

基于深度卷积神经网络的多元医学信号多级上下文自编码器

袁野 贾克斌* 刘鹏宇

^①(北京工业大学信息学部 北京 100124)

^②(北京工业大学计算智能与智能系统北京重点实验室 北京 100124)

摘要: 多元医学信号的典型代表有多模态睡眠图和多通道脑电图等,采用无监督深度学习表征多元医学信号是目前健康信息学领域中的一个研究热点。为了解决现有模型没有充分结合医学信号多元时序结构特点的问题,该文提出了一种无监督的多级上下文深度卷积自编码器(mCtx-CAE)。首先改进传统卷积神经网络结构,提出一种多元卷积自编码模块,以提取信号片段内的多元上下文特征;其次,提出采用语义学习技术对信号片段间的时序信息进行自编码,进一步提取时序上下文特征;最后通过共享特征表示设计目标函数,训练端到端的多级上下文自编码器。实验结果表明,该文所提模型在两种应用于不同医疗场景下的多模态和多通道数据集(UCD和CHB-MIT)上表现均优于其它无监督特征学习方法,能有效提高多元医学信号的融合特征表达能力,对提高临床时序数据的分析效率有着重要意义。

关键词: 多元医学信号; 自编码器; 上下文学习; 卷积神经网络; 深度学习

中图分类号: TP391.4

文献标识码: A

文章编号: 1009-5896(2020)02-0371-08

DOI: [10.11999/JEIT190135](https://doi.org/10.11999/JEIT190135)

Multi-context Autoencoders for Multivariate Medical Signals Based on Deep Convolutional Neural Networks

YUAN Ye JIA Kebin LIU Pengyu

^①(Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China)

^②(Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing University of Technology, Beijing 100124, China)

Abstract: Learning unsupervised representations from multivariate medical signals, such as multi-modality polysomnography and multi-channel electroencephalogram, has gained increasing attention in health informatics. In order to solve the problem that the existing models do not fully incorporate the characteristics of the multivariate-temporal structure of medical signals, an unsupervised multi-Context deep Convolutional AutoEncoder (mCtx-CAE) is proposed in this paper. Firstly, by modifying traditional convolutional neural networks, a multivariate convolutional autoencoder is proposed to extract multivariate context features within signal segments. Secondly, semantic learning is adopted to auto-encode temporal information among signal segments, to further extract temporal context features. Finally, an end-to-end multi-context autoencoder is trained by designing objective function based on shared feature representation. Experimental results conducted on two public benchmark datasets (UCD and CHB-MIT) show that the proposed model outperforms the state-of-the-art unsupervised feature learning methods in different medical tasks, demonstrating the effectiveness of the learned fusional features in clinical settings.

Key words: Multivariate medical signals; Autoencoders; Context learning; Convolutional neural networks; Deep learning

收稿日期: 2019-03-07; 改回日期: 2019-08-17; 网络出版: 2019-08-28

*通信作者: 贾克斌 kebinj@bjut.edu.cn

基金项目: 国家自然科学基金(81871394), 先进信息网络北京实验室基金(040000546618017)

Foundation Items: The National Natural Science Foundation of China (81871394), The Beijing Laboratory of Advanced Information Networks Foundation (040000546618017)

1 引言

随着医疗采集设备的普及与信息化的迅猛发展,多元医学信号可由多传感器同时采集并持续反映人体不同部位的体征信息,以辅助医生实现健康监测和疾病诊断,其高效的特征表示技术是当前需求迫切并具有重要应用前景的研究课题^[1,2]。在生物医学信息领域,多元医学信号可根据数据类型分为多模态信号和具有单模态的多通道信号,在临床医疗中得到了广泛地应用。例如,医生通过多模态睡眠图(PolySomnoGraphy, PSG)监控患者的心电图、脑电图(ElectroEncephaloGram, EEG)、肌电图等生理信号,并对其睡眠质量进行综合判断^[3]。再者,多通道EEG可同时记录不同脑区域的电生理活动,是实现癫痫检测^[4]、精神分裂症诊断^[5]以及情绪识别^[6]的有效途径。综上所述,多元医学信号的特征表示模型主要分为监督模型和无监督模型两种。由于在实际情况中医生需要花费大量时间对种类繁多的冗长波形数据进行专业分析,很难获得充足的标注数据训练监督模型。故本文重点研究基于无监督学习的多元医学信号特征表示模型。

目前,国内外学者已提出多种无监督特征表示模型用来提取多元医学信号中的有效信息,这些模型大致可分为两类:人工表示模型和深度学习模型^[7]。一方面,许多信号处理和数据降维方法被广泛引入人工表示模型中,用来提取医学信号的时域特征和频域特征^[8]。另一方面,通过构建多层神经网络,一些深度学习技术被用来从原始非标注数据中直接学习医学信号的抽象表征,主要包括基于栈式自编码器(Stacked AutoEncoders, SAE)^[9-16]和基于深度置信网络^[17-19]的特征学习模型。与人工表示模型相比,数据驱动深度学习模型具有更好的特征泛化能力,因此受到广泛关注。尽管基于深度学习的特征表示模型可以在减少人工干预的同时抽象表达医学信号中的复杂表示,但目前其研究还没有充分地结合医学信号多元时序的结构特点。首先,大多数深度学习模型通常将波形信号切割成长度相同的时间片段进行独立训练^[9-12,17-19],没有考虑波形片段间的时序相关性,这将会损失一部分动态语义信息。其次,一些模型没有明确地将信号的多元相关性纳入目标函数中^[13-15],忽略了信号片段内的元间上下联系。文献^[16]提出了一种基于SAE的多特征融合模型提取医学信号不同层面的特征,但该模型中的各特征学习模块是单独训练的,在训练过程中无法协同各模块进行参数联调,并非端到端的深度学习模型。

