

基于深度学习网络的神经元自适应投影分类方法

蔺想红, 郑鉴洋, 王向文, 马慧芳
(西北师范大学计算机科学与工程学院, 甘肃兰州 730070)

摘 要: 传统的基于几何形态的神经元分类方法依赖于神经元空间结构特征的提取与选择, 会损失大量有用的神经元分类信息. 应用自适应投影算法将三维神经元进行转换, 不需要提取神经元的几何特征, 提出了一种基于深度学习网络的神经元几何形态分类方法. 该方法将原始神经元数据进行三维体素重建, 经过自适应投影过程构成二维神经元图像数据, 并构建了基于双卷积门限循环神经网络的深度学习模型对神经元进行分类. 将该方法应用于三种神经元分类数据集, 通过与基于特征提取的神经元分类方法相比, 实验结果表明该方法具有更高的分类准确率和良好的适应能力.

关键词: 神经元分类; 自适应投影; 卷积神经网络; 门限循环单元

中图分类号: TP183

文献标识码: A

文章编号: 0372-2112 (2020)07-1321-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2020.07.010

A Neuronal Classification Approach with Adaptive Projection Using Deep Learning Networks

LIN Xiang-hong, ZHENG Jian-yang, WANG Xiang-wen, MA Hui-fang
(School of Computer Science and Engineering, Northwest Normal University, Lanzhou, Gansu 730070, China)

Abstract: Traditional morphology-based neuronal classification approaches largely rely on the feature extraction and selection techniques of neuronal spatial structures, a lot of useful information for neuronal classification may be lost. Using the adaptive projection algorithm to convert the three-dimensional neuron data without feature extraction, this paper proposes a neuronal morphology classification approach based on deep learning networks. The three-dimensional voxel reconstruction is used for the original neuron data, and the two-dimensional neuron data is generated through adaptive projection process. Then, the deep learning model of double convolutional gated recurrent neural networks is established to classify neurons. The proposed approach is successfully applied to three neuronal classification datasets, the experiment results show that the proposed method has higher classification accuracy and flexibility than the neuronal classification methods based on feature extraction.

Key words: neuronal classification; adaptive projection; convolution neural network; gated recurrent unit

1 引言

大脑的结构和功能非常复杂, 人类脑计划结合神经科学与信息科学对大脑的结构特征和认知功能进行研究^[1,2]. 神经元是构成大脑复杂结构与功能的基本单位, 其中神经元的几何形态特征和电学物理特性是两个重要方面. 电学特性是指神经元在不同的刺激下所具有的电位发放模式, 电位发放可以通过微电极穿刺神经元得到, 研究者利用神经元细胞的电位发放模式

区分神经元的类别^[3]. 几何形态特征是指神经元的空间构象, 具体包含接受信息的树突, 处理信息的胞体和传出信息的轴突三部分结构^[4]. 实际上, 神经元具有复杂多样的空间几何形态结构, 应用几何形态数据对神经元的类型进行合理划分, 对于理解大脑的结构与功能关系, 以及信息的传递非常重要.

目前, 研究者应用机器学习方法对神经元几何形态分类问题进行深入研究, 取得了诸多成果^[5]. Alavi等^[6]对神经元的显微图像进行分析, 从中获取神经元

收稿日期: 2019-01-11; 修回日期: 2019-12-15; 责任编辑: 孙瑶

基金项目: 国家自然科学基金(No. 61762080, No. 61762078); 兰州市科学技术计划(No. 2019-1-34); 西北师范大学青年教师科研能力提升计划创新团队(No. 6008-01602)

的几何形态特征信息,从而对啮齿动物的多巴胺能神经元进行分类,还比较了支持向量机(Support Vector Machine, SVM)、反向传播神经网络(Back Propagation Neural Network, BPNN)和逻辑回归(Logistic Regression, LR)三种方法的神经元分类性能. Han 和 Zeng^[7]使用分形几何方法描述神经元的空间结构,计算出神经元的分形维度作为形态特征,并与其他 16 个形态特征构成分类特征集合,基于 SVM 的实验结果表明分形维度对于神经元分类的重要性. Mihaljević 等^[8]基于朴素贝叶斯(Naive Bayes, NB)方法构建了贝叶斯网络分类器,通过对五类轴突分支特征的分析与选择,实现了对氨基丁酸能中间神经元的几何形态分类. 文献[9]提出了基于集成极限学习机(Extreme Learning Machine, ELM)的神经元分类方法,首先使用稀疏主成分处理神经元几何特征,然后对神经元的分类数据进行分类. 文献[10]提出了基于深度残差神经网络(Deep Residual Neural Network, DRNN)的神经元分类方法,首先对神经元的几何形态特征数据进行归一化处理,然后对神经元进行分类. Hernández-Pérez 等^[11]将神经元的三维结构变换为特定的时间序列,再从时间序列数据中提取特征并进行选择,应用 SVM 等机器学习方法实现神经元的分类. 此外,一些神经元分类方法没有应用神经元的类别信息,采用聚类思想实现神经元几何形态的划分^[12,13].

通过以上分析发现,这些基于特征提取的方法主要是选择一些基本的几何形态特征(或加入特殊的几何形态特征)构成特征集合,从而实现神经元分类问题的求解^[14]. 但实际上,三维神经元的几何形态结构非常复杂,基于特征提取的神经元分类方法存在以下局限性:(1)神经元分类的准确性依赖于得到的特征值,而神经元的几何特征提取与选择缺乏统一的标准,不同神经元数据集的分类方法对几何形态特征的提取与选择具有较大的差异;(2)所提取的特征值一般表示神经元几何形态的统计特性,这会损失大量有用的神经元分类信息,特别是神经元的房室角度、结构变化等细节. 因此,应用表示神经元几何结构的整体图像,通过深度学习网络进行几何形态特征的学习与变换,从而构建神经元分类的自适应计算框架是一个重要的研究内容.

