

# 基于脑电熵值特征和功能连接的不同线型 道路下驾驶状态检测

常文文, 闫光辉, 杨志飞, 张冰涛, 罗 浩

(兰州交通大学 电子与信息工程学院, 甘肃兰州 730070)

**摘 要:** 基于脑电信号完成对不同驾驶过程的解码分析, 并就驾驶意图做出预测, 是基于脑机接口的人机协同智能驾驶控制中的核心问题. 为了实现对直线、左弯道和右弯道驾驶过程的识别, 本文提出了基于脑电功能性脑网络和熵值特征的驾驶行为特征检测方法, 并结合支持向量机和高斯混合模型等算法完成对不同线型驾驶过程的分类识别. 模拟驾驶实验结果表明, 本文提出的方法可有效实现对不同线型驾驶过程的识别, 针对 16 名被试对直线和弯道驾驶过程的识别准确率均高于 82%, 最高达到 86.66%, 对左弯道和右弯道驾驶过程的识别准确率均高于 75%, 最高达到 77.95%. 对主要脑区间相互依赖关系的分析结果表明, 弯道驾驶过程表现出明显的大脑对侧性特征, 且左弯道驾驶相比右弯道需要更多的脑区间交互活动, 而直线驾驶过程中左脑区的活动稍强于右脑区. 本文研究结果对理解弯道驾驶过程中驾驶员脑认知特性, 以及开展不同线型道路下驾驶行为检测和驾驶状态研究, 具有一定的参考价值.

**关键词:** 驾驶行为; 弯道驾驶; 脑电信号; 脑功能连接; 熵

**基金项目:** 兰州市科技计划项目(No.2021-1-150); 国家自然科学基金(No.62062049, No.61962034); 甘肃省科技计划项目(No.21ZD8RA008); 兰州交通大学“天佑青年托举人才计划”基金(No.20190024)

**中图分类号:** TP391; TP18

**文献标识码:** A

**文章编号:** 0372-2112(2023)10-2874-10

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

**DOI:** 10.12263/DZXB.20210885

## Detection of Driving State Under Different Curve Road based on Entropy and Functional Connectivity of EEG

CHANG Wen-wen, YAN Guang-hui, YANG Zhi-fei, ZHANG Bing-tao, LUO Hao

(School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China)

**Abstract:** The decoding of different driving processes and driving intention prediction based on electroencephalogram (EEG) signals are the key issue of human computer interface based intelligent driving control. In order to realize the identification of driving process in straight road, left curve and right curve road, this paper proposes a feature extraction method for driving behaviors based on functional brain network and entropy features of EEGs, and achieve the classification of different driving conditions under various curve by combining with several classifiers with the extracted EEG features. Corresponding simulation driving experiments are designed and the results show that the method proposed in this study can effectively identify the driving process under various curve. All the classification accuracy for the 16 subjects between straight and curve road are higher than 82%, with the highest value to 86.66%, while the accuracy between left curve and right curve are higher than 75%, with the highest value to 77.95%. Interdependence analysis between different brain regions shows that there are obvious brain contralateral characteristics during curve driving. In addition, left curve driving needs more interactions between the brain regions than right curve driving, while the left hemisphere is slightly more active than the right hemisphere during straight driving. The result has significant value for understanding driver's brain cognitive characteristics in the process of curve driving and driving behavior detection under different curve road.

**Key words:** driving behavior; curve driving; electroencephalogram (EEG); functional brain network; entropy

**Foundation Item(s):** Science Project of Lanzhou City (No.2021-1-150); National Natural Science Foundation

(No.62062049, No.61962034); Science Project of Gansu Province (No.21ZD8RA008); Tianyou Youth Talent Lift Program of Lanzhou Jiaotong University (No.20190024)

### 1 引言

据世界卫生组织统计,全球每年约有 135 万人死于各类交通事故,交通事故已成为全球第五大死亡原因<sup>[1]</sup>. 统计分析显示 90% 的交通事故在一定程度上都是由于驾驶员的不当驾驶行为. 为了应对和减少此类问题,提高驾驶过程的安全性,出现了各种智能辅助驾驶系统. 但目前的智能辅助驾驶系统都基于车辆的外部传感器,如雷达、声纳和摄像头等,并没有将驾驶员的意图考虑在内<sup>[2]</sup>. 作为驾驶系统的重要组成部分,驾驶员应该始终位于整个驾驶控制的环路中,参与完成感知、判断、决策和控制等驾驶过程. 随着脑科学研究的发展,近年来越来越多的研究者开始探讨基于脑-机接口的智能辅助驾驶技术,开展驾驶员动作意图的脑神经信号特征分析和解码研究. 理解大脑认知活动和各驾驶行为之间的关系,对开发基于人机协同的智能驾驶系统具有重要作用<sup>[3,4]</sup>.

脑电(Electro Encephalo Gram, EEG)测量由于其简单、便携和高时间分辨率的特点,成为一种监测驾驶员认知状态的有效工具. 作为智能辅助驾驶系统研究的重要内容,研究者们基于模拟驾驶实验和 EEG 信号分析,就各类驾驶行为开展了广泛研究<sup>[5]</sup>. Haufe 等人<sup>[3]</sup>和 Kim 等人<sup>[6]</sup>等基于准备电位、事件相关去同步电位和事件相关电位,实现对紧急制动意图和正常驾驶过程的分类识别,并实现对制动意图的提前检测. Wang 等人<sup>[7,8]</sup>就紧急制动过程中 EEG 信号的频域特征开展了一系列研究,提出了基于 EEG 功率谱密度的紧急制动意图检测方法,结合支持向量机和线性判别分类器实现对紧急制动、软制动和正常驾驶过程的分类识别,他们提出的方法最早能在 420 ms 之前就检测到制动意图. Zhang 等人<sup>[9,10]</sup>就转向过程中 EEG 信号特征展开分析,提出了基于错误相关电位的转向意图检测方法.

Khaliliardali 等人<sup>[11,12]</sup>对加、减速过程对应的 EEG 特征展开分析,提出了基于预期皮层慢电位的加、减速识别算法. 上述研究加深了学者对不同驾驶过程对应脑认知机制的理解,也实现了对不同驾驶行为的有效检测和识别. 但是,这些研究主要集中在感觉运动脑区的少数电极通道上,缺乏全脑角度的特征信息.