为了解决上述问题,本文提出一种端到端的多

级上下文深度卷积自编码器(mCtx-CAE),以无监督方式协同提取医学信号中的多元时序信息。首先,根据信号的多元结构特点,提出一种多元卷积自编码模块提取信号片段内的多元上下文特征;其次,引入语义学习技术,基于多元编码进一步提取信号片段间的时序上下文特征;最后,通过神经网络设计统一的目标函数,共享表征医学信号的多元时序信息,训练端到端的多级上下文自编码器。本文使用两种应用在不同医疗场景下的多模态PSG数据集和多通道EEG数据集来验证模型的有效性。通过对比7种常用的无监督特征表示模型,实验结果表明本文方法整体优于目前在医学领域主流的基准比较方法,是一种有效融合多元时序特征的多元医学信号无监督深度学习模型。本文剩余部分的结构安排如下:第2节介绍所提出的多级上下文深度卷积自编码器;第3节给出并分析本文模型在UCD和CHB-MIT数据集上的对比实验结果;第4节总结本文工作内容。

2 多级上下文深度卷积自编码器

为充分结合医学信号多元时序结构特点,本文提出一种基于卷积神经网络的多级上下文自编码器,通过无监督端到端训练同时学习医学信号的多元和时序信息,其网络结构如图1所示。具体而言,给定 C 元信号时间片段 $\mathbf{X}_t = \{\mathbf{x}_{t1}, \mathbf{x}_{t2}, \dots, \mathbf{x}_{tC}\}$,其中 \mathbf{x}_{tc} 表示第 c 元信号时间片段,首先提出多元上下文特征自编码模块,通过考虑信号元内和元间信息学习多元特征编码 \mathbf{s}_t ,该模块分别由元内卷积-池化层、元间卷积-池化层、及其相应的反卷积-池化层构建而成。随后,提出时序上下文特征自编码

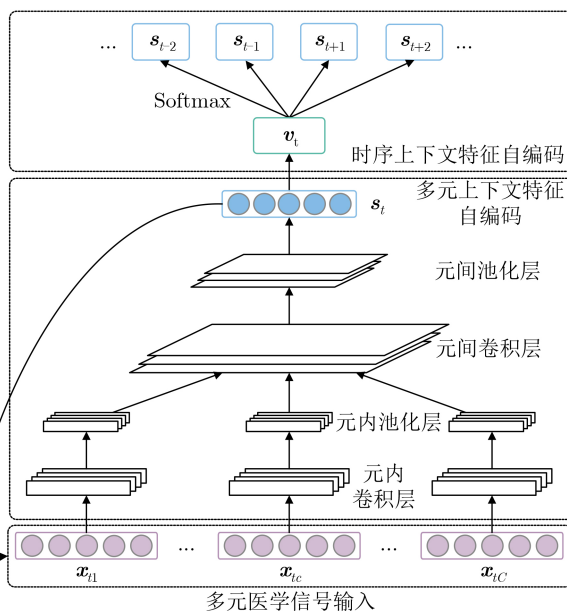


图1 本文提出的多级上下文深度卷积自编码器结构图

块，通过临近时序推断进一步学习时序嵌入特征编码 v_t 。最后，提出结合多元重构误差和嵌入误差共同训练神经网络，建立端到端的多级上下文深度卷积自编码器。

2.1 多元上下文特征自编码

在基于深度学习的多元医学信号特征表示任务中，单独学习各元信号片的特征或统一学习级联信号片的特征会忽略各元信号间的内部联系。为了充分利用医学信号的多元结构信息，本文通过改进卷积自编码器(Convolutional AutoEncoders, CAE)^[20]的神经网络结构，提出多元卷积自编码模块，鼓励模型从不同角度学习多元信号时间片段的上下文特性，即多元上下文特征。一般而言，CAE属于无监督的局部连接神经网络，由一个具有多卷积核的编码器和一个具有多反卷积核的解码器函数组合而成。与全连接的SAE^[21]相比，CAE在重建输入时会考虑更多的细节信息，因此更适用于多元特性的表征。对于本文的多元数据结构，模型首先对各元信号输入 $\mathbf{x}_{tc} \in \mathbb{R}^{n_c}$ 进行多核卷积编码，提取元内深度卷积特征，其中由第 k 个卷积核编码出的元内特征 \mathbf{h}_{tc}^k 可表示为

$$\mathbf{h}_{tc}^k = f(\mathbf{x}_{tc} * \mathbf{W}_c^k + \mathbf{b}_c^k) \quad (1)$$

