arXiv:2305.03178v1 [eess.SP] 5 May 2023

基于受试者间相关性的睡眠分期对比学习

Tongxu Zhang 和 Bei Wang(✉)

华东理工大学信息科学与工程学院，上海，200237，中国 juk@mail.ecust.edu.cn, beiwang@ecust.edu.cn

摘要。 近年来，许多研究将深度学习应用于自动睡眠分期分类。然而，事实上，这些工作较少关注睡眠分期中的跨被试问题。与此同时，关于主体间相关性的新兴神经科学理论可以为跨主体分析提供新的见解。本文介绍了用于睡眠分期研究的 MViTime 模型。我们通过对比学习实现了受试者间相关性理论，为解决睡眠分期分类中的跨被试问题提供了一种可行方案。最后，本文给出了实验结果和结论，表明所提出的方法在睡眠分期方面取得了最先进性能。消融实验的结果也证明了基于对比学习的跨主体方法的有效性。代码可通过以下网址获取：
https://github.com/jukieCheung/MViTime。

关键词： 深度学习 · 对比学习 · 睡眠阶段 · 跨主体。

1 引言

睡眠是每个人生活中不可或缺的一部分。良好的睡眠对于维持个人身心健康至关重要 [16,9]。随着现代社会的快速发展，高强度的工作和学习以及不规律的生活方式影响着大多数人的睡眠。目前，睡眠问题已逐渐成为重要的公共卫生问题之一。

睡眠阶段判别在监测睡眠质量和诊断睡眠障碍方面发挥着重要作用。医生凭借专业资质和临床经验，对每段睡眠数据进行人工分类。显然，人工划分睡眠阶段十分耗时。与人工分类相比，基于算法/模型的自动分类方法效率更高，是临床应用中的重要工具。近年来，深度学习模型已应用于许多领域。随着深度学习日益普及，许多基于卷积神经网络（CNNs）、循环神经网络（RNNs）和Transformer的自动睡眠阶段分类方法应运而生 [17,12,13]。这些深度

学习模型均为端到端网络，但目前仅采用监督学习实现。

除此之外，深度学习模型在睡眠分期分类中的实际临床应用仍有许多问题需要研究和探索。不同被试的电生理信号不可避免地存在个体差异，这会影响训练良好的模型在实际应用中的判别性能。文献中的研究 [8] 和 [1] 表明，由于用户疲劳、电极放置位置不同、阻抗不同等因素，跨被试情况下的脑电信号不稳定。因此，如何设计并实现能够应对跨被试问题的睡眠阶段自动分类模型至关重要。

为解决跨被试问题，研究人员已将域自适应（DA）方法应用于脑电信号 [5]。然而，域自适应方法需要访问测试数据，因而无法保证不会出现信息泄漏问题。同时，基于新兴的被试间相关性（ISC）神经科学理论，并结合对比学习方法，可以采用一种新方法来探索被试不变性并开展跨被试分析。CLISA [15] 正是这样一项工作，它从被试间相关性的视角出发，使用对比学习方法进行基于脑电图的情绪识别。对比学习已广泛应用于许多领域。例如，在计算机视觉（CV）领域，可以通过基于图像间对比的大量无标签数据进行学习，提升网络的表征 [2]。在现有文献中，仅发现一项将对比学习用于自动睡眠分期的研究 [6]。然而，文献 [6] 并未考虑被试间相关性，而只是对信号进行了比较。

总之，本研究从受试者间相关性的角度，探讨使用对比学习方法区分睡眠阶段，以克服个体差异的影响。最终目的是为跨被试睡眠分期提供可行且可实施的方案。本文的主要贡献总结如下：

1. 针对时间序列任务改进 MobileViT，并将其与对比学习方法相结合，以实现最佳的睡眠分期分类。
2. 基于对比学习方法和被试间的相关性，设计了一种用于睡眠分期的跨受试者方案。

2 方法

2.1 对比学习方法

本研究采用的对比学习方法主要基于 SimClr [2] 的工作。不过，对比学习策略有所不同，其中包括为解决跨被试问题而设计的自对比和跨被试对比，同时还考虑了睡眠脑电信号和睡眠分期任务的特点。

