常值具有一定的鲁棒性和特征可解释性。目前,该方法已被广泛应于脑电领域并获得了不错效果,如精神分裂症和癫痫分类^[19-20],但尚未用于尖峰分类相关研究。经过格拉姆角和场变换后,本文将二维图片输入到基于注意力残差网络的重叠尖峰分类模型中。该模型结合了卷积块的注意力模块(Convolutional Block Attention Module, CBAM)和残差网络(Residual Network, ResNet)中的ResNet34结构,解决了一维CNN模型泛化弱和依赖行不强的问题,提高了重叠尖峰分类精度。

1 模型方法

本文模型框架主要包括尖峰数据输入、GASF转换以及基于CBAM-ResNet的尖峰分类模块,如图1所示。首先,一维尖峰数据通过GASF转变为 64×64 的二维图像表达,作为分类神经网络的输入;其次,将二维图像进行卷积和Batchnorm操作,从原有的单通道转为64通道,提取更丰富的特征;接着,将特征输入4个注意力残差块,关注数据中最重要的特征并避免梯度消失和梯度爆炸;随后,通过池化窗口为 1×1 的平均池化,以提高模型泛化能力;最后,模型输出尖峰所属类别,实现尖峰分类。

1.1 重叠尖峰模版构建

本文数据集为模拟数据集,采样率为24 000 Hz,由真实记录的594个尖峰波形生成。该数据集包含了4个子集数据,根据波形相似性分别将子集命名为Easy1、Easy2、Difficult1和Difficult2^[25]。为了模拟真实环境中噪声对数据的干扰,每个子集的尖峰信号都叠加了不同级别的噪声信号,以此生成不同信噪比的数据,具体信息如表1所示。




Fig. 1 Framework of the model

图1 模型框架

Table 1 The number of spikes of different categories

表1 不同类别的尖峰数量

数据集	噪声水平	聚类1	聚类2	聚类3	重叠1	重叠2	重叠3
C_Easy1	0.05	1 165	1 157	1 192	58	44	45
C_Easy1	0.10	1 151	1 134	1 237	44	40	45
C_Easy1	0.15	1 132	1 188	1 157	41	43	68
C_Easy1	0.20	1 198	1 128	1 148	51	53	42
C_Easy1	0.25	1 094	1 089	1 115	34	41	45
C_Easy1	0.30	1 162	1 164	1 149	56	59	47
C_Easy1	0.35	1 208	1 137	1 189	52	55	60
C_Easy1	0.40	1 079	1 158	1 149	41	39	54
C_Easy2	0.05	1 130	1 113	1 167	49	41	55
C_Easy2	0.10	1 160	1 146	1 214	52	52	56
C_Easy2	0.15	1 181	1 098	1 132	45	54	36
C_Easy2	0.20	1 186	1 188	1 152	52	40	37
C_Difficult1	0.05	1 115	1 113	1 155	46	49	55
C_Difficult1	0.10	1 164	1 155	1 129	35	47	48
C_Difficult1	0.15	1 159	1 172	1 141	47	48	51
C_Difficult1	0.20	1 136	1 099	1 179	43	53	45
C_Difficult2	0.05	1 120	1 109	1 135	49	44	54
C_Difficult2	0.10	1 187	1 136	1 139	30	44	44
C_Difficult2	0.15	1 142	1 113	1 185	59	52	46
C_Difficult2	0.20	1 151	1 195	1 147	56	42	48

表1中重叠1、重叠2和重叠3表示聚类1和聚类2的重叠尖峰、聚类1和聚类3的重叠尖峰、聚类2和聚类3的重叠尖峰。值得注意的是,在原始数据集中,重叠尖峰数量明显少于非重叠尖峰。为了解决样本分布不均匀的问题,便于训练之后的分类模型,本文在构建测试集时选择部分非重叠尖峰作为模板构建重叠尖峰,具体过程如算法1所示。

