

参赛队员姓名： 李宛泽

中学： 杭州外国语学校

省份： 浙江省

国家/地区： 中国

指导教师姓名： 黄正行 罗威

指导教师单位： 浙江大学

论文题目： 面向多模态智能睡眠分期任务的增量学习研究

面向多模态智能睡眠分期任务的增量学习方法研究

李宛泽

杭州外国语学校

邮箱 3099223404@qq.com

摘要

根据《2022 中国国民健康睡眠白皮书》，超过 3 亿中国人存在睡眠障碍，而基于多导睡眠图（PSG）的睡眠阶段分期是当前医生诊断睡眠障碍的基本手段。不同于传统的手动标注法，基于深度学习的自动睡眠分期技术能对患者整晚 PSG 数据进行快速、准确、客观的标注。然而患者个体间存在差异，故在特定群体上训练而来的模型在其他个体上往往需要进行增量学习，不断迭代训练是改进模型的必要手段。在医疗领域，患者数据的院内管理与隐私保护等因素使得睡眠相关数据的广泛可及性受到很大制约，已有的模型在新数据上训练时往往无法接触旧数据，由于神经网络灾难性遗忘的特质，这种制约会使模型遗忘之前学到的特征，阻碍其增量学习过程。本文围绕睡眠模型的有效增量学习方法展开研究，从模型方面，我们探索了两种多模态数据融合方式对灾难性遗忘的影响；从优化算法方面，我们使用了正则化增量学习方法缓解灾难性遗忘现象。两者的结合为睡眠分期模型的泛化应用提供了一种新的技术手段。实验结果表明，特征级融合模型在全数据训练场合下效果最好，而用数据级融合的方式结合基于损失函数正则化的增量学习算法在相比之下更能缓和灾难性遗忘。

关键词：睡眠分期，增量学习，卷积神经网络，多模态特征融合

Abstract

According to the *2022 China National Healthy Sleep White Paper*, more than 300 million Chinese have sleep disorders, and sleep staging based on polysomnography (PSG) is the fundamental tool for diagnosing sleep disorders today. Unlike the traditional manual labeling method, deep learning-based automatic sleep staging technology can provide fast, accurate and objective diagnosis of patients' PSG data throughout a night. However, because of the differences between individual patients, models trained on a specific group often require incremental learning on other individuals, and therefore continuous iterative training is one necessary method. In the medical field, factors such as in-hospital management of patients' data and privacy protection make the widespread availability of sleep-related data constrained, and existing models are often unable to access old data when trained on new data. Due to the catastrophic forgetting property of neural networks, this constraint would render the models forget previously learned features and impede its incremental learning process. In this paper, we focus on an effective incremental learning approach for sleep staging models: from the perspective of models, we have explored the effect of multimodal data fusion approach on catastrophic forgetting; from the perspective of optimizing algorithm, we use a regularizer-based incremental learning method to alleviate catastrophic forgetting phenomenon. The combination of these provides a new technical approach for sleep stage classification. The experimental results demonstrate that feature-fusion models work better than data-fusion models while a complete dataset is available. However, in an incremental learning scenario, data-fusion models combined with regularizer-based incremental learning methods can better alleviate catastrophic forgetting.

Key words: sleep stage classification, incremental learning, convolutional neural network, multimodal feature fusion

目录

1. 引言	5
2. 研究背景及相关工作	6
2.1 睡眠分期	6
2.1.1 睡眠特征波形	6
2.1.2 人工睡眠分期	7
2.1.3 基于深度学习的自动睡眠分期	7
2.2 增量学习	8
2.2.1 原理及方法	8
2.2.2 增量学习的相关工作	8
3. 方法	9
3.1 数据处理	9
3.1.1 数据集	9
3.1.2 数据预处理	10
3.2 模型架构	10
3.2.1 并行卷积神经网络	13
3.2.2 特征融合网络	13
3.2.3 分类输出网络	13
3.2.4 不同融合方式	14
3.3 基于正则化的增量学习算法	14
4. 实验	16
4.1 全数据集实验	16
4.1.1 数据增强方法研究	16
4.1.2 多模态数据融合方法研究	17
4.2 增量学习场景实验	18
5. 结论	20
6. 参考文献	21
7. 致谢	23

1. 引言

据世界卫生组织统计，全世界的睡眠障碍率高达 27%。而在中国，成年人的失眠率已经达到 38.2%，在 90 后中，保持健康睡眠习惯的只有 17%，老年人睡眠障碍患病率则为 35.9%，可见睡眠障碍已是困扰中国人乃至全世界最广泛的健康问题之一。

当下睡眠障碍的诊断依据主要是专家对患者整晚多导睡眠数据(PSG)的标注结果。人工判读、标注有以下三个缺点：(1)标注精度取决于判读者个体经验，且会受到个体认知、偏见的影响；(2)判读时间长，标注一个病人整晚数据往往需要数个小时；(3)必须使用 PSG 数据中尽可能多的通道以保证判读准确率。

在自动睡眠分期方面出现过一些基于机器学习[1-3]解决方案。相较于这些方法，深度学习算法有自动抽象数据中重要特征的能力。H.W. Loh[4]等人认为在可预见的未来，所有关于自动睡眠阶段分类的研究至少提到基于深度学习的技术作为参考。Yi-China Kung[5]等人比较了在一个大型生理学数据库上训练的不同学习方法，得出的结论是深度学习模型总体上优于传统机器学习方法。基于这些研究，本文采取深度学习的方法。

虽然近年出现了几种高性能的基于深度学习的睡眠分期系统[6-9]，但由于患者个体差异等客观因素，在少量个体数据上训练的模型在新的临床数据上的正确率往往不如其在训练数据集上的表现。因此，基于深度学习的睡眠分期辅助判读应当是半自动的，睡眠技师可对神经网络模型误判的结果进行修正。这样一来，这种半自动的工作模式同时也会产出新的训练用数据集，帮助模型提升客观整体正确率。然而，由于数据隐私等因素，模型在新数据集上训练时无法重新观察到之前训练用数据集。考虑如下场景，A 医院将其在本院数据上训练的模型分享给 B 医院，B 医院想进一步利用本院数据提升该模型准确率，但无法获取 A 医院数据。由于神经网络灾难性遗忘的特性，在这类增量学习场景下，在旧数据集上学得的“知识”将被新观测到的数据抹去，反而可能造成客观整体正确率的降低。

针对这一问题，本文从模型结构和优化算法两个方面对神经网络在睡眠分期任务上的灾难性遗忘进行了分析。在模型结构方面，我们考虑了两种不同的多模态特征融合方法；在优化算法方面，我们考虑了基于正则化方法的增量学习算法。

