

基于二维特征和 CNN 分析的无人机 操控员情绪状态检测

杨宇超, 刘 聪

(空军工程大学 航空机务士官学校, 河南 信阳 464000)

摘要: 为了实时检测无人机操控员的情绪状态, 提出了一种基于二维特征和卷积神经网络 (CNN) 分析的无人机操控员情绪状态检测算法; 针对脑电信号 (EEG) 中眼电伪迹干扰的问题, 设计实现了一种基于二阶盲辨识 (SOBI) 的去除伪迹算法; 针对其它模型检测率低的问题, 通过微分熵特征 (DE) 提取、2-DMapping 映射及稀疏运算将一维脑电信号转化为包含情感信息的二维特征图, 并对脑电信号进行扩增处理, 提出二维特征图与 CNN 相结合的方式, 使得各通道的情感特征相互关联; 利用 CNN 自动学习深层次特征的优势, 深度挖掘二维特征图里的脑电情感信息, 较好地实现了无人机操控员积极、中性以及消极三种情绪状态检测。

关键词: EEG; SOBI; CNN; 二维特征; 眼电伪迹; 情绪状态检测

The Emotional Status Testing of UAV Operator Based on the Two-dimensional Feature Maps and CNN

YANG Yuchao, LIU Chong

(Aviation Maintenance NCO School, Air Force Engineering University, Xinyang 464000, China)

Abstract: In order to detect the emotional state of the UAV operator in real time, a UAV operator emotional state detection algorithm analyzed based on the Two-dimensional Feature Maps and Convolutional Neural Network (CNN). Aiming at the problem of the interference comes from ocular artifacts in electroencephalogram signals (EEG), a removal algorithm of the Second Order Blinding Identification (SOBI) is designed. For the problems of low detection rates of other models, extraction of one-dimensional brain electrical signal into a two-dimensional special symbol with emotional information through the Differential Entropy (DE) extraction, 2-D Mapping mapping and sparse computing, and the electrical signal is converted into emotional information. The amplification treatment is performed, and the method of combining the Two-dimensional Feature Maps with CNN is proposed to make the emotional characteristics of each channel interconnected. Using CNN to automatically learn the advantages of deep-level characteristics, and deeply excavate the emotional information of the Electrical Electricity in the Two-dimensional Feature Maps, it has better realized the three emotional states of the UAV operator positive, neutrality and negative emotional state.

Keywords: electroencephalogram signals; second order blinding identification; convolutional neural network; two-dimensional feature; ocular artifacts; emotion recognition

0 引言

无人机在战争中的应用越来越广泛, 其在战争中扮演的角色也越来越重要, 同时对无人机操控员的要求也越来越高。无人机操控员执行任务时, 需同时观察多个显示屏及参数, 加之操作舱噪声大、辐射强等影响, 极易导致消极情绪。研究^[1]显示, 长时间作业和实时注意大量数据, 易造成精力疲惫, 导致操作失误和事故发生的概率增加, 也使无人机操控员存在持久性的慢性疲劳和持续的睡眠不足等问题。由于情绪状态不佳操作极易诱发险情, 因此需要实时检测无人机操控员的情绪状态, 以此作为依据采取相应的措施来减少事故的发生。情绪状态就是人在受到外界影响后所发生的一种生理反应, 大致可以分为积极情绪、

消极情绪和中性情绪 3 类, 而脑电信号是大脑中的电生理活动在大脑皮质或头皮表层上的整体反映, 其蕴含丰富的生理、心理及病理信息, 能够实时反映人的情绪状态, 因此利用脑电信号对无人机操控员的情绪状态进行检测具有十分重要的意义, 能够在一定程度上降低飞行事故发生的概率。

脑电信号是一种极其微弱的信号, 总是受到各种噪声的污染, 其中由于眼动、眨眼产生的眼电伪迹对脑电信号的处理和分析影响非常之大, 因此如何去除眼电伪迹获取纯净脑电信号至关重要, 目前大部分眼电伪迹去除算法都直接或间接采用眼电记录导联信号作为参考^[2]。另外进行无人机操控员情绪状态检测, 除了需要得到较为纯净的脑

收稿日期: 2024-08-12; 修回日期: 2024-09-20。

作者简介: 杨宇超 (1995-), 男, 硕士, 助教。

引用格式: 杨宇超, 刘 聪. 基于二维特征和 CNN 分析的无人机操控员情绪状态检测[J]. 计算机测量与控制, 2024, 32(12): 96-102.

电信号外, 关键点是如何实现情绪识别。现阶段情绪识别领域, 各国研究人员都取得了丰硕成果, 有些已广泛运用于疲劳驾驶检测、飞行员心理状态检测等场景, 按照采用方法的不同可以分为基于不同信号源的情绪识别^[3]、基于不同刺激材料的情绪识别^[4-5]、基于不同特征提取算法的情绪识别^[6]以及基于不同分类算法的情绪识别^[7]等几种类型。

本文在国内外相关学者的研究基础上, 从以下两个方面进行了研究: 脑电信号的眼电伪迹去除, 分析传统算法的计算模型, 结合伪迹的特点及传统算法的不足, 提出了一种基于二阶盲辨识的盲源分离去除伪迹算法, 通过实验对比, 突出其优越性; 脑电信号的情绪检测, 对去除眼电伪迹后的脑电信号进行预处理, 利用 CNN 良好的分类效果对信号进行分类, 计算出其准确率, 与传统的情绪状态检测算法进行对比。

