

基于 Gamma 深度信念网络的飞行员 脑疲劳状态识别

罗映雪¹, 贾 博², 裘旭益³, 邓平煜³, 任 和⁴, 吴 奇^{1,3}

(1. 上海交通大学电子信息与电气工程学院自动化系, 上海 200240; 2. 中国东方航空技术应用研发有限公司, 上海 201700;
3. 中国航空无线电电子研究所, 上海 200233; 4. 中国商飞上海飞机客户服务有限公司, 上海 200241)

摘 要: 飞行员疲劳状态识别面临两个重要问题, 如何提取表征疲劳的特征以及如何对疲劳特征建模学习. 首先提取脑电节律波, 计算基于仿射伪平滑 Wigner-Ville 分布的瞬时频域信息, 构建疲劳状态指标. 其次, 基于脑电节律波各通道的周期性变化提出 Gamma 深度信念网络的疲劳状态分类算法, 与采用卷积与池化运算的学习网络不同, Gamma 深度信念网络没有将图像或信号按尺度分割, 但在底部的隐藏层已经可以有效地学习特定区域的特征, 且当层数增加时, 可有效提取特征的区域增多, 学习到的特征更为一般化. 然后改进用于训练深度信念网络的 Gibbs 采样算法, 提出向上向下 Gibbs 采样以推断网络参数. 最后, 实验结果显示, 本文的 Gamma 深度信念网络在识别准确率、稳定性、迭代用时等方面均达到了令人满意的效果.

关键词: 脑电信号; 飞行员疲劳; 疲劳识别; Gamma 深度信念网络

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2020)06-1062-09

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

DOI: 10.3969/j.issn.0372-2112.2020.06.003

Pilots' Brain Fatigue State Inference Based on Gamma Deep Belief Network

LUO Ying-xue¹, JIA Bo², QIU Xu-yi³, DENG Ping-yu³, REN He⁴, WU Qi^{1,3}

(1. Department of Automation, School of Electronic Information and Electrical Engineering, Shanghai Jiaotong University, Shanghai 200240, China;
2. China Eastern Airlines Technology Application R&D Center Co., Ltd., Shanghai, Shanghai 201700, China;
3. China National Aeronautical Radio Electronics Research Institute, Shanghai 200233, China;
4. COMAC Shanghai Aircraft Customer Service Co., Ltd., Shanghai 200241, China)

Abstract: Pilots' fatigue state recognition faces two important issues: how to extract the characteristics that characterize fatigue and how to model fatigue characteristics. Firstly, the EEG (Electroencephalogram) signal is extracted, and the instantaneous frequency domain information based on the affine pseudo-smooth Wigner-Ville distribution is calculated to construct the fatigue state index. Secondly, based on the periodic changes of each channel of EEG signals, the fatigue state classification algorithm of Gamma deep belief network is proposed. Unlike other learning network using convolution and pooling, the proposed network does not split the image or signal, but the hidden layer at the bottom can effectively learn the features of a specific region, and when the number of layers increases, the number of features increases and the features are more general. The Gibbs sampling algorithm for training the deep belief network is improved. The up-down Gibbs sampling is proposed to infer the network parameters. Finally, the experimental results show that the Gamma deep belief network in this paper has achieved satisfactory results in terms of recognition accuracy, stability and iteration time.

Key words: EEG signals; pilots' fatigue; fatigue recognition; Gamma deep belief network

1 引言

大脑长期维持高注意力状态进行认知行为将导致脑疲劳的发生, 脑疲劳常伴随着决策力、注意力及反应速度的

下降^[1]. 飞行过程中, 睡眠不足, 飞行时间长、天气恶劣等因素都可能引起飞行员脑疲劳, 进而产生误操作或误判断, 是飞行过程的潜在隐患. 因此, 由客观准确的手段监测飞行员疲劳状态, 及时预警, 对确保飞行安全有重大意义.

脑状态可分为清醒与疲劳两类,当处于疲劳状态时,疲劳将随着时间推移逐渐加深.目前疲劳程度评估可通过主动或被动方式进行.主动评估方式通过被试者的主观感受推断工作负荷或脑疲劳状态,包括 NASA 的任务负荷指数(Task Load Index, TLX)^[2], Karolinska 困倦程度度量表(Karolinska Sleepiness Scale, KSS)^[3]等.被动评估方式通过驾驶员的动作^[4]如长时间闭眼、打哈欠或生物信号如血压、心电图,给出对疲劳状态的评估.

主观评估方式依赖于个人主观反馈,且可能分散驾驶员注意力,对问卷的验证评估需要时间,存在滞后性.被动评估方式中,记录驾驶员动作或面部表情可能存在隐私问题.脑机交互(Brain-Computer Interfaces, BCIs)作为一种被动评估方法,已被证实可有效估计脑认知状态^[5].基于脑动力学的评估方法包括计算机断层成像(Computer Tomography, CT)、脑电图(Electro Encephalography, EEG)、核磁共振成像(Magnetic Resonance Imaging, MRI)等.与其他数据提取方法相比,EEG 的显著优势是可进行实时测量,且大脑的活动变化已被证实与疲劳状态相关^[6,7],如 Azarnoosh 等人发现基于大脑中心和枕叶部分的动力学,可以根据模拟实验中的响应时间(Response Time, RT)识别注意力和疲劳之间的差异^[8],Saroj 等通过分析发现,EEG 中 α 节律功率的大小是困倦发生的重要特征之一^[9].因此 EEG 被认为是一种可靠的疲劳检测方法,在疲劳检测领域得到了广泛应用.因此本文将基于 EEG 信号的变化对飞行员疲劳状态进行评估.

脑电信号分析方法可分为两类:(1)基于定量指标的经验分析;(2)基于深度网络的分析.

基于定量指标的经验分析方法通过已被证实的脑电信号变化趋势推度疲劳程度.如 Christos 等通过分析驾驶员的 EEG 信号的 Shannon 熵和 KL 熵的相对频带比(Relative Band Ratio, RBR),发现驾驶事故发生前 α 节律的 RBR 显著增加,KL 熵显著下降^[10],Jap 等通过脑电信号中 $\delta, \theta, \alpha, \beta$ 节律的变化趋势评估疲劳状态,并指出随着时间推移, δ 波与 θ 波活动较稳定, α 轻微衰减, β 明显衰减^[11].

