



# 南京大學

## 研究生畢業論文 (申請碩士學位)

論 文 題 目         基于卷积神经网络的脑电信号识别研究

        及脑机接口应用

作 者 姓 名         卜宇轩

学 科、专 业 方 向         计算机科学与技术

研 究 方 向         人工智能

指 导 教 师         申富饶 教授, 吴楠 副教授

2021 年 5 月 31 日

学 号：**MG1833002**

论文答辩日期：**2021 年 5 月 20 日**

指 导 教 师：

(签字)

# EEG Recognition Based on Convolutional Neural Network

by

**Yuxuan Bu**

Supervised by

Furao shen

A dissertation submitted to  
the graduate school of Nanjing University  
in partial fulfilment of the requirements for the degree of  
MASTER  
in  
Computer Science and Technology



Department of Computer Science and Technology  
Nanjing University

May 2021



# 南京大学研究生毕业论文中文摘要首页用纸

毕业论文题目： 基于卷积神经网络的脑电信号识别研究  
及脑机接口应用

---

计算机科学与技术 专业 2018 级硕士生姓名： 卜宇轩

指导教师（姓名、职称）： 申富饶 教授， 吴楠 副教授

## 摘 要

脑电信号作为一种重要的生物信号，在医疗、娱乐、机械辅助、监控等各行各业都有着极为广泛的应用。通过对脑电信号数据的分析和挖掘，可以将人脑电信号翻译为外在的行动指令，实现脑与设备的信息交互。

然而，由于脑电信号本身的特殊性以及复杂环境下获取脑电信号呈现的特点，脑电信号识别目前仍面临诸多挑战。一方面，脑电信号有别于一般的数据，其自身的特殊性带来两方面的问题。首先，脑电信号本身极为微弱，即使在实验室环境下也极易受到噪声干扰，具有低信噪比的特点，进行识别时应充分考虑这种低信噪比；此外，脑电信号作为生物信号，从不同被试采集得到的脑电信号数据往往因人而异，数据分布存在严重差异。一般的脑电信号识别方法都需要具有一定的跨被试泛化能力，而如何克服这种个体间的数据分布差异是脑电信号识别独有的技术难点。另一方面，有别于传统的图像识别，语音识别，获取脑电数据的条件更为苛刻，训练数据有限，如何从有限的数据实现高精度的分类和识别是脑电信号识别所面临的又一挑战。

为了解决上述脑电信号识别任务存在的低信噪比、个体差异、训练数据有限等问题，针对基于脑电识别的脑机接口系统，本文以卷积神经网络为基础模型，提出了两种脑电信号识别方法，分别面向二分类任务和多分类任务并成功应用到了实际的脑机接口系统中。主要内容如下：

本文提出一种基于度量学习和自动编码器的卷积神经网络。该方法使用卷积神经网络作为基础模型。卷积神经网络拥有从脑电信号中有效地学习时间和空间特征的能力，节省了繁杂的预处理步骤。自动编码器则具有数据压缩能力，可以学到数据的潜在表征。通过融合深度度量学习（DML），该方法能够学习原始脑电数据中保留了分类信息的潜在表征。通过在多个公开数据集上的实验，证明了该模型优于传统的 FBCSP 算法和流行的神经网络 (EEGNet)。

通过特征可视化，验证了基于自动编码器的深度度量学习在脑电识别领域的可行性。

本文提出了一种黎曼网络结构，为对称正定矩阵（SPD 矩阵）的深层非线性学习开辟了一个新的方向。SPD 矩阵经常被用于脑电信号识别中作为特征，但是过去对 SPD 矩阵的使用往往是简单地基于度量的分类，没有深层次探索 SPD 矩阵的表示能力。首先，效仿卷积网络中的卷积层将输入 SPD 矩阵转换为更理想的 SPD 矩阵，并对新的 SPD 矩阵应用非线性激活函数，然后设计了一个特征值对数层对规则输出层的 SPD 矩阵进行黎曼计算。为了训练所提出的深度网络，在 SPD 流形上利用一种新的随机梯度下降反向传播来更新结构化连接权值和所涉及的 SPD 矩阵数据。实验结果表明，在典型的脑电数据分类任务中，所提出的 SPD 矩阵网络训练简单，性能优于现有的 SPD 矩阵学习和最新的方法。

本文提出的两种脑电识别方法成功地应用在了实际生产环境中。本文根据脑机接口系统的客观要求，在保证脑电识别精度同时，提升了跨被试泛化能力和数据受限情况下的学习能力。

相关的实验表明，本文提出的两种方法的有效性，并且相比较于已有的脑电识别手段，其准确率更高，跨被试泛化能力更强。在相关应用实践中，本文的识别方法也表现出了较高的识别精度，充分证明了其实用价值。最后按照本文的工作路线，也可以继续开展相关的研究工作。

**关键词：**卷积神经网络；脑电信号识别；脑机接口；黎曼流形

## 南京大学研究生毕业论文英文摘要首页用纸

THESIS: EEG Recognition Based on Convolutional Neural Network

SPECIALIZATION: Computer Science and Technology

POSTGRADUATE: Yuxuan Bu

MENTOR: Furao shen

### **Abstract**

As an important biological signal, EEG signals are widely used in various industries such as medical treatment, entertainment, mechanical assistance, and monitoring. The analysis and mining of EEG signal data can translate human EEG signals into external action instructions and realize the information interaction between the brain and the device.

However, due to the particularity of the EEG signal itself and the characteristics of the EEG signal obtained in a complex environment, EEG signal recognition still faces many challenges. On the one hand, the EEG signal is different from ordinary data, and its own particularity brings about two problems. First of all, the EEG signal itself is extremely weak, Even in the laboratory environment, it is extremely susceptible to noise interference and has the characteristics of low signal-to-noise ratio. This low signal-to-noise ratio should be fully considered when identifying; In addition, the EEG signal is a biological signal, and the EEG signal data collected from different subjects often varies from person to person, and there are serious differences in data distribution. General EEG signal recognition methods need to have a certain ability to generalize across subjects, and how to overcome this difference in data distribution between individuals is brain telecommunications Number recognition unique technical difficulties. On the other hand, different from traditional image recognition and speech recognition, the conditions for obtaining EEG data are more demanding. Data is limited. How to achieve high-precision classification and recognition from limited data is another challenge faced by EEG signal recognition.

In order to solve the problems of low signal-to-noise ratio, individual differences, and limited training data in the above-mentioned EEG signal recognition task, the brain-

computer based on EEG recognition Interface system. Based on the convolutional neural network model, this article proposes two EEG signal recognition methods, and successfully applied them to the actual brain-computer interface In the system. The main contents are as follows:

1. This paper proposes a convolutional neural network based on metric learning and autoencoder. This method uses a convolutional neural network as the base model. Convolutional neural networks have the ability to effectively learn temporal and spatial features from EEG signals, saving complicated preprocessing steps. Autoencoder can efficiently learn for data compression and classification tasks simultaneously and can learn the potential characterization of the data. In this way, the proposed method is able to learn latent representations that preserve discriminative information of the original EEG data by fusing deep metric learning (DML). Through experiments on the BCI IV 2a data set, it is proved that the model is superior to the traditional FBCSP algorithm and popular Network (EEGNet). Through feature visualization, the feasibility of deep metric learning based on autoencoder in the field of EEG recognition is verified.
2. This paper proposes a Riemannian network structure, which opens up a new direction for deep nonlinear learning of symmetric positive definite matrices (SPD matrices). SPD Matrix is often used as a feature in the recognition of EEG signals, but in the past the use of SPD matrix is often simply a classification based on metrics, without in-depth exploration of the representation ability . First, imitating the convolutional layer in the convolutional network, a bilinear mapping layer is designed to convert the input SPD matrix into a more ideal SPD matrix. The eigenvalue correction layer is used to apply a nonlinear activation function to the new SPD matrix, and an eigenvalue logarithmic layer is designed to perform Riemannian analysis on the SPD matrix of the regular output layer. In order to train the proposed deep network, a new stochastic gradient descent backpropagation is used on the SPD manifold to update the structured connection weights and the SPD matrix data involved. The experimental results show that in three typical EEG data classification tasks, the proposed SPD matrix network is simple to train and the performance is better than the existing SPD matrix learning and the latest methods.
3. The two EEG identification methods proposed in this paper have been success-

fully applied in actual production environments. In accordance with the objective requirements of the brain-computer interface system, this paper improves the inter-subject generalization ability and the learning ability in the case of limited data while ensuring the accuracy of EEG recognition.

Experiments show that the two methods proposed in this article are effective, and compared with the existing EEG recognition methods, their accuracy is higher and inter-subjects generalization ability is better. In the relevant application practice, the recognition method in this paper also showed a high recognition accuracy, which fully proved its practical value. Finally, according to the work line of this article, we can continue to carry out related research work.

**keywords:** Convolutional neural network; EEG signal recognition; Brain-computer interface; Metric learning



# 目 次

目 次 .....	11
插图清单 .....	13
附表清单 .....	15
<b>1 绪论 .....</b>	<b>1</b>
1.1 研究背景及意义 .....	1
1.2 研究现状和研究难点 .....	2
1.3 研究内容 .....	4
1.4 论文纲要 .....	5
<b>2 脑机接口的相关工作 .....</b>	<b>7</b>
2.1 脑电信号识别和脑机接口 .....	7
2.1.1 脑机接口的实验范式 .....	8
2.1.2 脑电信号特征 .....	10
2.2 机器学习方法 .....	11
2.3 基于黎曼几何的分类方法 .....	12
2.4 深度学习方法 .....	14
2.4.1 卷积神经网络和受限玻尔兹曼机 .....	15
2.4.2 深度学习的应用 .....	17
2.5 本章小结 .....	19
<b>3 融合度量学习和自动编码器的卷积网络模型设计 .....</b>	<b>21</b>
3.1 融合度量学习的模型设计思路 .....	21
3.2 融合度量学习的卷积网络结构 .....	23
3.3 实验与分析 .....	27
3.3.1 数据集介绍 .....	27
3.3.2 对比实验 .....	28

3.3.3 度量学习有效性验证实验 .....	31
3.3.4 超参数评估实验 .....	32
3.4 本章小结 .....	35
<b>4 应用于脑电识别的黎曼卷积网络 .....</b>	<b>37</b>
4.1 现有黎曼几何方法的局限性 .....	37
4.2 结合黎曼几何的卷积网络设计 .....	39
4.2.1 结合黎曼几何的卷积结构 .....	39
4.2.2 整体设计 .....	41
4.2.3 优化算法 .....	42
4.3 实验与分析 .....	43
4.3.1 数据集介绍 .....	43
4.3.2 二分类对比实验 .....	44
4.3.3 多分类实验 .....	47
4.3.4 黎曼结构有效性评估实验 .....	48
4.4 本章小结 .....	49
<b>5 应用：脑控机器人小车系统 .....</b>	<b>51</b>
5.1 运动想象脑机接口背景 .....	51
5.2 基于运动想象的脑控机器人小车系统 .....	52
5.2.1 系统需求 .....	52
5.2.2 使用流程 .....	53
5.3 系统架构和实现 .....	54
5.3.1 数据采集模块 .....	55
5.3.2 在线识别模块 .....	56
5.3.3 离线评估模块 .....	57
5.4 系统应用反馈 .....	58
5.5 本章小结 .....	61
<b>6 总结与展望 .....</b>	<b>63</b>
<b>参考文献 .....</b>	<b>65</b>
<b>简历与科研成果 .....</b>	<b>73</b>

目 次	13
致 谢 .....	<b>75</b>



# 插图清单

2-1	脑机接口系统示意 .....	8
2-2	稳态视觉诱发电位 .....	8
2-3	p300 示意 .....	9
2-4	不同运动想象任务激活脑区示意 .....	9
2-5	黎曼流形示意 .....	12
2-6	RMDM 算法示意 .....	13
2-7	卷积层的三维结构表示 .....	15
2-8	一个有 7 个变量的受限玻尔兹曼机 .....	16
3-1	自动编码器模型架构 .....	24
3-2	电极信道示意 .....	28
4-1	黎曼流形和切平面示意 .....	40
4-2	黎曼卷积块示意 .....	41
4-3	黎曼卷积提取特征可视化 .....	46
5-1	使用流程图 .....	53
5-2	一次数据采集示意 .....	54
5-3	epocX 脑电数据采集设备和 cykit 即时数据流 .....	56
5-4	离线评估模块 .....	58
5-5	屏幕提示右手运动想象 .....	59
5-6	屏幕显示正在左手运动想象 .....	59
5-7	四分类脑电识别命令行演示 .....	60



# 附表清单

3-1	模型整体架构参数 .....	26
3-2	DML-AE 模型对比实验结果 .....	29
3-3	DML-AE 模型运行时间对比实验结果 .....	31
3-4	深度度量学习有效性评估实验结果 .....	32
3-5	超参数设置 .....	33
3-6	margin 的参数选择影响 .....	34
4-1	RG-CNN 模型对比实验结果 .....	45
4-2	OpenBMI 数据集多分类任务黎曼卷积结构实验结果 .....	47
4-3	BCIC IV 2b 数据集多分类任务黎曼卷积结构实验结果 .....	48
4-4	黎曼结构有效性评估实验结果 .....	49
5-1	脑机接口控制小车系统实际环境实验结果 .....	60



# 第一章 绪论

## 1.1 研究背景及意义

脑电信号 (Electroencephalography, EEG) 是脑神经细胞电生理活动在大脑皮层或头皮表面的总体反映。作为一种人体生物数据,脑电信号在临床医学、心理学、神经科学以及神经工程学等方面都有着广泛的应用。其中,基于脑电信号的脑机接口技术近年来越来越引起人们关注。

脑机接口 (BCI) 是一种在大脑和外部设备之间发送和接收信号的技术。脑机接口收集并解释大脑信号,然后将其传输到连接的机器,该机器执行与接收到的大脑信号相关的命令。基于脑电信号的脑机接口技术的特点是利用无创性的脑电电极测量大脑活动,并将记录的脑信号转换为指令。BCI 通过脑电图检测大脑活动的变化。然后,BCI 技术将这些信号传递给机器学习算法。机器学习算法已经被训练用来提取与某些情绪、动作和表情相关的脑电活动。当算法识别出匹配的脑电活动时,脑机接口可以发送外部命令来控制一个设备(如电脑光标、机械臂或轮椅)。这些设备已经被编程来解释和执行这些命令。以数字接口进行外部动作为例,佩戴脑电图设备的受试者可以思考“向左移动”,光标向左移动。一个使用基于脑电的脑机接口连接到机械臂的受试者可以思考“波动”,机械臂也会随之波动。

然而,由于脑电信号本身的低信噪比和个体差异性,以及脑电信号受限的实验环境,传统的脑电信号识别方法不能够满足当下脑机接口大规模商业应用的需求。因此,如何更为有效的利用脑电数据,建立高效的脑电信号识别模型也就成为了一个重要课题。

脑电信号识别在各个领域都得到了广泛的应用,这些应用不仅仅局限于传统意义上的临床医学,在心理学、神经科学、甚至虚拟现实技术和游戏娱乐等方面都发挥重要作用。以下列举一些新兴的实际应用的场景。

在医疗康复领域,脑机接口<sup>[1]</sup>可以帮助那些无法使用四肢、需要辅助设备或不能说话的人。在神经康复中使用脑机接口有助于提高个人在日常生活中的自理能力。脑机接口通常用于中风或受伤后的康复。在未来,我们可能会看到

BCI 医疗产品用于外科手术或其他医疗操作。脑机接口使有运动障碍的受试者能够利用他们的大脑活动来控制他们周围的物体并进行交流。使用脑电信号的脑机接口可以帮助他们控制假肢或计算机接口。

在教育培训领域，脑机接口可以帮助有注意力缺陷的儿童或成人提升专注力以及情绪调控能力。除此以外，为了安全起见，在车辆行驶过程中预测驾驶员的困倦和警报状态非常重要。通过脑电识别方法可以预测驾驶员的疲惫和警觉状态，并给出警报，一方面锻炼驾驶员的专注力，另一方面作为辅助驾驶的一种手段。

在娱乐交互领域，脑机接口可以将脑电数据中的精神指令“翻译”成视频游戏中的指令。在脑机接口游戏中，受试者在玩虚拟现实游戏时戴着脑电图耳机来控制虚拟物体。在 BCI 游戏中，受试者不使用传统的游戏控制器，而是使用心理指令来启用游戏中基于动作的动作，如“推”、“拉”或“跳”。脑机接口处理来自脑电信号的心理指令，并触发虚拟现实游戏中相应的动作。

以上表明，脑电识别技术具有可行性及必要性，设计能够有效克服低信噪比和用户个体差异性，调试方便的脑电识别算法，有助于脑机交互技术的实际应用和部署，具有强烈的现实意义。

## 1.2 研究现状和研究难点

脑电数据不同于传统机器学习所处理的数据类型，如图像数据、文本数据、语音数据等。脑电数据是从被试者采集得到的生物信息。从真实的人体采集得到的生物特性，决定了对此类数据的识别和分类都有别于其他数据，带来的问题主要存在于以下两方面。

一方面，脑电数据的低信噪比，要求识别算法具有抵抗噪声的能力。脑电波是极微弱的生物电信号，其强度在微伏级。当前的脑电采集硬件，即使在环境干扰较少的实验室环境下，采集得到的脑电数据依旧存在大量噪声。如果使用一般的机器学习算法进行识别，则模型往往受噪声干扰而无法有效在实际环境中使用。

另一方面，脑电数据存在被试个体差异性问题，要求识别算法具有个体无关的泛化性。脑电波作为生物信号，在不同的被试个体采集到的脑电数据分布差异巨大。如果把传统的其他领域的机器学习算法直接套用于脑电信号识别，根据不同被试采集到的所有数据作为整体训练数据，则模型很难学习到准确的

知识。而如果针对每名被试，单独使用其个人的数据来训练模型，虽然识别的准确度提高了，但是每名用户在使用模型前都必须单独采集数据进行训练，失去了模型在不同个体间的迁移性，依据此法搭建的系统也就没有易用性。现阶段，脑电识别算法的难点之一就在于在保持模型识别精度的同时，提升跨被试泛化的能力。

以上两点都是脑电信号作为生物数据本身特性带来的挑战。除此之外，脑电数据本身获取难度较高，与图像数据、文本数据、语音数据等比较起来，呈现高质量开源数据集相对缺乏和实验门槛较高的特点。另外，搭建具有实际使用价值的脑机系统，也要求脑电识别算法可以在短时间内校准完成。具有现实意义的脑电识别算法必须具有在有限的数据集上实现高精度分类的能力。

当前，针对脑机接口系统中，脑电信号识别的问题，主要的方法可以分为以下几大类：传统的基于机器学习的方法、基于矩阵和张量分类的方法以及基于神经网络的方法。

其中，2007年以前，应用于脑机接口的脑电识别算法主要以传统的基于机器学习方法为主。线性分类器使用每个类的特征向量之间的线性决策边界进行分类。它们包括线性判别分析 (LDA) 和支持向量机 (SVM)。LDA 和 SVM 直到现在都是基于 EEG 的脑机接口最流行的分类器，特别是在线实时的脑机接口中被广泛使用。非线性贝叶斯分类器是一种对每一类的概率分布进行建模，并利用贝叶斯规则选择要分配给当前特征向量的类的分类器。这类分类器主要包括贝叶斯二次分类器和隐马尔可夫模型 (HMM)。最近邻分类器根据当前特征向量的最近邻居为其分配一个类。这些邻居可以是训练特征向量或类原型向量。此类分类器包括 k-最近邻 (kNN) 算法或马氏距离分类器。最后，分类器组合是通过组合多个分类器的输出以最大化其互补性的方式对其进行训练来组合多个分类器的算法。当时用于 BCI 的分类器组合包括 boosting、voting 或 stacking 组合算法。分类器组合在离线评估中是基于脑电的脑机接口中性能最好的分类器之一。

