

基于动态图卷积的自动睡眠分类

周荣昊, 宁晓军, 何远来, 王晶

(北京交通大学计算机与信息技术学院, 北京 100044)

摘要: 睡眠分期作为脑电研究的一大分支, 能够辅助医学专家进行睡眠状态的评估和睡眠障碍的诊断。在睡眠分期以往的研究中, 如何充分利用脑电中所包含的特征是提高睡眠分期准确率的关键。受脑电本身所具有的网络结构的启发, 本文使用图数据结构对脑电进行建模, 并且扩展了传统图卷积, 使其能够动态的学习脑电中存在的内在联系, 从而更有利于判别性的脑电特征提取。本文在 Montreal Archive of Sleep Studies 睡眠数据集上进行了大量实验, 实验结果表明我们的方法要明显优于基准方法, 达到了 87.04% 的分类准确率。该结果表明, 本文提出的动态图卷积方法能够明显提升睡眠分期的表现。

关键词: 脑电信号; 深度学习; 图卷积

中图分类号: TP391

Automatic sleep classification based on dynamic graph convolution

ZHOU Ronghao, NING Xiaojun, HE Yuanlai, WANG Jing

(School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044)

Abstract: As a major branch of EEG research, sleep stage classification can assist medical experts in the assessment of sleep status and the diagnosis of sleep disorders. In previous studies of sleep stage classification task, how to make full use of the features contained in the EEG is the key to improving the accuracy of sleep stage classification. Inspired by the network structure of the EEG itself, this paper models the EEG using graph data structure and extends the traditional graph convolutional, enabling it to dynamically learn the intrinsic connections that exist in the EEG, which is more conducive to discriminative EEG feature extraction. In this paper, a large number of experiments were conducted on the Montreal Archive of Sleep Studies sleep dataset, and the experimental results showed that our method was significantly better than the baseline method, achieving a classification accuracy of 87.04%. The results also show that the dynamic graph convolution proposed in this paper can significantly enhance the performance of sleep stage classification.

Key words: EEG; deep learning; graph convolution

0 引言

随着社会和科学技术的发展, 人们对于健康的需求愈加强烈, 而睡眠作为占用了一个人每日三分之一时间的生理活动对人的健康状态判断是极具意义的, 因此作为辅助睡眠状态诊断的睡眠分期就显得十分重要了。睡眠专家通过观察多导睡眠图(包含脑电信号, 心电信号, 肌电信号, 眼电信号等), 并且根据睡眠分期标准来对睡眠进行分期。主流的睡眠分期标准包括 Rechtschaffen and Kales(R&K)^[1]标准和 American Academy of Sleep Medicine (AASM)^[2]标准。尽管这些标准为睡眠分期提供了很有用的信息, 但是这仍旧需要睡眠专家花费大量的时间对睡眠数据进行分期和标签。

作者简介: 周荣昊(1998-), 男, 本科在读, 主要研究方向: 睡眠脑电信号的分析与挖掘

通信联系人: 王晶(1987-), 女, 副教授、博士生导师, 主要研究方向: 生理时间序列分析与挖掘. E-mail: wj@bjtu.edu.cn

为了减少这种不必要的人工花费并且随着机器学习的高速发展,自动睡眠分期成为了一个新兴的研究领域。许多的研究者们在该领域做出了贡献,首先是传统的机器学习方法,诸如支持向量机(SVM)^[3],随机森林(RF)^[4]等,这些方法往往依赖于大量领域知识。为了打破传统机器学习方法的限制,研究者们开始将深度学习应用于自动睡眠分期领域,例如卷积神经网络(CNN)^[5]和递归神经网络(RNN)^[6],端到端的特性可以让它们从原始数据中学习合适的特征表示。但是,这些深度学习的方法仍存在局限性——他们所需的数据都必须是网格数据,从而忽略了脑区之间存在的连接关系。

鉴于图卷积神经网络(GCN)^[7]在近期达成了许多突破,我们提出了动态图卷积神经网络,用于学习脑电中存在的内在连接关系并提取出判别性的脑电特征。动态图卷积相较于传统图卷积可以动态更新邻接矩阵,以学习到最适合当前情景的图结构。本文在 Montreal Archive of Sleep Studies (MASS)^[8]数据集上进行了大量实验,结果表明本文提出的方法实现了更好的结果。由此证明,我们的方法能够更好的完成睡眠分期任务。