1 眼电伪迹去除算法分析

1.1 眼电伪迹特征

脑电信号通过放置在头皮表面的电极采集得到 (如图 1 所示), 会伴随着各种噪声干扰, 其中眼电伪迹是脑电信号噪声的主要成分。

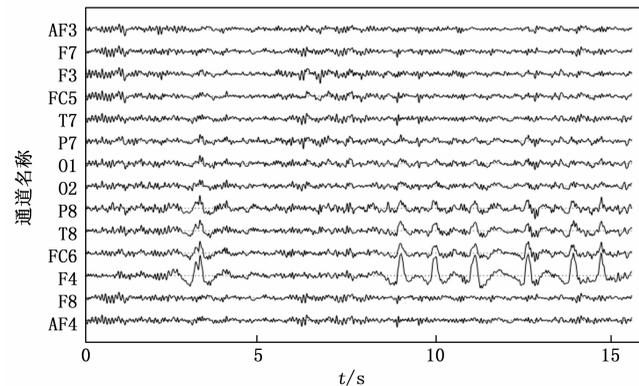


图 1 脑电信号 (14 通道)

大多数情况下眼动会是眼跳, 即眼睛迅速发生弹道式转移, 朝一个方向眼跳后会伴随另一个眼跳回到注视点, 导致眼电伪迹的产生^[8]。眼电伪迹的幅值通常是真实脑电信号的数倍, 但与脑电信号的频率范围十分接近, 给脑电信号的特征提取造成困难, 影响后续情绪状态检测的准确率, 眼电伪迹如图 2 所示。

1.2 基于二阶盲辨识去伪迹算法的设计与实现

国内外对眼电伪迹的去除进行了大量的研究, 其中比较经典的伪迹去除方法就是 ICA 分析法, 能够有效地去除脑电信号中的眼电伪迹, 但是也存在一定的不足^[9]。盲源分离 (BSS, blind source separation) 处理脑电信号的基本思想是将脑电信号和伪迹成分分解为相互独立的源信号, 含有伪迹的源信号作置零处理, 然后重构出纯净的脑电信号, SOBI 算法属于一种基于二阶统计量的 BSS 模型^[10-11]。

本文将 SOBI 算法运用到脑电信号中的眼电伪迹去除, 利用了源信号的时序结构特征, 通过计算源信号的混

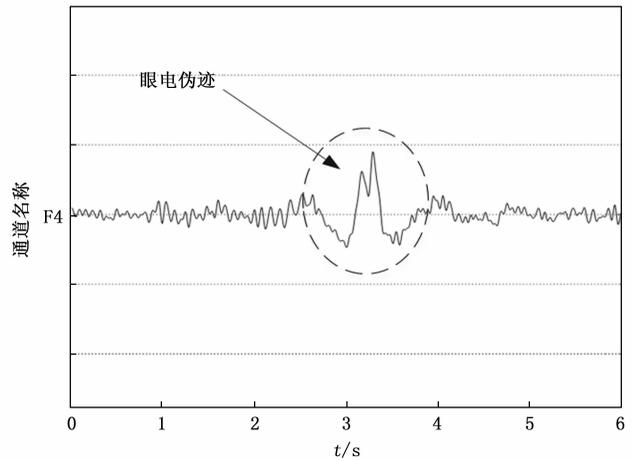


图 2 脑电信号中的眼电伪迹

合矩阵并将噪声成分置零处理来去除干扰重构信号。同时 SOBI 不需考虑多个源信号为高斯分布的情况, 不必估计源信号的概率密度函数, 相比较于 ICA 的高阶统计量, 具有复杂度低、运算速度快的优点, 有利于脑电信号在线处理及实际应用^[12]。SOBI 算法采用简单的二阶统计变量, 将其协方差矩阵联合近似对角化来达到盲源分离的目的, 能够在源信号和混合模型都未知的条件下, 从观测信号中分离出源信号的各个独立分量。根据 BSS 模型, SOBI 去除眼电伪迹算法如下:

1) 设信号 $\mathbf{X}(n) = [x_1(n), x_2(n), \dots, x_m(n)]^T$; $[m, N, ntrials] = \text{size}(\mathbf{X}(n)); n = 1, 2, \dots, N$;

2) 中心化处理 $\bar{\mathbf{X}}(n) = \mathbf{X}(n) - \frac{1}{N} \sum_{k=0}^{N-1} x(k) = \mathbf{A}\mathbf{S}(n)$;

\mathbf{A} 为未知混合矩阵;

3) 初始化向量 $\mathbf{Z}(n) = [z_1(n), z_2(n), \dots, z_m(n)]^T$;

$$E[\mathbf{Z}(n)] = 0, E[\mathbf{Z}(n)\mathbf{Z}^T(n)] = \mathbf{I}$$

4) 计算信号 $\bar{\mathbf{X}}(n)$ 的协方差矩阵 $\mathbf{R}_{\bar{\mathbf{X}}} = E[\bar{\mathbf{X}}(n)\bar{\mathbf{X}}^T(n)]$;

分解 $\mathbf{R}_{\bar{\mathbf{X}}} = \mathbf{V}\mathbf{D}\mathbf{V}^T$;

5) 计算白化矩阵 $\mathbf{P} = \mathbf{D}^{(-1/2)}\mathbf{V}^T$; $\mathbf{Z}(n) = \mathbf{P}\bar{\mathbf{X}}(n) = \mathbf{P}\mathbf{A}\mathbf{S}(n)$; 初始化矩阵 $\mathbf{U} = \text{eye}(n)$;