基于经验的分析方法依赖于已有的研究成果,由于脑电信号的复杂多变性,可能存在特征丢失或不匹配的情况.基于深度学习网络的分析方法可以较好解决上述问题,因此已被广泛应用于 EEG 信号的处理分析.如 Cai 等通过深度信念网络(Deep Belief Network, DBN)分析 EEG 信号进行抑郁症检测,并与 K 近邻(K-Nearest Neighbor, KNN)、人工神经网络进行对比,结果显示使用 DBN 的识别精度可达到 78.24%^[12],J. X. Chen 等人提出基于深度卷积神经网络(Deep convolution neural network, DCNN)的脑电情感学习模型,有效提高了脑

电情感识别的准确性和稳定性^[13].

目前针对脑电信号的分析集中在情感动作识别^[14]、驾驶员疲劳识别、疾病诊断等方面,飞行员的脑疲劳识别领域研究较少,而飞行员疲劳检测是确保飞行安全中不可或缺的一环.此外,目前脑电信号分析方法以人工经验评估或仅基于深度网络进行训练预测为主,因此本文提出一种融合定量指标与深度学习网络的学习算法,为飞行员疲劳检测提供可靠的解决方案.

首先,基于已有研究中脑电节律波的变化与大脑活动的相关性,采用仿射伪平滑 Wigner-Ville 分布(Affine Smoothed Pseudo Wigner-Ville Distribution, ASPWVD)代替快速傅里叶变换(Fast Fourier Transformation, FFT)计算频谱,给出信号点的实时频谱信息,然后构造疲劳指标 $\theta/\beta, \alpha/\beta, (\alpha + \theta)/\beta, (\theta + \delta)/(\alpha + \beta)$ 和 $(\alpha + \theta)/(\alpha + \beta)$. Sigmoid 信念网络(Sigmoid Belief Network, SBN)通过 Sigmoid 函数连接相邻层的二进制单元,推断多变量二维向量的深层表示^[15]. DBN 是将 SBN 的顶部隐含层替换为无向的受限玻尔兹曼机得到的深度网络,使用 RBM 连接相邻层的二进制单元,模拟二进制观测^[16],其优势在于可通过逐层训练有效学习深层次概率模型,并借助判别微调算法优化分类性能,在多种分类情景下均能给出较好的结果.本文在 DBN 的基础上,引入 Gamma 分布建模隐藏单元,使网络能够通过二进制单元连接不同层,无偏差推断特征向量的多层表示,捕获所有层中可见与隐藏特征之间的相关性.与 DBN 需要利用二进制单元进行推理并需要调整每层的宽度(隐藏单元数)和网络深度(层数)的深层网络不同,本文的模型通过 Gibbs 采样,向上采样 Dirichlet 分布式连接权重,向下采样服从 Gamma 分布的隐藏单元,从而联合训练所有隐含层,可以在给定的第一层宽度下以贪婪的分层方式学习每个隐含层的宽度.

2 基于 ASPWVD 的疲劳指标

基于已有研究^[9-11], EEG 信号中 $\delta, \theta, \alpha, \beta$ 节律波会随疲劳状态的改变而出现增大或减小的趋势,对应的能量与熵也会出现相应变化.因此,EEG 节律波作为大脑活动变化的直接反映,可作为脑疲劳评估的切入点, $\delta, \theta, \alpha, \beta$ 节律对应频率段及特点如表 1 所示.

表 1 EEG 节律对应频率与特点

节律	频率	特点
δ	0 ~ 4Hz	又称睡眠波,常见于睡眠状态;
θ	4 ~ 8Hz	与中枢神经系统的抑制状态有关,常见于疲倦期;
α	8 ~ 13Hz	常见于闭眼状态,受刺激后消失;
β	13 ~ 30Hz	常作为 α 的附加节律出现,受刺激状态下,将转换为 β 节律.

为将节律波转换为更显著的特征,利用改进的基于 Kaiser 窗的 Wigner-Ville 分布计算节律波瞬时频谱信息. 该算法通过加入滑动指数窗使原分布仿射平滑化,以抑制 Wigner-Ville 分布中的交叉项干扰,可记作仿射伪平滑 Wigner-Ville 分布.

对给定信号 $s(t)$, 时频分布可表示为:

$$w(t, \omega) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \phi(\theta, \tau) s(u + \frac{\tau}{2}) \cdot s^*(u + \frac{\tau}{2}) e^{-j\theta t - j\tau\omega - j\theta u} du d\tau d\theta \quad (1)$$

其中 $\phi(\theta, \tau)$ 为核函数, $s^*(u)$ 表示 $s(u)$ 的共轭.

核函数 $\phi(\theta, \tau) = 1$ 时为 Wigner-Ville 分布:

$$w(t, \omega) = \int_{-\infty}^{+\infty} s^*(t - \frac{\tau}{2}) s(t + \frac{\tau}{2}) d\tau \quad (2)$$

Wigner-Ville 分布可看作信号在时频平面的能量密度分布. 对连续信号 $s(t)$, WVD 可表示为:

$$w(t, \omega) = \int s(t + \frac{\tau}{2}) s^*(t - \frac{\tau}{2}) e^{-j\omega\tau} d\tau \quad (3)$$

相应地,对离散信号 $s(t)$, WVD 可表示为:

$$w(t, \omega) = 2 \sum_{\tau=-\infty}^{\infty} s(t + \tau) s^*(t - \tau) e^{-j2\omega\tau} \quad (4)$$

令 $n = 0, \dots, N-1$, 采样信号 $s(n)$ 的离散形式为:

$$w(l, k) = \frac{1}{N} \sum_{n=0}^{N-1} s(l+n) s^*(l-n) e^{-\frac{4j\pi nk}{N}} \quad (5)$$

为避免采样 $s(t)$ 时信号混叠,利用被分析信号的解析信号,解析信号由实部和虚部组成,虚部可由 Hilbert 变换得到,解析信号可表示为:

$$H(s_r(t)) = s_r(t) * h(t) \quad (6)$$

$$h(t) = \begin{cases} \frac{2 \sin^2(\frac{\pi t}{2})}{\pi t}, & t \neq 0 \\ 0, & t = 0 \end{cases} \quad (7)$$

其中符号 $*$ 表示卷积, $H(\cdot)$ 表示 Hilbert 变换.