在公开数据集上,我们通过分割数据集模拟了增量学习场景。针对类不平衡现象,我们还基于滑窗法对数据进行了增强。实验结果表明,对小样本类的数据增强能提升模型整体正确率。特征级融合模型在全数据集上表现优于数据级融合模型;而在增量学习场景下,数据级融合模型比特征级融合模型灾难性遗忘性小,在正则化增量学习方法的辅助下,最终在各数据组上的平均正确率更高。

2. 研究背景及相关工作

2.1 睡眠分期

2.1.1 睡眠特征波形

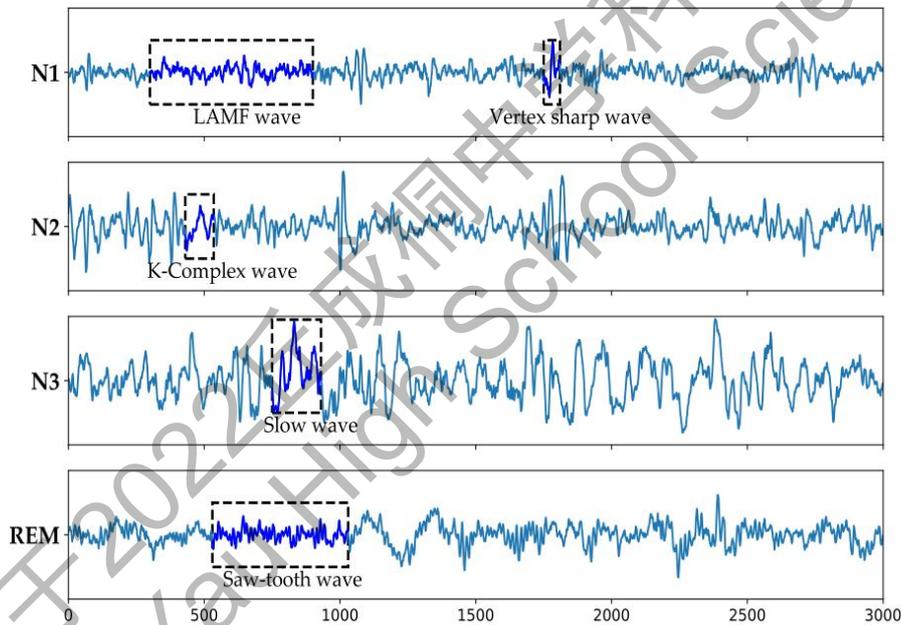


图 2.1 不同睡眠分期下 EEG 信号具有的形态特征[10]

脑电信号是睡眠分期最重要的分类依据,如图 2.1 所示,在不同的睡眠分期下 EEG 信号具有不同的形态特征,其一般按照频率、波幅的范围可以分类成多个特征波形。例如,纺锤波频率在 11~16Hz,有规则的形状,常见于 N2、N3 期; δ 波频率在 0.3~4Hz,波幅通常大于 75 μ V,在 N2 时期时所占比例低于 20%,在 N3 时期所占比例大于 20%; REM 期最常见的锯齿波呈尖锐的三角形,频率在 3~7Hz。

2.1.2 人工睡眠分期



图 2.2 多导睡眠仪病人数据采集过程¹

如图 2.2 所示，在临床中，医生使用多导睡眠检测仪获取病人的 PSG 数据，对具有睡眠问题的病人进行精准诊断。AASM(美国科学睡眠指南)[11]为睡眠分期制定了统一的标准，将睡眠时期分为 5 个类别：清醒期(Wake)，非快速眼动期(N1, N2, N3)，快速眼动期(REM)。分类过程以帧为单位判读，30 秒/帧，每帧只有一个分期，根据大于 50%的 EEG、EOG 的表现分类。如果一帧出现多个睡眠期特征(含清醒期)时，首先判断是清醒期优势还是睡眠期优势，再判断哪种睡眠期占优势就判读为何期。

睡眠分期是睡眠研究的基础，睡眠结构变化可反映潜在睡眠障碍、躯体疾病或某种物质的影响，例如入睡开始不久就出现 REM 期提示可能患有发作性睡病[12]，睡眠期变化快提示可能患有阻塞性呼吸暂停或周期性肢动[13]。由此可见，无论是简单判断睡眠质量好坏还是探究深层睡眠问题，睡眠分期都起着至关重要的作用。

2.1.3 基于深度学习的自动睡眠分期

深度学习拥有端对端的特性，不需要人工参与特征提取，神经网络的参数通过反向传播的方式自动更新。神经网络应用于睡眠分期问题的时候，输入和网络结构是我们更关心的两个重要方向。

Mathias 等人[14]设计了 U-sleep 网络，使用来自 21 个数据集的 19924 个 PSG

¹ <https://www.medicalexpo.com.cn/prod/neurosoft/product-69506-983572.html>

记录上，输入为 EEG 和 EOG 信号的组合。其网络结构借鉴了 U-net，可以做到样本点级别的分类，网络包括三个部分：编码器，解码器，分类器；Akara 等人[15]使用 Montreal Archive of Sleep Studies (MASS)和 Sleep-EDF 两个数据集。模型包含特征学习和序列残差学习两个部分。在表征学习部分中使用了两个卷积网络获取不同尺度的信息，序列残差部分使用了双向长短时记忆网络。

2.2 增量学习

2.2.1 原理及方法

人在成长过程中可以不断获取、优化和传承知识技能，这种不断更新和巩固知识的能力被称为终生学习(Life-Long Learning)，在深度学习上又称增量学习(Incremental Learning)或连续性学习(Continual Learning)。但对于神经网络来说，从非平稳数据分布中不断递增获取可用信息往往会导致灾难性遗忘(Catastrophic Forgetting)，现阶段主流的解决方案分为三种：(1)存储之前的任务信息(Memory Replay)，如整合新旧训练数据、每层网络训练得出的阶段性特征；(2)选择性的突触可塑性(Selective Synaptic Plasticity)，如在损失函数中加入正则函数，根据预设的权重弹性更新部分参数；(3)参数隔离(Parameter Isolation)，在新任务上扩大旧的模型，对新旧模型的参数进行不同程度的隔离。

一个常见的增量学习网络优劣的判断方法如下：每次训练一个任务，当验证集准确率不再提高后停止训练，同时获得在所有任务上的准确率。训练完一个任务后以当前得到的参数作为下一个任务训练的原始参数重新训练，同样在验证集准确率不再提高后获得所有任务上的准确率，直到训练完最后一个任务。

2.2.2 增量学习的相关工作

Shin 等人[16]提出基于数据回放方法的网络 Deep Generative Replay，该网络是由生成器和解决器组成的对偶模型，每一个任务都有对应的生成器和解决器，之前生成器生成的类真实数据和当前任务的真实数据依一定比率混合作为当前生成器的输入，以重建累计输入空间，解决器将输入和目标进行匹配。该方法一定程度上解决了灾难性遗忘的问题，但是生成器很难生成高清的影像，其是否能被广泛应用依然是个问题。

