



(12)发明专利申请

(10)申请公布号 CN 110432870 A
(43)申请公布日 2019.11.12

(21)申请号 201910745381.9

(22)申请日 2019.08.13

(71)申请人 重庆邮电大学

地址 400065 重庆市南岸区黄桷垭崇文路2号

(72)发明人 赵德春 王怡 冯明扬 李小祥 唐琪

(74)专利代理机构 北京同恒源知识产权代理有限公司 11275

代理人 赵荣之

(51)Int.Cl.

A61B 5/00(2006.01)

权利要求书1页 说明书8页 附图2页

(54)发明名称

一种基于1D CNN-LSTM的睡眠信号自动分期方法

(57)摘要

本发明涉及一种基于1D CNN-LSTM的睡眠信号自动分期方法,属于信号处理及模式识别领域。该方法具体包括:S1:选择数据,从睡眠数据库中选择不同通道的EEG信号以及EOG信号作为原始信号;S2:信号预处理,利用小波变换方法对原始两个通道的EEG和EOG信号分别进行预处理,选出训练集数据和测试集数据;S3:将预处理之后的信号输入深度学习分类模型中,利用深度学习算法对睡眠状态进行分期,并输出分期结果。本发明提高睡眠分期准确度,降低信号的信噪比,从而有效节省运算时间;并且通过优化算法实现准确度高的睡眠自动分期,为睡眠质量评估提供有效依据。



1. 一种基于1D CNN-LSTM的睡眠信号自动分期方法,其特征在于,该方法具体包括以下步骤:

S1:选择数据,从睡眠数据库中选择不同通道的EEG信号以及EOG信号作为原始信号;

S2:信号预处理,利用小波变换方法对原始两个通道的EEG和EOG信号分别进行预处理,选出训练集数据和测试集数据;

S3:将预处理之后的信号输入深度学习分类模型中,利用深度学习算法对睡眠状态进行分期,并输出分期结果。

2. 根据权利要求1所述的一种基于1D CNN-LSTM的睡眠信号自动分期方法,其特征在于,所述步骤S2具体包括:使用小波变换方法对原始信号进行降噪处理,小波降噪的参数:小波基选择'db4',小波分解层数为5层,使用stein无偏估计方法确定阈值并且选择硬阈值函数对原始信号进行预处理。

3. 根据权利要求1所述的一种基于1D CNN-LSTM的睡眠信号自动分期方法,其特征在于,所述步骤S3中,构建深度学习分类模型具体包括以下步骤:

S31:训练集数据以每30s为一阶段,深度学习分类模型用300个神经元的全连接层连接输入,将原本的3000个样本点的数据格式调整为300*10输入模型;假设总样本数为N,训练集的样本数为 N_1 ,则训练时输入数据的格式是 $N_1*300*10$;测试时的输入格式为 $(N-N_1)*300*10$;

S32:经过全连接层之后,利用2个1D CNN卷积层进行卷积,卷积核的大小为3,分别选用64个卷积核和128个卷积核,在两次卷积之后,选择最大池化,池化核大小为2,步长为2;然后再次进行两层1D卷积操作,卷积核的大小为5,分别选用128个卷积核和256个卷积核,两次卷积之后,再一次进行最大池化,池化核大小为2,步长为2;所有卷积层的激活函数都是“Relu”;

S33:在1D CNN与LSTM之间添加一个dropout层,dropout为0.5,然后经过3个LSTM层堆叠,将经过1D CNN处理之后的信号进行进一步处理,神经元的数目均为300;然后再一次dropout,为0.4;

S34:最后通过全连接层输出,全连接层的单元数为6,激活函数为“softmax”。

4. 根据权利要求3所述的一种基于1D CNN-LSTM的睡眠信号自动分期方法,其特征在于,构建深度学习分类模型中,使用categorical_crossentropy多分类交叉熵函数计算损失。

5. 根据权利要求3所述的一种基于1D CNN-LSTM的睡眠信号自动分期方法,其特征在于,构建深度学习分类模型中,模型的优化函数使用sgd优化模型参数。

6. 根据权利要求3所述的一种基于1D CNN-LSTM的睡眠信号自动分期方法,其特征在于,所述深度学习分类模型在构建过程中,对模型进行训练100次,找出最优的结果,然后用于测试。

一种基于1D CNN-LSTM的睡眠信号自动分期方法

技术领域

[0001] 本发明属于信号处理及模式识别领域,涉及睡眠自动分期以及深度学习算法,具体涉及一种基于1D CNN-LSTM的睡眠信号自动分期方法。

背景技术

[0002] 目前,睡眠障碍已被确认为一种具有公共危害性的疾病,越来越受到人们的高度重视。通过各生理信号对人体睡眠状态进行分期,是客观评估睡眠质量的一种有效方法。人们可以通过对睡眠状况来对睡眠质量和某些基于睡眠的疾病如神经衰弱、心血管疾病进行检测。而睡眠分期是了解睡眠状况和睡眠质量评价的关键,基于睡眠分期的睡眠评分同时也是精神病学和神经病学最重要的诊断方法。

