

基于 PCA 和改进 K 均值算法的动作电位分类

师 黎, 杨振兴, 王治忠, 王 岩

(郑州大学电气工程学院, 郑州 450001)

摘 要: 微电极阵列记录的神经元信号往往是电极临近区域数个神经元的动作电位信号以及大量背景噪声的混叠, 研究神经系统的信息处理机制以及神经编码、解码机理需了解相关每个神经元的动作电位, 因此需从记录信号中分离出每个神经元的动作电位。基于此, 提出基于主元分析(PCA)和改进 K 均值相结合的动作电位分类方法。该方法采用 PCA 提取动作电位特征, 使用改进 K 均值算法实现动作电位分类。实验结果表明, 该方法降低了动作电位的特征维数以及 K 均值算法对初始分类重心的依赖, 提高动作电位分类结果的正确率及稳定性。尤其是在处理低信噪比信号时, 分类正确率仍能达到理想水平。

关键词: 微电极阵列; 主元分析; 特征提取; 改进 K 均值; 动作电位分类

Action Potential Classification Based on PCA and Improved K-means Algorithm

SHI Li, YANG Zhen-xing, WANG Zhi-zhong, WANG Yan

(School of Electrical Engineering, Zhengzhou University, Zhengzhou 450001, China)

【Abstract】 Neural signal recorded by the microelectrode array is often the mixture which is composed of action potentials of several neurons near the electrodes and the background noises. Researches on the nervous system information processing mechanism and neural coding and decoding mechanism need know every related neuron's action potential. Therefore, every neuron's action potential is essential to be separated from the recorded signal. This paper proposes a method based on Principal Component Analysis(PCA) combined with improved K-means for action potential classification. The action potentials' features are extracted by PCA, the action potential classification is implemented by the improved K-means algorithm. Experimental results show that the method brings down action potential's feature dimensions and dependence of the initial classification center for the K-means algorithm, and increases the accuracy and stability of the classification results. Particularly, when processing the low Signal to Noise Ratio(SNR) signals, it can also achieve an expected purpose.

【Key words】 microelectrode array; Principal Component Analysis(PCA); feature extraction; improved K-means; action potential classification

DOI: 10.3969/j.issn.1000-3428.2011.16.062

1 概述

动物神经系统依靠神经元发放动作电位进行信息的传递、交流和处理^[1]。当受到正常静息阈值以上的去极化刺激时, 神经元细胞就会产生动作电位。通常, 每个神经元仅发放一类特定形状的动作电位^[2], 这些动作电位通过轴突在神经系统中传递并被神经元用作信息编码。因此, 通过神经元动作电位可以了解神经元的放电模式, 进而研究神经系统的信息处理机制以及神经编码、解码机理。目前, 神经元发放的动作电位通常由微电极阵列记录得到。微电极阵列获取的信号往往是电极邻近区域数个神经元的动作电位以及大量背景噪声的混叠。所以, 从记录信号中分离出每个神经元的动作电位(称为动作电位分类)极为重要, 也非常具有挑战性。

目前, 针对动作电位分类, 国内外学者提出了模板匹配分类方法、基于小波变换的分类方法、贝叶斯分类方法和基于人工智能的分类方法等。文献[3]选用一组典型动作电位作为分类模板, 根据待分类的动作电位到各个模板的距离大小将其归类。通常, 这种方法的分类模板较难选取。文献[4]在时频空间内对动作电位数据矩阵进行小波分解, 然后找出对构成动作电位波形信息量贡献率大于 90% 的前 8 个小波系数进行系统聚类。可是, 动作电位的信息由小波系数整体合并才能反映, 在分类的过程中小波系数是单独作用, 会造成很多有用信息的丢失。文献[5]把每一类动作电位都认为是贝叶

斯混合模型中的一个独立统计分布的模型, 通过极值化概率函数获得最优的类别参数进而实现动作电位分类。它较好地利用了动作电位数据的统计特性, 提高了分类正确率。但是由于检测信号背景噪声复杂, 统计特性不明了, 相关参数的确定也比较困难。随着人工智能与机器学习的发展, 最近几年, 学者已经提出了基于人工智能的动作电位分类方法。文献[6]提出基于径向基函数(RBF)神经网络的动作电位分类方法, 在较高信噪比情况下, 此方法可获得较高精度的分类, 但人工神经网络自身的局限性以及动作电位的分布极大影响了分类效果。

为了提高神经元动作电位分类结果的正确率及稳定性, 本文利用主元分析(Principal Component Analysis, PCA)提取动作电位特征, 然后基于 PCA 提取的特征采用改进 K 均值方法实现动作电位分类。

