

# 基于脑电信号的飞行员认知负荷实时监测评估系统



李葳宁, 韩宗昌, 邢晨光

中国航空系统工程研究所, 北京 100012

**摘要:**对飞行员在执行空战任务时的认知负荷状态进行实时监测和评估,对于保障执行任务的安全和高效具有重要作用。本文基于脑电信号(EEG)提出了动态图卷积-长短期记忆(DGCN-LSTM)网络认知负荷评估模型,该方法基于动态图卷积网络提取脑电的空间拓扑特征,并通过LSTM网络在时间维度上融合特征在不同时刻的时序信息,最终融合特征信息利用全连接层构建分类器,进行认知负荷状态的评估。为验证该算法的可行性,试验范式通过建立飞行任务仿真平台模拟多种典型的空战任务,设置复杂度不同的任务场景以诱发飞行员不同水平的认知负荷状态,采集被试者脑电信号用于模型训练与评估。在本文试验采集的样本数据集中,该算法在认知负荷分类的准确率达到89.08%,参数量为1.24M,性能优于其他基于支持向量机(SVM)等传统机器学习、卷积神经网络(CNN)、循环神经网络(RNN)、图卷积神经(GCN)骨干网络的算法模型,能够实现飞行员较准确的认知负荷实时监测评估。

**关键词:**认知负荷评估; 脑电信号分析; 图神经网络; LSTM; 实时监测系统

中图分类号: TN99

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2024.11.012

在空战任务下飞行员认知和情绪状态的实时检测和评估对于机载环境的人机功效提升和保障任务执行的安全高效具有重要作用。随着现代空战武器的空前发展和飞机自动化程度的提高,执行空战任务的飞行员在与飞机通过感知、认知、决策、操作进行循环交互时,由于强对抗、高动态的环境和复杂的态势变化,使得飞行员短间接收海量信息的冲击,从而造成工作负荷急剧上升、任务绩效下降。

飞行员的认知负荷是指飞行员用于集中注意力、感知情境、合理决策及行动所需的认知资源,即飞行员在单位时间内承受的工作量和处理信息所需的精力总和。飞行员经常会承受较大的工作负荷而导致应激紧张、记忆力下降、反应停滞、失误增加等情况,对机动决策响应时间造成影响。另外,在巡航工作量较低时期,飞行员处于低唤醒水平,也容易产生疏漏失误的可能。因此飞行员无论是在超高负荷和超低负荷情况下都容易导致人为错误的增加,从而使任务失败或者任务绩效受损。对于空战来说,评估飞行作战内容和飞行员认知状态,对于揭示飞行绩效、人因因素和操作动作间的耦合关系,将智能化识别飞行员认知状态情况

与空战态势信息提示或决策辅助相结合,对提升作战效能具有重要意义。

目前国内外对于认知负荷状态评估的方法可分为主观评价法与客观测量法两类。主观评价方法主要有身体活动情绪(PAAS)量表<sup>[1]</sup>、自我情绪评定(SAM)量表<sup>[2]</sup>、主观负荷评估(SWAT)量表<sup>[3]</sup>、美国国家航空航天任务负荷指数(NASA-TLX)量表<sup>[4]</sup>等。但是在某些任务环境下进行主观评价还很困难,实施效果受任务环境影响。主观评价受被试者主观感受和心理水平的影响程度较大,评价标准难以保持一致。研究表明主观量表在敏感性、稳定性、抗干扰性和共时效度均有所差异。另外,主观方法要求被实验者在任务结束后进行主观报告,无法做到实时测量。

客观直接测量方法主要是基于生理指标的认知状态识别方法,其实施过程具有良好的可重复性,随着测量技术的发展,生理指标获取越来越容易,可以为评估提供客观依据,因此被越来越广泛地使用。生理指标根据产生机理分为两大类:与中枢神经系统相关联的脑电信号(EEG)、眼电信号(EOG)、脑磁图(EGG)、功能性近红外光谱(fNIRS)技

收稿日期: 2024-03-29; 退修日期: 2024-06-19; 录用日期: 2024-08-28

引用格式: Li Weining, Han Zongchang, Xing Chenguang. Real-time mental workload monitoring and evaluation system based on EEG signals of pilots[J]. Aeronautical Science & Technology, 2024, 35(11):95-103. 李葳宁, 韩宗昌, 邢晨光. 基于脑电信号的飞行员认知负荷实时监测评估系统[J]. 航空科学技术, 2024, 35(11):95-103.

术测量脑血红蛋白浓度等指标,以及与周围神经系统相联系的皮电信号(EDA)、心电信号(ECG)、呼吸信号、体表温度、瞳孔直径等。与主观评测方法比较,基于生理信号识别评价飞行员的认知状态具有很高的实用性和客观性。张益凡等<sup>[5]</sup>通过眼动信息对飞行员的注意力状态进行识别与检测。