这些传统的基于机器学习的方法需要算法设计者精心设计输入的特征。以线性判别分析为例，传统的使用线性判别分析往往需要同时搭配使用共空间模型算法 (CSP) 来提取特征，对数据预处理有较高的要求。另一方面，这些传统的算法缺乏针对跨被试泛化的要求做特殊设计。在跨被试泛化能力上并不理想。

以黎曼几何分类器为代表的基于矩阵和张量的分类算法在 BCI 领域的引

入对经典分类方法中采用的一些惯例提出了挑战；黎曼几何分类器（RGC）不通过空间滤波或其他方法提取特征，而是将数据直接映射到具有合适度量的几何空间。在这样一个空间中，可以轻松地对数据进行各种操作，例如均值、平滑、内插、外推和分类。由于其对数性质，黎曼距离对噪声具有鲁棒性。此外，对称正定矩阵的黎曼距离对矩阵反演和数据的任何线性可逆变换都具有不变性。这些特性，不仅使基于矩阵和张量的分类算法具有很好的泛化性，也使得跨被试的无需校准的脑电识别模型成为了可能。

自从 2012 年以来，深度学习在多个领域，如图像识别<sup>[2]</sup>、语音识别<sup>[3]</sup>、文本分类<sup>[4]</sup> 取得巨大突破。深度学习是一种特殊的机器学习算法，它可以实现端到端的学习，直接从数据中学习特征和分类器。“深度学习”一词是由该模型的体系结构命名的，它基于可训练的特征提取模块和非线性的级联。由于这样的级联，学习到的特征通常与概念的层次增加有关。在深度学习的各大经典模型中，在脑电识别领域，又以卷积神经网络和受限玻尔兹曼机更为流行。

深度学习具有从原始脑电数据中同时学习有效特征和分类器的潜力。考虑到在其他领域的有效性和巨大突破，深度学习在脑电识别领域也被寄予厚望产生更好的特征和分类器，从而实现更为稳健的 EEG 分类。然而，虽然产生了诸如 EEGNet 等优秀的尝试，海量已经发表的研究表明深度学习在脑电识别领域，尤其在用于脑机接口的脑电识别上，并没有颠覆性成果。在其他领域通过堆叠网络层数获得精确度提升不同，在脑电识别受限的数据集下，无法通过简单地重复堆叠网络来提升精度。一项统计表明，浅层的卷积神经网络在脑电数据上的表现甚至比动辄数十层的深层的卷积神经网络更好。因此，本文不是简单复制其他领域的成功经验，而是充分挖掘卷积神经网络的潜力，探索更适合脑电数据的网络结构，使之成功解决上述的挑战和困难。

### 1.3 研究内容

本文主要针对脑电识别，尤其是脑机接口系统中遇到的低信噪比、跨被试泛化问题、训练数据受限等三大困难进行了深入的研究，在充分研究卷积神经网络架构和脑电数据特点以及考虑脑机接口系统客观需求的基础上，提出了对应的解决办法，并成功运用于实际的脑机接口系统中。主要研究内容如下：

首先，本文提出一种基于度量学习和自动编码器的卷积网络模型。该方法使用卷积神经网络作为基础模型。卷积神经网络拥有从脑电信号中有效地学习

时间和空间特征的能力，节省了繁杂的预处理步骤。自动编码器则具有数据压缩能力，可以学到数据的潜在表征。通过融合深度度量学习（DML），该方法能够学习原始脑电数据中保留了分类信息的潜在表征。通过在多个公开数据集上的实验，证明了该模型优于传统的 FBCSP 算法和流行的通用网络 (EEGNet)，验证了基于自动编码器的深度度量学习在脑电识别领域的可行性。

随后，本文提出了一种黎曼卷积网络结构，为对称正定矩阵（SPD 矩阵）的深层非线性学习开辟了一个新的方向。SPD 矩阵经常被用于脑电信号识别中作为特征，但是过去对 SPD 矩阵的使用往往是简单地基于度量的分类，没有深层次探索 SPD 矩阵的表示能力。首先，效仿卷积网络中的卷积层设计了黎曼卷积层，将输入 SPD 矩阵转换为更理想的 SPD 矩阵，利用黎曼激活函数层对新的 SPD 矩阵应用非线性激活函数，并设计了一个特征值对数层对规则输出层的 SPD 矩阵进行黎曼计算。为了训练所提出的深度网络，在 SPD 流形上利用一种新的随机梯度下降反向传播来更新结构化连接权值和所涉及的 SPD 矩阵数据。实验结果表明，在三种典型的脑电数据分类任务中，所提出的 SPD 矩阵网络训练简单，性能优于现有的 SPD 矩阵学习和最新的方法。

本文提出的两种脑电识别方法成功地应用在了实际生产环境中。本文根据脑机接口系统的客观要求，在保证脑电识别精度同时，提升了跨被试泛化能力和数据受限情况下的学习能力。

## 1.4 论文纲要

本文主要研究了基于卷积神经网络的脑电信号识别方法，分别是基于度量学习和自动编码器的卷积神经网络和黎曼卷积神经网络，并在实际的生产环境中得以应用。全文共分为六章：第一章为绪论，主要介绍了研究背景及其意义，和本文的研究内容；第二章介绍了相关的研究工作；第三章主要介绍基于度量学习和自动编码器的卷积神经网络的模型设计以及实验验证；第四章介绍黎曼网络的模型设计及实验验证；第五章主要介绍脑机接口系统中的应用和实现；第六章总结全文，并对未来工作进行了展望。



## 第二章 脑机接口的相关工作

脑电信号识别的研究由来已久，自 19 世纪 90 年代以来，基于脑电识别的脑机接口的阶段性成果不断涌现，各种各样的识别方法和模型不断被提出。早期，脑电信号的识别方法主要是基于一些经典的机器学习算法和信号处理方法发展而来。后来，针对脑电数据本身的特点，基于矩阵和张量的分类方法在 2010 年后被提出，并逐渐受到重视。近期，被冠以深度学习之名的神经网络方法在计算机视觉、语音识别和自然语言处理等领域迅速崛起，深度神经网络被引入脑电识别领域，并被寄予厚望。

本章将主要介绍脑电信号识别相关的背景知识和基本概念，并总结在此领域中有一定代表性的研究工作，分析这些方法各自的优势以及局限性，为引入本文提出的识别方法打下良好基础。

### 2.1 脑电信号识别和脑机接口

脑机接口 (BCI) 是一个将用户的大脑活动模式转换为交互式应用程序的消息或命令的系统。BCI 使用者通常通过脑电图 (EEG) 来测量大脑活动。例如，BCI 可以使用户通过分别想象左手或右手的移动，无需肢体行为即可控制外部设备。

使用脑机接口通常需要两个阶段：(1) 离线训练阶段，在此期间对系统进行校准；(2) 操作在线阶段，在此阶段，系统可以识别大脑活动模式并将其转换为计算机的命令。在线脑机接口系统是一个闭环系统，首先由用户产生特定的脑电模式（例如，使用运动想象）并测量这些脑电信号。然后，通常使用各种空间和频谱滤波器对 EEG 信号进行预处理，并从这些信号中提取特征，以便以恰当的形式表示它们。最后，对这些脑电特征进行分类，将这些脑电特征转化为应用程序的命令，向用户提供反馈以告知他们是否识别出特定的精神命令。

尽管目前正在努力实现无需校准的脑机接口系统，但离线校准目前仍然占据主流，并且在大多数 BCI 中是实验可靠系统所必需的。在这一阶段，对分类

算法进行校正，并从多个脑电通道中选择最优特征。对于该校准，需要从用户处预先记录训练数据集。脑电信号具有高度的用户特异性，因此，目前大多数脑机接口系统都是专门为每个用户校准的。该训练数据集包含用户根据给定的指令多次执行感兴趣的每项脑力任务时记录的脑电信号。

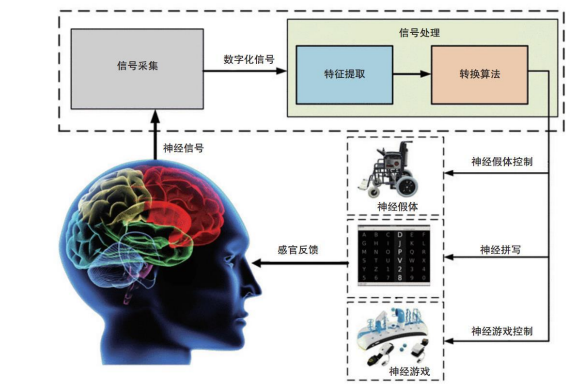


图 2-1: 脑机接口系统示意

### 2.1.1 脑机接口的实验范式

基于脑电信号的脑机接口研究由来已久，在长期的发展中，逐渐形成了三大实验范式，分别是稳态视觉诱发电位实验范式、P300 实验范式以及运动想象实验范式。

基于稳态视觉诱发电位 (Steady-state visual evoked potentials, SSVEP)<sup>[5]</sup> 的 BCI 系统，是目前最常用的头皮脑电 BCI 系统之一。其所使用的 SSVEP 是一种通过向被试呈现以一定频率快速闪烁的刺激块，然后在头皮上记录到与刺激频率倍频相同的稳态脑电响应。




图 2-2: 稳态视觉诱发电位

如图 2-2 所示，给被试呈现了以 12Hz 闪烁的刺激块时，其 EEG 在频域与时域的波形显示。可清楚观察到明显的峰值在 12,24,36,48Hz，即就是 1,2,3,4 倍频处。由于 SSVEP 具有显著的频率特征，基于频率的特征提取方法被广泛采用。

基于 P300<sup>[6]</sup> 的 BCI 系统是以事件相关电位 (event-related potential, ERP) 中的 P300 作为目标信号的脑机接口系统。P300 电位是与大脑决策过程相关的 ERP 成分, 反映着大脑对外界刺激的评价与分类过程。从 EEG 的时域图来看, 是指大脑接受目标刺激大概 250-500ms 内呈现的正向偏移电位。




图 2-3: p300 示意

如图 2-3 所示, P300 是在事件 (如听觉、视觉刺激) 发生后大约 300ms 出现的一个正向波, 它是以  $\delta$ (0.5-4Hz) 脑波和  $\theta$ (4-7.5Hz) 脑波响应的融合。

基于运动想象<sup>[7]</sup> 的脑机接口系统是通过检测用户想象运动时产生的脑电波来判断用户意图, 进而实现人脑与外部设备之间的直接通信与控制。被试在想象运动的过程中, 大脑皮层会产生两种变化明显的节律信号, 8-15Hz 的  $\mu$  与 18-24Hz 的  $\beta$ 。同时, 大脑皮层对侧运动感觉区的脑电节律能量会明显降低, 而同侧运动感觉区的脑电节律能量增大, 这种现象为事件相关异步 (Event Related Desynchronization, ERD) 和事件相关同步 (Event Related synchronization, ERS)。且不同部位的躯体运动想象与该躯体对应的感觉皮层 ERD/ERS 相关, 也就是说 ERD/ERS 现象存在空间分布特性。也就是因为运动想象 EEG 空间分布的特性, 构成了解码运动想象思维信号的生理基础。




图 2-4: 不同运动想象任务激活脑区示意

如图 2-4 所示, 在进行不同运动想象任务时, 激活的脑区呈现空间分布的特点, 因此, 经常使用空间滤波捕捉脑电信号空间分布上的特征。

### 2.1.2 脑电信号特征

脑电信号 (Electro Encephalogram Gram, EEG) 产生机理复杂, 具备典型的非平稳, 非线性, 微弱性等特点, 准确而快速实现对不同意识活动脑电信号的区分是当前研究的热点和难点, 其中特征提取是关键。目前常用的特征提取方法可以概括分为时域特征提取, 频域特征提取和空间域特征提取三大类。

虽然有许多方法可以作为脑电信号的特征表示, 但用于表示 EEG 信号的两种最常见的特征类型是频带能量特征<sup>[8]</sup>和时间点特征<sup>[9]</sup>。

频带能量特征表示为给定信道中给定频带的脑电信号在给定的时间窗口内的平均能量 (对于许多 BCI 范式通常为 1 秒)。频带能量特征可以用多种方法计算, 并被广泛应用于 BCI 中用于表示 EEG 节奏振幅的变化。因此, 频带能量特征是基于运动想象的脑机接口和致力于解码心理状态 (如心理负荷或情绪) 的被动脑机接口的标准特征, 此外在基于稳态视觉诱发电位 (SSVEP) 的脑机接口中也被经常使用。

时间点特征是来所有通道的脑电样本的串联。通常, 这些特征是在一些预处理 (特别是带通或低通滤波和下采样) 之后提取的。它们是用于分类事件相关电位 (ERP) 的典型特征, 事件相关电位是 EEG 信号在给定的事件/刺激后振幅随时间变化。这些是大多数基于 P300 的 BCI 中使用的特征。

这两种类型的特征都使用空间滤波提取<sup>[10]</sup>。空间滤波将原始传感器信号组合在一起, 从而得到比单个传感器的信噪比更高的信号。空间滤波器可以是数据无关的, 数据无关的空间滤波器通常是根据 EEG 信号穿过皮肤和头骨的物理现象考虑, 比如出名的拉普拉斯滤波或基于逆解的空间滤波。空间滤波器也可以通过以数据驱动和无监督的方式获得, 如主成分分析 (PCA) 或独立成分分析 (ICA)<sup>[11]</sup> 等方法。最后, 空间滤波器可以通过数据驱动和有监督的方式获得, 这也是目前最流行的方法。有监督的空间滤波器包括专用于频带能量特征的公共空间模式 (CSP)<sup>[12]</sup> 以及用于基于时间点特征的 ERP 分类例如 xDAWN<sup>[13]</sup> 或 Fisher 空间滤波器<sup>[14]</sup>。由于这种有监督的空间滤波器在实践中获得了良好的分类性能, 这些算法的诸多变体已经被开发出来, 通过正则化、鲁棒数据平均或新的散度量等改进, 对噪声和非平稳信号更加鲁棒。类似地, 这些方法也被扩展来同时优化光谱和空间滤波器, 例如, 流行的滤波器组 CSP

(FBCSP) 方法<sup>[15]</sup> 和其他方法<sup>[16][17][18]</sup>。

虽然空间滤波后的频带能量或时间点特征提取是目前基于脑电信号的脑机接口中最常用的特征，但其他特征类型已经被探索和使用。首先，越来越多使用的类型是连接性特征<sup>[19]</sup>。这些特征测量来自不同传感器和/或频带的信号之间的相关性或同步性。这可以通过光谱相干性、相位锁定值或定向传递函数等<sup>[20]</sup> 特征来测量。研究人员还探索了各种 EEG 信号复杂性度量或高阶统计量作为 EEG 信号的特征<sup>[21][22][23][24]</sup>。最后，最近的研究也探索了如何用协方差矩阵或张量（即二维或二维以上的阵列和多路阵列）<sup>[25][26][27]</sup> 来表示 EEG 信号，以及如何直接对这些矩阵或张量进行分类，而不是使用特征向量。当使用矩阵或张量分解时，得到的特征是各种传感器数据、时间点或频率的线性组合。因此，暂时没有一个明显的物理解释。

最后，与使用单一特征类型相比，将各种类型的特征（例如，带功率的时间点或带功率与连接性特征）相结合<sup>[22][28][29][30][31][32]</sup>，通常会导致更高的分类精度。组合多个特征类型通常会增加维数；因此需要选择最相关的特征以避免维数灾难。

## 2.2 机器学习方法

之前的章节讲述了很多应用于脑电数据的特征提取方法。而在经过人工精心设计进行的特征工程后，完成可以使用机器学习模型训练得到识别结果。在脑电识别领域中，比较常用的方法包括线性分类器、神经网络、贝叶斯分类器、最近邻分类器等<sup>[33]</sup>。

线性分类器收集使用每个类的特征向量之间的线性决策边界的鉴别分类器。它们包括线性判别分析 (LDA)、正则化 LDA 和支持向量机 (SVM)。LDA 和 SVM 直到现在都是基于 EEG 的脑机接口最流行的分类器，特别是在线和实时脑机接口中被广泛使用。

经典神经网络是人工神经元的集合，神经元的分层排列，可以用来逼近任何非线性决策边界。当时用于脑机接口的最常见的神经网络类型是多层感知器 (MLP)，通常只使用一个或两个隐藏层。其他神经网络类型的探索更边缘，如高斯分类器神经网络或学习矢量量化 (LVQ) 神经网络。

非线性贝叶斯分类器是对每一类的概率分布进行建模，并利用贝叶斯规则选择要分配给当前特征向量的类的分类器。这类分类器主要包括贝叶斯二次分

类器和隐马尔可夫模型 (HMMs)。

最近邻分类器根据当前特征向量的最近邻为其分配一个类。这些邻居可以是训练特征向量或类原型。此类分类器包括 k-最近邻 (kNN) 算法或马氏距离分类器。

最后, 分类器组合是通过组合多个分类器的输出以最大化其互补性的方式对其进行训练来组合多个分类器的算法。当时用于 BCI 的分类器组合包括 boosting、voting 或 stacking 组合算法。分类器组合在离线评估中是基于脑电的脑机接口中性能最好的分类器之一。

传统的机器学习方法大多都是通用于多个机器学习问题的标准分类器。脑电识别方法面临的主要挑战是脑电信号的低信噪比<sup>[34]</sup>, 脑电信号随时间、在用户内部或用户之间的非平稳性<sup>[35]</sup>, 以及训练数据量有限等问题。因为缺乏针对基于脑电的脑机接口的特殊性设计, 传统的用于 BCI 的机器学习方法整体性能较差。

## 2.3 基于黎曼几何的分类方法

黎曼几何在 BCI 领域的引入对经典分类方法中采用的一些惯例提出了挑战。黎曼几何分类器 (RGC) 的思想不是估计空间滤波器或选择特征, 而是将数据直接映射到具有合适度量的几何空间。在这样一个空间中, 数据可以很容易地用于多种目的, 例如平均、平滑、内插、外推和分类。这种映射的原理是基于这样一个假设, 即对于给定的生物状态, 脑电信号源的能量和空间分布可以被认为是固定的, 并且这种信息可以通过协方差矩阵进行编码。黎曼几何研究可以局部线性逼近的光滑曲线空间。曲线空间被称为流形, 它在每个点的线性逼近就是切线空间。在黎曼流形中, 切线空间具有一个点到点平滑变化的内积。这就产生了任意两点之间距离的非欧几里德概念以及任意数量点的质心概念。




图 2-5: 黎曼流形示意

如图 2.5 所示, 一个时间窗的脑电数据被表示为流行空间上的一个点。左

图示意在流形空间上的一个点  $G$  所对应的切平面空间。流形上两点  $C_1$  和  $C_2$  的最短路径是流形上连接两点的测地线，其长度为它们之间的黎曼距离。流形上通过一点的曲线在切线空间上映射为直线。右图， $G$  表示点  $G_1, G_2, G_3, G_4$  的重心，即使自身和四个点之间的距离平方和最小的点。重心在 RGC 中经常被用作给定类的代表。