其中， $*$ 表示卷积运算， \mathbf{W}_c^k 和 \mathbf{b}_c^k 表示第 k 个卷积核的可学习参数， $f(\cdot)$ 表示非线性变换函数。经过元内卷积层得到的卷积结果经由池化层下采样后进行元间堆叠，得到通道内特征矩阵 \mathbf{H}_t^k 。通过这种方式，各元信号的独特性会被保留下来，并映射到统一的维度空间中。对于所有卷积核的元内特征矩阵 $\{\mathbf{H}_t^1, \mathbf{H}_t^k, \dots, \mathbf{H}_t^K\}$ ，本模型对其进行进一步卷积编码，提取多元信号的元间卷积特征

$$\mathbf{s}_t^l = f\left(\sum_{k=1}^K \mathbf{H}_t^k * \mathbf{W}_{gk}^l + \mathbf{b}_g^l\right) \quad (2)$$

其中， \mathbf{W}_{gk}^l 和 \mathbf{b}_g^l 表示第 l 个卷积核的可学习参数， \mathbf{s}_t^l 表示第 l 个卷积核的元间编码结果。同样地，经过元间卷积操作得到的卷积结果经由池化层下采样后进行特征核串联，最终得到向量 $\mathbf{s}_t \in \mathbb{R}^p$ ，它表示多元医学信号在相同时间片段下的多元上下文特征编码。

对于解码器，本模型通过构建对应的反卷积函数将编码向量 \mathbf{s}_t 重建为原始输入 $\hat{\mathbf{X}}_t = \{\hat{\mathbf{x}}_{t1}, \hat{\mathbf{x}}_{t2}, \dots, \hat{\mathbf{x}}_{tC}\}$ ：

$$\hat{\mathbf{H}}_t^k = f\left(\sum_{l \in \chi_g} \mathbf{s}_t^l * \tilde{\mathbf{W}}_{gk}^l + \mathbf{c}_g^l\right) \quad (3)$$

$$\hat{\mathbf{x}}_{tc} = f\left(\sum_{k \in \chi_c} \hat{\mathbf{H}}_{tc}^k * \tilde{\mathbf{W}}_c^k + \mathbf{c}_c^k\right) \quad (4)$$

其中， $\tilde{\mathbf{W}}_{gk}^l$ ， $\tilde{\mathbf{W}}_c^k$ ， \mathbf{c}_g^l 和 \mathbf{c}_c^k 为相应反卷积核的可学习参数。多元卷积自编码模块的训练目标为最小化输入信号时间片段的多元重构误差。给定无标注训练样本集合 $\{\mathbf{X}_t, t = 1, 2, \dots, T\}$ ，其成本函数 J_{SC} 可用基于交叉熵的重构误差表示为

$$J_{SC} = -\frac{1}{T} \sum_{t=1}^T \sum_{c=1}^C \left[\mathbf{x}_{tc} \ln(\hat{\mathbf{x}}_{tc}) + (\mathbf{1} - \mathbf{x}_{tc}) \ln(\mathbf{1} - \hat{\mathbf{x}}_{tc}) \right] \quad (5)$$

2.2 时序上下文特征自编码

为了考虑多元医学信号的时序相关性，本文提出采用语义学习技术对信号片段间的时序信息进行自编码。其主要思路是根据当前片段的多元特征编码推断它在时序上的前后邻居片段。通过这种方式学习临近片段出现的概率，会让具有相似语义的信号在新向量空间中映射到相近的位置，以提取时序上下文特征。虽然基于文本语义模型的特征表示算法可以学习时序上下文特征，如Skip-gram^[22]和Med2Vec^[23]，但对于医学信号这种连续波形数据，无法预先建立完备的语料库对时序波形片段进行one-hot初始化表达。为此，本模型使用由多元卷积自编码模块提取的多元特征 \mathbf{s}_t 隐式表达初始编码，并学习其嵌入向量 $\mathbf{v}_t \in \mathbb{R}^q$ 表示多元医学信号的时序上下文特征编码，如式(6)

$$\mathbf{v}_t = f(\mathbf{W}_v \mathbf{s}_t + \mathbf{b}_v) \quad (6)$$

其中， \mathbf{W}_v 和 \mathbf{b}_v 分别为可学习的权值矩阵和偏置向量。之后通过训练一个Softmax解码器来预测当前时序窗口内的邻居片段。给定嵌入向量集合 $\{\mathbf{v}_t, t = 1, 2, \dots, T\}$ ，使用基于交叉熵的嵌入误差描述时序上下文特征自编码器的成本函数 J_{TC} ，如式(7)

$$J_{TC} = -\frac{1}{T} \sum_{t=1}^T \sum_{\substack{-w \leq i \leq w, \\ i \neq 0}} \left[s_{t+i}^T \ln(\hat{y}_t) + (1 - s_{t+i})^T \ln(\mathbf{1} - \hat{y}_t) \right] \quad (7)$$

其中，

$$\hat{y}_t = \frac{\exp(\mathbf{W}_s \mathbf{v}_t + \mathbf{b}_s)}{\sum_{j=1}^n \exp(\mathbf{W}_s[j, :] + \mathbf{b}_s[j])} \quad (8)$$

其中， \mathbf{W}_s 和 \mathbf{b}_s 是可学习的参数，这里 $\exp(\cdot)$ 是元素指数函数， w 是预定义的时序上下文窗口大小。

