

基于功率谱熵特征提取的脑电波大脑年龄预测

徐伟¹, 姜罗罗¹, 汪秉宏²

1. 温州大学数理与电子信息工程学院, 温州 325035

2. 中国科学技术大学近代物理系, 合肥 230026

摘要 大脑会随着年龄的增加而出现功能衰退, 通过决策实验获取年轻人和中老年人的脑电信号, 可以定量分析大脑随年龄增长而出现的变化。提出了一种基于熵的脑电波刻画方法, 并利用机器学习的方法能够比较准确地预测人的大脑年龄。研究表明, 脑电波功率谱熵(PSE)具有良好的时域分辨能力和更准确的区分效果, 年轻人在做决策时的脑电波功率谱熵的分布是大于中老年人的, 即年轻人所产生的脑电波信息量更大。此外, 支持向量机(SVM)的分类效果优于随机森林(RF)方法, 最高平均精度达88.02%, 比随机森林高出2.66%。通过基尼指数对特征重要性排序, 还发现决策过程中左眼电区域、大脑的颞和中央区域的决策反应差异很大, 分类器更容易在这些特征区域做出更好的分类。

关键词 脑电波年龄; 决策实验; 功率谱熵; 支持向量机

大脑在整个生命过程中微妙地控制着人类的行为和活动, 它经历连续的变化, 可能是平行的形态发生, 即随着神经蛋白对的后期退化, 尤其是在线粒体中, 而逐渐成熟^[1]。时间不可避免地影响所有的器官, 其中大脑似乎特别容易受到影响。它的脆弱性会随着年龄的增长而迅速增加, 并且有很多临床表现。脑电图(electroencephalogram, EEG)是大脑功能一个很好的指示器。

已知正常衰老伴随着大脑物质的损失。Luders等^[2]研究了冥想练习与脑年龄缩短之间的关系, 通过应用机器学习算法训练模型, 以识别大脑年龄的解剖相关性, 通过50个长期冥想者和50个对照者的大样本, 估

计和比较他们的大脑年龄, 发现在50岁时, 冥想者的大脑估计比对照者年轻7.5岁。此外, 在50岁以上的每1年, 估计冥想者的大脑年龄比其实际年龄年轻1个月22天。总之, 冥想有利于大脑的能量储存, 能够有效地保护年龄相关性萎缩, 并始终保持较慢的脑老化速度。Vysata等^[3]提出一致性变化可以反映人类衰老涉及的病理和生理过程, 分析了17722名健康职业驾驶员群体脑电波年龄的一致性变化, 通过线性回归分析估计年龄和一致性之间的线性相关性。结果表明, 在theta和alpha波段年龄的一致性显著下降, 然而在beta波段的一致性却增加, 最明显的变化发生在alpha波段, 而三角洲包含运动假象, 这很可能不会随着年龄的变化而改

收稿日期: 2018-01-30; 修回日期: 2018-04-08

基金项目: 浙江省自然科学基金项目(LY17F030005)

作者简介: 徐伟, 硕士研究生, 研究方向为模式识别与数据挖掘, 电子信箱: joey_boyi@foxmail.com; 姜罗罗(通信作者), 博士, 研究方向为数据挖掘, 电子信箱: jiangluo@foxmail.com

引用格式: 徐伟, 姜罗罗, 汪秉宏. 基于功率谱熵特征提取的脑电波大脑年龄预测[J]. 科技导报, 2018, 36(8): 40-47; doi: 10.3981/j.issn.1000-7857.2018.08.004

变。此外, Van 等^[4]调查研究了健康人群中基于生理学的 EEG 谱参数与年龄相关的变化。将 1486 名 6~86 岁健康被试者的闭眼 EEG 谱和横断面研究中的丘脑皮层动力学平均场模型拟合, 年龄趋势近似使用具有单个转折点的光滑渐进性函数。其结果表明, 儿童时期的变化趋势最为迅速, 一般在 15~20 岁时就会趋于平稳。随着年龄的增长, 大多数收益都会下降, 功率标准化也会减少。不仅如此, Pace-Schott 等^[5]研究了睡眠认知功能的年龄变化, 认为健康老化的特点之一是睡眠质量的下降、睡眠时间较少和睡眠开始过程中清醒的时间增加。在年轻人中表现出显著的睡眠依赖性巩固的学习形式中, 运动顺序学习表明, 随年龄增长会丧失睡眠依赖性巩固, 而依赖睡眠的言语陈述记忆的巩固显现出来。Cirelli 等^[6]通过比较 7 岁儿童与成人的 beta 波段波动的 EEG 测量研究大脑中振荡活动的发展。脑磁图 (MEG) 研究表明, 来自听觉皮层的诱导 beta 波段振荡活动在每个节拍发作之后降低, 并在预测的方式下在下一个节拍开始之前出现反弹。在成年人中, 高 beta 波段 (20~25 Hz) 的感应功率在每个音调开始之后下降, 并在下一个音调开始之前在速度条件下反弹, 这与 MEG 的发现一致。在儿童中, 在两个较慢的节奏条件下测量类似的模式, 但是在最快的条件下较弱。