[0003] 目前大多是基于脑电信号来对睡眠进行研究,因为其于睡眠有直接联系,可以更加准确地分析睡眠情况。通过不同分析方法提取EEG信号的特征参数,再利用分类器进行分类是睡眠分期的经典方法。对EEG的分析方法主要是从其时域、频域和非线性方面进行分析。刘志勇等通过对EEG进行非线性符号动力学分析、去趋势波动分析和频谱分析的方法,并结合最小二乘向量机分类器将睡眠状态分为5期,准确率达到92.87%,但该算法只对每个样本进行单独的训练和验证,泛化能力有待提高。谢宏等利用离散小波变换结合非线性支持向量机的方法满足了模型对泛化能力的要求,准确率为81.65%。但现有的公共睡眠数据集包含具有多个EEG通道的PSG记录,以及其他模式,如EOG或EMG通道。虽然人类睡眠专家在睡眠评分过程中使用这些方式,但很少被自动睡眠评分系统考虑。大多都仅仅只关注EEG信号,很自然地认为EEG数据的多变量性质确实携带了宝贵的信息,但它通常仅用于处理电极去除或不良信道的问题,而不是用作改进算法的杠杆。因此除EEG外,还有许多其他生理信号,如ECG,EOG,EMG也常应用于睡眠自动分期,并有助于睡眠相关疾病的鉴定。EEG在睡眠各阶段的特征波不同,EMG在觉醒阶段具有高肌电水平,而在快速眼动期具有低肌电水平。为提高睡眠分期的准确度,研究者们提出一种新的思想,即利用人体其他生理电信对睡眠进行分期研究,如心电(electrocardiogram,ECG)、EMG、EOG、血氧、呼吸等。因此,目前在睡眠生理信号的选择与预处理方面存在如下缺陷:①睡眠生理信号多,选择方式各不相同。②睡眠生理信号随机性强,易受干扰,预处理要求高。睡眠生理信号(包括EEG,EOG等)具有很高的时变敏感性,其信号极易被无关噪音污染,从而形成各种噪音和伪迹。如何对常见的噪音进行有效的消除和尽可能避免在信号中产生伪迹是预处理的关键,同时也是影响睡眠分期准确度的关键因素。

[0004] 深度学习根源于神经网络算法,“深度”源于其含有多层网。深度学习的方法是受到大脑的分层处理机制的启发发展而来的。典型的浅层的机器学习算法包括隐马尔科夫模型、最大熵模型、支持向量机等,均为单层结构。因为其自身存在的局限性,从而激发了利用深度网络的动机。Hinton等人于2006年提出的深度信念网络(DBN)解决了BP算法训练多层网络时需要大量含标签的样本、收敛速度慢以及容易陷入局部最优的难题。自此以后,深度学习成为学术界关注的热点,在应用领域显示出巨大的优势。除了图像和语言方面,深度学

习还应用在自然语言处理,搜索广告预测等方面。将深度学习算法用于时序信号的处理方面的成果相对较少。

[0005] 在睡眠分期过程中,睡眠分期准确度是一个重要的衡量指标。睡眠分期准确度主要取决于睡眠分期特征选择和提取、特征筛选和分类器选择和分类器内部参数调优。传统的处理方式在睡眠分期准确度方面存在以下缺点:

[0006] ①特征多,特征提取计算量大且特征筛选难度大。传统的机器学习实现睡眠自动分期,其准确度很大程度上依赖于特征的优劣。可用于睡眠脑电信号的特征很多,如时域上的均值、方差、时频域上的不同节律波的小波系数、样本熵、Reyi系数、排列熵等。基于时域和时频域上的特征参数比较容易计算。但是基于非线性的算法的如样本熵、关联维数、最大Lyapunov熵等进行算法提取时如嵌入维数、延迟时间等特征参数的计算量就大许多。而目前的研究中,非线性特征的分期效果比时域、时频域特征的分期效果更好一些,因此特征提取往往需要消耗大量时间。

[0007] 对于睡眠信号的特征有很多,前面提到了时域、时频域或者非线性特征。但是目前没有统一的原则针对于信号是睡眠脑电信号时特征参数选择。不同的选择原则有不同特征选择方案。如针对于分期算法高效性原则,特征算法中不应有关联维数、最大Lyapunov熵等运算周期长的特征算法。如针对于分期算法的准确度原则,需要对特征进行特征筛选工作。其目的在于找出和原信号相关系数高的特征算法。对特征算法进行怎样的筛选方法决定了分期算法的准确度。而特征筛选这一核心步骤不仅要求严格,计算量往往也很大,运算时间长,因此难度很大。