实际上，对比学习是一种预训练方式，即通过对比学习利用输入训练集初始化网络参数。随后再次输入训练集，以微调网络并同时训练分类器。

将对比学习应用于脑电信号，需要通过计算余弦度量空间中不同特征之间的相似度来学习脑电信号的表征。在此，记 x 和 y 为两个脑电信号的向量表征，并记 $sim(x, y)$ 为两个向量 x 和 y 的相似度度量，

$$sim(x, y) = \cos(\theta_{x,y}) = \frac{x^T y}{\|x\|\|y\|}, sim(x, y) \in [0, 1] \quad (1)$$

如果余弦值接近 1，则表示两个向量之间的夹角较小，信号也更加相似。当余弦值为 0 时，则表示两个向量之间的夹角较大，信号也更加不同。

该模型的自对比基于 SimClr 的工作，其中信号的两种不同变换参考了 SSL 的工作 [6]。长度为 n 个历元的原始信号序列首先分别经过两次变换，即裁剪和置换，从而生成 $2n$ 个变换后的信号。随后将其输入网络以提取特征。在训练过程中，网络会测量每个历元的特征相似度。在剩余的 $2n-1$ 个样本中，寻找相应的、信号相同但变换不同的样本，即将具有相同历元的样本作为正样本对，其余样本作为负样本对。交叉熵函数的损失使用图 1 所示的真实标签进行计算。

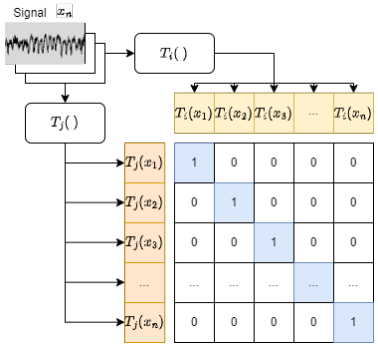

图 1. 脑电信号对比学习的真实标签。

总共有五个睡眠阶段需要识别，即清醒期、快速眼动期（REM）以及非快速眼动期的 S1期、S2期和 S3期。为了实现跨被试对比学习模型，五个

选取与上述睡眠阶段相对应的历元（每个历元为 30 秒）。通过使用 PCA（主成分分析）进行降维，将一个 30 秒的片段作为一个被试的特征。假设有 n 个被试，则有 n 个被试特征。再次进行两种不同的变换，生成 $2n$ 个变换后的信号，并将其输入网络进行特征提取。同一被试经过不同变换后得到的信号构成正样本对，而不同被试之间经过变换后的信号构成负样本对。使用相同的交叉熵函数计算损失。

此外，上述两种不同的变换具体定义如下：
裁剪：原始脑电信号 $T(t)$ ($t = 1, 2, \ldots, L$) 被随机分割成若干片段 $\{T_1(t)$ $T_2(t)$ $\ldots, T_n(t)\}$；然后随机选取一个 $T_r(t)$，并将其调整为原始长度 L。

置换：原始脑电信号 $T(t)$ ($t = 1, 2, \ldots, L$) 被随机分割成若干片段 $\{T_1(t)$ $T_2(t)$ $\ldots, T_n(t)\}$；这些片段被无序排列为 $\{T_{k_1}(t)$ $T_{k_2}(t)$ $\ldots, T_{k_n}(t)\}$，其中 $\{k_1, k_2, \ldots, k_n\}$ 的$\{1, 2, \ldots, n\}$为；随后将这些片段重新组合在一起。

上述对比学习策略能够最大限度地扩大一个样本与其他样本之间的差异。同时，该策略考虑了被试间相关性，以最大限度地利用相关数据。因此，对于跨被试睡眠分期，训练好的模型可以应用于新的被试。这能够提高基于深度学习模型的自动睡眠分期分类的实用性。

2.2 基于对比学习的睡眠分期模型

本研究所使用的睡眠分期分类模型主要参考了文献 [4] 和 [14]。采用文献 [10]中的 MobileViT，是因为 Transformer 能够提取长程局部特征，而 CNN 能够提取全局特征。主要区别在于，MobileViT 是一种图像模型。因此，我们对 MobileViT 进行了调整，使其适用于处理一维时间序列的深度学习模型。所开发的模型命名为 MViTime。MViTime 的架构如图 2 所示。