2.3 端到端的多级上下文模型训练

为了共同训练端到端的多级上下文自编码器，本文通过共享特征表示设计目标函数，以构建统一

的无监督深度神经网络，在减少信息损失的同时协同学习多元医学信号的多元时序上下文特征。给定无标注训练样本集合，本文提出的多级上下文深度卷积自编码器的成本函数 J_{mCtx} ，在可学参数集 $\{\mathbf{W}_{c,g,v,s}, \mathbf{b}_{c,g,v,s}\}$ 下可定义为

$$\begin{aligned}
 & J_{\text{mCtx}}(\mathbf{W}_{c,g,v,s}, \mathbf{b}_{c,g,v,s}) \\
 &= \frac{1}{T} \sum_{t=1}^T \left\{ -\beta_1 \sum_{c=1}^C [\mathbf{x}_{tc} \ln(\widehat{\mathbf{x}}_{tc}) \right. \\
 &\quad \left. + (\mathbf{1} - \mathbf{x}_{tc}) \ln(\mathbf{1} - \widehat{\mathbf{x}}_{tc}) \right] + \beta_2 \sum_{-w \leq i \leq w, i \neq 0} \\
 &\quad \left[-\mathbf{s}_{t+i}^T \ln(\widehat{\mathbf{y}}_t) - (\mathbf{1} - \mathbf{s}_{t+i}^T)^T \ln(\mathbf{1} - \widehat{\mathbf{y}}_t) \right] \\
 &\quad \left. + \sum_j \text{KL}(\rho_j \| \widehat{\rho}_j) \right\} \quad (9)
 \end{aligned}$$

其中， β_1 和 β_2 是控制每个成本函数贡献的权值。式(9)中的第3项是基于KL散度的稀疏惩罚项，通过抑制模型中神经元的平均活跃度 $\widehat{\rho}_j$ 诱导编码 \mathbf{s}_i 稀疏化从而近似one-hot表达，另外还可以有效抵抗波形数据带来的输入扰动。通过这种方式，医学信号的多元时序信息可以在多级上下文特征学习中得到参数共享，这种互补形式的端到端训练模式可以提高多元时序信息的利用率，并提升融合特征的表达能力。

3 实验与结果讨论

3.1 实验数据与实验说明

本文分别在CHB-MIT^[24]和UCD^[25]两种应用在不同医疗场景下的公开数据库上对所提出的多级上下文深度卷积自编码器进行验证。其中CHB-MIT是波士顿儿童医院建立的多通道EEG数据库，用于癫痫检测任务。该数据集包含23个256 Hz的EEG通道，用来监测不同脑区域的神经活动。所有癫痫发作事件均由医学手动标记(癫痫或正常)。基于已有文献[4,13,16]中采用的预处理经验，本实验对所有研究对象的记录数据进行分割，生成了256,862个波形向量作为模型输入。其中窗口长度和步长分别被设置为3 s和1 s。UCD数据库收集于圣文森特大学医院和都柏林大学，用于睡眠阶段分类任务。该数据为多模态PSG信号，包括128 Hz EEG, 64 Hz眼电图, 64 Hz肌电图等14项体征波形数据。根据R&K(Rechtschaffen and Kales, R&K)标准，每30 s的睡眠记录被专家标记为5种睡眠阶段之一：清醒、快速眼动、睡眠阶段1、睡眠阶段2和睡眠阶段3。本实验从所有研究对象数据中生成287,840个30 s波形向量。

由于所提出的模型为无监督方法，本文选取了7种目前在医学领域内主流的特征表示模型作为比较方法。其中PCA为经典的人工特征降维算法，CAE^[20]和SAE^[21]是被广泛应用的深度自编码器，Skip-gram^[22]和Med2Vec^[23]为目前主流的嵌入模型。在此，本文直接用原始数据训练Med2Vec模型，而对于Skip-gram+模型，先使用文献[13]中的方法学习基于SAE的信号字典，再用Skip-gram模型进一步学习嵌入特征。Wave2Vec^[14]和CtxFusionEEG^[15]是领域内最新的针对多元医学信号的无监督特征学习模型。对于实验结果的验证，本文对不同无监督模型提取相同维度 q 的特征向量，并用学习到的特征训练标准SVM分类器。由于在医学领域中，疾病的发生可被视为罕见事件，即数据具有非均衡属性，因此本文用准确率(Accuracy)和F1分数(F1-score)验证算法的分类结果与标注的一致性。上述衡量指标的计算方法为

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (10)$$

$$\text{F1-score} = \frac{2 \times \text{Prec} \times \text{Rec}}{\text{Prec} + \text{Rec}} \quad (11)$$

其中，TP, FN, TN和FP分别代表真阳性、假阴性、真阴性和假阳性， $\text{Prec} = \text{TP}/(\text{TP} + \text{FP})$ 表示精确率， $\text{Rec} = \text{TP}/(\text{TP} + \text{FN})$ 表示召回率。由式(11)可以看出，F1分数是精确率和召回率的调和平均，数值上接近两者中的较小值。当F1分数高时，说明精确率和召回率都较高。