6) 计算时延相关矩阵个数 $p = \min(100, \text{ceil}(N/3))$, 初始化 $k = 1, pm = p * m$;

7) For $u = 1; m; pm$ {

$k = k + 1$;

协方差矩阵 $\mathbf{R}_{x_p} = \mathbf{Z}(:, k; N)\mathbf{Z}(:, 1; N - k + 1)^T / ((N - k + 1) * ntrials)$;

$$\mathbf{M}(:, u; u + m - 1) = \text{norm}(\mathbf{R}_{x_p}) * \mathbf{R}_{x_p}; \}$$

end For

8) For $p = 1; m - 1$ {

For $q = p + 1; m$ { // 向量 \mathbf{g} 的初始化与矩阵 \mathbf{M} 有关初始化向量 \mathbf{g} ;

$$[\mathbf{U}c_p, \mathbf{D}] = \text{eig}(\text{real}(\mathbf{g} * \mathbf{g}^T)); [\mathbf{la}, \mathbf{K}] = \text{sort}(\text{dig}(\mathbf{D}));$$

$$\text{angles} = \text{sign}(\mathbf{U}c_p(:, \mathbf{K}(3))) * \mathbf{U}c_p(:, \mathbf{K}(3)); c =$$

```

sqrt( $\frac{0.5 + \text{angles}(1)}{2}$ );
sr = 0.5 * (angles(2))/c; sc = conj(sr);
计算出  $U(:,p) = c * U(:,p) + sr * U(:,q)$ ;
计算出  $U(:,q) = c * U(:,q) - sc * U(:,p)$ ; }
end For }
end For
9) 计算出混合矩阵  $A = P^+ U$ ;

```

SOBI 算法的关键一步是计算出混合矩阵 A , 从而得到分离矩阵 $W = U^T P$, 分解出脑电信号的独立分量 $IC_s(n) = [ics_1(n), ics_2(n), \dots, ics_c(n)]^T, (c = 1, 2, \dots, L), c$ 为独立分量序号。依据独立分量 $IC_s(n)$ 的特性, 将相应的伪迹信号 $ics_a(n)$ 进行置零处理, 得到去伪迹后的脑电信号独立分量 $IC_r(n)$ 。

2 情绪状态检测模型设计与实现

为实现无人机操控员情绪状态检测, 本文搭建了基于脑电信号的情绪状态检测模型, 从最开始信号采集到最终特征提取后输入到卷积神经网络中实现情绪分类, 得到相对应的检测精度, 整个模型框架如 3 所示。

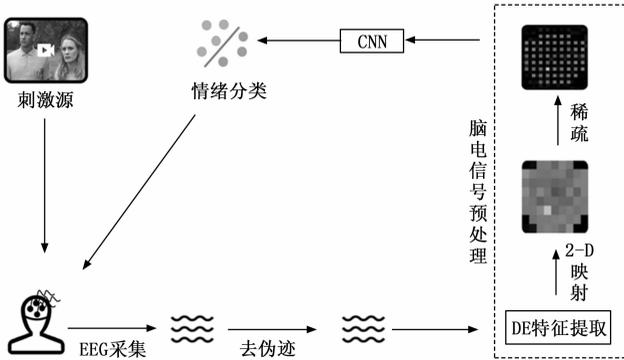


图 3 情绪状态检测模型框架

2.1 脑电信号预处理

由于情感是由大脑各脑区协同工作产生的并且原始脑电信号不满足卷积神经网络的输入要求, 需要对脑电信号进行预处理, 使其在保持各通道相对位置, 增强通道相关度的同时, 不丢失一维脑电信号所具有的情感信息。预处理分为三部分: DE 特征提取、2-D Mapping 映射和稀疏运算。

2.1.1 微分熵特征 (DE, differential entropy) 提取的实现

脑电信号极其微弱, 具有不确定性且很难直接看出所包含的情绪信息, 需要进行特征提取。所谓熵, 信息论中表示信息不确定性的量度, 可以运用到脑电信号的特征提取中, 用来提取信号中所蕴含的相关信息^[13]。DE 与香农熵 (Shannon Entropy) 密切相关, 当时间序列 X 是连续的, 香农熵就被称为微分熵^[14]。假如 X 概率密度函数已知, 通过 DE 提取可以计算出 X 的复杂度:

$$g(x) = - \int_X \lg(h(x)) \cdot h(x) dx \quad (1)$$

其中: $h(x)$ 是 X 的概率密度函数。

将时间序列分割成较小的时间段, 并且在每个时间段内, 脑电活动被认为是静止的, 这个过程被称为短时傅立叶变换 (STFT)。STFT 将时间的函数 (在本文中为脑电信号) 分解为以固定的时间间隔构成的频率。STFT 的计算公式如下:

$$S(\tau, \omega) = \int_{-\infty}^{\infty} s(t) e^{-j\omega t} \cdot \omega(t - \tau) dt \quad (2)$$