以上研究表明, 不同年龄层次的大脑活动表现存在差异。然而, 通过预测大脑年龄来区分不同年龄层次的大脑活动是很多研究者需要深入探究的。Dosenbach 等^[7]使用基于支持向量机 (support vector machines, SVM) 的多元模式分析功能连接性磁共振成像 (fcMRI) 数据中提取足够的信息, 以准确预测个人的大脑成熟度跨发展。其中被试者年龄为 7~30 岁, 可以预测个体大脑成熟度作为功能性连接成熟指数, 预测个体大脑成熟度的最大相对贡献是由于成人大脑主要功能网络之间的短程功能连接减弱。此外, Cole 等^[8]在 1537 名健康个体中使用机器学习来定义正常衰老的预测模型, 其结果表明, 初始模型准确地预测了健康个体的年龄, 并且创伤性脑损伤 (TBI) 患者的大脑年龄要比实际年龄要大, 这种差异随着时间的推移而增加, 这表明 TBI 加快了脑萎缩的速度。Gur 等^[9]检测了神经认知年龄, 并比较典型发育中的被试者和精神病谱被试者。结果表明, 在儿童期和青春期, 精神病谱的预测年龄低于正常发育和其他精神症状组。Federmeier 等^[10]认为在句子理解中, 中老年人比年轻人更不太可能预测

即将到来的单词特征。他们通过两个语言理解实验分析中老年人和年轻人在反应上的差异。另外, Meier 等^[11]提出了使用 SVM 分类器区分中老年人和年轻人基于其休息状态功能连接, 他们选择了 26 个年轻人 (18~35 岁) 和 26 个中老年人 (55~85 岁) 作为其实验数据, 分类结果为 84%。

以上研究结果表明, 虽然很多研究者通过各种实验方法去探索不同年龄层次的脑电波差异, 试图通过一些定量方法去分析其差异, 如 fcMRI 和机器学习方法。然而, 这些研究方法不仅不能够表征脑电波信号的特征, 而且其分类精度并不高且不能够用于大脑年龄诊断。脑电图是评价人脑功能的一种基本手段, 通过简单的实验获得脑电信号后, 如何提取脑电信号特征来分析信号是值得研究的。綦宏志等^[12]用 2 种信息熵 (功率谱熵 (PSE) 和小波熵 (WE)) 分析手部想象动作执行前后的动态脑电信号, 结果显示功率谱熵和小波熵具有良好的时域分辨能力和更准确的区分结果。周酥^[13]提出将不同频段的功率谱作为一个独立信源计算其信息熵的一种新方法, 这样可以对其信号进行判别分析, 并利用支持向量机预测识别 2 种异常心音, 结果获得较高识别率。任亚莉^[14]提出组合信号功率谱熵和频带能量作为提取脑电特征信号, 并获得满意结果。费成巍等^[15]利用熵理论, 融合了支持向量机的优点, 提出过程功率谱信息熵 (power spectrum entropy, PSE) 支持向量机的故障诊断方法且效果良好。然而, 王凯明等^[16]利用改进的功率谱熵仿真实验证明功率谱熵和信号活跃性之间存在正相关关系, 基于这种相关性, 实验结果表明抑郁症患者脑电信号的功率谱熵在部分脑区显著弱于正常健康人, 并且证明该谱熵能够表征大脑电生理活动状况。虽然很多研究者提出了使用各种各样的信息熵 (小波熵、近似熵和功率谱熵等) 提取脑电信号, 且使用机器学习方法 (如支持向量机和随机森林 (random forest, RF) 等) 对提取得到的信号特征进行分类预测, 但很少有研究人员用功率谱熵方法提取脑电波年龄的信号特征和分类。支持向量机是定义在特征空间上的间隔最大的线性分类器。支持向量机还包括核函数技巧, 通过核函数映射高维空间使它成为非线性分类器, 支持向量机的学习算法是求解凸二次规划的最优化算法。支持向量机具有适应性强、全局最优化、训练时间短、泛化性能等优点, 已经在很多领域广泛应用^[17-18]。