[0008] ②深度学习分类算法应用较少且效果不够显著。可应用于睡眠分期的机器学习算法很多,如支持向量机、随机森林等。而近几年,深度学习在计算机视觉,图像处理,语音识别等方面的应用取得突破性的进展,尤其是在大规模数据集的情况下体现出其优越性。在生理信号处理方面也逐渐发展起来,如在阿尔兹海默症检测,癫痫检测,睡眠分期方面等都有一定的应用。越来越多的研究人员将深度学习应用于与健康生理学相关的数据挖掘和模式识别问题,从好的方面来看,它培养了一种有趣的趋势,并提升了机器学习带来的期望。但它不是一个灵丹妙药,无法在临时生物信息学应用中提供很好的结果。仍然存在许多潜在的挑战,包括有限或不平衡的数据,深度学习结果的解释,以及选择适当的架构和超参数。并且在睡眠自动分期的应用中,虽然可以有效地避免了特征提取的复杂性和特征选择的主观性,但是由于面向的原始睡眠信号数据集是属于类别分布不均衡的数据集,其学习模型的分类效果并不是特别理想。

[0009] 因此,亟需一种能够缩减运算步骤,减小计算量的睡眠分期方法。

发明内容

[0010] 有鉴于此,本发明的目的在于提供一种基于1D CNN-LSTM的睡眠信号自动分期方法,探究睡眠与除EEG以外的其他生理信号之间的相关性,利用多种生理信号对睡眠状况进行分析。缩减运算步骤,减小计算量的基础上实现准确的睡眠分期,进而提供一种科学的参考依据,使个体和医师能够利用本算法得到睡眠分期的结果了解睡眠质量状况和某些睡眠疾病发病可能性。

[0011] 为达到上述目的,本发明提供如下技术方案:

[0012] 一种基于1D CNN-LSTM的睡眠信号自动分期方法,利用深度学习算法对睡眠生理信号(包括EEG,E0G等)进行分析,在对原始信号进行预处理之后便作为深度学习框架的输入,利用模型的学习最后输出睡眠分期结果并就此进行分析评估睡眠状况以及疾病预测等。该方法具体包括以下步骤:

[0013] S1:选择数据,从睡眠数据库中选择不同通道的EEG信号以及E0G信号作为原始信号;

[0014] S2:信号预处理,利用小波变换方法对原始两个通道的EEG和E0G信号分别进行预处理,选出训练集数据和测试集数据;

[0015] S3:将预处理之后的信号输入深度学习分类模型中,利用深度学习算法对睡眠状态进行分期,并输出分期结果。

[0016] 进一步,所述步骤S2具体包括:使用小波变换方法对原始信号进行降噪处理,可以有效地提高信号的信噪比,小波降噪的主要参数:小波基选择‘db4’,小波分解层数为5层,使用stein无偏估计方法确定阈值并且选择硬阈值函数对原始信号进行预处理。

[0017] 进一步,所述步骤S3中,构建深度学习分类模型具体包括以下步骤:

[0018] S31:训练集数据以每30s为一阶段,由于信号的采样频率为100Hz,因此每30s包含3000个数据,即每一个样本有3000个样本点;深度学习分类模型用300个神经元的全连接层连接输入,因此将原本的3000个样本点的数据格式调整为 300×10 输入模型;假设总样本数为N,训练集的样本数为 N_1 ,则训练时输入数据的格式是 $N_1 \times 300 \times 10$;测试时的输入格式为 $(N - N_1) \times 300 \times 10$;

[0019] S32:经过全连接层之后,利用2个1D CNN卷积层进行卷积,卷积核的大小为3,分别选用64个卷积核和128个卷积核,在两次卷积之后,选择最大池化,池化核大小为2,步长为2;然后再次进行两层1D卷积操作,卷积核的大小为5,分别选用128个卷积核和256个卷积核,两次卷积之后,再一次进行最大池化,池化核大小为2,步长为2;所有卷积层的激活函数都是“Relu”;

[0020] S33:为了防止过拟合,在1D CNN与LSTM之间添加一个dropout层,dropout为0.5,然后经过3个LSTM层堆叠,将经过1D CNN处理之后的信号进行进一步处理,神经元的数目均为300;然后再一次dropout,为0.4;

[0021] S34:最后通过全连接层输出,由于本发明睡眠分为6期,因此全连接层的单元数为6,激活函数为“softmax”。

[0022] 进一步,构建深度学习分类模型中,使用categorical_crossentropy多分类交叉熵函数计算损失。

[0023] 进一步,构建深度学习分类模型中,模型的优化函数使用sgd优化模型参数。

[0024] 进一步,所述深度学习分类模型在构建过程中,对模型进行训练100次,找出最优的结果,然后用于测试。

[0025] 本发明的有益效果在于:

[0026] (1) 本发明选用了EEG和E0G这两种睡眠生理信号来进行睡眠自动分期,为算法提供充足的数据量,以便提高睡眠分期准确度;

[0027] (2) 本发明预处理阶段设计了合适的降噪方法来有效提高信号的信噪比,为提高睡眠分期准确度奠定基础;

[0028] (3) 本发明设计了一种新的、泛化能力强的、准确度高的算法作为睡眠自动分期算法。适应于多生理信号,避免了特征提取与筛选步骤过程繁琐计算量大的问题,有效节省运算时间。并且通过优化算法实现准确度高的睡眠自动分期,为睡眠质量评估提供有效依据。