其中: $s(t)$ 是原始信号, 而 $\omega(t)$ 是窗口函数。汉宁窗口 (式 (3) 中是一个离散版本) 是调制矩形窗口的线性组合, 通常运用在低混叠和较少频谱泄漏的应用中。

$$\omega(m) = \frac{1 - \cos\left(\frac{2\pi m}{M-1}\right)}{2} \quad (3)$$

其中: m 是窗口长度, M 是采样数。DE 被称为香农熵的扩展^[14]。

$$g(x) = - \sum_{j=1}^M \lg[p(s_j)] \cdot p(s_j) \quad (4)$$

DE 是香农熵的连续版本, 原始的计算公式可以写为:

$$g(x) = - \int \lg[h(x)] \cdot h(x) dx \quad (5)$$

DE 特征提取是对离散随机变量的复杂度的简单但有效的评估, 提供了一个很好的选择来表征脑电信号时间序列, 之前的研究表明 DE 优于功率谱密度 (PSD)^[15]。根据文章^[15], 对于固定长度的脑电信号, DE 等于特定频带中 PSD 的对数。如果随机变量服从高斯分布 $N(\mu, \sigma^2)$, 则可以通过以下公式简单地计算式 (5) 中的 DE 特征:

$$g(x) = - \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(\frac{(x-\mu)^2}{2\sigma^2}\right) \lg \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(\frac{(x-\mu)^2}{2\sigma^2}\right) dx = \frac{1}{2} \lg(2\pi e \sigma^2) \quad (6)$$

其中: e 是欧拉常数, σ 是时间序列的标准偏差, 脑电信号的 DE 特征通过其偏差来评估。

feature_extraction=

4.9499	4.7114	5.7395	4.9050	5.5122	3.1993	4.1665
5.6195	5.5877	5.7701	5.3973	6.1351	5.5373	5.4677

图 4 脑电信号 (14 个通道) 微分熵特征值

2.1.2 2-D Mapping 映射的实现

原始的脑电信号不满足卷积神经网络的输入要求, 不能直接作为输入信号, 为适应输入特点需要将一维脑电信号转化为二维图像信号。为了保存每个电极中包含的脑电信息, 以 1 秒的时间间隔将从 14 个通道提取的 DE 特征组织为二维矩阵。本文以最简单的方式组织二维矩阵信号, 并且位置关系非常直观, 以这种方式结合 DE 特征提取生成的二维矩阵并加以处理馈送至 CNN。2-D Mapping 映射的具体步骤如下:

1) 建立坐标系; O1 和 O2 所在的直线为 x 轴, T7 所在的直线为 y 轴, 如图 5 (a) 所示, 确定各电极在坐标系

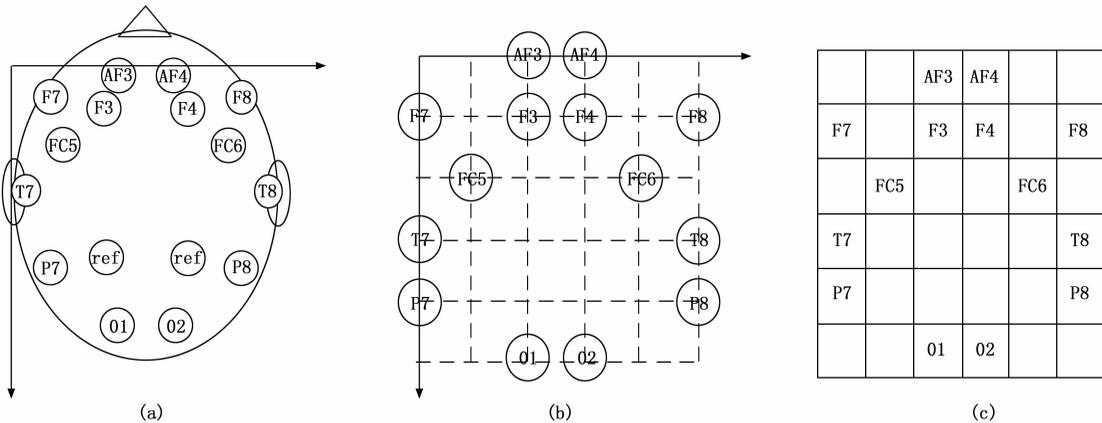


图 5 2-D Mapping 映射

中的位置。

2) 确定各通道的相对位置关系, 增强通道相关度; 微调各通道坐标, 使 F7、T7、P7; AF3、F3、O1; AF4、F4、O2; F8、T8、P8; F7、F3、F4、F8 在一条线上, 如图 5 (b) 所示。

3) 将图 5 (b) 转化为一个二维矩阵, 如图 5 (c) 所示。

通过这种方法, 电极的空间关系被考虑在内, 每个通道的信号经过 DE 特征提取后, 根据二维矩阵上电极位置, 与其一一对应, 就转化为 CNN 输入需要的信号。经过上述映射处理, 14 通道的脑电信号转化为一个 6×6 二维矩阵信号。

2.1.3 稀疏运算的实现

虽然通过 DE 特征提取和 2-D Mapping 映射将脑电信号转化为二维矩阵, 但存在两个问题: (1) 对于 14 电极放置, 二维信号尺寸太小为 6×6, 很难训练具有多层网络的 CNN。(2) 在 6×6 二维信号中, 每个电极的特征值被其相邻电极的值紧密围绕, 特征太过于集中, 紧随其后的卷积和池化操作容易造成信息泄露。因此引入稀疏运算来进行稀疏 DE 映射: 全零行和列添加在备用行和列上, 全零帧也被添加到图的四个边缘上, 以保存隐藏在外围电极中的脑电信号特征。插值处理后的二维信号更加适合 CNN, 并且信息泄露在很大程度上减少。