$s(t)$ 为离散信号时,式(6)可改写为:

$$H(s_r(n)) = \sum_{m=-\infty}^{\infty} s_r(m) h(n-m) \quad (8)$$

为抑制交叉项干扰,引入 Kaiser 窗函数 $G(t, w)$:

$$G(t, w) = \frac{I_0[a \sqrt{1 - (t/\tau)^2} + a \sqrt{1 - (w/\tau)^2}]}{I_0(a)} \quad (9)$$

其中 a 为调节窗口形状的非负参数, τ 为 Kaiser 窗驻留时间, I_0 为第一类零阶修正 Bessel 函数. 加入 Kaiser 窗函数的 Wigner-Ville 分布可表示为:

$$w(t, w) = \frac{1}{2\pi} \iint w(t', \omega') G(t - t', w - \omega') dt' d\omega' \quad (10)$$

其中 $G(t, w)$ 为 Kaiser 窗函数.

将窗函数应用于范围 $\pm 2\sigma_t$ 与 $\pm 2\sigma_w$, w 和 t 为时间

和频率步长的倍数,可得采样的窗函数:

$$G[p, q] = \frac{I_0}{I_0(a)} \left[a \sqrt{1 - (\frac{2p}{N-1} - 1)^2} + a \sqrt{1 - (\frac{2q}{N-1} - 1)^2} \right] \quad (11)$$

其中 p 和 q 为取值于 $\pm 2j, \pm 2k$ 之间的整数.

然后,由式(10)与式(11),加入窗函数的 WVD 采样形式为:

$$W(l, m) = \frac{\Delta t \Delta \omega}{2\pi} \sum_{p=l-j}^{l+j} \sum_{q=m-k}^{m+k} w(p, q) G(p-l, q-m) \quad (12)$$

加入平滑函数 $\Psi(t, m)$, 得到 ASPWVD:

$$\Omega(t, \beta) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \Psi(\frac{s-t}{\beta}, \beta m) W(l, m) dl dm \quad (13)$$

然后,由 ASPWVD 计算节律波 $\delta, \theta, \alpha, \beta$ 的瞬时频谱能量,将其组合为 5 个疲劳特征:

$$\begin{cases} p_\alpha(\omega)/p_\beta(\omega) \\ p_\theta(\omega)/p_\beta(\omega) \\ (p_\alpha(\omega) + p_\theta(\omega))/p_\beta(\omega) \\ (p_\theta(\omega) + p_\delta(\omega))/(p_\alpha(\omega) + p_\beta(\omega)) \\ (p_\alpha(\omega) + p_\theta(\omega))/(p_\alpha(\omega) + p_\beta(\omega)) \end{cases} \quad (14)$$

其中 $p_x(\omega)$ 为 X 波 ASPWVD 的能量谱密度大小.

3 Gamma 深度信念网络模型

3.1 Gamma 深度信念网络

Gamma 深度信念网络由底层至顶层分别为观测层、第 1 层隐含层, ..., 第 $K-1$ 层隐含层, 第 K 层顶层. 最底层为观测层,由观测单元 $\mathbf{o}_n^{(1)}$ 组成,利用 Poisson 因子分析^[17],可将其表示为连接权重与下一层隐藏单元的乘积:

$$\mathbf{o}_n^{(1)} \sim \text{Pois}(\mathbf{\Omega}^{(1)} \mathbf{h}_n^{(1)}) \quad (15)$$

其中 $\mathbf{\Omega}^{(1)}$ 为连接权重, $\mathbf{o}_n^{(1)}$ 为第 1 层隐含层, $x \sim \text{Pois}(\lambda)$ 表示 x 服从参数为 λ 的 Poisson 分布.

由观测层至顶层依次为第 1, ..., k, \dots, K 层隐含层, 第 1, ..., $k, \dots, K-1$ 层可表示为:

$$\begin{cases} \mathbf{h}_n^{(1)} \sim \text{Gam}\left(\mathbf{\Omega}^{(2)} \mathbf{h}_n^{(2)}, \frac{\varphi_n^{(2)}}{1 - \varphi_n^{(2)}}\right) \\ \mathbf{h}_n^{(k+1)} \sim \text{Gam}\left(\mathbf{\Omega}^{(k+2)} \mathbf{h}_n^{(k+2)}, \frac{1}{\lambda_n^{(k+2)}}\right) \\ \mathbf{h}_n^{(K-1)} \sim \text{Gam}\left(\mathbf{\Omega}^{(K)} \mathbf{h}_n^{(K)}, \frac{1}{\lambda_n^{(K)}}\right) \end{cases} \quad (16)$$

其中 $\mathbf{\Omega}^{(k)}$ 为连接权重, $\mathbf{h}_n^{(k)}$ 为第 k 层隐含层, $\varphi_n^{(2)}$ 为概率参数,满足:

$$\frac{\varphi_n^{(2)}}{1 - \varphi_n^{(2)}} = \frac{1}{\lambda_n^{(2)}} \quad (17)$$

$x \sim \text{Gam}(\alpha, \frac{1}{\lambda})$ 表示 x 服从形状参数为 α , 尺度参数为

$\frac{1}{\lambda}$ 的 Gamma 分布, 概率密度函数为:

$$f(x; \alpha, \lambda) = \begin{cases} \frac{\lambda^\alpha x^{\alpha-1} e^{-\lambda x}}{\Gamma(\alpha)}, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (18)$$

类似地, 第 K 层可表示为:

$$\begin{cases} \mathbf{h}_n^{(K)} \sim \text{Gam}\left(\boldsymbol{\alpha}, \frac{1}{\lambda_n^{(K+1)}}\right) \\ \boldsymbol{\alpha} = (\alpha_1, \alpha_2, \dots, \alpha_{M_K})' \end{cases} \quad (19)$$

对于顶层 $\mathbf{h}_n^{(K)}$, $\boldsymbol{\alpha}$ 为共享的 Gamma 分布形状参数, $\frac{1}{\lambda_n^{(K+1)}}$ 为尺度参数.