鉴于目前研究中存在的这些问题,本文提出了一种新的三维神经元几何形态分类方法,该方法的特点是不需要提取神经元的几何特征,结合神经元图像信息与深度学习网络对神经元进行类型划分. 首先,构建了三种不同的三维神经元分类数据集,三维神经元数据采用 SWC 格式表示. 其次,将原始神经元的 SWC 数据进行三维体素重建,经过自适应投影过程构成二维神经元数据,包括像素数量最多投影和图像尺寸最大

投影两类数据. 最后,提出了一种双卷积门限循环神经网络(Double Convolutional Gated Recurrent Neural Network, DCGRNN)深度学习模型,并应用所转化的二维投影数据进行神经元几何形态的分类.

2 三维神经元数据的自适应投影方法

2.1 三维神经元数据集

NeuroMorpho. Org 是一个包含三维重建数据和神经元相关信息的神经元数据库,收集来自全球 200 多个实验室的神经元数据,并不断更新和发布新数据^[15]. 为了验证本文方法的有效性,根据不同位置区域的神经元、不同动物新皮质锥体神经元、以及线虫体内的不同神经元构建了三种神经元分类数据集.

(1)不同位置区域神经元数据集. 该数据集主要进行黑腹果蝇的类胆碱功能神经元所处不同位置区域的判定分类. 所选取的区域为:蘑菇体(Mushroom Body)、食管下神经节(Subesophageal Ganglion)、腹外侧神经髓质(Ventrolateral Neuropils)和触角神经叶(Antennal Lobe). 对于四个不同的位置区域,每个区域神经元选择的分类样本数量均为 43,样本总数为 172. 由于不同位置区域神经元具有较高的几何形态相似性,要对其进行准确的分类非常具有挑战性.


(2)不同动物种类神经元数据集. 该数据集主要对不同动物种类新皮质区域中的锥体神经元(Pyramidal Neuron)进行分类. 所选动物种类为人类、黑猩猩和老鼠三个类别,其中每个分类样本数量为 43,样本总数为 129. 该数据集中的神经元几何形态具有一定差异性,可以较好地检验本文方法和特征提取方法对神经元分类的效果.

(3)线虫体内神经元种类数据集. 该数据集收集了线虫神经系统中不同类别的神经元. 所选神经元类型共三类,分别为中间神经元(Interneuron)、运动神经元(Motoneuron)和躯体神经元(Somatic Neuron). 在所构建的神经元分类数据集中,每个分类样本数量均为 64,样本总数为 192.


2.2 神经元的三维体素重建方法

NeuroMorpho. Org 提供了 SWC 格式的神经元数据,一个神经元根据空间结构可以离散为很多房室,每行表示一个房室,包含了 7 个标准数据点:房室的标号,房室的类型(例如胞体、轴突、树突、尖端树突等),房室的 x, y, z 坐标,房室的半径,以及与该房室连接的母房室标号. 要通过三维神经元的 SWC 数据来生成投影图像,需要先构建神经元的三维体素图像. 如果直接利用 SWC 文件中的每个房室信息表征神经元的三维几何形态结构,将可能丢失大量神经元三维结构的体素信息. 因此,基于神经元房室的三维坐标和母房室数据,可以得到

当前房室的起始坐标 $C_s = \{x_s, y_s, z_s\}$ 和终止坐标 $C_e = \{x_e, y_e, z_e\}$, 利用线性插值的方法构建该房室的三维体素向量数据. 对所有房室进行线性插值, 就得到神经元的三维体素重建图像. 图 1 给出了线性插值前后的三维神经元图像, 图 1(a) 表示仅应用 SWC 文件中的房室坐标生成的三维神经元图像, 图 1(b) 表示应用线性插值后生成的三维神经元体素图像. 可以看出, 体素重建后的神经元几何结构信息更详细, 可进一步进行神经元的自适应投影.



(a) 应用SWC文件房室坐标生成的三维神经元图像



(b) 基于线性插值生成的三维神经元体素图像

图1 三维神经元原始图像与体素重建图像

2.3 神经元的自适应投影算法

在得到三维神经元体素图像后, 应用投影变换原理将神经元投影到一个投影面上, 其投影能反映它在长、宽、高三个方向的形状, 并能沿轴向测量^[16]. 采用正轴测投影的方式, 把三维神经元绕 Y 轴旋转 φ 角, 再绕 X 轴旋转 α 角, 在 $Z=0$ 作正投影, 通过正轴测投影矩阵计算三维体素坐标点投影后的二维像素坐标点, 从而得到投影的二维神经元图像. 投影角度 φ 和 α 在区间 $[0^\circ, 330^\circ]$ 每隔 30° 进行取值, 这样每个神经元样本共可投影生成 144 个二维神经元图像. 为了尽可能的保存投影后的三维神经元形态特征信息, 本文设计了两种自适应的二维神经元图像数据集构建方式: (1) 基于像素数量最多化的投影准则, 通过遍历单个神经元的 144 个投影角度生成对应的像素图像, 选取所生成二维图像中像素最多的投影作为结果; (2) 基于图像尺寸最大化的投影准则, 在 144 个投影中选取图像尺寸最大的二维神经元图像作为结果. 此外, 为了与自适应投影进行比较, 随机生成角度 φ 和 α 进行投影, 并用投影生成的二维神经元图像构成数据集.