对于 6×6 的矩阵如图 6 (a) 所示, 分别按照行和列, 每隔一行插入两行全 0 行, 每隔一列插入两列全 0 列, 随后把边缘扩展到 20×20, 遇见奇数无法扩展成偶数的情况, 可以在边缘多插入一行或者一列, 上下左右都可以, 只要保持所有的数据一致即可, 数据是否在图片中央不影响结果, CNN 会自动去适应。因此经过稀疏运算之后, 一个 6×6 的矩阵就被稀疏成一个 20×20 的二维矩阵, 然后转化为灰度图, 如图 6 (b) 所示, 该二维特征图的尺寸足以训练小规模 CNN, 并且能有效减少信息泄露。

在进行 CNN 训练之前, 由于样本数不足, 需要对脑电信号样本进行扩增处理, 常见的扩增方式有平移、缩放等。本文采用旋转的方式来增加样本, 通过旋转 180°, 旋转后的通道位置分布如图 7 (a) 所示, 然后对其进行稀疏运算处

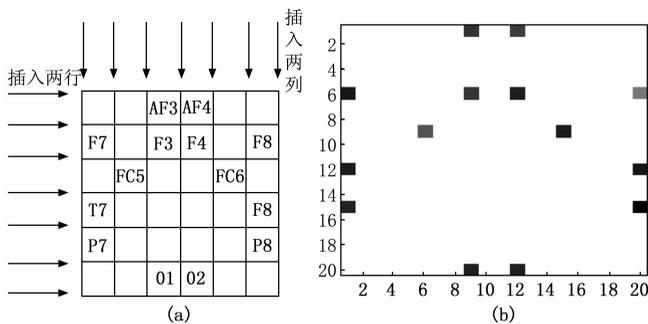


图 6 稀疏运算的实现

理, 生成相应的灰度图, 如图 7 (b) 所示。经过扩增处理后, 样本数量增加为原来的两倍, 每种情绪数据有 1 200 张灰度图, 3 种情绪状态共计 3 600 张灰度图。

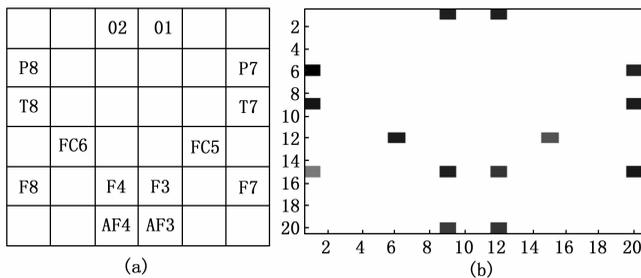


图 7 扩增处理后的矩阵和灰度图

2.2 基于 CNN 的情绪状态检测模型

传统情绪状态检测算法都是对单通道脑电信号进行特征提取, 然后通过分类器进行分类, 但是这样存在一个问题: 不能很好地把多通道的特征关联起来, 造成情绪检测的精度不是很高。本文设计了一种基于 CNN 的情绪状态检测模型, 能从图像处理局部特征角度来检测不同的情绪状态, 具体网络结构见图 8。整个 CNN 网络由 2 个 2D 卷积层, 2 个池化层, 一个全连接层组成, 相关参数如表 1 所示。卷积层包含多个特征图, 特征图被卷积核卷积, 然后通过一个激活函数来进行输入输出映射, 卷积操作后的矩阵尺寸计算公式如下:

$$O_w = (I_w - F_w + 1) / S_l \quad (7)$$

$$O_h = (I_h - F_h + 1) / S_l \quad (8)$$

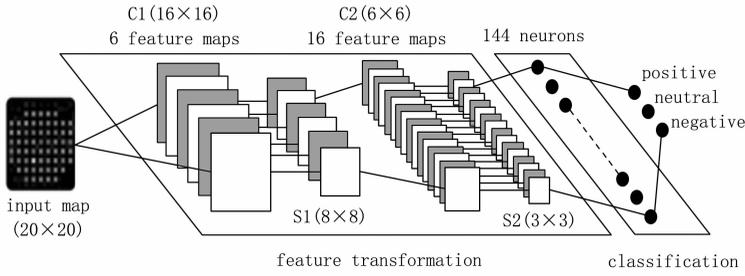


图 8 CNN 情绪状态检测示意图

其中： O_w 和 O_h 表示输出矩阵的宽度和高度， I_w 和 I_h 表示输入矩阵的宽度和高度， F_w 和 F_h 表示卷积核的宽度和高度， S_i 为步长。池化层是一个降采样过程，紧跟在卷积层之后，目的是减弱卷积层出现的信息冗余，本文采用最大值池化^[16]。

表 1 情绪状态检测模型中 CNN 参数

类型	输入尺寸	卷积数目	卷积步幅	卷积尺寸	输出尺寸
Input	20×20	—	—	—	20×20
2-D Conv	20×20	6	1	5×5	16×16
Max Pooling	16×16	—	2	2×2	8×8
2-D Conv	8×8	16	1	3×3	6×6
Max Pooling	6×6	—	2	2×2	3×3
FC	3×3	—	—	—	144×1
SOFTMAX	144×1	—	—	—	3×1