另外，本文还绘制了ROC曲线和PR曲线，如图2所示。并计算其曲线下方的总面积AUC-ROC和AUC-PR，来观察模型的稳定性。一方面，ROC曲线表现了正阳率和假阳率的权衡关系，曲线越靠近左上角，其线下面积越大，说明模型的整体表现越好。由于ROC曲线的两个指标均不依赖于数据具体的类别分布^[26]，故适用于评估模型在非均衡数据下的整体性能。另一方面，PR曲线表现了召回率和精确率的权衡关系，曲线越靠近右上角，其线下面积越大，说明模型的整体表现越好。对于数据不平衡问题，本文主要关注模型对正例(即罕见事件)的分类表现，由于PR曲线的两个指标都聚焦正例^[27,28]，故适用于评估模型对罕见事件的分类性能。

对于实验中模型实现的细节，本文设置 $p = 256$, $q = 128$ 作为默认超参数，表1为所提出的多元卷积自编码模块的具体配置参数。在此，元间编解码单元的卷积核参数被设置为元数 C ，以避免多元数据的排列关系对模型带来影响。本文基于PyTorch实现所有深度学习方法，并使用NVIDIA Titan Xp

GPU加速训练速度。在模型训练中使用Adadelta算法^[29]进行参数优化,并使用权值衰减、动量和Dropout优化技术避免模型过学习。非线性激活函数使用ReLU函数。为客观评估模型特征的学习性能,本文所有实验采用5折对象独立交叉验证方法(5-Fold Subject-Independent Cross Validation),并给出衡量指标的平均值和方差。训练、验证和测试集的比例为7:1:2。

3.2 结果分析与讨论

表2和表3列出了本文所提出的多级上下文深度卷积自编码器(mCtx-CAE)在两个数据库上的对比实验结果。本文还实现了一个简化模型m-CAE,该模型只包括所提出的多元卷积自编码模块部分。由表2和表3可知,所提出的mCtx-CAE模型整体性能在两个数据库上均优于基线,综合指标优于其他比较算法。具体来看,经典的PCA算法在两个任务中表现优于标准SAE和CAE深度自编码模型。一个合理的解释是,多元医学信号波形分辨率较高,原始特征在串联后输入维度较大,使得这种数据驱动的神经网络在梯度下降训练时很难找到全局最小点。而PCA通过奇异值分解能选择更合适的主成分作为特征向量。对于嵌入算法,Med2Vec模

型的准确率低于其它方法。这是因为连续波形数据不适合被直接输入到离散的嵌入模型中,导致Med2Vec模型很难从连续信号中提取到有效的时序信息。Skip-gram+模型采用基于SAE的人工词表示策略作为预处理步骤,有效降低了信号的波形扰动,能更好地学习时序特征。最新的CtxFusion-EEG和Wave2Vec模型的结果优于其他比较算法。相较于多阶段训练的CtxFusionEEG模型而言,端到端的Wave2Vec模型在两个数据库上表现更加理想,这是由于多阶段模型里的各特征提取模块在训练过程中不能共享参数进行联调,从而降低了对多元医学信号的融合表征能力。

通过比较本文模型与其它特征表示方法,m-CAE简化模型的实验结果略优于其他比较模型,说明在

表1 多元卷积自编码模块具体配置参数

编码单元	卷积层	非线性变换	池化层
元内编码单元	$1 \times 3 \times 16$	ReLU	1×2
元间编码单元	$C \times 3 \times 8$	ReLU	1×2
解码单元	反卷积层	非线性变换	反池化层
元间解码单元	$C \times 3 \times 8$	ReLU	1×2
元内解码单元	$1 \times 3 \times 16$	ReLU	1×2

表2 CHB-MIT数据库上的方法比较结果

方法	AUC-ROC	AUC-PR	F1分子	准确率
PCA	0.8291 ± 0.0434	0.7021 ± 0.0872	0.6421 ± 0.0223	0.8768 ± 0.0223
SAE	0.5934 ± 0.0377	0.4180 ± 0.1189	0.0668 ± 0.0415	0.7987 ± 0.0309
CAE	0.8657 ± 0.0305	0.7646 ± 0.0881	0.6277 ± 0.1246	0.8690 ± 0.0267
Med2Vec	0.8155 ± 0.1181	0.5870 ± 0.1670	0.6066 ± 0.2363	0.8351 ± 0.0359
Skip-gram+	0.9090 ± 0.0356	0.7467 ± 0.1540	0.6288 ± 0.2040	0.8898 ± 0.0173
CtxFusionEEG	0.9287 ± 0.0306	0.7833 ± 0.1147	0.7202 ± 0.1485	0.9025 ± 0.0104
Wave2Vec	0.9035 ± 0.0371	0.8839 ± 0.0261	0.8267 ± 0.0184	0.9210 ± 0.0099
m-CAE	0.8946 ± 0.0401	0.8727 ± 0.0189	0.8417 ± 0.0131	0.9324 ± 0.0058
mCtx-CAE	0.9372 ± 0.0495	0.8980 ± 0.0333	0.8493 ± 0.0191	0.9412 ± 0.0110