Kirkpatrick 等人[17]提出 EWC 方法，其基本思想是保护模型中对之前任务重

要的参数，改变不重要的参数，通过在损失函数后添加正则项实现，见公式 2.1

$$L'(\theta) = L(\theta) + \lambda \sum_i b_i (\theta_i - \theta_i^b)^2 \quad (2.1)$$

上式中 θ_i^b 是之前任务训练的参数， θ_i 是当前任务的参数，通过 b_i 自动调节两个参数的之前的距离。 b_i 由损失函数的二次微分得来，用于表示某方向上梯度变化的快慢。易得出 b_i 越大，该方向上参数的变化引起的损失函数的变化越大(一般是上升)，训练过程中当前参数 θ_i 和 θ_i^b 的差距会越小，有效的保护了重要参数。同理可得对之前任务影响不大的参数变化的距离会不受限制。如图 2.3 所示，相比于不增加正则项和 L2 正则化方法，使用 EWC 方法的参数更新的方向会趋近于同时满足两个任务：

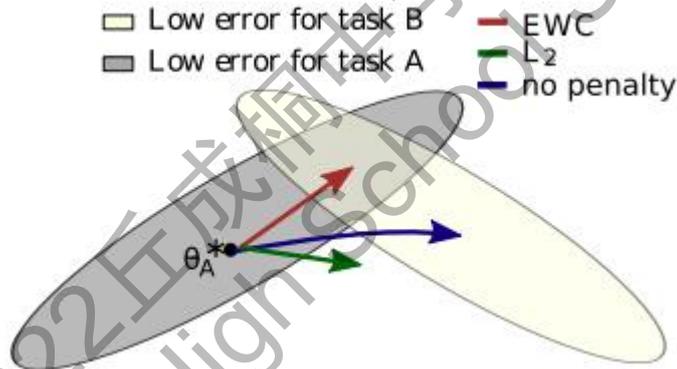


图 2.3 参数更新轨迹[17]

这种方法也存在着缺陷，需要两个任务存在较高的相似度，才能有较低的损失函数值重合的区域。

3. 方法

3.1 数据处理

3.1.1 数据集

为了保障研究和实验的正确性，本文采用广为使用的公开数据集 Sleep-EDF 扩展数据集(Sleep-EDF Database Expanded, SleepEDFx)[18]作为基准测试数据，该

数据集可从 PhysioNet 数据库中获取。该数据集包含 Sleep Cassette(SC)和 Sleep Telemetry(ST)两个数据子集共 104 位个体的多导睡眠图，每位被试记录了两个昼夜时段大约 20 个小时的信号，其中被试 36 和 52 的第一个晚上和被试 13 号的第二个晚上由于磁带或激光磁盘故障而丢失。

该数据集中，*PSG.edf 文件记录被试的生理信号，包含脑电信号(EEG)、眼电信号(EOG)、颏下肌电信号(EMG)和事件标记(Event)；*Hypnogram.edf 记录对应 PSG 文件的睡眠注释，包括失眠阶段 W、R、1、2、3、4、M(运动时间)和? (不得分)。

本文选择使用 SC 子集中年龄范围为 25 至 34(28 ± 2.9)的 20 个被试共 39 条记录作为实验数据，图 3.1 为 SC400 号病人第一整晚 PSG 数据中的一部分。根据先验知识可知睡眠分期主要与脑电信号相关，N1 期和 N3 期的判读与眼电信号有关，于是本文采用其中两个 EEG 通道和一个 EOG 通道信号作为模型的可选输入，三个通道的采样率皆为 100Hz。

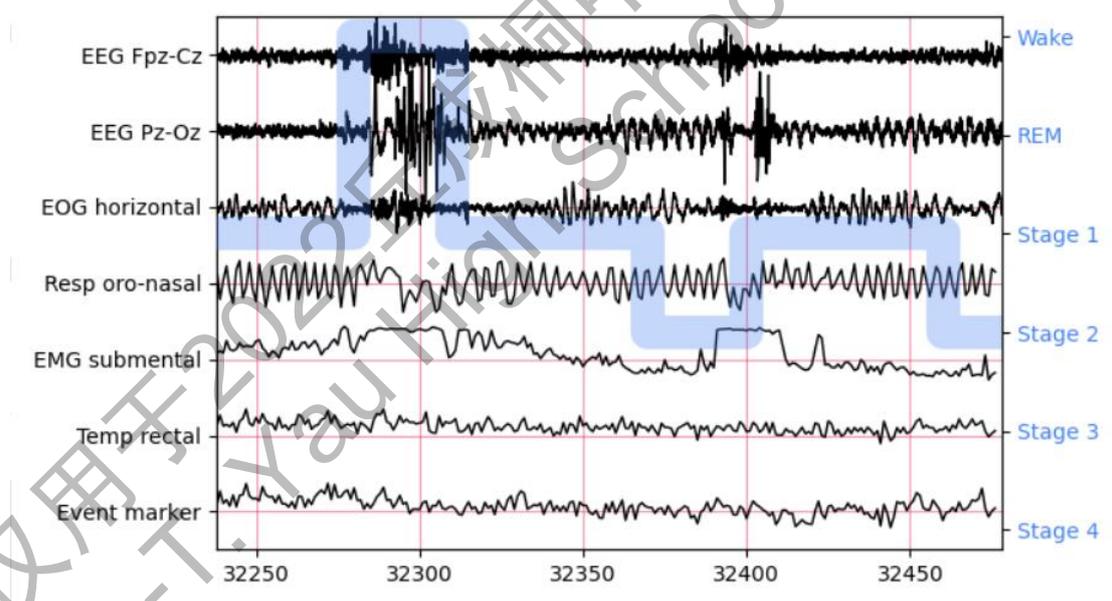


图 3.1 多导睡眠图及对应睡眠分期标注

3.1.2 数据预处理

SleepEDFx 数据集的睡眠分期标记由专家按照 R&K 指南将 30s 长度的信号标记为 8 个类别，但是目前临床采用的主流标记方法遵循 AASM 指南，因此本文按照 AASM 指南将 M 和? 类别进行排除，同时将 N3 和 N4 合并为 N3 分期。此外由于数据中包含了过多的觉醒状态时的记录，影响分期结果的可信度，本文按照

Supratak[3]等人的方法只保留被试进入睡眠前 30 分钟和重新苏醒后 30 分钟清醒期数据，需要提出的是，被试 12 的注释文件中并没有完整的苏醒后 30 分钟清醒期数据。表 3.1 展示了经过上述处理后类别分布信息：

表 3.1 SleepEDFx 数据集数据分布

睡眠周期	Wake	REM	N1	N2	N3	总计
	9081	7717	2804	17799	5703	43104
占比(%)	21.07	17.90	6.50	41.29	13.23	/

