

doi:10.12068/j.issn.1005-3026.2026.20240229

# 基于黎曼几何的跨被试认知负荷检测研究

李子阳, 王宏, 颜万吉, 李承昊

(东北大学 机械工程与自动化学院, 辽宁 沈阳 110819)

**摘要:** 针对认知负荷跨被试检测的难点, 结合黎曼几何方法在脑电(electroencephalography, EEG)信号分析中的优势, 提出基于均值最小距离(minimum distance to mean, MDM)和切空间的认知负荷跨被试检测方法. 本研究基于60通道EEG信号的多源干扰任务(multi-source interference task, MSIT)数据, 经数据预处理后提取事件相关数据段, 并采用xDawn空间滤波器优化EEG协方差特征表示. 通过对比传统特征方法, 验证所提方法在认知负荷检测任务中的有效性. 结果表明, 在1.2 s长度的数据窗口中, 基于黎曼几何的方法在留一法(leave one subject out, LOSO)跨被试分类中, 最优分类性能的受试者工作特征曲线下面积(area under the receiver operating characteristic curve, ROC AUC)达0.7901;而在被试内(Within)分类中, ROC AUC最高为0.8062. 相较于深度学习模型, 所提方法在保持较高分类性能的同时, 显著提升了计算效率, 为实时监测提供了可行方案.

**关键词:** 认知负荷检测; 脑电信号; 黎曼几何; 均值最小距离; 切空间; 跨被试分类

中图分类号: R 318 文献标志码: A 文章编号: 1005-3026(2026)03-0001-09

## Research on Cross-Subject Cognitive Load Detection Based on Riemannian Geometry

LI Zi-yang, WANG Hong, YAN Wan-ji, LI Cheng-hao

(School of Mechanical Engineering & Automation, Northeastern University, Shenyang 110819, China. Corresponding author: WANG Hong, E-mail: hongwang@mail.neu.edu.cn)

**Abstract:** To address the challenge of cross-subject cognitive load detection, by combining the advantages of Riemannian geometry methods in electroencephalography (EEG) signal analysis, a method of cross-subject cognitive load detection based on minimum distance to mean (MDM) and tangent space was proposed. Based on 60-channel EEG signals from the multi-source interference task (MSIT) data, event-related data segments were extracted through data preprocessing, and the xDAWN spatial filter was employed to optimize the representation of the EEG covariance matrix features. Compared with traditional feature-based methods, the effectiveness of the proposed method in cognitive load detection tasks was verified. The results show that, for the data window with the length of 1.2 s, the Riemannian geometry-based method achieves an area under the receiver operating characteristic curve (ROC AUC) of 0.7901 for the optimum classification performance in leave one subject out (LOSO) cross-subject classification and reaches a maximum ROC AUC of 0.8062 within subject (Within) classification. Compared to deep learning models, the proposed method maintains high classification performance while significantly improving computational efficiency and providing a feasible solution for real-time monitoring.

**Key words:** cognitive load detection; electroencephalography signal; Riemannian geometry; minimum distance to mean; tangent space; cross-subject classification

在认知神经科学与脑-机接口(brain computer interface, BCI)研究中, 基于EEG的认

收稿日期: 2024-12-15

基金项目: 国家重点研发计划项目(2021YFF0306405).

作者简介: 李子阳(1991—), 男, 山西吕梁人, 东北大学博士研究生.

通信作者: 王宏, E-mail: hongwang@mail.neu.edu.cn.

知负荷检测是一个重要方向<sup>[1-2]</sup>. 认知负荷反映了个体在特定任务情境下的心理资源消耗水平, 其有效检测对于提升人机交互效率、预防过度疲劳和优化学习体验具有重要意义<sup>[3]</sup>. 然而, 现有的认知负荷检测方法在跨被试情境下的表现依然面临诸多挑战, 尤其是跨被试认知负荷检测<sup>[4]</sup>, 仍然是检测方法走向实际应用需要解决的关键问题. 跨被试认知负荷检测的主要难点在于个体间脑电信号的高度异质性. 不同被试的脑电信号在空间分布、频谱特性和噪声水平等方面存在显著差异<sup>[5]</sup>, 导致传统的机器学习模型在不同被试之间的泛化性能较差. 此外, 跨被试数据通常需要更大的样本量以捕捉足够的统计特性, 但数据采集过程的高成本和复杂性以及生理数据的安全性要求使得大规模标注数据的获取变得困难. 传统方法多采用时频分析、特征提取与分类算法. 这些方法对特征空间的选择依赖较强, 且在高维特征空间中容易受限于维度灾难, 往往难以有效捕捉脑电信号的多维特性, 从而限制了模型性能. 为应对上述问题, 空间滤波方法被广泛应用于脑电信号分析中, 如脑电信号预处理去伪影常用的独立成分分析 (independent component analysis, ICA). 在分类算法中, 常见的空间滤波方法包括共空间模式 (common spatial pattern, CSP) 及其变体, 这类方法通过优化滤波器以最大化类别间的方差差异, 从而提取出与任务相关的特征. 在跨被试情境下, CSP 的性能虽有所下降, 但结合域自适应技术或正则化方法后, 其仍然能够在一定程度上提升泛化性能<sup>[6]</sup>. 然而, 空间滤波方法依赖于线性假设, 可能在处理脑电信号复杂的非线性特性时存在局限.