2 神经元动作电位信号分类

神经元动作电位分类主要分 2 个过程: 特征提取和分类。首先利用 PCA 进行动作电位特征提取; 然后以 PCA 提取的

基金项目: 国家自然科学基金资助项目(60841004, 60971110)

作者简介: 师 黎(1964—), 女, 教授、博士生导师, 主研方向: 动作电位分类方法, 故障诊断, 容错控制, 智能检测, 生物信号处理; 杨振兴, 硕士研究生; 王治忠, 博士研究生; 王 岩, 硕士研究生

收稿日期: 2010-01-18 **E-mail:** shili@zzu.edu.cn

特征为基础采用改进 K 均值算法实现动作电位分类。

2.1 基于 PCA 的动作电位特征提取

PCA 算法是基于 K-L 变换的统计学分析方法, 其主要思想是寻找一组有序的正交向量基捕获数据集的最大变化方向, 将高维向量通过一个特殊的特征向量矩阵投影到一个低维的向量空间中, 表征为一个低维向量^[7]。本文 PCA 提取的特征是动作电位原有波形值的一种线性组合, 可以达到特征增强和降维效果。利用主元分析提取动作电位特征方法如下:

假设一数据集具有 n 个动作电位, 每个动作电位由 m 维特征向量 $(x_{11}, x_{12}, \dots, x_{1m})$ 描述(本文提到的动作电位均用 m 维向量表示), 这样就构成一个 $n \times m$ 的动作电位数据矩阵 X :

$$X = (X_1, X_2, \dots, X_m) = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix} \quad (1)$$

其中, 列向量 $X_i = \begin{bmatrix} x_{1i} \\ x_{2i} \\ \vdots \\ x_{ni} \end{bmatrix}$, $i = 1, 2, \dots, m$ 。

作向量 X_1, X_2, \dots, X_m 的线性组合求得综合特征量, 记为向量 Z_1, Z_2, \dots, Z_m , 则:

$$\begin{cases} Z_1 = c_{11}X_1 + c_{21}X_2 + \dots + c_{m1}X_m \\ Z_2 = c_{12}X_1 + c_{22}X_2 + \dots + c_{m2}X_m \\ \vdots \\ Z_m = c_{1m}X_1 + c_{2m}X_2 + \dots + c_{mm}X_m \end{cases} \quad (2)$$

上述方程组需满足: $c_{1i}^2 + c_{2i}^2 + \dots + c_{mi}^2 = 1, i = 1, 2, \dots, m$, 其中系数 c_{ij} 满足以下要求:

(1) Z_i, Z_j ($i \neq j, j = 1, 2, \dots, m$) 不相关;

(2) 向量 Z_1 是 X_1, X_2, \dots, X_m 的一切线性组合中方差最大者, Z_2, Z_3, \dots, Z_m 是其线性组合方差的依次递减。

经过上述变换后, 动作电位综合特征量 Z_1, Z_2, \dots, Z_m 称之为第 1, 2, \dots, m 主分量。主分量 Z_i 之间具有最小的相关性, 且它们所包含的信息量呈逐渐减少的趋势, 第一主成分集中了最大的信息量, 第二主成分、第三主成分包含的信息量依次递减, 到了第 m 个主成分, 其所包含的信息几乎为 0, 对其原始数据的影响可以忽略。因此, 经过主元变换的动作电位数据包含了比原始数据内容更为丰富的信息, 起到了特征增强的作用, 同时选取最能描述动作电位的前几个主分量来描述动作电位也起到了降维的作用。本文选取主分量对动作电位信息量的累计贡献率超过 80% 的前 p ($p < m$) 个主分量描述动作电位。

2.2 基于改进 K 均值的动作电位分类

动作电位特征提取后, 本文选择 K 均值算法实现动作电位分类。由于 K 均值算法对初始聚类重心比较敏感, 从不同的聚类重心出发, 得到的分类结果也有很大差别, 并且容易陷入局部极小值, 很可能得不到全局最优分类。利用 K 均值算法对动作电位分类很难达到理想的效果。因此, 本文考虑用一组能反映动作电位数据集中动作电位分布特征的动作电位作为初始聚类重心, 进而采用改进 K 均值聚类方法, 实现对动作电位数据集的划分。

在一个动作电位数据空间中, 高密度的动作电位区域被低密度的区域所分割, 通常认为处于低密度区域的动作电位为噪声点。为了避免取到噪声点, 选取相互距离最远的 K 个