然而,车辆驾驶是一个涉及感知、判断、决策和控制的复杂认知过程,需要各脑区间的协调和配合来共同完成整个驾驶过程<sup>[13]</sup>. 研究表明大脑左、右半球的功能和作用并不相同,除了左、右转向动作能够表现两个大脑半球的协作过程之外,驾驶过程中大脑活动可能会随着道路线形(如左弯道或右弯道)的不同而不同<sup>[14]</sup>. Oka 等人<sup>[15]</sup>和 Li 等人<sup>[16]</sup>基于近红外光谱成像技术,就左、右弯道驾驶过程中的脑神经活动展开研究,发现右弯道驾驶导致脑区的激活程度并没有高于左弯道驾驶,但右侧前运动皮层、右侧额叶皮层和双侧顶枕叶皮层的激活在左弯道驾驶中明显增强. 这表明左弯道驾驶需要更多的大脑活动,可能是由于左弯道驾驶比右弯道驾驶需要更多的视觉注意. 然而,目前并没有基于 EEG 的研究工作对其进行验证,此外,这些结论是否可用于开展不同线型道路(直线行驶、左弯道和右弯道)驾驶过程的识别和分类,仍然并不清楚.

为此,本文设计了包含左、右弯道和直线行驶的模拟驾驶实验,并同步采集了全脑区 EEG 信号,通过构建脑功能网络就左、右弯道和直线驾驶过程中对应脑区间的依赖关系及协作过程展开分析. 此外,为了实现对不同道路线型对应驾驶过程的识别,本文提出了一种基于脑功能网络特征参数和脑电非线性神经动力学参数的特征表示方法,通过统计分析提取不同类型间存在显著性差异的特征参数构成特征矩阵,最后使用支持向量机、高斯混合模型等多种算法完成分类识别过程. 图 1 所示为本文技术路线框图.

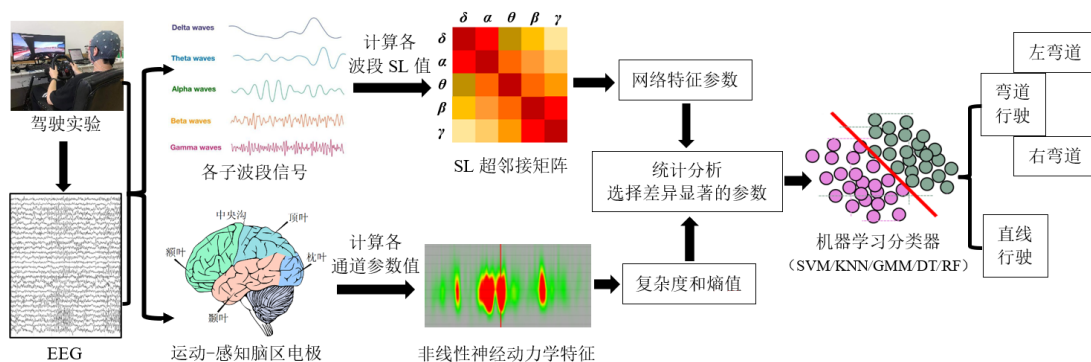


图 1 不同线型道路驾驶行为识别技术路线图

## 2 实验设计

### 2.1 实验方案

如图2(a)所示,本文使用的模拟驾驶平台基于罗技 G29 模拟驾驶器(包括方向盘、脚踏板和排挡杆)和 Unity-3D 虚拟现实软件开发完成,整个模拟驾驶实验系统组成如图2(b)所示.模拟驾驶场景通过一个 38 英寸的曲面屏显示给被试,驾驶线路为如图2(c)所示的“工”字形环形路线,由 5 段直线行驶和 6 段弯道路行

路段组成.为保证驾驶的安全性和稳定性,弯道弧度设计为 $15^\circ$ .图2(d)~(f)分别为驾驶实验中的直行(第一视角)、左弯道(全景视角)和右弯道驾驶(全景视角)场景.驾驶过程中没有其他车辆出现,要求车速保持在 80 km/h 到 90 km/h 的速度区间内,每次在进入直行、左弯道或右弯道路段时路旁都出现对应的指示标记,提示被试进入相应驾驶路段,同时触发 trigger 信号并将信号发送到脑电记录计算机以完成对该路段的数据标记.

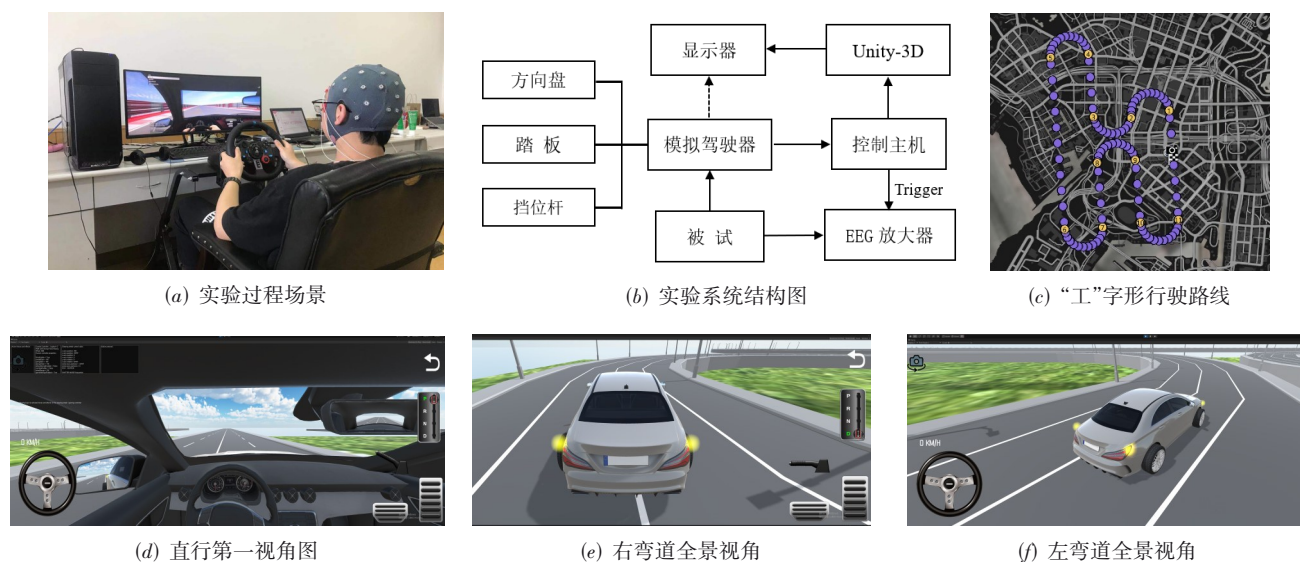


图2 模拟驾驶实验平台以及3种驾驶场景

本次实验共召集到 16 名被试,平均年龄为 23.6 岁,身体健康,均为右利手.所有被试都有驾驶证且具有一年以上的驾驶经验.车辆设置为自动驾驶模式,被试距显示屏 80 cm,实验过程中被试佩戴双通道耳机以便感知车辆的行驶声音.实验过程中要求被试集中注意力认真驾驶,除了必要的驾驶动作,身体尽量保持不动,以合理的速度完成驾驶实验.