[0029] (4) 本发明设计的深度学习分类模型是在LSTM基础上增加了CNN,(由于CNN能够权重共享,从而可以减少网络各层之间的连接,同时又降低了过拟合的风险)因此简化了模型的复杂度,从而提高模型的分类效率。

[0030] 本发明的其他优点、目标和特征在某种程度上将在随后的说明书中进行阐述,并且在某种程度上,基于对下文的考察研究对本领域技术人员而言将是显而易见的,或者可以从本发明的实践中得到教导。本发明的目标和其他优点可以通过下面的说明书来实现和获得。

附图说明

[0031] 为了使本发明的目的、技术方案和优点更加清楚,下面将结合附图对本发明作优选的详细描述,其中:

[0032] 图1为本发明所述自动分期方法的自动分期流程图;

[0033] 图2为生理信号在时间序列上的预测结果(左为EEG,右为EOG)示意图;

[0034] 图3为原始信号与降噪后信号的对比图示意图;

[0035] 图4为深度学习分类模型示意图;

[0036] 图5为LSTM模型示意图。

具体实施方式

[0037] 以下通过特定的具体实例说明本发明的实施方式,本领域技术人员可由本说明书所揭露的内容轻易地了解本发明的其他优点与功效。本发明还可以通过另外不同的具体实施方式加以实施或应用,本说明书中的各项细节也可以基于不同观点与应用,在没有背离本发明的精神下进行各种修饰或改变。需要说明的是,以下实施例中所提供的图示仅以示意方式说明本发明的基本构想,在不冲突的情况下,以下实施例及实施例中的特征可以相互组合。

[0038] 请参阅图1~图5,图1为本发明所述的基于1D CNN-LSTM的睡眠信号自动分期方法,利用深度学习方法来实现睡眠自动分期,与传统的机器学习睡眠分期方法相比,可以节省特征提取与特征筛选步骤,避免了特征提取计算量大的问题以及特征筛选缺少准则的问题。将原始信号进行预处理之后直接输入深度学习模型,最后输出分期结果,从而分析睡眠状况,对睡眠质量进行评估。其主要流程如下图1所示,具体包括以下步骤:

[0039] 1、数据选择

[0040] 睡眠数据库来自于PhysioBank的Sleep-EDF数据库中的数据,即Sleep-EDF Database[expanded]。该数据库包括61个PSG以及每30s一段的人工专家睡眠分期的注释,主要有两类文件,分别是SC文件和ST文件。SC文件,是在79名年龄在25-101岁的健康高加索人没有任何睡眠相关药物的年龄对睡眠影响的研究中获得的。被摄对象36和52的第一晚以及被摄对象13的第二晚由于卡盒或激光磁盘失效而丢失。因此,目前包括在这里的受试者,编号00至19,男性10人,女性10人,25-34岁。ST文件中,共有22名具有轻微入睡困难的健

康人群。记录了Fpz-Cz和Pz-Oz两个通道的EEG信号、Horizontal EOG信号(采样频率均为100Hz)以及颞下巴EMG信号(采样频率为1Hz),数据中带有专家的人工分期标准,每30s判断一次睡眠分期状态。本方法选用不同通道的EEG信号以及EOG信号作为原始信号来进行睡眠自动分期。

[0041] 表1. 本方法采用的睡眠数据分布表

[0042]

睡眠时期	Awake	N1	N2	N3	N4	REM	Total
数据(30S)	11382	915	4704	723	587	1736	20047

[0043] 如上表1所示,训练集的样本数是17277,测试集的样本数是 $20047-17277=2770$,数据集选择上述数据库中10个人的完整睡眠记录,其中训练集选自9个完整睡眠数据记录中的数据,测试集为其中1的完整睡眠数据记录。因为在睡眠记录中各时期的分布及其不均衡,因此在训练集是由前9个人的数据记录中某一个统一时间段的数据组合而成。而测试集则是保留剩余1人的完整睡眠数据,以此来进行睡眠自动分期。为了体现睡眠分期模型的有效性,测试集则选用一个人的完整睡眠数据记录,其中包含4~5个睡眠周期。

[0044] 探究各生理信号在睡眠周期中的时间依赖性:本发明的睡眠自动分期不再依赖于特征提取与特征选择,而是利用多种生理信号作为睡眠分期的主要依据。考虑到整个睡眠过程中的信号都存在一定的联系,因此需要探究原始生理信号在睡眠分期中所表现出的可预测性。前阶段的睡眠状态是否会影响到后阶段的睡眠状态,而这样的相互影响在生理信号中有怎样的体现是本课题需要研究的。在整个睡眠活动中,NREM和REM睡眠相交替出现,形成一个睡眠周期大约90分钟,人每晚一般有4~5个睡眠周期。因此在生理信号上也会呈现出相应的周期性。利用LSTM方法对时间序列信号进行预测,可以得到良好的效果,可见睡眠EEG信号和EOG信号在睡眠周期中有一定的前后关联性,因此可以用来完成睡眠自动分期。其预测结果如图2所示,图2中黑色为原始信号,浅灰色为训练集,深灰色为测试集。可以看出预测的结果与原始信号的趋势基本相同,在睡眠周期中存在可预测性。