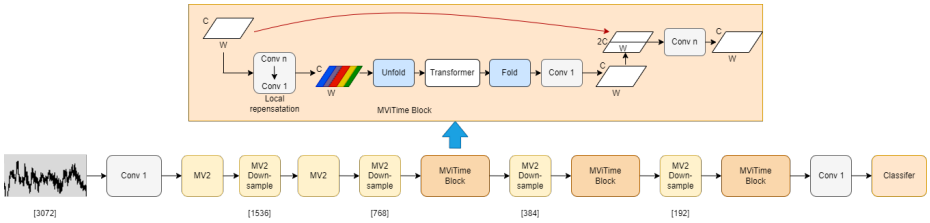

图 2. MViTime 的网络结构。

在图 3 中，输入 MViTime 模块的信号通过 Patchsize 被划分为许多标记。随后进行位置编码，以表示

信号的特征。因此，MViTime 模块中的每个赫兹信号都与其他信号相关联。随后，将颜色相同的标记重新排列，并通过 Transformer 进行自注意力计算。这样可以减少自注意力机制所需的计算量。

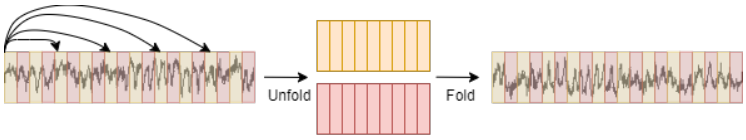

图 3. MViTime 的展开与折叠。

SiLU 用作激活函数，优化器为随机梯度下降。与 ReLU 函数相比，SiLU 函数更平滑且单调性更弱，从而提升了模型的泛化性能。对比学习模块的批量大小设为 128，主要是为了让模型能够加载到图形处理器（Nvidia RTX 3090）上。对于分类器的训练，批量大小设为 512，并采用余弦预热策略。

2.3 睡眠分期分类模型

图 4 展示了所开发的 MViTime 模型的对比学习策略。输入数据集被送入 MViTime 骨干网络进行预训练，通过对比学习方法初始化参数。随后再次输入这些数据集，以进行微调并训练分类器。选择微调而非线性探测的原因是，线性探测会冻结骨干网络来训练分类器，也就是说，它相当于只微调最后一个分类层。神经网络应作为一个整体进行优化，以实现最终分类。仅操作最后一层是不太可能的。因此，我们认为整体微调与神经网络的运行方式一致。

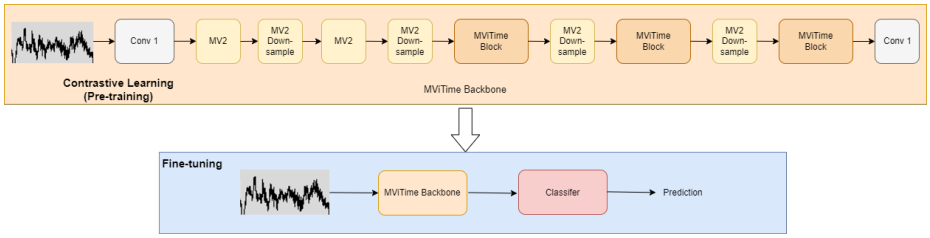

图 4. MViTime 通过对比学习方法进行预训练来初始化网络参数，随后对这些参数进行微调。

2.4 基于对比学习的跨受试者睡眠分期策略

图 5 展示了 MViTime 模型的跨被试对比学习策略。在跨受试者策略的实验中，基于自对比和跨被试对比得到的骨干网络输出经过加权并组合，然后输入网络以训练分类器。主要目标是最大化不同睡眠阶段之间的差异，并最大化被试之间的差异。组合方式有两种：一种是组合两种对比的对比学习模块，但不组合两种对比之后的分类器；另一种是组合两种对比的整个网络，包括对比学习模块和分类器。两种方法也都采用微调进行训练。