EEG信号能够直接反映大脑活动状态,与心理认知状态直接相关,基于EEG信号的分析目前有很多相关工作。通常采用的方法是先将脑电信号进行预处理与特征提取,提取的时域或频域特征通过传统机器学习算法,如支持向量机(SVM)<sup>[6]</sup>、K最近邻算法(KNN)<sup>[7]</sup>等对样本进行分类处理。近年来,基于深度学习算法对脑电信号的分类分析逐渐成为主流方法。Alhagry等<sup>[8]</sup>利用长短时记忆(LSTM)网络结构提取EEG信号的时序信息来对情绪状态进行识别分类。Zhang Dalin等<sup>[9]</sup>通过卷积神经网络(CNN)对EEG信号的空间信息进行特征提取。尽管这些方法能够提高分类性能,但它们没有将时域空域特征相结合进行提取与分类。为解决这一问题,Xu Guixun等<sup>[10]</sup>提出一种门控循环单元-卷积(GRU-Conv)模型提取脑电的时空特征。该模型将原始EEG信号作为输入,结合CNN与门控循环神经网络(RNN)结构完成对信号的分类处理。由于脑电信号采集时电极位置具有非欧式性,Song Tengfei等<sup>[11]</sup>提出一种动态图卷积网络的方法提取脑电的空间拓扑信息。在此基础上,Zhong Peixiang等<sup>[12]</sup>提出了正则化图神经网络以解决脑电情绪识别中的跨个体差异性问题。但这些工作没有将空间拓扑特征与时域特征相融合,忽略了认知负荷变化相关的脑电信号的时序相关性。

本文提出基于DGCN-LSTM网络的EEG信号认知负荷分类算法,利用滑动窗法对不同频带信号提取的特征作为网络输入,同时对脑电信号的空间拓扑特征和时序信息进行特征提取,用于认知负荷分类。

## 1 EEG信号预处理与特征提取方法

### 1.1 EEG信号预处理

脑电图是一种使用电生理指标记录大脑皮质神经活动的方法,广泛应用于人体心理认知状态的评估。EEG信号按频率可被划分为几个频段:(1)delta节律(1~3Hz)主要分布在额叶区域,其所占的能量也会随着大脑从清醒状态变为疲劳状态而增加;(2)theta节律(4~7Hz)会在困倦时出现,与反应的迟缓有关;(3)alpha节律(8~13Hz)在休息时出现在中央区,也会在放松或闭眼时出现,同时与控制减弱有

关,也与不同脑区的抑制有关;(4)beta节律(14~30Hz)大部分出现在额叶,幅值较低,在积极思考、注意力集中、焦虑和警觉时出现;(5)gamma节律(31~50Hz)通常与大脑的剧烈活动有关。

脑电信号采集时易受到其他生理电信号如眼电、肌电和心电等伪迹干扰以及工频信号、周围环境和电极固有噪声的影响。眼电伪迹包括眨眼伪迹与眼动伪迹,主要频率范围低于4Hz,肌电伪迹主要频率高于30Hz,心电伪迹由心脏跳动引起,频率约为1.2Hz。眨眼伪迹是由眨眼造成偶极子电势差的急剧变化引起的,其中额叶部位脑电信号受到眨眼伪迹的影响最大。眨眼伪迹在脑电图上的主要表现为窄的尖峰、幅值大,随着电极位置越靠后,其幅值会逐渐变小,且尖峰的时间范围也会变宽,是对脑电信息质量影响最大的伪迹类型。因此需要对原始脑电信号进行数据预处理,通过基线校正和滤波降噪的方法降低伪迹和噪声影响。

为保证样本数量充足且分布均衡,需要对采集的脑电信号进行滑窗法处理,通过长度为 $T$ 、重叠率为 $r$ 的移动滑窗实现样本扩增,其中窗长和重叠率大小的设置需要进行多次试验调整,选择预测效果最佳的数值。图1所示为EEG信号的预处理流程,首先将脑电信号通过移动滑窗进行数据扩增,而后通过巴特沃斯带通滤波器和陷波滤波器降低工频、噪声和生理电信号高频伪迹的干扰,并对每个通道数据进行小波分解,计算近似系数序列的尖峰区系数并进行软阈值处理后重构,最终保留脑电( $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$ ,  $\gamma$ )主要频段成分。

### 1.2 EEG信号预处理

脑电信号特征主要包括时域特征、频域特征、时频特征以及空间域特征。用于认知负荷状态评估的常见特征有微

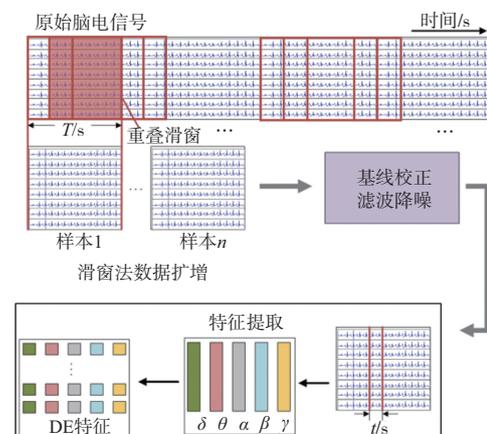


图1 EEG信号预处理流程示意图

Fig.1 EEG signals preprocessing workflow

分熵 (DE)<sup>[13]</sup>、功率谱密度 (PSD)<sup>[14]</sup>、差异不对称 (DASM)<sup>[15]</sup>、有理不对称 (RASM)<sup>[16]</sup>等。

微分熵可以有效平衡各频率成分之间的贡献水平,被广泛应用于认知状态识别任务中,并表现出良好的性能。微分熵是香农信息熵 (Shannon entropy) 在有限区间内连续变量的推广形式,其计算公式如下

$$\text{Shannon Entropy} = - \sum_x p(x) \log p(x) \quad (1)$$

$$\text{DE} = - \int_a^b p(x) \log p(x) dx \quad (2)$$

式中,  $p(x)$  表示连续信号的概率密度函数。对于一段特定长度的近似服从高斯分布  $p(x) \sim N(\mu, \sigma_i^2)$  的脑电信号,其 DE 特征计算公式如下

$$\text{DE} = - \int_a^b \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(x-\mu)^2}{2\sigma_i^2}} \log \left( \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(x-\mu)^2}{2\sigma_i^2}} \right) dx = \frac{1}{2} \log (2\pi\sigma_i^2) \quad (3)$$