以上方法通常假设数据服从欧几里得空间的分布特性, 而脑电信号的协方差矩阵却具有非欧几里得性质, 这种不匹配进一步限制了模型的性能<sup>[7]</sup>. 针对上述问题, 黎曼几何方法为跨被试认知负荷检测提供了新的解决思路. 黎曼几何方法能够有效处理脑电信号的协方差矩阵, 这种矩阵定义在对称正定矩阵 (symmetric positive definite, SPD) 空间中<sup>[8]</sup>, 该空间构成一个黎曼流形而非传统的欧几里得空间. 黎曼几何方法通过利用流形空间的内在几何结构, 能够更加准确地刻画不同被试之间的脑电信号特性. 近年来, 基于黎曼几何的分析方法逐渐成为 EEG 信号处理的一个重要方向, 尤其是在运动想象<sup>[9-10]</sup>和稳态视觉诱发电位<sup>[11-12]</sup>范式 BCI 识别的研究中. 在黎

曼几何框架下, 最小均值距离法和切空间映射 (tangent space mapping, TSM) 是基于黎曼几何的信号处理和分类中常用的方法<sup>[13]</sup>, 尤其适用于 EEG 数据分析. 两者虽然都利用了协方差矩阵, 但在特征提取和分类策略上有很大不同. MDM 方法基于黎曼流形空间中类别均值的几何距离进行分类. 通过计算测试样本与各类别均值协方差矩阵之间的黎曼距离, MDM 方法避免了对高维特征的显式建模, 具有简单直观且计算效率高的特点, 尤其适合小样本场景. 切空间映射方法则通过将协方差矩阵映射到参考点 (通常是流形的均值) 处的切空间, 将流形上的非线性问题转化为切空间的线性问题. 这种方法不仅保留了黎曼流形的几何信息, 还能够结合传统的线性分类器 (如支持向量机), 在复杂分类任务中展现出较强的泛化能力<sup>[14]</sup>.

基于以上背景, 以跨被试认知负荷检测为研究目标, 系统探讨了黎曼几何方法在认知负荷检测中的应用价值与实践路径. 主要贡献包括: 对比 CSP 方法, 验证了基于协方差矩阵的黎曼几何方法在跨被试认知负荷检测中的有效性; 比较 MDM 和切空间映射方法的性能, 分析了其在不同样本量和数据分布下的适用性; 测试分析不同参数下 xDAWN 滤波优化算法对模型性能提升的效果; 在干扰抑制 MSIT 上对比验证, 分析黎曼几何方法检测的适应性. 研究结果将为提升跨被试脑电信号分析的鲁棒性和准确性提供新的理论依据, 为未来基于黎曼几何的跨被试研究提供理论支持与实践参考, 同时推动认知负荷检测技术在实际应用中的发展.

## 1 黎曼几何方法

黎曼几何提供了一种强有力的数学工具, 用于研究非欧几里得空间中数据的结构特性. 与传统的欧几里得几何不同, 黎曼几何的研究对象是具有非平坦特性的空间, 例如曲面、球面或更一般的流形. 对于 EEG 信号, 协方差矩阵通常被用作特征表征, 其位于对称正定矩阵流形上. 通过在流形上直接定义距离和运算, 黎曼几何方法能够更准确地反映数据的内在结构, 避免传统欧几里得假设带来的偏差<sup>[15]</sup>. 一个黎曼流形  $(M, g)$  包括以下要素:  $M$  为一个光滑流形, 用来表示几何对象的空间;  $g$  为一个在每个点定义的正定双线性形式, 即黎曼度量, 用来测量流形上任意两个

切向量之间的内积.任一点 $p$ 处的黎曼度量可以表示为

$$\mathbf{g}_p(\mathbf{u}, \mathbf{v}) = \sum_{i,j} \mathbf{g}_{ij} \mathbf{u}^i \mathbf{v}^j. \quad (1)$$

其中: $\mathbf{g}_{ij}$ 是度量张量; $\mathbf{u}^i, \mathbf{v}^j$ 是切向量的分量; $i, j = 1, 2, \dots, N$ ,其中, $N$ 为 $M$ 的维度.

如图1所示,一个流形 $M$ 上有两个点 $P$ 和 $Q$ ,黎曼距离一般指流形上连接两点的最短路径(即测地线)的长度,最小化路径长度的积分计算为

$$d_g(P, Q) = \inf_{\gamma} \int_0^1 \sqrt{\mathbf{g}_{\gamma(t)} \left( \frac{d\gamma(t)}{dt}, \frac{d\gamma(t)}{dt} \right)} dt. \quad (2)$$

其中: $\gamma \in [0, 1]$ 是一条连接点 $P$ 和 $Q$ 的路径(曲线),满足边界条件 $\gamma(0) = P, \gamma(1) = Q$ ;  $\mathbf{g}_{\gamma(t)}$ 即为路径上点 $\gamma(t)$ 处的度量张量(式(1));  $\inf_{\gamma}$ 表示对所有满足边界条件的路径 $\gamma$ 求积分值的下确界.




图1 黎曼流形及切空间的示意图

Fig. 1 Schematic diagram of Riemannian manifold and tangent space

协方差矩阵可以视为嵌入到黎曼流形上的一个点.SPD矩阵,以下简称正矩阵,可以被认为是平方实数在多维空间下的推广.在黎曼几何中,协方差矩阵不仅仅是一个矩阵对象,而是一个度量空间的元素.黎曼几何提供了一种度量这些矩阵之间距离的方法.正矩阵流形上的黎曼距离可以理解为一维几何距离在任何维度的直接推广<sup>[7]</sup>.测地线距离是黎曼流形上最短路径的度量,能够更加精确地反映流形的几何结构.另外,在流形上的每一点处,都可以定义一个线性空间,称为切空间.切空间是对流形局部进行线性近似的工具,用来处理非线性结构.如图1所示, $G$ 为连接 $P$ 和 $Q$ 的测地线上的中点,使得两个平方距离之和 $\delta^2(P, G) + \delta^2(Q, G)$ 最小化.在 $G$ 处构造切空间 $T_G M$ ,存在唯一一个切向量 $\overrightarrow{GP}$ ( $\overrightarrow{GQ}$ ),对应于从 $G$ 出发到达流形上点 $P$ ( $Q$ )的测地线;从切线空间(对称矩阵)到流形(正矩阵)的映射是指数映射.从流形到切线空间的逆映射是对数映射.