[0045] 2、信号预处理

[0046] 使用小波变换方法对原始信号进行降噪处理,可以有效地提高信号的信噪比,小波降噪的主要参数:小波基选择'db4',小波分解层数为5层、使用stein无偏估计方法确定阈值并且选择硬阈值函数对原始信号进行预处理。原始信号与降噪后信号的对比结果如图3所示,降噪后的EEG信号与原始信号相比,err的值为154.3849,per的值为0.9911,snr的值为26.1129。降噪后的EOG信号与原始信号相比,err的值为174.5264,per的值为0.9994,snr的值为29.5350(per值为降噪信号的方差/原始信号的模,err为降噪信号和原始信号差的模,snr为信噪比)。从数值上看,此算法达到了很好的降噪效果。从图3中可以看出,原始信号上局部混杂较为严重,而通过降噪处理之后,混杂部分得到有效消除,并且降噪后的信号能够保留原始信号的特点,减少失真,对后续睡眠自动分期有一定帮助。

[0047] 3、深度学习分类模型

[0048] 本发明采用CNN与RNN(LSTM)结合的方式对多通道睡眠数据进行研究,从而实现睡眠自动分期。LSTM常用于处理各种生理信号,它克服了传统神经网络模型存在梯度消失的

问题,但是运算速度较慢,而CNN的加入,其局部感受野与权值共享特性可以加快运算速度,二者的结合进一步提高了睡眠准确度。如图4所示,深度学习分类模型通过1D CNN-LSTM实现睡眠自动分期的过程为:

[0049] 第一步:信号预处理,利用小波变换对原始两个通道的EEG、EOG信号分别进行预处理,小波基选择‘db4’,小波分解层数为5层、使用stein无偏估计方法确定阈值并且选择硬阈值函数对原始信号进行预处理。

[0050] 第二步:将预处理之后的信号输入深度学习模型中。

[0051] (1) 训练数据以每30s为一阶段,由于信号的采样频率为100Hz,因此每30s包含3000个数据即每一个样本有3000个样本点。模型是用300个神经元的全连接层连接输入,因此将原本的3000个样本点的数据格式调整为300*10输入模型。(训练集的样本数是17277,所以输入数据的格式是17277*300*10)

[0052] (2) 经过全连接层之后,利用2个1D CNN卷积层进行卷积,卷积核的大小为3,分别选用64个和128个,在两次卷积之后,选择最大池化,池化核大小为2,步长为2。然后再次进行两层1D卷积操作,卷积核的大小为5,分别选用128个和256个,两次卷积之后,再一次进行最大池化,池化核大小为2,步长为2。所有卷积层的激活函数都是“Relu”。

[0053] (3) 为了防止过拟合,在1D CNN与LSTM之间添加一个dropout层,dropout为0.5,然后经过3个LSTM层堆叠,将经过1D CNN处理之后的信号进行进一步处理,神经元的数目均为300。然后再一次dropout,为0.4。

[0054] (4) 最后通过全连接层输出,由于本实施例睡眠分为6期,因此全连接层的单元数为6,激活函数为“softmax”。

[0055] 其中,使用categorical_crossentropy多分类交叉熵函数计算损失;模型的优化函数使用sgd优化模型参数。

[0056] 第三步:完成运行,输出结果。

[0057] 在第二步中,1D-CNN的内部结构为:1D-CNN卷积运算是一维卷积运算,适合于一维输入数据,如生物医学信号。对于一维输入信号S和内核W,卷积运算定义为:

$$[0058] \quad (S * W)_n = \sum_{i=1}^{|W|} W_i S(i+n-1)$$

[0059] 在该等式中,*运算符表示离散卷积运算。卷积过程的输出称为特征映射。设 $(S|_{W(i,j)})_n$ 是权重矩阵的输入矩阵的受限矩阵。 $(S|_{W(i,j)})_n$ 的元素表示从n到W(i,j) .维度的S中的元素。因此,输出矩阵可以由通式表示,其在以下公式给出。

$$[0060] \quad O_n^j = (S|_{W(i,j)} * W(i,j))_n$$

[0061] CNN的结构主要包括输入层,隐藏层和输出层。卷积和池化操作通常在隐藏层完成。

[0062] 其次,LSTM的内部结构为:LSTM由三个门和一个细胞状态组成。每个输入由两部分组成,一个是时间t的输入状态 (x_t) ,另一个是时间t-1的输出状态 (h_{t-1}) 。每个门结构都需要激活功能,其结构如图5所示,输入门由以下公式计算:

$$[0063] \quad i_t = \sigma(W_i[x_t, h_{t-1}, C_{t-1}] + b_i)$$

$$[0064] \quad \tilde{C}_t = \tanh(W_c[x_t, h_{t-1}, C_{t-1}] + b_c)$$

[0065] 遗忘门是第二种门类型,它可以控制细胞状态删除一些信息,定义为:

$$[0066] \quad f_t = \sigma(W_f[h_{t-1}x_t] + b_f)$$

[0067] 细胞状态通过遗忘门和输入门更新信息,定义为:

$$[0068] \quad C_t = C_{t-1}f_t + \tilde{C}_t i_t$$

[0069] 最后,输出结果通过输出门获得,计算公式为:

$$[0070] \quad o_t = \sigma(W_o[x_t, h_{t-1}, C_t] + b_o)$$

$$[0071] \quad h_t = \tanh(C_t) \cdot o_t$$

[0072] 在上面的公式中, x_t 是输入序列, h_{t-1} 是前一个输出; C_{t-1} 是先前的细胞状态, b 是偏置矢量; W 表示每个输入的单独特重向量, σ 是逻辑sigmoid函数。

[0073] LSTM的关键是细胞状态,即图5中间的水平线。如果仅有水平输入不能添加或删除信息,则需要“门”结构来选择性地传递信息。在LSTM中,第一步是通过遗忘门,它根据单元的状态决定丢弃哪些信息。然后通过输入门,它将决定添加到单元状态的新信息量。最后,输出门根据单元的状态确定输出的值。信息进入LSTM网络,可以根据规则进行判断。只保留符合算法认证的信息,并且忘记门将忘记不匹配的信息。这使得LSTM能够解决长阶依赖问题,其通用性非常高,它可以带来很多可能性,使得应用范围非常广泛。

[0074] 4、分类评估

[0075] 利用深度学习分类模型对睡眠状态进行分期后,需要对分期的结果进行评估,来判定分期算法的优劣。常用的评估参数主要是分类准确度。根据R&K睡眠分期标准,本实施例将睡眠分为六期即Awake, N1, N2, N3, N4, REM。建立基于睡眠六期的分期结果如下表2所示:

[0076] 表2. 各组测试的分期结果

[0077]

测试数	准确度 (%)	平均准确度 (%)
测试 1 (Fpz-Cz)	92.16	
测试 2 (Pz-Oz)	87.76	89.85
测试 3 (Fpz-Cz+Pz-Oz)	89.64	
测试 4 (Fpz-Cz+EOG)	93.86	
测试 5 (Pz-Oz+EOG)	90.14	92.21
测试 6 (Fpz-Cz+Pz-Oz+EOG)	92.64	

[0078] 如上表2中所示,前三组测试是仅用EEG信号进行睡眠自动分期,后三组测试是将EEG与EOG相结合使用。可以看出本方法无论是针对单独的EEG信号或是将EEG信号与EOG信号结合用于睡眠自动分期都表现出良好的分类性能。但是有了EOG的加入,其分期准确度更高,均达到90%以上,平均准确度为92.21%,最高达93.86%。并且针对一个完整的睡眠数据记录来实现睡眠自动分期,也进一步说明睡眠生理信号在睡眠周期中表现出一定的前后关联性。对于测试4,其准确度最高,可达93.86%,其混淆矩阵如下表所示:

[0079] 表3. 对于测试4的分期结果混淆矩阵

[0080]

		Predict						Number of data
		Awake	N1	N2	N3	N4	REM	
Expert	Awake	2007	23	2	2	3	32	2069
	N1	4	39	8	0	0	5	56
	N2	1	2	363	20	5	16	407
	N3	0	0	5	27	3	0	35
	N4	2	0	1	5	93	0	101
	REM	4	0	27	0	0	71	102
	Precision (%)	97.00	69.64	89.19	77.14	92.08	69.61	
Recall (%)	99.41	60.94	88.97	50.00	89.42	52.99		
F1 score (%)	98.19	65.00	89.08	60.67	90.73	60.17		
Total ACC (%)							93.86	

[0081] 从上表3可以看出,深度学习分类模型在清醒时期的分期准确度可以达到97%,N4时期准确度也达到90%以上,在N1以及REM时期的准确度偏低,是由于该数据集的分布及其不平衡,其清醒时期占比最高,而这两个时期的数据量偏少,因此分期的效果也偏差。而对于通常情况来讲比较难分的N2时期与REM期,从混淆矩阵中也可以看出,这两期的混淆程度偏高,因为有了EOG的加入,算法在这两期中所呈现出的分期准确度也是较好的。但是REM时期的数据量较少,依然会受到N2时期的混淆,但是总体准确度是偏高的,达到93.86%。此外,可以由总体准确度计算出kappa系数,kappa系数可以用来衡量专家分期和本方法分期结果的吻合程度。

$$[0082] \quad \kappa = \frac{ACC - ACC_0}{1 - ACC_0}$$

[0083] 其中,ACC表示总体分类准确度,ACC₀表示机会水平。ACC₀=1/N_Y,N_Y为分类数目。当kappa系数为0时,表示分类准确度为机会水平程度,kappa系数为1意味着最好的分类效果。本方法的kappa系数为0.94,说明分期的效果具有很高的一致性。由此可见,本方法能够实现高效准确的睡眠自动分期,与一般的深度学习睡眠分期的算法相比,具有一定优势。