在 BCI 应用中最常见的矩阵流形中，对称正定 (SPD) 矩阵<sup>[36]</sup> 的流形，以及处理子空间或正交矩阵时的 Stiefel 和 Grassmann 流形<sup>[37]</sup> 被使用最多。利用流形的几何约束，可以很容易地将一些机器学习方法扩展到这些流形上<sup>[38]</sup>。以 SPD 矩阵为例，两个 SPD 矩阵  $C_1$  和  $C_2$  之间的内在距离平方具有一个闭式表达式：

$$\delta^2(C_1, C_2) = \sum_n \log^2 \lambda_n(C_1^{-1}C_2) \quad (2-1)$$

其中  $\lambda_n(\mathbf{M})$  表示矩阵  $M$  的第  $n$  个特征值。对于  $C_1$  和  $C_2$  两个 SPD 矩阵，这个距离是非负的，对称的，当且仅当  $C_1 = C_2$  时才等于零。利用方程 (1) 中的距离， $k$  个 SPD 矩阵  $C_1 \dots C_k$  的质心  $G$ ，也称为几何平均值，是以下优化问题的唯一解。

$$\operatorname{argmin}_G \sum_k \delta^2(C_k, G) \quad (2-2)$$

这个定义类似于算术平均值  $1/K \sum_k C_k$  的定义，当使用欧几里德距离而不是黎曼距离时，它是优化问题 (2-2) 的解。与算术平均数相比，几何平均数没有封闭形式的解。文献<sup>[39]</sup> 提出了一种计算几何平均值的快速而稳健的迭代算法。最简单的 RGC 方法通过简单的最近邻方法对数据进行分类。例如，黎曼最小平均距离 (RMDM) 分类器<sup>[40]</sup> 使用训练数据计算每个类的几何平均值，然后将未标记试验分配给对应于最接近平均值的类 (图 3)。另一类 RGC 包括将数据点投影到切线空间，然后使用常见的分类器，如 LDA、SVM、logistic 回归等<sup>[41][39]</sup>。另一种方法是在切线空间中投影数据，在那里过滤数据 (例如通过 LDA)，然后将数据映射回流形，最终执行 RMDM。




图 2-6: RMDM 算法示意

如图 2-6 所示, RMDM 算法根据训练数据计算每个类的质心  $G_1$  和  $G_2$ 。然后将一个未标记的数据分配给重心最接近的类, 在本例中是  $G_1$ 。RMDM 以相同的方式工作于数据的任何维度、任何数量的类和任何 BCI 范式。它不需要任何空间滤波和特征选择, 也不需要任何参数调整。

像 RMDM 这样的黎曼方法的处理过程比更经典的方法更简单, 涉及的阶段更少。此外, 黎曼分类器同样适用于所有 BCI 范式。不同实验范式下只有数据点在 SPD 流形中的映射方式不同。与大多数分类方法相比, RMDM 方法是无参数的, 也就是说, 它不需要任何参数调整。因此, 黎曼几何为建立简单、更稳健、更精确的预测模型提供了新的工具。

由于其对数性质, 黎曼距离对极值具有鲁棒性。此外, SPD 矩阵的固有黎曼距离对矩阵反演和数据的任何线性可逆变换都是不变的, 应用于 EEG 源的任何干扰都不会改变协方差矩阵之间的距离。这些特性部分解释了为什么黎曼分类方法提供了良好的泛化能力。

如前所述, 脑机接口中的分类通常涉及脑电信号的空间滤波, 然后对滤波后的数据进行分类。这导致了多组参数的独立优化, 即空间滤波器和最终分类器。一些研究已经证明, 可以将这种双重优化问题表述为一个单一的优化问题, 其中空间滤波器和线性分类器的参数同时优化, 并且有可能获得改进的性能。这些方法的关键是直接使用协方差矩阵或其矢量形式作为分类器的输入。

本文提出的一种黎曼神经网络, 将 SPD 矩阵作为深度神经网络的输入, 并在隐藏层中依旧保持了 SPD 矩阵的特性, 将黎曼几何和深度学习两大类方法的优点相结合, 具体将在第四章详细描述。

## 2.4 深度学习方法

深度学习是一种特殊的机器学习算法, 它直接从数据中学习特征和分类器。“深度学习”一词是由该模型的体系结构而命名的, 它基于可训练的特征提取模块和非线性的级联。由于这样的级联, 学习到的特征通常与概念的层次增加有关。在本节中, 我们将讨论用于脑机接口系统中最流行的两种深度学习方法: 卷积神经网络和受限玻尔兹曼机。

### 2.4.1 卷积神经网络和受限玻尔兹曼机

卷积神经网络 (CNN) 是具有至少一个卷积层的前馈神经网络<sup>[42]</sup>, 即信息从输入到隐藏层到输出单向流动的网络。这种卷积层通过卷积将其输入映射到输出。假设输入是具有  $N$  个样本的 1D 信号  $\{x_n\}$ , 其通过大小为  $M$  的 1D 滤波器  $\{h_m\}$  的卷积由下式给出:

$$y(n) = \sum_{i=0}^{M-1} h_i x_{n-i} \quad \forall n = 0, \dots, N-1. \quad (2-3)$$

通过根据维数增加求和的个数, 这个方程可以推广到更高的维数。在卷积运算中也可以独立地使用几个滤波器, 从而增加输出中的信道数。卷积层后面通常是池化层, 通常通过平均或最大运算, 将输出的局部信息聚合为单个值。标准卷积神经网络体系结构通常将其中几个层 (卷积 + 池化层) 堆叠起来, 然后是全连接层充当分类层。在给定结构的情况下, 模型的参数是用于卷积的所有滤波器的权值和全连接层的权值<sup>[43]</sup>。

CNN 通常通过解决以下形式的经验风险最小化问题, 以有监督的方式进行训练:

$$\hat{\mathbf{w}} = \arg \min_{\mathbf{w}} \frac{1}{\ell} \sum_i L(y_i, f_{\mathbf{w}}(\mathbf{x}_i)) + \Omega(\mathbf{w}) \quad (2-4)$$

其中,  $\{\mathbf{x}_i, y_i\}_{i=1}^{\ell}$  是训练数据,  $f_{\mathbf{w}}$  是与卷积网络相关的预测函数,  $L(\cdot, \cdot)$  是衡量  $\mathbf{x}_i$  和  $f_{\mathbf{w}}(\mathbf{x}_i)$  之间差异性的损失函数,  $\Omega$  是针对卷积网络参数的正则化函数。由于使用单个样本的平均损失的特殊形式, 随机梯度下降及其变种是优化深度网络的最常用方法。此外,  $f_{\mathbf{w}}(\cdot)$  的前馈结构允许使用链规则计算任何给定层的梯度。这使得反向传播算法有效地执行。




图 2-7: 卷积层的三维结构表示

在一些领域应用中, 卷积网络非常成功, 因为它们能够学习到与任务最相

关的特征。然而，它们的性能很大程度上取决于它们的体系架构和学习的超参数。

受限玻尔兹曼机 (Restricted Boltzmann Machine, RBM) 是一个二分图结构的无向图模型<sup>[44]</sup>，如图 2-8 所示。受限玻尔兹曼机中的变量也分为隐变量和可观测变量。我们分别用可观测层和隐藏层来表示这两组变量。同一层中的节点之间没有连接，而不同层一个层中的节点与另一层中的所有节点连接，这和两层的全连接神经网络的结构相同。




图 2-8: 一个有 7 个变量的受限玻尔兹曼机

一个受限玻尔兹曼机由  $K_v$  个可观测变量和  $K_h$  个隐变量组成，其定义如下：

- (1) 可观测的随机向量  $\mathbf{v} \in \mathbb{R}^{K_v}$ .
- (2) 隐藏的随机向量  $\mathbf{h} \in \mathbb{R}^{K_h}$ .
- (3) 权重矩阵  $\mathbf{W} \in \mathbb{R}^{K_v \times K_h}$ ，其中每个元素  $w_{ij}$  为可观测变量  $v_i$  和隐变量  $h_j$  之间边的权重。
- (4) 偏置  $\mathbf{a} \in \mathbb{R}^{K_v}$  和  $\mathbf{b} \in \mathbb{R}^{K_h}$ ，其中  $a_i$  为每个可观测的变量  $v_i$  的偏置， $b_j$  为每个隐变量  $h_j$  的偏置。

受限玻尔兹曼机的能量函数定义为

$$\begin{aligned} E(\mathbf{v}, \mathbf{h}) &= -\sum_i a_i v_i - \sum_j b_j h_j - \sum_i \sum_j v_i w_{ij} h_j \\ &= -\mathbf{a}^\top \mathbf{v} - \mathbf{b}^\top \mathbf{h} - \mathbf{v}^\top \mathbf{W} \mathbf{h} \end{aligned} \quad (2-5)$$

受限玻尔兹曼机的联合概率分布  $p(\mathbf{v}, \mathbf{h})$  定义为

$$\begin{aligned} p(\mathbf{v}, \mathbf{h}) &= \frac{1}{Z} \exp(-E(\mathbf{v}, \mathbf{h})) \\ &= \frac{1}{Z} \exp(\mathbf{a}^\top \mathbf{v}) \exp(\mathbf{b}^\top \mathbf{h}) \exp(\mathbf{v}^\top \mathbf{W} \mathbf{h}) \end{aligned} \quad (2-6)$$

其中  $Z = \sum_{\mathbf{v}, \mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h}))$  为配分函数。

因此，通过优化所有模型参数  $\mathbf{W}, \mathbf{b}, \mathbf{a}$ ，可以对可观测变量的概率分布进行

建模。

为了学习输入数据的概率分布，RBM 通常按照一种称为对比散度的学习方法进行训练。该学习过程基于训练数据对数似然的梯度上升。一个输入  $\mathbf{v}$  的对数似然的导数可以很容易地推导出来，并且这个导数在训练集上的平均值有以下规则：

$$\sum_{\mathbf{v}} \frac{\partial L(\mathbf{W} | \mathbf{v})}{\partial w_{i,j}} \propto \langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{model}} \quad (2-7)$$

两个括号分别表示对  $p(\mathbf{h} | \mathbf{v})q(\mathbf{v})$  和模型  $p(\mathbf{v}, \mathbf{h})$  的期望， $q$  是输入的经验分布。虽然这个梯度的第一项是可处理的，但第二项具有指数复杂性。对比散度的目的是使用吉布斯链来近似这个梯度，吉布斯链使用  $p(\mathbf{h} | \mathbf{v})$  计算  $\mathbf{h}$  的二元状态，然后使用  $p(\mathbf{v} | \mathbf{h})$  获得  $\mathbf{v}$  的估计值<sup>[45]</sup>。

上面的步骤允许我们使用一个简单的 RBM 层来学习输入的生成模型。将一层的隐单元作为后续层的输入，通过叠加多个 RBM，可以得到一种深度学习策略。每一层通常以贪婪的方式进行训练，并且可以根据模型的最终目标进行微调。

## 2.4.2 深度学习的应用

深度神经网络已被用于所有主要类型的基于 EEG 的 BCI 系统，如 P300、SSVEP、运动想象。

关于基于 P300 的脑机接口，Cecotti 等人发表了第一篇研究 CNN 的脑机接口的论文<sup>[46]</sup>。他们的网络包括两个卷积层，一个学习空间滤波器，另一个学习时间滤波器，然后是一个全连接层。该网络在 P300 拼写器数据集上优于当时 BCI 竞赛的优胜者。

对于 SSVEP，相关研究<sup>[47]</sup>探索了一个空间卷积层以及一个时间卷积层的 CNN。该 CNN 获得了类似于三层 MLP 的分类器的性能。然而，该方法未与 SSVEP 的最新方法进行比较。

针对运动想象的研究是脑机接口多个实验范式中最热门的，在运动想象任务中使用深度学习的尝试也是最多的。运动想象也是本文在第五章中实现脑机接口系统所使用的范式。

文献<sup>[48]</sup>中探讨了一种 DBN 来对两个 EEG 通道的特征进行分类。该网络的性能优于 FBCSP，但在删除或添加单个神经元时，该网络的性能远低于

FBCSP, 因此其可靠性不足。

文献<sup>[49]</sup>中使用了另一种 DBN 进行运动想象分类, 其性能优于简单的 CSP+LDA 分类器。作者提出了一种方法来解释网络所学到的知识和它的决定, 这为错误分类的可能神经生理学原因提供了有用的见解。

文献<sup>[50]</sup>探讨了 CNN 和 DBN 的结合。他们使用了一个 CNN, 它的输出被用作六层 SAE 的输入。与单独使用 CNN、DBN 或 SVM 相比, CNN+DBN 方法似乎更为有效。不过遗憾的是, 该模型并没有与 BCI 竞赛的获胜者进行比较, 也没有与其他流行的方法进行比较, 如黎曼几何和 FBCSP。

schirmeister 等人<sup>[51]</sup>探讨了用于运动想象的深度学习模型。各种 DNN 结构被探索和提出, 并被严格与最先进的方法进行对比。他们探索了浅层 CNN (只有一个时间卷积, 一个空间卷积, 平方和平均池, 一个 softmax 层的 CNN), 深层 CNN (时间卷积, 空间卷积, 然后是三层标准卷积和一个 softmax 层), 混合浅层 + 深层 CNN (即它们的串联) 和残差网络 (时间卷积, 空间卷积、34 个残差层和 softmax 层)。深度和浅层的 CNN 都显著优于 FBCSP, 而混合 CNN 和剩下的其他尝试则没有。浅层 CNN 是最有效的, 其分类准确率比 FBCSP 高 3.3%。作者还提出了解释网络所学内容的方法, 这可以提供有用的神经生理学见解。

深度学习具有从原始脑电数据中同时学习有效特征和分类器的潜力。考虑到深度学习在其他领域的有效性, 深度学习无疑在脑电识别领域有望比传统的机器学习方法产生更好的特征和分类器, 从而实现更为稳健的脑电识别。然而到目前为止, 因为脑电数据的有限性, 绝大多数已发表的基于脑电的脑机接口的深度学习研究在实际应用中都无法证明其与最先进的脑机接口方法的优越性。

相关研究表面, 浅层的 CNN 可以胜过 FBCSP。这表明 DNN 在基于脑电的脑机接口中的主要局限性在于这种网络的参数非常多, 因此需要大量的训练样本来进行校正。不幸的是, 典型的 BCI 数据集和实验只有很少的训练示例, 因为 BCI 用户在实际使用 BCI 之前不能被要求执行数百万甚至数千个心理命令。事实上, 在 BCI 领域之外已经证明, DNN 实际上是次优的, 并且是训练集相对较小条件下的最差分类器之一<sup>[52]</sup>。不幸的是, 通常只有很小的训练集可用于设计 BCI。这也许可以解释为什么只有参数少得多的浅层网络被证明对 BCI 有用。因此, 有必要设计参数较少的更适合脑电识别的网络结构。

本文所设计的两个神经网络模型主要针对脑机接口中的运动想象实验范

式，分别从度量学习和卷积结构两方面出发设计具有更强抗噪声能力，更优秀跨被试能力的网络模型，在实验中被证明达到当下领先水平。

## 2.5 本章小结

本章主要介绍了脑电识别的一些基本的背景知识以及一些当下常用的识别方法，并对与其优势以及弊端做了简要的介绍。通过本章的介绍，可以发现，当前的脑电识别算法虽然可以满足脑机接口系统的部分需要，但是无法满足易用性和实用性等需求。深度学习在脑电识别领域的探索仍不充分，不断来有许多相关的方法被提出。受限于篇幅，本章的介绍是简略的，旨在为读者提供一个脑机接口和脑电识别的整体概念，为读者理解本文具体工作做好理论铺垫。



# 第三章 融合度量学习和自动编码器的卷积神经网络模型设计

第一章绪论中介绍了，在脑电识别任务中，存在低信噪比，被试个体差异性和训练数据受限等困难。为了应对上述挑战，本章提出一种在自动编码器中融合了深度度量学习的卷积神经网络模型。本模型根据脑电信号的数据特点，尝试从度量学习的角度解决被试个体差异性问题将深度度量学习融入到自编码器中，在脑电数据中学习具有区分度的特征的同时进行分类。被试无关实验中，分类精度优于传统脑电识别方法。旨在立起一类精度更高、实用性更强、鲁棒性更好的脑电识别方法。

## 3.1 融合度量学习的模型设计思路

度量学习 (metric learning) <sup>[53]</sup> 研究如何在一个特定的任务上学习一个距离函数，使得该距离函数能够帮助基于近邻的算法 (kNN、k-means 等) 取得较好的性能。深度度量学习 (deep metric learning) <sup>[54]</sup> 是度量学习的一种方法，它的目标是学习一个从原始特征到低维稠密的向量空间 (称之为嵌入空间, embedding space) 的映射，使得同类对象在嵌入空间上使用常用的距离函数 (欧氏距离、余弦距离等) 计算的比较近，而不同类的对象之间的距离则比较远。深度度量学习在多个领域取得了非常多的成功的应用，比如人脸识别、人脸验证、图像检索、签名验证、行人识别等。

近年来，许多损失函数，如对比损失 (Contrastive loss)、三元组损失 (Triplet loss)、四元组损失 (quadruplet loss) 被开发用于深度度量学习。这些损失函数用于计算相关样本的相似性度量，以使同一类的样本相互靠近，并使不同类的样本相互分离，从而增强特征识别。

在脑电信号识别领域，DML 已应用于基于脑电信号的脑机接口研究，并取得了可喜的成果。

自动编码器 (Autoencoder, AE) <sup>[55]</sup> 是一种无监督学习算法。自动编码器通

常被用于数据压缩、去噪、降维和特征提取。这种网络体系结构从无标签或有标签的输入数据中学习有意义的特征。然后使用学习到的潜在表示来重构原始输入。

假设有一组  $D$  维的样本  $\mathbf{x}^{(n)} \in \mathbb{R}^D, 1 \leq n \leq N$ , 自编码器将这组数据映射到特征空间得到每个样本的编码  $\mathbf{z}^{(n)} \in \mathbb{R}^M, 1 \leq n \leq N$ , 并且希望这组编码可以重构出原来的样本。

其中, 编码器 (Encoder) 定义为  $f: \mathbb{R}^D \rightarrow \mathbb{R}^M$ .

解码器 (Decoder) 定义为  $g: \mathbb{R}^M \rightarrow \mathbb{R}^D$ .

自编码器的学习目标是 minimized 重构错误 (Reconstruction Error)

$$\begin{aligned} \mathcal{L} &= \sum_{n=1}^N \left\| \mathbf{x}^{(n)} - g(f(\mathbf{x}^{(n)})) \right\|^2 \\ &= \sum_{n=1}^N \left\| \mathbf{x}^{(n)} - f \circ g(\mathbf{x}^{(n)}) \right\|^2 \end{aligned} \quad (3-1)$$

如果特征空间的维度  $M$  小于原始空间的维度  $D$ , 自编码器相当于是一种降维或特征抽取方法. 如果  $M \geq D$ , 一定可以找到一组或多组解使得  $f \circ g$  为单位函数 (Identity Function), 并使得重构错误为 0. 然而, 这样的解并没有太多的意义. 但是, 如果再加上一些附加的约束, 就可以得到一些有意义的解, 比如编码的稀疏性、取值范围,  $f$  和  $g$  的具体形式等. 如果我们让编码只能取  $K$  个不同的值 ( $K < N$ ), 那么自编码器就可以转换为一个  $K$  类的聚类 (Clustering) 问题.