### 2.2 数据采集和预处理

被试完成一圈大概需要 10 min,即一个实验 session.本次实验总共完成 6 个 session,被试每完成一个 session 之后,中间休息 2 分钟,以确保不会产生疲劳.在整个驾驶过程中使用 SAGA 32+ 脑电采集设备(荷兰 TMSi 公司)全程记录被试的 EEG 信号,该系统为 10-20 国际标准的 30 通道脑电采集系统,在线采样频率为 1 024 Hz,在线采样频段为 0~200 Hz,数据记录采用平均参考模式,额顶处为接地电极,垂直眼电极放置在左眼上下 2 cm 处,水平眼电极放置在两只眼睛的外眼角处.

脑电数据预处理使用 EEGLAB 完成,首先完成对

所有 session 数据的整合,然后将数据降采样到 250 Hz,并完成 0.5~48 Hz 的带通滤波,并剔除系统中的坏电极和无关通道,根据 SAGA 系统电极位置完成对所有通道 EEG 信号的电极定位.然后通过视觉检查剔除受伪迹影响较大的信号成分,之后完成 ICA 分解和伪迹成分的判别,剔除信号中可能的伪迹成分,如眼动、眨眼等.之后完成坏电极的插值处理.基于驾驶实验中的 Mark 标记,完成对不同线型路段 EEG 数据分段,在没有叠加的情况下截取 5 s 的数据作为一个 epoch,之后对所有的 epoch 数据进行平均重参考,从而完成预处理过程.通过该预处理过程最后选取了表示直线驾驶(Straight Driving, SD)、左弯道驾驶(Left Curve, LC)和右弯道驾驶(Right Curve, RC)的 600 个有效 epoch 数据段,并提取了所有 EEG 数据段的 5 个子波段信号(如图 3 所示,分别为 delta, theta, alpha, beta 和 gamma),用于后续的同步似然分析;之后选取了感知运动脑区的 11 个电极通道(FC5, FC1, FC2, FC6, C3, Cz, C4, CP5, CP1, CP2, CP6),进行了非线性神经动力学特征分析.




图3 EEG信号5个子波段示意图

### 3 研究方法

#### 3.1 同步似然分析

驾驶过程涉及多种复杂的认知活动,需要整个大脑各个脑区间的协调和配合才能完成.而通过讨论不同脑区信号间相互依赖关系来构建功能性脑网络的方法,为表征这种空间的协调机制提供了强有力的工具.脑电信号是一种非稳态、非线性的时间序列信号,而同步似然分析最大的优点是对非线性关系也非常的敏感,能够同时实现对脑电信号之间线性和非线性功能耦合的同步测量,从而很好地表征两个脑区之间的复杂交互作用<sup>[17,18]</sup>.

同步似是神经生理数据中估计广义同步的最常用指标,它的理论依据是系统在某一个时刻的状态可以用一个插值向量来表示,当系统的这个状态再次出现时,可用一个相似的插值向量对其进行表示<sup>[17,18]</sup>.本文对2个通道EEG信号间的同步似然计算依据以下步骤展开.

**步骤1** 脑电信号时间序列重建,对来自通道A的脑电信号 $x_{A,i}(i=1,2,\dots,N,N$ 为采样点数)进行 $m$ 维空间嵌入,得到

$$\mathbf{X}_{A,i}=(x_{A,i},x_{A,i+l},x_{A,i+2l},\dots,x_{A,i+(m-1)l}) \quad (1)$$

其中, $l$ 为时间延迟.同理对通道B的EEG信号进行重构得到 $\mathbf{X}_{B,i}$ .

**步骤2** 对于通道A上的第 $i$ 个样本,设定各个向量之间彼此的距离小于 $s$ 的概率为

$$P_{A,i}^s = \frac{1}{2(\omega_2 - \omega_1)} \sum_{\substack{j=1 \\ \omega_1 < |i-j| < \omega_2}}^N \theta(s - |\mathbf{X}_{A,i} - \mathbf{X}_{A,j}|) \quad (2)$$

其中, $|\cdot|$ 表示两个相空间矢量的欧氏距离; $\theta$ 为Heaviside 阶梯函数,满足当 $x \leq 0$ 时 $\theta(x)=0$ ,当 $x > 0$ 时 $\theta(x)=1$ ;正常通过 $\omega_1$ 和 $\omega_2$ 来控制时间窗,满足

$$\omega_1 \ll \omega_2 \ll N.$$

步骤3将通道A信号在采样点 $i$ 处的临界距离定义为 $s_{A,i}; P_{A,i}^{s_{A,i}}=p_{ref}$ ,其中 $p_{ref} \leq 1$ ;同样可确定通道B中信号的临界距离为 $s_{B,i}; P_{B,i}^{s_{B,i}}=p_{ref}$ .

步骤4在得到上述临界距离之后,可以对来自通道A和通道B的两路EEG信号计算同步似然指数SL,它表示通道A信号和通道B信号同时重现其状态向量的可能性,即当 $\mathbf{X}_{A,i}$ 和给定的 $\mathbf{X}_{A,j}$ 之间的距离小于临界距离 $s_{A,i}$ 时,同时 $\mathbf{X}_{B,j}$ 和 $\mathbf{X}_{B,i}$ 之间距离也小于 $s_{B,i}$ 的可能性.根据之前文献中的经验,本文选择对应参数为 $l=10, m=10, \omega_1=100, \omega_2=400, p_{ref}=0.01$ .