首先,从3类非重叠尖峰(C_i)中随机选取两类线性叠加,以构建重叠尖峰模板;其次,将两个尖峰的发放时间间隔设置为随机整数 P , P 取值范围为0~25个采样点,其中0表示两个尖峰同时产生,25定义了重叠尖峰中两个尖峰的最大间隔,即如果两个尖峰发放间隔超过25个采样点,将被识别为独立的非重叠尖峰^[17];再次,分别从 C_1 和 C_2 类中随机选择尖峰 $Spike_1$ 和尖峰 $Spike_2$;之后,通过函数Move将 $Spike_2$ 整体平移 P 个数据点;接着,将 $Spike_1$ 和经过平移后的 $Spike_2'$ 进行线性叠加生成模板 T ;最后,通过函数Label定义模板 T 的类别标签 L 。模板构造中的所有随机数都由

算法1 重叠尖峰模板训练集构建

输入:聚类1($Cluster1$),聚类2($Cluster2$),聚类3($Cluster3$),模板数量(Num);

输出:模板 T ,模板标签 L

```

1 function CreateTemplate
2   FOR i from 1 to Num do
3      $C_1, C_2 \leftarrow \text{Random selection}(Cluster1, Cluster2, Cluster3)$ 
4      $Spike_1 \leftarrow \text{Random selection}(C_1)$ 
5      $Spike_2 \leftarrow \text{Random selection}(C_2)$ 
6      $Spike_2' \leftarrow \text{move}(Spike_2, P)$ 
7      $T \leftarrow Spike_1 + Spike_2'$ 
8      $L \leftarrow \text{Label}(C_1, C_2)$ 
9   END FOR
10  RETURN  $T, L$ 
11 END function

```

Python随机函数返回指定范围内的随机整数,以约束模板类别数量,使其遵循均匀分布。

重叠尖峰模板构建完成后,新数据集由原始非重叠尖峰、原始重叠尖峰和重叠模板组成,如图2所示。非重叠尖峰数据集随机等分为3个部分:第一部分根据尖峰类别标签,制作重叠尖峰训练模板,并与第二部分组成模型训练集,占总数据集的60%;第三部分与原始重叠尖峰数据集构成本文模型测试集,占总数据集剩余的40%。




Fig. 2 The construction of overlapping spikes dataset

图2 重叠尖峰数据集构建

1.2 GASF-CBAM-ResNet

1.2.1 格拉姆角和场GASF

格拉姆角场(Gramian Angular Field, GAF)是一种将时间序列信号编码为图像的方法^[21]。经过编码后,图像能够保留每个时间点之间的相关性,同时也可将最先进的计算机视觉模型应用于时间序列数据,有效地提高数据利用率^[22]。格拉姆角和场GASF是GAF的一种常用形式,使用极坐标系而非传统的笛卡尔坐标系表示时间序列,这使得编码过程更具可视化效果。尖峰编码过程如下:

首先,通过归一化处理,尖峰 $X = \{x_1, x_2, \dots, x_n\}$ 中的所有值缩放到 $[0, 1]$ 范围内,如式(1)所示。

$$\tilde{x}_0^i = \frac{x_i - \min(X)}{\max(X) - \min(X)} \quad (1)$$

然后,将归一化尖峰编码为角余弦,并将数据点编码为映射到极坐标系中的半径,如式(2)所示。

$$\begin{cases} \varphi_i = \arccos(\tilde{x}_i), 0 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, t_i \in \mathbb{N} \end{cases} \quad (2)$$

其中, φ_i 是尖峰序列 $\tilde{x}_i (i = 1, 2, 3, \dots, n)$ 在极坐标中映射的角度, t_i 表示数据点, N 表示标准化极坐标系跨度的常数因子^[26]。