### 1.1 协方差矩阵

在处理EEG数据时,协方差矩阵的估计方法

是非常关键的一步,特别是在黎曼几何相关的分类和特征提取方法中.黎曼框架描述了协方差矩阵空间的特定几何形状.它嵌入了特定的属性,如仿射不变性,使得基于传感器的协方差矩阵之间或基于源的协方差矩阵间的距离相等.常见的两种估计方法是样本协方差矩阵(sample covariance matrix, SCM)和优化收缩(oracle approximating shrinkage, OAS)估计协方差矩阵.在EEG分析中,给定一个 $n \times m$ 的数据矩阵 $X$ ,其中 $n$ 是数据长度(即EEG信号的采样点数), $m$ 是通道数量,每个样本是一组二维数据.协方差矩阵是通道信号之间的统计关系的量化表达.SCM是最常见的协方差矩阵估计方法,通过直接计算样本之间的协方差来估计真实的协方差矩阵.给定数据矩阵 $X = [x_1, x_2, \dots, x_n]^T$ ,样本协方差矩阵 $C$ 的计算公式为

$$C = \frac{1}{n-1} X^T X. \quad (3)$$

这里, $C$ 是 $m \times m$ 的对称矩阵,表示信号各个通道之间的协方差.

由于协方差矩阵在黎曼几何中的应用,通常假设它是对称正定矩阵.SCM在样本数较少时容易导致估计不稳定,尤其是在EEG数据中,样本数较少而特征维度较高的情况很常见.OAS方法旨在改进样本协方差矩阵的估计,增强其稳定性<sup>[16]</sup>.OAS估计公式为

$$C_{OAS} = \frac{1}{n} (\text{tr}(C)I - C). \quad (4)$$

其中: $\text{tr}(C)$ 是协方差矩阵的迹(即其对角元素的和); $I$ 是单位矩阵.OAS方法通过引入正则化项,减小协方差矩阵估计中的噪声成分,从而增强估计的鲁棒性.因此,本研究中基于黎曼几何的分类方法均使用OAS协方差矩阵.

### 1.2 仿射不变黎曼度量

仿射不变黎曼度量(affine-invariant Riemannian metric, AIRM)是在SPD流形上定义的黎曼度量,它使切空间变成一个内积空间(“带度量的线性空间”),而非具有固定全局内积的欧氏空间.切空间上的内积依赖于基点 $G$ ,所以每个点的切空间“形状”都不同.SPD流形上的AIRM内积专门设计为在任意仿射变换下保持不变,保证了不同参考系下的协方差矩阵比较具有一致意义.对于一个给定的黎曼流形 $M$ 上的两点 $P$ 和 $Q$ ,如图1所示,仿射不变黎曼度量距离 $d_{\text{AIRM}}(P, Q)$ 定义为

$$d_{\text{AIRM}}(\mathbf{P}, \mathbf{Q}) = \left\| \lg(\mathbf{P}^{-1/2} \mathbf{Q} \mathbf{P}^{-1/2}) \right\|_F. \quad (5)$$

其中:  $\mathbf{P}^{-1/2}$  表示矩阵  $\mathbf{P}$  的逆平方根;  $\mathbf{P}^{-1/2} \mathbf{Q} \mathbf{P}^{-1/2}$  将  $\mathbf{Q}$  映射到  $\mathbf{P}$  的标准化空间;  $\|\cdot\|_F$  表示 Frobenius 范数, 即矩阵元素的平方和的平方根。

通过对 SPD 流形上的测地线进行特殊变换, 把计算问题转化成在切空间中两个点进行“直线比较”。AIRM 距离直接度量了两点在 SPD 流形上的最短路径长度, 严格遵循流形几何结构, 具有仿射不变性, 即无论矩阵经过怎样的非奇异线性变换, 它们之间的距离保持不变, 因此在协方差矩阵分类中被广泛应用。

对数欧几里得距离 (log-Euclidean distance, Log-E) 可以视为流形上测地线距离的一种近似<sup>[17]</sup>, 通过对数映射将问题转化为欧几里得空间中的计算, 以避免计算复杂的最短路径 (测地线)。这种方法比较简单, 但 Log-E 只有在正交变换时才保持不变。由于脑电信号在空间采集上的特性, 通道间协方差结构更符合黎曼流形而非欧氏空间的几何假设, 因此本文中基于黎曼几何的分类方法均选择仿射不变黎曼度量, 以更精确地刻画通道间关系。

### 1.3 均值最小距离

MDM 算法是已知最简单的黎曼分类方法<sup>[7]</sup>, 基于黎曼几何原理, 通过计算类均值 (或中心) 和样本之间的最小距离来进行分类。具体来说, 该算法计算每个样本点到各类均值的距离, 并将样本分配到距离最近的类。其核心思想是计算每个类别的均值协方差矩阵, 然后将测试样本的协方差矩阵与各个类别的均值协方差矩阵之间的距离进行比较, 最终选择最小距离对应的类别作为预测结果。给定训练集中的多个类别  $\{\mathbf{C}_1, \mathbf{C}_2, \dots, \mathbf{C}_k\}$ , MDM 算法的分类规则为

$$\hat{y} = \arg \min_i d_{\text{AIRM}}(\mathbf{C}_{\text{test}}, \mathbf{C}_{\mu_i}). \quad (6)$$