近年来, 丰富的自动编码器结构被开发用于脑电识别. 去噪稀疏自编码器 (DSAE) 被提出用于基于 EEG 的癫痫发作检测. DSAE 的稀疏性约束使得从受污染的 EEG 输入中重构原始 EEG 更加高效. 在此基础上, 提出了一种基于自动编码器的压缩感知 (CS) 方法来处理生物电信号远程监测系统. 他们揭示了在寻找最优数据压缩对脑电信号进行分类方面取得的成就. 然而, 大多数研究只侧重于将自动编码器作为一种无监督学习方法来提取原始数据的显著特征, 并没有尝试搭建端到端的识别模型。

因此, 本章提出了一种新的自动编码器的结构和相应的损失函数, 融合度量学习和自动编码器, 利用自动编码器的特征学习能力来学习脑电数据特征, 并利用度量学习扩大类间样本特征的差异, 从而增强模型的跨被试任务的识别精度. 在运动想象范式的脑电识别任务上, 经实验证明, 具有更好的精确度和鲁棒性。

## 3.2 融合度量学习的卷积网络结构

脑电数据是一种随时间变化的信号。为了对脑电数据使用卷积神经网络，通常将脑电数据使用频带滤波进行预处理，对预处理后的脑电数据分成多个时间片 (trial)，每个时间片的脑电数据作为卷积神经网络的输入。因此可以形式化描述作为卷积神经网络输入的脑电数据：

$x \in \mathbb{R}^{C \times T}$  是来自  $k$  个类别的脑电数据片，其对应的标签为  $y \in \{1, 2, \dots, k\}$ 。其中， $C$  是信道的数目， $T$  是时间点采样的数目。

本章提出的网络模型融合了度量学习和自动编码器，以下简称为 DML-AE，目的在于充分利用自动编码器学习脑电数据特征的能力和度量学习促使类内距离近而类间距离远的特性。模型整体共分为三大子模块，分别是自编码器，深度度量学习和监督学习。下面就这三大子模块分别进行介绍。

### 自动编码器

本节提出的自编码器模块由编码器  $z = q(x)$  和解码器  $\hat{x} = p(z)$  两个主要组件组成。在编码器中，输入信号  $x$  通过减小输入信号的维数编码成一个向量  $z$ 。在解码器中，向量  $z$  被解码回输入信号  $\hat{x}$ 。模型架构如图 3-1 所示：

编码器有两个卷积块，每个块由一个 2D 卷积层、一个批归一化 (batch normalization, BN) 层、一个指数线性单元 (ELU)、一个平均池化层 (AveragePooling2D) 组成。最终 CNN 层的输出作为是映射潜在表示的全连接层的输入。

受 CSP 启发，模式使用卷积网络作为空间滤波，以便能从一组脑电数据输入中学习到具有区分度的特征。每一层卷积操作都面向所有信道的组合，那么卷积操作可以看作是对所有给定信道的线性组合沿着时间维度执行卷积运算，同时从所有通道中提取空间和时间信息。编码器使用的 CNN 层维度依次减小，平均池化层用于提取给定输入信号的重要特征并减少参数数量。对于脑电数据，平均池化层还有在输入信号的所有信道之间共享权重的好处。在每个 CNN 层和平均池化层之间使用批归一化层。经过最后的平均池化层后的特征通过展平映射为向量表示。最后，将展平向量嵌入到一个全连接层中生成隐向量。

解码器结构以与编码器组件对称的方式排列。由于匹配 CNN 块的输入维数是必要的，因此将隐向量通过全连接层，然后送入整形层以构造合适维数的数据。

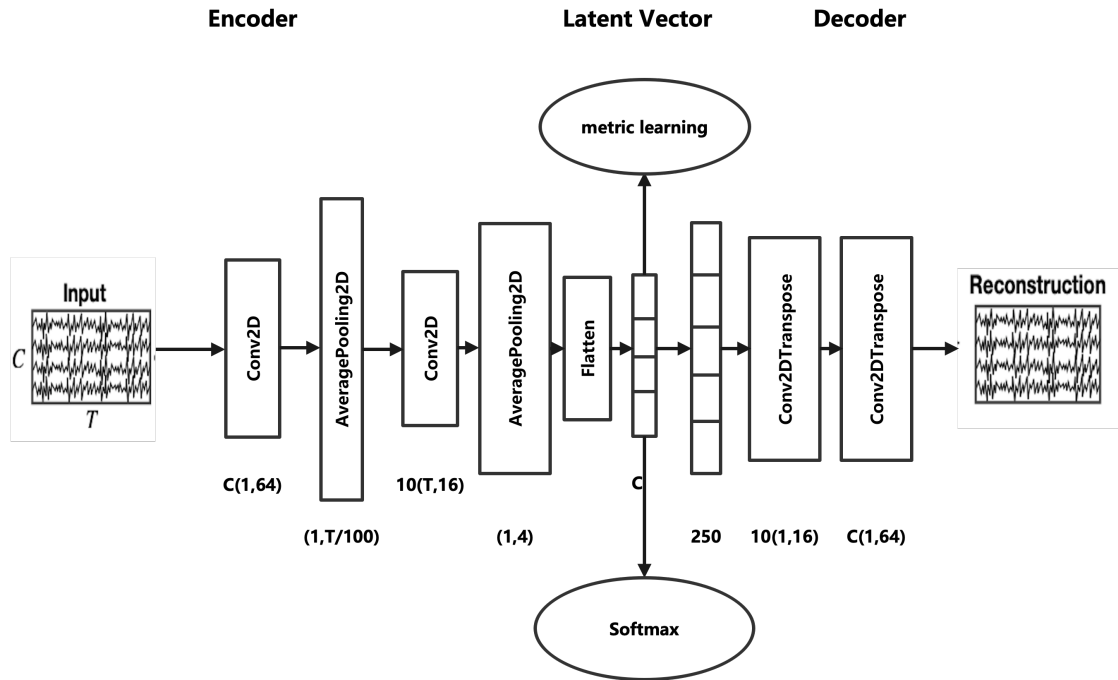


图 3-1: 自动编码器模型架构

解码器组件的两个 CNN 块中的每一个利用具有 2 步长的转置卷积层 (conv2dtranpse) 和 ELU 层。以与上采样层类似的方式, 使用 2 的步长对数据进行上采样。转置卷积可以提取有用特征, 减少无用特征, 有利于重构隐向量。

自动编码器的训练目的在于最小化输入重构错误。在这里, 使用均方误差作为损失函数。对于输入数据  $x_j = \{x_1, x_2, \dots, x_C\}$ , 损失函数表达如下:

$$\mathcal{L}_{\text{MSE}}(x, \hat{x}) = \frac{1}{C} \sum_{j=1}^C \|x_j - \hat{x}_j\|^2 \quad (3-2)$$

其中,  $\hat{x}_j$  是来自信道  $j$  的重构数据。

自动编码器的中间结果隐向量, 被看作输入数据的恰当表示, 而作为度量学习模块的输入。

### 度量学习模块

深度度量学习通过学习一个距离度量增强学习特征的区分度。将深度度量学习引入到自动编码器, 有利于充分利用自动编码器的隐向量学习到更好的特

征表达。使得不同样本之间，类内距离近，而类间距离远，从而提高模型整体的分类性能。

此处使用三元组损失作为度量学习的损失函数，在训练过程中，从训练数据中随机采样一个三元组  $\{x^a, x^p, x^n\}$ ，其中，锚样本  $x^a$  离正样本  $x^p$  更近，离负样本  $x^n$  更远。这三个输入信号在经过编码器后得到各自的三个隐向量，即  $z^a, z^p, z^n$ 。相应的损失函数可以公式化描述如下：

$$\mathcal{L}_{\text{triplet}}(z^a, z^p, z^n) = \frac{1}{2} \left[ \|z^a - z^p\|^2 - \|z^a - z^n\|^2 + \alpha \right]_+ \quad (3-3)$$

其中， $[z]_+ = \max(x, 0)$ ，阈值  $\alpha$  是被称为 **margin** 的常数超参数。**margin** 使得锚样本离正样本的距离近而离负样本的距离远。**margin** 的选取对度量学习效果影响巨大，在之后的实验部分将重点讨论。

此处使用 **semi-hard** 三元组限制，主要是因为普通的三元组损失在训练后期，多次迭代之后，大多数样本间距离都在损失函数的约束条件之内，从而导致训练收敛慢的问题。

### 监督学习模块

模型采用一个标准的 **softmax** 分类器作为有监督的分类器来对隐向量进行分类。隐向量  $z$  通过 **softmax** 激活函数被输入一个全连接层，表达如下：

$$\hat{y} = \text{softmax}(Wz + b) \quad (3-4)$$

其中， $W$  是参数矩阵， $b$  为偏置向量。模型使用交叉熵作为损失函数，计算公式如下：

$$\mathcal{L}_{\text{cross-entropy}}(y, \hat{y}) = - \sum_{k=1}^{|\text{class}|} y_k \log \hat{y}_k \quad (3-5)$$

其中， $y$  和  $\hat{y}$  分别为真实标签和分类标签。

### 模型整体的损失函数

模型整体的损失函数，是公式 (3-2)、公式 (3-3)、公式 (3-5) 的结合。最终的损失函数如下：

$$\mathcal{L}(x, \hat{x}, z^a, z^p, z^n, y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N \left\{ \beta_1 \mathcal{L}_{\text{MSE}}(x_i, \hat{x}_i) + \beta_2 \mathcal{L}_{\text{triplet}}(z_i^a, z_i^p, z_i^n) + \beta_3 \mathcal{L}_{\text{cross-entropy}}(y_i, \hat{y}_i) \right\} \quad (3-6)$$

其中  $N$  是输入脑电数据的数目， $\beta_1, \beta_2, \beta_3$  分别是协调三个子损失函数的超参数。

表 3-1: 模型整体架构参数

BLOCKS	Layer	Filter Size	Stride	Activation	Output	
Encoder	Input	(1,T,C)			(1,T,C)	
	Conv2D	C	(1,64)	1	ELU	(1,T,C)
	BatchNormalization				(1,T,C)	
	AveragePooling2D		(1,T//100)		(1,100,C)	
	Conv2D	10	(1,16)	1	ELU	(1,100,10)
	BatchNormalizaiton				(1,100,10)	
	AveragePooling2D		(1,4)		(1,25,10)	
	Flatten				250	
Latent	FC	(C)			(C)	
	FC	(250)			(250)	
Decoder	Reshape		(1,25,10)		(1,25,10)	
	Conv2DTranspose	10	(1,16)	4	ELU	(1,100,10)
	Conv2DTranspose	C	(1,64)	T//100	ELU	(1,T,C)
Metric Learning	Input	(1)			(1)	
	Latent				(C)	
	Concentrate				(C+1)	
Supervised Learning	Latent				(C)	
	FC	N		softmax	(N)	

### 整体网络架构

前几小节介绍了设计的三个网络组件，在本小节中将会介绍最终网络模型架构的设计和所选择的参数。

表 3-1 给出了本网络模型绝大部分数据，超参数  $\beta_1, \beta_2, \beta_3$  在实际使用中，可以根据具体的数据集和任务灵活调整，故在此不加描述。

$x \in \mathbb{R}^{C \times T}$  是来自  $k$  个类别的脑电数据片，其对应的标签为  $y \in \{1, 2, \dots, k\}$ 。其中， $C$  是信道的数目， $T$  是时间点采样的数目。

## 3.3 实验与分析

为了证明本方法是具有现实意义的脑电识别方法，在三大标准开源数据集 BCI IV 2a、SMR-BCI 以及 OpenBMI 上分别进行被试相关实验和被试无关实验。其中被试无关实验因为其不依赖于具体被试而考察模型跨被试泛化能力，在搭建实际的具有易用性的脑机接口系统上具有现实意义。

### 3.3.1 数据集介绍

为了验证本章提出的网络架构的有效性，分别在 BCI IV 2a、SMR-BCI 以及 OpenBMI 上做了一系列的实验进行验证。BCI IV 2a 和 SMR-BCI 是运动想象脑机接口的基准数据集，OpenBMI 是当下最大规模的运动想象数据集。

BCI IV 2a 数据集包含了 9 个名健康被试，进行左手、右手、脚以及舌头四种运动想象。脑电数据使用 22 通道的 Ag/AgCl 电极以 250Hz 的采样频率进行采集，分两天一共记录了 288 个时间窗 (trial) 的脑电数据。

为了保持和其他数据集实验的一致性，只使用来自左手和右手运动想象的数据。这些数据中，只有其中的 20 个与运动皮层相关的区域信道被使用，分别是 FC3, F C1, F Cz, F C2, F C4, C5, C3, C1, Cz, C2, C4, C6, CP3, CP1, CPz, CP2, CP4, P1, Pz, P2。脑电数据使用下采样从 250Hz 下采样至 100Hz。一个时间窗的时长为 3 秒，因此其维度为通道数  $\times$  采样时间点数，即  $20 \times 300$ 。

SMR-BCI 数据集包含 15 个信道的来自二分类类运动想象任务的数据，这些数据从 14 个健康被试上采集而来。采样频率为 512Hz。每名被试采集来自两次，共 160 个时间窗的数据。

类似的，使用下采样从 512Hz 下采样至 100Hz。每个时间窗时长 4 秒，因此其维度为通道数  $\times$  采样时间点数，即  $15 \times 400$ 。

OpenBMI 数据集一共采集了 54 名被试进行左手和右手运动想象的脑电数据。采集的脑电数据信道数为 62，采样频率为 1000Hz。

为了保持实验的一致性方便对比，采用其中 20 个与运动反应皮层相关的信道数据。FC3, F C1, F Cz, F C2, F C4, C5, C3, C1, Cz, C2, C4, C6, CP3, CP1, CPz, CP2, CP4, P1, Pz, P2。类似的，使用下采样从 1000Hz 下采样至 100Hz。每个时间窗时长 4 秒，因此其维度为通道数  $\times$  采样时间点数，即  $20 \times 400$ 。

电极信道依照国际标准电极分布规则，分布如图 3-2 所示。




图 3-2: 电极信道示意

### 3.3.2 对比实验

为了验证本章提出的 DML-AE 模型的优越性，与现有的一些常用方法在多个数据集上的效果进行对比验证。这些被挑选用于对比实验的方法分别为 FBCSP-SVM<sup>[56]</sup>、Deep Convnet<sup>[51]</sup>、EEGNet-8,2<sup>[57]</sup>、Spectral-spatial CNN<sup>[58]</sup>。

以下简单介绍这些被挑选出来作为对比的实验方法。

**FBCSP-SVM:** FBCSP 是在 CSP 算法的思想基础上而开发的。通过使用 FBCSP 作为特征提取方法，从多个频带中提取 EEG 特征。应用 4 个空间滤波器将 EEG 信号分解为 9 个频带，每个频带带宽为 4Hz，分别为 (4 - 8Hz, 8 - 12 Hz, ..., 36 - 40 Hz)。随后，通过结合网格搜索算法，使用支持向量机 (SVM) 进行分类。对于网格搜索算法，评估了对分类验证集的预测，以获得最优的超参数集。最终，将具有最佳参数的 SVM 分类器用于测试目的。

**Deep Convnet:** Deep Convnet 是早期被引入的具有两个卷积块结构的神经网络模型。Deep Convnet 使用 8-30Hz 频带滤波后的脑电数据作为输入，被证明可以有效的用于处理脑电信号分类。

**EEGNet-8,2:** EEGNet-8,2 是受 FBCSP 启发而提出的一种具有影响力的深度神经网络模型。可以学习到具有区分度的脑电数据特征，并且可以通用于多个脑机接口的实验范式。为了增强对比实验的说服力，此处用作对比方法的 EEGNet 使用原始论文中最优的超参数进行训练。原始的 EEG 数据以与 Deep

Convnet 相同的方法进行预处理，作为 EEGNet-8, 2 的输入。

Spectral-spatial CNN: Spectral-spatial CNN 是基于卷积神经网络架构设计的专用于脑电数据识别的网络模型，在被试无关的运动想象任务中达到当下最先进的水平。模型学习脑电数据的空间域上的特征和频域上的特征。因此所学习到的特征更具有区分度。

为了进行公平的比较，所有方法都在相同的训练、验证和测试集上进行了评估。实验整体设计为 BCI IV 2a、SMR-BCI、OpenBMI 三个数据集上的左手/右手二分类运动想象任务。在每个数据集上，同时进行被试相关和被试无关两项任务的实验验证。

对于每一次实验都会报告其准确度和 F1 分数 (F1-score) 两方面指标。

表 3-2: DML-AE 模型对比实验结果

Dataset	Model	subject-dependent		subject-independent	
		Accuracy	F1-score	Accuracy	F1-score
BCI IV 2a	FBCSP-SVM	75.64± 14.49	74.49 ± 18.68	58.09 ± 9.91	51.53 ± 24.01
	Deep Convnet	63.72 ± 17.18	59.85 ± 22.17	56.34 ± 8.86	30.62 ± 28.96
	EEGNet-8,2	65.93 ± 18.44	64.45 ± 26.23	64.26 ± 11.03	60.19 ± 19.96
	Spectral-spatial CNN	<b>76.91 ± 13.75</b>	<b>77.03 ± 15.41</b>	<b>66.05 ± 13.70</b>	<b>61.91 ± 20.31</b>
	DML-AE	75.23 ± 16.14	74.72 ± 18.39	65.03 ± 9.24	59.09 ± 23.28
SMR-BCI	FBCSP-SVM	74.50 ± 18.14	<b>70.65 ± 23.65</b>	62.64 ± 15.43	45.07 ± 34.93
	Deep Convnet	60.79 ± 16.07	56.84 ± 17.83	65.26 ± 16.83	54.38 ± 32.58
	EEGNet-8,2	67.76 ± 18.09	68.05 ± 21.11	58.07 ± 11.45	34.43 ± 31.35
	Spectral-spatial CNN	<b>76.76 ± 16.66</b>	69.87 ± 28.15	<b>66.21 ± 15.15</b>	54.36 ± 31.21
	DML-AE	75.90 ± 16.50	68.13 ± 17.66	59.79 ± 13.72	<b>61.10 ± 23.64</b>
OpenBMI	FBCSP-SVM	<b>66.06 ± 16.58</b>	64.66 ± 19.47	64.96 ± 12.70	65.25 ± 15.14
	Deep Convnet	60.31 ± 16.76	61.66 ± 18.17	68.33 ± 15.33	70.20 ± 17.10
	EEGNet-8,2	60.41 ± 17.12	56.80 ± 23.54	68.84 ± 13.87	70.39 ± 14.30
	Spectral-spatial CNN	65.19 ± 15.94	<b>66.97 ± 16.71</b>	68.11 ± 13.53	65.96 ± 16.79
	DML-AE	61.03 ± 14.47	63.59 ± 14.52	<b>72.03 ± 13.95</b>	<b>72.62 ± 14.14</b>

具体的相关统计结果展示在表 3-2 中。表格统计结果以均值和标准差两部分组成。均值是对同一数据集内多名被试的统计数据进行均值计算的结果，标

准差是对同一数据集内多名被试统计数据进行标准差计算得出的结果。

在 BCIC IV2a 数据集的实验中，Spectral-spatial CNN 的方法在被试依赖的任务中表现最佳，在准确度和 F1 得分上都取得了最优成绩。而在被试无关的任务中，Spectral-spatial CNN 仍表现最佳，在准确度和 F1 得分上都取得了最优结果。

在 SMR-BCI 数据集的实验中，被试依赖的任务中，准确度最高的是 Spectral-spatial CNN，而 F1 得分最高的是 FBCSP + SVM 方法。在被试无关的任务中，本文提出的 DML-AE 方法 F1 得分表现最佳，在准确度指标上 Spectral-spatial CNN 取得了最优结果。

在 OpenBMI 数据集的实验中，被试依赖任务的准确度最高模型是 FBCSP-SVM，而 F1 得分最高的算法是 Spectral-spatial CNN。在被试无关的任务上，DML-AE 方法取得了最好成绩，在准确度和 F1 得分两项指标上取得最优结果。

本文提出的 DML-AE 模型在被试无关的实验上，在三大数据集上的准确度和 F1 分数上对比作为对比的四大基准方法略优。在 SMR-BCI 和 OpenBMI 两大数据集的被试无关实验中，相比其他方法中的最优结果更有着显著的突破。而在被试相关的实验中，DML-AE 方法虽然没有达到最优结果，仍然取得了和其他当前主流算法相近的结果。

DML-AE 模型通过在三大数据集，被试相关任务和被试无关任务上的优秀表现，证明了自动编码器和深度度量学习可以有利与卷积网络模型学习到脑电数据更合适的表达，获得更好的分类结果。

接下来的实验，将 DML-AE 和对比方法的运行速度和训练速度进行了比较。具体结果如图 3-3 所示。

整体而言，DML-AE 模型的训练速度和识别速度与 Deep Convnet 和 EEGNet-8, 2 类似。显著快于 Spectral-spatial CNN 模型。这主要是因为参数量的问题，Deep Convnet 和 EEGNet-8, 2 分别具有 151027 和 5162 个参数，而本文提出的 DML-AE 模型参数为 55232 个参数。相比之下，Spectral-spatial CNN 拥有 77577714 个参数。另一方面，FBCSP+SVM 的方法是传统的机器学习方法，所以不适合与其余深度学习方法比较训练速度，此处没有给出详细训练时间的对比。