最后, GASF 被定义为通过三角函数表示时间关系, 如式(3)所示^[27]。

$$GASF = \begin{bmatrix} \cos(\varphi_1 + \varphi_1) & \cos(\varphi_1 + \varphi_2) & \cdots & \cos(\varphi_1 + \varphi_n) \\ \cos(\varphi_2 + \varphi_1) & \cos(\varphi_2 + \varphi_2) & \cdots & \cos(\varphi_2 + \varphi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\varphi_n + \varphi_1) & \cos(\varphi_n + \varphi_2) & \cdots & \cos(\varphi_n + \varphi_n) \end{bmatrix} \quad (3)$$

本文将 64 个采样点的尖峰数据编码到极坐标系中, 得到二维图像, 图像大小为 64×64 像素点。

1.2.2 CBAM-ResNet

注意力残差网络由卷积核大小为 3×3 的卷积层、批归一化层、ReLU 激活层、4 个残差块、平均池化层和两个全连接层组成, 如图 1 所示。表 2 描述了每个模块的参数, 每个残差块包含 2 个卷积核大小为 1×1 的卷积层、1 个注意力模块、1 个批归一化层和 1 个 ReLU 激活函数层。与经典的 34 层残差网络^[24]相比, 本文残差块引入了注意力模块, 更加关注重要特征并抑制不必要的特征^[23]。

Table 2 CBAM-ResNet model structure

表 2 CBAM-ResNet 模型结构

模块名称	层名称	层描述
	Input layer	64×64 GASF 图像
	Conv2D	卷积核 3×3; Strides=1; Padding=1; 批归一化; ReLU 激活
残差块 1	Conv2D	滤波器数量 64;
	Conv2D	卷积核 1×1; Strides=1; Padding=1;
	Conv2D	批归一化; ReLU 激活;
	CBAM	通道注意力; 时空注意力
残差块 2	Conv2D	滤波器数量 128;
	Conv2D	卷积核 1×1; Strides=1; Padding=1;
	Conv2D	批归一化; ReLU 激活;
	CBAM	通道注意力; 时空注意力
残差块 3	Conv2D	滤波器数量 256;
	Conv2D	卷积核 1×1; Strides=1; Padding=1;
	Conv2D	批归一化; ReLU 激活;
	CBAM	通道注意力; 时空注意力
残差块 4	Conv2D	滤波器数量 256;
	Conv2D	卷积核 1×1; Strides=1; Padding=1;
	Conv2D	批归一化; ReLU 激活;
	CBAM	通道注意力; 时空注意力
	Average Pool	池化窗口 1×1
	Flatten	/
	Full Connection	Dense = 512
	Full Connection	Dense = 6; Linear

残差块中的 CBAM 模块由通道注意力模块和空间注意力模块组成。通道注意力可以增强模型泛化能力, 空间注意力模块可以自适应地捕获数据空间结构有关信息^[28]。

通道注意力通过特征的通道间关系生成通道注意力图, 并关注尖峰中最有意义的部分。该模块对输入特征进行平均池化和最大池化操作, 以生成两个不同的空间上下文描述符 F_{avg}^c 和 F_{max}^c , 该上下文描述符被输入多层感知机 (Multilayer Perceptron, MLP), 最终使用元素求和合并输出特征向量, 以生成尖峰通道注意力图。通道注意力描述如式(4)所示。

$$\begin{aligned} M_c(F) &= \sigma \left(MLP \left(AvgPool(F) \right) + MLP \left(MaxPool(F) \right) \right) \\ &= \sigma \left(W_1 \left(W_0 \left(F_{avg}^c \right) \right) + W_1 \left(W_0 \left(F_{max}^c \right) \right) \right) \end{aligned} \quad (4)$$

其中, σ 代表 Sigmoid 函数, W_1 和 W_0 代表 MLP 的共享权重, F 代表输入特征。

空间注意力是对通道注意力模块的补充, 该模块通过序列化最大池化和平均池化操作生成空间注意力图, 将它们聚合成特征图, 然后通过卷积生成尖峰空间注意力图。空间注意力模块描述如式(5)所示。

$$\begin{aligned} M_s(F) &= \sigma \left(f \left(\left[AvgPool(F); MaxPool(F) \right] \right) \right) \\ &= \sigma \left(f \left(\left[F_{avg}^s; F_{max}^s \right] \right) \right) \end{aligned} \quad (5)$$