为限制网络复杂度、便于参数推断, 对 $\boldsymbol{\Omega}^{(k)} \in \mathbf{R}^{M_{k-1} \times M_k}$ 的每一列基于 L1 范式规则化, 对于 $k = 1, 2, \dots, K-1$, 使:

$$\begin{cases} \boldsymbol{\omega}_i^{(k)} \sim \text{Diri}(\boldsymbol{\eta}^{(k)}, \dots, \boldsymbol{\eta}^{(k)} | \alpha_i) \\ \alpha_i \sim \text{Gam}\left(\frac{\gamma_0}{M_k}, \frac{1}{\lambda_0}\right) \end{cases} \quad (20)$$

其中 $\text{Diri}(\mathbf{p} | \boldsymbol{\alpha})$ 表示 \mathbf{p} 服从参数为 $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_K)$ 的 Dirichlet 分布, 概率密度函数为:

$$\text{Diri}(\mathbf{p} | \boldsymbol{\alpha}) = \frac{1}{B(\boldsymbol{\alpha})} \prod_{k=1}^K p_k^{\alpha_k - 1} \quad (21)$$

$B(\boldsymbol{\alpha})$ 表示 Dirichlet 分布的归一化常数:

$$B(\boldsymbol{\alpha}) = \int \prod_{k=1}^K p_k^{\alpha_k - 1} dp \quad (22)$$

式(21)中, $\boldsymbol{\omega}_i^{(k)} \in \mathbf{R}^{M_{k-1}}$ 为 $\boldsymbol{\Omega}^{(k)}$ 的第 i 列, λ_0, γ_0 服从 Gamma 分布:

$$\begin{cases} \lambda_0 \sim \text{Gam}\left(a_0, \frac{1}{b_0}\right) \\ \gamma_0 \sim \text{Gam}\left(c_0, \frac{1}{d_0}\right) \end{cases} \quad (23)$$

对于 $k = 3, \dots, T+1$, 有:

$$\begin{cases} \lambda_n^{(k)} \sim \text{Gam}\left(a_0, \frac{1}{b_0}\right) \\ \varphi_n^{(2)} \sim \text{Beta}(c_0, d_0) \end{cases} \quad (24)$$

其中 $x \sim \text{Beta}(\alpha, \beta)$ 表示 x 服从参数为 α, β 的 Beta 分布, 概率密度函数为:

$$f(x; \alpha, \beta) = \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1} \quad (25)$$

因此, M_k 行各隐藏单元 $\mathbf{h}_1^{(k)}, \mathbf{h}_2^{(k)}, \dots, \mathbf{h}_n^{(k)}$ 的关系可由 $\boldsymbol{\Omega}^{(k+1)}$ 的列向量 $\boldsymbol{\omega}_i^{(k+1)}$ ($i = 1, 2, \dots, M_k$) 表示.

由于网络中 Gamma 分布形状参数的共轭先验未知, 计算条件后验推导网络结构存在困难, 因此可基于文献[18]中的数据增强算法简化计算, 推导得: 在 $T = 1$ 的单层网络中, 每层的隐藏单元独立于先验, $T \geq 2$ 的深度网络可以捕获隐藏单元间的关联性. 对 $k = 1, 2, \dots, K$, 有:

$$\begin{cases} \varphi_n^{(1)} = 1 + \frac{1}{e} \\ \varphi_n^{(k+1)} = \frac{-\ln(1 - \varphi_n^{(k)})}{\lambda_n^{(k+1)} - \ln(1 - \varphi_n^{(k)})} \end{cases} \quad (26)$$

然后, $\mathbf{u}_n^{(i)}$ ($k = 1$ 时为观测层, $k = 2, 3, \dots, K$ 时为隐含层) 可由 $\boldsymbol{\Omega}^{(k)}$ 与 $\mathbf{h}_n^{(k)}$ 的乘积在 k 层的 Poisson 概率表示:

$$\mathbf{u}_n^{(k)} \sim \text{Pois}(-\boldsymbol{\Omega}^{(k)} \mathbf{h}_n^{(k)} \ln(1 - \varphi_n^{(k)})) \quad (27)$$

上式对 $k = 1$ 成立, $k = 2, 3, \dots, K$ 时:

$$\begin{cases} u_{mn}^{(k)} = \sum_{i=1}^{M_k} u_{mni}^{(k)} \\ u_{mni}^{(k)} \sim \text{Pois}(-\omega_{mi}^{(k)} \mathbf{h}_{in}^{(k)} \ln(1 - \varphi_n^{(k)})) \end{cases} \quad (28)$$

令 $q_{in}^{(k)(k+1)} = u_{ni}^{(k)} = \sum_{m=1}^{M_i} u_{mni}^{(k)}$ 表示 t 层中因子 $i \in \{1, \dots, M_k\}$

出现在观察单元 n 的次数, $q_n^{(k)(k+1)} = (u_{n1}^{(k)}, \dots, u_{nM_k}^{(k)})'$. 然后边缘化 $\boldsymbol{\Omega}^{(k)}$, 得到

$$q_n^{(k)(k+1)} \sim \text{Pois}(-\mathbf{h}_n^{(k)} \ln(1 - \varphi_n^{(k)})) \quad (29)$$

然后, 从以上 Poisson 概率中边缘化 Gamma 分布 $\boldsymbol{\omega}_n^{(k)}$, 得到

$$q_n^{(k)(k+1)} \sim \text{NB}(\boldsymbol{\Omega}^{(k+1)} \mathbf{h}_n^{(k+1)}, \varphi_n^{(k+1)}) \quad (30)$$

$x \sim \text{NB}(r, p)$ 表示 x 服从参数为 r, p 的负二项分布.