表3 UCD数据库上的方法比较结果

方法	AUC-ROC	AUC-PR	F1分数	准确率
PCA	0.8177 ± 0.0142	0.5764 ± 0.0172	0.5204 ± 0.0275	0.6193 ± 0.0638
SAE	0.7068 ± 0.1372	0.4965 ± 0.0951	0.2760 ± 0.1815	0.4917 ± 0.1364
CAE	0.8386 ± 0.0376	0.5710 ± 0.0429	0.5180 ± 0.0701	0.6208 ± 0.0961
Med2Vec	0.7479 ± 0.0796	0.4836 ± 0.1046	0.3997 ± 0.1361	0.5619 ± 0.0619
Skip-gram+	0.8010 ± 0.0992	0.5406 ± 0.0995	0.4342 ± 0.1731	0.5884 ± 0.1077
CtxFusionEEG	0.7941 ± 0.1485	0.6358 ± 0.0709	0.5171 ± 0.1994	0.6375 ± 0.1074
Wave2Vec	0.8161 ± 0.0507	0.5984 ± 0.0698	0.5268 ± 0.0661	0.6408 ± 0.0723
m-CAE	0.8446 ± 0.0361	0.5727 ± 0.0215	0.5600 ± 0.0482	0.6562 ± 0.0767
mCtx-CAE	0.8648 ± 0.0258	0.6423 ± 0.0452	0.5655 ± 0.0228	0.6734 ± 0.0562

考虑多元信号间的相关性后,改进的多元卷积自编码模块可以通过优化重建误差学习到具有多元上下文特性的深度特征,从而提高实验结果。在进一步结合时序上下文特征后, mCtx-CAE模型的实验结果要明显优于其它算法。图2展示了不同特征学习模型在CHB-MIT和UCD数据库上的ROC曲线和PR曲线。结合表1和表2可以看出,本文提出的mCtx-CAE模型获得了最高的AUC-PR和AUC-ROC。这再次说明了多级上下文深度卷积自编码器的优势。从图2(b)中可以明显看出, mCtx-CAE模型的真阳率从一开始就快速增加,整体靠近(0,1)点。说明mCtx-CAE模型可以抓取有效分离数据的关键信息,从而获得最佳的F1分数和准确度。

为了进一步评估mCtx-CAE模型的性能,本文通过敏感性分析研究超参数配置对模型的影响。具体来说,研究了3个主要方面:多元上下文特征维度 p ,时序上下文特征维度 q 和时序上下文窗口大小 w ,并使用不同的超参数设置绘制准确率结果曲线。本实验中所有模型的配置是 $p = 256, q = 128, w = 1$ 。在每个步骤中,改变1个超参数,同时保持其它超参数不变。图3和图4展示了mCtx-CAE, Wave2Vec和CtxFusionEEG 3个模型分别在CHB-MIT和UCD数据库上针对不同超参数的准确率变化曲线。从图中可知,一方面,当 p 和 q 维度较小时,所有模型均很难提取足够丰富的特征,从而导致准确率下降。另一方面,当 p 和 q 维度过大时,模型没有足够