针对上文获得的信号样本，本文将进行进一步的数据处理：第一步对信号进行滤波操作，对睡眠分期任务来说，一些高频的信号不是有效的信号成分，因此本文采用 FIR(有限长单位冲激响应)低通滤波器进行滤波，仅保留 35Hz 以下的信号用于后续处理。第二步是对信号进行归一化，该方法是构建神经网络时经常采用的数据预处理方法，一方面可以使输入的信号处于同一个量纲方便进行融合，另一方面可以使模型训练更加稳定且加快收敛过程。为了防止不同个体不同时期的数据分布不同，本文对每一个记录的每一个通道单独做归一化处理，如式 3.1 所示， μ_x 和 σ_x 表示某个记录中某个通道的均值和方差。

$$x_{norm} = \frac{x - \mu_x}{\sigma_x} \quad (3.1)$$

第三步是对样本做均衡处理，由表 1 可知各个类别的样本数据是不均衡的，N2 分期最多，N1 分期的样本数据最少。过采样是解决样本不均衡常用的方法，因为一个睡眠分期中包含多种信号的特征波形并根据大于 50%的特征波形进行判断，存在一定的容错率，所以本文采用随机窗口滑动的方法对 N1 期数据进行增强。具体做法是在原始信号随机向前或随机向后滑动以形成新的样本，例如 SleepEDFx 中的某样本在原始信号的样本点位置为(K, K+3000)，则可以通过随机生成的滑动量 δ 来生成新的 N1 信号样本为(K+ δ , K + 3000 + δ)并直接插入到原始样本后。本文使用的随机量 δ 服从均匀分布 U(- 400, 400)，即信号最大偏移不超过 4 秒。和简单的重复相比，该方法在增加了少样本数量的同时缓解了对少量样本过

拟合的风险，另一方面保留了睡眠分期之间的时序关系。

3.2 模型架构

模型主要由三个部分组成：并行卷积神经网络、特征融合网络和分类输出网络，其中并行卷积神经网络自动提取特征并由特征融合网络融合，分类网络进行评分输出，图 3.2(c)包含了特征提取和融合网络, (d)表示分类网络。

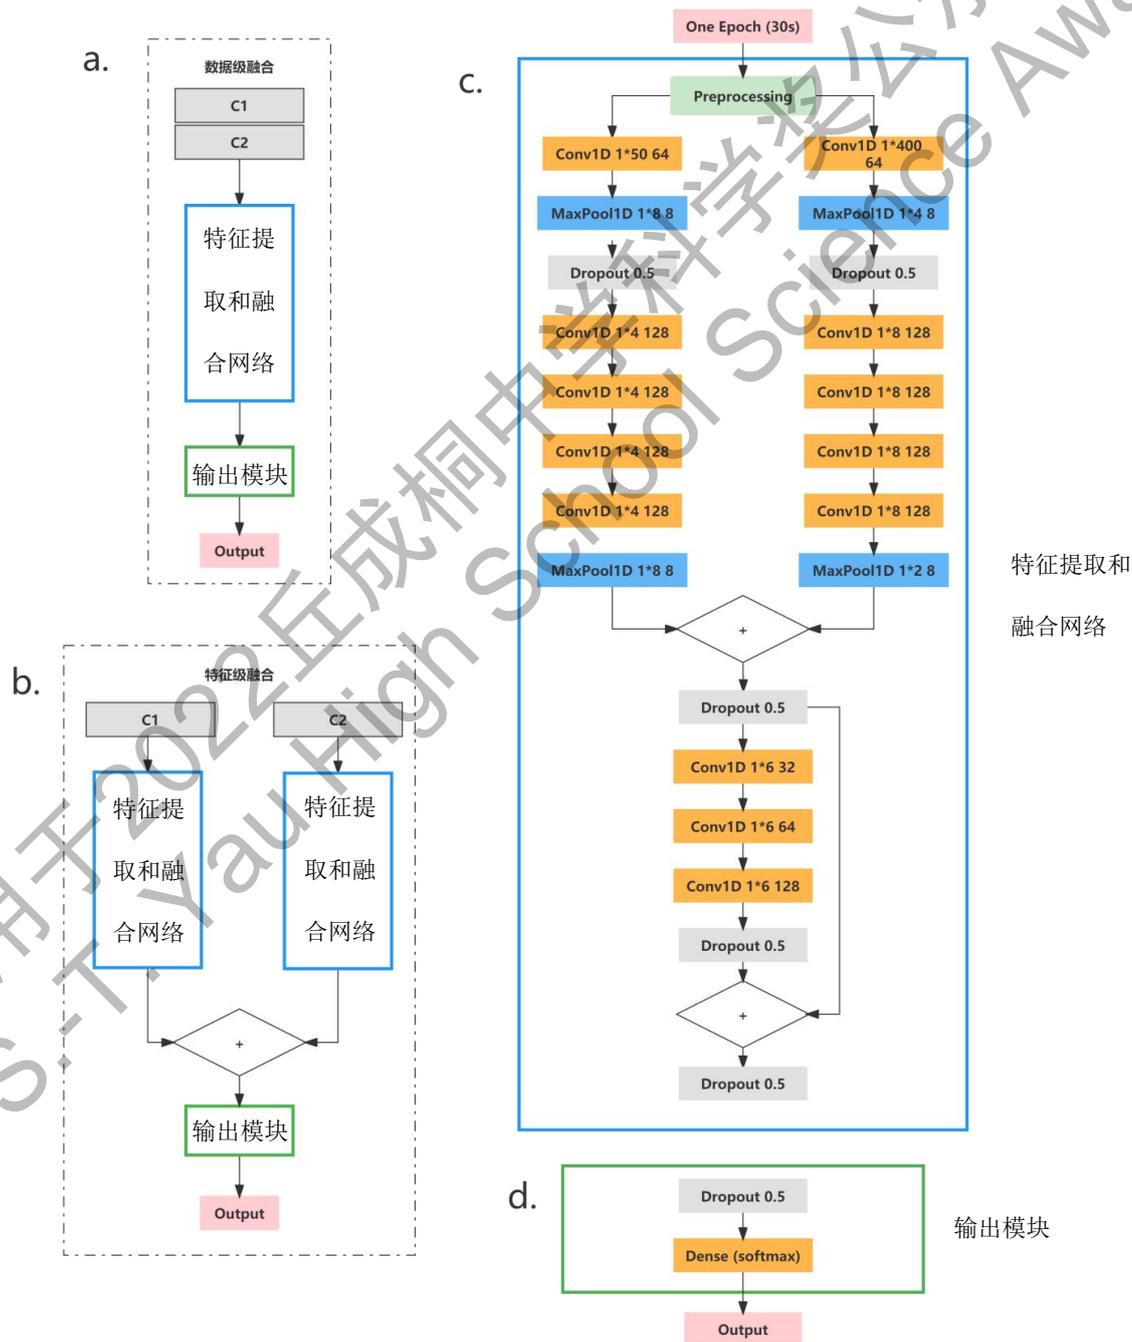


图 3.2 模型架构

3.2.1 并行卷积神经网络

卷积神经网络主要由卷积层、池化层组成，卷积层有局部感受野和权值共享的特点，池化层起到降采样的功能，降低了网络模型的复杂度，同时有对于平移、旋转、尺度缩放等形式的不变性，因此被广泛应用于识别和分类任务中。睡眠脑电信号在不同分期具有不同形态的特征波形，本文利用其强大的特征提取能力对这些波形进行学习，模拟临床医生通过特征波形进行分类的行为。受到 DeepSleepNet 的启发，本文选用两个卷积神经网络分支 CNN-A, CNN-B 分别提取输入序列信号的时域和频域信息。CNN-A 的第一层卷积核的大小为序列信号采样率的 1/2，步长设置为采样率的 1/16，获取时域信息。CNN-B 的第一层卷积核个数与 CNN-A 相同，不同的是卷积核的尺寸大于采样频率，用于获取频域信息。