从训练时间和预测时间对比以及模型参数量上，可以看出 DML-AE 是一种轻量的深度模型。其训练时间较短，易于训练，所以方便用于实际的脑机接口

表 3-3: DML-AE 模型运行时间对比实验结果

Dataset	Model	subject-dependent		subject-independent	
		Training	Predict	Training	Predict
BCI IV 2a	FBCSP-SVM	-	0.0008	-	0.0112
	Deep Convnet	0.1709	0.1617	0.2748	0.1739
	EEGNet-8,2	0.1476	0.1173	0.3735	0.0920
	Spectral-spatial CNN	10.2031	0.7600	8.1334	0.7444
	DML-AE	0.2320	0.1803	0.4724	0.2373
SMR-BCI	FBCSP-SVM	-	0.0005	-	0.0047
	Deep Convnet	0.1352	0.1519	0.2412	0.1906
	EEGNet-8,2	0.1164	0.1296	0.3210	0.1105
	Spectral-spatial CNN	2.1321	1.0257	5.8785	0.6688
	DML-AE	0.1463	0.2433	0.4948	0.2966
OpenBMI	FBCSP-SVM	-	0.0020	-	0.1906
	Deep Convnet	0.1804	0.1618	1.7497	0.47345
	EEGNet-8,2	0.1882	0.1439	3.0951	0.1372
	Spectral-spatial CNN	2.2476	1.0934	11.9067	0.8560
	DML-AE	0.3527	0.2851	1.3626	0.1043

系统中，更方便部署和调整。其识别速度快，对于在线的脑机接口系统，有利于提升系统的响应速度。所以，从训练时间和预测时间两方面来看，DML-AE方法在具备识别的可靠性同时，兼具了在实际项目中的实用性。

### 3.3.3 度量学习有效性验证实验

为了验证引入的深度度量学习的有效性，所以设计此实验。本实验使用DML-AE模型和只使用自动编码器而不使用深度度量学习的网络模型进行对比。为了客观公正，保留与深度度量学习无关的模型架构和参数，在BCIC IV 2a、SMR-BCI、OpenBMI三大数据集上进行验证。在每个数据集上，同时进行被试相关和被试无关两项任务的实验验证。

具体的相关统计结果展示在表 3-4 中。表格统计结果以均值和标准差两部

分组成。均值是对同一数据集内多名被试的统计数据进行均值计算的结果，标准差是对同一数据集内多名被试统计数据进行标准差计算得出的结果。单纯使用自动编码器而没有使用深度度量学习的模型这里标记为 only AE。

表 3-4: 深度度量学习有效性评估实验结果

Dataset	Model	subject-dependent		subject-dependent	
		Accuracy	F1-score	Accuracy	Accuracy
BCIC IV 2a	only AE	60.76 ± 11.93	61.09 ± 13.83	58.70 ± 8.91	49.06 ± 20.25
	DML-AE	<b>65.23 ± 16.14</b>	<b>64.72 ± 18.39</b>	<b>60.03 ± 9.24</b>	<b>49.09 ± 23.28</b>
SMR-BCI	only AE	63.86 ± 14.13	61.31 ± 16.19	57.95 ± 12.55	60.53 ± 20.33
	DML-AE	<b>65.90 ± 16.50</b>	<b>64.13 ± 17.60</b>	<b>59.79 ± 13.72</b>	<b>61.10 ± 23.64*</b>
OpenBMI	only AE	59.66 ± 14.02	61.64 ± 14.44	71.10 ± 13.58	69.28 ± 16.10
	DML-AE	<b>61.03 ± 14.47</b>	<b>63.59 ± 14.52</b>	<b>72.03 ± 14.04</b>	<b>72.62 ± 14.14</b>

在所有的三个数据集上的被试相关任务和被试无关任务上，DML-AE 模型在准确度和 F1 得分两项指标的表现均优于不使用深度度量学习的 only AE 模型。

模型参数的大小会对模型整体效果产生影响，但是因为度量学习本身对模型整体参数量影响可以忽略不计，所以这里不将删去度量学习相关后的参数变化考虑在内，同样具备客观性。

实验结果验证了深度度量学习具有帮助卷积神经网络学习到更优秀的特征的作用，具有改善既有卷积网络模型提高识别精度的积极效果。引入度量学习，可以在不明显改变模型结构和模型参数的情况下，通过损失函数的修改，缩小卷积网络提取到的特征向量的类内距离，增加提取到的特征向量的类间距离。进而在被试相关任务和被试无关任务都有显著成效。

本度量学习有效性验证实验充分证明了引入深度度量学习的有效性。证明了本章提出的 DML-AE 模型将深度度量学习与自编码器相结合的合理性。

### 3.3.4 超参数评估实验

超参数的选择对模型的最终表现影响重大<sup>[59]</sup>，本模型主要的超参数共有  $\beta_1\beta_2\beta_3\alpha$  四个超参数。其中  $\beta_1\beta_2\beta_3$  均被用于协调三个子部分损失函数对最终损

失函数的占比，而  $\alpha$  则是深度度量学习中产生重要影响的被称为 **margin** 的超参数。

而  $\beta_1\beta_2\beta_3$  的最优选择根据实际经验手动调整得出，记录如表 3-5 所示：

表 3-5: 超参数设置

Dataset	Parameter					
	Subject-dependent			Subject-independent		
	$\beta_1$	$\beta_2$	$\beta_3$	$\beta_1$	$\beta_2$	$\beta_3$
BCI IV 2a	0.1	0.1	1.0	0.5	0.5	0.5
SMR-BCI	0.1	0.1	1.0	0.1	0.5	0.5
OpenBMI	0.5	0.1	0.5	0.5	1.0	1.0

对于 BCIC IV 2a 数据集，被试相关实验中， $\beta_1\beta_2\beta_3$  分别为 0.1、0.1、1.0 效果最佳。被试无关实验中， $\beta_1\beta_2\beta_3$  分别为 0.5、0.5、0.5 效果最佳。

对于 SMR-BCI 数据集，被试相关实验中， $\beta_1\beta_2\beta_3$  分别为 0.1、0.1、1.0 效果最佳，被试无关实验中， $\beta_1\beta_2\beta_3$  分别为 0.1、0.5、0.5 效果最佳。

对于 OpenBMI 数据集，被试相关实验中， $\beta_1\beta_2\beta_3$  分别为 0.5、0.1、0.5 效果最佳，被试无关实验中， $\beta_1\beta_2\beta_3$  分别为 0.5、1.0、1.0 效果最佳。

$\alpha$  是深度度量学习中产生重要影响的被称为 **margin** 的超参数，探讨  $\alpha$  对深度度量学习的影响，进而分析对整体的模型性能影响，有利于证明 DML-AE 的有效性。表 3-6 展示了 DML-AE 模型在三大数据集，被试相关和被试无关任务上，**margin** 超参数选择分别在 0.1, 0.5, 1.0, 5.0, 10.0 时的各自表现。

在 BCIC IV2a 数据集上，被试相关任务中，**margin** 分别设置为 10.0 和 5.0 时，准确度和 F1 得分表现最优。而在被试无关任务中，**margin** 设置为 1.0 时表现最优。

在 SMR-BCI 数据集上，被试相关任务中，**margin** 设置为 1.0 时，准确度和 F1 得分表现最优。而在被试无关任务中，**margin** 设置为 1.0 时准确度和 F1 得分表现最优。

在 OpenBMI 数据集上，被试相关任务中，**margin** 设置为 1.0 时，准确度和 F1 得分表现最优。而在被试无关任务中，**margin** 同样设置为 1.0 时表现最优。

综合来看，无论是被试相关任务还是被试无关任务中，**margin** 设置为 1.0 效果为最好。在一些特殊任务中，可以通过灵活选取 **margin** 超参数，改善模型

表 3-6: margin 的参数选择影响

Dataset	Margin	subject-dependent		subject-independent	
		Accuracy	F1-score	Accuracy	F1-score
BCIC IV 2a	0.1	62.28 ± 13.90	62.61 ± 15.13	58.64 ± 8.57	46.59 ± 23.58
	0.5	62.25 ± 13.89	63.08 ± 14.70	59.27 ± 8.38	49.01 ± 19.29
	1.0	63.46 ± 14.33	64.28 ± 15.27	<b>60.03 ± 9.24</b>	<b>49.09 ± 23.28</b>
	5.0	63.66 ± 13.65	<b>64.37 ± 14.57</b>	59.61 ± 8.84	49.53 ± 19.56
	10.0	<b>63.87 ± 14.51</b>	64.03 ± 15.66	59.85 ± 8.44	48.39 ± 20.37
SMR-BCI	0.1	64.93 ± 15.51	62.85 ± 13.82	56.76 ± 11.19	57.83 ± 20.50
	0.5	64.31 ± 15.70	62.27 ± 17.07	58.45 ± 12.67	58.41 ± 22.40
	1.0	<b>65.90 ± 16.60</b>	<b>64.13 ± 17.66</b>	<b>59.79 ± 13.72</b>	<b>61.10 ± 23.64</b>
	5.0	65.14 ± 16.08	62.04 ± 18.20	59.69 ± 13.86	58.88 ± 22.48
	10.0	65.45 ± 15.81	62.01 ± 17.82	58.81 ± 13.50	58.61 ± 23.43
OpenBMI	0.1	59.25 ± 14.27	61.79 ± 14.26	72.14 ± 14.22	72.07 ± 15.19
	0.5	59.85 ± 13.93	62.17 ± 14.17	71.06 ± 13.91	71.23 ± 14.40
	1.0	<b>61.03 ± 14.47</b>	<b>63.59 ± 14.52</b>	<b>72.03 ± 14.04</b>	<b>72.62 ± 14.14</b>
	5.0	59.93 ± 13.77	62.41 ± 14.31	70.43 ± 13.81	71.00 ± 13.90
	10.0	58.97 ± 13.56	61.51 ± 14.14	69.43 ± 14.29	69.46 ± 15.32

性能。

注意到 **margin** 作为深度度量学习的关键超参数，对最终的分类结果有着重大影响。**margin** 在度量学习中，通常用于限制锚样本与正样本和负样本之间的距离差。

**margin** 在被试相关和被试无关任务中最优超参数不同，主要是因为深度度量学习对不同被试的数据分布的个体差异性充分体现到了最终的分类结果中。此外在不同数据集，不同被试上，**margin** 的选取也受数据分布的个体差异性影响。

**margin** 不同设置对最终结果产生重大影响<sup>[60]</sup>，也说明了深度度量学习对分类准确度提升，特别是跨被试任务上识别精度的提升产生了重要的作用。度量学习在脑电数据的识别上，起到了缩小类内距离，扩大了类间距离的效果。这与本模型设计的初衷也是吻合的。

## 3.4 本章小结

在本章中，提出了一种融合了度量和自动编码器的卷积神经网络设计方法。其中，自动编码器可以学习到脑电数据的恰当表示，深度度量学习的引入强化了模型的跨被试泛化能力。在对比实验中，证明了该方法在被试无关的任务中优于基准方法。此外，还深入探索了深度度量学习的设计和其 **margin** 超参数对模型整体的影响，证明了设计的有效性和合理性。



# 第四章 应用于脑电识别的黎曼卷积网络

在第三章中，主要设计了一个融合度量学习与自动编码器的卷积神经网络模型。引入度量学习，尝试从损失函数的角度解决不同被试之间的生物差异性。然而，融合度量学习的自编码器虽然在二分类任务中相比于其他基准方法拥有更好的跨被试泛化能力。但是在多分类任务下，分类精度相对不足，对训练数据集的大小也存在相对严重依赖。为此，本章根据脑电数据本身的特点，提出一种黎曼卷积网络模型。它沿袭了度量的思想，利用黎曼流形和其自带的黎曼距离的优秀特性，学习到更适合脑电数据的表示，具有更好的多分类任务下的跨被试识别能力。

## 4.1 现有黎曼几何方法的局限性

黎曼几何是研究光滑曲面空间的数学分支。这种光滑的曲面空间被称为黎曼流形，它在局部表现出像欧式空间一般的性质。作为一种生僻的数学工具，黎曼几何的概念对脑电识别和神经网络的研究者来说是陌生的，因此本节给出关于黎曼流形和黎曼距离的基本介绍，为之后的模型设计打下良好的基础。

流形是局部具有欧几里得空间性质的空间，是高维空间中曲线、曲面概念的拓广。可以在低维上直观理解这个概念，比如三维空间中的一个曲面是一个二维流形，因为它的本质维度（intrinsic dimension）只有 2，一个点在这个二维流形上移动只有两个方向的自由度。同理，三维空间或者二维空间中的一条曲线都是一个一维流形。欧几里得空间就是最简单的流形的实例。

黎曼流形是指在流形上任意一点的切空间处定义了欧式内积的平滑微分流形。每点  $p$  的切空间都定义了点积，而且其数值随  $p$  平滑地改变。它容许我们定义弧线长度、角度、面积、体积、曲率、函数梯度及向量域的散度。常见的黎曼流形可以分为 SPD 流形、Grassmann 流形以及 Stiefel 流形。

本章所涉及的黎曼流形专指 SPD 流形，因此对 SPD 流形进行详细介绍。

在 SPD 流形中，每个对称正定矩阵（symmetric positive definite matrix，SPD 矩阵）对应 SPD 流形上的一个点。SPD 流形上的任意两个 SPD 矩阵  $C_1, C_2$  之间，使用 SPD 流形自带的黎曼距离进行计算：

$$\delta_G(C_1, C_2) = \left\| \log(C_1^{-1/2} C_2 C_1^{-1/2}) \right\|_F = \sqrt{\sum_{n=1}^N \log^2 \lambda_n} \quad (4-1)$$

其中， $\lambda_i$  是矩阵  $\mathbf{P}_1^{-1} \mathbf{P}_2$  的严格正特征值， $\|\cdot\|_F$  是矩阵的 Frobenius 范数。

与欧式距离不同，黎曼距离具有尺度不变性（scale invariance）：

$$\delta_G(\mathbf{X} C_1 \mathbf{X}^T, \mathbf{X} C_2 \mathbf{X}^T) = \delta_G(C_1, C_2) \quad (4-2)$$

和反演不变性（inversion invariance）：

$$\delta_G(C_1^{-1}, C_2^{-1}) = \delta_G(C_1, C_2) \quad (4-3)$$

尺度不变性和反演不变性被证明对于增强脑电信号识别算法的鲁棒性有重大作用。

在以往的脑电识别算法中，经常使用空间滤波和源分离的方法提取特征。这类方法将实际采集到的脑电信号看作真实的脑电信号和噪声的组合。目的在于仅使用真实的脑电信号提取的特征进行分类而改善分类精度。

对于  $N$  维的实际采集到的脑电信号  $x(t)$ ，其对应的真实的脑电信号为  $s(t)$ ，噪声和真实脑电信号的混合可建模为：

$$x(t) = A s(t) \quad (4-4)$$

其中， $A$  是混合矩阵。

现假定， $S_i$  和  $S_j$  是两个时间片的脑电数据，使用其协方差矩阵作为特征分别是  $C_i = A S_i A^T$  和  $C_j = A S_j A^T$ 。

因为黎曼距离的尺度不变性，

$$\delta_G(S_i, S_j) = \delta_G(C_i, C_j) \quad (4-5)$$

使用黎曼距离作为度量，具有更好的抗噪声能力。因此黎曼距离在 2010 年就被 Alexandre Barachant 等人引入，并在此基础上做了诸多尝试。

在获取全局的几何特征时，传统的数据分析一般会导致失败。其原因在于

空间本质上是全局线性的，而数据本身往往呈现出强非线性特征。这是可以借助流形，在欧氏空间中嵌入非欧式低维流形。从几何的角度来看，流形本质上反映了全局与局部属性的区别和联系。

然而，传统的基于黎曼几何的方法，只是简单的利用黎曼流形的特性，将数据点映射到黎曼空间中，使用简单的基于距离的分类方法，例如 kNN 等。没能充分利用深度学习层次化结构的成功经验，在识别精度上也逐渐落后于深度学习方法。为了充分利用黎曼几何和深度学习两方面方法的突出能力，本章将黎曼几何与深度学习做结合，设计一种用于脑电数据识别的黎曼卷积网络模型。

## 4.2 结合黎曼几何的卷积网络设计

### 4.2.1 结合黎曼几何的卷积结构

脑电识别方法中，经常使用协方差矩阵作为脑电数据的特征。协方差具有衡量脑电信号所具有的能量生物意义，并且协方差矩阵天然就是对称正定矩阵。因此，对脑电数据的协方差矩阵使用 SPD 流形的黎曼距离进行分类可以具有更好的抗噪声和跨被试泛化的能力。

然而，以往对黎曼流形的使用仅是简单的类似于最近邻分类等直接基于度量的分类方法，并没有充分利用黎曼距离的优越性。深度学习具有自动学习数据特征的优势，本章提出一种将 SPD 流形与深度神经网络相结合模型，通过对卷积神经网络的拓展，使得输入的 SPD 矩阵在网络的层间传递中仍旧保持 SPD 矩阵的形式。

为了达成这一目标，根据传统卷积神经网络的卷积层，ReLU 层等，推演设计了黎曼卷积下的相应版本。并给出对应的训练方法。

设计黎曼卷积网络的目的之一就在于在深度神经网络的内部保持输入的 SPD 矩阵的形式，因此，卷积层的设计是其中关键。新设计的卷积层通过双线性映射，将输入的 SPD 矩阵转化为另一 SPD 矩阵，公式化描述如下：

$$\mathbf{X}_k = f_b^{(k)}(\mathbf{X}_{k-1}; \mathbf{W}_k) = \mathbf{W}_k \mathbf{X}_{k-1} \mathbf{W}_k^T \quad (4-6)$$

其中， $\mathbf{X}_{k-1}$  是第 k 层卷积层的输入矩阵， $\mathbf{W}_k \in \mathbb{R}_*^{d_k \times d_{k-1}}$  是变换矩阵（权重参数）， $\mathbf{X}_k$  是第 k 层卷积层的输出矩阵。为了确保输出的 SPD 矩阵依旧符合

SPD 矩阵的特性， $\mathbf{W}_k$  必须满足满秩的要求。

SPD 矩阵在经过黎曼卷积层之后，从一个原始 SPD 流形上的一点转化为一个新的 SPD 流形上的一点。也就保证了每个黎曼卷积层对应一个 SPD 流形。

ReLU 作为激活函数被引入深度学习，并被用于改善训练表现。目前已经成为最广泛使用的激活函数之一。借鉴 ReLU 的成功经验，设计一个类似于 ReLU 的激活函数是十分有必要的。

受 ReLU 非线性的  $\max(0, x)$  启发，在针对 SPD 流形设计的激活函数中，也采用类似的非线性函数设计，从而对 SPD 矩阵进行修正。其公式化表达如下：

$$\mathbf{X}_k = f_r^{(k)}(\mathbf{X}_{k-1}) = \mathbf{U}_{k-1} \max(\epsilon \mathbf{I}, \Sigma_{k-1}) \mathbf{U}_{k-1}^T \quad (4-7)$$

其中， $\mathbf{U}_{k-1}$  和  $\Sigma_{k-1}$  通过特征值分解  $\mathbf{X}_{k-1} = \mathbf{U}_{k-1} \Sigma_{k-1} \mathbf{U}_{k-1}^T$  得到。 $\epsilon$  作为修正阈值， $\max(\epsilon \mathbf{I}, \Sigma_{k-1})$  是一个对角矩阵。该对角矩阵的每一个元素被定义为

$$\mathbf{A}(i, i) = \begin{cases} \Sigma_{k-1}(i, i), & \Sigma_{k-1}(i, i) > \epsilon \\ \epsilon, & \Sigma_{k-1}(i, i) \leq \epsilon \end{cases} \quad (4-8)$$