本文通过对原始脑电信号进行傅里叶变换得到频域信息,通过变换得到的傅里叶成分计算功率谱密度,并计算功率谱熵获得功率谱熵数据集。使用支持向量机和随机森林对数据集进行分类(二分类:年轻人的标签为1和中老年人的标签为-1)和使用分类器性能评价指标比较分类模型。使用基尼指数对数据集特征排序,获得其特征重要性,选取最重要的6个特征进行特征分析。

1 方法

1.1 特征提取和获取分类数据集

傅里叶变换(fast Fourier transform, FFT)算法计算序列的离散傅里叶变换(discrete Fourier transform, DFT)。傅里叶分析把原始的脑电信号从时域转变到可表示的频域^[19]。在原始脑电信号序列中,定义 x_0, x_1, \dots, x_{N-1} 为 N 个点的长序列,这里序列长度为700(反应刺激前后的时间范围为-199~500 ms(负数表示刺激前))。则离散傅里叶变换式为

$$X_k = \sum_{n=0}^{N-1} x_n e^{-i2\pi k \frac{n}{N}} \quad k=0, 1, \dots, N-1 \quad (1)$$

式中, X_k 是计算得到的傅里叶成分,共有 N 个输出。

通过傅里叶成分计算功率谱密度(P)为

$$P_k = \frac{1}{N} |X_k|^2 \quad (2)$$

式中, P_k 是计算得到的功率谱密度,共有 N 个输出。

将 P_k 按总的谱功率进行归一化后得到功率谱密度分布函数为

$$p_i = \frac{P_{ki}}{\sum_{i=1}^N P_{ki}} \quad (3)$$

对于一个系统来说,信息熵表征了系统不确定因素的混乱程度,如果系统越混乱,随机性越大,则此系统的信息熵值就越高;反之亦然^[20]。若用一个随机变量 X 表示系统的状态, X 的取值假设为

$$X = \{x_1, x_2, \dots, x_n\}, \quad (n \geq 1) \quad (4)$$

对应的取值概率为

$$p = \{p_1, p_2, \dots, p_n\} \quad 0 \leq p_i \leq 1, i=1, 2, \dots, n \quad (5)$$

且

$$\sum_{i=1}^n p_i = 1 \quad (6)$$

则该系统的信息熵表示为

$$H = -\sum_{i=1}^n p_i \ln p_i \quad (7)$$

因此,计算功率谱熵把式(3)代入式(7)即得。

1.2 分类器

1.2.1 支持向量机

支持向量机是最强大的分类方法之一^[18]。SVM在高维或者无限维空间中构建超平面或一组超平面,它可以用于功率谱熵数据集的分类。直观地说,一个好的分离间隔是最大化超平面两边的最近数据点距离超平面的间隔,因为边缘越大,分类器的泛化错误就越低。SVM有效地利用径向基核函数(radial basis function, RBF)进行非线性分类^[21]。两类(年轻被试者的数据标签标记为1,中老年被试者的数据标签标记为-1)的向量为 $y \in \{1, -1\}^n$,则SVM的对偶形式为

$$\begin{aligned} \min_{\alpha} & \frac{1}{2} \alpha^T Q \alpha - e^T \alpha \\ \text{subject to} & y^T \alpha = 0 \\ & 0 \leq \alpha_i \leq c, i=1, \dots, n \end{aligned} \quad (8)$$

式中, ω 为决定超平面的法向量; b 为决定超平面与原点之间距离的位移项; ξ 为松弛变量; e 为所有元素都是1的矩阵; $C>0$ 为常数上界; Q 为 $n \times n$ 的正半定矩阵,则 $Q_{ij} = y_i y_j K(x_i, x_j)$; $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ 是核函数,这里通过函数 ϕ 把训练集向量隐式地映射到高维空间。

本文使用的核函数为RBF核,表达式为

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) = \exp(-\gamma \|x_i - x_j\|^2) \quad (9)$$

式中, σ 是RBF核宽度; γ 定义为

$$\gamma = \frac{1}{2\sigma^2} \quad (10)$$

决策函数为

$$\text{sgn}\left(\sum_{i=1}^n y_i \alpha_i K(x_i, x) + \rho\right) \quad (11)$$

在SVM-RBF模型中有2个主要参数:常数上界 C 和核参数 γ 。在本文中,接下来会找到这2个最佳参数。

1.2.2 随机森林

随机森林是用于机器学习分类的一种集成学习方法^[22],它是在训练时间内利用随机重采样方法Bootstrap,即有放回地随机抽取 k 个训练子集,并由此构建 k (通常为 n_{tree})棵决策树,每次未被抽到的样本组成了 k 个袋外数据(out-of-bag, OOB),并在此过程中,随机从数据集有 n 个属性特征选择 m_{try} ($m_{try} \leq n$)个特征,每个节点根据基尼指数选取最优特征集,分裂直至树完全生