由式(24)与式(26)可从第 k 层隐变量 $u_{mn}^{(k)}$ 推导得第 $k+1$ 层:

$$\begin{aligned} & \{ (u_{mn1}^{(k)}, \dots, u_{mnM_i}^{(k)}) | u_{mn}^{(k)}, \boldsymbol{\omega}_m^{(k)}, \mathbf{h}_n^{(k)} \} \sim \\ & \text{Multi}\left(u_{mn}^{(k)}, \frac{\omega_{m1}^{(k)} \mathbf{h}_{1n}^{(k)}}{\sum_{i=1}^{M_i} \omega_{mi}^{(k)} \mathbf{h}_{in}^{(k)}}, \dots, \frac{\omega_{mi}^{(k)} \mathbf{h}_{in}^{(k)}}{\sum_{i=1}^{M_i} \omega_{mi}^{(k)} \mathbf{h}_{in}^{(k)}}\right) \end{aligned} \quad (31)$$

$$\begin{aligned} & \{ u_{in}^{(k+1)} | q_{in}^{(k)(k+1)}, \boldsymbol{\omega}_{i:}^{(k+1)}, \mathbf{h}_n^{(k+1)} \} \sim \\ & \text{CRT}(q_{in}^{(k)(k+1)}, \boldsymbol{\omega}_{i:}^{(k+1)}, \mathbf{h}_n^{(k+1)}) \end{aligned} \quad (32)$$

其中 Multi 为多项分布, CRT 为中餐馆分布^[19].

3.2 Gibbs 向上向下采样

Gibbs 采样是难以直接对样本采样时, 从某一个多分量概率分布中近似抽样样本序列的算法. 深度信念网络中, 受限玻尔兹曼机使用二维 Gibbs 采样近似估计参数, 将可见向量的值映射到隐藏单元, 再基于隐藏单元重建可见单元, 不断重复以上步骤进行逐层训练.

类似地, 对 Gamma 信念网络, 可以采用 n 维 Gibbs 算法估计隐变量, 联合训练网络所有层, 在每次迭代中对一层网络进行采样, 向上采样服从 Dirichlet 分布的连接权重, 向下采样服从 Gamma 分布的隐含单元, 将其记作 Gibbs 向上向下采样.

对 Gamma 深度信念网络中的每一层, 进行如下迭代采样:

对 $u_{mni}^{(k)}$ 采样: 由式(31), 在所有层中对 $u_{mni}^{(k)}$ 进行采样, 但对第 1 层隐含层, 可以将观察单元 $u_{mn}^{(1)}$ 看作是第 n 个状态中第 m 个特征的序列, 将 $\{m_{nj}\}_{j=1, \dots, u_n}$ 逐个分配

给隐藏因子,并将 $\Omega^{(1)}$ 与 $\mathbf{h}_n^{(1)}$ 边缘化,对 $i \in \{1, \dots, M_{1\max}\}$:

$$P(l_{nj} = i | -) \propto \frac{\delta^{(1)} + u_{m_{n,i}}^{(1)-\eta}}{M \delta^{(1)} + u_{\cdot, i}^{(1)-\eta}} (u_{\cdot, ni}^{(1)-\eta} + \omega_i^{(2)} \mathbf{h}_n^{(2)}) \quad (33)$$

其中 l_{nj} 是 m_{nj} 的特征标签,符号表示对应标签的求和,如 $u_{\cdot, ni}^{(1)} = \sum_m x_{mni}^{(1)}$, x^{-nj} 表示不考虑第 n 个状态中特征 j 的计数序列. 为简化模型,加入截断步骤,即如果 $K=1$,则限制隐藏单元数量为 $M_{1\max}$,并令 $\alpha_i \sim \text{Gam}\left(\frac{\gamma_0}{M_{1\max}}, \frac{1}{\lambda_0}\right)$.

对 $\omega_i^{(k)}$ 采样:

$$(\omega_i^{(k)} | -) = \text{Diri}(\eta^{(k)} + u_{1, \cdot i}^{(k)}, \dots, \eta^{(k)} + u_{M_{1, \cdot k}^{(k)}}) \quad (34)$$

对 $u_{mn}^{(k+1)}$ 采样:由式(33)对 $u_n^{(k+1)}$ 采样,将 $\Omega^{(K+1)} \mathbf{h}_n^{(K+1)}$ 替换为 $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_{M_k})'$.

对 $\mathbf{h}_n^{(k)}$ 采样:由式(27)及 Gamma 分布与 Poisson 分布的共轭性,对 $\mathbf{h}_n^{(k)}$ 采样:

$$(\mathbf{h}_n^{(k)} | -) = \text{Gam}(\Omega^{(k+1)} \mathbf{h}_n^{(k+1)} + q_n^{(k)(k+1)}, (\lambda_n^{(k+1)} - \ln(1 - \varphi_n^{(k)}))^{-1}) \quad (35)$$

对 α 采样:

$$(\alpha_m | -) = \text{Gam}\left(\frac{\gamma_0}{M_K} + u_{m, \cdot}^{(K+1)}, \lambda_0 - \sum_n \ln(1 - \varphi_n^{(K+1)})^{-1}\right) \quad (36)$$

对 $\lambda_n^{(k)}$ 采样:先对 $\varphi_n^{(2)}$ 采样,

$$(\varphi_n^{(2)} | -) = \text{Beta}(c_0 + q_{\cdot, n}^{(1)(2)}, d_0 + \mathbf{h}_{\cdot, n}^{(2)}) \quad (37)$$

再由式(28)可得:

$$(\lambda_n^{(k)} | -) = \text{Gam}(a_0 + \mathbf{h}_{\cdot, n}^{(k)}, (b_0 + \mathbf{h}_{\cdot, n}^{(k-1)})^{-1}) \quad (38)$$

其中 $\mathbf{h}_{\cdot, n}^{(k)} = \sum_{i=1}^{M_k} \mathbf{h}_{in}^{(k)}$ ($k=1, 2, \dots, K$), $\mathbf{h}_{\cdot, n}^{(K+1)} = \alpha$.