为了更加详细地表征不同波段EEG信号间的这种依赖关系,本文分别计算了5个子波段频段内和频段间的同步似然指数,最后得到3种道路线型对应的同步似然超邻接矩阵,如图4所示.该SL矩阵是一个 $150 \times 150$ 的方阵(每个子波段为 $30 \times 30$ 的矩阵),可以看到在各个子波段内的SL值相对较大,特别是delta和theta波段的连接最为明显,而在频段之间的同步似然连接关系相对都较小.

#### 3.2 阈值选择和脑功能网络参数分析

基于图论的复杂网络分析理论为脑功能网络的分析提供了有力工具.上述通过同步似然指数得到的频段内和频段间的超邻接矩阵中的一个值,表示了来自不同脑区或同一脑区不同通道间EEG信号的这种同步依赖关系,期间存在有大量的弱连接边,可能是由于噪声或其他非特征性的信号间的相互作用.此外,大量处于中间的连接边权值并不能很好地区分和表征不同驾驶状态之间脑区间的这种依赖关系,因此,需要设定一个合适的阈值来对上述超邻接矩阵进行筛选,保留具有一定区分度的较高连接边权值.为此,首先将3种道路线型对应的SL超邻接矩阵中连接权值放在一起组成一个权值向量,图5所示为该向量的频率直方图,然后找到该向量取值分布中的上分位点作为最终的阈值<sup>[19]</sup>,依据上述方法,本文得到的阈值为0.035.

在完成阈值筛选之后,考虑重点讨论网络的平均度、平均聚集系数、全局效率、同配系数、传递性系数和节点介数中心性<sup>[20,21]</sup>.其中网络中节点的度(Degree, D)被定义为与该节点相连的边权值之和,通常,将网络中所有节点的度的平均作为网络的度(Average Degree, AD).网络的其他2个基本特征参数为聚集系数(Clustering coefficient, C)和特征路径长度(characteristic path Length, L).对于一个度值为 $d_i$ 的节点 $i$ 来讲,聚集系数被定义为与邻居节点之间已有连接边的数目( $e_i$ )和可能存在的最大连接边的数目的比值,即




图4 3种线型(LC, RC, SD)对应的EEG信号同步似然超邻接矩阵

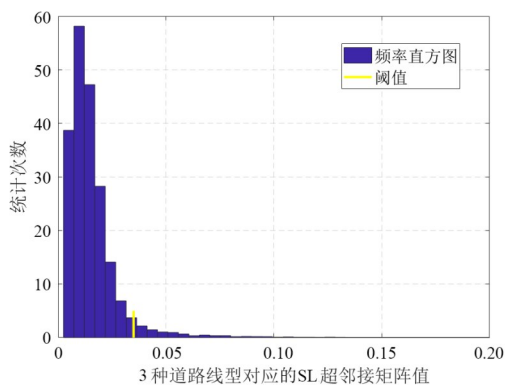


图5 三种线型对应SL超邻接矩阵值统计分布

$$C_i = \frac{2e_i}{d_i(d_i-1)} = \frac{\sum_{j,m} w_{i,j} w_{j,m} w_{m,i}}{d_i(d_i-1)} \quad (3)$$

通常,网络的聚集系数定义为所有节点聚集系数的平均值,即

$$C = \frac{1}{N} \sum_{i=1}^N C_i \quad (4)$$

特征路径长度通常被定义为节点对之间最短路径的平均值.为了处理图中的孤立节点或子图的问题,一般通常用网络全局效率的倒数来定义特征路径长度.权值网络的全局效率定义为

$$E_{\text{glob}} = \frac{\sum_{i \in N} \sum_{j \in N, j \neq i} (L_{ij}^w)}{N(N-1)} \quad (5)$$

如果一个网络中高度值的节点相互连接,则认为这个网络是同配的,可通过同配系数来度量网络中高度数节点之间的连接程度.对于一个权值网络,其同配系数(Assortativity coefficient, Ass)被定义为

$$ASS = \frac{l^{-1} \sum_{(i,j) \in L} w_{ij} d_i d_j - \left[ l^{-1} \sum_{(i,j) \in L} w_{ij} (d_i + d_j) / 2 \right]^2}{l^{-1} \sum_{(i,j) \in L} w_{ij} (d_i^2 + d_j^2) / 2 - \left[ l^{-1} \sum_{(i,j) \in L} w_{ij} (d_i + d_j) / 2 \right]^2} \quad (6)$$

其中 $l$ 为网络中所有权值边的总和.

网络的传递性意味着如果从节点 $i$ 到节点 $j$ 存在一条连接边,从节点 $j$ 到节点 $h$ 也有一条连接边,则从节点 $i$ 到节点 $h$ 之间也存在一条连接边,因此,它依赖于3个节点所组成的子图.将权值网络的传递性系数(Transitivity, Tra)定义为

$$\text{Tra} = \frac{\sum_{i \in N} 2t_i}{\sum_{i \in N} d_i(d_i-1)} \quad (7)$$

其中, $t_i$ 是节点 $i$ 周围的三角结构的几何平均,且有 $t_i = 0.5 \sum_{j,h \in N} (w_{ij} w_{jh} w_{hi})^{1/3}$ .

节点的介数中心性是网络中包含该节点的所有最短路径的条数.介数中心性高的节点参与了图中大量的最短路径.对于节点 $i$ ,其介数中心性(Betweenness Centrality, BC)被定义为

$$\text{BC} = \frac{1}{(N-1)(N-2)} \sum_{h,j \in N, h \neq i, h \neq j} \frac{\rho_{hj}(i)}{\rho_{hj}} \quad (8)$$

其中, $\rho_{hj}$ 是节点 $h$ 和 $j$ 之间的最短路径,而 $\rho_{hj}(i)$ 是通过节点 $i$ 的在节点 $h$ 和 $j$ 之间的最短路径.