长。最终通过投票得到分类结果。RF使用OOB方法评估算法的预测性能。其中基决策树个数 n_{tree} 和变量子集 m_{try} 是RF需要调节的参数。

RF模型借助基尼指数来评价模型中单个变量的重要性,基尼指数表示属性集合中的不确定性。因此,基尼指数值越小,属性集合的纯度就越高。基尼指数定义为

$$Gini(p) = \sum_{k=1}^K p_k(1-p_k) \quad (12)$$

式中, K 是数据集中类别的个数(对于本数据集, K 为2, p_k 是样本点属于第 k 类的概率, $Gini(p)$ 为概率分布的基尼指数。

于是,在选择划分属性时,选择那个使得划分后基尼指数最小的属性最为最优划分属性。

2 实验设计

2.1 实验流程和数据描述

2.1.1 实验流程

在本实验中,选择了18位健康的被试者,其中6位女性,12位男性。定义低于30岁的被试者为年轻类(共9人,8男1女),高于45岁的被试者为中老年类(共9人,4男5女)。其中年轻人的(年龄,性别)分别为(20岁,男)、(24岁,女)、(25岁,男)、2位(26岁,男)、2位(28岁,男)、(29岁,男)和(30岁,男)共9人;中老年人的(年龄,性别)分别为2位(46岁,女)、2位(48岁,男)、2位(50岁,女)、(53岁,男)、(54岁,女)和(63岁,男)共9人。

本研究目的是通过功率谱熵提取被试者的脑电波特征得到熵的数据集并且用机器学习分类方法区分年轻人和中老年人的脑电波,此外用基尼指数方法排序特征重要性,从特征角度分析年轻人和中老年人的大脑年龄差异。原始信号收集过程如图1所示。

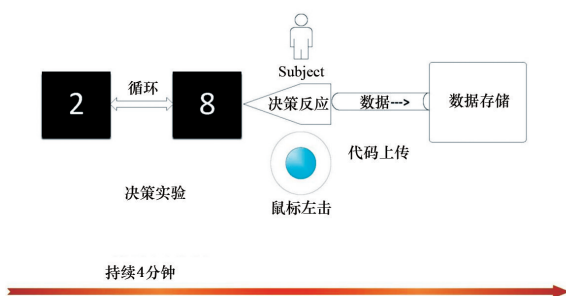


图1 决策实验流程

Fig. 1 Diagram of decision-making (DM) experiments

(1) 整个实验EEG信号的采样率设置为1000 Hz,且有36个通道,即36个特征。

(2) 在整个实验过程中,被试者穿戴电极帽,同时,被试者需要根据电脑的提示做出反应选择:在电脑屏幕上以1 s的间隔不断地反复出现数字2和8,且2和8出现的比例分别是1:4。当被试者在电脑屏幕上看到数字2的时候以点击鼠标左键来做出反应选择,如此重复,直到实验结束,最后整个实验中被试者做出反应选择的代码传输到另一台电脑上,用Curry 7软件记录保存下来。

2.1.2 数据描述

通过决策实验获得的原始脑电信号需要做以下分析处理。

1) 使用Curry 7软件预处理:基线校准、滤波、直流漂移预调和去除眼电和伪迹等。

2) 为了能够覆盖研究成分的潜伏期,当刺激出现时,原始脑电信号保留了刺激后-199~500 ms的时间序列数据。

3) 通过FFT方法把原始脑电信号的时域信号变换为频域信息,从而获得功率谱密度成分,然后计算功率谱概率分布,最后计算得到功率谱信息熵,因此,分类数据集通过以上计算获得。

分类数据集中共有36个特征,表1是分类数据集的36个特征在大脑空间的具体位置描述。数据集中共有553个样本,其中295个样本为正类(即年轻类,标记为1),258个样本为负类(即中老年类,标记为-1)。为了验证算法的准确性和有效性,在分类时,使用10折交叉验证训练模型^[23]。