4 实验

4.1 数据采集

模拟飞行设备:实验全程在 CRJ-200 飞行模拟器上进行,模拟器内环境与真实飞行过程一致,操作系统提供了飞机当前姿态、发动机转速等飞行所需参数,CRJ-200 飞行模拟器外景及内景如图 1 所示.



图1 CRJ-200飞行模拟器

实验飞行员:参与模拟飞行的被试者为 20 名中国航空公司现役飞行员,平均飞行时长 7173h,平均年龄 39 岁,在实验开始前均参加了模拟飞行器的培训,熟悉操作流程.所有飞行员在实验前一周的飞行时间为 15 ~ 20h,各项生理指标正常,且在实验前一天得到充分休息,确保实验开始时为非疲劳状态.

脑电数据采集:EEG 数据采集过程使用 BCI 2000 系统,包括国际通用 10-20 系统中 64 个参考电极,采样频率为 160Hz,采集的 EEG 信号为 64 通道.64 个电极在采集设备上的分布如图 2 所示.




图2 国际10-20系统64参考电极分布

实验流程:数据采集过程分为 4 个阶段,每个阶段数据采集结束后,飞行员需填写困倦度量表(包括 Stanford 困倦度量表与 Karolinska 困倦度量表),实验各阶段的时间与流程如表 2 所示.

表 2 EEG 数据采集实验流程

阶段	时间	实验要求
1	8:30 ~ 9:00	静坐休息
2	9:00 ~ 10:00	正常模拟飞行
3	10:00 ~ 11:00	气流扰动等复杂环境下的模拟飞行
4	11:00 ~ 12:00	模拟起飞降落等复杂操作

为保证信号平稳,排除实验开始和结束的干扰,选取每个实验阶段中间 12min 的信号.实验共进行 2 天,采集到共计 40 份样本,每份样本为 1 位飞行员 4 个阶段的 EEG 信号,其中数据各阶段标签与困倦度量表结果一致的共有 36 份样本,将其作为后续的实验样本.对每份样本数据,将其划分为长度为 24s 的独立样本信号,每份样本包含 4 段时长分别为 12min 的 EEG 数据,故可得到 4320 份独立样本信号.

4.2 信号预处理与特征提取

首先对脑电信号进行去噪等预处理,再基于 db10 的小波包分解提取 $\delta, \theta, \alpha, \beta$ 节律波,如图 3 所示.

为将节律波转换为更显著的特征,分别利用 ASPWVD 与 SPWVD 计算瞬时时频域信息,EEG 信号经 SPWVD 与 ASPWVD 变换后的时频分布如图 4、图 5 所示.

可以看到经 ASPWVD 与 SPWVD 均能给出信号的瞬时三维特征,但 ASPWVD 提取的瞬时局部频谱信息更丰富.




图3 $\delta, \theta, \alpha, \beta$ 节律波

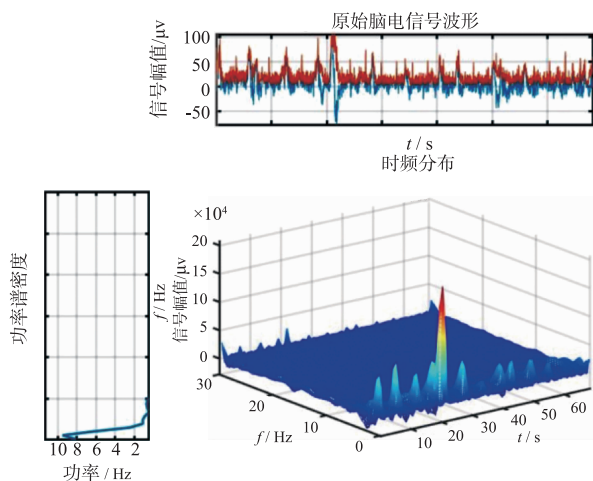


图4 由SPWVD得到的时频分布

基于 ASPWVD 计算瞬时频谱后,构造疲劳指标 $\theta/\beta, \alpha/\beta, (\alpha + \theta)/\beta, (\theta + \delta)/(\alpha + \beta)$ 和 $(\alpha + \theta)/(\alpha + \beta)$. 为选取更显著的特征,将各指标的疲劳状态与非疲劳状态进行对比,如图 6 所示. 横轴为样本序号,纵轴为功率谱密度振幅比值. 可以看到疲劳状态下,5 个指标的比值均呈上升趋势,其中 $\theta/\beta, (\alpha + \theta)/\beta, (\alpha + \theta)/(\alpha + \beta)$ 这 3 个比值增加幅度更大,因此将其组合作为网络的输入特征.

4.3 模型建立与识别

根据第 3 节推导内容,以 MATLAB 为编程工具建立 Gamma 深度信念网络,从底层开始基于 Gibbs 向上向下采样算法进行逐层训练,以确保向量映射到不同的特征空间时尽可能多保留特征信息. 为选取合适的