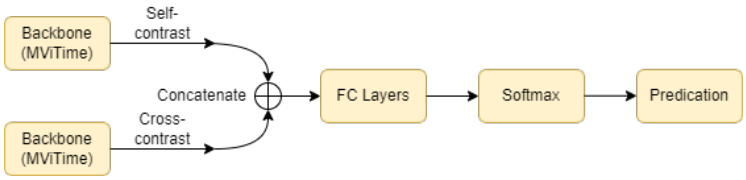

图 5. MViTime 的跨被试对比学习策略。

3 实验

3.1 数据集

本研究中的多导睡眠监测数据来自 Sleep-EDF 数据集 [7]，其中包含 197 份整夜多导睡眠监测记录。Sleep-EDF 数据集中的睡眠分期标记基于与 R&K 睡眠分期指南相对应的睡眠分期定义和特征。Sleep-EDF 数据分为两部分：Sleep Cassette 和 Sleep Telemetry。共有 153 份 SC 记录（SC=Sleep Cassette）和 44 份 ST 记录（ST=Sleep Telemetry）。

Sleep-EDF 数据集是公开可用的数据集，其中 SC 数据也是自动睡眠分期方法研究中更常用的数据集。根据处理方法的不同，文献中使用的数据量有所差异：文献 [11], 177,411 中使用了 222,479 个记录数据片段，文献 [5] 中使用了记录数据片段，文献 [3] 中使用了 195,479 个记录数据片段。此外，Sleep-EDF 中的脑电信号包含 Fpz-Cz 和 Pz-Oz 导联。文献 [5] 认为，Fpz-Cz 导联比 Pz-Oz 导联更靠近眼部，因此更适合捕捉与眼球运动的电活动相对应的睡眠状态特征。

本研究采用了与文献 [3]相同的 195,479 个记录片段，并选择 Fpz-Cz 单通道进行自动睡眠分期分类。

实验使用了来自 Sleep-EDF 数据集的 78 名健康受试者的数据。这 78 名健康受试者构成了一个数据集，该数据集通常被划分为两个数据集，即 EDF-20（也称为 Sleep-EDF-2013）和 EDF-78（也称为 Sleep-EDF-2018），其中 EDF-20 是从 78 名被试中选取的前 20 名被试。两个数据集中对应五个睡眠阶段的历元分布如表 1 所示。

表 1. 两个数据集中各睡眠阶段 30 秒历元的数量和百分比。

数据集	清醒期总数		第1期	第2期	第3期	快速眼动期
Sleep-EDF-20	42308	8285 (19.6%)	2804 (6.6%)	17799 (42.1%)	5703 (13.5%)	7717 (18.2%)
Sleep-EDF-78	195479	65951 (33.7%)	21522 (11.0%)	69132 (35.4%)	13039 (6.7%)	25835 (13.2%)

3.2 性能指标

为评估所提出模型的分类性能，我们根据混淆矩阵计算了准确率、召回率和F1分数等指标。各指标的说明见表2。

表 2. 准确率、召回率和 F1分数的含义。

指标 描述	
准确率	这衡量的是正确 分类实例在所有实例中所占的比例。
召回率	这衡量的是被模型正确识别的阳性 实例所占的比例。
F1分数	这是精确率和召回率的调和平均值。 它在精确率和召回率之间取得平衡， 同时考虑了假阳性和假阴性。

3.3 睡眠分期实验结果

图 6 分别展示了使用我们提出的方法在 Sleep-EDF-20 和 Sleep-EDF-78 两个数据集上获得的混淆矩阵和性能指标。混淆矩阵的行表示医生判读的睡眠分期，而列表示自动分类结果。