2.2 性能评价标准

为了估计SVM和RF两个分类模型性能,使用4个经典的模型性能评价标准,分别是Accuracy(ACC)、Precision、Area under the receiver operating characteristic (ROC) curve (AUC)和F1-score。表2给出了可视化一个算法性能的混淆矩阵。结合数据集含义如下:TP是把年轻类预测为年轻类;TN是把中老年类预测为中老年类;FP是把中老年类预测为年轻类;FN是把年轻类预测为中老年类。在统计学上,ROC曲线是图形化表示一个二分类系统的鉴别阈值变化的诊断能力。AUC的值为ROC曲线下的面积,如果模型预测十分准确,则AUC的值为1。根据上述描述和混淆矩阵,性能评价标准可计算为

表1 分类数据集特征信息

Table 1 Feature of the classification dataset

电极	特征	位置
E1	Fp1	前额
E2	Fp2	前额
E3	F7	侧额
E4	F3	额
E5	Fz	额
E6	F4	额
E7	F8	侧额
E8	FT7	
E9	FC3	
E10	FCz	
E11	FC4	
E12	FT8	
E13	T3	颞
E14	C3	中央
E15	Cz	中央
E16	C4	中央
E17	T4	颞
E18	TP7	
E19	CP3	
E20	CPz	
E21	CP4	
E22	TP8	
E23	A1	耳
E24	T5	后颞
E25	P3	
E26	Pz	
E27	P4	
E28	T6	后颞
E29	A2	耳
E30	O1	枕
E31	Oz	
E32	O2	枕
E33	HEOL	左水平眼电
E34	HEOR	右水平眼电
E35	VEOU	右垂直眼电
E36	VEOL	左垂直眼电

表2 混淆矩阵

Table 2 Confusion matrix

	预测标签	
	标签=1 (年轻人)	标签=-1 (中老年人)
真实 标签	标签=1(年轻人) 真正类(TP)	标签=-1(中老年人) 假负类(FN)
	假正类(FP)	真负类(TN)

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (13)$$

$$p = \frac{TP}{TP + FP} \times 100\% \quad (14)$$

$$F_1 = \frac{2TP}{2TP + FP + FN} \times 100\% = \frac{2p \cdot r}{p + r} \times 100\% \quad (15)$$

$$TPR = r = \frac{TP}{TP + FN} \times 100\% \quad (16)$$

$$FPR = \frac{FP}{FP + TN} \times 100\% \quad (17)$$

式中, p 、 F_1 和 r 分别为 *precision*、 F_1 -score 及 *recall* 模型评价标准。

3 结果与讨论

3.1 特征分析

为分析PSE数据集的特征重要性,用基尼指数方法排序数据集特征重要性。如图2所示,在OOB值取得最大时,计算每个特征的基尼指数并从大到小排序。从3.2节通过调参获得RF模型中的最优参数($m_{try}=6$),因此,这里选取排序靠前的6个特征,即HEOL、T4、FC4、C3、VEOL和T5,并以这6个重要特征作为接下来的特征分析。结合表1,发现年轻人和中老年人在做决策时,在左眼电区域、大脑的颞和中央区域决策反应差别很大,分类器更容易在这些特征区域做出更好的分类。


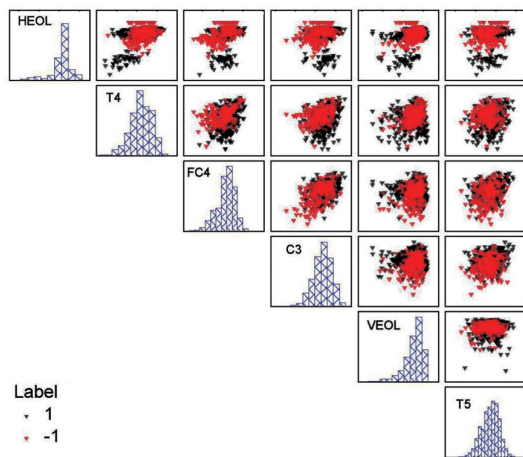


图2 用基尼指数对功率谱信息熵数据集进行特征重要性排序
Fig. 2 The Gini index is used to rank the feature importance of PSE dataset

为了更好地区分这6个特征的正负样本的分布(图3),以黑色表示样本正类,以红色表示样本负类,图3的散点图是两两特征之间正负类样本的对比图,可以很

清晰地看到 HEOL 特征与其他 5 个特征的正负样本辨识度很高,这也表明 HEOL 特征的正负样本容易被区分,但是其他 5 个特征的正负样本辨识度不高,需要把数据映射到高维空间。在本研究中,使用 SVM 模型通过 RBF 核把样本映射到高维空间进行分类预测,可以更好地区分正负类从而获得更高的分类精度。