图5 由ASPWVD得到的时频分布

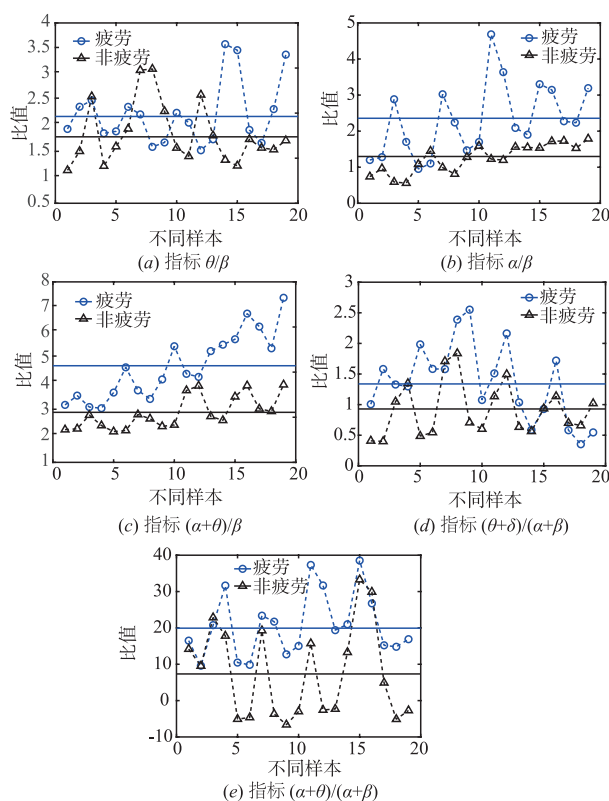


图6 疲劳状态与非疲劳状态的疲劳指标

层数 K 、第一层宽度 M_{1max} 与学习率 η 这些关键参数,选取不同值进行实验以判定各参数对识别率的影响.

对于深度神经网络,添加更多层可以改善网络在无监督地提取特征和预测数据方面的性能,而网络深度的增加将引起训练速度慢与过拟合等问题. 另外, Gamma 深度信念网络可由第一层的宽度(隐藏单元数量)自动推断后续层数量,因此第一层宽度对网络的识别精度非常关键. 本实验中,令网络深度 $K = 1, 2, \dots, 5$, M_{1max} 分别取值 25, 50, 100, 200, 400, 600, 800, 在原数据集 1/3 大小的数据集上进行训练与预测(训练集与测试

集的比例为 3: 1), 得到准确率如图 7、8 所示。




图7 不同 M_{1max} 的识别准确率




图8 不同网络层数 K 识别准确率

由图 7 可以看到, 对任意网络层数 K , 随着第一层宽度增大, 识别准确率呈上升趋势, 增加到 200 后趋于稳定, 仅存在一些波动。

图 8 为 M_{1max} 取不同值时, 层数 K 对识别性能的影响, 可以看到增加层数对提高识别准确率有较好的效果。当第一层宽度取值适中时, 增加层数对准确率的效果更明显, 取值很大时, 每层节点数较多, 模型复杂度与预测能力增加, 此时增加网络深度对模型性能的提升有限。

图 9 为 $\eta = 0.01, 0.05, 0.1, 0.5$ 时, 模型在各网络深度下的识别准确率与识别过程每次迭代用时, 层数 T 增加与学习率减小将导致每次迭代用时增加, 同时, 随着学习率增大, 识别准确率先增大后减小。

因此, 综合考虑计算量与网络性能, 取 $M_{1max} = 200, K = 4, \eta = 0.05$, 即建立一个 4 层的 Gamma 深度信念网络, 学习率为 0.05, 第 1 层宽度 (隐藏单元数量) 为 200, 第 2 层之后的宽度将在给定的第 1 层宽度 200 下以贪婪的逐层训练方式进行学习, 实验流程如图 10 所示。

为进一步验证 Gamma 深度信念网络的识别性能, 选择不同的模型进行训练并预测, 对 4230 份样本, 以 3:1 的比例随机分为训练集与测试集, 对每个模型进行




图9 不同 η 的识别准确率与迭代用时

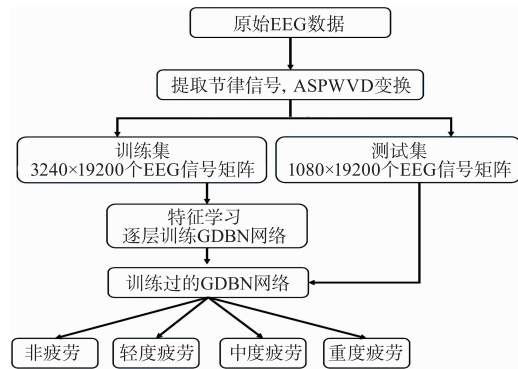


图10 脑电信号分类实验流程

4 折交叉验证, 得到在不同模型下的识别准确率 (表 3)。由表中结果可以看到, TRFN 模型在本实验数据集下的识别率最低, 且波动较大。DBN 及其相关模型的识别准确率较高, 识别率波动较小, 即有更好的泛化能力。准确率波动幅度相近的模型中, GDBN 有更高的识别率, 即本文的 Gamma 深度信念网络对飞行员脑疲劳有较好的学习与预测能力。

表 3 不同模型的识别准确率

分类器	精确率 (均值 \pm 标准差)	每次迭代用时 (s)
TRFN ^[20]	0.8065 \pm 0.081	0.0382
FWNN ^[21]	0.8179 \pm 0.073	0.0337
DBN ^[16]	0.8639 \pm 0.026	0.0301
SDBN ^[22]	0.9053 \pm 0.034	0.0388
GDBN	0.9334 \pm 0.031	0.0346

5 结论

对于复杂 EEG 信号,完全依赖人工经验指标提取特征将导致特征丢失,因此,将定量疲劳指标与深度学习网络结合,并针对 FFT 只能给出一段时间内的平均频谱信息的局限性,利用 ASPWVD 代替 FFT 计算瞬时频谱,从 EEG 信号中最大限度提取表征疲劳的特征成分.同时针对 EEG 信号各通道特征的强相关性及周期性,在 DBN 中引入 Gamma 分布,使网络每一层的隐藏单元服从 Gamma 分布,构建 GDBN 模型以无偏差推断特征向量的多层表示,捕获所有层中可见与隐藏特征之间的相关性.并通过 Gibbs 向上向下采样迭代联合训练所有隐含层,避免 DBN 中需要调整每层隐藏单元数和网络深度的问题,以尽可能简单的网络结构表征数据集特征.最后,基于真实飞行员 EEG 数据的实验结果显示,GDBN 在推断飞行员脑疲劳方面有较好的性能,且迭代用时未出现大幅增长.因此,基于 Gamma 深度信念网络的飞行员脑疲劳推理识别方法有较好的可行性与识别效果.