1 数据集和数据预处理

1.1 数据集简述

本文所采用的数据集为 Montreal Archive of Sleep Studies (MASS)数据集的 SS3 部分,该部分数据集包含了 62 个健康人的多导睡眠图,每张多导睡眠图中都包含 20 导 EEG, 2 导 EOG, 3 导 EMG 和 1 导 ECG, 电极信息如表 1 所示。并且睡眠专家还依据 AASM 标准将多导睡眠图中的记录划分为 5 种睡眠阶段(W, N1, N2, N3 和 REM)。其中 W (Wake) 阶段表示清醒状态; N1-N3 统称为非快速眼动期(NREM), 分别表示清醒到睡眠的过渡期(N1), 占比最多的睡眠状态(N2), 深睡期(N3); REM 表示快速眼动期。

表 1 PSG 中的电极信息
Tab. 1 Electrode information of PSG

信号	电极
EEG	20 (BASE, Fp1, Fp2, Fz, Oz)
EOG	2 (left, right)
EMG	3 (chin)
ECG	1 (D-I)

注: BASE 包含电极: C3, C4, Cz, F3, F4, F7, F8, O1, O2, P3, P4, Pz, T3, T4, T5, T6。

1.2 数据预处理

MASS-SS3 所提供的数据已经经过一定的预处理,操作如表 2 所示。除了数据集本身自带的预处理之外,我们还对数据进行了一定的筛选,因为完整数据中是整晚睡眠图,所以包含了一部分的动作期数据,并且数据中还存在有极少部分的未知类别数据,为了减少数据中

存在的噪声，我们去除了这些无关部分。

表 2 MASS-SS3 数据集预处理
Tab. 2 Preprocessing of MASS-SS3 data set

信号	带通滤波器
EEG	0.30Hz-100Hz
EOG	0.10Hz -100Hz
ECG	0.10Hz -100Hz
EMG	10Hz -100Hz

1.3 特征提取

然后划分出 9 个交叉频带: 0.5-4Hz, 2-6Hz, 4-8Hz, 6-11Hz, 8-14Hz, 11-22Hz, 14-31Hz, 22-40Hz, 31-50Hz, 并且在每个频带中提取每个信号的微分熵(DE)特征。

$$DE = -\int_{-\infty}^{\infty} P(x) \ln(P(x)) dx \quad (1)$$

假设脑电信号服从高斯分布 $x \sim N(\mu, \sigma^2)$, DE 特征计算可简化为如下公式:

$$DE = -\int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \ln\left(\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)\right) dx = \frac{1}{2} \ln 2\pi e \sigma^2 \quad (2)$$

数据预处理的整体流程如图 1 所示。

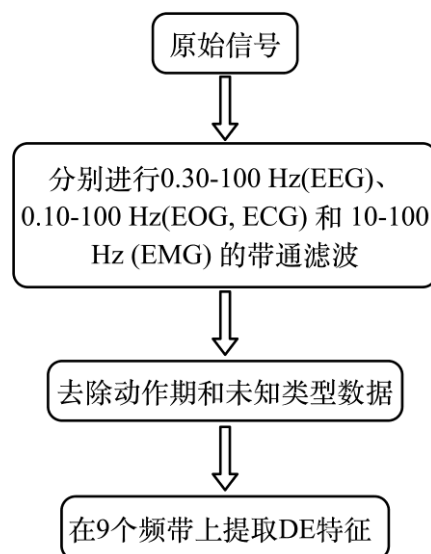


图 1 数据预处理流程图

Fig. 1 Data pre-processing flowchart

2 动态图卷积

为了充分利用脑电信号中存在的特征信息,我们在图数据结构的基础上应用了动态图卷积神经网络,具体流程如下:首先从原始数据中提取 DE^[9]特征,再将提取完成的 DE 特征输入到动态图卷积网络中提取判别性特征,然后通过全连接层输出分期结果,最后将预测结

果输入损失函数中，再通过反向传播的方式更新邻接矩阵。模型整体架构如图 2 所示。




图 2 动态图卷积模型整体结构

Fig. 2 The overall architecture of dynamic graph convolution

2.1 图卷积

本文使用了基于谱图理论的图卷积以提取输入数据中的空间信息，此外本文还利用 K 阶切比雪夫多项式简化后的图卷积^[10]以减少计算复杂度。简化后的图卷积公式如下：

$$g_{\theta} *_{\mathcal{G}} x = g_{\theta}(\mathbf{L})x = \sum_{k=0}^{K-1} \theta_k T_k(\tilde{\mathbf{L}})x \quad (3)$$

$$\mathbf{L} = \frac{2}{\lambda_{\max}} \mathbf{L} - \mathbf{I}_N \quad (4)$$

公式(1)中 g_{θ} 表示通过切比雪夫多项式近似展开简化后的卷积核，拉普拉斯矩阵 $\mathbf{L} = \mathbf{D} - \mathbf{A}$ ，其中 $\mathbf{D}, \mathbf{A} \in \mathbb{R}^{N \times N}$ 分别表示度矩阵和邻接矩阵， x 表示输入， $\theta \in \mathbb{R}^K$ 表示切比雪夫系数矩阵， λ_{\max} 表示拉普拉斯矩阵 \mathbf{L} 的最大特征值， \mathbf{I}_N 表示单位矩阵。 T_k 表示 K 阶切比雪夫多项式，其递归定义为： $T_0(x) = 1$ ， $T_1(x) = x$ ， $T_k(x) = 2xT_{k-1}(x) - T_{k-2}(x)$ 。