情绪状态检测模型中，输入得二维图像信号尺度为 20×20。C1 为卷积层：内核大小为 5，步长为 1，卷积数目为 6，经过第一次 2-D Conv 后输出尺度为 16×16。S1 是最大池化层，并且尺寸大小为 2，步长为 2，经过 Max Pooling 操作后获得 6 张大小为 8×8 特征图。C2 代表第二卷积层：内核大小为 3，步长为 1。C2 的输入是 S1 中的 6 个特征图，此时指定了 16 个过滤器，所以特征图编号扩展到 16。因此，通过第二次 2-D Conv 操作后，16 张 6×6 特征图在 C2 中形成。S2 则是另一个最大池化层，并且尺寸大小是 2，步长也是 2，经过第二次 Max Pooling 操作后在 S2 中获得了 16 张 3×3 的特征图。然后根据它们的空间位置将 S2 中所有图像拉伸并连接以生成 144-D 向量，向量完全连接到 3 个输出节点，每个节点对应于一种情绪状态，以实现情绪分类。数据集中 75% 的数据用于 CNN 的参数训练，剩余的 25% 用于测试，设置学习速率为 0.001，迭代次数为 50 个 n_epoch。

整个模型中需要选取合适的激活函数，激活函数的作用是通过加入非线性因素，将输入和输出进行非线性映射。激活的加入提高了模型的鲁棒性，缓解了梯度消失问题，常用的有 sigmoid 函数、relu 函数和 tanh 函数：

$$\text{sigmoid 函数: } h(x) = \frac{1}{1 + e^{-x}} \quad (9)$$

$$\text{relu 函数: } h(x) = \max(0, x) \quad (10)$$

$$\text{tanh 函数: } h(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (11)$$

每个激活函数都考虑输入输出以及数据变化，选取合适的激活函数有利于提高分类准确率。图 9 为不同激活函数下的准确率，由图可得 tanh 函数的检测准确率 87.21%，总体呈上升趋势；relu 函数前 20 次迭代和 tanh 函数大致相同；sigmoid 函数和 relu 函数的检测准确率分别为 79.01%、84.03%；tanh 函数的准确率明显高于其他两种函数，所以选取 tanh 函数作为网络激活函数。

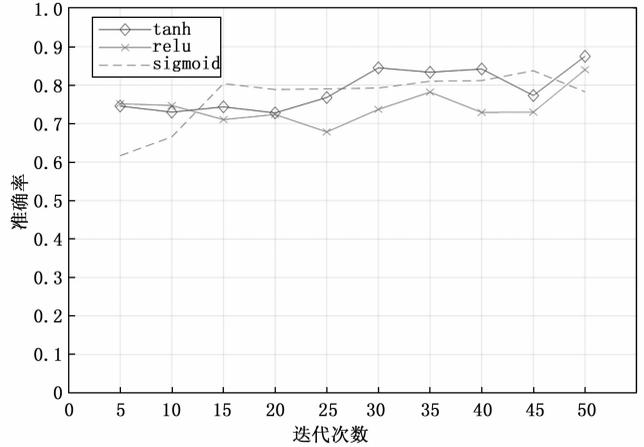


图 9 不同激活函数下准确率对比

3 实验结果与分析

为了采集不同情绪状态下产生的脑电信号，建立情感数据库，本文采用视听诱发的方式，通过观看富含情感色彩的视频，刺激实验者产生积极、中性、消极 3 种不同情绪。采集的脑电信号分为 AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 共 14 个通道，14 个通道分别对应大脑皮层的 14 个位置。共计采集了 600 人次的脑电数据，对信号进行抽样处理，每种情绪数据保存为一张 Excel 表格，3 种情绪各产生 600 张数据表格，共 1 800 张表格。

3.1 去伪迹算法实验结果与分析

为了更加直观的对比伪迹去除效果，有处理时间、信噪比和相关系数 3 种常用的伪迹去除评价准则^[17]。对一段含有眼电伪迹的脑电信号进行伪迹去除，从处理时间、信噪比以及相关系数 3 方面对经典伪迹去除算法 (ICA) 和本文运用的基于二阶统计量的 SOBI 算法进行对比分析。

3.1.1 处理时间

在程序运行时间方面，相比较于 ICA，SOBI 去伪迹的单个样本处理时间分别缩短了 356.216、120.548、93.571、

表 2 不同算法程序运行时间

实验者编号	ICA-Time/s	SOBI-Times/s
1	2.116 961	1.760 745
2	1.883 021	1.762 473
3	2.005 276	1.911 705
4	2.396 221	2.070 349
5	2.078 491	1.793 703
6	1.987 605	1.753 932

325.872、284.788、233.673 ms, ICA 的平均运行时间为 2.078 s, SOBI 的平均运行时间为 1.842 s, SOBI 的运行时间相比较于 ICA 提高了 11.35%, 同样的时间采用 SOBI 算法能处理更多的数据。

3.1.2 信噪比 (SNR)

信噪比与伪迹去除干净效果成正比, 信噪比的值越大, 伪迹去除效果越好, 计算公式为:

$$SNR = 10 \log_{10} \left[\frac{\sum_{i=1}^N s_i^2(t)}{\sum_{i=1}^N [x_i(t) - s_i(t)]^2} \right] \quad (12)$$

其中: V_{ij} 为输出信号, V_{ij} 为源信号。

表 3 为不同算法下各通道信噪比对比, 分析表中数据, 对于通道 AF3、F7、F3、FC5、T7、O1、T8、FC6、F4、F8 和 AF4, SOBI 算法的信噪比要高于 ICA 算法, 14 个通道的平均信噪比达到了 11.58, 相比较于 ICA 算法的平均信噪比 4.92, 要高出 2.4 倍。信噪比越大, 去噪声的效果就越好。由此可见, 采用本文提出的 SOBI 算法处理的脑电信号, 眼电伪迹去除得更干净, 效果要优于传统的 ICA 算法。