由于神经元数据范围较大, 为了尽可能保留神经元之间的比例特征, 同时减少平移不变性的影响, 对于投影构成的二维神经元数据样本集按比例进行缩放. 考虑深度学习网络的训练精度和时间性能, 将投影数据集中尺寸最大的神经元缩放为 256×256 大小的图像, 其余神经元的投影图像根据最大神经元的尺寸按比例对像素坐标进行缩放计算. 投影图像数据集按比例缩放完成后, 由于输入深度神经网络的神经元统一为 256×256 大小的图像, 将小于 256×256 的神经元图像居中并填充为 256×256 大小的图像, 即对扩大部分用白色像素进行填充. 算法 1 给出了神经元的自适应投影算法, 分为两个阶段: 第一个阶段为神经元的投影与选择过程, 第二个阶段为投影构成二维神经元图像的缩放过程. 对于神经元的随机角度投影, 仅在第一阶段中随机生成角度 φ 和 α 投影得到二维神经元图像, 第二阶段与自适应投影算法相同.

算法 1 神经元的自适应投影算法

```

输入: 三维神经元体素图像数据集、投影方式
输出: 对应投影方式的二维神经元图像数据集
//第一阶段: 三维神经元投影与选择过程
1. for 每一个输入的三维神经元体素图像 do
2.   for 在区间  $[0^\circ, 330^\circ]$  内每隔  $30^\circ$  变化投影角度  $\varphi$  和  $\alpha$  do
3.     对当前三维神经元体素图像进行投影变换
4.     switch 投影方式
5.       case 像素数量最多化: 记录像素数量最多投影结果
6.       case 图像尺寸最大化: 记录图像尺寸最大投影结果
7.     end switch
8.   end for
9.   将选择的投影图像存入二维神经元图像数据集
10. end for
//第二阶段: 二维神经元图像的缩放过程
11. 在二维神经元图像集中选择尺度最大的图像, 并记录最大尺寸值
12. for 数据集中每一个投影的二维神经元图像 do
13.   根据当前二维神经元图像的尺寸计算缩放比例
14.   根据缩放比例对当前神经元图像的像素坐标进行缩放
15. end for
16. for 数据集中每一个缩放的二维神经元图像 do
17.   将二维神经元图像居中, 填充为  $256 \times 256$  大小的图像
18. end for
19. 构成最终的二维神经元图像数据集

```

图 2 给出了基于自适应投影算法的二维神经元图像生成结果, 图 2(a) 表示使用线性插值后生成的三维神经元体素图像, 图 2(b) 和 (c) 分别表示从 144 个投影图像中选择得到的像素数量最多和图像尺寸最大的投影图像, 图 2(d) 表示在随机投影角度下生成的投影图像. 为了分析不同投影选择方式对神经元分类准确率的影响, 对于不同位置区域神经元数据集、不同物种神经元的数据集和线虫体内神经元种类数据集, 分别

构成像素数量最多投影、图像尺寸最大投影和随机角度投影三类不同的二维神经元图像样本集.

3 神经元几何形态分类模型

3.1 双卷积门限循环神经网络

卷积神经网络是一种适用于深度学习理论的人工神经网络模型,广泛应用于各种图像识别任务.由于该模型可以直接使用图像数据作为输入,从而避免了图像预处理和特征提取等复杂操作^[17].而门限循环神经网络是长短时记忆网络(Long Short-Term Memory Net-

work, LSTM)的一个变体,与传统神经网络和卷积神经网络不同,门限循环单元网络一般利用“序列信息”来表达对数据信息的记忆,可以更有效地学习数据的重要特征,丢弃数据干扰特征^[18].结合卷积神经网络和门限循环单元网络,本文提出了一种双卷积门限循环神经网络,通过先使用两个卷积神经网络分别对像素数量最多和图像尺寸最大的神经元投影图像进行特征学习,接着将两个卷积神经网络的平铺层进行横向拼接融合,再利用门限循环单元神经网络进一步得到其中更关键的特征,最后进行神经元的分类.