黑色倒三角散点是正类样本(年轻类),红色倒三角散点是负类样本(中老年类)。蓝色柱状图为重要特征样本区间分布图,横坐标为 PSE 值的区间,纵坐标为样本区间的个数总计

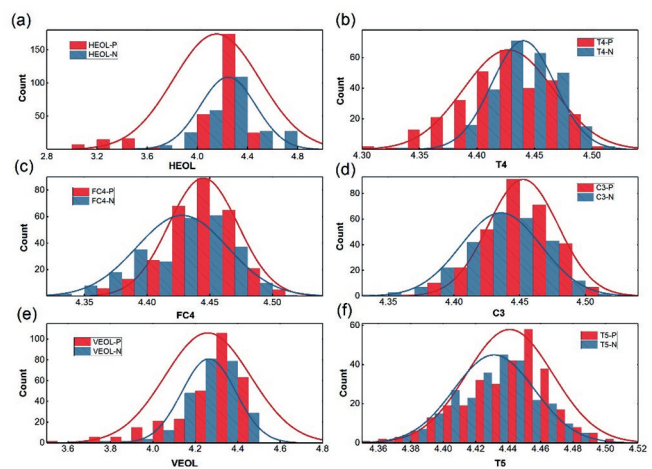
图 3 前 6 个最重要特征的功率谱信息熵数据集的正负样本散点矩阵图和特征样本分布

Fig. 3 Map of scatter matrix and the distribution map of feature of PSE sample where the top six most important features of the PSE dataset of positive and negative sample are selected

同时,图 4 可视化了 6 个同一特征下的 PSE 数据集正负样本的分布图,除了 4(b)外,其他 5 幅图红色的样本分布是大于蓝色的样本分布,即在同一特征下正类样本分布大于负类样本分布,即年轻人的功率谱熵普遍大于中老年人的功率谱熵。年轻人和中老年人在做决策时,年轻人产生脑电波的信息熵大于中老年人产生脑电波的信息熵,即年轻人在做出决策时所产生的信息量大于中老年人在做出决策时所产生的信息量。因此,年轻人比中老年人在做决策时更会产生更多的不确定性和未知性。

3.2 分类结果比较

1) 用对 2 个模型(SVM 和 RF)调参操作,SVM-RBF 有 2 个重要参数,分别是 C 和核参数 γ 。在调节参数时,选择参数 C 的调节范围集合为 $\{2^{-15}, 2^{-14}, \dots, 2^{15}\}$,选择参数 γ 的调节范围集合为 $\{2^{-15}, 2^{-14}, \dots, 2^1\}$ 。通过网格搜索方法^[24]获得的最优参数对为 $(C=0.125, \gamma=2)$ 。最终使



红色的柱状图是该特征的正类样本(P),蓝色对的柱状图是该特征对的负类样本(N)。横坐标是功率谱信息熵值的区间,纵坐标是每个区间的总计个数,曲线是柱状分布图对的拟合曲线

图 4 前 6 个最重要特征的正负类样本分布图

Fig. 4 The distribution of positive and negative samples of the top six most important features

用最优参数对计算分类指标。RF 有 2 个重要参数,分别是决策树个数 n_{tree} 和变量数量 m_{try} 。在调节参数时,选择参数 n_{tree} 的调节范围为 $[1, 1000]$,步数为 1,选择参数 m_{try} 的调节范围为 $\left\{\frac{\sqrt{M}}{2}, \log_2 M, \sqrt{M}, 2\sqrt{M}, M\right\}$,这

里 M 为总特征数,即 36。RF 调参时,训练 RF 不同的决策树 n_{tree} 从 1 到 1000 和 6 个不同的 m_{try} 值,计算每个 n_{tree} 值对应的 OOB 值,OOB 值最大对应的参数对就是需要的最优参数对,通过以上训练,RF 最优参数对为 $(n_{tree}=410, m_{try}=6)$,最终使用这最优参数对计算其分类指标。

2) 为了能够有效地比较 2 个分类器性能,用同样的 PSE 数据集和对数据集进行 10 折交叉验证。通过上面获得的最优参数对计算 SVM 和 RF 在分类 PSE 数据集时的 4 个性能指标。如表 3 所示,分别计算了 2 个模型的各个指标的最大值、最小值和平均值,其中 SVM 的平均值为 88.02%,比 RF 的平均值高了 2.66%,从表 3 可以