其中, σ 代表 Sigmoid 函数, f 代表卷积操作。

1.3 评价指标

模型性能评估采用精度、准确度、F1 分数 3 个评价指标。精度定义为如式(6)所示。

$$precision = \frac{TP}{TP + FP} \quad (6)$$

其中, FP 表示负样本, TP 表示正样本。

准确度计算所有数据中正确分类的分类样本百分比, 定义为如式(7)所示。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

其中, TN 表示真阴性样本。

F1 分数是精确率和召回率的调和平均值, 旨在综合评估模型性能, 定义为如式(8)所示。

$$F1 \text{ Score} = 2 \times \frac{precision \times recall}{precision + recall} \quad (8)$$

2 结果分析

模型基于 PyTorch 框架实现, 并在搭载 GTX 3060 和 Intel(R) Core(TM) i7-10870H CPU@2.20GHz 的平台上进行训练。模型采用 Adam 优化器训练, 初始学习率设置为 10^{-3} , 训练 epoch 次数为 30 次, 批次大小为 16, 损失函数为 CrossEntropy。

2.1 尖峰数据集

原始数据集是一个不平衡数据集, 其中重叠尖峰比例

非常低。在采用了重叠尖峰模板构建的方法后,重叠尖峰数据得到了增强,以确保6类尖峰的均匀分布,结果如图3所示。




Fig. 3 Distribution of data in the training set

图3 训练集数据分布

图中横坐标为不同类尖峰数量,纵坐标为不同噪声水平的数据集,例如C_Difficult1_020,指噪声水平为0.20的C_Difficult1数据集。

2.2 整体表现

本文在4个子数据集C_Easy1、C_Easy2、C_Difficult1和C_Difficult2上评估了模型分类性能,如表3所示。数据集中尖峰波形之间的相似程度是影响模型分类准确率的关键因素。与相似程度较高的C_Difficult1和C_Difficult2数据集相比,在C_Easy1和C_Easy2数据集上,模型获得了相对更高的准确率。此外,虽然随着噪声水平的提升,模型准确度有所降低,但平均准确度达到了92.74%,误差为2.84%。

为了进一步证明GASF-CBAM-ResNet模型的优越性,

Table 3 Overlapping spikes classification performance of GASF-CBAM-ResNet

表3 GASF-CBAM-ResNet 重叠尖峰分类表现

数据集	噪声水平	精度/%	准确度/%	F1/%
C_Easy1	0.05	94.369	95.210	94.341
C_Easy1	0.10	97.084	96.262	96.143
C_Easy1	0.15	94.666	93.831	93.293
C_Easy1	0.20	92.962	94.574	92.894
C_Easy1	0.25	92.460	92.310	92.181
C_Easy1	0.30	90.702	91.260	90.258
C_Easy1	0.35	89.962	89.974	89.257
C_Easy1	0.40	89.974	90.738	89.569
C_Easy2	0.05	94.086	94.069	93.540
C_Easy2	0.10	90.529	92.549	90.129
C_Easy2	0.15	91.687	92.954	90.957
C_Easy2	0.20	87.600	90.408	87.815
C_Difficult1	0.05	93.340	93.652	93.201
C_Difficult1	0.10	93.403	94.118	92.991
C_Difficult1	0.15	92.719	93.278	92.575
C_Difficult1	0.20	90.564	92.077	90.980
C_Difficult2	0.05	93.199	93.646	93.134
C_Difficult2	0.10	91.071	92.274	90.716
C_Difficult2	0.15	89.788	91.092	89.383
C_Difficult2	0.20	89.503	90.471	89.337
Mean±std		91.983±5.020	92.737±2.837	91.635±4.205