睡眠阶段。通过三个指标评估与目视检查结果相比的分类性能。

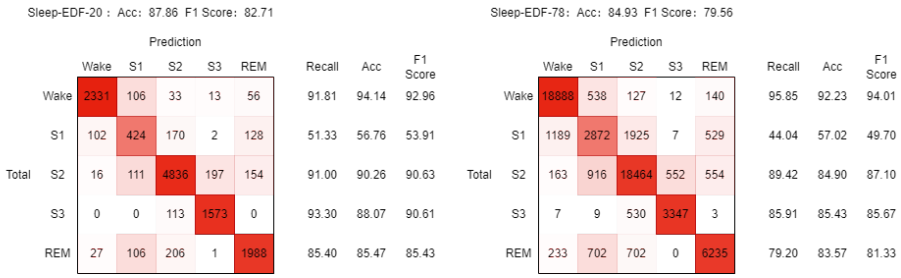

(a) MViTime 在 Sleep-EDF-20 上的结果 (b) MViTime 在 Sleep-EDF-78 上的结果

图6. MViTime 的混淆矩阵和性能指标

此外，我们的方法所得结果还与近期文献中的其他深度学习方法进行了比较。睡眠分期结果汇总于表3，其中给出了总体准确率和F1分数，以及各个阶段的F1分数。

表3. Sleep-EDF 数据集与最先进方法的性能比较。

数据集	方法	准确率	F1分数	各类别F1分数				
				W	S1期	S2期	S3期	快速眼动期
EDF-20	DeepSleepNet [17]	81.9	76.6	86.7	45.5	85.1	83.3	82.6
	SleepEEGNet [11]	81.5	76.6	89.4	44.4	84.7	84.6	79.6
	He's work [5]	85.2	78.9	-	-	-	-	-
	AttnSleep [3]	84.4	78.1	89.7	42.6	88.8	90.2	79.0
	XSleepNet [18]	86.3	80.6	-	-	-	-	-
	自监督学习 [6]	87.5	82.1	92.4	51.5	**90.9**	90.6	85.1
	MViTime（我们的方法）	**87.8**	**82.7**	**93.0**	**53.9**	90.6	**90.6**	**85.4**
EDF-78	SleepEEGNet [11]	74.2	69.9	89.8	42.1	75.2	70.4	70.6
	U-Time [12]	81.3	76.3	92.0	**51.0**	83.5	74.6	80.2
	He's work [5]	83.9	77.6	-	-	-	-	-
	AttnSleep [3]	81.3	75.1	92.0	42.0	85.0	82.1	74.2
	XSleepNet [18]	84.0	77.8	-	-	-	-	-
	SleepTransformer [13]	**84.9**	78.9	93.5	48.5	86.5	80.9	**84.6**
	自监督学习 [6]	84.2	79.0	94.0	50.4	86.1	84.5	80.1
	MViTime（我们）	**84.9**	**79.6**	**94.0**	49.7	**87.1**	**85.7**	81.3

图6和表3中的结果表明，我们提出的MViTime方法在Sleep-EDF-20和Sleep-EDF-78数据集上均取得了最佳的整体性能指标（State-of-the-art）。根据各睡眠阶段的F1分数这一综合指标，分类性能

在睡眠阶段上的表现相当令人满意，尤其是在W期、S2期、S3期和快速眼动期。S1期是从清醒期到睡眠的过渡状态，其特征难以精确识别。尽管S1期的F1分数低于其他睡眠阶段，但与其他深度学习模型相比，其表现仍达到了相当不错的水平。

3.4 跨被试实验结果

为验证基于 MViTime 的跨受试者策略，开展了进一步实验。在此实验中，从Sleep-EDF-20数据集中随机选择一名被试。将所选被试的睡眠记录用作测试数据，其余被试的数据用作训练数据。对 MViTime 的性能以及基于 MViTime 的跨受试者策略的有效性进行了比较评估。表 4 展示了使用三名被试的 MViTime、MViTime+ 和 MViTime++ 所得的比较结果。MViTime 表示所开发的深度学习模型，MViTime+ 和 MViTime++ 分别对应第 2.4 节和图 5 中所述的两种跨被试策略。

表 4. 跨被试协议对 五阶段F1分数的影响 针对三名被试。

受试者	方法	W	S1	S2	S3	REM
SC4131	MViTime	91.7	60.2	**91.4**	**91.3**	**90.8**
	MViTime+	**92.3**	**71.2**	90.7	90.3	88.5
	MViTime++	91.6	47.6	90.9	90.7	87.5
SC4052	MViTime	83.1	37.3	92.0	85.9	76.4
	MViTime+	85.1	36.5	88.7	83.1	68.1
	MViTime++	**89.4**	**41.4**	**92.6**	**86.5**	**78.6**
SC4032	MViTime	93.0	35.8	86.4	82.3	79.5
	MViTime+	92.6	34.2	86.8	86.7	78.2
	MViTime++	**93.7**	**37.7**	**89.6**	**89.4**	**82.5**