每个卷积层都会执行批量归一化操作，激活函数为线性整流函数(rectified linear unit, ReLU)，其表达式如下式：

$$f(x) = \max(0, x) \quad (3.2)$$

池化层选择最大池化操作，将输入的序列信号划分若干个分段，每个分段只输出最大值，即提取特征图中响应最强烈的部分，符合睡眠分期根据最大特征判读的思路。随机失活函数(Dropout)将隐藏层的部分权重和输出随机归零，降低节点之间的相互依赖性从而实现神经网络的正则化。

3.2.2 特征融合网络

特征融合网络将前一层网络提取的时域和频域信息结合，通过空洞卷积进行深层次的融合。相比普通的卷积运算，其通过在扩张卷积核，增大神经元感受野。除此之外，我们在模型中使用残差结构来弥补因卷积和池化而降低的空间分辨率。

3.2.3 分类输出网络

分类输出网络则由全连接层和 softmax 逻辑回归层(softmax regression)构成，全连接层中的每一个神经元和前一层的所有神经元连接，可以整合卷积层或者池化层中具有类别区分性的局部信息，最后由 softmax 层进行分类，softmax 激活函数的公式如下， c_k 代表所求类别的原始值， n 代表类别数量。softmax 的作用在于将向量变换到元素介于(0, 1)范围的向量且和为 1，表示输入信号属于不同

类别的概率。

$$\gamma(c_k) = \exp(c_k) / \sum_j^n \exp(c_j) \quad (3.3)$$

模型预测的类别概率输出与真实类别的 one hot 形式向量作交叉熵损失函数的计算，通过反向传播的方法对模型的参数进行训练。交叉熵损失函数是分类问题最常用的损失函数，其计算公式如下， M 是类别的数量， y_{ic} 是符号函数(0 或 1)，若为真实样本取 1，否则取 0， p_{ic} 是观测样本 i 属于类别 c 的预测概率。

$$L = \frac{1}{N} \sum_i L_i = -\frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \log(p_{ic}) \quad (3.4)$$

3.2.4 不同融合方式

为了提高分类准确率，本文还使用数据级融合和特征级融合方法对模型进行改进，并比较哪种融合方式的准确率更高。如图 3.2(a)所示，数据级融合是将不同的输入数据进行拼接，共同作为特征提取网络的输入。第四章实验中将选用两个 EEG 信号和一个 EOG 信号进行随机组合，得到最优的组合方式。如图 3.2(b)所示，特征级融合是将不同通道的数据分别进行特征提取，将提取的特征进行拼接作为分类网络的输入，输入的通道选择数据融合实验的最优组合。除此之外，本文还将探究两种融合方式在增量式学习的表现，具体实验见第四章。

3.3 基于正则化的增量学习算法

在增量式学习三种方法中，数据回放需要占用额外的计算资源和存储空间，受到硬件资源的限制，在实际生产环境中还可能存在数据隐私泄露的问题；参数隔离方法需要引入较多的参数和计算量，因此只能适用于简单的任务增量学习中。相比之下，选择性突触可塑化不需要回放旧参数，也不需要扩展新的网络，只需要加入约束保护旧参数不被破坏，是最优雅的一类增量学习方法。其一般表达式如式 3.5， $L(\theta)$ 表示上一个任务的损失函数， λ 为常数， Ω 为权重参数，衡量每一个参数对之前任务的重要性，不同的正则化方法对该参数的表达式不同。

$$\min_{\theta} L(\theta) + \lambda \cdot \Omega \odot (\theta - \theta^*)^2 \quad (3.5)$$

本文采用 SI(Synaptic Intelligence)方法, 该方法由 Zenke 等人[19]提出, 属于选择性突触可塑化的一种, 通过计算参数改变对损失函数的影响作为前一个任务的参数权重。从深度学习的反向传播计算方法可知, 损失函数的改变量可以由参数改变量及其对应的梯度计算。在 t 时刻取无穷小参数更新量 $\delta(t)$, 此时损失函数的改变量可由下列公式得出:

$$L(\theta(t) + \delta(t)) - L(\theta(t)) \approx \sum_k g_k(\theta(t)) \delta_k(\theta(t)) \quad (3.6)$$

$$g_k = \frac{dL}{d\theta}$$

该公式计算的是当前时刻所有参数量的贡献总和。为了计算整个训练过程中损失函数的总改变量, 可以对上述公式得到的结果作积分运算, 如下式:

$$\int_c g(\theta(t)) d\theta = \int_{t_0}^{t_1} g(\theta(t)) \cdot \delta(t) dt = \sum_k \int_{t_0}^{t_1} g_k(\theta(t)) \delta(t) dt \quad (3.7)$$

令 $\omega_k^v = - \int_{t_0}^{t_1} g_k(\theta(t)) \delta(t)$, 需要说明的是, ω_k^v 为损失函数的变化量, 可以直观地理解为第 k 参数对损失函数的下降贡献, 所以在前面需要添加负号。由此, 我们计算出了单个参数在整个训练过程中损失函数的下降量, 同时用 Δ_k^v 表示在该参数在训练过程中的改变量, 通过对这两个参数的除法运算就可以一定程度上表示第 k 个参数的正则权重:

$$\Omega_k^\mu = \sum_{v < \mu} \frac{\omega_k^v}{(\Delta_k^v)^2 + \xi} \quad (3.8)$$

ξ 为阻尼参数, 防止在 Δ_k^v 趋于 0 的时候表达式趋于无穷。需要说明的是 ω_k^v 和 Δ_k^v 在每一次迭代都更新, 在下一个任务前初始化为 0, 而 Ω_k^μ 在任务结束的时候才更新。由此, 我们可以得到加了惩罚项的损失函数, 如下式:

$$\tilde{L}_\mu = L_\mu + c \sum_k \Omega_k^\mu (\tilde{\theta}_k - \theta_k)^2 \quad (3.9)$$