将本文方法与其他方法进行了比较,实验结果如表4所示。在4个子数据集C_Easy1、C_Easy2、C_Difficult1和C_Difficult2上,本文模型的平均准确率均高于一维CNN模型和一维CNN+LSTM模型。本文模型不仅在低级别噪声下有良好表现,在高噪声数据集C_Difficult1上更是有出色表现,准确率达到93.282%,明显高于前两者。文献[18]使用一维CNN+LSTM对重叠尖峰进行分类,分类准确率达到99.0%。但值得说明的是,在Liu等[18]采用的分类结果评价标准中,虽然数据集包括了6类尖峰(其中3类独立尖峰和3类重叠尖峰),但是模型性能评估时采用的是三分类标准,即识别出重叠尖峰聚类包含的其中一类独立尖峰聚类,则认为分类正确。而本文采用了更严格的评价标准,即六分类标准。在该标准中,重叠尖峰单独作为一个类别,也即如果独立尖峰聚类1被归类为聚类1,则认为结果正确;但是,如果独立尖峰聚类1的尖峰被归类为重叠1或重叠3,则认为分类错误。该方法旨在训练出一个更加精确,鲁棒性也更强的重叠尖峰分类模型。

Table 4 Result comparison of different classification models

表4 不同分类模型下的结果比较

(%)

数据集	CNN ^[18]	CNN+LSTM ^[18]	Ours
C_Easy1	89.820±1.40	89.479±1.94	91.974±5.33
C_Easy2	89.4781.94	88.827±1.14	93.309±0.58
C_Difficult1	89.889±0.06	88.471±0.11	93.282±0.76
C_Difficult2	89.946±1.74	88.644±0.12	91.870±1.46

2.3 与其他图像表示方法比较

图4为通过GASF转换后的6种尖峰示例,以及它们对应的二维图像。经编码后,图像可以有效地表达非重叠尖峰和重叠尖峰之间的差异。表5对比了GASF和格拉姆角差场(Gramian Angular Difference Field, GADF)、递归图(Recurrence Plot, RP)、马尔科夫变迁场(Markov Transition Field, MTF)这4种常用编码方法对分类效果的影响。

可以看到,GASF平均准确率超过93%,GADF为90.89%,RP为91.13%,MTF为84.64%,GASF明显优于其他图像表示法。尽管随着噪声水平的提升,分类准确率均下降,但即使在噪声水平为20%的数据集上,GASF分类准确率也高于90%。特别是对比分析5%噪声和20%噪声水平下的准确率,GASF在面对更高水平的噪声时能够表现得更好,体现了GASF的鲁棒性。此外,相较于Easy数据集,Difficult数据集中尖峰的相似性增加,导致分类难度更大。然而,有趣的是,GASF在Difficult数据集上的准确性表现更佳,显示出其对于相对复杂数据集的良好处理能力。

2.4 注意力机制对准确性的影响

本文开展了消融实验以探讨注意力模块对残差网络模块的影响。表6为4个子数据集在4个噪声水平上的平均准确率,其中,ResNet是原始残差网络,Channel-ResNet融合了ResNet和通道注意力模块,Spatial-ResNet融合了ResNet和CBAM中的空间注意力模块。在4个子数据集




Fig. 4 Overlapping spikes and non-overlapping spikes are transformed into image representation through GASF

图 4 重叠尖峰和非重叠尖峰通过 GASF 转化为图像表示

Table 5 The classification accuracy is obtained by 4 common coding methods

表 5 4 种常用编码方法下的分类准确率 (%)					
数据集	噪声水平	RP	MTF	GADF	GASF
C_Easy1	0.05	93.293	89.735	94.115	95.210
C_Easy1	0.10	92.865	85.000	93.902	96.262
C_Easy1	0.15	93.478	84.339	93.116	93.831
C_Easy1	0.20	91.695	82.142	91.383	94.574
C_Easy2	0.05	93.693	88.524	92.236	94.069
C_Easy2	0.10	92.035	86.177	91.361	92.549
C_Easy2	0.15	90.420	84.602	90.117	92.954
C_Easy2	0.20	88.737	80.878	88.052	90.408
C_Difficult1	0.05	92.058	87.058	92.157	93.652
C_Difficult1	0.10	90.564	84.354	90.645	94.118
C_Difficult1	0.15	89.744	81.092	89.741	93.278
C_Difficult1	0.20	88.285	77.868	87.227	92.077
C_Difficult2	0.05	91.701	89.419	91.598	93.646
C_Difficult2	0.10	90.784	87.352	90.490	92.274
C_Difficult2	0.15	89.863	84.825	89.594	91.092
C_Difficult2	0.20	88.811	80.941	88.465	90.471
Mean±std		91.127±2.86	84.644±10.77	90.887±3.78	93.154±2.49