表4中可以观察到，MViTime++的跨受试者策略显著提高了受试者 SC4032 和 SC4052E0 的 S1期 F1分数，分别从 35.8% 提高到 37.7%，以及从 37.3% 提高到 41.4%。对于受试者 SC4131，MViTime 和 MViTime+略优于 MViTime++。这似乎表明，MViTime 本身的表现已经足够出色，因此跨受试者方案 MViTime++ 可能无法进一步优化网络参数。总体而言，当深度学习模型面对具有个体差异的新睡眠记录时，所提出的基于受试者间相关性的跨受试者策略对睡眠分期是有效的。

3.5 消融

通过消融实验，验证对比学习预训练的重要性以及大规模预训练的潜力。

对比学习模块。定义了以下模型：(1)基线：MViTime网络，但不进行对比学习预训练；(2) 基线+CL：MViTime网络，并进行对比学习预训练，其结果见第3.3节；(3) 基线 + CL-Large：MViTime网络，并进行对比学习预训练，其中预训练使用 Sleep-EDF-78 中剩余的58名被试，即排除 Sleep-EDF-20 的20名被试。消融实验的结果见表5。

表5. Sleep-EDF 数据集上的消融实验。

数据集	方法	准确率	F1分数	各类别F1分数				
				清醒期	S1期	S2期	S3期	快速眼动期
EDF-20	基线	86.1	80.0	92.5	46.0	89.6	89.1	82.9
	基线 + CL	87.8	82.7	93.0	53.9	90.6	90.6	85.4
	基线 + CL-Large	88.2	82.1	93.2	48.7	90.9	91.0	86.5
EDF-78	基线	83.6	76.8	93.9	41.8	86.1	83.8	78.7
	基线 + 对比学习	84.9	79.6	94.0	49.7	87.1	85.7	81.3

从表5可以看出，对比学习预训练模块提升了模型的分类性能。此外，在 EDF-20 中，使用与 EDF-20 无关的 58 名被试的数据进行对比学习预训练后，模型的准确率从 87.8% 提高到了 88.2%。预训练数据量的增加使模型效果得到提升。结果表明，所提出的对比学习模块能够有效地进一步提升模型性能，并显示出增加对比学习预训练数据量有望改善模型性能。

此外，本文还探讨了大规模对比学习预训练在跨受试者问题上的潜力。结果对比见表6。此处，MViTime-58 使用的是未采用跨受试者策略的 MViTime，并利用 Sleep-EDF-78 中其余 58 名被试进行对比学习预训练。MViTime++ 与表4中的相同。

表6. 预训练数据增加对三名被试五个阶段F1分数的影响 .

受试者	方法	W	S1期	S2期	S3期	快速眼动期
SC4131	MViTime-58	93.5	64.2	91.1	90.2	88.0
	MViTime++	91.6	47.6	90.9	90.7	87.5
SC4052	MViTime-58	89.9	47.3	94.5	93.4	76.9
	MViTime++	89.4	41.4	92.6	86.5	78.6
SC4032	MViTime-58	96.7	53.9	91.3	90.9	88.5
	MViTime++	93.7	37.7	89.6	89.4	82.5

从表6可以看出，随着预训练数据量的增加，对比学习提升了模型在各被试上的表现。MViTime-58 在三名被试的清醒期和难度更高的 S1期均取得了超过 5% 的显著性能，表现可与 MViTime++ 在 S2期、S3期和快速眼动期的结果相当，甚至更好。值得注意的是，与 MViTime++相比，MViTime-58 无需额外进行跨受试者相关性对比，只需增加用于自对比的预训练数据量即可。这一结果归功于 MViTime 的内部结构，因为它采用了 Transformer 的自注意力机制。

4 结论

本研究开发了一种用于睡眠分期的对比学习方法，该方法结合了跨受试者相关性理论。针对单通道脑电信号，提出了一种基于 MViTime 的深度学习睡眠分期分类模型。利用 Sleep-EDF 中两个数据集的睡眠记录进行评估。通过多项对比实验验证并分析了本方法的主要改进。消融实验表明，对比学习模块是有效的，并凸显了对比学习预训练的重要性。此外，在临床应用中，轻量级跨受试者策略比大规模预训练更具意义。然而，在微调时，使用对比学习进行预训练有望显著提升分类性能和跨被试性能。