通过带通滤波器将各通道原始信号分解成 5 个频段 ( $\delta, \theta, \alpha, \beta, \gamma$ ) 的信号,通过非重叠滑动窗口将样本分为若干个子片段,计算各子片段的微分熵特征,最后拼接得到特征量。

## 2 基于 DGCN-LSTM 网络的认知负荷识别算法

本文提出基于 DGCN-LSTM 模型对脑电进行认知负荷状态分类,该方法可以实现对脑电信号的空间域及时域的特征提取和信息聚合,整体网络结构如图 2 所示。

### 2.1 基于动态图卷积网络的非欧空间信息聚合

脑电模态的连接关系具有不规则的空间结构,属于非欧式空间信息。由于传统卷积神经网络卷积核尺寸固定,因此相较于 CNN,脑电信号更适合通过图卷积神经网络 (GCNN) 进行特征聚合。图结构比栅格结构更能正确体现大脑各区域之间的联系性,在训练中将表示节点连接关系的邻接矩阵作为参数更新,使得模型自动学习到拓扑结构。

在图理论中,数据信息由多个节点的特征以及不同节点间连接构成的拓扑关系表达  $G=(N, E, W)$ ,其中  $N$  代表图结构中的节点的集合,在本文中对应 EEG 各通道信号,  $E$  表示为图结构中连接各节点的边的集合,  $W \in \mathbb{R}^{n \times n}$  为用于描述两节点间连接重要性的邻接矩阵,计算第  $i$  个和第  $j$  个节点间连接重要性  $w_{ij}$  的常用方法有距离函数法和 K 最近邻 (KNN) 法。由于大脑活动涉及多个脑区的协同合作,本文中将各通道间的皮尔逊 (Pearson) 相关系数作为功能连接指标,对所有

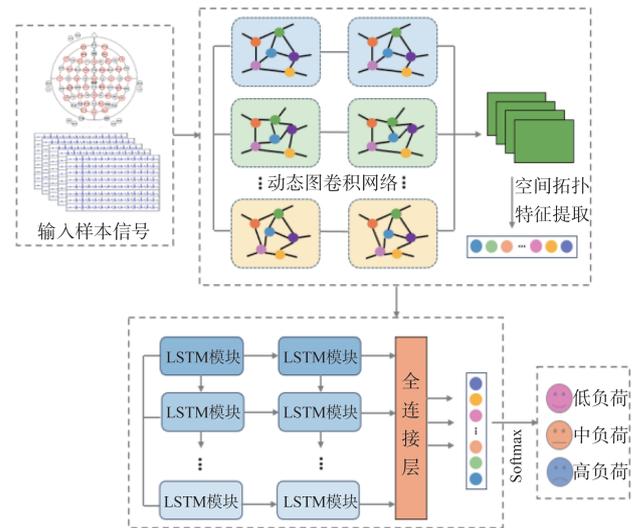


图2 基于 EEG 信号的认知负荷识别网络结构

Fig.2 Model architecture of mental workload estimation based on EEG signals

样本取均值并归一化后作为邻接矩阵的初始值。另外,消极情绪能激活右侧额叶、颞叶和顶叶,而积极情绪能激活左侧区域,形成了脑电信号的空域特征。为了充分利用这种信息的不对称性,在邻接矩阵中添加全局连接。

通过设计有效的谱图滤波器来学习图空间结构特征、抽象高维特征得到了广泛研究。借助图谱理论实现拓扑图卷积操作,通过图的拉普拉斯矩阵特征值和特征矢量研究图的性质<sup>[17]</sup>。图的拉普拉斯矩阵定义为  $L = D - W \in \mathbb{R}^{N \times N}$ ,其中  $W$  为邻接矩阵,  $D$  为一个对角矩阵,各对角元素  $D_{ii} = \sum_j w_{ij}$ 。由于  $L$  是一个实对称矩阵,可以对  $L$  进行正交对角化

$$L = UAU^T \quad (4)$$

式中,  $U$  为  $L$  的特征矢量矩阵,  $A = \text{diag}([\lambda_0, \dots, \lambda_{N-1}])$  为  $L$  的特征值矩阵。根据图谱理论,拉普拉斯矩阵特征值定义了图模态的频率信息,特征矢量构成的矩阵  $U^T$  构成了图傅里叶变换 (GFT)<sup>[18]</sup> 的变换阵,即图傅里叶变换与逆变换表达式如下

$$\hat{f} = U^T f \quad (5)$$

$$f = U\hat{f} \quad (6)$$

将图傅里叶变换推广至图卷积,根据卷积定理,函数卷积的傅里叶变换是函数傅里叶变换的乘积,即

$$f \odot g = F^{-1}\{F(f) * F(g)\} = F^{-1}\{\hat{f} * \hat{g}\} \quad (7)$$

式中,  $\odot$  为卷积运算符,  $F(\cdot)$  与  $F^{-1}(\cdot)$  分别为傅里叶变换和傅里叶逆变换。因此,对图上的卷积可以表示为