参考文献

- [1] Maarten A S, Theo F, Monicque M. Effects of mental fatigue on attention: An ERP study [J]. *Cognitive Brain Research*, 2005, 25(1): 107 - 116.
- [2] Moroney W, Biers D W, Eggemeier F T, et al. A comparison of two scoring procedures with the NASA task load index in a simulated flight task [A]. *Proceedings of the IEEE 1992 National Aerospace and Electronics Conference* [C]. Dayton, OH, USA: IEEE, 1992. 734 - 740.
- [3] Kaida K, Takahashi M, Akerstedt T, et al. Validation of the Karolinska sleepiness scale against performance and EEG variables [J]. *Clinical Neurophysiology*, 2006, 117(7): 1574 - 1581.
- [4] Hong J W, Sun W L, Jean-Philippe P. Real time eye tracking interface for visual monitoring of radar controllers [A]. *AIAA Modeling and Simulation Technologies Conference* [C]. Grapevine, Texas, USA: AIAA, 2017. 1317.
- [5] Nijholt A, Tan D. Brain-computer interfacing for intelligent systems [J]. *IEEE Intelligent Systems*, 2008, 23(3): 72 - 79.
- [6] Craig A, Tran Y, Wijesuriya N, et al. Regional brain wave activity changes associated with fatigue [J]. *Psychophysiology*, 2012, 49(4): 574 - 582.
- [7] Lal S K L, Craig A, Boord P, et al. Development of an algorithm for an EEG-based driver fatigue countermeasure [J]. *Journal of Safety Research*, 2003, 34(3): 321 - 328.
- [8] Azarnoosh M, Nasrabadi A M, Mohammadi M R, et al. Investigation of mental fatigue through EEG signal processing based on nonlinear analysis; Symbolic dynamics [J]. *Chaos Solitons Fractals*, 2011, 44(12): 1054 - 1062.
- [9] Lal S K L, Craig A. A critical review of the psychophysiology of driver fatigue [J]. *Biological Psychology*, 2001, 55(3): 173 - 194.
- [10] C Papadelis, et al. Indicators of sleepiness in an ambulatory EEG study of night driving [A]. *International Conference of the IEEE Engineering in Medicine and Biology Society* [C]. New York: IEEE, 2006. 6201 - 6204.
- [11] Jap B T, Lal S, Fischer P, et al. Using EEG spectral components to assess algorithms for detecting fatigue [J]. *Expert Systems with Applications*, 2009, 36(2): 2352 - 2359.
- [12] Cai H, Sha X, Han X, et al. Pervasive EEG diagnosis of depression using deep belief network with three-electrodes EEG collector [A]. *IEEE International Conference on Bioinformatics and Biomedicine* [C]. Shenzhen: IEEE, 2016. 1239 - 1246.
- [13] Chen J X, Zhang P W, Mao Z J, et al. Accurate EEG-based emotion recognition on combined features using deep convolutional neural networks [J]. *IEEE Access*, 2019, 7: 44317 - 44328.
- [14] 孙曜, 文成林, 韦巍. 基于脑电和眼电的运动想象多尺度识别方法研究 [J]. *电子学报*, 2018, 46(03): 714 - 720. Sun Yao, Wen Chenglin, Wei Wei. Research on EEG and EOG based multiscale recognition method of motor imagery [J]. *Acta Electronica Sinica*, 2018, 46(03): 714 - 720. (in Chinese)
- [15] Saul L K, Jaakkola T, Jordan M I. Mean field theory for sigmoid belief networks [J]. *Journal of Artificial Intelligence Research*, 1996, 4(1): 61 - 76.
- [16] Hinton G E, Osindero S, The Y W. A fast learning algorithm for deep belief nets [J]. *Neural Computation*, 2006, 18(7): 1527 - 1554.
- [17] Zhou M, Hannah L, Dunson D, et al. Beta-negative binomial process and poisson factor analysis [A]. *International Conference on Artificial Intelligence and Statistics* [C]. La Palma: IEEE, 2012. 1462 - 1471.
- [18] Dyk D A V, Meng X L. The art of data augmentation [J]. *Journal of Computational & Graphical Statistics*, 2001, 10(1): 1 - 50.
- [19] Blackwell, Macqueen J. Ferguson distributions via Polya urn schemes [J]. *The Annals of Statistics*, 1973, 1(2): 353 - 355.
- [20] Juang C F. A TSK-type recurrent fuzzy network for dynamic systems processing by neural network and genetic algorithms [J]. *IEEE Transactions on Fuzzy Systems*, 2002, 10(2): 155 - 170.
- [21] Yilmaz S, Oysal Y. Fuzzy wavelet neural network models

for prediction and identification of dynamical systems[J]. IEEE Transactions on Neural Networks, 2010, 21(10): 1599 – 1609.

[22] Chai R, Ling S H, San P P, Naik G R, et al. Improving

EEG-based driver fatigue classification using sparse-deep belief networks[J]. Frontiers in Neuroscience, 2017, 11: 103 – 117.

作者简介



罗映雪 女, 1996 年出生, 湖北洪湖人, 上海交通大学控制工程专业硕士研究生, 主要研究方向为飞行员工作负荷评价。
E-mail: dyljxl@sjtu.edu.cn



贾博 男, 1988 年出生, 甘肃兰州人, 东航技术应用研发中心有限公司工程师, 主要研究方向为人机交互, 智能飞行。



裘旭益 男, 1983 年出生, 浙江慈溪人, 中国航空无线电电子研究所高级工程师, 上海交通大学博士研究生, 主要研究方向为智能作战与人机交互。



邓平煜 男, 1979 年出生, 甘肃张掖人, 中国航空无线电电子研究所总工程师, 研究员, 主要研究方向为航电系统架构与人机交互。



任和 男, 1967 年出生, 澳洲人, 中国商飞上海飞机客户服务有限公司副总工程师, 国家千人计划教授, 主要研究方向为飞行数据管理与人机交互。



吴奇(通信作者) 男, 1978 年出生, 安徽合肥人, 上海交通大学电子信息与电气工程学院副教授, 主要研究方向为视脑交互。
E-mail: wuqi7812@sjtu.edu.cn