致谢本研究得到国家自然科学基金项目编号61773164的资助。

参考文献

1. Buttfield, A., Ferrez, P.W., Millan, J.R.: 迈向稳健的脑机接口：错误电位与在线学习。《IEEE神经系统与康复工程汇刊》**14**(2), 164–168 (2006) 2. Chen, T., Kornblith, S., Norouzi, M., Hinton, G.: 一种用于视觉表征对比学习的简易框架。载于：国际机器学习会议。第1597–1607页。PMLR (2020) 3. Eldele, E., Chen, Z., Liu, C., Wu, M., Kwoh, C.K., Li, X., Guan, C.: 一种基于注意力机制的深度学习方法，用于单通道脑电图睡眠分期分类。《IEEE神经系统与康复工程汇刊》**29**, 809–818 (2021) 4. Hannun, A.Y., Rajpurkar, P., Haghpanahi, M., Tison, G.H., Bourn, C., Turakhia, M.P., Ng, A.Y.: 使用深度神经网络，在动态心电图中实现心脏病专家级别的心律失常检测与分类。《自然医学》**25**(1), 65–69 (2019) 5. He, Z., Du, L., Wang, P., Xia, P., Liu, Z., Song, Y., Chen, X., Fang, Z.: 基于数据增强和跨受试者差异缓解的单通道脑电图睡眠分期。《生物学与医学中的计算机》**149**, 106044 (2022)

6. Jiang, X., Zhao, J., Du, B., Yuan, Z.: 用于脑电图睡眠分期的自监督对比学习。载于：2021年国际神经网络联合会议（IJCNN）。第1–8页。IEEE (2021) 7. Kemp, B., Zwinderman, A.H., Tuk, B., Kamphuisen, H.A., Oberye, J.J.: 睡眠依赖性神经元反馈环路分析：脑电图慢波微连续性。《IEEE生物医学工程汇刊》**47**(9), 1185–1194 (2000) 8. Li, Y., Kambara, H., Koike, Y., Sugiyama, M.: 协变量偏移自适应技术在脑机接口中的应用。《IEEE生物医学工程汇刊》**57**(6), 1318–1324 (2010) 9. Maquet, P.: 睡眠在学习与记忆中的作用。《科学》**294**(5544), 1048–1052 (2001) 10. Mehta, S., Rastegari, M.: MobileViT：轻量级、通用且适用于移动设备的视觉Transformer。arXiv预印本 arXiv:2110.02178 (2021) 11. Mousavi, S., Afghah, F., Acharya, U.R.: SleepEEGNet：采用序列到序列深度学习方法的自动睡眠分期评分。PLOS ONE **14**(5), e0216456 (2019) 12. Perslev, M., Jensen, M., Darkner, S., Jennum, P.J., Igel, C.: U-Time：一种用于时间序列分割并应用于睡眠分期的全卷积网络。《神经信息处理系统进展》**32** (2019) 13. Phan, H., Mikkelsen, K., Chén, O.Y., Koch, P., Mertins, A., De Vos, M.: Sleep-transformer：具有可解释性和不确定性量化功能的自动睡眠分期。《IEEE生物医学工程汇刊》**69**(8), 2456–2467 (2022) 14. Ronneberger, O., Fischer, P., Brox, T.: U-Net：用于生物医学图像分割的卷积网络。载于：医学图像计算与计算机辅助干预——MICCAI 2015：第18届国际会议，德国慕尼黑，2015年10月5日至9日，论文集，第三部分18。第234–241页。施普林格 (2015) 15. Shen, X., Liu, X., Hu, X., Zhang, D., Song, S.: 面向跨被试情绪识别的主体不变脑电图表征对比学习。《IEEE情感计算汇刊》 (2022) 16. Siegel, J.M.: 哺乳动物睡眠功能的线索。《自然》**437**(7063), 1264–1271 (2005) 17. Supratak, A., Dong, H., Wu, C., Guo, Y.: DeepSleepNet：一种基于原始单通道脑电图的自动睡眠分期评分模型。《IEEE神经系统与康复工程汇刊》**25**(11), 1998–2008 (2017) 18. Phan, H., Chén, O.Y., Tran, M.C., Koch, P., Mertins, A., De Vos, M.: XSleepNet：用于自动睡眠分期的多视图序列模型。《IEEE模式分析与机器智能汇刊》 **44**(9), 5903–5915 (2021)