根据 ReLU 函数的经验，ReLU 函数的整流可以产生稀疏性。公式 4-7 的变换，可以防止输入的矩阵贴近非正矩阵。在应用卷积层之后，输入的矩阵已经是非奇异的。也就是说，即使原始 SPD 矩阵的特征值都远大于零，将  $\epsilon$  设置在前  $n$  个最小特征值之上也是有必要的。

对数映射层是黎曼流形上的卷积网络特有的一种结构。

根据黎曼流形本身的理论，黎曼流形上每个点都对应一个切平面，在这个切平面上，流形上的其他点，都可以通过简单的变换映射到该切平面上。其相对关系如图 4-1 所示。




图 4-1: 黎曼流形和切平面示意

SPD 流形上的点可以通过如下一组操作映射到该切平面上。

$$\text{Exp}_{\mathbf{P}}(\mathbf{S}_i) = \mathbf{P}^{1/2} \text{Exp}(\mathbf{P}^{-1/2} \mathbf{S}_i \mathbf{P}^{-1/2}) \mathbf{P}^{1/2} \quad (4-9)$$

该切平面上的点也可以通过逆向操作映射回 SPD 流形上。

$$\log_{\mathbf{P}}(\mathbf{P}_i) = \mathbf{P}^{1/2} \log(\mathbf{P}^{-1/2} \mathbf{P}_i \mathbf{P}^{-1/2}) \mathbf{P}^{1/2} \quad (4-10)$$

通过把黎曼流形上的点和切平面上的点相互映射，可以将 SPD 矩阵映射成方便进行传统欧式空间下操作的形式。

将这种黎曼计算应用于卷积网络，可以方便地将 SPD 矩阵映射回欧式空间中的特征向量，可以得到：

$$\mathbf{X}_k = f_l^{(k)}(\mathbf{X}_{k-1}) = \log(\mathbf{X}_{k-1}) = \mathbf{U}_{k-1} \log(\boldsymbol{\Sigma}_{k-1}) \mathbf{U}_{k-1}^T \quad (4-11)$$

其中  $\mathbf{X}_{k-1} = \mathbf{U}_{k-1} \boldsymbol{\Sigma}_{k-1} \mathbf{U}_{k-1}^T$  是常见的矩阵特征值分解， $\log(\boldsymbol{\Sigma}_{k-1})$  是由特征值的对数操作得到的对角矩阵。

传统的神经网络通常使用反向传播算法进行整体的训练。当前的反向传播算法虽然对黎曼卷积层依旧奏效，在黎曼 ReLU 和 LogEig 层上却需要进一步优化。所幸，Ionescu 等人在 2015 年就推广了 SPD 矩阵的反向传播过程。

$$\frac{\partial L^{(k)}(\mathbf{X}_{k-1}, y)}{\partial \mathbf{X}_{k-1}} = \mathcal{F}^* \left( \frac{\partial L^{(k+1)}(\mathbf{X}_k, y)}{\partial \mathbf{X}_k} \right) \quad (4-12)$$

通过公式 4-12 对反向传播做变形即可。

### 4.2.2 整体设计

一个 SPD 流形下的黎曼卷积块结构如图所示：在对数映射层之后，输出




图 4-2: 黎曼卷积块示意

的向量可以被用于传统的神经网络操作。比如使用全连接层作为分类器进行

分类。

本章提出的黎曼卷积结构均可以推广到其他使用卷积神经网络进行脑电识别的模型中。可以根据实际需要调整卷积参数，以便获得更佳效果。

这里给出一种极其简单的模型架构，称之为 **RG-CNN** 模型。模型由两个黎曼卷积层、一个对数映射层和一个全连接层组成。相邻黎曼卷积层之间使用 **SPD** 流形下的 **ReLU** 函数作为激活函数。

与第三章提出的模型不同，黎曼卷积网络使用的输入数据是 **SPD** 矩阵，对于脑电数据来说，是每个时间片数据的协方差矩阵形式。可以通过如下变换得到：

$$\mathbf{Z} = \frac{1}{T-1} \mathbf{X}\mathbf{X}^T \quad (4-13)$$

其中， $\mathbf{x} \in \mathbb{R}^{C \times T}$  是来自  $k$  个类别的脑电数据片，其对应的标签为  $y \in \{1, 2, \dots, k\}$ 。 $C$  是信道的数目， $T$  是时间点采样的数目， $\mathbf{Z}$  为得到的用作输入的协方差矩阵。

### 4.2.3 优化算法

黎曼卷积模型在实际训练中容易遇到难以收敛或收敛过慢，或陷入局部最优解的问题。这主要是因为，黎曼卷积结构的每个卷积块对应的卷积操作，都保持了输入矩阵的对称正定形式。因此黎曼卷积可以看作是原始输入的数据点在 **SPD** 黎曼流形上的位置变换。所以在经过一定次数的迭代之后，同类间数据点距离变动太小。

为了解决这个问题，有必要提出一种优化迭代算法。

传统的基于黎曼几何的分类方法，经常会计算不同类的质心。基于黎曼几何的方法认为，每个对称正定的矩阵都对应着黎曼流形上的一个点，而属于同一个类的众多点构成了一个类的分布。黎曼流形上距离这个类所有点距离最小的点，称为这个类的质心，标记为  $\mathbf{G}$ 。

此处参考了这一概念，提出一种新的专用于黎曼卷积网络的损失函数。

$$\mathcal{L}(\mathbf{Z}) = -\log \frac{e^{-\delta^2(\mathbf{f}(\mathbf{Z}), \mathbf{f}(\mathbf{G}))}}{\sum_{i=1}^K e^{-\delta^2(\mathbf{f}(\mathbf{Z}), \mathbf{f}(\mathbf{G}_i))}} \quad (4-14)$$

其中， $\mathbf{Z}$  表示输入的矩阵， $f(\cdot)$  表示当前使用的模型，这个损失函数即计算了矩阵  $\mathbf{Z}$  到当前几个质心的距离的交叉熵损失。

基于此损失函数，优化算法设计为算法 4-1 所示

**算法 4.1** 黎曼卷积优化算法

输入：数据集  $S = \{Z_i, y_i\}_{i=1}^N$

输出：模型参数  $\varphi$

初始化：模型参数  $\varphi$ ，学习率  $\alpha$

使用 Adam 优化算法更新学习率  $\alpha$

1: **repeat**

2: 更新模型参数

3:  $\varphi_{\text{model}} = \varphi_{\text{model}} - \alpha \left( \frac{\partial \mathcal{L}(S)}{\partial \varphi_{\text{model}}} \right)$

4: 更新每个类的质心

5: 如果模型训练已经迭代了  $m$  次，则更新  $\alpha = 0.1 \times \alpha$

6: **until** 模型收敛

这样的优化迭代算法，将质心的偏移考虑在其中，并根据次数即时调整学习率的大小，超参数  $m$  可以根据经验人为设定。减缓了黎曼卷积模型在实际训练中难以收敛或收敛过慢，或陷入局部最优解的问题。

## 4.3 实验与分析

### 4.3.1 数据集介绍

与第三章所做实验类似，依旧在 BCI IV 2a、SMR-BCI、OpenBMI 三大运动想象数据集上进行实验。BCI IV 2a 和 SMR-BCI 是运动想象脑机接口的基准数据集，OpenBMI 是当下最大规模的运动想象数据集。

BCI IV 2a 数据集包含了 9 个名健康被试，进行左手、右手、脚以及舌头四种运动想象。脑电数据使用 22 通道的 Ag/AgCl 电极以 250Hz 的采样频率进行采集，分两天一共记录了 288 个时间窗 (trial) 的脑电数据。

为了保持和其他数据集实验的一致性，只使用来自左手和右手运动想象的数据。这些数据中，只有其中的 20 个与运动皮层相关的区域信道被使用，分别是 FC3, F C1, F Cz, F C2, F C4, C5, C3, C1, Cz, C2, C4, C6, CP3, CP1, CPz, CP2, CP4, P1, Pz, P2。脑电数据使用下采样从 250Hz 下采样至 100Hz。一个时间窗的时长为 3 秒，因此其维度为通道数  $\times$  采样时间点数，即  $20 \times 300$ 。

SMR-BCI 数据集包含 15 个信道的来自二分类类运动想象任务的数据，这些数据从 14 个健康被试上采集而来。采样频率为 512Hz。每名被试采集来自两次，共 160 个时间窗的数据。

类似的，使用下采样从 512Hz 下采样至 100Hz。每个时间窗时长 4 秒，因

此其维度为通道数  $\times$  采样时间点数，即  $15 \times 400$ 。

OpenBMI 数据集一共采集了 54 名被试进行左手和右手运动想象的脑电数据。采集的脑电数据信道数为 62，采样频率为 1000Hz。

为了保持实验的一致性方便对比，采用其中 20 个与运动反应皮层相关的信道数据。FC3, F C1, F Cz, F C2, F C4, C5, C3, C1, Cz, C2,C4, C6, CP3, CP1, CPz, CP2, CP4, P1, Pz, P2。类似的，使用下采样从 1000Hz 下采样至 100Hz。每个时间窗时长 4 秒，因此其维度为通道数  $\times$  采样时间点数，即  $20 \times 400$ 。

### 4.3.2 二分类对比实验

为了验证模型的优越性，将本章提出的 RG-CNN 模型与现有的一些常用方法在多个数据集上的效果进行对比验证。这些被挑选用于对比实验的方法分别为 FBCSP-SVM、Deep Convnet、EEGNet-8,2、Spectral-spatial CNN。

以下简单介绍这些被挑选出来作为对比的实验方法。

**FBCSP-SVM:** FBCSP 是在 CSP 算法的思想基础上而开发的。通过使用 FBCSP 作为特征提取方法，从多个频带中提取 EEG 特征。应用 4 个空间滤波器将 EEG 信号分解为 9 个频带，每个频带带宽为 4Hz，分别为 (4 - 8Hz, 8 - 12 Hz, ..., 36 - 40 Hz)。随后，通过结合网格搜索算法，使用支持向量机 (SVM) 进行分类。对于网格搜索算法，评估了对分类验证集的预测，以获得最优的超参数集。最终，将具有最佳参数的 SVM 分类器用于测试目的。

**Deep Convnet:** Deep Convnet 是早期被引入的具有两个卷积块结构的神经网络模型。Deep Convnet 使用 8-30Hz 频带滤波后的脑电数据作为输入，被证明可以有效的用于处理脑电信号分类。

**EEGNet-8,2:** EEGNet-8,2 是受 FBCSP 启发而提出的一种具有影响力的深度神经网络模型。可以学习到具有区分度的脑电数据特征，并且可以通用于多个脑机接口的实验范式。为了增强对比实验的说服力，此处用作对比方法的 EEGNet 使用原始论文中最优的超参数进行训练。原始的 EEG 数据以与 Deep Convnet 相同的方法进行预处理，作为 EEGNet-8, 2 的输入。

**Spectral-spatial CNN:** Spectral-spatial CNN 是基于卷积神经网络架构设计的专用于脑电数据识别的网络模型，在被试无关的运动想象任务为了进行公平的比较，所有方法都在相同的训练、验证和测试集上进行了评估。对于每一次实验都会报告其准确度和 F1 分数 (F1-score) 两方面指标。

将其具体的相关统计结果展示在表 4-1 中。表格统计结果以均值和标准差

两部分组成。均值是对同一数据集内多名被试的统计数据进行均值计算的结果，标准差是对同一数据集内多名被试统计数据进行标准差计算得出的结果。

表 4-1: RG-CNN 模型对比实验结果

Dataset	Model	subject-dependent		subject-independent	
		Accuracy	F1-score	Accuracy	F1-score
BCI IV 2a	FBCSP-SVM	75.64± 14.49	74.49 ± 18.68	58.09 ± 9.91	51.53 ± 24.01
	Deep Convnet	63.72 ± 17.18	59.85 ± 22.17	56.34 ± 8.86	30.62 ± 28.96
	EEGNet-8,2	65.93 ± 18.44	64.45 ± 26.23	64.26 ± 11.03	60.19 ± 19.96
	Spectral-spatial CNN	<b>76.91 ± 13.75</b>	<b>77.03 ± 15.41</b>	<b>66.05 ± 13.70</b>	<b>61.91 ± 20.31</b>
	RG-CNN	67.32 ± 11.52	61.69 ± 14.57	64.15 ± 13.21	59.26 ± 19.64
SMR-BCI	FBCSP-SVM	74.50 ± 18.14	<b>70.65 ± 23.65</b>	62.64 ± 15.43	45.07 ± 34.93
	Deep Convnet	60.79 ± 16.07	56.84 ± 17.83	65.26 ± 16.83	<b>54.38 ± 32.58</b>
	EEGNet-8,2	67.76 ± 18.09	68.05 ± 21.11	58.07 ± 11.45	34.43 ± 31.35
	Spectral-spatial CNN	<b>76.76 ± 16.66</b>	69.87 ± 28.15	<b>66.21 ± 15.15</b>	54.36 ± 31.21
	RG-CNN	67.31 ± 12.64	62.64 ± 16.69	63.67 ± 15.24	52.12 ± 32.54
OpenBMI	FBCSP-SVM	<b>66.06 ± 16.58</b>	64.66 ± 19.47	64.96 ± 12.70	65.25 ± 15.14
	Deep Convnet	60.31 ± 16.76	61.66 ± 18.17	68.33 ± 15.33	70.20 ± 17.10
	EEGNet-8,2	60.41 ± 17.12	56.80 ± 23.54	68.84 ± 13.87	70.39 ± 14.30
	Spectral-spatial CNN	65.19 ± 15.94	<b>66.97 ± 16.71</b>	68.11 ± 13.53	65.96 ± 16.79
	RG-CNN	64.47 ± 11.46	64.30 ± 13.37	<b>69.65 ± 12.95</b>	<b>62.45 ± 13.32</b>

在 BCIC IV2a 数据集的实验中，Spectral-spatial CNN 的方法在被试依赖的任务中表现最佳，在准确度和 F1 得分上都取得了最优成绩。在被试无关的任务中，Spectral-spatial CNN 方法表现最佳，在准确度和 F1 得分上都取得了最优结果。

在 SMR-BCI 数据集的实验中，被试依赖的任务中，准确度最高的是 Spectral-spatial CNN，而 F1 得分最高的是 FBCSP + SVM 方法。在被试无关的任务中，Spectral-spatial CNN 方法在准确度上都取得了最优结果。Deep Conv 在 F1 得分上表现最佳。

在 OpenBMI 数据集的实验中，被试依赖任务的准确度最高模型是 FBCSP-SVM，而 F1 得分最高的算法是 Spectral-spatial CNN。在被试无关的任务上，

RG-CNN 取得了最好成绩，在准确度和 F1 得分两项指标上取得最优结果。

本章提出的 RG-CNN 模型在被试无关的实验上，在三大数据集上的准确度和 F1 分数均达到作为对比的四大基准方法的水平。在 OpenBMI 数据集的被试无关实验中，相比其他方法中的最优结果更有着显著的突破。而在被试相关的实验中，RG-CNN 方法虽然没有达到最优结果，仍然取得了和其他当前主流算法相近的结果。

为了更好展示黎曼卷积结构对脑电数据的特征提取能力，将每一层结构所提取的特征可视化展示如图 4-3 所示。图中，蓝红两色数据点分别代表两类数据分布。四幅子图分别展示 (a) 原始的 SPD 矩阵数据分布情况，(b) SPD 矩阵数据在经过第一层 ReEig 后所得特征的分布情况，(c) 数据经过第二层 ReEig 后所得特征的分布情况，以及 (d) 整体结构最终提取到的数据特征分布情况。

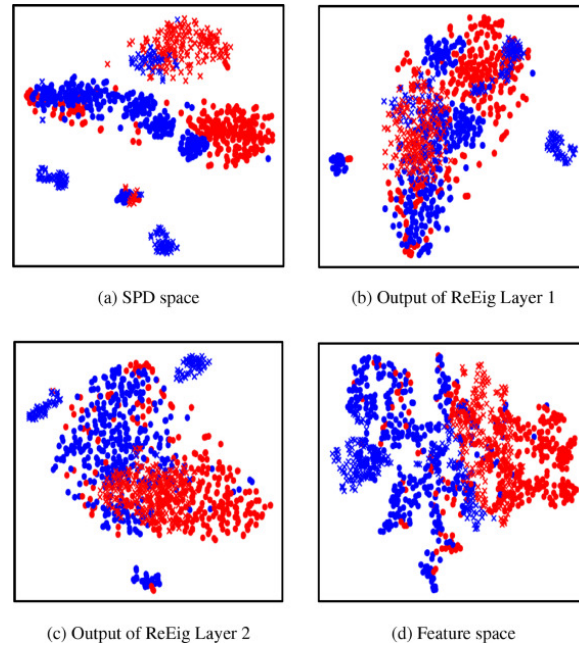


图 4-3: 黎曼卷积提取特征可视化

黎曼卷积提取特征的可视化过程，形象地解释了原始的 SPD 矩阵数据在经过多层黎曼卷积特征提取后，数据在保持 SPD 矩阵性质的同时进行的变化，代表两类数据的数据点逐渐分离，便于更高精度的分类。从 SPD 流形的角度，两类数据的 SPD 矩阵在黎曼流形上的几何距离增大，有利于提高分类的鲁棒性。

RG-CNN 模型通过在三大数据集，被试相关任务和被试无关任务上的优秀表现，证明了自动编码器和深度度量学习可以有利与卷积网络模型学习到脑电数据更合适的表达，获得更好的分类结果。同时，经过特征提取的可视化，确

定了黎曼卷积结构对于脑电数据出色的特征提取能力，验证了黎曼卷积结构推广到其他传统卷积结构用于脑电数据分类的可行性。

### 4.3.3 多分类实验

为了验证模型的优越性，将 RG-CNN 模型与现有的一些常用方法在 OpenBMI 和 BCIC IV 2b 上的效果进行对比验证。对于 OpenBMI 数据集，进行三分类实验。对于 BCIC IV 2b 数据集，进行四分类两方面实验，并针对每名被试上的表现进行详细分析。这些被挑选用于对比实验的方法分别为 FBCSP-SVM、Deep Convnet、EEGNet-8,2。

为了进行公平的比较，所有方法都在相同的训练、验证和测试集上进行了评估，并统计其准确度作为评估指标。

在 OpenBMI 数据集上的相关统计结果展示在表 4-2 中。表格统计结果以均值和标准差两部分组成。均值是对同一数据集内多名被试的统计数据进行均值计算的结果，标准差是对同一数据集内多名被试统计数据进行标准差计算得出的结果。

表 4-2: OpenBMI 数据集多分类任务黎曼卷积结构实验结果

Algorithms	Accuracy
FBCSP-SVM	52.01 ± 9.99
DeepConvNet	52.05 ± 11.62
EEGNet Model	62.06 ± 10.45
RG-CNN	68.81 ± 12.44

作为对比的三类脑电识别模型在 OpenBMI 上的三分类任务识别精度从 52% 至 62% 之间。本章提出的 RG-CNN 模型与现有的一些常用方法在 OpenBMI 和 BCIC 识别精度达到了 68%，相比于其他主流模型的识别精度取得了巨大的突破。

在 BCIC IV2b 数据集上的相关统计结果展示在表 4-3 中。表格统计了 BCIC IV2b 数据集中，每名被试的识别精度。

在 BCIC IV2b 数据集上的四分类任务中，FBCSP+SVM 的分类方法表现最差，平均分类精度仅有 35%，远低于其他方法，并且在不同被试之间的精度标准差大，FBCSP 算法的整体表现缺乏稳定性。