$$f \odot g = U((U^T g) * (U^T f)) \quad (8)$$

式中,\*为内积运算符。把 $U^T g$ 看作可学习的卷积核 $g_\theta$ ,则最终图上卷积公式为

$$f \odot g = U g_\theta U^T f \quad (9)$$

在图卷积网络中,卷积核 $g_\theta$ 为图卷积中可学习参数的集合,是图卷积网络的核心构成。

但是上述矩阵运算过程计算复杂度过高,特征矢量 $U$ 的复杂度为 $O(N^2)$ ,对于大型图结构来说,拉普拉斯矩阵特征值分解的计算量很大,需要构建近似方法降低计算复杂度。本文采用图拉普拉斯算子的切比雪夫(Chebyshev)展开式降低计算复杂度,设置卷积核 $g_\theta$ 为特征值矩阵 $A$ 的函数,定义特征矢量矩阵 $U$ 的对角矩阵的切比雪夫多项式为滤波器<sup>[9]</sup>,利用低阶切比雪夫多项式拟合卷积核降低计算复杂度

$$g_\theta = g_\theta(A) = \sum_{i=0}^{K-1} \theta_i T_k(\hat{\lambda}) \quad (10)$$

式中, $K$ 为切比雪夫多项式阶数,通过对 $K$ 的选择截断多项式,获得对信号 $x$ 与滤波器 $g_\theta$ 图卷积的结果,表达式为

$$g_\theta \odot x = U g_\theta U^T x = \sum_{i=0}^{K-1} \theta_i T_k(\hat{L}) x \quad (11)$$

GCNN网络由若干个上述图神经元(图滤波器)构成,每个图神经元执行基于切比雪夫多项式拟合图卷积核的卷积操作,进行不同脑电节点间的信息融合。

本文采用动态图卷积网络(DGCN)<sup>[10]</sup>对于图结构中各节点邻接矩阵的学习建立自适应的图学习机制,在训练过程中,图的结构通过动态学习得到而非人为事先设定。设节点之间的成对关系由实对称矩阵 $A$ 定义,即 $A$ 为图的邻接矩阵。对于 $A$ 中的各个元素,定义非负函数 $A_{mn} = g(x_m, x_n)$ 来表示节点 $x_m$ 和 $x_n$ 之间的连接关系, $g(x_m, x_n)$ 通过具有可学习权矢量 $\omega$ 的神经网络来实现,具体公式如下

$$A_{ij} = g(x_i, x_j) = \frac{e^{\text{ReLU}(w^T |x_i - x_j|)}}{\sum_{i=1}^N e^{\text{ReLU}(w^T |x_i - x_j|)}} \quad (12)$$

式中,激活函数ReLU保证了 $A_{mn}$ 的非负性。softmax对 $A$ 的每一行进行规范化。权矢量 $\omega$ 通过最小化以下损失函数来进行参数更新

$$L_g = \sum_{i,j=1}^N \left\| |x_i - x_j| \right\|_2^2 A_{ij} + \lambda \|A\|_F^2 \quad (13)$$

因此,节点 $x_i$ 和 $x_j$ 之间的距离越大, $A_{ij}$ 越小。由于大脑连接结构不是一个完全连通的图,通过上述损失函数的正则项来控制图的稀疏性,其中 $\lambda \geq 0$ 为正则化参数。

## 2.2 基于长短时记忆的时序特征提取

脑电信号作为时序信号,具有时间相关性,LSTM<sup>[20]</sup>广泛应用于时序信号分类问题,能够进行时间维度上的特征融合,具有较好的时间信息学习能力。LSTM由门控子网络构成,分为遗忘门、输入门和输出门。针对无用历史信息的堆积问题,遗忘门对历史单元状态中的分量进行选择性地忘记。当前输入与上一时刻隐层状态经过sigmoid神经层获得遗忘系数,再与上一时刻的单元状态进行内积实现历史信息的遗忘过程

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (14)$$

式中, $f_t$ 为 $t$ 时刻遗忘门输出值, $\sigma$ 表示sigmoid激活函数, $W_f$ 为遗忘门权重矩阵, $h_{t-1}$ 为前一个时间步的隐藏状态值, $x_t$ 为当前时间步的输入, $b_f$ 为遗忘门的偏置项。

输入门又称为记忆门,用来控制是否将当前时刻输入信息融合到单元状态。使用tanh函数层将现在的矢量中的有效信息提取出来,然后基于sigmoid函数来控制这些记忆信息进入单元状态

$$C'_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (15)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (16)$$

$$C_t = f_t C_{t-1} + i_t C'_t \quad (17)$$

式中, $C'_t$ 为候选记忆细胞,用于存储并更新长期依赖信息的中间值, $C_t$ 为当前时间步更新后的记忆细胞。 $W_c$ 、 $b_c$ 分别为候选记忆细胞的权重矩阵和偏置项。 $i_t$ 是输入门的输出值, $W_i$ 、 $b_i$ 分别为输入门的权重矩阵和偏置项。

输出门用于计算当前时刻LSTM网络输出值,先将当前输入与上一时刻隐层状态经过sigmoid神经层获得输出系数,然后将当前单元状态经过tanh函数映射至特征区间 $(-1, 1)$ 中,最后将两者内积获得输出特征值

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (18)$$

$$h_t = o_t \tanh(C_t) \quad (19)$$

本文基于图卷积网络提取脑电的空间拓扑特征,并通过LSTM网络在时间维度上融合特征在不同时刻的动态变化信息,将最终特征传送至全连接层构建分类头,进行认知负荷状态分类。