表 3 不同算法信噪比(SNR)对比

通道名称	ICA	SOBI
AF3	3.93	15.49*
F7	0.11	13.20*
F3	6.18	17.95*
FC5	4.33	18.60*
T7	4.40	19.93*
P7	6.97*	6.43
O1	7.17	8.26*
O2	7.03*	5.70
P8	1.80*	0.29
T8	3.58	3.70*
FC6	3.63	4.46*
F4	14.85	15.07*
F8	0.16	13.36*
AF4	4.48	19.68*

3.1.3 相关系数 (V_{ij})

相关系数介于 0 与 1 之间, 来表示去伪迹后脑电信号的损失程度。相关系数能直观表明变量 x_i 和 s_i 之间的相关程度, 相关系数越大代表两者关系性越强, 去伪迹后信号损失越小, 计算公式为:

$$V_{ij} = V(x_i, s_i) = \frac{|\sum_{i=1}^N s_i(t) \cdot x_i(t)|}{\sqrt{\sum_{i=1}^N x_i^2(t) \cdot \sum_{i=1}^N s_i^2(t)}} \quad (13)$$

表 4 为不同算法下各通道相关系数对比, 分析表中数据, 对于通道 AF3、F7、F3、FC5、T7、O1、O2、T8、FC6、F4、F8 及 AF4, SOBI 算法的相关系数大于 ICA 算法, 14 个通道的平均相关系数为 0.843 7, 相比较于 ICA 算法的平均相关系数 0.758 0, 提高了约 11.3%。相关系数越高, 去伪迹后的脑电信号与源信号的相关度越高, 信号的

损坏程度就越小。由此可见, 采用本文的 SOBI 算法去除眼电伪迹, 重构后的脑电信号损失度更小, 更加接近源信号, 性能要优于 ICA 算法。

表 4 不同算法相关系数(V_{ij})对比

通道	ICA	SOBI
AF3	0.832 9	0.986 0*
F7	0.718 9	0.976 9*
F3	0.894 8	0.992 1*
FC5	0.857 5	0.993 3*
T7	0.860 8	0.995 0*
P7	0.913 4*	0.904 7
O1	0.921 0	0.937 5*
O2	0.896 9	0.917 7*
P8	0.793 9*	0.740 9
T8	0.584 9	0.590 5*
FC6	0.538 0	0.572 0*
F4	0.218 6	0.233 6*
F8	0.718 9	0.976 9*
AF4	0.860 8	0.995 0*

为进一步阐述本文提出的算法的有效性, 表 5 给出了不同方法去除眼电伪迹的运行时间、平均信噪比以及平均相关系数三项指标结果。通过综合评价小波变换法(WT)^[18]、ICA 算法和 SOBI 算法去除眼电伪迹效率的彻底程度, 源信号损失程度, 算法运行效率, 突出本文提出算法(SOBI)的良好性能。表中数据表示的是所有脑电通道的 3 个评价指标的平均值, 由表可知, 本文的 SOBI 算法运行时间最短, 平均信噪比和平均相关系数最高, 表明其能在相同的时间内处理更多的脑电信号, 并且去除伪迹的效果较好, 信号的损坏程度更低, 是一种性能较好的伪迹去除方法。

表 5 不同方法对应的运行时间、平均信噪比、平均相关系数

不同方法	运行时间/s	平均信噪比	平均相关系数
WT ^[18]	1.926	4.35	0.713 4
ICA	2.078	4.92	0.758 0
SOBI	1.842	11.58	0.843 7

3.2 情绪状态检测实验结果与分析

为了验证本章中提出的基于 CNN 情绪状态模型的优越性, 将检测准确率作为性能评价指标与近几年其他算法相比较。本文算法(CNN)与 SVM^[19]、KNN^[19]进行比较, 可以突出深层模型处理复杂数据的优点, 与 SAE^[20](使用 DEAP 数据库)的性能比较说明了保留拓扑二维特征组织的好处, 图 4 中数据表示的是 3 次实验的平均情绪检测准确率, 可以看出本文的采用的算法取得了良好的情绪检测效果, 由此可见本文基于 CNN 的情绪检测模型能够充分提取脑电信号中的情绪信息, 获得更好的检测效果, 提高准确率。

由图 10 可知, 本章提出的利用 CNN 实现情绪检测的准确率均高于 SAE、SVM 和 KNN, 表现出良好的情绪检测效

果,分析原因如下:1)引入了DE特征提取、2-D Mapping映射和稀疏运算,分类时保留了二维特征组织,而SAE一维深层分类模型则没有保留。二维特征图包含用于情绪检测的局部空间信息,通过维持相邻电极之间的空间位置关系来加强各通道间特征相关度,与大脑各脑区协同工作的机制类似,是一种较理想的脑电情绪信息处理方式。因此将CNN和二维特征组织结合起来效果更好;2)引入卷积神经网络,相比其他浅层分类模型(例如SVM、KNN模型),通过设计卷积层、池化层、连接层以及激活函数并加以训练来对特征多尺度学习,提高了分类准确率。