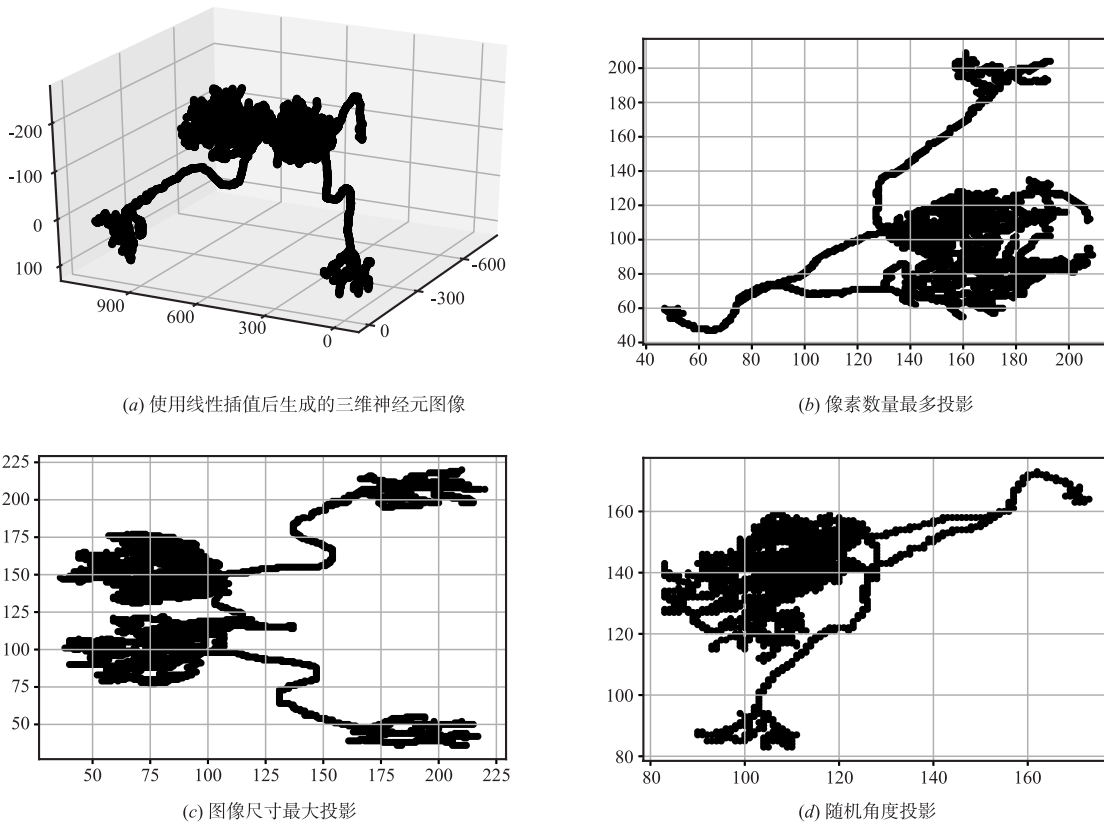


图2 基于自适应投影算法的二维神经元图像生成结果

work, LSTM)的一个变体,与传统神经网络和卷积神经网络不同,门限循环单元网络一般利用“序列信息”来表达对数据信息的记忆,可以更有效地学习数据的重要特征,丢弃数据干扰特征^[18].结合卷积神经网络和门限循环单元网络,本文提出了一种双卷积门限循环神经网络,通过先使用两个卷积神经网络分别对像素数量最多和图像尺寸最大的神经元投影图像进行特征学习,接着将两个卷积神经网络的平铺层进行横向拼接融合,再利用门限循环单元神经网络进一步得到其中更关键的特征,最后进行神经元的分类.

双卷积门限循环神经网络模型基于 Keras 实现^[19],其结构如图 3 所示.卷积部分具体参数如下:按层顺序滤波器数量为 32-64-128-256-512,卷积核大小为 6-5-4-3-2,滑动步长为 3-2-2-1-1,池化大小为 3-2-2-2,随机丢弃保留比例为 0.3-0.3-0.2-0.2.门限循环单元神经网络具体参数如下:时间步长为 4,神经元数量为 128-64.双卷积门限循环神经网络模型其他参数为:使用漏电 ReLU 作为激活函数,批量归一化来优化权重调整,损失函数为分类交叉熵(Categorical Cross Entropy),最后使用 Softmax 作为激活函数实现多分类.深度学习网络迭代次数为 200,并且应用了过早停止技术来防止过拟合^[20].由于不同的训练批次参数是影响神经元分类准确率的关键因素之一,所以对于不同数据集使用的训练批次大小(Batch Size)

参数在第 4 节实验中进行了分析,深度学习网络的其余初始化参数均使用 Keras 推荐的参数.

3.2 神经元几何形态分类计算框架

为了应用双卷积门限循环神经网络实现三维神经元的形态分类,图 4 给出了基于自适应投影的神经元几何形态分类计算框架.神经元几何形态分类的主要流程为:首先,将神经元的 SWC 格式数据应用线性插值方法重建三维神经元的体素图像.其次,将三维体素图像按照第 2 节中的自适应投影方法生成基于像素数量最多化和图像尺寸最大化两个二维神经元数据集.最后,基于设定的随机种子数按照 8:2 的比例划分训练集和测试集,再将划分好的训练集用于深度学习网络模型,测试集用于验证训练之后分类模型的性能.




图3 双卷积门限循环神经网络结构示意图

4 模拟实验与结果分析

在模拟实验中,重复进行10次随机实验,通过计算10次实验的平均值和标准偏差作为最终结果.对于神经元几何形态分类准确率的计算可定义为

$$accuracy = \frac{1}{n_{sample}} \sum_{i=0}^{n_{sample}-1} 1(\hat{y}_i = y_i) \quad (1)$$

其中,设 \hat{y}_i 是第 i 个样本的预测值, y_i 是相应的实际值, n_{sample} 表示神经元分类数据集中的样本数量.

4.1 不同深度学习网络模型的分析

在该组实验中,针对投影生成的不同二维神经元图像数据集,分析比较以下四种基于深度学习网络的神经元分类模型:(1)双卷积门限循环神经网络,同时将像素数量最多和图像尺寸最大神经元数据集输入到