表 3 SVM 和 RF 分类器的不同评价标准

Table 3 Different metrics with the SVM and RF classifiers

Classifier	Metrics			
	ACC	Precision	AUC	F1-score
SVM_Min	75.68%	70.91%	74.59%	77.36%
SVM_Max	97.30%	100.00%	97.18%	97.56%
SVM_average	88.02%	89.27%	88.03%	88.66%
RF_Min	70.27%	60.00%	69.32%	71.70%
RF_Max	97.30%	100.00%	97.25%	97.44%
RF_average	85.36%	84.04%	85.17%	86.65%

看出SVM的4个指标都要比RF高一点,所以,在分类PSE数据集时,SVM更能区分年轻类和中老年类的脑电波,且精度很高。

图5为SVM和RF的被试者工作特征曲线ROC。图中,ROC区域下的面积即AUC的值。ROC常常用来评估敏感度(Sensitivity)和1-特异性(1-Specificity)之间的权衡,且AUC值是衡量分类器性能的一个指标。一个完美的分类器其ROC曲线将会从左下角经过左上角一直到右上角。1-Specificity=FPR,表示分类器错认为正类的负实例占有所有负实例的比例;Sensitivity=TPR,表示分类器识别出正实例占有所有正实例的比例。SVM和RF都是有比较低的FPR和比较高的TPR。但是在左上角至右上角SVM的识别率要比RF更为准确。因此,在总体上,SVM的分类性能比RF效果好。




图5 在10折交叉验证分析下2个分类器的被试者工作特征曲线(ROC)

Fig. 5 Receiver operating characteristic curve (ROC) of the two classifiers with different areas under the curve (AUC) values in 10-fold CV analysis

4 结论

提出了用功率谱信息熵方法去提取在年轻人和中老年人在做决策实验时所产生的脑电信号特征,并用SVM和RF机器学习分类方法对提取到功率谱信息熵数据集进行分类预测。结果表明,用功率谱信息熵提取脑电波年龄信号特征从PSE样本分布和分类器的预测精度均有很高的辨识度。以上验证了通过机器学习方法区分不同年龄层次脑电波的可行性,只是目前实验规模尚较小,以后会通过更多的被试者和样本进一

步验证和扩展本研究的结论。此外,分类模型在分类不同年龄的脑电波时,特征选择、算法改进和提升进度是本研究组接下来的工作。

参考文献(References)

- [1] Swerdlow R H. Brain aging, Alzheimer's disease, and mitochondria[J]. *Biochimica et Biophysica Acta (BBA)-Molecular Basis of Disease*, 2011, 1812(12): 1630-1639.
- [2] Luders E, Cherbuin N, Gaser C. Estimating brain age using high-resolution pattern recognition: Younger brains in long-term meditation practitioners[J]. *Neuroimage*, 2016, 134: 508-513.
- [3] Vysata O, Kukul J, Prochazka A, et al. Age-related changes in EEG coherence[J]. *Neurologia i Neurochirurgia Polska*, 2014, 48(1): 35-38.
- [4] van Albada S J, Kerr C C, Chiang A K I, et al. Neurophysiological changes with age probed by inverse modeling of EEG spectra[J]. *Clinical Neurophysiology*, 2010, 121(1): 21-38.
- [5] Pace-Schott E F, Spencer R M C. Age-related changes in the cognitive function of sleep[M]//Green A M, Chapman E C, Kalska J F, et al. *Progress in Brain Research*. Amsterdam: Elsevier, 2011: 75-89.
- [6] Cirelli L K, Bosnyak D, Manning F C, et al. Beat-induced fluctuations in auditory cortical beta-band activity: Using EEG to measure age-related changes[J]. *Frontiers in Psychology*, 2014, 5: 742.
- [7] Dosenbach N U F, Nardos B, Cohen A L, et al. Prediction of individual brain maturity using fMRI[J]. *Science*, 2010, 329(5997): 1358-1361.
- [8] Cole J H, Leech R, Sharp D J. Prediction of brain age suggests accelerated atrophy after traumatic brain injury[J]. *Annals of Neurology*, 2015, 77(4): 571-581.
- [9] Gur R C, Calkins M E, Satterthwaite T D, et al. Neurocognitive growth charting in psychosis spectrum youths[J]. *JAMA Psychiatry*, 2014, 71(4): 366-374.
- [10] Federmeier K D, Kutas M, Schul R. Age-related and individual differences in the use of prediction during language comprehension[J]. *Brain and Language*, 2010, 115(3): 149-161.
- [11] Meier T B, Desphande A S, Vergun S, et al. Support vector machine classification and characterization of age-related reorganization of functional brain networks[J]. *Neuroimage*, 2012, 60(1): 601-613.
- [12] 蔡宏志, 程龙龙, 陈彬津, 等. 想象动作中动态脑电的信息熵研究[J]. *中国生物医学工程学报*, 2007, 26(1): 74-77.
Yan Hongzhi, Cheng Longlong, Chen Binjin, et al. Information entropy of dynamic EEG in imaginary movements[J]. *Chinese Journal of Biomedical Engineering*, 2007, 26(1): 74-77.