[0084] 综上所述,本发明所述方法可以实现准确的睡眠自动分期,在不同的测试中也展现出良好的分类性能,在睡眠研究中可提供较为准确的参考结果。除此之外,该方法也可用于其他生理信号的分类研究中,具有广泛的应用前景,并且为深度学习在医学生理信号中的应用奠定了一定的基础。

[0085] 最后说明的是,以上实施例仅用以说明本发明的技术方案而非限制,尽管参照较佳实施例对本发明进行了详细说明,本领域的普通技术人员应当理解,可以对本发明的技术方案进行修改或者等同替换,而不脱离本技术方案的宗旨和范围,其均应涵盖在本发明的权利要求范围当中。

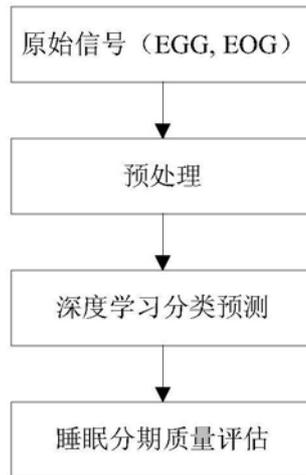


图1

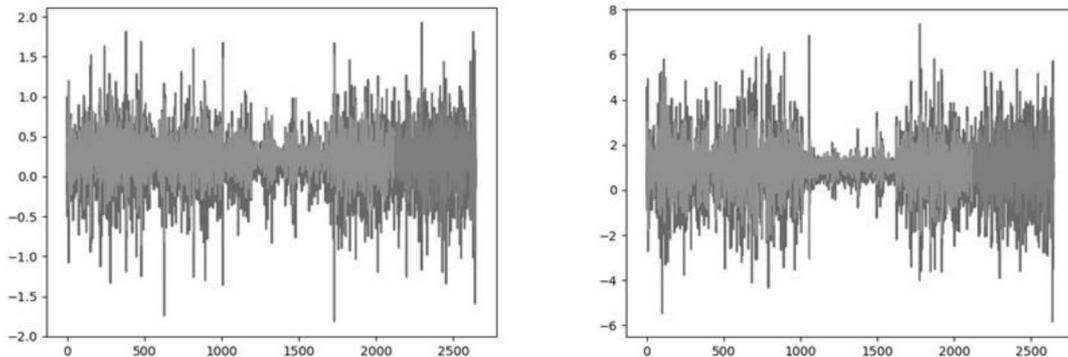


图2

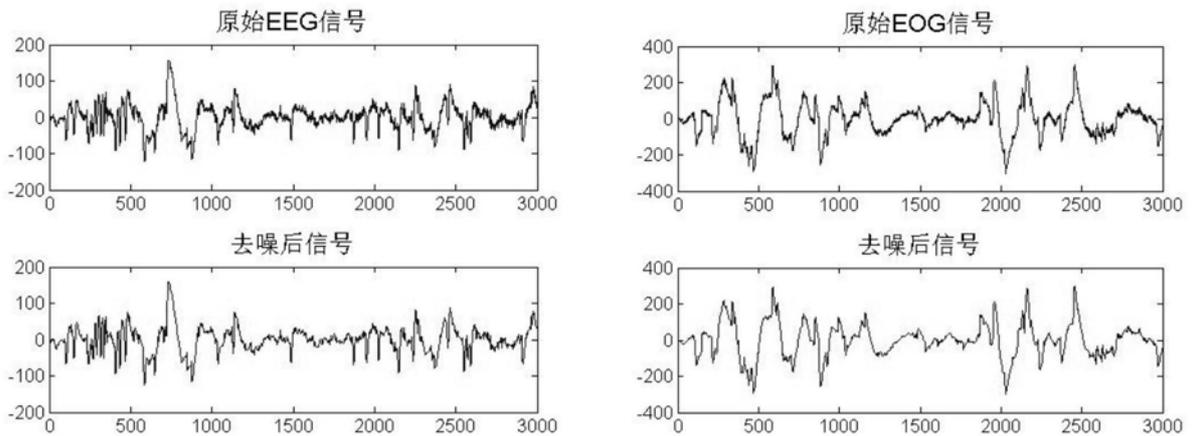


图3

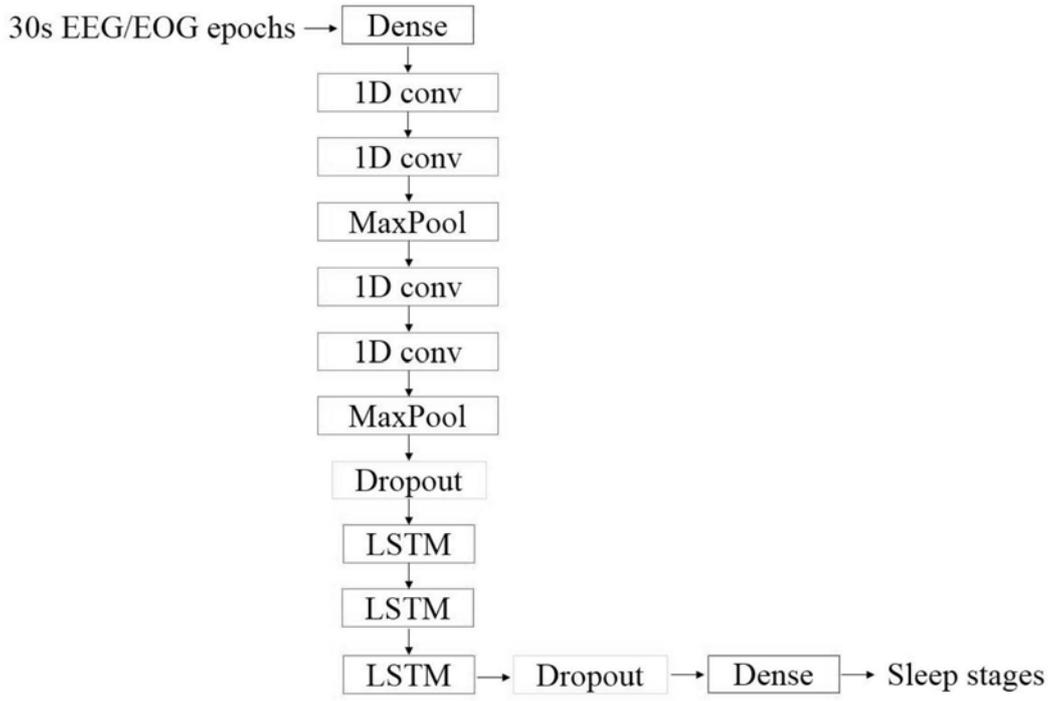


图4

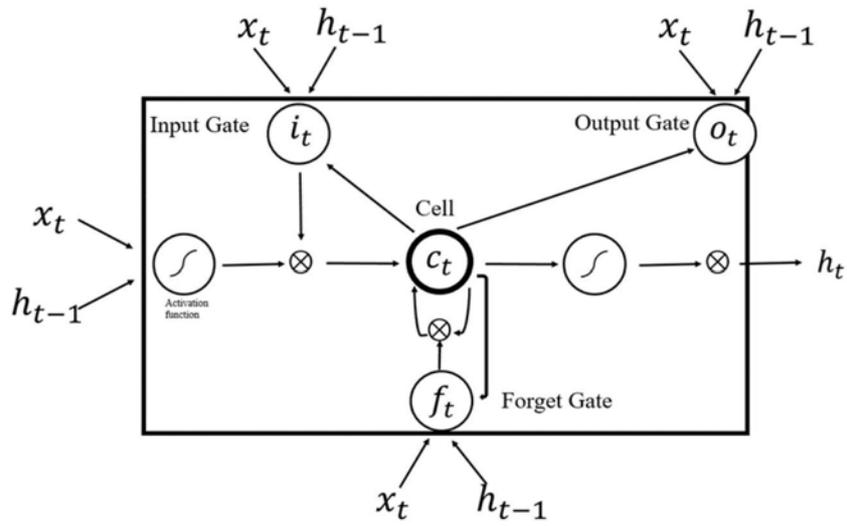


图5

专利名称(译)	一种基于1D CNN-LSTM的睡眠信号自动分期方法		