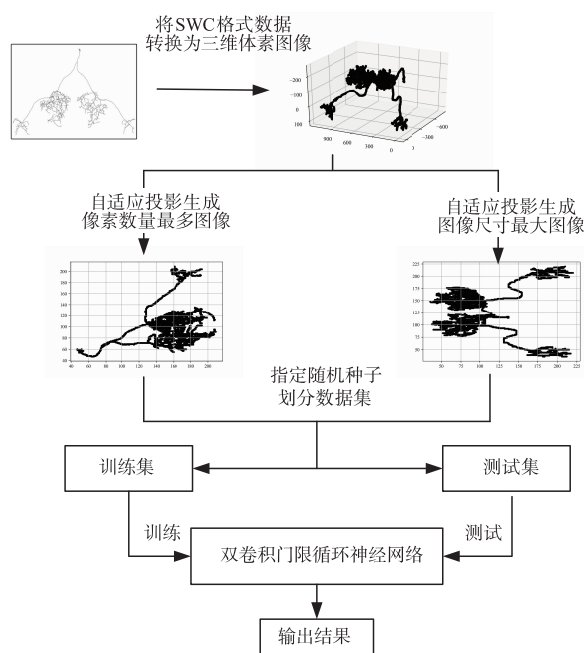


图4 基于自适应投影的神经元几何形态分类计算框架

两个卷积神经网络中,然后应用门限循环单元网络进行训练;(2)应用单个卷积神经网络和像素数量最多神经元数据集进行分类;(3)应用单个卷积神经网络和图像尺寸最大神经元数据集进行分类;(4)应用单个卷积神经网络和随机角度投影(即从2.3节生成的144个二维神经元图像中随机选择1个)生成的神经元数据集进行分类.其中单个卷积神经网络模型的规模和参数设置和双卷积门限循环神经网络中的卷积部分一致,具体描述见3.1节.此外,对于深度学习神经网络来说,选择合适的训练批次大小对于模型学习的结果具有重要影响.为了分析批次大小对训练模型的影响,选择的参数值分别为4、8、16、32、64和128.

图5~图7给出了双卷积门限循环神经网络和三种单个卷积神经网络模型在不同批次大小下的性能比较结果,可以看出双卷积门限循环神经网络模型具有更高的神经元分类准确率.对于不同位置区域神经元

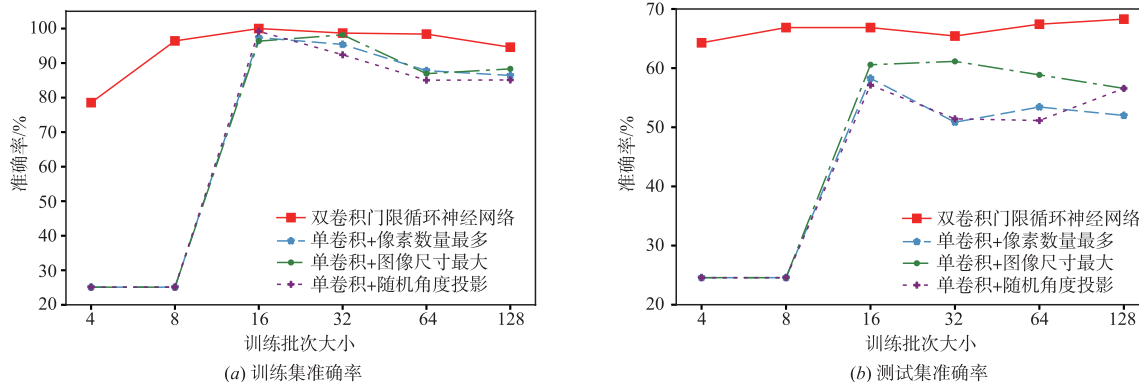


图5 不同位置区域神经元数据集分类准确率比较

数据集使用双卷积门限循环神经网络模型时,选择批次大小为 16 时训练集准确率达到 100%,而选择批次大小为 128 时测试集准确率最高,平均值为 68.29% (如图 5 所示).在图 6 中可以看出,不同动物种类神经元数据集应用双卷积门限循环神经网络模型时,批次

大小为 16 时训练集准确率为 100%,批次大小为 64 时测试集准确率最高,平均值为 95.00%.如图 7 所示,线虫体内神经元种类数据集在批次大小为 32 时训练集和测试集的分类准确率最高,分别为 99.93% 和 81.54%.