### 3.3 非线性神经动力学分析

非线性动力学分析的目的是揭示复杂系统动力学特征的变化.近年来,越来越多的研究者开始通过EEG信号的非线性动力学分析来评估大脑的活动状态<sup>[22]</sup>.其中“熵”是一种应用最为广泛的分析方法,目前已有多种熵值方法<sup>[23,24]</sup>被用于神经信号分析.为了更加全面地讨论各种熵值对不同驾驶过程对应各通道脑电信号的表征,本文讨论了香浓熵(Shannon Entropy, ShEn)、近似熵(Aproximate Entropy, ApEn)、样本熵(Sample Entropy, SaEn)、排序熵(Permutation Entropy, PeEn)、状态熵(Conditional Entropy, CoEn)和模糊熵(Fuzzy Entropy, FuEn)等基于时域的熵值方法,同时也计算了表征时频特征的小波熵(Wavelet Entropy, WaEn).此外,本文还讨论了Hurst指数和Hjorth参数等分析方法,就感觉运

动皮层主要电极通道上的非线性动力学参数展开对比分析,通过统计分析来选择不同线型道路驾驶过程中存在显著差异的脑电通道和网络参数来组成特征向量。

### 4 结果分析与讨论

经过预处理之后总共得到了 600 个有效 epoch 数据

段,分别对这 600 个数据段计算 SL 超邻接矩阵,并将阈值设定为 0.035 完成对所有 epoch 数据的权值筛选,大于该阈值的连接边权值保留,小于该阈值的连接边设置为 0。之后对所有 SL 超邻接矩阵计算上述 6 类网络特征参数,并按照 LC, RC 和 SD 的类型计算其总平均,如图 6 所示。

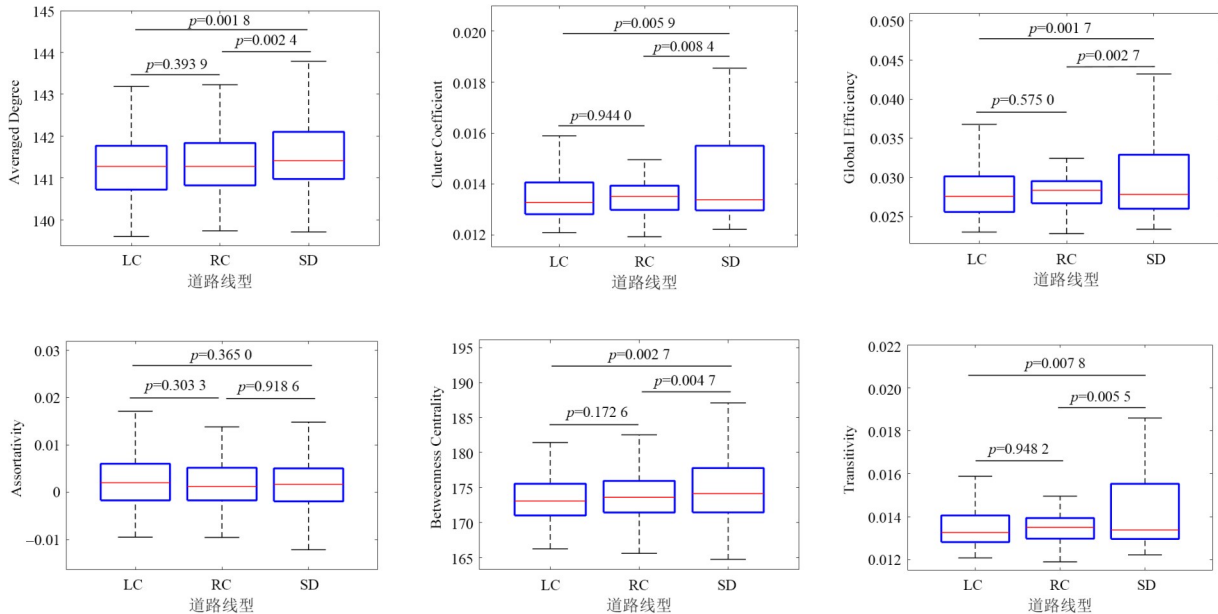


图 6 SL 超邻接矩阵网络特征参数

为了从上述 6 类网络特征参数中确定对不同驾驶状态敏感的网络特征量,本文对所有网络特征参数都进行了 ANOVA 统计分析,最后发现,在这 6 类网络参数中,Ass 在 3 种状态之间都不存在显著差异,而其他的 5 类网络参数都表现为在 LC 和 RC 之间并无显著差异 ( $p < 0.05$ ),但在 LC 和 SD 以及 RC 和 SD 之间存在显著差异 ( $p < 0.05$ )。这表明由各通道 EEG 信号的 5 个子波段在频段内和频段间构成的此 SL 超邻接矩阵的网络特征参数(平均度、平均聚集系数、全局效率、传递性系数和平均节点介数)可用于实现对直线道路行驶和弯曲道路行驶状态的识别。为此,本文首先以此 5 类差异显著的网络参数组成特征向量,即

$$V_{net} = (AD, C, E_{glob}, Tra, BC) \quad (9)$$

然后以此向量组成特征向量矩阵,使用支持向量机 (Support Vector Machine, SVM)、高斯混合模型 (Gaussian Mixture Model, GMM)、K 最近邻算法 (K-Nearest Neighbor, KNN)、决策树 (Decision Tree, DT) 和随机森林算法 (Random Forest, RF) 5 种分类算法对该特征量进行测试,完成对直线和弯道驾驶状态的识别。图 7 所示为十折交叉验证得到的平均分类准确率。可以看到, GMM, KNN, SVM, DT 和 RF 的准确率分别达到 86.33%,

82.30%, 86.66%, 85.30% 和 83.90%, 所有分类器准确率均在 82% 以上,其中 SVM 的分类效果最好,证明了该方法的有效性。

但是上述统计分析发现,该网络特征参数在左弯道和右弯道驾驶之间并无显著差异,即不能通过此类网络的特征参数实现对左弯道和右弯道驾驶过程的识别。这主要是因为网络的特征参数是从整个脑网络全局角度来度量网络的结构关系,对左、右大脑活动对应网络结构的差异性并不能进行很好地表示。但是可以实现对直线和弯道驾驶过程的识别,说明在弯道驾驶过程中整个大脑的网络结构和直线驾驶过程有很大的差异,通过量化的网络特征参数分析就可实现对此类差异的表示。

为了实现对左弯道和右弯道驾驶的识别,本文选取了感知运动脑区 11 个电极通道 (FC5, FC1, FC2, FC6, C3, Cz, C4, CP5, CP1, CP2 和 CP6) 上的 EEG 信号,分别计算并讨论了上述 7 种熵值以及 Hurst 指数和 Hjorth 参数,表 1 所示为左弯道和右弯道驾驶对应各类熵值的平均值,同样对这两种状态对应各熵值进行了配对样本  $T$  检验。最后发现,各通道上 ApEn 值和 PeEn 值在两种状态之间均没有显著差异; WaEn 值、CoEn 值