## 3 认知负荷监测系统设计与试验验证

### 3.1 认知负荷评估的试验范式设计与数据采集

为激发飞行员不同的认知负荷状态,本文通过建立飞行任务仿真平台模拟多种典型的空战任务,通过设置复杂度不同的任务场景以激发飞行员不同水平的认知负荷状态,见表

1,在本文试验范式设计中,将平稳飞行、频繁起降和战斗空战场景作为激发飞行员低、中、高三种负荷状态的任务场景,试验过程中采集多位飞行员被试的脑电信号,并同步记录三种不同难度任务场景的切换时间戳,方便后续数据标注。每次任务执行完毕后,被试飞行员须立即填写NASA-TLX量表和SAM量表,尽可能准确地回忆任务执行过程中的负荷状态和情绪状态。量表结果可以帮助了解飞行员在任务过程中的主观感受,并作为判断认知负荷和情绪状态的辅助依据。

表 1 试验范式设计

Table 1 Experimental paradigm design

负荷状态	低	中	高
任务场景设置	平稳飞行	滑行起飞、目标巡航、降落	移动目标攻击、战斗
任务时长	5min	5min	以确定打击目标开始至攻击时间超5min结束
计时方法	记录脑电开始、视频开始、任务开启、任务结束机器时间		
主观评价	NASA-TLX量表,SAM量表		

图3所示为认知负荷状态评估试验的环境搭建示意图,该系统由脑电信号采集设备、飞行任务仿真平台、视频采集设备及时间戳同步记录4部分构成。飞行员被试的脑电信号采集设备采用BCI pro 32导放大器,采用湿式脑电帽(CM-HG01-2074),电极位置遵循10-20国际系统标准<sup>[21]</sup>,采样率设置为1000Hz。通过摇杆、节流阀和脚舵等操纵设备搭建飞行任务仿真平台,以模拟飞行员在不同负荷下的飞行任务场景。同时,视频采集设备对飞行员被试执行模拟飞行任务采集脑电信号的全过程进行录制,并同



图3 试验环境

Fig.3 Experimental environment

步记录关键事件发生时间戳,以此作为脑电信号的分类依据用于后续算法训练与评估。

为验证本文提出的算法对飞行员认知负荷状态的评估效果,基于该试验范式采集了6名不同飞行员在完成低、中、高负荷飞行任务试验的脑电信号,平均每个被试进行10余组试验,共收集到210段脑电数据,每段信号时长约为5min。本文数据集采集中选取了32个通道的脑电数据,分别为1~8号(F8,FC2,FC6,C4,T8,CP2,CP6,PO4)、9~16号(F7,FC5,FC1,T7,C3,CP5,CP1,PO3)、17~24号(FP1,FP2,AF3,AF4,F3,FZ,F4,CZ)、25~32号(P7,P3,PZ,P4,P8,O1,OZ,O2)。这些通道覆盖了全脑所有区域,并呈左右对称状态。

### 3.2 认知负荷识别算法的试验验证与结果分析

为验证本文提出的认知负荷识别算法的可行性,本文基于试验范式所采集到的数据样本对算法进行训练和验证。本文认知负荷识别算法基于Pytorch框架设计完成,下面将从损失函数、训练优化器超参数设置两方面并结合模型评价方法对算法验证试验进行介绍与结果分析。

损失函数由于受试者在飞行任务中不一定产生预期的负荷,对标签给定造成了一定的困难。在机器学习中一个样本的类标签通常是确定的,如0或1或2。对此,本文学习了一个类的先验概率分布,其中 $\varepsilon$ 定义为一个控制噪声的超参数,本文试验中设置为0.15。

$$Y_i = \begin{cases} \left(1 - \frac{2\varepsilon}{3}, \frac{2\varepsilon}{3}, 0\right), & Y_i = 0 \\ \left(\frac{\varepsilon}{3}, 1 - \frac{2\varepsilon}{3}, \frac{\varepsilon}{3}\right), & Y_i = 1 \\ \left(0, \frac{2\varepsilon}{3}, 1 - \frac{2\varepsilon}{3}\right), & Y_i = 2 \end{cases} \quad (20)$$

然后利用KL散度作为损失函数衡量类的先验概率分布和模型输出的概率分布之间的相似性,计算公式如下

$$D_{KL}(p||q) = \sum_{i=1}^N p(x_i) \cdot \log \left( \frac{p(x_i)}{q(x_i)} \right) = \sum_{i=1}^N p(x_i) \cdot [\log p(x_i) - \log q(x_i)] = \mathbb{E}_{x \sim p(x)} [\log p(x) - \log q(x)] \quad (21)$$

此外,由于多次重复试验,飞行员对于战斗场景逐渐熟悉,导致高负荷样本数量明显少于低/中负荷样本数量。为减小样本不平衡对模型训练造成的影响,本文中根据低/中/高样本数计算得到标签类别权重比值大小,计算加权损失函数,以缓解样本不平衡的问题。