其中:  $\mathbf{C}_{\text{test}}$  是测试样本的协方差矩阵;  $\mathbf{C}_{\mu_i}$  是类别  $\mathbf{C}_i$  的均值协方差矩阵。

### 1.4 切空间

切空间方法通过将协方差矩阵从黎曼流形映射到欧几里得空间, 生成特征向量, 从而便于使用传统的机器学习算法。该方法能够克服传统欧几里得空间方法的限制, 提高跨被试、跨任务等复杂情境下分类任务的性能。在黎曼几何中选择一个参考点  $\mathbf{C}_{\text{ref}}$ , 通常为训练集协方差矩阵的黎曼均值。将每个协方差矩阵投影到参考点的切空间, 得到一个欧几里得特征向量, 可以直接用于分类。对于

一个协方差矩阵  $\mathbf{C}$ , 其对数映射的数学表达式为

$$\mathbf{V} = \lg(\mathbf{C}_{\text{ref}}^{-1/2} \mathbf{C} \mathbf{C}_{\text{ref}}^{-1/2}). \quad (7)$$

特征向量可以通过展平  $\mathbf{V}$  或提取其上三角部分获得。切空间是流形上的局部近似空间, 是通过在给定点处做线性逼近获得的。切空间内的点表示协方差矩阵在流形附近的局部线性行为。在映射到切空间之前, 其几何结构保持了 AIRM 的不变性; 而在切空间内进行的后续处理, 如分类或回归, 则因线性化的空间结构而变得更加简单高效。切空间和 MDM 方法都依赖于将协方差矩阵映射到切空间, 但它们的目的是和应用有所不同。切空间方法主要用于特征映射和后续的传统分类模型 (例如 SVM 或 kNN), 而 MDM 是基于最小距离原则进行分类的。

## 2 实验方法

### 2.1 数据集

PEARL 神经数据集采集了 79 名中年被试执行认知任务时的脑电数据, 采用多源干扰任务 (multi-source interference task, MSIT) 数据。实验使用具有 128 个电极的 Brain Products 系统记录原始 EEG 数据。在线参考电极为 FCz, 采样频率为 1 000 Hz。电极阻抗保持在 5~10 k $\Omega$  之间, 以确保高质量和可靠的数据采集。在记录过程中, 仅使用截止频率为 280 Hz 的低通滤波器, 未应用任何陷波或高通滤波器。每位参与者都被要求通过按键正确及时地响应 166 个 MSIT 数据; 任务包括高/低需求两种刺激条件。实验范式的刺激间隔在设定范围内变化以尽量减少大脑的适应效应。同时记录参与者的反应事件。更多关于该数据集的详细信息可以在其原始出版物中找到<sup>[18]</sup>。

由于公开数据集包含采集的原始数据, 因此在进行研究之前, 预处理是至关重要的。数据预处理使用 Matlab (v9.11.0 R2021b) 中的 EEGLAB (v2023.1) 进行。如图 2 所示, 将脑电信号重新参考至近似平均乳突参考点 P9 和 P10, 以提高信号的稳定性。选择了 60 个常用的脑电通道, 如图 3 所示, 覆盖大脑的 6 个子区域: 前额叶、额叶、颞叶、中央区、顶叶和枕叶。数据被下采样至 250 Hz, 并采用带通滤波器对其进行去噪, 滤波范围为 1~30 Hz, 半幅截止频率, 滚降为 12 dB/倍频程。随后, 通过独立成分分析 (ICA) 和伪迹抑制技术进一步清理数据。考虑到 EEG 记录中高频信号可能因容积传导效应而导致伪迹, 本研究采用 30 Hz 的低通滤

波(半幅截止滤波),以排除潜在的不可靠 $\gamma$ 波影响.在数据筛选阶段,仅纳入具有正确事件响应的试次,反应时间短于200 ms的刺激被视为误触发并予以排除.对于MSIT数据,选择刺激开始后1.5 s内正确响应的有效试次.这一数据预处理流程有效确保了研究数据的可靠性和可用性.

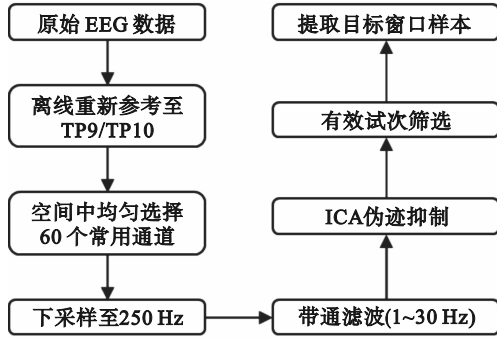


图2 EEG 数据预处理流程图

Fig. 2 Flowchart of EEG data preprocessing




图3 脑电信号电极分布图

Fig. 3 Electrode distribution diagram of EEG signals

从每个有效试次中提取刺激前0.2 s到刺激后1.2 s的数据段作为一个样本.每个样本的数据量为60通道 $\times$ 350样本点.如果任一通道的峰-峰振幅超过150  $\mu$ V,该段数据将被视为噪声并予以排除.同时,基于以下原因排除部分受试者:缺少事件标签、正确响应的试次数量不足、伪影过多或存在不可接受数量的坏通道.最终保留50位被试,由于每位被试有效响应试次数量不同,MSIT样本量(均值 $\pm$ 标准差)为161.66 $\pm$ 4.53.