其中 c 为无量纲常数参数，用来权衡新旧知识的存储，当其设置为 1 时表示新旧任务的重要性相等， $\tilde{\theta}_k$ 为上一个任务的对应参数， Ω_k^μ 为第 k 个参数的正则权重。

4. 实验

本文首先在全数据集上研究了数据增强方法，找到了基于滑窗的最佳数据平衡设置。在这个基础上，我们进一步对比了单模态和多模态，以及不同多模态融合方式对睡眠分期正确率的影响。然后，我们对全数据集进行分割，模拟了增量学习场景。在这个场景下，我们研究了基于正则化的增量学习训练方法在不同特征融合方式下的表现。

本文实验使用开源框架 xai-kit[20] 完成。所有模型由学习率为 0.003 的 Adam 优化器训练，批大小设置为 32。在训练中，我们采用了早停 (early stop) 技术。我们在每个训练代 (epoch) 中对模型进行两次验证，若经过 10 个训练代，模型在验证集上的正确率没有提升，则停止训练，并在对应测试集上进行测试。在所有实验中，我们取对应数据集各类的前 70% 数据作为训练集，10% 作为验证集，剩余 20% 作为测试集。

4.1 全数据集实验

在全数据集实验中，我们从召回率 (recall)，精确性 (precision)，F1 分数，及正确率四个方面比较各方法性能。

4.1.1 数据增强方法研究

由表 3.1 可知，睡眠数据各类别不平衡。为此，我们采用 3.1.2 节中介绍的随机滑窗法对数据进行增强。在实验中，我们仅对训练数据集进行增强，在相同的测试集上进行测试。表 4.1 包含了不同增强策略下数据级融合模型对模型性能的影响，第一列表示相应的分期数量变为原来的 X 倍，其他分期数据保持不变。

从结果可知，第三组和第五组结果优于其他策略，因为在样本不均衡的实验中，F1 分数的可靠性往往优于准确率，故本文选择 $N1 * 3$ 的方法为最优策略。

表 4.1 数据增强对模型性能的影响

	Recall	Precision	F1	Accuracy
Original	0.7769	0.7633	0.7585	0.8126
$N1 * 2$	0.8060	0.7905	0.7924	0.80631
$N1 * 3$	0.8308	0.8097	0.8169	0.8212
$N1 * 2 + N3 * 2$	0.8102	0.8061	0.8049	0.8183
$N1 * 3 + N3 * 3$	0.8171	0.8171	0.8150	0.8242
$N1 * 2 + R * 2$	0.7962	0.7844	0.7870	0.8060

图 4.1 实现了数据增强前（左）及采用 $N1 * 3$ 方法增强后（右）的结果混淆矩阵。由此可以观察到一种现象，对 $N1$ 数据进行增强虽然能有效提高模型对其分类的正确率，但是在其他分类的准确率会有所下降，说明并不是一味增强某一类的数量就能达到最好的效果，需要在各个类别之间找到平衡。在接下来的实验中，我们采用 $N1 * 3$ 的数据增强方式，即将 $N1$ 数据量增强至 3 倍。

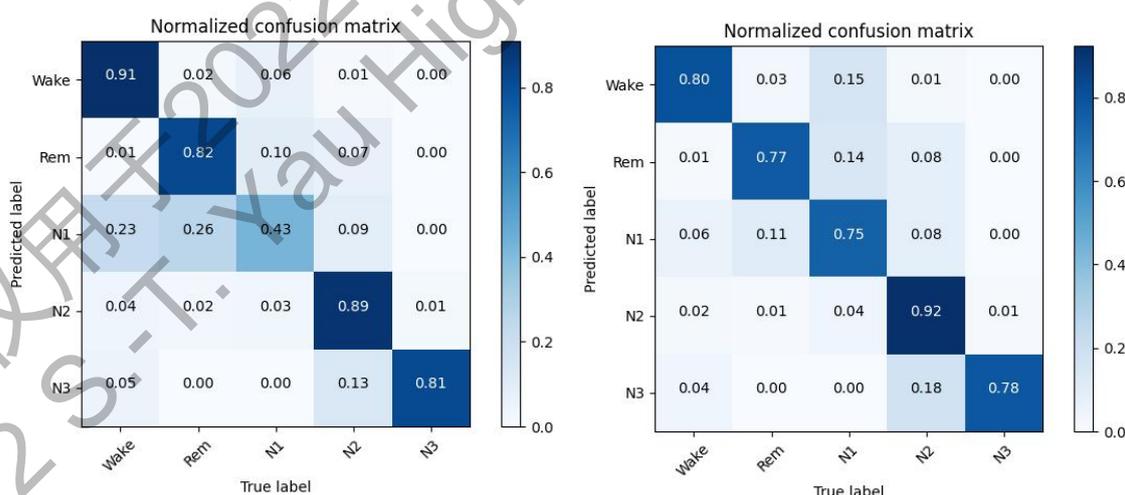


图 4.1 原始数据和数据增强混淆矩阵

4.1.2 多模态数据融合方法研究

本节实验中，我们对比了不同单模态及不同多模态的睡眠分期模型性能。首先可以看到，单模态模型性能明显不如多模态模型。其中，基于 EEG 信号的分类

准确率要高于 EOG 信号。

在不同融合方式模型对比中，我们通过缩减特征融合模型每层通道数将其总参数量与数据级融合模型保持基本一致以确保公平对比。从结果可以看到，在全数据集上，特征级融合模型性能要好于数据级融合模型。

表 4.2 多模态数据融合实验

	Recall	Precision	F1	Accuracy
Fpz-Cz	0.7521	0.7218	0.7155	0.7796
Pz-Oz	0.6969	0.7448	0.6854	0.7499
EEG * 2	0.7690	0.7619	0.7284	0.7934
EOG(horizontal)	0.6248	0.6144	0.5815	0.6409
EEG * 2 & EOG	0.8099	0.8014	0.8028	0.8459
Fpz-Cz & EOG	0.8132	0.7838	0.7948	0.8009

4.2 增量学习场景实验

本节实验中，我们通过分割 SleepEDFx 数据集模拟了一个由 5 个同任务但不同数据集组成的增量学习场景，分别包含 10, 2, 2, 2, 2 位不同个体的睡眠数据。我们在每组数据上对模型进行独立训练的同时，还记录了该模型在其他组测试集上的正确率。表 4.3 包含了不同数据融合方式下，不使用任何增量学习手段以及使用 SI 方法，在不同 λ 值下的最终平均正确率。可以看到，SI 方法在不同多模态数据融合方法下都能缓和模型在增量学习中的灾难性遗忘。然而，尽管特征级融合模型在全数据集上的表现优于数据级融合模型，其在增量学习场景下表现却不如后者。