上, Spatial-ResNet 和 CBAM-ResNet 的准确率高于 ResNet 和 Channel-ResNet, 表明空间注意力模块对模型性能有显著贡献。总体而言, CBAM-ResNet 能够在 4 个残差网络中以最高的精度对重叠尖峰进行分类。

Table 6 Average accuracy of 4 subdatasets at 4 noise levels

表 6 4 个子数据集在 4 个噪声水平上的平均准确率 (%)				
数据集	ResNet	Channel-ResNet	Spatial-ResNet	CBAM-ResNet
C_Easy1	91.445	89.913	92.365	93.020
C_Easy2	90.844	89.603	91.196	92.495
C_Difficult1	89.465	87.703	92.281	93.281
C_Difficult2	89.472	88.600	91.326	91.871

3 结语

在以往研究中,虽然监督学习已经应用于端到端的尖峰排序过程,但重叠尖峰问题仍需要手动或专门软件参与,例如 Phy、Neuroscope、CellExplorer。本文针对神经元电信号解码中的重叠尖峰分类问题,提出了一种基于 GASF-CBAM-ResNet 的尖峰分类模型,实现了无需人工操作的重叠尖峰自动分类。首先,针对重叠尖峰数据不平衡性问题,本文提出了一种构建重叠尖峰训练模板的方法,解决了分类器训练上的难题;其次,采用基于 GASF 的数据编码方法,将一维尖峰时序信号转换为二维图像,提升了对数据特征的表示;最后,设计了 CBAM-ResNet 模型,有效地结合了注意力机制和残差网络,增强了模型适用性和泛化性。在后续工作中,该模型可以与尖峰自动检测算法融合,实现真正意义上的端到端尖峰排序。未来,将考虑尖峰排序模型的轻量级和实时性,为在线侵入式脑机接口的实现提供算法基础。

参考文献:

[1] QUIROGA R Q, NADASDY Z, BENSHAUL Y. Unsupervised spike detection and sorting with wavelets and superparamagnetic clustering[J]. Neural Computation, 2004, 16(8): 1661-1687.

[2] WOUTERS J, KLOOSTERMAN F, BERTREND A. A neural network-based spike sorting feature map that resolves spike overlap in the feature space[C]//IEEE International Conference on Acoustics, Speech and Signal Processing, 2020: 1175-1179.

[3] BUCCINO A P, GARCIA S, YGER P. Spike sorting: new trends and challenges of the era of high-density probes[J]. Progress in Biomedical Engineering, 2022, 4(2): 022005.