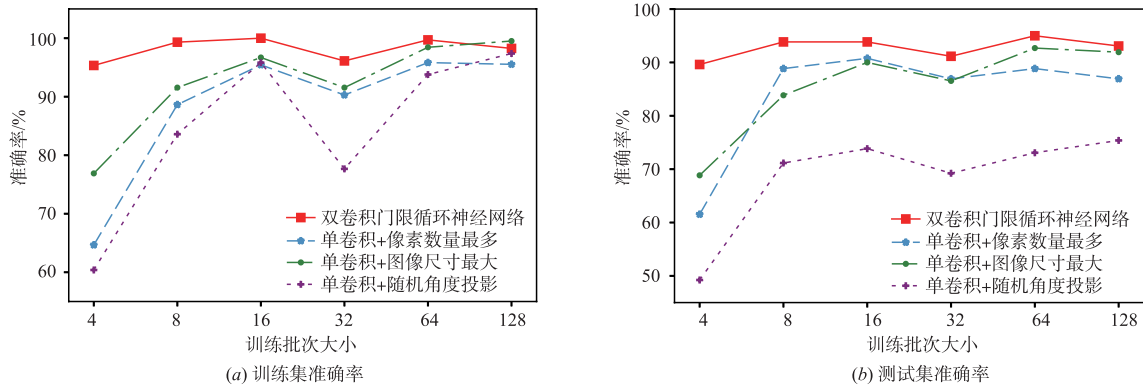


图6 不同动物种类神经元数据集分类准确率比较

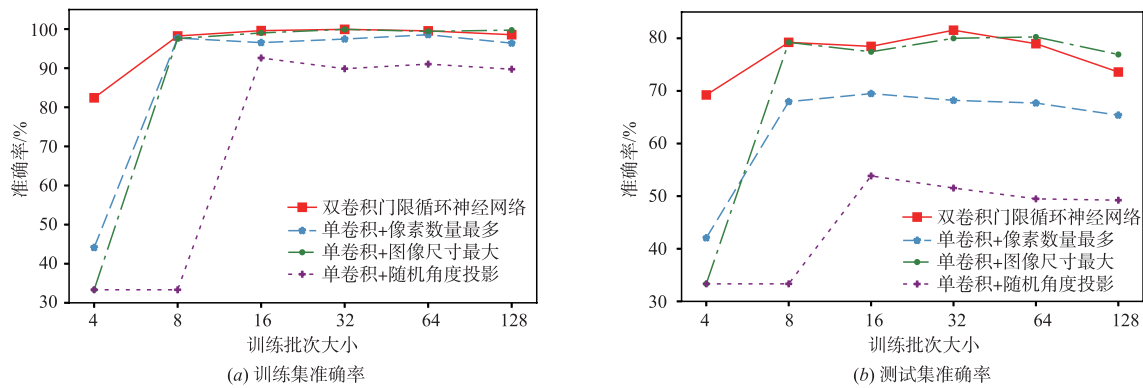


图7 线虫体内神经元种类数据集分类准确率比较

对于四种不同的基于深度学习网络的神经元分类模型,双卷积门限循环神经网络模型具有最高的神经元分类准确率,主要原因是在深度学习网络的训练过程中,同时使用了像素数量最多投影和图像尺寸最大投影两类神经元图像数据集,通过网络学习和映射可以获取到更多的三维神经元几何形态特征.而应用单个卷积神经网络模型,并输入像素数量最多或图像尺寸最大投影图像的情况下,神经元的分类准确率要低于双卷积门限循环神经网络模型.从图 5 ~ 图 7 中可以看出,单个卷积神经网络与随机角度投影生成的神经元数据集构成的分类模型准确率最低,表明神经元的自适应投影算法得到的二维图像比随机角度投影生成的图像数据包含更多的神经元几何形态特征信息.

4.2 神经元分类过程分析

应用双卷积门限循环神经网络对神经元进行分类,图 8 给出了三类神经元数据集一次训练过程的分类准确率变化曲线.从图 8(a)可以看出,不同位置区域神经元数据集在整个过程中训练集和测试集准确率缓

慢上升,在 50 次迭代之前上升较快.由于该数据集中神经元形态差异较小,而且类别较多,导致了双卷积门限循环神经网络模型在该数据集上训练的收敛过程较为缓慢.如图 8(b)所示,不同动物种类神经元数据集在训练迭代到 10 次左右时准确率会快速上升,之后产生一定震荡,接着震荡减少并趋于稳定,然后在过早停止机制下结束训练.由于该数据集中神经元的几何形态具有较大差异,可以看出本文所提模型在该数据集上的训练非常有效,当批次大小为 64 时,平均训练集准确率为 99.71%,测试集准确率为 95.00%.如图 8(c)所示,线虫体内神经元种类数据集在 85 次迭代后,训练集数据的分类准确率趋于稳定,而测试集数据的分类准确率具有较大的振荡.主要原因是该数据集中神经元几何形态的差异不像不同动物种类神经元数据集中那样明显,而且数据量也更大,从而导致了该数据集的训练过程更慢且波动更大.

根据以上结果可以看出,应用双卷积门限循环神经网络模型实现神经元类别的划分,所构建的三维神经元




图8 神经元分类准确率变化曲线

数据集对分类准确率具有较大的影响,数据集中神经元几何形态的差异越小,深度学习模型对神经元的分类就越困难.数据集中神经元的类别越多,比如不同位置区域神经元数据集为四分类问题,而不同动物种类和线虫体内神经元数据集为三分类问题,分类模型的训练收敛过程就越慢,神经元的分类准确率也更低.

4.3 不同神经元分类方法的比较

为了进一步分析基于双卷积门限循环神经网络的神经元分类模型,应用基于特征提取的方法进行对比.根据文献[6~11]等神经元几何形态特征的选择方式,本文选取神经元的两类特征来刻画神经元形态:(1)描述神经元的总体特征,包括:胞体表面积,干的数目,分叉数目,分支数目,神经元的宽度、高度和深度,以及总长度、表面积和体积;(2)描述神经元房室、分叉和分支

的分布特征,包括:房室的直径、吸氏距离和路径距离,表示分叉特征的非对称分化、罗尔比率、局部分叉角和远处分叉角,以及表示分支特征的分支级数、压缩比和破碎程度.总共 20 个特征参数,使用 L-Measure 来计算每个神经元的形态特征值^[21].