## 2.2 模型

### 2.2.1 xDAWN空间滤波算法

由于ERP信号的幅度远低于背景EEG噪声水平<sup>[19]</sup>,单个试次的样本协方差矩阵所承载的空间结构信息不足,难以实现有效分类.xDAWN方

法旨在增强与事件相关的脑电信号,其计算的协方差矩阵更能突出事件信号与背景噪声的差异<sup>[20]</sup>.假设EEG信号 $X(t)$ 是事件相关信号 $S(t)$ 和背景噪声 $N(t)$ 的叠加:

$$X(t) = S(t) + N(t). \quad (8)$$

对于ERP相关实验,要求最大化信号 $S(t)$ 的贡献,同时最小化背景噪声 $N(t)$ .xDAWN使用优化的滤波矩阵 $W$ 对信号进行加权:

$$X' = W^T X. \quad (9)$$

xDAWN滤波后的信号用于计算协方差矩阵.对于数据量较大的情况,设置较多的滤波器可以提取更多的特征,可能获得更好的分类性能.

### 2.2.2 CSP

CSP是一种经典的空间滤波技术,广泛应用于EEG分析,尤其是运动想象任务(motor imagery, MI)中的二分类问题.其主要目的是提取两类信号之间差异最大的空间特征,从而增强分类性能.CSP基于两类信号的协方差矩阵优化问题,目标是找到能够最大化类间方差比的空间滤波器<sup>[21]</sup>.例如,有两类信号的协方差矩阵 $C_1$ 和 $C_2$ .通过最大化一类信号的方差,同时最小化另一类信号的方差来实现特征提取.优化问题可表示为

$$W = \arg \max_W \frac{W^T C_1 W}{W^T C_1 W + W^T C_2 W}. \quad (10)$$

对联合协方差矩阵 $C = C_1 + C_2$ 进行归一化:

$$C_{\text{norm}} = P^{-1/2} C P^{-1/2}. \quad (11)$$

其中 $P$ 是 $C$ 的特征值分解结果.使用广义特征值分解来求解最优空间滤波器:

$$C_1 W = \lambda C_{\text{norm}} W. \quad (12)$$

其中 $\lambda$ 是广义特征值.最后选择特征值最大的几个特征向量,即滤波器,也被称为CSP分量,其数量通过参数设置.

### 2.2.3 实验设置

本文设置了4种测试模型和4个基准模型,如表1所示,包括CSP结合SVM线性分类器<sup>[22]</sup>以及脑电领域的3种经典的深度学习模型(EEGInception<sup>[23]</sup>, EEGNet4<sup>[24]</sup>和ShallowFBCSPNet<sup>[25]</sup>),作为非黎曼几何方法的基准模型.黎曼几何方法主要为MDM分类器和基于切空间特征的SVM线性分类器.作为对比实验,以验证黎曼几何方法检测认知负荷的分类性能.所有实验统一使用受试者工作特征曲线下面积(area under the receiver operating characteristic curve, ROC AUC)指标来表征模型性能.考虑到类别不平衡问题,使用加

权指标进行评估.此外,还通过模型的样本平均耗时对模型进行综合评价.为了验证跨被试分类的有效性,实验中使用 MOABB (mother of all BCI benchmarks) 框架<sup>[26]</sup>进行了 3 种模式的模型评估:跨被试评估使用留一被试法 (leave one subject out, LOSO) 和留部分被试法 (leave part subjects out, LPSO), 被试内 (within subject, Within) 评估使用五折交叉验证.在 LPSO 中设置 20% 的比例,即每次有 10 名被试作为测试集且不重复.此外还进行了几组消融实验:①通过对比

MDM 和切空间方法是否使用 xDAWN 滤波,测试 xDAWN 模块的作用;②xDAWN 和 CSP 空间滤波算法可以配置滤波器数量参数,本文设置了常用的 4 (CSP 和 X 的默认值) 和 8 (模型名称分别标明为 CSP8 和 X8), 以比较不同滤波器数量的效果;③截取刺激点后的数据段进行检测,评估模型是否真正依赖任务相关特征进行决策;④基础分类器使用线性 SVM, 同时对比测试了使用径向基核函数 (radial basis function, RBF) 的 SVM 分类器.

表 1 模型列表  
Table 1 Model list

分组	模型名称	方法流程	滤波器数量
测试	MDM	协方差矩阵+MDM	—
	X_MDM	xDAWN 滤波协方差矩阵+MDM	4, 8
	T_S	协方差矩阵+切空间+SVM	—
	XT_S	xDAWN 滤波协方差矩阵+切空间+SVM	4, 8
基准	CSP_S	CSP+SVM	4, 8
	Incept	EEGINception	—
	Netv4	EEGNetv4	—
	SFBCSP	ShallowFBCSPNet	—

### 3 实验结果与讨论

模型分类结果如图 4 所示,图 4a 为使用 1.4 s 完整数据段的 MSIT 任务认知负荷检测结果,图 4b 为截取刺激时间点后的 1.2 s 数据段的检测结果.可以看到,只包含刺激点后数据的样本在被试内检测和跨被试检测的 ROC AUC 差值明显小于完整数据样本的 ROC AUC 差值,并且跨被试分类性能在两种数据样本实验中相差不大,区别

主要在被试内检测中.如图 4a 所示, X8\_MDM (滤波器数量为 8 的 X\_MDM 模型) 在被试内取得 0.851 4 的最优结果,但在 LOSO 跨被试检测中 ROC AUC 仅为 0.780 8.而在图 4b 中, X8\_MDM 在被试内结果大幅降为 0.806 2, LOSO 检测中的 0.772 2 降幅则小很多.考虑到刺激点前并没有任务触发,说明模型在跨被试检测中可以识别到认知负荷相关的特征,而被试内检测更容易识别到任务不相关的特征,例如个体的个性化大脑指纹特征.