本文选用Adam自适应优化器进行算法训练,通过调

整学习率和权重衰减率使目标函数快速收敛。模型主要超参数设计见表2,包括样本数据预处理、DGCN、LSTM以及训练部分。

表2 模型超参数设计

Table 2 Hyperparameters of the proposed model

模块	超参数	取值范围
训练	学习率	[0.001, 0.00001]
	权重衰减率	[0.001, 0.00001]
	批量大小	[8, 32]
	迭代次数	200
动态图卷积网络	近邻K数量	[2, 4, 8]
	图卷积层数	2
长短时记忆网络	隐藏层个数	[128, 256]
	层数	[2, 3]
样本预处理	滑动窗长大小	[1s, 4s]
	滑动窗重叠率	[0.25, 0.75]
	特征提取窗长	[0.1s, 0.2s]

试验中,将基于传统机器学习算法、图卷积神经网络、CNN、LSTM的现有算法与本文提出的模型在数据集上进行训练,并对各算法的识别精度进行对比,对比结果见表3。

表3 不同模型结果对比

Table 3 Comparison between different models

模型	提取特征	测试集准确率/%
SVM	微分熵	70.63
EEGNet	微分熵	80.39
GCNN	微分熵	81.47
LSTM	微分熵	84.32
本文模型	微分熵	89.08

由对比试验结果可以看出,本文提出的基于GCN-LSTM模型相比于其他算法,在自采EEG数据集上对工作负荷的分类效果更好,平均准确率为89.08%,训练损失函数收敛曲线和准确率曲线如图4所示。

本文还对比了使用不同脑电特征对模型分类效果的影响。表4所示为EEG提取不同特征的模型分类效果的对比。

由不同特征的对比结果可以看出,微分熵和功率谱密度特征在工作负荷分类任务中具有较好性能。图5分别展示了低、中、高负荷场景下不同频带的脑电功率密度分布图。

针对不同的超参数设定,如数据增强中使用的脑电信号的滑窗大小及重叠率也会对模型分类效果产生影响。本文选取了不同窗长和重叠率参数分别对模型进行训练,

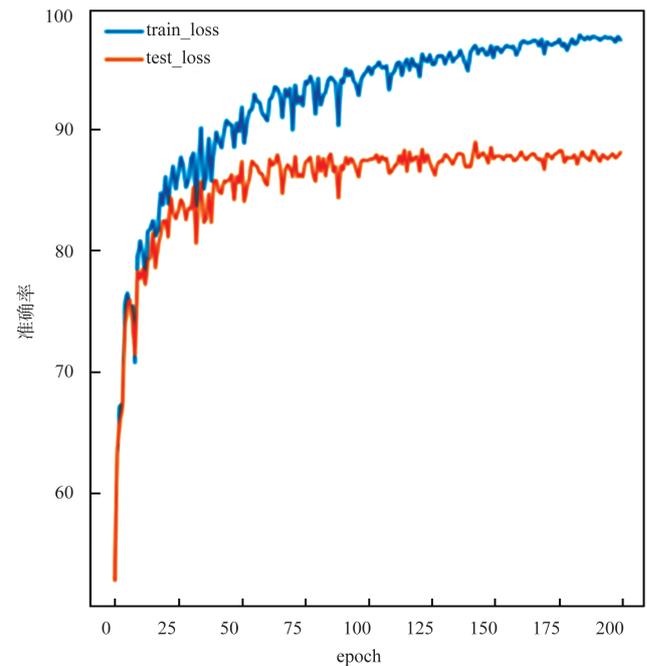
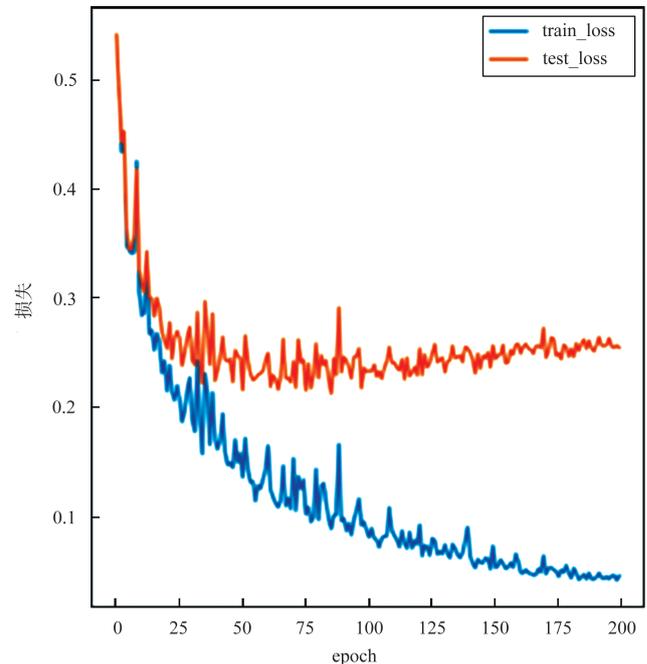


图4 模型训练的损失函数收敛曲线与准确率曲线

Fig.4 Loss function convergence curve and accuracy curve of model training

测试结果见表5。

本文对比了不同层数下模型的参数量大小与在训练集和测试集上的识别准确率大小,试验结果见表6。

由上述试验结果可以看出,在本文识别任务场景下,采用75%重叠率的4s滑动窗进行脑电处理时模型分类效果

表 4 脑电信号不同提取特征的结果对比  
Table 4 Comparison between different EEG extracted features

提取特征	提取特征窗长	测试集准确率/%
微分熵	0.2s	85.21
功率谱密度	0.2s	86.08
差异不对称性	0.2s	79.77
有理不对称性	0.2s	65.81

表 5 不同窗长及重叠率的结果对比  
Table 5 Comparison between different window length and overlap hyperparameters