表 1 感觉运动脑区各熵值大小

| 熵/通道      |     | FC5     | FC1      | FC2     | FC6      | C3       | Cz      | C4       | CP5     | CP1     | CP2     | CP6      |
|-----------|-----|---------|----------|---------|----------|----------|---------|----------|---------|---------|---------|----------|
| ApEn 值    | 左弯道 | 0.420 3 | 0.467 8  | 0.461 5 | 0.433 6  | 0.462 1  | 0.467 6 | 0.450 3  | 0.468 6 | 0.464 6 | 0.455 6 | 0.401 2  |
|           | 右弯道 | 0.423 6 | 0.470 2  | 0.474 6 | 0.424 4  | 0.472 7  | 0.475 7 | 0.450 5  | 0.463 8 | 0.475 8 | 0.464 8 | 0.420 1  |
| WaEn 值    | 左弯道 | 0.535 9 | 0.459 3  | 0.445 6 | 0.563 8  | 0.426 5* | 0.398 8 | 0.458 9* | 0.499 3 | 0.408 8 | 0.427 4 | 0.554 6  |
|           | 右弯道 | 0.558 5 | 0.486 4  | 0.476 3 | 0.597 8  | 0.500 1* | 0.410 8 | 0.536 3* | 0.534 0 | 0.429 1 | 0.466 4 | 0.586 6  |
| CoEn 值    | 左弯道 | 0.582 0 | 0.547 4  | 0.547 7 | 0.599 8  | 0.543 2* | 0.548 7 | 0.551 2* | 0.585 0 | 0.539 1 | 0.557 0 | 0.626 4  |
|           | 右弯道 | 0.602 4 | 0.574 8  | 0.573 8 | 0.627 3  | 0.586 7* | 0.546 1 | 0.598 7* | 0.600 3 | 0.547 0 | 0.561 2 | 0.621 4  |
| FuEn 值    | 左弯道 | 0.212 5 | 0.174 1* | 0.182 1 | 0.218 5* | 0.176 0* | 0.167 7 | 0.188 0* | 0.196 3 | 0.167 7 | 0.169 2 | 0.221 7  |
|           | 右弯道 | 0.226 5 | 0.198 8* | 0.196 5 | 0.241 8* | 0.202 4* | 0.172 3 | 0.215 4* | 0.208 5 | 0.173 5 | 0.187 4 | 0.235 0  |
| SaEn 值    | 左弯道 | 0.708 4 | 0.643 1* | 0.659 5 | 0.735 4* | 0.648 6* | 0.637 2 | 0.670 3* | 0.698 5 | 0.630 2 | 0.625 9 | 0.737 9  |
|           | 右弯道 | 0.704 8 | 0.695 4* | 0.694 5 | 0.782 3* | 0.704 4* | 0.647 6 | 0.731 7* | 0.726 1 | 0.641 0 | 0.670 3 | 0.767 7  |
| Hjorth 参数 | 左弯道 | 0.322 2 | 0.270 6  | 0.268 4 | 0.340 2  | 0.277 5  | 0.256 8 | 0.280 3* | 0.292 0 | 0.253 7 | 0.253 4 | 0.342 9  |
|           | 右弯道 | 0.340 0 | 0.284 8  | 0.281 8 | 0.355 1  | 0.292 3  | 0.225 0 | 0.313 2* | 0.307 5 | 0.252 8 | 0.270 8 | 0.350 9  |
| Hurst 指数  | 左弯道 | 0.336 6 | 0.399 0  | 0.396 9 | 0.326 6  | 0.377 3  | 0.385 2 | 0.376 0  | 0.365 6 | 0.395 8 | 0.403 0 | 0.287 0* |
|           | 右弯道 | 0.332 6 | 0.401 4  | 0.400 2 | 0.325 6  | 0.383 2  | 0.401 1 | 0.364 2  | 0.367 7 | 0.407 3 | 0.396 1 | 0.316 8* |

\*  $p < 0.01$ , 在左弯道和右弯道驾驶过程中感觉运动脑区熵值特征存在显著差异的通道和对应的熵值。




图 7 不同分类器分类准确率

和ShEn值均在C3和C4上表现出显著差异;FuEn值和SaEn值在FC1,FC6,C3和C4上表现出显著差异.此外,Hjorth参数值和Hurst指数值分别在C4和CP6上表现出显著差异.最后由这些存在显著差异的通道上的非线性动力学参数构成特征向量,同样利用SVM等各类分类器实现对左弯道驾驶过程和右弯道驾驶过程的分类识别,如图7所示,GMM,KNN,SVM,DT和RF在十折交叉验证后的平均识别正确率分别为77.06%,75.95%,75.80%,77.95%和77.10%.可以看到识别效果较好,正确率均在75%以上,而此时决策树算法的识别效果最好,证明可以借助感知运动脑区某些电极上的熵值特征实现对左弯道和右弯道驾驶过程的识别.通过对比可以看出左、右弯道驾驶相比直线驾驶和曲线驾驶的识别率整体要低(75% vs. 82%),表明通过熵值和复杂度来对左弯道和右弯道驾驶过程中脑认知过程的表征还不够充分,有望通过开展更为广泛的研究,如考虑左右弯道驾驶过程中大脑对称性的空间域新特征,以及使用一些新的时频分析方法,来提高整体识别效率.

以上对不同线型驾驶过程对应网络结构和熵值特征进行了量化分析,为了实现对各状态对应大脑活动和脑区间的交互作用展开讨论,如图8所示,将全脑区30个电极按照其所所在位置划分为主要的4个脑区,并按照左、右脑结构分别表示为左额叶(Left Frontal, LF)、右额叶(Right Frontal, RF)、左顶叶(Left Parietal, LP)、右顶叶(Right Parietal, RP)、左颞叶(Left Temporal, LT)、右颞叶(Right Temporal, RT)、左枕叶(Left Occipital, LO)和右枕叶(Right Occipital, RO)总共8个区域.以该区域内电极信号的平均作为该区域内的信号值,之后计算了脑区内EEG信号间的同步似然指数,图9所示为各驾驶状态对应脑区间的连接关系.