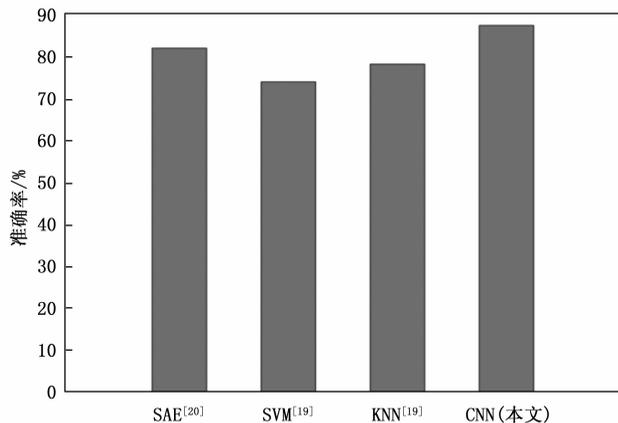


图 10 不同算法情绪状态检测准确率对比

4 结束语

本文提出一种基于脑电信号的无人机操控员情绪状态检测算法,重点研究了眼电伪迹去除算法和基于脑电信号的情绪检测模型,并通过理论与实验验证了算法的可行性与优势。针对脑电信号微弱易受到眼电伪迹干扰的问题,结合脑电信号自身的特点以及传统去伪迹法所存在的问题,将SOBI算法运用到去伪迹中。针对情绪状态检测问题,本文创新性地将一维脑电信号组织为二维特征图,并结合CNN来实现无人操控员的情绪状态检测。

参考文献:

- [1] 王晓旭,王新攀,王开辉.对飞行员健康管理的思考[J].中国保健营养,2017,27(31):386.
- [2] AMERI SK, KIM M, KUANG I A, et al. Imperceptible electrooculography graphene sensor system for human-robot interface[J]. Npj 2D Materials and Application, 2018, 2(10): 34-42.
- [3] PICARD R W, HEALEY J. Affective wearables[J]. Personal Technologies, 1997, 1(4): 231-240.
- [4] PATIL A, DESHMUKH C, PANT A R. Feature extraction of EEG for emotion recognition using Hjorth features and higher order crossings[C]//Advances in Signal Processing (CASP), Conference on IEEE, 2016: 429-434.
- [5] NIE D, WANG X W, SHI L C, et al. EEG-based emotion recognition during watching movies[C]//International IEE/EM-

- BS Conference on Neural Engineering. IEEE, 2011: 667-670.
- [6] LI M, LU B L. Emotion classification based on gamma-band EEG[C]//Engineering in Medicine and Biology Society, 2009. EMBC 2009. Annual International Conference of the IEEE, 2009: 1223-1226.
- [7] THAMMASAN N, FUKUI K, NUMAO M. Application of deep belief networks in EEG-Based dynamic music-emotion recognition[C]//2016 International Joint Conference on Neural Networks (IJCNN), IEEE, 2016: 881-888.
- [8] DAUBECHIES I. The wavelet transform, time-frequency localization and signal analysis[J]. IEEE Transactions on Information Theory, 1999, 36(5): 961-1005.
- [9] GROSSE W M, HARMEILING S, ZANDER T, et al. How to test the quality of reconstructed sources in independent component analysis (ICA) of EEG/MEG data[C]//2013 International Workshop on Pattern Recognition in Neuroimaging (PRNI), IEEE, 2013: 102-105.
- [10] 王 魁,叶 闯,沈益青.脑电信号中眼电伪迹的自动去除算法[J].计算机工程,2011,23(37):256-260.
- [11] 高建彬.盲源分离算法及相关理论研究[D].成都:电子科技大学,2008.
- [12] 章云元,杨帮华,李华荣,等.脑机接口中基于SOBI的EEG预处理[J].北京生物医学工程,2016,35(1):26-30.
- [13] 石立臣.基于脑电信号的警觉度估计研究[D].上海:上海交通大学,2012.
- [14] DUAN R N, ZHU J Y, LU B L. Differential entropy feature for EEG-based emotion classification[C]//2013 6th International IEEE/EMBS Conference on Neural Engineering (NER), IEEE, 2013: 81-84.
- [15] ZHENG W L, BAO L L. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks[J]. IEEE Trans Auton. Ment. Dev., 2015, 7(3): 162-175.
- [16] ZUBAIR S, YAN F, WANG W. Dictionary learning based sparse coefficients for audio classification with max and average pooling[J]. Digital Signal Processing, 2013, 23(3): 960-970.
- [17] LIO G, BOULINGUEZ P. Greater robustness of second order statistics than higher order statistics algorithms to distortions of the mixing matrix in blind source separation of human EEG: Implications for single-subject and group analyses[J]. Neuro Image, 2013, 67: 137-152.
- [18] NUNEZ P L, SRINIVASAN R, WESTDORP A F, et al. EEG coherency: I; statistics, reference electrode, volume conduction, Laplacians, cortical imaging, and interpretation at multiple scales[J]. Electroencephalography and Clinical Neurophysiology, 2015, 103(5): 499-515.
- [19] LI J P, ZHANG Z X, HE H G. Hierarchical convolutional neural networks for EEG-based emotion recognition[J]. Cognitive Computation, 2018, 12(10): 368-380.
- [20] XING X F, LI Z Q, XU T Y, et al. SAE plus LSTM: a new framework for emotion recognition from multi-channel EEG[J]. Frontiers in Neuroinformatics, 2019, 13: 75-89.