图2 不同特征表示模型在CHB-MIT和UCD数据库上的ROC和PR曲线

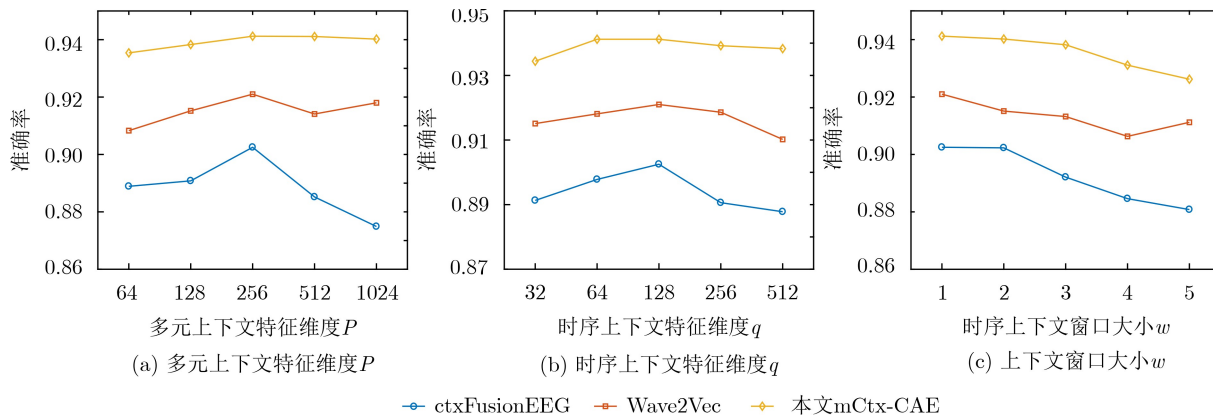


图3 不同特征学习模型在CHB-MIT数据库上对不同超参数配置的影响

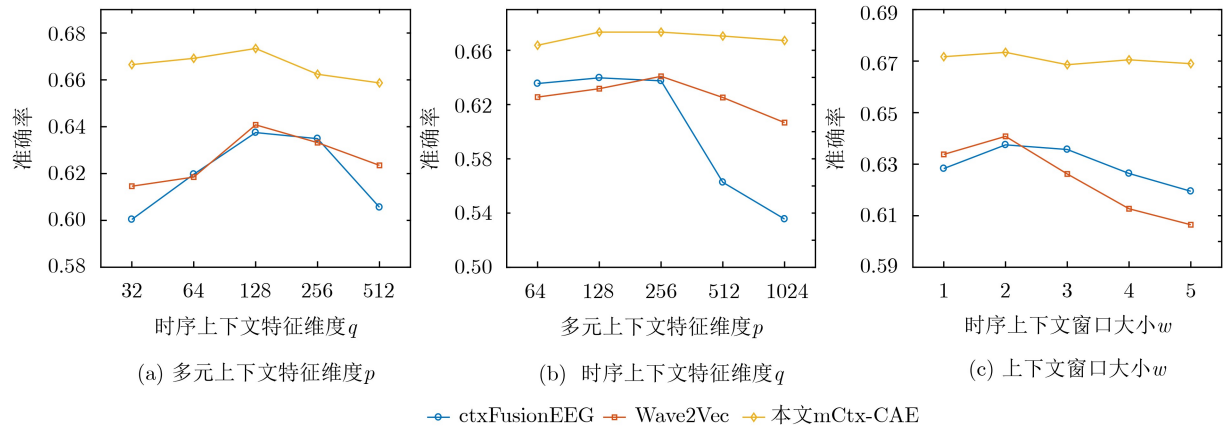


图4 不同特征学习模型在UCD数据库上对不同超参数配置对的影响

的样本来训练大容量网络，也会导致准确率降低。在实验中，当 $p=256, q=128$ 时，所提出的模型性能达到最佳。对于时序上下文窗口大小 w ，增加窗口大小会降低模型准确率，因为它会导致模型过拟合。从图3(c)和图4(c)中可以看出，模型分别在 $w=1$ 和 $w=2$ 时在CHB-MIT和UCD数据库上达到最佳性能，这是由于不同特征学习任务对时序上下文的依赖程度不同。通过对比不同方法，本文提出的mCtx-CAE模型相较于其它模型而言对超参数的选择不太敏感，具有更好的模型泛化能力。

综上所述，本文所提出的mCtx-CAE模型对多元医学信号的特征表示效果提高显著。多元时序信息在无监督的多元医学信号表征模型中发挥着重要作用，这种端到端的共享学习策略为多特征融合提供了互补信息，从而提升多元医学信号联合特征的表达能力。

4 结束语

本文提出了一种针对多元医学信号的无监督多级上下文深度卷积自编码器。该模型的贡献在于结合医学信号多元时序结构特点，改进传统卷积神经网络结构，并引入语义学习技术共享参数进行端到端无监督训练，学习融合信号多元时序信息的特征表示。实验结果显示，本文模型在两种应用在不同医疗场景下的公开数据库上表现均优于其他无监督特征学习模型，对提高临床时序数据分析效率有着重要意义。mCtx-CAE模型虽然是针对多元医学信号提出的深度自编码器，但该方法可扩展至具有相似数据结构的其它多元时序任务中，是一种有效的无监督多特征融合模型。

参考文献

- [1] JOHNSON A E W, GHASSEMI M M, NEMATY S, *et al.* Machine learning and decision support in critical care[J]. *Proceedings of the IEEE*, 2016, 104(2): 444–466. doi: 10.1109/JPROC.2015.2501978.
- [2] RAVI D, WONG C, DELIGIANNI F, *et al.* Deep learning for health informatics[J]. *IEEE Journal of Biomedical and Health Informatics*, 2017, 21(1): 4–21. doi: 10.1109/JBHI.2016.2636665.
- [3] BOOSTANI R, KARIMZADEH F, and NAMI M. A comparative review on sleep stage classification methods in patients and healthy individuals[J]. *Computer Methods and Programs in Biomedicine*, 2017, 140: 77–91. doi: 10.1016/j.cmpb.2016.12.004.
- [4] YUAN Ye, XUN Guangxu, JIA Kebin, *et al.* A multi-view deep learning framework for EEG seizure detection[J]. *IEEE Journal of Biomedical and Health Informatics*, 2019, 23(1): 83–94. doi: 10.1109/JBHI.2018.2871678.
- [5] ACAR E, LEVIN-SCHWARTZ Y, CALHOUN V D, *et al.* Tensor-based fusion of EEG and fMRI to understand neurological changes in schizophrenia[C]. 2017 IEEE International Symposium on Circuits and Systems, Baltimore, USA, 2017: 1–4.
- [6] JIA Xiaowei, LI Kang, LI Xiaoyi, *et al.* A novel semi-supervised deep learning framework for affective state recognition on EEG signals[C]. 2014 IEEE International Conference on Bioinformatics and Bioengineering, Boca Raton, USA, 2014: 30–37.
- [7] LÄNGKVIST M, KARLSSON L, and LOUFI A. A review of unsupervised feature learning and deep learning for time-series modeling[J]. *Pattern Recognition Letters*, 2014, 42: 11–24. doi: 10.1016/j.patrec.2014.01.008.
- [8] HOLZINGER A. *Machine Learning for Health Informatics*[M]. Cham: Springer, 2016: 161–182.
- [9] SUPRATAK A, LI Ling, and GUO Yike. Feature extraction with stacked autoencoders for epileptic seizure detection[C]. The 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Chicago, USA, 2014: 4184–4187.