表 4-3: BCIC IV 2b 数据集多分类任务黎曼卷积结构实验结果

Subjects	FBCSP+SVM	DeepConvNet	EEGNet	RG-CNN
sub1	31.95	60.37	57.37	66.25
sub2	26.15	63.37	50.75	68.37
sub3	27.75	68.50	61.87	73.50
sub4	49.50	75.00	73.25	77.88
sub5	28.20	65.62	58.37	73.88
sub6	47.65	62.37	58.00	66.00
sub7	32.65	56.50	52.00	66.00
sub8	37.90	83.37	78.02	85.38
Avg	35.21	66.88	61.20	72.15

DeepConvNet 和 EEGNet 作为卷积网络用于脑电数据识别的经典尝试，表现相似，平均分类精度分别为 66% 和 61%。

本章提出的 RG-CNN 模型，不仅在平均识别精度上远高于其他方法，达到了 72%，并且精度方差减小，算法稳定性相比于传统方法进一步改善。在不同被试的统计结果中，均强于同类方法，这说明 RG-CNN 网络的鲁棒性，RG-CNN 网络所使用的黎曼卷积层相比于传统的卷积结构具有更好的学习脑电数据特征的表现，在面对不同被试的生物差异性和对抗脑电数据低信噪比的特点时，具有更好的鲁棒性。

#### 4.3.4 黎曼结构有效性评估实验

为了验证模型的优越性，将 RG-CNN 模型与具有相同层数的传统卷积网络在 BCIC IV 2a、SMR-BCI 和 OpenBMI 三大数据集进行对比验证。在每个数据集上，同时进行被试相关和被试无关两项任务的实验验证。

作为对比的传统卷积网络标记为 Deep Conv，与 RG-CNN 具有相似的卷积层数。为了客观公正，保留与卷积结构无关的模型架构和参数。所有方法都在相同的训练、验证和测试集上进行了评估，并统计其准确度和  $F1_{defen}$  作为评估指标。

在三大数据集上的相关统计结果展示在表 4-4 中。表格统计结果以均值和标准差两部分组成。均值是对同一数据集内多名被试的统计数据均值计算

的结果，标准差是对同一数据集内多名被试统计数据进行标准差计算得出的结果。

表 4-4: 黎曼结构有效性评估实验结果

Dataset	Comparison Model	subject-dependent		subject-dependent	
		Accuracy	F1-score	Accuracy	F1-score
BCIC IV 2a	Deep Conv	63.72 ± 17.18	59.85 ± 22.17	56.34 ± 8.86	30.62 ± 28.96
	RG-CNN	67.32 ± 11.52	61.69 ± 14.57	64.15 ± 13.21	59.26 ± 19.64
SMR-BCI	Deep Conv	61.40 ± 15.66	55.27 ± 22.00	65.26 ± 16.83	54.38 ± 32.58
	RG-CNN	67.31 ± 12.64	62.64 ± 16.69	63.67 ± 15.24	52.12 ± 32.54
OpenBMI	Deep Conv	60.31 ± 16.76	61.66 ± 18.17	68.33 ± 15.33	70.20 ± 15.18
	RG-CNN	64.47 ± 11.46	64.30 ± 13.37	69.65 ± 12.95	62.45 ± 13.32

在所有的三个数据集上的被试相关任务和被试无关任务上，RG-CNN 模型在准确度和 F1 得分两项指标的表现整体优于使用传统卷积结构的 Deep Conv 模型。

其中，在 BCIC IV 2a 的被试无关任务中，RG-CNN 模型相比于传统的 CNN 模型优势明显。其准确度得到了 8% 以上的识别率提高。对于 SMR-BCI 数据集上的被试无关实验，虽然指标有所下降，但是在被试相关的实验中准确度和 F1 得分均获得大幅提高。

实验结果验证了黎曼卷积结构具有帮助卷积神经网络学习到更优秀的特征的作用，具有改善既有卷积网络模型提高识别精度的积极效果。

这充分证明了黎曼卷积结构的有效性，并说明了黎曼卷积结构推广到其他传统卷积网络的合理性。

## 4.4 本章小结

本章提出的一种黎曼网络结构，为对称正定矩阵（SPD 矩阵）的深层非线性学习开辟了一个新的方向。SPD 矩阵经常被用于脑电信号识别中作为特征，但是过去对 SPD 矩阵的使用往往是简单地基于度量的分类，没有深层次探索 SPD 矩阵的表示能力。首先，效仿卷积网络中的卷积层设计了双线性映射层，将输入 SPD 矩阵转换为更理想的 SPD 矩阵，利用特征值校正层对新的 SPD 矩

阵应用非线性激活函数，并设计了一个特征值对数层对规则输出层的 SPD 矩阵进行黎曼计算。为了训练所提出的深度网络，在 SPD 流形上利用一种新的随机梯度下降反向传播来更新结构化连接权值和所涉及的 SPD 矩阵数据。实验结果表明，在三种典型的脑电数据分类任务中，所提出的 SPD 矩阵网络训练简单，性能优于现有的 SPD 矩阵学习和最新的方法。

# 第五章 应用：脑控机器人小车系统

为了验证本文提出的脑电识别算法的实用性，我们将本文提出的两个脑电识别模型成功地使用在实际系统中。本章主要介绍一个基于脑电识别的运动想象脑机接口系统。通过这个案例的实践证明，本文提出的方法具有较高的实用性，能够在实际应用中发挥很大的作用。

## 5.1 运动想象脑机接口背景

脑机接口 (BCI) 可以定义为一个系统，它将用户的大脑活动模式转换为交互式应用程序的消息或命令。BCI 使用者的大脑活动通常是通过脑电图 (EEG) 来测量的。例如，BCI 可以使用户通过分别想象左手或右手的移动，将光标移动到计算机屏幕的左侧或右侧，无需任何体力活动即可实现计算机控制。基于脑电的脑机接口有望彻底改变许多应用领域，特别是使严重运动障碍的用户能够控制辅助技术，例如文本输入系统或轮椅，或者将脑机接口作为中风患者的康复设备，作为新的游戏输入设备，或者设计能对用户心理状态做出反应的自适应人机界面。

基于运动想象的脑机接口是通过检测用户想象运动时产生的脑电信号来判断用户意图，进而实现人脑与外部设备之间的直接通信与控制。被试在想象运动的过程中，大脑皮层会产生两种变化明显的节律信号，8-15Hz 的  $\mu$  与 18-24Hz 的  $\beta$ 。同时，大脑皮层对侧运动感觉区的脑电节律能量会明显降低，而同侧运动感觉区的脑电节律能量增大，这种现象为事件相关异步 (Event Related Desynchronization, ERD) 和事件相关同步 (Event Related synchronization, ERS)。ERD/ERS 现象存在空间分布特性。也就是因为运动想象 EEG 空间分布的特性，构成了解码运动想象思维信号的生理基础。

为了使用脑机接口，通常需要两个阶段：(1) 离线训练阶段，在此期间对系统进行校准；(2) 操作在线阶段，在此阶段，系统可以识别大脑活动模式并将其转换为计算机的命令。在线脑机接口系统是一个闭环系统，首先由用户产生特定的脑电模式（例如，使用运动想象）并测量这些脑电信号。然后，

通常使用各种空间和频谱滤波器对 EEG 信号进行预处理，并从这些信号中提取特征，以便以恰当的形式表示它们。最后，对这些脑电特征进行分类，将这些脑电特征转化为应用程序的命令，向用户提供反馈以告知他们是否识别出特定的精神命令。

尽管目前正在努力实现无需校准的脑机接口系统，但离线校准目前仍然占据主流，并且在大多数 BCI 中是实验可靠系统所必需的。在这一阶段，对分类算法进行校正，并从多个脑电通道中选择最优特征。对于该校准，需要从用户处预先记录训练数据集。脑电信号具有高度的用户特异性，因此，目前大多数在线的脑机接口系统都是专门为每个用户校准的。该训练数据集包含用户根据给定的指令多次执行感兴趣的每项脑力任务时记录的脑电信号。

## 5.2 基于运动想象的脑控机器小车系统

本节将对我们搭建的基于运动想象的脑控机器小车系统做一个全面的介绍，包括系统需求、使用流程、系统架构几个方面。

### 5.2.1 系统需求

目前，脑机接口进入广泛使用阶段的关键在于提高识别精度和减少校准时间。

精度的判断指标主要有两个，准确度和 F1 得分。准确度，即将一段脑电信号正确识别出相对应指令的概率，准确度越高，构建出的脑机接口系统越可靠。另一指标是 F1 得分，F1 得分同时兼顾了分类模型的准确度和召回率，可以视为模型精确度和召回率的调和平均。

校准时间指的是用户佩戴脑电数据采集设备到算法微调完毕可以进行实际的指令解析的时间。因为脑机接口系统是致力于用户实际使用的系统，所以能够便捷地校准使用，对提高用户体验，增强系统实用性至关重要。用户实际用于校准的时间既包含对脑电采集的硬件设备的校准时间，又包括因脑电数据特有的用户各异性所带来的算法校准时间开销。本系统不涉及对硬件的校准改进，侧重于改进算法本身的校准时间开销。具体表现为，使用本文提出的具备高精度的跨被试任务识别能力的两种模型，实现模型校准时间的减少。其中，二分类任务使用的算法为第三章所设计的 DML-AE 模型，多分类任务使用的算法为第四章所设计的 RG-CNN 模型。

### 5.2.2 使用流程

本小节介绍脑控机器人小车系统的使用流程。

具体的使用流程如图 5-1 所示：




图 5-1: 使用流程图

首先，用户根据是否第一次使用脑控小车系统选择注册 ID 和用户名。

然后，用户佩戴脑电数据采集头盔，并调试头盔通过蓝牙连接上位机。保持实验环境电噪声干扰相对较小，并矫正头盔和上位机之间的数据传输效果。如果电噪声干扰过大或数据传输质量差则提示用户重新矫正头盔和上位机之间的数据连接，并重新检查实验环境。

在上位机获取稳定的脑电数据流之后，使用流程可以分为数据训练和在线脑电信号识别两个使用阶段。其中，数据训练阶段工作流程如下：

上位机提示进入训练数据采集阶段，用户根据眼前屏幕提示进行运动想象任务。脑电数据采集可随实验范式、分类数量等即时调整。此处以 BCI C 数据集的采集过程为基础模版，介绍一次二分类运动想象离线数据采集过程。

用户被要求根据眼前的屏幕提示进行想象左手或者想象右手运动。一次有效实验的时间为 9s，具体流程包含三个阶段，如图 5-2 所示：

0 秒至 3 秒为准备时间，用户前方显示屏不开机，处于黑屏状态，提示被试志愿者放松；

3 秒时，试验开始提示，用户前方显示屏出现十字光标，提示用户试验马上开始；

3 秒至 9 秒为试验时间，当显示屏上出现“向左”或“向右”箭头时，用户被要求按照光标提示方向进行想象左手或者右手在运动。每次试验的有效数据为第 3s 到第 9s 之间的数据。




图 5-2: 一次数据采集示意

上位机截取第 3s 到第 9s 之间的脑电数据作为一个时间片 (trial) 的脑电数据，并存入数据库，用作构建用户专属的个人脑电数据集。

上位机使用用户专属的个人脑电数据集对算法模型进行训练。若是二分类运动想象任务则使用第三章提出的 DML-AE 模型，若是多分类任务则使用第四章提出的 RG-CNN 模型。在经过足够的训练迭代之后，算法模型的识别精度足够稳定，将模型保存。

在线脑电信号识别阶段的工作流程如下：

上位机提示进入在线数据识别阶段，根据用户选择的实验范式和分类数目选择相应的模型。若是二分类运动想象任务则使用第三章提出的 DML-AE 模型，若是多分类任务则使用第四章提出的 RG-CNN 模型。选择好模型之后，进行在线的脑电识别，将每个数据窗的脑电数据识别为用于控制机器人小车的指令。并通过 ROS 系统传输指令完成控制。

### 5.3 系统架构和实现

为了实现上述的目标，需要从系统架构层面对系统进行精心设计，使系统不仅具有在线识别脑电信号的可靠性，而且具有相当程度的易用性。

为了实现通用化和标准化的系统功能接口，系统整体使用 Python 语言实现。系统架构设计将脑机接口系统中常用到的流程接口化，如存储脑电数据、对脑电数据进行归类保存、脑电数据在线分类等。此外，还考虑到当前已经集

成的和将来可能需要集成的脑电识别模型所必须的功能，为了更好地兼容相应第三方平台，预留了数据接口。

系统根据承担的职能不同，可以分为数据采集、在线识别和离线评估三大模块。其中数据采集模块采集用户信息，包括用户身份信息和用户脑电数据。数据采集模块，不仅为脑机接口系统的在线使用提供即时数据，也将不同用户的不同任务的数据分类保存，作为本系统特定数据集服务于模型离线评估模块和在线识别模块。在线识别系统，使用数据采集模块提供的即时数据流和模型离线评估模块提供的评估结果，将用户即时脑电数据解析识别为对应的机器指令，用于交互可能的外部设备，比如 ROS 机器人等。模型离线评估模块通过拆分组合各个预处理和分类算法对模型性能进行离线评估，既可以对在线识别模块的实际模型使用提供指导，又可以作为天然的不同脑电识别算法的实验评估平台。

### 5.3.1 数据采集模块

数据采集模块中，系统应用了高性能的 EPOC X 和 openvibe 分别作为数据采集的硬件设备和软件平台。

基于脑电信号识别的脑机接口系统，需要使用脑电波采集设备对用户脑电信号进行采集并放大。采集设备的好坏，直接影响所获得的脑电数据的质量。市面上可供选择的脑电信号采集设备可大致区分为消费级和医疗级，消费级设备售价便宜而信噪比高难以支撑科学研究，而医疗级设备信噪比高却成本高昂，不利于脑机接口系统的消费普及。

为了兼顾信号质量和成本，选择了 EMOTIV 公司生产的 EPOC X 脑电信号采集头盔。EMOTIV 公司是一家专业生产脑机接口设备的公司，其生产的脑机接口采集设备因出色的性价比成为国内外脑机接口入门级研究和商业化应用的优先选择。EPOC X 是其中一款采用盐水电极的便捷头戴式脑电信号采集头盔，共含有 14 个脑电采集信道，分别是 AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4。EPOC X 最高采集频率可达 50Hz，并允许使用蓝牙与个人电脑软件平台连接。

EPOC X 可以通过蓝牙与配套的软件平台 EmotivPro 连接，读取并打印即时脑电数据流。为了方便后续开发和基于成本的考虑，此处采用开源第三方脑机接口平台 cykit + openvibe 读取并打印即时脑电数据流。

openvibe 是知名的开源的脑机接口平台，对脑电数据提供了波形打印和导




图 5-3: epocX 脑电数据采集设备和 cykit 即时数据流

入导出等功能。cykit 是对 `openvibe` 的二次封装和开发，方便与 EPOC 设备进行连接，并允许在 web 端打印即时脑电数据。即时数据的传输格式采用 `fif` 格式，`fif` 格式是即时脑电数据流的常用格式。

数据采集模块的存储功能使用 `LevelDB` 非关系型数据库存储系统来管理用户数据，包括身份信息、用户自身的脑电数据和相应设置参数等。`LevelDB` 和与 `python` 之间的接口 `Plyvel` 可以用作数据采集模块与 `LevelDB` 之间的交互接口。之所以使用 `LevelDB` 作为数据存储是因为作为新一代非关系数据库，在响应速度上相比传统的 `MySQL` 具有天然优势，更适合对相应速度有高要求的在线系统使用。而相比与其他非关系数据库，比如 `Redis` 等，`Redis` 虽然速度足够快，但是使用内存存储数据，`LevelDB` 在持久化上具有明显优势。

### 5.3.2 在线识别模块

在线识别模块，主要包括数据预处理和识别算法两方面。

数据预处理部分主要通过 `python` 的 `mne` 库来实现。`mne` 是基于 `python` 开发的一个开源的脑电数据处理包，`mne` 打包了常用的脑电数据处理函数。比如小波变换，快速傅立叶变换等。

为了对连续的原始脑电数据流进行数据预处理，首先需要进行信道选择。在使用在线的脑机接口系统时，脑电采集头盔的多个信道往往并不全部使用，所以需要根据算法的实际需要，和当前各个信道数据质量的表现，选择有需要的信道数据，而忽略掉来自其余信道的数据。

随后，对筛选得到的信道数据进行数据切片，按照预先设定的切片时间窗，每 1s 截取一次时间窗的脑电数据。一般每个时间窗设置为 6s。相邻两时间窗的脑电数据之间存在 5s 的数据覆盖。这主要是为了提高在线系统的响应粒

度，另一方面，也起到了数据增强的效果。

对各个时间窗的数据进行平均化，然后进行带通滤波。这里使用的带通滤波主要是 0.5Hz-50Hz 的带通滤波，这主要是脑电信号的生理特点决定的。脑电信号中包含多种波，包括 Delta 波，Theta 波，Alpha 波、Beta 波、Gamma 波。这些波的频率大多在 0.5Hz-50Hz 之内。使用频带滤波可以过滤大部分噪声。

最后，根据需要对筛选得到的信道数据进行伪迹去除。伪迹是一些干扰信号在脑电数据上的表现。用户自身的眼电信号（EOG），肌肉电信号（EMG），心电信号（ECG）都会对我们需要关注的脑电信号造成干扰，在波形上多反应为有规律的波形特征。除了在数据采集过程中尽量避免伪迹干扰外，还可以对即时脑电波形进行观察并采取针对性措施。以处理眼电伪迹为例，使用基于时域或者是频域的回归方法，可以去除眼活动造成的高频率电信号干扰。

识别算法方面，主要是使用了第三章和第四章提出的两种深度神经网络模型。其中，第三章提出的 DML-AE 模型对于二分类任务的脑电识别表现更出色，而在多分类任务中第四章提出的 RG-CNN 模型一般效果更好。所以系统默认的二分类任务模型为 DML-AE 模型，多分类任务模型为 RG-CNN 模型。这里值得强调的是，运动想象的脑电识别任务，因为客观的脑电采集设备和生理特性，无法进行细粒度的分类，主要任务大致有二分类到四分类等。二分类主要是左手运动想象和右手运动想象。四分类任务在左右手的运动想象的基础上增加了舌头的运动想象和双脚的运动想象。正是因为这些生理基础造成了脑机接口在二分类任务和多分类任务中有不同的模型偏好。

以上两种模型均使用 Pytorch 框架实现，Pytorch 是便于 python 语言开发和部署调试的深度学习框架，相比于 TensorFlow、MxNet 等，在具有相同的运行速度和训练速度的同时，提升了构建模型的敏捷性和易用性。

以上介绍了在线识别模块所涉及的部分，在线识别模块部署在上位机中，一般使用 Anaconda 管理 python 环境。因为一些分析工具的限制，上位机建议使用 Windows 系统。

### 5.3.3 离线评估模块

模型离线评估模块中，系统将算法模型评估所需的数据、范式处理、识别算法和结果可视化等步骤拆分成单独的组件。方便后续对模型算法进行评估。离线评估系统提供了对各组件的抽象管理，主要包括 4 大概念，分别是