处于高密度区域的动作电位作为初始聚类重心。这样做最根本的目的就是使同一个类中的动作电位是相似的, 而不同类中的动作电位是不相似的。

本文引入以下相关定义:

定义 1(2 个动作电位之间的距离) 任意 2 个动作电位 x, y 的欧式距离 $d(x, y) = \sqrt{|x - y|^2}$ 。

定义 2(密度) 以数据空间中每个动作电位 x_i 为球心、某一个正数 γ 为半径的球形区域中包含 α 个动作电位, α 称为该动作电位的密度。

定义 3(任一动作电位到动作电位数据集的距离) 动作电位 x' 与数据集矩阵 X 中所有动作电位的欧氏距离的最短距离 $d(x', X) = \min(d(x', x_i)), (x_i \in X)$ 。

假设把 n 个动作电位的数据集分为 K 类, 使同类内的动作电位具有较高的相似性, 而不同类之间的动作电位具有较低的相似程度(相似度的计算是依据动作电位之间的欧式距离进行测度的)。经过 PCA 提取动作电位特征后, 用 PCA 特征表示动作电位并依据特征实现动作电位分类。具体方法描述如下:

步骤 1 设定某一半径 γ , 计算动作电位 PCA 特征数据集 X 中每个动作电位特征向量的密度, 得到处于最高密度区域的点, 从而得到一个高密度的数据集。在 X 中选取最大密度特征向量作为第 1 个聚类中心 \bar{x}_1 , 并在 X 中将其去除; 在区域 X 取处于距离 \bar{x}_1 最远的一个动作电位作为第 2 个聚类中心 \bar{x}_2 , 同时在 X 中将其删除作为新的高密度区域; 然后计算 \bar{x}_1, \bar{x}_2 到 X 的距离, 取满足:

$$\begin{aligned} \max(d(\bar{x}_1, X), d(\bar{x}_2, X)) &= \max(\min(d(\bar{x}_1, x_i)), \\ \min(d(\bar{x}_2, x_i))), (x_i \in X) \end{aligned}$$

的数据点作为 \bar{x}_3 , 然后在数据集 X 中去除 \bar{x}_3 作为新的数据集 X ; 第 k 个聚类重心 \bar{x}_k 为数据集 X 中与前 $k-1$ 个聚类重心的距离最大的点。至此, 可以求出较为理想的 K 初始数聚类重心。

步骤 2 计算动作电位数据集 X 中所有动作电位特征向量 x_i 到各个类重心 \bar{x}_j 的欧氏距离, 找出 x_i 到聚类重心 \bar{x}_j 的最短距离, 然后把 x_i 归入到与聚类重心 \bar{x}_j 最小的类中。

步骤 3 重新计算各类的重心: $\bar{x}_j = \frac{1}{n_j} \sum_{i=1}^{n_j} x_i^j$, 其中, x_i^j 是第 j 类中的动作电位, $i = 1, 2, \dots, n_j, j = 1, 2, \dots, K$ 。

步骤 4 计算误差平方和准则函数: $J_k = \sum_{j=1}^K \sum_{i=1}^{n_j} \|x_i^j - \bar{x}_j\|^2$, 并与前一次的误差准则函数比较, 如果 $|J_k(m) - J_k(m-1)| > \varepsilon$ (ε 为设定一个数值, m 为迭代的次数), 则转入步骤 2 执行, 直至 $|J_k(m) - J_k(m-1)| < \varepsilon$ 时结束。

步骤 5 输出分类后的各类动作电位。

3 实验和结果分析

3.1 实验

本文研究选取年龄 2 个月~6 个月、体重 150 g~250 g 的大鼠作为实验对象(由郑州大学动物中心提供)。记录大鼠大脑初级视觉皮层 V1 区的神经信号, 首先需将大鼠腹腔用麻醉剂麻醉后固定于立体定位仪, 以刀剃掉头皮上的毛发, 切开头部皮肤, 暴露颅骨, 用手术刀刮去颅骨附着脑膜, 并用过氧化氢(3%)去除颅骨上多余物质。然后将多通道微电极阵列(4×4 钨丝微电极)植入大鼠大脑的初级视觉皮层 V1 区