基于所选取的 20 个用来刻画神经元几何形态的特征参数,并使用不同类型的机器学习方法对神经元进行分类,例如基于广义线性的逻辑回归^[6]、基于先验概率推断的朴素贝叶斯^[8]、基于信息熵的决策树(Decision Tree, DT)^[22]、基于空间距离的 K 近邻(K-Nearest Neighbor, KNN)^[23]和支持向量机模型^[7]、BP 神经网络、长短时程记忆网络^[24]、集成极限学习机^[9]和深度残差神经网络^[10].对于 LR、NB、DT、KNN、SVM 和 BPNN 分类器,采用 SKLEARN 实现^[25],参数设置在 SKLEARN 中推荐参数的基础上,通过大量的实验对参数进行了调优设置. LSTM 包含 2 层,每层有 50 个神经元,应用 Keras 实现^[19]. ELM 和 DRNN 按照对应论文中的参数,并结合本文实验中所使用的神经元分类数据集对参数进行了微调.如表 1 所示,给出了各种不同分类器的神经元分类结果.对于不同位置区域神经元数据集,基于特征提取的 DRNN 方法具有较高的神经元分类准确率,训练集和测试集的分类准确率分别为 78.18% 和 65.43%,而基于自适应投影的 DCGRNN 方法的分类准确率分别为 94.60% 和 68.29%.对于不同动物种类神经元数据集,SVM、BPNN 和 ELM 分类方法在训练集的分类准确率分别为 97.67%、96.70% 和 96.41%,在测试集的分类准确率均为 92.69%,而本文所提 DCGRNN 方法在训练集和测试集上的分类准确率分别为 99.71% 和 95.00%.对于线虫体内神经元种类数据集的测试,特征提取方法中的 KNN 在测试集中具有较高的分类准确率 77.18%,但仍然低于 DCGRNN 方法的分类准确率 81.54%.

5 结论

生物神经元具有复杂多样的空间几何形态结构,神经元的几何形态分类是神经信息学研究领域的一个重要问题.本文提出一种基于双卷积门限循环神经网络的神经元自适应投影及形态分类方法.该方法先把 SWC 格式的三维神经元数据通过线性插值方法重建为三维体素图像,并应用自适应投影算法生成像素数量最多和图像尺寸最大两类二维神经元图像数据集,然后再使用提出的双卷积门限循环神经网络模型对神经元进行分类.在模拟实验中,对于所构建的三种神经元数据集,分析了不同深度学习网络模型和训练批次大小对神经元分类准确率的影响,以及双卷积门限循环神经网络模型分类准确率的变化过程.通过与已有文献中基于特征提取的分类方法进行比较,表明本文所

表 1 本文方法与特征提取方法的分类准确率比较

数据集	分类方法		分类准确率(%)	
			训练集	测试集
不同位置 区域神经 元数据集	特征提取	LR	75.55 ± 1.89	63.14 ± 15.03
		NB	79.64 ± 1.80	47.14 ± 11.84
		DT	100	55.00 ± 16.82
		KNN	87.96 ± 0.79	64.57 ± 14.70
		SVM	81.68 ± 1.80	64.86 ± 12.42
		BPNN	83.43 ± 1.98	58.86 ± 15.07
		LSTM	80.95 ± 11.15	52.86 ± 17.57
		ELM	81.38 ± 2.49	63.43 ± 72.28
		DRNN	78.18 ± 7.97	65.43 ± 4.93
	自适应投影	DCGRNN	94.60 ± 4.99	68.29 ± 7.06
不同动物 种类神经 元数据集	特征提取	LR	93.79 ± 1.84	90.00 ± 7.94
		NB	96.89 ± 0.77	77.31 ± 9.15
		DT	100	84.23 ± 6.14
		KNN	92.52 ± 1.78	91.15 ± 7.91
		SVM	97.67 ± 1.23	92.69 ± 5.86
		BPNN	96.70 ± 1.14	92.69 ± 6.89
		LSTM	98.35 ± 2.71	90.38 ± 7.08
		ELM	96.41 ± 1.03	92.69 ± 8.78
		DRNN	97.67 ± 3.24	92.31 ± 6.01
	自适应投影	DCGRNN	99.71 ± 0.66	95.00 ± 3.65
线虫体内 神经元种 类数据集	特征提取	LR	77.78 ± 1.69	67.69 ± 7.66
		NB	79.93 ± 1.31	58.97 ± 9.21
		DT	100	71.03 ± 7.93
		KNN	83.20 ± 2.18	77.18 ± 4.26
		SVM	82.35 ± 1.80	69.23 ± 7.15
		BPNN	84.90 ± 2.19	72.05 ± 6.45
		LSTM	88.17 ± 3.10	60.77 ± 11.34
		ELM	85.03 ± 2.29	61.54 ± 11.1
		DRNN	85.75 ± 5.06	76.41 ± 3.97
	自适应投影	DCGRNN	99.93 ± 0.61	81.54 ± 8.53

提基于自适应投影的双卷积门限循环神经网络分类方法具有更高的准确率和稳定性。基于自适应投影的神经元分类方法不再计算和选择三维神经元的几何形态特征,为解决神经元的分类问题提供了一种新思路。然而该方法目前仅使用了三维神经元的房室坐标及连接信息,没有考虑房室的类型和半径信息,因此,如何在分类模型中加入这些信息以提高神经元的分类准确率,需要进一步的研究。