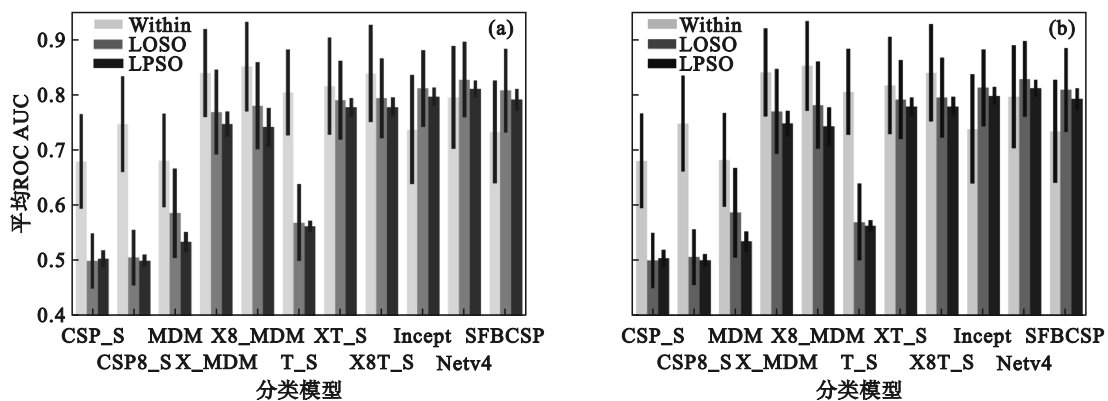


图 4 模型在不同评估模式下的分类性能对比

Fig. 4 Comparison of model classification performance under different evaluation modes

(a) —完整数据(-0.2 s~1.2 s); (b) —刺激点后数据(0~1.2 s).

综合两种数据输入的模型性能结果,尤其是跨被试测试结果,基于黎曼几何的方法优于基于CSP的基准模型,这证实了基于黎曼方法进行认知负荷检测有效性的假设.对比MDM和切空间方法,切空间方法优于MDM方法.如图4b所示,X8T\_S在LOSO跨被试测试中取得了0.790 1的ROC AUC值,虽然低于X8\_MDM被试内最优的0.806 2,但X8\_MDM的跨被试测试的ROC AUC值仅为0.772 2.这说明X8\_MDM方法更适合于被试内检测,而X8T\_S方法更适合于跨被试检测.另外,图中显示xDAWN空间滤波器对于任务负荷检测具有关键作用,对比MDM和X\_MDM,以及T\_S和XT\_S,可以见到显著的ROC AUC提升.考虑xDAWN空间滤波器数量,X8\_MDM相对于X\_MDM,以及X8T\_S相对于XT\_S的ROC AUC略微提升,例如在图4b中,XT\_S在LOSO中取得了0.780 8的ROC AUC值,比X8T\_S的0.790 1低0.009 3.对于CSP的滤波器数量,除了被试内测试,跨被试测试并未表现出性能提升.从图中可以看到,鉴于深度学习模型卓越的特征表征能力,不论是否包含刺激点前数据,3种深度学习模型在LOSO或LPSO跨被试试验的分类性能均优于基于黎曼空间的最优X8T\_S方法,其中以EEGNetv4的ROC AUC最高.以LOSO为例,EEGNetv4在刺激点后1.2 s的数据上取得0.822 6的ROC AUC,高于X8T\_S的0.790 1.但在被试内试验中,深度学习模型则均低于黎曼空间中最优的X8\_MDM和次优的X8T\_S方法.这可能是由于单个被试的样本量较小(<200),复杂模型容易过拟合.这表明基于黎曼空间的方法具有更高的

鲁棒性,尤其对于样本量受限的情况.

为了综合评价模型的能力,实验对比了黎曼方法模型的执行时间,即预测阶段耗时.按样本量平均,得到单个测试样本的推理时间.以刺激点后1.2 s的数据段实验为例,模型在NVIDIA GeForce RTX 4060平台上的用时如表2所示.执行时间最短的是LPSO中的X\_MDM,平均每个样本耗时0.652 ms,而LOSO中的T\_S所用时间最长(12.746 ms).这可能与训练时模型拟合需要的迭代次数有关.综合考虑模型分类ROC AUC和模型的性能,实验结果表明X8\_MDM模型适合于被试内检测,而X8T\_S适合于跨被试检测.在跨被试检测中,XT\_S可以较小的ROC AUC代价节省约50%的时间.值得注意的是,3种深度学习模型的运行时间显著大于其他方法,即使是以轻量化为目标的SFBCSP模型也是X8T\_S的3倍多.而X8T\_S模型在LOSO分类任务中达到了0.790 1的ROC AUC,与SFBCSP方法的0.801 6表现接近,表明基于黎曼空间的方法在分类性能与计算效率之间实现了良好的平衡.此外,实验还测试了SVM分类器的核函数对认知负荷检测的影响.如表3所示,RBF是一种常用的非线性核函数,与前文基于线性核函数的模型的ROC AUC结果(均值±标准差)进行对比发现:以刺激后数据段在LPSO测试下的结果为例,除T\_S模型外,不论是CSP特征还是切空间特征,RBF核函数均未明显提升分类ROC AUC值,甚至有所降低.T\_S模型虽然有部分提升(0.602 1),但数值仍然较低.结果表明,相对于线性核函数,SVM非线性核函数并未显著提升认知负荷检测能力.