(以前囟为原点, 向后 7.3 mm, 向外 3.0 mm 定出初级视皮层在水平面上的位置)将硬脑膜挑破, 微电极穿过软脑膜, 从软脑膜开始记录深度。微电极位置确定后, 再等待几分钟, 然后用牙科水泥将其固定, 最后通过信号采集设备记录大鼠初级视觉皮层 V1 区的自发神经元放电信号。本研究记录神经元动作电位信号所采用的采集设备为 128 通道的神经信号处理系统——Cerebus system(Blackrock Microsystem 公司生产)。在采用 Cerebus system 长时间记录大鼠的神经信号时, 首先要进行有效的阈值调节并选定最佳阈值以便系统进行动作电位自动检测, 并把动作电位采样点数设为 48, 采样频率选为 30 000 Hz。Cerebus system 采集的大鼠初级视觉皮层 V1 区神经元动作电位信号如图 1 所示。




图 1 大鼠初级视觉皮层 V1 区神经元动作电位信号

3.2 结果分析

通过读取 Cerebus system 记录的大鼠视觉皮层 V1 区神经元动作电位信号(时间为 112.21 s, 含 1 000 个神经动作电位)。利用主元分析对读取的 1 000 个神经元动作电位进行特征提取得到一组新的数据, 取其每个波形的 前 3 个主分量。以第一主分量为横坐标, 第二主成分为纵坐标, 第三主成分为竖坐标, 绘制三维归一化后的主元分析特征散点图, 如图 2 所示。




图 2 动作电位的第一主成分-第三主成分散点图

从图 2 中可以看出, 这些散点由 2 类不同的放电行为构成, 可以推知本通道电极捕捉到 2 个神经元的放电行为, 即采集的动作电位可以分为 2 类(A 类和 B 类)。

经过 PCA 特征提取后, 得到一组动作电位特征数据, 采用改进 K 均值聚类方法对新数据进行分类处理, 然后恢复分类后动作电位波形结果如图 3 所示, 其中, A 类有 744 个, B 类有 256 个。通过图 3 可知, 同类中的动作电位波形相似度较高, 2 类之间的相似度较低, 进一步验证此通道电极记录到 2 个相邻神经元的放电行为。从而进一步确定本通道采集到 2 个神经元发放的动作电位。




图 3 大鼠初级视觉皮层 V1 区一通道神经元动作电位分类结果

本文把实验记录到的动作电位作为无噪声存在的原始信号, 然后加入不同信噪比的噪声, 对分类结果进行对比, 如表 1 所示, 其中, 正确率以无噪声时的分类结果为基准。

表 1 不同信噪比情况下的分类结果比较

信噪比/dB	贡献率为 85%时 PCA 特征/维	A 类/个	B 类/个	正确率/(%)
-	7	744	256	100.0
5	7	741	259	99.7
-5	8	743	257	99.9
-10	9	742	258	99.0
-15	16	736	264	95.8
-20	28	723	277	95.0
-25	34	710	290	85.2
-30	36	546	454	68.0
-35	37	530	470	62.6

通过表 1 可以看出, 在信噪比大于-20 dB 时, 实现正确分类的比率能达到 95%以上; 当信噪比低于-30 dB 时, 分类正确率迅速下降到 68%以下。另外, 在特征累计贡献率在 85% 时, 信噪比高于-15 dB 时, PCA 特征维数远远低于原始动作电位维数(48 维); 信噪比低于-25 dB 时, PCA 特征维数基本接近原始动作电位维数。同时, 随着信噪比的降低, PCA 提取的特征的维数越多, 但是分类正确率并没有提高。表 2 给出了 K 均值和改进 K 均值 2 种方法的结果比较。

表 2 不同信噪比下改进 K 均值与 K 均值分类正确率比较

信噪比/dB	PCA-改进 K 均值/(%)	PCA-K 均值/(%)
-	100.0	100.0
5	99.7	96.4
-5	99.9	99.9
-10	99.0	99.0
-15	95.8	86.8
-20	95.0	88.5
-25	85.2	86.1
-30	68.0	58.6
-35	62.6	54.3

通过表 2 可以发现, 在信噪比低于-25 dB 时, 与改进 K 均值分类正确率相比, K 均值分类正确率下降更快。另外, 在信噪比为 10 dB、5 dB、-15 dB、-20 dB 时, 改进 K 均值方法分类的正确率要高于 K 均值方法的分类正确率; 在信噪比为-5 dB、-10 dB、-25 dB 时, 2 种方法分类的正确率非常接近。经分析这主要是 K 均值的初始聚类重心造成的。K 均值初始聚类重心是随机初始化的, 其并不能反映目标数据集的分布特征, 这样就很容易造成聚类结果陷入局部最优。改进 K 均值算法克服这一局限, 总体上, 改进 K 均值方法分类正确率明显高于 K 均值方法。(下转第 187 页)