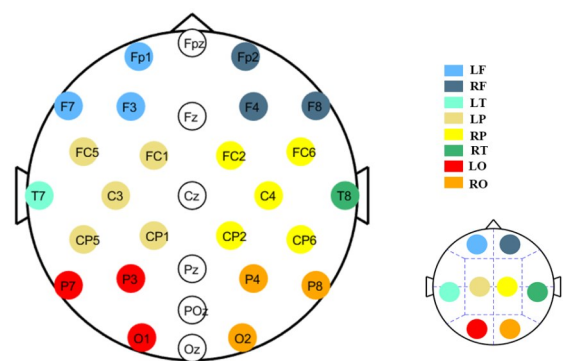


图 8 大脑基本脑区分示意图

如图9所示,左弯道驾驶(Left Curve, LC)过程中,脑区间的交互主要出现在中央-右半球各脑区之间,而右弯道驾驶(Right Curve, RC)过程中,脑区间的交互主要存在于中央-左半球各脑区之间,这和左、右脑区对应




图9 各脑区之间同步似然连接关系

的功能相对应,即弯道驾驶过程中大脑活动表现出明显的对侧性特征.相比之下,左弯道驾驶过程比右弯道驾驶过程需要更多的脑区间交互,特别是在双侧顶-枕区域,这个结论和文献中得到的结论相一致,同时左弯道驾驶过程中顶-枕区和右颞区的交互更加频繁,这也支持了文献中关于左弯道驾驶需要更多的大脑活动参与的结论.而在直线驾驶(Straight Driving,SD)过程中,脑区间的交互主要表现在额-顶-枕区之间,以及两侧颞叶和顶叶之间,其中左枕-顶之间的交互活动要强于右侧脑区,本文认为主要原因是在整个驾驶过程中,被试者都是右利手.

此外,为了对不同线型驾驶中对应脑功能网络结

构随时间进行的动态变化有一个直观的表现,本文讨论了在进入不同线型的2 min内全波段EEG信号对应的脑功能网络连接,分别取该时间段内最前端时间片、最后端时间片、最中间时间片、位于最前端和最中间之间的时间片以及最中间和最后端中间的时间片总共5个时间片构建5种不同线型道路对应的脑功能网络,如图10所示,可以看出,在该时间段内,随着时间的推移,5种道路线型下对应网络的拓扑结构并没有发生明显的变化,不同线型间的网络结构之间也没有显著的差异.这主要和本文所选的驾驶时间长度有关,这也是后期需要进一步讨论的一个问题.

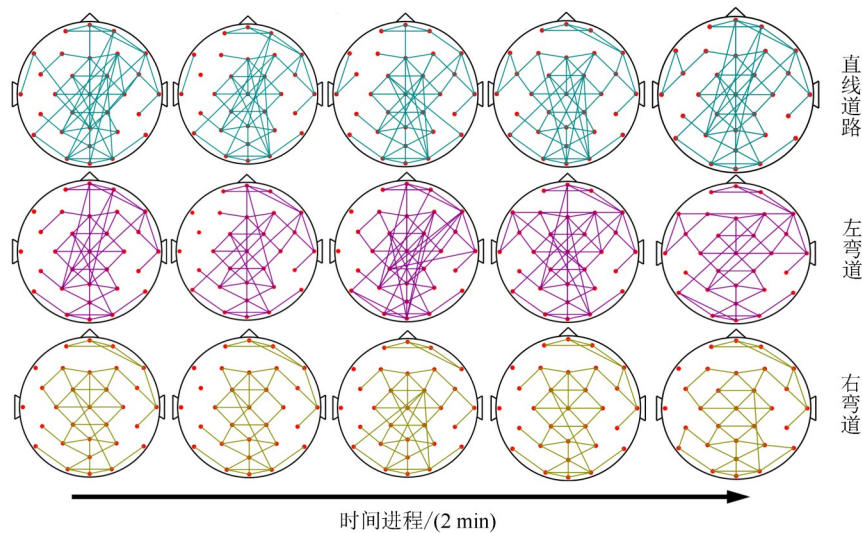


图10 不同驾驶道路下功能性脑网络拓扑结构随时间进程的变化过程

### 5 结论

本文通过设计不同线型下的模拟驾驶实验,完成了对直线行驶、左弯道和右弯道行驶对应脑电信号的同步似然分析,通过构建脑电信号5个子波段上的超邻接矩阵展开对不同驾驶状态脑功能网络的特征分析.基于该网络特征参数的统计分析,确定对不同驾驶状

态敏感的网络特征量,并利用支持向量机、高斯混合模型等算法实现对直线行驶和弯道行驶的分类识别,所有分类器的识别率均高于82%,最高达到86.66%.此外,基于感知运动脑区有显著差异的通道上的脑电信号的熵值特征,各分类算法可实现对左弯道和右弯道驾驶过程的识别,正确率均保持在75%以上,最高达到77.95%,证明了脑功能网络特征参数和脑电熵值特征

在不同线型驾驶过程识别中的有效性.

本文通过对脑区间同步似然关系的分析,确定了直线行驶、左弯道和右弯道行驶过程中脑区间的相互依赖关系. 其中弯道驾驶过程中大脑活动表现出明显的对侧性特征,且左弯道驾驶过程相比右弯道驾驶过程需要更多的脑区间交互和大脑活动,而直线驾驶过程中左枕-顶交互活动要强于右侧脑区. 本文的结果不但有力地支撑了之前文献的结论,也为弯道驾驶过程中大脑活动机制提供了新见解,对开展不同线型道路下驾驶状态研究和驾驶行为识别具有一定的参考价值.