- [13] 周酥. 基于功率谱信息熵的异常心音识别[J]. 中国医学物理学杂志, 2014, 31(3): 4933-4935.
Zhou Su. Abnormal heart sound recognition based on power spectrum information entropy[J]. Chinese Journal of Medical Physics, 2014, 31(3): 4933-4935.
- [14] 任亚莉. 基于功率谱熵和频带能量的运动意识任务分类研究[J]. 计算机应用与软件, 2010, 27(12): 105-107.
Ren Yali. Research on task classification of motion awareness based on power spectrum entropy and frequency band energy [J]. Journal of Computer Applications and Software, 2010, 27(12): 105-107.
- [15] 费成巍, 白广忱, 李晓颖, 等. 基于过程功率谱熵SVM的转子振动故障诊断方法[J]. 推进技术, 2012, 33(2): 293-298.
Fei Chengwei, Bai Guangchen, Li Xiaoying, et al. Rotor vibration fault diagnosis method based on process power spectral entropy SVM[J]. Propulsion Technology, 2012, 33(2): 293-298.
- [16] 王凯明, 钟宁, 周海燕, 等. 基于改进功率谱熵的抑郁症脑电信号活跃性研究[J]. 物理学报, 2014, 63(17): 178701-178708.
Wang Kaiming, Zhong Ning, Zhou Haiyan, et al. Study on the activity of EEG signals in depression based on improved power spectral entropy[J]. Acta Physica Sinica, 2014, 63(17): 178701-178708.
- [17] Sun Y. EEG signal analysis by using SVM and ELM[D]. Northridge: California State University, Northridge, 2015.
- [18] Cortes C, Vapnik V. Support-vector networks[J]. Machine learning, 1995, 20(3): 273-297.
- [19] Goda K, Jalali B. Dispersive Fourier transformation for fast continuous single-shot measurements[J]. Nature Photonics, 2013, 7(2): 102.
- [20] Gray R M. Entropy and information theory[M]. New York: Springer Science & Business Media, 2011.
- [21] Chang Y W, Hsieh C J, Chang K W, et al. Training and testing low-degree polynomial data mappings via linear SVM[J]. Journal of Machine Learning Research, 2010, 11: 1471-1490.
- [22] Biau G. Analysis of a random forests model[J]. Journal of Machine Learning Research, 2012, 13: 1063-1095.
- [23] Borra S, Ciaccio A D. Measuring the prediction error. A comparison of cross-validation, bootstrap and covariance penalty methods[J]. Computational statistics & data analysis, 2010, 54(12): 2976-2989.
- [24] Pedregosa F, Varoquaux G, Gramfort A, et al. Scikit-learn: Machine learning in Python[J]. Journal of machine learning research, 2011, 12: 2825-2830.

The brain age prediction based on the power spectrum entropy feature extraction

XU Wei¹, JIANG Luoluo¹, WANG Binghong²

1. College of Mathematics Physics and Electronic Information Engineering, Wenzhou University, Wenzhou 325035, China
2. Department of Modern Physics, University of Science and Technology of China, Hefei 230026, China

Abstract The brain activity sees a functional decline in the aging process. The Electroencephalogram (EEG) signals of young and elderly people are obtained by the decision-making experiment to be used to quantitatively analyze the changes of the brain with age. This paper presents an entropy-based characterization method of the EEG, which can accurately predict the human brain age by the machine learning method. The results show that there is a rich performance with the power spectrum entropy (PSE) in the time-resolution ability and the effect of the accurate differentiation. The distribution of the entropy of the young people in a decision-making process has a greater intensity than that of the elderly. In other words, the amount of information of the brain generated by young people is larger than that of the elderly. In addition, the support vector machine (SVM) is superior to the random forest (RF) method, since the highest average accuracy (ACC) is 88.02% and is 2.66% higher than that of the RF method. It is also found that a great difference is observed in the responses of the decision-making, especially in the left EOG, temporal and central regions of the brain, which can be more easily classified by the classifiers.

Keywords brain age; decision-making; power spectrum entropy; support vector machine ●



(责任编辑 王志敏)