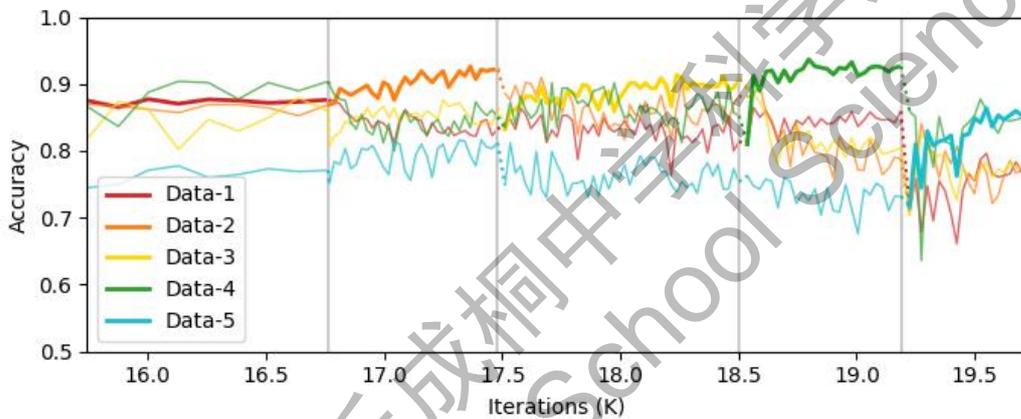
表 4.3 SI 方法在数据、特征级融合模型上的平均正确率

λ	0	0.5	1.0	2.0
数据级	0.806	0.835	0.847	0.837

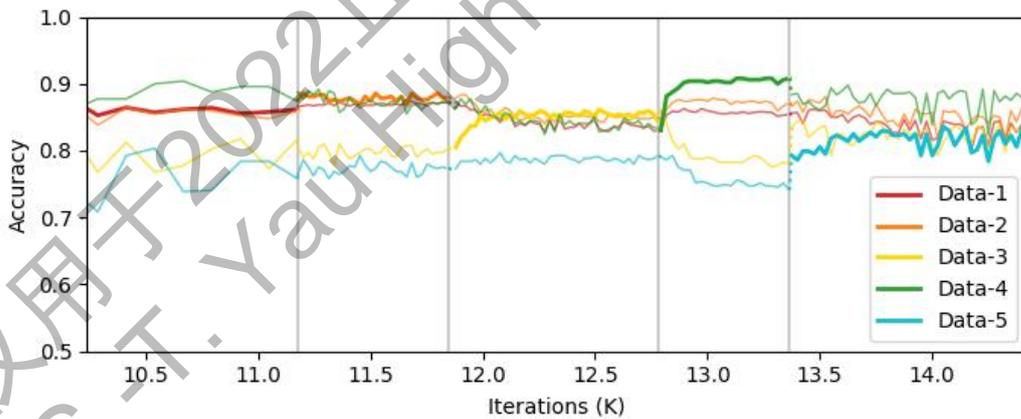
特征级	0.731	0.836	0.833	0.818
-----	-------	-------	-------	-------

图 4.2 是训练过程中模型在各组测试集上的正确率趋势图,加粗的线条表示当前组测试集正确率。可以看到,若不施加正则化增量学习方法($\lambda = 0$),模型在当前数据组上的正确率提高的同时,在之前数据组上的正确率会下降。使用了 SI 方法后,模型则会在保持旧数据组正确率的前提下提升其在当前数据组上的正确率。

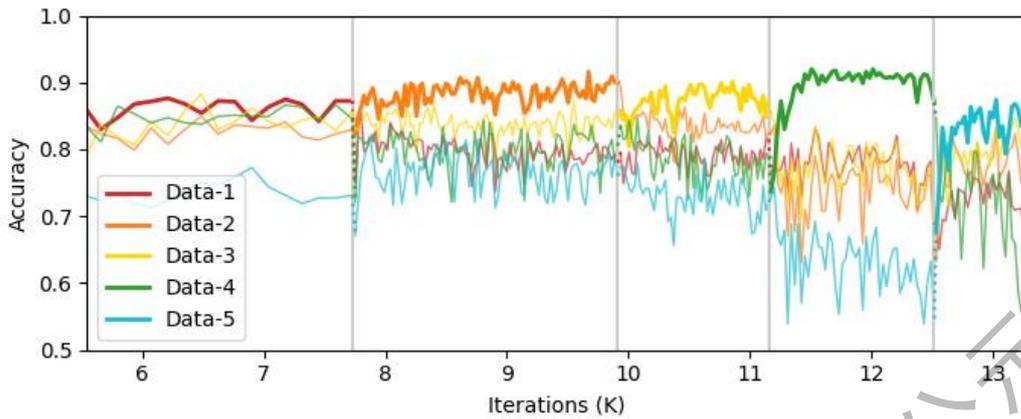
数据级融合
 $\lambda=0$



数据级融合
 $\lambda=0.5$



特征级融合
 $\lambda=0$



特征级融合
 $\lambda=0.5$

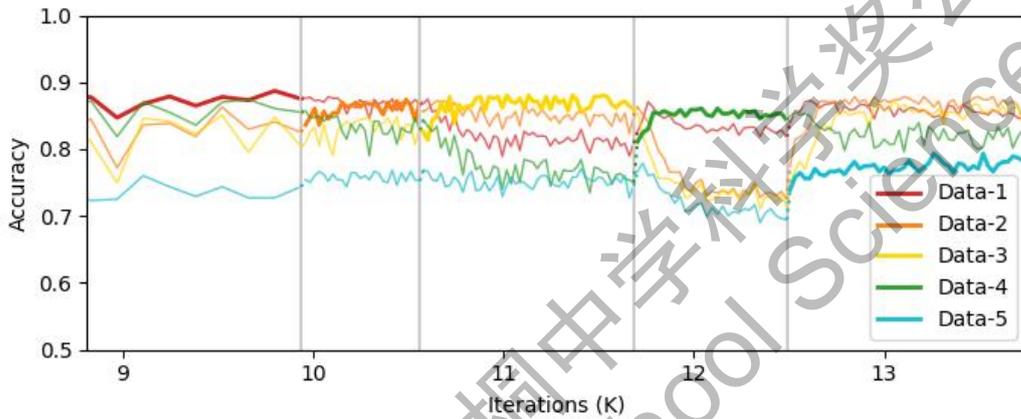


图 4.2 正确率趋势图

5. 结论

本文从模型以及训练算法两个角度研究了面向多模智能睡眠分期任务的增量学习。针对睡眠数据不平衡的问题，我们使用了基于随机滑窗法的数据增强方法，提高了模型在小样本类上的性能，从而提高了模型的总体正确率。在多模态数据融合比较实验中，我们发现在全数据集上，特征级融合模型性能要优于数据级融合模型。然而在特定增量学习场景下，数据级融合模型最终的平均正确率要高于特征级融合模型。这个结果可以为睡眠分期在实际应用时提供参考：若能取得所有历史训练数据，则可选用特征级融合模型；若模型只能在当前新数据下独立训练，则可选用数据级融合模型，并结合特定正则化增量学习算法进行辅助训练。