2.2 动态图卷积

在传统图卷积中，输入的邻接矩阵在训练过程中往往是初始存在或者根据领域知识手工

生成的，这会导致图卷积的学习能力受限，因为这些邻接矩阵往往会缺乏某些隐含信息，这些信息可能是目前的领域知识尚且无法解释和说明的。因此我们将传统图卷积扩展为动态图卷积，使模型能够动态的学习和更新邻接矩阵，以保证所邻接矩阵对当前问题的最适性。邻接矩阵的更新方式如下：

$$\mathbf{A}^{l+1} = (1 - \rho)\mathbf{A}^l + \rho \frac{\partial \mathcal{L}}{\partial \mathbf{A}^l} \quad (5)$$

其中 \mathbf{A}^l 表示第 l 层动态图卷积输出的邻接矩阵， ρ 为模型的学习率， \mathcal{L} 为损失函数。为了优化网络参数我们在用于多分类任务的交叉熵损失函数的基础上结合了一个正则项用于防止过拟合：

$$\mathcal{L} = \mathcal{L}_c + \lambda \|\theta\| \quad (6)$$

$$\mathcal{L}_c = -\frac{1}{L} \sum_{i=1}^L \sum_{r=1}^R y_{i,r} \log \hat{y}_{i,r} \quad (7)$$

$$\frac{\partial \mathcal{L}}{\partial \mathbf{A}^l} = \begin{pmatrix} \frac{\partial \mathcal{L}}{\partial A_{11}^l} & \cdots & \frac{\partial \mathcal{L}}{\partial A_{1n}^l} \\ \vdots & \ddots & \vdots \\ \frac{\partial \mathcal{L}}{\partial A_{n1}^l} & \cdots & \frac{\partial \mathcal{L}}{\partial A_{nn}^l} \end{pmatrix} \quad (8)$$

$$\frac{\partial \mathcal{L}}{\partial A_{ij}^l} = \frac{\mathcal{L}_c}{\partial \tilde{\mathbf{L}}} \cdot \frac{\partial \tilde{\mathbf{L}}}{\partial A_{ij}^l} + \lambda \frac{\partial \|\theta\|}{\partial A_{ij}^l} \quad (9)$$

其中 \mathcal{L}_c 表示用于优化多分类任务的交叉熵， $\lambda \|\theta\|$ 是用于防止过拟合的正则项， λ 表示正则系数， θ 表示模型的所有参数， L 表示样本数， R 表示分类时睡眠阶段的种类数， y 表示样本的真实标签， \hat{y} 表示模型的预测标签。

2.3 全连接层

在输入经过动态时空图卷积的处理后，将提取出的特征输入全连接层以将分布式的特征表示映射到样本标记空间。

$$\mathbf{X}' = \mathbf{W}\mathbf{X} + \mathbf{b} \quad (10)$$

其中 \mathbf{X} 表示全连接层的输入， \mathbf{W} 表示可学习权重矩阵， \mathbf{b} 表示偏置。最后再使用 softmax 函数对输出进行分类，得到睡眠分期的结果。

$$\hat{\mathbf{y}} = \text{softmax}(\mathbf{X}') \quad (11)$$

3 实验

3.1 实验设置

本文在 MASS-SS3 数据集上应用了 31 折交叉验证用于评估模型的表现，并且在数据集划分时采用受试者独立（每位受试者的数据在划分时都作为一个不可分割的整体）的方法来随机划分训练集和测试集，以提高模型的鲁棒性和泛化性，模型的详细的超参设置如表 3

130 所示。

表 3 实验超参数设置
Tab. 3 Experiment hyperparameter setting

超参数属性	值
动态图卷积的层数	1
图卷积的卷积核个数	10
切比雪夫多项式阶 K	3
正则参数	0.001
Dropout 概率	0.5
批量规模	64
训练轮数	50
学习率	0.001
优化器	Adam

3.2 评价指标

135 为了量化模型表现，我们采用了准确率（ACC）以及总体性指标 F1 分数（F1-score）
作为评估指标，公式如下：

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

$$F1 \text{ score} = \frac{2TP}{2TP + FP + FN} \quad (13)$$

140 其中 TP（True Positive）和 TN（True Negative）分别表示将正类预测为正类数和将负类预测为负类数，都表示预测正确；FP（False Positive）和 FN（False Negative）分别表示将负类预测为正类数和将正类预测为负类数，都表示预测错误。