[4] SAIF-UR-REHMAN M, ALI O, DYCK S, et al. SpikeDeep-Classifier: a

- deep-learning based fully automatic offline spike sorting algorithm [J]. Journal of Neural Engineering, 2021, 18(1):016009.
- [5] EOM J, PARK I Y, KIM S, et al. Deep-learned spike representations and sorting via an ensemble of auto-encoders [J]. Neural Networks, 2021, 134: 131–142.
- [6] LI Z, WANG Y, ZHANG N, et al. An accurate and robust method for spike sorting based on convolutional neural networks [J]. Brain Sciences, 2020, 10(11):835.
- [7] RACE M, LIBER C, NEMETH E, et al. Spike detection and sorting with deep learning [J]. Journal of Neural Engineering, 2020, 17(1):016038.
- [8] WU T, RAKAI A, SCHLETT K, et al. Learning to sort: few-shot spike sorting with adversarial representation learning [C]//2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2019: 713–716.
- [9] BERNERT M, YVERT B. An attention-based spiking neural network for unsupervised spike-sorting [J]. International Journal of Neural Systems, 2019, 29(8):1850059.
- [10] QIAN L, ZHENG S, DENG C, et al. An adaptive contrastive learning model for spike sorting [DB/OL]. <https://arxiv.org/abs/2205.11914>, 2022.
- [11] REY H G, PEDREIRA C, QUIROGA R Q. Past, present and future of spike sorting techniques [J]. Brain Research Bulletin, 2015, 119: 106–117.
- [12] MOKRI Y, SALAZAR R F, GOODELL B, et al. Sorting overlapping spike waveforms from electrode and tetrode recordings [J]. Frontiers in Neuroinformatics, 2017, 11: 53.
- [13] GARCIA S, BUCCINO A P, YGER P. How do spike collisions affect spike sorting performance? [J]. Neuroscience, 2022, 9(5):244819325.
- [14] PACHITARIU M, STEINMETZ N, KADIR S, et al. Kilosort: realtime spike-sorting for extracellular electrophysiology with hundreds of channels [DB/OL]. <https://www.biorxiv.org/content/10.1101/061481v1>, 2016.
- [15] FRANKE F, QUIROGA R, HIERLEMANN A, et al. Bayes optimal template matching for spike sorting - combining fisher discriminant analysis with optimal filtering [J]. Journal of Computational Neuroscience, 2015, 38:439–459.
- [16] EKANADHAM C, TRANCHINA D, SIMONCELLI E P. A unified framework and method for automatic neural spike identification [J]. Journal of Neuroscience Methods, 2014, 222:47–55.
- [17] PILLOW J W, SHLENS J, CHICHILNISKY E J, et al. A model-based spike sorting algorithm for removing correlation artifacts in multi-neuron recordings [J]. Plos One, 2013, 8(5):e62123.
- [18] LIU M, FENG J, WANG Y, et al. Classification of overlapping spikes using convolutional neural networks and long short term memory [J]. Computers in Biology and Medicine, 2022, 148:105888.
- [19] KIRANYAZ S, AVCI O, ABDELJABER O, et al. 1D convolutional neural networks and applications: a survey [J]. Mechanical Systems and Signal Processing, 2021, 151:107398.
- [20] STOLLENGA M F, BYEON W, LIWICKI M, et al. Parallel multi-dimensional LSTM, with application to fast biomedical volumetric image segmentation [C]//NIPS'15: Proceedings of the 29th International Conference on Neural Information Processing Systems, 2015:2998–3006.
- [21] SHANKAR A, DANDAPAT S, BARMA S. Seizure type classification using EEG based on Gramian Angular Field transformation and deep learning [C]//2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society, 2021:3340–3343.
- [22] KO D W, YANG J J. EEG-based schizophrenia diagnosis through time series image conversion and deep learning [J]. Electronics, 2022, 11(14):2265.
- [23] WANG Z, OATES T. Imaging time-series to improve classification and imputation [DB/OL]. <https://arxiv.org/abs/1506.00327>, 2015.
- [24] 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.
- [25] WANG M, ZHANG L, YU H, et al. A deep learning network based on CNN and sliding window LSTM for spike sorting [J]. Computers in Biology and Medicine, 2023, 159:106879.
- [26] XI C, LIU R. Detection of small floating target on sea surface based on Gramian angular field and improved efficientNet [J]. Remote Sensing, 2022, 14(17):4364.
- [27] LIAO Y, QING X, WANG Y, et al. Damage localization for composite structure using guided wave signals with Gramian angular field image coding and convolutional neural networks [J]. Composite Structures, 2023, 312:116871.
- [28] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]//Proceedings of the European Conference on Computer Vision, 2018:3–19.
- [29] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020:11534–11542.

(责任编辑:孙娟)