表2 平均每个样本的模型执行时间  
Table 2 Average model execution time per sample

模式	MDM	X_MDM	X8_MDM	T_S	XT_S	X8T_S	Incept	Netv4	SFBCSP
Within	2.888	1.315	2.126	3.109	1.327	2.158	16.769	12.773	6.361
LOSO	3.448	0.663	1.448	12.746	0.917	2.78	38.616	13.426	8.535
LPSO	3.415	0.652	1.379	9.791	0.867	2.449	38.435	12.238	8.314

表3 SVM核函数性能比较(ROC AUC)  
Table 3 Performance comparison of SVM kernel functions (ROC AUC)

SVM核	CSP	CSP8	T	XT	X8T
线性	0.510 2±0.016 1	0.505 6±0.009 7	0.565 8±0.007 3	0.768 8±0.015 8	0.771 3±0.013 8
RBF	0.505 7±0.018 5	0.511 2±0.013 7	0.602 1±0.012 0	0.766 1±0.012 7	0.770 0±0.013 0

针对结果中的两个模型(被试内测试最优的X8\_MDM和LOSO跨被试最优的X8T\_S),检索了相关研究文献,如表4所示,本文所采用的被试数量多于其他对比研究,具备更强的样本代表性

与统计可靠性.M-CV (mixed-subject cross-validation)表示所有被试的所有样本进行交叉验证,是目前文献中的常见形式.虽然其准确率在90%左右,但由于没有确保测试样本来自训练阶

段不可见的被试,其结果并非真正意义上的跨被试分类性能.CNN\_DG方法仅取得了60.60%的准确率,而CDA达到98.18%的高准确率,但其仅有13名被试,每个试次长达3.5 s(记忆编码和保持期间的脑电图).该模型计算复杂度较高,原始文献虽未明确列出训练或推理时间,但远达不到所提出的X8T\_S方法的计算效率.X8T\_S方法以较高的计算效率取得了较高的ROC AUC值,很好地平衡了计算精度与成本.现有被试内测试多采用传统的手工特征提取与机器学习方法.相比

之下,本文提出的X8\_MDM模型尽管在分类性能上略低于部分方法,但其端到端的识别流程有效减少了人工特征工程的复杂性,提高了模型的自动化程度.此外,本文所选被试群体平均年龄约为55岁,属于中年人群,更容易在高负荷工作条件下出现认知或健康问题;而对比研究中多为平均年龄20余岁的年轻健康被试.因此,本文的研究成果在中年人群认知负荷监测与健康风险评估方面具有更高的实际应用价值.

表4 本文方法(1.2 s数据)与其他方法在EEG认知负荷分类任务中的性能比较

Table 4 Performance comparison of the proposed method (1.2 s data) with other methods in EEG cognitive load classification tasks

模式	方法	被试	任务	准确率/%	灵敏度/%	特异性/%	ROC AUC
M-CV	DWT SVM <sup>[27]</sup>	26	N-back	87.89	—	—	—
	MuLHiTA <sup>[28]</sup>	20	MSIT	93.58	93.63	—	0.993 2
LOSO	CNN_DG <sup>[2]</sup>	15	MATB II	60.60	—	—	—
	CDA <sup>[4]</sup>	13	工作记忆	98.18	—	—	—
	X8T_S	50	MSIT	—	—	—	0.790 1
Within	RBF SVM <sup>[29]</sup>	22	MSIT	88.69	87.60	89.70	0.951 0
	功能脑网络 <sup>[30]</sup>	10	MSIT	89.72	93.66	90.21	—
	X8_MDM	50	MSIT	—	—	—	0.806 2

## 4 结 论

1) 本文提出的基于xDawn空间滤波与黎曼几何方法相结合的认知负荷检测框架,在多个评估设置下展现出优越性能.与传统的非黎曼空间特征提取方法相比,MDM与切空间方法在认知负荷分类任务中表现出更高的鲁棒性与精度,验证了黎曼流形方法的优势.

2) 针对50名中年被试的1.2 s长的MSIT任务EEG数据,X8T\_S的LOSO跨被试分类效果最好,达到了0.790 1的ROC AUC;而X8\_MDM在被试内分类效果最好,达到了0.806 2的ROC AUC.所提方法能够稳健地识别与任务负荷相关的关键特征.

3) 消融实验表明,xDAWN空间滤波器可以大幅度提升任务负荷检测的ROC AUC值.

4) 所提方法具有良好的计算效率与泛化能力,具备在实时认知状态监测、人机交互界面设计优化以及长期神经状态追踪等实际场景中的应用潜力,具有重要的科研与工程价值.

### 参考文献:

[1] Antonenko P, Paas F, Grabner R, et al. Using

electroencephalography to measure cognitive load [J]. *Educational Psychology Review*, 2010, 22(4): 425-438.

[2] 周月莹, 公沛良, 王澎湃, 等. 基于卷积神经网络和领域泛化的跨操作员认知负荷识别[J]. *电子与信息学报*, 2023, 45(8): 2796-2805.

(Zhou Yue-ying, Gong Pei-liang, Wang Peng-pai, et al. Cross-operator cognitive workload recognition based on convolutional neural network and domain generalization[J]. *Journal of Electronics & Information Technology*, 2023, 45(8): 2796-2805.)

[3] Paas F, Tuovinen J E, Tabbers H, et al. Cognitive load measurement as a means to advance cognitive load theory [M]. Routledge: *Cognitive Load Theory*, 2016: 63-71.

[4] Jiménez-Guarneros M, Gómez-Gil P. Custom domain adaptation: a new method for cross-subject, EEG-based cognitive load recognition [J]. *IEEE Signal Processing Letters*, 2020, 27: 750-754.

[5] Roy Y, Banville H, Albuquerque I, et al. Deep learning-based electroencephalography analysis: a systematic review [J]. *Journal of Neural Engineering*, 2019, 16(5): 051001.

[6] 肖晓琳, 辛风然, 梅杰, 等. 自适应脑机接口研究综述 [J]. *电子与信息学报*, 2023, 45(7): 2386-2394.

(Xiao Xiao-lin, Xin Feng-ran, Mei Jie, et al. A review of adaptive brain-computer interface research [J]. *Journal of Electronics & Information Technology*, 2023, 45(7): 2386-2394.)