但是受限于个人时间、精力以及有限的深度学习计算资源，这次的研究仍具有可改进的方向：（1）在更广的超参空间寻找最优超参组合；（2）提出新的、

有效的增量学习方法，并在其他数据集（如图像数据集）上进行验证；（3）用更大的计算集群进行反复实验，用统计量对结果进行描述；（4）将深度学习的黑盒打开，解释实验结果发生的原因。

6. 参考文献

- [1] Santaji, S., Desai, V. "Analysis of EEG Signal to Classify Sleep Stages Using Machine Learning". *Sleep Vigilance* 4, 145–152 (2020).
- [2] Chriskos, Panteleimon, et al. "Automatic sleep stage classification applying machine learning algorithms on EEG recordings." 2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS). IEEE, (2017).
- [3] Hassan, Ahnaf Rashik, and Mohammed Imamul Hassan Bhuiyan. "Automatic sleep stage classification." 2015 2nd International Conference on Electrical Information and Communication Technologies (EICT). IEEE, (2015).
- [4] Loh, Hui Wen, et al. "Automated detection of sleep stages using deep learning techniques: a systematic review of the last decade (2010–2020)." *Applied Sciences* 10.24 (2020): 8963.
- [5] Kung, Yi-Chia, et al. "Instability of brain connectivity during nonrapid eye movement sleep reflects altered properties of information integration." *Human brain mapping* 40.11 (2019): 3192-3202.
- [6] Supratak, Akara, and Yike Guo. "TinySleepNet: An efficient deep learning model for sleep stage scoring based on raw single-channel EEG." 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). IEEE, (2020).
- [7] Jadhav, Pankaj, et al. "Automatic sleep stage classification using time–frequency images of CWT and transfer learning using convolution neural network." *Biocybernetics and Biomedical Engineering* 40.1 (2020): 494-504.
- [8] Wang, In-Nea, et al. "An Ensemble Deep Learning Approach for Sleep Stage Classification via Single-channel EEG and EOG." 2020 International Conference on Information and Communication Technology Convergence (ICTC). IEEE, (2020).
- [9] Wang, Huafeng, et al. "A novel sleep staging network based on multi-scale dual attention." *Biomedical Signal Processing and Control* 74 (2022): 103486.
- [10] 朱天其.面向脑电信号识别的深度神经网络模型算法研究[D].浙江:浙江大学

生物医学工程与仪器科学学院, 2021.

[11] Iber, C., Ancoli-israel, S., Chesson, A., et al. "The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specifications[J]." Westchester, IL: American Academy of Sleep Medicine, (2007).

[12] Stephansen, Jens B., et al. "Neural network analysis of sleep stages enables efficient diagnosis of narcolepsy." *Nature communications* 9.1 (2018): 1-15.

[13] Ross, Dian-Marie, and Edmond Cretu. "Probabilistic Modelling of Sleep Stage and Apneic Events in the University College of Dublin Database (UCDDDB)." 2019 IEEE 10th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON). IEEE, (2019).

[14] Perslev, Mathias, et al. "U-Sleep: resilient high-frequency sleep staging." *NPJ digital medicine* 4.1 (2021): 1-12.

[15] Supratak, Akara, et al. "DeepSleepNet: A model for automatic sleep stage scoring based on raw single-channel EEG." *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 25.11 (2017): 1998-2008.

[16] Shin, Hanul, et al. "Continual learning with deep generative replay." *Advances in neural information processing systems* 30 (2017).

[17] Kirkpatrick, James, et al. "Overcoming catastrophic forgetting in neural networks." *Proceedings of the national academy of sciences* 114.13 (2017): 3521-3526.

[18] Kemp, B., Zwinderman, A. H., Tuk, B., et al. "Analysis of a sleep-dependent neuronal feedback loop: the slow-wave microcontinuity of the EEG[J]." *IEEE Transactions on Biomedical Engineering*, (2000), 47(9): 1185-1194.

[19] Zenke, Friedemann, Ben Poole, and Surya Ganguli. "Continual learning through synaptic intelligence." *International Conference on Machine Learning*. PMLR, (2017).

[20] W. Luo, "xai-kit," <https://github.com/WilliamRo/xai-kit>.

7. 致谢

我从小时候就对数学很感兴趣，这种兴趣很简单，主要是来自课内知识在生活中应用带来的乐趣。而长大之后，我又接触到了其他学科：物理，化学，生物，计算机.....其中最感兴趣的是计算机，它吸引我的在于通过以数学理论为基础，简单的代码的组合便可以实现不同的功能，这对我而言，是很新奇且具有探索性的。而这样的兴趣一直伴随我到了现在，并因为不断的课内外新知识的输入而增强，同时也因为兴趣在国内外的数学与计算机的项目中取得较好成绩，例如在去年的 USA Computing Olympiad (USACO)比赛中晋级银级，今年初 American Invitational Mathematics Examination (AIME)考试中取得的高分（11/15）。

2021年暑假，我来到了浙江大学生仪学院的实验室，第一次进行了生物医学与计算机学科的交叉学科的研究，学习到了很多 python 代码知识以及计算机理论知识（如机器学习、神经网络），同时对于睡眠问题有了初步的了解。而在今年，在自己拥有睡眠问题知识的基础上，在老师的指导下，我选择了睡眠科医生关注的睡眠自动分期问题作为研究方向。在学习过程中，我掌握了实验室当前基于增量学习的睡眠分期模型，同时了解到当下的睡眠分期模型面临的主要问题是神经网络固有的遗忘性。在老师们的悉心指导下，我基于实验室提供的开源 python 软件库（xai-kit），主要独立完成了以下工作：（1）封装 Sleep EDFx 数据集，并实现基于滑窗的数据增强、数据预处理及分割逻辑；（2）复现文献中基于前馈神经网络的睡眠分期模型，并在其基础上实现了不同特征融合方法；（3）基于 xai-kit 中 tframe 深度学习框架，实现了一种增量学习中正则化算法，即 SI 算法，并进行批量实验；（4）基于 xai-kit 中的 pictor 库，对增量学习的结果进行可视化。

在本次的研究中，我要衷心感谢黄正行老师与罗威老师对我的指点。黄正行老师对于我在选择课题中以及提供了宝贵建议，而在后续研究过程中，我得到了黄正行老师在理论方面的指点以及罗威老师全方面的指导，包括实验设计以及论文撰写相关的建议。同时我也要感谢我的父母以及校内老师，他们对我关心与支持让我一直以来坚定地走着我所热爱的道路。缺少了上述任何一位长辈的帮助，我都难以完成这项艰巨的任务，在这里对他们表达深刻的敬爱之情与感激之情。