#### 参考文献

- [1] WORLD HEALTH ORGANIZATION. Global status report on road safety[EB/OL]. (2018)[2021]. <https://www.who.int/publications/i/item/9789241565684>.
- [2] XING Y, LV C, WANG H, et al. Driver Lane Change information inference for Intelligent Vehicles: Framework, survey, and challenges[J]. IEEE Transactions on Vehicular Technology, 2019, 68(6): 5379-5390.
- [3] HAUFE S, TREDER M, GUGLER M, et al. EEG potentials predict upcoming emergency brakings during simulated driving[J]. Journal of Neural Engineering, 2011, 8(5): 056001.
- [4] YANG L, HE Z, WEI G, et al. Exploring the relationship between electroencephalograph (EEG) and ordinary driving behavior: a simulated driving study[J]. Transportation Research Record Journal of The Transportation Resarch Board, 2018, 7: 172-180.
- [5] 关伟,杨柳,江世雄,等. 脑电在交通驾驶行为中的应用研究综述[J]. 交通运输系统工程与信息, 2016, 3(16): 35-43. GUAN W, YANG L, JIANG S X, et al. Review on the application of EEG in traffic driving behavior study[J]. Journal of Transportation Systems Engineering and Informaton Technology, 2016, 3(16): 35-43. (in Chinese)
- [6] KIM I H, KIM J W, HAUFE S, et al. Detection of braking intention in diverse situations during simulated driving based on EEG feature combination[J]. Journal of Neural Engineering, 2015,12: 016001.
- [7] WANG H, BI L, TENG T. Neural correlates and detection of braking intention under critical situations based on the power spectra of EEG signals[J]. Science China Information Sciences, 2020, 63(1): 1-3.
- [8] WANG H, BI L, FEI W, et al. An EEG based multi classification method of braking intentions for driver vehicle interaction[C]//Proceedings of the IEEE International Conference on Real-time Computing and Robotics. Irkutsk: IEEE, 2019: 438-441.
- [9] ZHANG H, CHAVARRIAGA R, KHALILIARDALI Z, et al. EEG-based decoding of error-related brain activity in a real-world driving task[J]. Journal of Neural Engineering, 2015, 12(6): 066028.
- [10] ZHANG H, CHAVARRIAGA R, GHEORGHE L, et al. Brain correlates of lane changing reaction time in simulated driving[C]//IEEE International Conference on Systems, Man, and Cybernetics. HongKong: IEEE, 2015: 3158-3163.
- [11] KHALILIARDALI Z, CHAVARRIAGE R, ZHANG H, et al. Real time detection of driver's movement intention in response to traffic lights[J]. bioRxiv Preprint, 2019, 11: 1-29.
- [12] KHALILIARDALI Z, CHAVARRIAGA R, CHEORGHE L A, et al. Action prediction based on anticipatory brain potentials during simulated driving[J]. Journal of Neural Engineering, 2015, 12(6): 066006.
- [13] YANG L, HE Z, GUAN W, et al. Exploring the relationship between electroencephalography (EEG) and ordinary driving behavior: a simulated driving study[J]. Transportation Research Record, 2018, 2672(37): 172-180.
- [14] MARS F, NAVARRO J. Where we look when we drive with or without active steering wheel control[J]. PLoS ONE, 2012, 7(8): e43858.
- [15] OKA N, YOSHINO K, YAMAMOTO K, et al. Greater activity in the frontal cortex on left curves: A vector-based fNIRS study of left and right curve driving[J]. PLoS ONE, 2015, 10(5): e0127594.
- [16] LI S, SUGIMACHI T, YAMABE S, et al. Characteristics Between Driving operation and brain activity in curve section [EB/OL]. (2014)[2021]. [https://www.researchgate.net/publication/287370697\\_Characteristics\\_between\\_driving\\_operation\\_and\\_brain\\_activity\\_in\\_curve\\_sections](https://www.researchgate.net/publication/287370697_Characteristics_between_driving_operation_and_brain_activity_in_curve_sections).
- [17] 李莉,陈静静,郑旭媛. 基于同步似然分析的阿尔茨海默症静息态脑电功能网络连接特性的研究[J]. 生物医学工程学杂志, 2015, 32(5): 952-957. LI L, CHEN J J, ZHENG X Y. Study on Brain Functional Connectivity Using Resting State Electroencephalogram Based on Synchronization Likelihood in Alzheimer's Disease[J]. Journal of Biomedical Engineering, 2015, 32 (5): 952-957. (in Chinese)
- [18] STAM C J, VAN DIJK B W. Sychronization likelihood and unbiased measure of feneralized Synchronization In Multivariate Date Sets [J]. Physica D, 2002, 163:

236-241.

- [19] CHANG W, WANG H, YAN G, et al. An EEG based familiar and unfamiliar person identification and classification system using feature extraction and directed functional brain network[J]. Expert Systems With Applications, 2020, 158: 113448.
- [20] STAM C J, REIJNEVELD J C. Graph theoretical analysis of complex networks in the brain[J]. Nonlinear Biomedical Physics, 2007, 1(3): 1-19.
- [21] RUBINOV M, SPORNS O. Complex network measures of brain connectivity: Uses and interpretations[J]. NeuroImage, 2010, 52: 1059-1069.
- [22] RODRÍGUEZ-SOTELO J L, OSORIO-FORERO A, JIMÉNEZ-RODRÍGUEZ A, et al. Automatic sleep stages classification using EEG entropy features and unsupervised pattern analysis techniques[J]. Entropy, 2014, 16: 6573-6589.
- [23] 高军峰, 司慧芳, 余彬. 基于脑电样本熵的测谎分析[J]. 电子学报, 2017, 45(8): 1836-1841.  
GAO J F, SI H F, YU B. Lie detection analysis based on the sample entropy of EEG[J]. Acta Electronica Sinica, 2017, 45(8): 1836-1841. (in Chinese)
- [24] 席旭刚, 左静, 罗志增. 肌电模糊熵特征的加权核 FDA 跌倒识别[J]. 电子学报, 2016, 44(6): 1376-1382.  
XI X G, ZUO J, LUO Z Z. Weighted kernel FDA fall recognition of EMG fuzzy entropy[J]. Acta Electronica Sinica, 2016, 44(6): 1376-1382. (in Chinese)

## 作者简介



常文文 男, 1987 年出生, 甘肃通渭人. 2019 年于东北大学获得工学博士学位. 瑞士洛桑联邦理工学院神经义肢技术中心访问学者. 现为兰州交通大学副教授、硕士生导师. 主要研究方向为事脑-机交互、脑电信号处理和模式识别. 中国电子学会会员编号: E190085440M.  
E-mail: changww2013@126.com



闫光辉(通讯作者) 男, 1970 年出生, 河南睢县人. 博士. 现为兰州交通大学教授、博士生导师. 主要研究方向为大数据智能挖掘、复杂网络分析和物联网工程与应用等.  
E-mail: yanguanghui@mail.lzjtu.cn