滑动窗窗长/s	重叠率	测试集准确率/%
1	0.75	84.01
	0.5	79.20
	0.25	78.15
2	0.75	84.72
	0.5	81.06
	0.25	79.83
4	0.75	89.08
	0.5	82.00
	0.25	79.28

较好。模型大小同样会对识别准确率产生影响,考虑到飞行员工作负荷评估对实时性具有较高要求,本文模型参数

量为 1.24M,模型在 Intel Core i5 CPU 上平均推理时间为 0.2s,能够实现在线实时识别<sup>[21]</sup>。

表 6 模型不同参数量的识别结果对比  
Table 6 Comparison between different sizes of the model

模型	层数	参数量	训练集准确率/%	测试集准确率/%	推理时间/s
DGCN-LSTM	2	1.24M	96.12	89.08	0.20
DGCN-BiLSTM	2	2.74M	96.30	86.98	0.33
DGCN-LSTM	3	1.77M	95.89	87.58	0.24
DGCN-LSTM	4	2.30M	94.86	87.28	0.26

### 4 结论

本文针对空战任务中飞行员认知负荷状态的实时监测与评估需求,提出了一种 DGCN-LSTM 算法。首先通过对脑电信号在不同频带内微分熵计算提取频域特征,并在空域和时域内对特征进一步融合提取,最终得到基于脑电信号的飞行员认知负荷状态的评估结果。通过试验验证,得出结论如下:

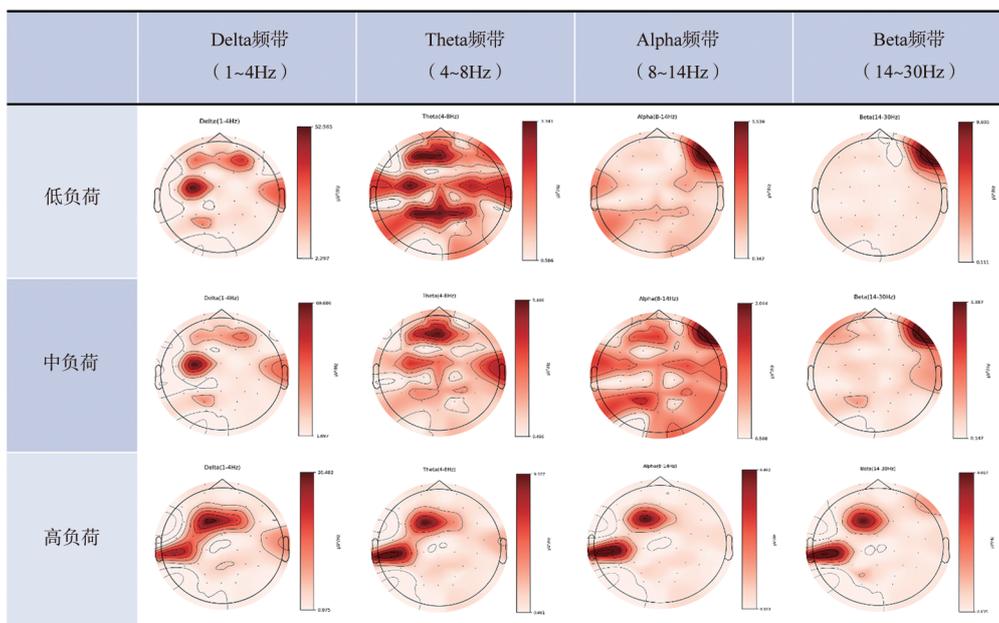


图 5 三种工作负荷状态的不同频带脑电功率密度分布  
Fig.5 EEG power map of different frequency bands under three workload statements

(1) 通过滑动窗对样本进行数据扩增,通过计算脑电信号在不同频带内的特征作为模型输入,可有效降低输入样本维度,减小模型参数量和FLOPs大小,提高评估效率和模型泛化能力。

(2) 分别对基于传统机器学习、GCNN、CNN、LSTM为骨干网络的算法与本文算法在同一数据集上进行训练和测试,试验结果表明,DGCN-LSTM算法在认知状态分类上具有较高性能,能够较准确地评估不同飞行任务下飞行员的工作负荷状态。

(3) 在脑电信号预处理中,提取特征不同,滑动窗窗长与重叠率的设置不同,都会对模型的识别准确率产生影响。通过试验对比,提取微分熵和功率谱密度特征在工作负荷分类任务中具有较好性能。

未来研究可通过模型轻量化部署在终端,实现飞行员认知负荷状态在线评估,对高负荷实施告警干预,并为有无人协同交互决策提供有效依据<sup>[22]</sup>,形成闭环系统,提高飞行员执行任务的安全性与可靠性。