参考文献

- [1] Wang Y, Li Y, Huang W, et al. Research progression on human brain project[J]. Chinese Journal of Medical Physics, 2016, 33(2): 109 - 112.
- [2] 彭丝雨,周到,张家琦,等. 基于互信息的脑网络及测谎研究[J]. 电子学报, 2019, 47(7): 1551 - 1556.
PENG Si-yu, ZHOU Dao, ZHANG Jia-qi, et al. Research on mutual information-based brain network and lie detection[J]. Acta Electronica Sinica, 2019, 47(7): 1551 - 1556. (in Chinese)
- [3] Oshio K I, Yamada S, Nakashima M. Neuron classification based on temporal firing patterns by the dynamical analysis with changing time resolution (DCT) method[J]. Biological Cybernetics, 2003, 88(6): 438 - 449.
- [4] Lin X, Li Z, Ma H, et al. An evolutionary developmental approach for generation of 3D neuronal morphologies using gene regulatory networks[J]. Neurocomputing, 2018, 273: 346 - 356.
- [5] Zeng H, Sanes J R. Neuronal cell-type classification: Challenges, opportunities and the path forward[J]. Nature Reviews Neuroscience, 2017, 18(9): 530 - 546.
- [6] Alavi A, Cavanagh B, Tuxworth G, et al. Automated classification of dopaminergic neurons in the rodent brain[A]. Proceedings of the International Joint Conference on Neural Networks[C]. Atlanta, Ga, USA: IEEE, 2009. 81 - 88.
- [7] Han F, Zeng J. Research for neuron classification based on support vector machine[A]. Proceedings of the 3d International Conference on Digital Manufacturing and Automation[C]. Guilin, China: IEEE, 2012. 646 - 649.
- [8] Mihaljević B, Benavides-Piccione R, Bielza C, et al. Bayesian network classifiers for categorizing cortical GABAergic interneurons[J]. Neuroinformatics, 2015, 13(2): 193 - 208.
- [9] 李佳. 基于集成极限学习机的神经元分类算法研究[D]. 上海: 东华大学, 2017.
Li Jia. Research on Neuron Classification Based on Ensemble of Extreme Learning Machine[D]. Shanghai: Donghua University, 2017. (in Chinese)
- [10] Lin X, Zheng J, Wang X, et al. A neuronal morphology classification approach based on deep residual neural networks[A]. Proceedings of the 25th International Conference on Neural Information Processing[C]. Siem Reap, Cambodia: Springer, 2018. 336 - 348.
- [11] Hernández-Pérez L A, Delgado-Castillo D, Martín-Pérez R, et al. New features for neuron classification[J]. Neuroinformatics, 2019, 17(1): 5 - 25.
- [12] 张静, 邓仕槐, 郭航, 等. 聚类分析在神经元形态特征分类中的应用[J]. 浙江大学学报(农业与生命科学版), 2011, 37(5): 493 - 500.

- Zhang Jing, Deng Shi-Huai, Guo Hang, et al. Application of cluster analysis in morphological characteristics of neurons[J]. Journal of Zhejiang University (Agriculture & Life Sciences), 2011, 37(5):493-500. (in Chinese)
- [13] Yu C, Han Z, Zeng W, et al. Morphology cluster and prediction of growth of human brain pyramidal neurons[J]. Neural Regeneration Research, 2012, 7(1):36-40.
- [14] López-Cabrera J D, Lorenzo-Ginori J V. Feature selection for the classification of traced neurons [J]. Journal of Neuroscience Methods, 2018, 303:41-54.
- [15] Ascoli G A, Donohue D E, Halavi M. NeuroMorpho. Org: A central resource for neuronal morphologies [J]. Journal of Neuroscience, 2007, 27(35):9247-9251.
- [16] Salomon D. Transformations and Projections in Computer Graphics[M]. Springer London, 2006.
- [17] 杨勃, 邵泉铭, 李文彬, 等. 深度卷积神经网络鉴别正交特征生成及其应用[J]. 电子学报, 2018, 46(10):2376-2383.
YANG Bo, SHAO Quan-ming, LI Wen-bin, et al. Deep-convolutional neural networks controlled by discriminatively orthogonal feature generation and its application [J]. Acta Electronica Sinica, 2018, 46(10):2376-2383. (in Chinese)
- [18] Chung J, Gulcehre C, Cho K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling [J]. arXiv, 2014, 1412.3555.
- [19] François Chollet et al. Keras [DB/OL]. <https://github.com/keras-team/keras>, 2015.
- [20] Wu X, Liu J. A new early stopping algorithm for improving neural network generalization [A]. Proceedings of the Second International Conference on Intelligent Computation Technology and Automation [C]. Changsha, China: IEEE, 2009. 15-18.
- [21] Scorcioni R, Polavaram S, Ascoli G A. L-Measure: A web-accessible tool for the analysis, comparison and search of digital reconstructions of neuronal morphologies [J]. International Journal of Cancer, 2008, 73(4):492-496.
- [22] Landgrebe D. A survey of decision tree classifier methodology [J]. IEEE Transactions on Systems Man and Cybernetics, 2002, 21(3):660-674.
- [23] Fukunaga K, Hostetler L. Optimization of K-nearest neighbor density estimates [J]. IEEE Transactions on Information Theory, 1973, 19(3):320-326.
- [24] 吕品, 李全刚, 柳厅文, 等. 基于双向 LSTM 的误植域名滥用检测方法 [J]. 电子学报, 2018, 46(9):2081-2086.
LÜ Pin, LI Quan-gang, LIU Ting-wen, et al. Towards typosquatting abuse detection using bi-directional LSTM [J]. Acta Electronica Sinica, 2018, 46(9):2081-2086. (in Chinese)
- [25] Pedregosa F, Varoquaux G, Gramfort A, et al. Scikit-learn: Machine learning in Python [J]. Journal of Machine Learning Research, 2011, 12:2825-2830.

作者简介



蔺想红 男, 1976 年 1 月生于甘肃天水. 2009 年获哈尔滨工业大学计算机应用技术专业博士学位, 现任西北师范大学计算机科学与工程学院教授, 硕士生导师. 研究方向为神经网络、深度学习、智能软件.
E-mail: linxh@nwnu.edu.cn



郑鉴洋 男, 1990 年 9 月生于广西柳州. 西北师范大学计算机科学与工程学院硕士研究生. 研究方向为神经网络、机器学习.
E-mail: 148406243@qq.com