- [10] YAN Bo, WANG Yong, LI Yuheng, *et al.* An EEG signal classification method based on sparse auto-encoders and support vector machine[C]. 2016 IEEE/CIC International Conference on Communications in China, Chengdu, China, 2016: 1–6.
- [11] LIN Qin, YE Shuqun, HUANG Xiumei, *et al.* Classification of epileptic EEG signals with stacked sparse autoencoder based on deep learning[C]. The 12th International Conference on Intelligent Computing, Lanzhou, China, 2016: 802–810.
- [12] YANG Jianli, BAI Yang, LI Guojun, *et al.* A novel method of diagnosing premature ventricular contraction based on sparse auto-encoder and softmax regression[J]. *Bio-medical Materials and Engineering*, 2015, 26(S1): S1549–S1558. doi: [10.3233/BME-151454](https://doi.org/10.3233/BME-151454).
- [13] XUN Guangxu, JIA Xiaowei, and ZHANG Aidong. Detecting epileptic seizures with electroencephalogram via a context-learning model[J]. *BMC Medical Informatics and Decision Making*, 2016, 16(Suppl 2): 70. doi: [10.1186/s12911-016-0310-7](https://doi.org/10.1186/s12911-016-0310-7).
- [14] LI Xiaoyi, JIA Xiaowei, XUN Guangxu, *et al.* Improving EEG feature learning via synchronized facial video[C]. 2015 IEEE International Conference on Big Data, Santa Clara, USA, 2015: 843–848.
- [15] YUAN Ye, XUN Guangxu, SUO Qiuling, *et al.* Wave2Vec: Deep representation learning for clinical temporal data[J]. *Neurocomputing*, 2019, 324: 31–42. doi: [10.1016/j.neucom.2018.03.074](https://doi.org/10.1016/j.neucom.2018.03.074).
- [16] YUAN Ye, XUN Guangxu, JIA Kebin, *et al.* A multi-context learning approach for EEG epileptic seizure detection[J]. *BMC Systems Biology*, 2018, 12(6): 47–57. doi: [10.1186/s12918-018-0626-2](https://doi.org/10.1186/s12918-018-0626-2).
- [17] ZHANG Junming, WU Yan, BAI Jing, *et al.* Automatic sleep stage classification based on sparse deep belief net and combination of multiple classifiers[J]. *Transactions of the Institute of Measurement and Control*, 2016, 38(4): 435–451. doi: [10.1177/0142331215587568](https://doi.org/10.1177/0142331215587568).
- [18] YULITA I N, FANANY M I, and ARYMURTHY A M. Sequence-based sleep stage classification using conditional neural fields[J]. *arXiv preprint arXiv:1610.01935*, 2016.
- [19] LÄNGKVIST M, KARLSSON L, and LOUTFI A. Sleep stage classification using unsupervised feature learning[J]. *Advances in Artificial Neural Systems*, 2012, 2012: 107046. doi: [10.1155/2012/107046](https://doi.org/10.1155/2012/107046).
- [20] MASCI J, MEIER U, CIREŞAN D, *et al.* Stacked convolutional auto-encoders for hierarchical feature extraction[C]. The 21st International Conference on Artificial Neural Networks, Espoo, Finland, 2011: 52–59.
- [21] HINTON G E and SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313(5786): 504–507. doi: [10.1126/science.1127647](https://doi.org/10.1126/science.1127647).
- [22] MIKOLOV T, SUTSKEVER I, CHEN Kai, *et al.* Distributed representations of words and phrases and their compositionality[C]. The 26th International Conference on Neural Information Processing Systems, Lake Tahoe, USA, 2013: 3111–3119.
- [23] CHOI E, BAHADORI M T, SEARLES E, *et al.* Multi-layer representation learning for medical concepts[C]. The 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, USA, 2016: 1495–1504.
- [24] SHOEB A H. Application of machine learning to epileptic seizure onset detection and treatment[D]. [Ph.D. dissertation], Massachusetts Institute of Technology, 2009.
- [25] GOLDBERGER A L, AMARAL L A N, GLASS L, *et al.* PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals[J]. *Circulation*, 2000, 101(23): E215–E220. doi: [10.1161/01.CIR.101.23.e215](https://doi.org/10.1161/01.CIR.101.23.e215).
- [26] FAWCETT T. An introduction to ROC analysis[J]. *Pattern Recognition Letters*, 2006, 27(8): 861–874. doi: [10.1016/j.patrec.2005.10.010](https://doi.org/10.1016/j.patrec.2005.10.010).
- [27] DAVIS J and GOADRICH M. The relationship between precision-recall and ROC curves[C]. The 23rd International Conference on Machine Learning, Pittsburgh, USA, 2006: 233–240.
- [28] HE Haibo and GARCIA E A. Learning from imbalanced data[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 21(9): 1263–1284. doi: [10.1109/TKDE.2008.239](https://doi.org/10.1109/TKDE.2008.239).
- [29] ZEILER M D. ADADELTA: An adaptive learning rate method[J]. *arXiv preprint arXiv:1212.5701*, 2012.
- 袁野: 男, 1991年生, 博士生, 研究方向为深度学习、健康信息学。
- 贾克斌: 男, 1962年生, 教授, 研究方向为多媒体信息系统、模式识别。
- 刘鹏宇: 女, 1979年生, 副教授, 研究方向为多媒体信息系统。