**AST**

## 参考文献

- [1] Lox C L, Jackson S, Tuholski S W, et al. Revisiting the measurement of exercise-induced feeling states: The physical activity affect scale (PAAS) [J]. *Measurement in Physical Education and Exercise Science*, 2000, 4(2):79-95.
- [2] Bradley M M, Lang P J. Measuring emotion: the self-assessment manikin and the semantic differential[J]. *Journal of Behavior Therapy and Experimental Psychiatry*, 1994, 25(1): 49-59.
- [3] Reid G B, Nygren T E. The subjective workload assessment technique: A scaling procedure for measuring mental workload [J]. *Advances in Psychology*, 1988, 52: 185-218.
- [4] Hart S G. NASA-task load index (NASA-TLX): 20 years later [C]//*Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 2006.
- [5] 张益凡,王宇超,张琴喻,等. 基于眼动指标的飞行员注意状态识别可行性研究[J]. *航空科学技术*, 2022, 33(4):39-46.  
Zhang Yifan, Wang Yuchao, Zhang Qinyu, et al. Feasibility study of pilot attention state recognition on eye movement indicators[J]. *Aeronautical Science & Technology*, 2022, 33(4): 39-46. (in Chinese)
- [6] Wang Xiaowei, Nie Dan, Lu Baoliang. EEG-based emotion recognition using frequency domain features and support vector machines[C]. *18th International Conference ICONIP 2011*, 2011.
- [7] Bahari F, Janghorbani A. EEG-based emotion recognition using recurrence plot analysis and K nearest neighbor classifier [C]. *2013 20th Iranian Conference on Biomedical Engineering (ICBME)*, 2013: 228-233.
- [8] Alhagry S, Fahmy A A, El-Khoribi R A. Emotion recognition based on EEG using LSTM recurrent neural network[J]. *International Journal of Advanced Computer Science and Applications*, 2017, 8(10):355-358.
- [9] Zhang Dalin, Yao Lina, Zhang Xiang, et al. Cascade and parallel convolutional recurrent neural networks on EEG-based intention recognition for brain computer interface[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*, 2018.
- [10] Xu Guixun, Guo Wenhui, Wang Yanjing. Subject-independent EEG emotion recognition with hybrid spatio-temporal GRU-Conv architecture[J]. *Medical & Biological Engineering & Computing*, 2023, 61(1): 61-73.
- [11] Song Tengfei, Zheng Wenming, Song Peng, et al. EEG emotion recognition using dynamical graph convolutional neural networks[J]. *IEEE Transactions on Affective Computing*, 2018, 11(3): 532-541.
- [12] Zhong Peixiang, Wang Di, Miao Chunyang. EEG-based emotion recognition using regularized graph neural networks [J]. *IEEE Transactions on Affective Computing*, 2020, 13(3): 1290-1301.
- [13] Duan Ruonan, Zhu Jiayi, Lu Baoliang. Differential entropy feature for EEG-based emotion classification[C]. *2013 6th International IEEE/EMBS Conference on Neural Engineering (NER)*, 2013: 81-84.
- [14] Alsolamy M, Fattouh A. Emotion estimation from EEG signals during listening to Quran using PSD features[C]. *2016 7th International Conference on Computer Science and Information Technology (CSIT)*, 2016: 1-5.
- [15] Liu Yisi, Sourina O. Real-time fractal-based valence level recognition from EEG[C]. *Transactions on Computational Science XVIII: Special Issue on Cyberworlds*, 2013: 101-120.
- [16] Lin Yuanpin, Wang Chihong, Jung TZYYPING, et al. EEG-based emotion recognition in music listening[J]. *IEEE Transactions on Biomedical Engineering*, 2010, 57(7): 1798-1806.

- [17] Shuman D I, Narang S K, Frossard P, et al. The emerging field of signal processing on graphs: Extending high-dimensional data analysis to networks and other irregular domains[J]. *IEEE Signal Processing Magazine*, 2013, 30(3): 83-98.
- [18] Zheng Weilong, Lu Baoliang. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks[J]. *IEEE Transactions on Autonomous Mental Development*, 2015, 7(3): 162-175.
- [19] Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering [C]. *Advances in Neural Information Processing Systems*, 2016.
- [20] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [21] Herwig U, Satrapi P, Schönfeldt-Lecuona C. Using the international 10-20 EEG system for positioning of transcranial magnetic stimulation[J]. *Brain Topography*, 2003, 16: 95-99.
- [22] 学喆, 张岳, 陈军. 无人-有人机混合主动式交互决策研究[J]. *航空科学技术*, 2022, 33(5): 44-52.
- Xue Zhe, Zhang Yue, Chen Jun. Research on active decision-making in hybrid unmanned-manned interaction[J]. *Aeronautical Science & Technology*, 2022, 33(5): 44-52. (in Chinese)

## Real-time Mental Workload Monitoring and Evaluation System Based on EEG Signals of Pilots

Li Weining, Han Zongchang, Xing Chenguang

*China Institute of Aeronautic System Engineering, Beijing 100012, China*

**Abstract:** Real-time monitoring and assessment of pilots' cognitive load status when performing air combat missions play an important role in ensuring the safety and efficiency of missions. Based on EEG signals, this paper proposes a DGCN-LSTM cognitive load assessment model. This method extracts the spatial topological features of EEG based on dynamic graph convolution networks, and fuses the temporal information of features at different locations in the time dimension through the LSTM network. Finally, the spatial and temporal features are extracted and fused to evaluate the cognitive workload status via the fully connected layers as a classifier. In order to verify the feasibility of the algorithm, the experimental paradigm simulated a variety of typical air combat missions by establishing a flight mission simulation platform, setting up mission scenarios with different complexities to stimulate pilots' different levels of cognitive load states, and collecting the subjects' EEG signals for model training and evaluation. In the sample data set collected in this article's experiment, the average accuracy of this algorithm in cognitive load classification reaches 89.08%, with 1.24M parameters of model, and its performance is better than other algorithm networks based on traditional machine learning, CNN, RNN, and GCN backbone. This work is proved to realize real-time mental workload estimation of pilots accurately.

**Key Words:** mental workload estimation; EEG signals analysis; graph neural networks; LSTM; real-time monitoring system