3.3 基准方法

为了验证本文所提出的方法的有效性，我们将和传统机器学习方法和深度学习的方法进行对比：

- 145 ● 支持向量机(SVM)：其基本模型为定义在特征空间上的间隔最大的线性分类器，因此要区别于感知机，在加入核技巧后，支持向量机也能成为实质上的非线性分类器。
- 随机森林(RF)：其本质为多个决策树的集成，不同的决策树之间没有关联，在进行分类任务时，会让森林中的每一颗决策树进行判断和分类，最后对每个决策树的结果进行统计，决策树的分类结果中哪一个分类最多，那么这个分类就是最终结果。
- 150 ● 多层感知机和长短期记忆(MLP+LSTM)^[11]：该方法采用多层感知机提取层次特征，并且利用长短期记忆网络进行序列数据学习以优化分类结果。在睡眠分期任务中达到了较高的准确率。

3.4 实验结果

在 MASS 数据集上进行大量实验后, 其结果和基准方法的对比如表 4 所示。

表 4 基于 MASS 数据集的和基准方法的表现对比

Tab. 4 The performance comparison of the baseline approaches on the MASS dataset

方法	总体指标		每个睡眠阶段的 F1 分数				
	ACC	F1-score	Wake	N1	N2	N3	REM
SVM	0.797	0.750	0.786	0.487	0.861	0.825	0.792
RF	0.817	0.724	0.782	0.351	0.880	0.815	0.794
MLP+LSTM	0.859	0.805	0.846	0.563	0.907	0.848	0.848
DMGCN	0.870	0.820	0.896	0.569	0.907	0.834	0.895

从表 3 中可以发现, 传统机器学习的方法只能达到 0.80-0.81 的分类准确率, 但是深度学习的的方法能达到 0.86-0.87 的分类准确率, 深度学习的的方法的结果都要明显优于传统机器学习方法。而在深度学习的方法中, 我们的方法又要明显优于另一深度学习的基准方法, 这一结果表明本文所提出的动态图卷积神经网络提取判别性脑电特征的能力要优于一般的深度学习方法。

4 结论

在本文中, 我们提出了一种新的动态图神经网络用于自动睡眠分期任务。首先通过使用图数据结构对脑电进行建模, 并且应用动态图卷积使模型能够动态更新邻接矩阵, 以适应模型当前所对应的情景要求。从表 3 中可以看出, 本文所提出的动态图卷积神经网络对于睡眠分期任务有着更为优异的表现。

[参考文献] (References)

- [1] Wolpert E A. A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects[J]. Archives of General Psychiatry, 1969, 20(2): 246-247
- [2] Berry R B, Budhiraja R, Gottlieb D J, et al. Rules for scoring respiratory events in sleep: update of the 2007 AASM Manual for the Scoring of Sleep and Associated Events. Deliberations of the Sleep Apnea Definitions Task Force of the American Academy of Sleep Medicine[J]. J Clin Sleep Med. 2012, 8(5): 597-619
- [3] Alickovic E, Subasi A. Ensemble SVM method for automatic sleep stage classification[J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(6): 1258-1265.
- [4] Memar P, Faradji F. A novel multi-class EEG-based sleep stage classification system[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2017, 26(1): 84-95.
- [5] Zhang Junming, Wu Yan. A New Method for Automatic Sleep Stage Classification[J]. IEEE transactions on biomedical circuits and systems. 2017, 11(5): 1097-1110
- [6] Phan H, Andreotti F, Cooray N, et al. SeqSleepNet: end-to-end hierarchical recurrent neural network for sequence-to-sequence automatic sleep staging[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(3): 400-410
- [7] Bruna J, Zaremba W, Szlam A, et al. Spectral networks and locally connected networks on graphs[C/OL]. Proc of the 5th Int Conf on learning Representations (ICLR), 2014, <https://iclr.cc/archive/2014/conference-proceedings>
- [8] O'reilly C, Gosselin N, Carrier J, et al. Montreal Archive of Sleep Studies: an open-access resource for instrument benchmarking and exploratory research[J]. Journal of sleep research, 2014, 23(6): 628-635
- [9] Hyvärinen A. New approximations of differential entropy for independent component analysis and projection pursuit [C]. Advances in neural information processing systems. Cambridge, Massachusetts: MIT Press, 1998: 273-279
- [10] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks[C/OL]. Proc of the 5th Int Conf on learning Representations (ICLR). 2017, <https://openreview.net/pdf?id=SJU4ayYgl>
- [11] Dong H, Supratak A, Pan W, et al. Mixed Neural Network Approach for Temporal Sleep Stage

Classification[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering. 2018, 26(2): 324-333