Dataset、Paradigm、Evaluation、Pipeline。其架构如图 5-4 所示。

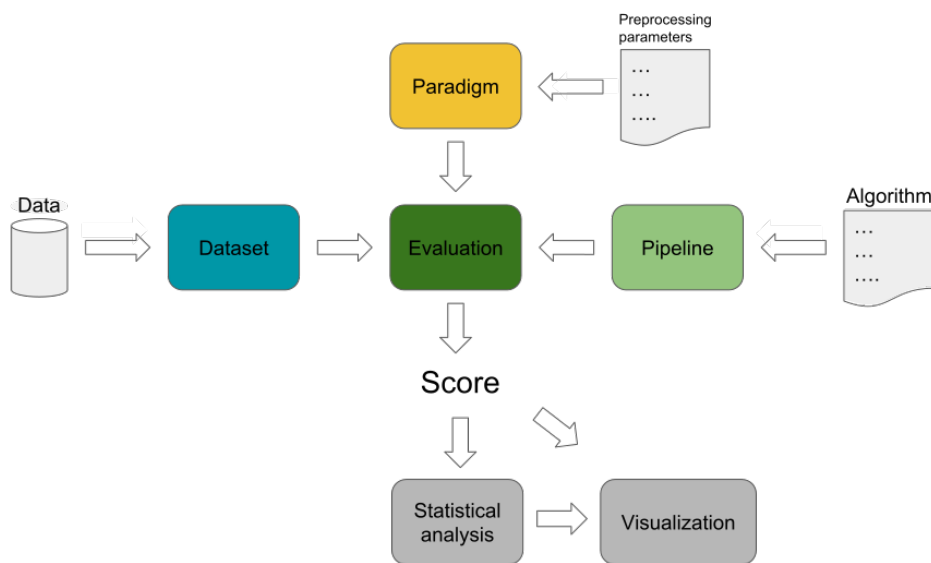


图 5-4: 离线评估模块

**Dataset** 模块部分提供对数据的抽象访问。数据集采用本地存储的数据，并将其转换为 MNE 原始对象。提供选项将每个被试的所有不同时期的数据记录分类存放。

**Paradigm** 模块部分定义了原始数据转换为预处理后的时间窗数据的方法。以及多分类任务的参数设置，比如运动想象任务中分类数目为二分类或是多分类；以及封装了用于不同实验范式的预处理方法。

**Evaluation** 模块部分定义了如何从每名被试的每次脑电数据得到最终识别性能的数据统计。可供选择的条目有被试相关评估和被试无关评估或是其他迁移学习的设置。

**Pipeline** 模块部分每个算法的用于识别的每个步骤。经典的脑电识别算法很多基于机器学习方法，并不是端到端的。此处将这系列方法打包作为处理流程。

## 5.4 系统应用反馈

目前本章所述脑机接口已部署于脑控机器车项目中，并投入实际使用。经过相关测试，本系统已证明可以满足基本的脑控机器小车的功能需要，相比于其他类似的脑控机器车，脑控轮椅等系统，本系统具有更好的可靠性和易用性。

在获取训练数据阶段，用户根据屏幕信息执行响应运动想象任务。web 提示如图 5-5 所示。屏幕出现红色向右箭头，提示用户进行右手运动想象。




图 5-5: 屏幕提示右手运动想象

在在线识别阶段，系统识别出指令后，屏幕显示蓝色方块，提示当下识别到的指令。屏幕出现蓝色左侧方块，显示当前上位机对用户脑电数据识别为左手运动想象。




图 5-6: 屏幕显示正在左手运动想象

默认采用的通用脑电识别模型分别为第三章提出的 DML-AE 网络和第四章提出的黎曼卷积网络。基于深度度量学习和自动编码器的 DML-AE 模型，对于二分类的脑电识别精度高，跨被试泛化能力强。而黎曼卷积网络在多分类任务中都具有优秀的跨被试泛化能力表现。其特有的黎曼卷积结构在复杂环境下，具有更强的抗噪声能力。

在实际使用中，取得了略次于实验室环境的识别精度表现。命令行启动四分类脑电识别，会根据即时数据流识别生成即时的指令流，演示如下：

在高信噪比、中信噪比、低信噪比三种实施环境下，识别准确度如表 5-1 所示。



## 5.5 本章小结

本章主要介绍了基于脑电识别的脑机接口实际应用案例。通过在实际脑机接口控制机器小车中的应用，充分验证了本文提出的脑电识别方法的实用性和易用性，证明其可作为脑机接口的大规模商业化普及的有效尝试。同时，通过对相关脑电采集硬件设备和软件平台的打通，再到建设公平有效的离线评估系统，使得本系统更具普遍适用性。在实际使用中，可以将指令控制的外设由机器小车更换为其他外设，达到根据需求灵活定制的效果。



## 第六章 总结与展望

本文主要分析了脑电信号识别任务的问题和挑战，针对脑机接口系统的可靠性和实用性发展，在充分分析现有脑机接口算法的基础上，提出了两种具有现实意义的脑电识别算法。

由于脑电信号本身的特殊性以及复杂环境下获取脑电信号呈现的特点，脑电信号识别目前仍面临诸多挑战。一方面，脑电信号有别于一般的数据，其本身的特殊性带来两方面的问题。首先，脑电信号本身极为微弱，即使在实验室环境下也极易受到噪声干扰，具有低信噪比的特点，进行识别时理应充分考虑这种低信噪比；此外，脑电信号作为生物信号，从不同被试采集得到的脑电信号数据往往因人而异，数据分布存在严重差异。一般的脑电信号识别方法都需要具有一定的跨被试泛化能力，而如何克服这种个体间的数据分布差异是脑电信号识别独有的技术难点。另一方面，有别于传统的图像识别，语音识别，获取脑电数据的条件更为苛刻，训练数据有限，如何从有限的数据实现高精度的分类和识别是脑电信号识别所面临的又一挑战。

为了解决上述脑电信号识别任务存在的低信噪比、个体差异、训练数据有限等问题，针对基于脑电识别的脑机接口系统，本文以卷积神经网络为基础模型，提出了两种脑电信号识别方法，并成功应用到了实际的脑机接口系统中。

本文提出的一种基于度量学习和自动编码器的卷积神经网络。该方法使用卷积神经网络作为基础模型。卷积神经网络拥有从脑电信号中有效地学习时间和空间特征的能力，节省了繁杂的预处理步骤。自动编码器则具有数据压缩能力，可以学到数据的潜在表征。通过融合深度度量学习（DML），该方法能够学习原始脑电数据中保留了分类信息的潜在表征。通过在 BCI IV 2a 数据集上的实验，证明了该模型优于传统的 FBCSP 算法和流行的神经网络（EEGNet）。通过特征可视化，验证了基于自动编码器的深度度量学习在脑电识别领域的可行性。

本文提出的一种黎曼网络结构，为对称正定矩阵（SPD 矩阵）的深层非线性学习开辟了一个新的方向。首先，效仿卷积网络中的卷积层设计了双线性映射层，将输入 SPD 矩阵转换为更理想的 SPD 矩阵，利用特征值校正层对新的

SPD 矩阵应用非线性激活函数，并设计了一个特征值对数层对规则输出层的 SPD 矩阵进行黎曼计算。为了训练所提出的深度网络，在 SPD 流形上利用一种新的随机梯度下降反向传播来更新结构化连接权值和所涉及的 SPD 矩阵数据。实验结果表明，在三种典型的脑电数据分类任务中，所提出的 SPD 矩阵网络训练简单，性能优于现有的 SPD 矩阵学习和最新的方法。

本文提出的两种脑电识别方法成功地应用在了实际生产环境中。本文根据脑机接口系统的客观要求，在保证脑电识别精度同时，提升了跨被试泛化能力和数据受限情况下的学习能力。相关的实验表明，本文提出的两种方法的有效性，并且相比较于已有的脑电识别手段，其准确率更高，跨被试泛化能力更强。在相关应用实践中，本文的识别方法也表现出了较高的识别精度，充分证明了其实用价值。

对于脑电信号识别问题的研究还有非常多的优化空间，沿着本文所述思路继续研究，可以对现有的经典模型进行优化改造，提高信号识别精度，和减少脑机接口系统的调试时间，提高系统的实用性。同时黎曼几何对于脑电信号识别的引入，为解决脑电识别模型的可解释性提供了新的思路。

## 参考文献

- [1] VALLABHANENI A, WANG T, HE B. Brain—computer interface[G] //Neural engineering. [S.l.]: Springer, 2005 : 85 – 121.
- [2] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C] // Proceedings of the IEEE conference on computer vision and pattern recognition. 2016 : 770 – 778.
- [3] RUBI C R, OTHERS. A review: speech recognition with deep learning methods[J]. International Journal of Computer Science and Mobile Computing, 2015, 4(5): 1017 – 1024.
- [4] RAKHLIN A. Convolutional Neural Networks for Sentence Classification[J]. GitHub, 2016.
- [5] ZHU D, BIEGER J, GARCIA MOLINA G, et al. A survey of stimulation methods used in SSVEP-based BCIs[J]. Computational intelligence and neuroscience, 2010, 2010.
- [6] POLICH J. Updating P300: an integrative theory of P3a and P3b[J]. Clinical neurophysiology, 2007, 118(10): 2128 – 2148.
- [7] SCHLÖGL A, LEE F, BISCHOF H, et al. Characterization of four-class motor imagery EEG data for the BCI-competition 2005[J]. Journal of neural engineering, 2005, 2(4): L14.
- [8] BRODU N, LOTTE F, LÉCUYER A. Comparative study of band-power extraction techniques for motor imagery classification[C] // 2011 IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB). 2011 : 1 – 6.
- [9] BLANKERTZ B, LEMM S, TREDER M, et al. Single-trial analysis and classification of ERP components—a tutorial[J]. NeuroImage, 2011, 56(2): 814 – 825.

- 
- [10] LOTTE F. A tutorial on EEG signal-processing techniques for mental-state recognition in brain-computer interfaces[J]. Guide to brain-computer music interfacing, 2014: 133–161.
- [11] KACHENOURA A, ALBERA L, SENHADJI L, et al. ICA: a potential tool for BCI systems[J]. IEEE Signal Processing Magazine, 2007, 25(1): 57–68.
- [12] BLANKERTZ B, TOMIOKA R, LEMM S, et al. Optimizing spatial filters for robust EEG single-trial analysis[J]. IEEE Signal processing magazine, 2007, 25(1): 41–56.
- [13] RIVET B, SOULOUMIAC A, ATTINA V, et al. xDAWN algorithm to enhance evoked potentials: application to brain-computer interface[J]. IEEE Transactions on Biomedical Engineering, 2009, 56(8): 2035–2043.
- [14] HOFFMANN U, VESIN J-M, EBRAHIMI T. Spatial filters for the classification of event-related potentials[R]. 2006.
- [15] ANG K K, CHIN Z Y, WANG C, et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b[J]. Frontiers in neuroscience, 2012, 6: 39.
- [16] DORNHEGE G, BLANKERTZ B, KRAULEDAT M, et al. Combined optimization of spatial and temporal filters for improving brain-computer interfacing[J]. IEEE transactions on biomedical engineering, 2006, 53(11): 2274–2281.
- [17] HIGASHI H, TANAKA T. Simultaneous design of FIR filter banks and spatial patterns for EEG signal classification[J]. IEEE transactions on biomedical engineering, 2012, 60(4): 1100–1110.
- [18] MENG J, YAO L, SHENG X, et al. Simultaneously optimizing spatial spectral features based on mutual information for EEG classification[J]. IEEE transactions on biomedical engineering, 2014, 62(1): 227–240.
- [19] GROSSE-WENTRUP M. Understanding brain connectivity patterns during motor imagery for brain-computer interfacing[J]. Advances in neural information processing systems, 2008, 21: 561–568.

- 
- [20] CARAMIA N, LOTTE F, RAMAT S. Optimizing spatial filter pairs for EEG classification based on phase-synchronization[C] // 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2014 : 2049 – 2053.
- [21] BALLI T, PALANIAPPAN R. Classification of biological signals using linear and nonlinear features[J]. *Physiological measurement*, 2010, 31(7) : 903.
- [22] BRODU N, LOTTE F, LÉCUYER A. Exploring two novel features for EEG-based brain–computer interfaces: Multifractal cumulants and predictive complexity[J]. *Neurocomputing*, 2012, 79 : 87 – 94.
- [23] LOTTE F. A new feature and associated optimal spatial filter for EEG signal classification: Waveform Length[C] // Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012). 2012 : 1302 – 1305.
- [24] ZHOU S-M, GAN J Q, SEPULVEDA F. Classifying mental tasks based on features of higher-order statistics from EEG signals in brain–computer interface[J]. *Information Sciences*, 2008, 178(6) : 1629 – 1640.
- [25] LOTTE F, BOUGRAIN L, CICHOCKI A, et al. A review of classification algorithms for EEG-based brain–computer interfaces: a 10 year update[J]. *Journal of neural engineering*, 2018, 15(3) : 031005.
- [26] 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.
- [27] YGER F, BERAR M, LOTTE F. Riemannian approaches in brain-computer interfaces: a review[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2016, 25(10) : 1753 – 1762.
- [28] DORNHEGE G, BLANKERTZ B, CURIO G, et al. Boosting bit rates in non-invasive EEG single-trial classifications by feature combination and multiclass paradigms[J]. *IEEE transactions on biomedical engineering*, 2004, 51(6) : 993 – 1002.

- [29] FREY J, APPRIOU A, LOTTE F, et al. Classifying EEG signals during stereoscopic visualization to estimate visual comfort[J]. *Computational intelligence and neuroscience*, 2016, 2016.
- [30] HÖHNE J, HOLZ E, STAIGER-SÄLZER P, et al. Motor imagery for severely motor-impaired patients: evidence for brain-computer interfacing as superior control solution[J]. *PloS one*, 2014, 9(8): e104854.
- [31] MÜHL C, JEUNET C, LOTTE F. EEG-based workload estimation across affective contexts[J]. *Frontiers in neuroscience*, 2014, 8: 114.
- [32] ROY R N, CHARBONNIER S, CAMPAGNE A, et al. Efficient mental workload estimation using task-independent EEG features[J]. *Journal of neural engineering*, 2016, 13(2): 026019.
- [33] LOTTE F, CONGEDO M, LÉCUYER A, et al. A review of classification algorithms for EEG-based brain-computer interfaces[J]. *Journal of neural engineering*, 2007, 4(2): R1.
- [34] SCHOMER D L, DA SILVA F L. *Niedermeyer's electroencephalography: basic principles, clinical applications, and related fields*[M]. [S.l.]: Lippincott Williams & Wilkins, 2012.
- [35] MILLAN J R. On the need for on-line learning in brain-computer interfaces[C] // 2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No. 04CH37541): Vol 4. 2004: 2877–2882.
- [36] BHATIA R. *Positive definite matrices*[M]. [S.l.]: Princeton university press, 2009.
- [37] EDELMAN A, ARIAS T A, SMITH S T. The geometry of algorithms with orthogonality constraints[J]. *SIAM journal on Matrix Analysis and Applications*, 1998, 20(2): 303–353.
- [38] ABSIL P-A, MAHONY R, SEPULCHRE R. *Optimization algorithms on matrix manifolds*[M]. [S.l.]: Princeton University Press, 2009.

- 
- [39] BARACHANT A, BONNET S, CONGEDO M, et al. Classification of covariance matrices using a Riemannian-based kernel for BCI applications[J]. *Neurocomputing*, 2013, 112 : 172 – 178.
- [40] BARACHANT A, CONGEDO M. A plug&play P300 BCI using information geometry[J]. arXiv preprint arXiv:1409.0107, 2014.
- [41] BARACHANT A, BONNET S, CONGEDO M, et al. Multiclass brain-computer interface classification by Riemannian geometry[J]. *IEEE Transactions on Biomedical Engineering*, 2011, 59(4) : 920 – 928.
- [42] LECUN Y, BOSER B, DENKER J S, et al. Backpropagation applied to handwritten zip code recognition[J]. *Neural computation*, 1989, 1(4) : 541 – 551.
- [43] BOUREAU Y-L, BACH F, LECUN Y, et al. Learning mid-level features for recognition[C] // 2010 IEEE computer society conference on computer vision and pattern recognition. 2010 : 2559 – 2566.
- [44] LI S Z. Markov random field modeling in image analysis[M]. [S.l.] : Springer Science & Business Media, 2009.
- [45] HINTON G E. Training products of experts by minimizing contrastive divergence[J]. *Neural computation*, 2002, 14(8) : 1771 – 1800.
- [46] CECOTTI H, GRASER A. Convolutional neural networks for P300 detection with application to brain-computer interfaces[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2010, 33(3) : 433 – 445.
- [47] KWAK N-S, MÜLLER K-R, LEE S-W. A convolutional neural network for steady state visual evoked potential classification under ambulatory environment[J]. *PloS one*, 2017, 12(2) : e0172578.
- [48] LUN, LIT, REN X, et al. A deep learning scheme for motor imagery classification based on restricted Boltzmann machines[J]. *IEEE transactions on neural systems and rehabilitation engineering*, 2016, 25(6) : 566 – 576.

- [49] STURM I, LAPUSCHKIN S, SAMEK W, et al. Interpretable deep neural networks for single-trial EEG classification[J]. *Journal of neuroscience methods*, 2016, 274: 141 – 145.
- [50] TABAR Y R, HALICI U. A novel deep learning approach for classification of EEG motor imagery signals[J]. *Journal of neural engineering*, 2016, 14(1): 016003.
- [51] SCHIRRMESTER 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.
- [52] ZHANG C, LIU C, ZHANG X, et al. An up-to-date comparison of state-of-the-art classification algorithms[J]. *Expert Systems with Applications*, 2017, 82: 128 – 150.
- [53] KULIS B, OTHERS. Metric learning: A survey[J]. *Foundations and trends in machine learning*, 2012, 5(4): 287 – 364.
- [54] HOFFER E, AILON N. Deep metric learning using triplet network[C] // *International workshop on similarity-based pattern recognition*. 2015: 84 – 92.
- [55] NG A, OTHERS. Sparse autoencoder[J]. *CS294A Lecture notes*, 2011, 72(2011): 1 – 19.
- [56] ANG K K, CHIN Z Y, ZHANG H, et al. Filter bank common spatial pattern (FBCSP) in brain-computer interface[C] // *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*. 2008: 2390 – 2397.
- [57] 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.
- [58] KWON O-Y, LEE M-H, GUAN C, et al. Subject-independent brain-computer interfaces based on deep convolutional neural networks[J]. *IEEE transactions on neural networks and learning systems*, 2019, 31(10): 3839 – 3852.

- 
- [59] SOHN K. Improved deep metric learning with multi-class n-pair loss objective[C] // Proceedings of the 30th International Conference on Neural Information Processing Systems. 2016: 1857–1865.
- [60] WANG X, HUA Y, KODIROV E, et al. Ranked list loss for deep metric learning[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 5207–5216.



# 简历与科研成果

## 基本信息

卜宇轩，男，汉族，1996年10月出生，江苏省宿迁人。

## 教育背景

2018年9月 — 2021年6月 南京大学计算机科学与技术系 硕士

2014年9月 — 2018年6月 山东大学计算机科学与技术系 本科

## 攻读硕士学位期间的发明专利

1. 申富饶，卜宇轩. “一种基于卷积神经网络的脑电识别方法” (202110404659.3)
2. 申富饶，严元杰，卜宇轩. “基于分离正负扰动生成抗机器识别的图片验证码的方法”(202010656484.0)



# 致 谢

转眼间我的三年研究生生活即将结束。回首这三年，我遇到了很多学识渊博的老师，也认识了很多志同道合的同学，学习到了很多知识，也经历了很多事情，老师和同学们教会了我很多很多，不只有渊博的知识，更多的是为人处世的道理和对科研严谨细致的态度。

感谢我的导师申富饶老师，在学术上，他严谨认真地教导着我们带着质疑的眼光去做研究，要以问题为导向而做研究。申老师告诉我们要反思自己的研究对于生产生活的意义，不单单局限在前人的工作上做修修补补的工作，要勇于提出自己的想法和思路。

感谢我的导师吴楠老师，吴老师儒雅随和，知识渊博。不仅具有深厚的学术造诣，更是一位德才兼备的师长。他的教诲帮助我们更好地走向社会，开始自己新的旅途。

此外，我还要感谢实验室的各位同学。他们给予了我很多帮助，也给了很多鼓励，和你们一起做事是我三年间最珍贵的回忆。与同学们融洽的相处过程中，在学习和工作上我都得到了长足的进步。能结交如此优秀一群朋友是我的幸运。

最后感谢我的父母，能够一直支持和鼓励我，你们是最坚实的后盾，让我放心大胆地追求自我的提高。