[7] Congedo M, Barachant A, Bhatia R. Riemannian geometry for EEG-based brain-computer interfaces: a primer and a review [J]. *Brain-Computer Interfaces*, 2017, 4(3): 155-174.

[8] Arsigny V, Fillard P, Pennec X, et al. Geometric means in a novel vector space structure on symmetric positive-definite matrices [J]. *SIAM Journal on Matrix Analysis and*

- Applications*, 2007, 29(1): 328–347.
- [9] Ding X T, Yang L, Li C S. Study of MI-BCI classification method based on the Riemannian transform of personalized EEG spatiotemporal features [J]. *Mathematical Biosciences and Engineering*, 2023, 20(7): 12454–12471.
- [10] Gaur P, Pachori R B, Wang H, et al. A multi-class EEG-based BCI classification using multivariate empirical mode decomposition based filtering and Riemannian geometry [J]. *Expert Systems with Applications*, 2018, 95: 201–211.
- [11] Ming Z Y, Zhang D Y, Liu S Y, et al. Exploring the feasibility of single-frequency multi-target SSVEP-based BCI for online control [C]//2023 17th International Conference on Complex Medical Engineering (CME). Suzhou, 2024: 1–5.
- [12] Chevallier S, Kalunga E K, Barthélemy Q, et al. Review of Riemannian distances and divergences, applied to SSVEP-based BCI [J]. *Neuroinformatics*, 2021, 19(1): 93–106.
- [13] 徐慧, 何宏, 张慧敏, 等. 黎曼流形切平面空间中运动想象脑电信号的迁移学习 [J]. *中国生物医学工程学报*, 2023, 42(6): 659–667.  
(Xu Hui, He Hong, Zhang Hui-min, et al. Transfer learning for motor imagery EEG signals in Riemannian manifold tangent space [J]. *Chinese Journal of Biomedical Engineering*, 2023, 42(6): 659–667.)
- [14] Zhao C L, Dong E Z, Tong J G, et al. Machine learning classification of Riemannian tangent spaces based on MI-BCI [C]//2023 IEEE International Conference on Mechatronics and Automation (ICMA). Harbin, 2023: 807–812.
- [15] Guigui N, Miolane N, Pennec X. Introduction to Riemannian geometry and geometric statistics: from basic theory to implementation with geomstats [J]. *Foundations and Trends in Machine Learning*, 2023, 16(3): 329–493.
- [16] Raninen E. Oracle approximating shrinkage covariance matrix estimators for complex elliptical distributions [C]//2024 32nd European Signal Processing Conference (EUSIPCO). Lyon, 2024: 2717–2721.
- [17] Arsigny V, Fillard P, Pennec X, et al. Log-Euclidean metrics for fast and simple calculus on diffusion tensors [J]. *Magnetic Resonance in Medicine*, 2006, 56(2): 411–421.
- [18] Dzianok P, Kublik E. PEARL-Neuro database: EEG, fMRI, health and lifestyle data of middle-aged people at risk of dementia [J]. *Scientific Data*, 2024, 11: 276.
- [19] Cui Y J, Xie S Y, Xie X Z, et al. LDER: a classification framework based on ERP enhancement in RSVP task [J]. *Journal of Neural Engineering*, 2023, 20(3): 036029.
- [20] Wang H T, Wang Z H, Sun Y, et al. A cascade xDAWN EEGNet structure for unified visual-evoked related potential detection [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2024, 32: 2270–2280.
- [21] Wei Q G, Ding X J. Intra- and inter-subject common spatial pattern for reducing calibration effort in MI-based BCI [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, 31: 904–916.
- [22] 刘冲, 赵海滨, 李春胜, 等. 基于CSP与SVM算法的运动想象脑电信号分类 [J]. *东北大学学报(自然科学版)*, 2010, 31(8): 1098–1101.  
(Liu Chong, Zhao Hai-bin, Li Chun-sheng, et al. CSP/SVM-based EEG classification of imagined hand movements [J]. *Journal of Northeastern University (Natural Science)*, 2010, 31(8): 1098–1101.)
- [23] Santamaria-Vazquez E, Martínez-Cagigal V, Vaquerizo-Villar F, et al. EEG-inception: a novel deep convolutional neural network for assistive ERP-based brain-computer interfaces [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 28(12): 2773–2782.
- [24] Lawhern V J, Solon A J, Waytowich N R, et al. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces [J]. *Journal of Neural Engineering*, 2018, 15(5): 056013.
- [25] Schirrneister R T, Springenberg J T, Fiederer L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization [J]. *Human Brain Mapping*, 2017, 38(11): 5391–5420.
- [26] Jayaram V, Barachant A. MOABB: trustworthy algorithm benchmarking for BCIs [J]. *Journal of Neural Engineering*, 2018, 15(6): 066011.
- [27] Khanam F, Hossain A B M A, Ahmad M. Electroencephalogram-based cognitive load level classification using wavelet decomposition and support vector machine [J]. *Brain-Computer Interfaces*, 2023, 10(1): 1–15.
- [28] Xia L K, Feng Y, Guo Z H, et al. MuLHiTA: a novel multiclass classification framework with multibranch LSTM and hierarchical temporal attention for early detection of mental stress [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(12): 9657–9670.
- [29] Al-Shargie F, Tang T B, Kiguchi M. Stress assessment based on decision fusion of EEG and fNIRS signals [J]. *IEEE Access*, 2017, 5: 19889–19896.
- [30] Avvaru S, Provenza N R, Widge A S, et al. Decoding human cognitive control using functional connectivity of local field potentials [C]//2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). Guadalajara, 2021: 451–454.