公开(公告)号	CN110432870A	公开(公告)日	2019-11-12
申请号	CN201910745381.9	申请日	2019-08-13
[标]申请(专利权)人(译)	重庆邮电大学		
申请(专利权)人(译)	重庆邮电大学		
当前申请(专利权)人(译)	重庆邮电大学		
[标]发明人	赵德春 王怡 冯明扬 李小祥 唐琪		
发明人	赵德春 王怡 冯明扬 李小祥 唐琪		
IPC分类号	A61B5/00		
CPC分类号	A61B5/4806 A61B5/4809 A61B5/4812 A61B5/4815 A61B5/7267		
外部链接	Espacenet SIPO		

摘要(译)

本发明涉及一种基于1D CNN-LSTM的睡眠信号自动分期方法，属于信号处理及模式识别领域。该方法具体包括：S1：选择数据，从睡眠数据库中选择不同通道的EEG信号以及EOG信号作为原始信号；S2：信号预处理，利用小波变换方法对原始两个通道的EEG和EOG信号分别进行预处理，选出训练集数据和测试集数据；S3：将预处理之后的信号输入深度学习分类模型中，利用深度学习算法对睡眠状态进行分期，并输出分期结果。本发明提高睡眠分期准确度，降低信号的信噪比，从而有效节省运算时间；并且通过优化算法实现准确度高的睡眠自动分期，为睡眠质量评估提供有效依据。

