

DOI:10.3969/j.issn.1005-202X.2025.09.018

医学人工智能

## 基于时空数据分析的深度学习慢性疼痛智能评估方法

郑锐<sup>1</sup>, 王翠玲<sup>2</sup>

1. 山西医科大学医学科学院, 山西 太原 030000; 2. 山西医科大学附属肿瘤医院门诊部, 山西 太原 030009

**【摘要】目的:**利用时空数据(包括生理信号和环境信息)构建深度学习模型,实现对慢性疼痛评分的精准预测,为智能化疼痛评估提供支持。**方法:**提出一种基于改进通道注意力机制的残差模块与双向长短时记忆网络(BiLSTM)的疼痛评分预测模型。改进的通道注意力机制提取关键特征并减少冗余信息,BiLSTM建模时间序列的依赖关系,结合改进粒子群优化算法优化模型超参数。在实验中,模型性能通过均方误差(MSE)、平均绝对误差(MAE)、决定系数( $R^2$ )这3个指标进行评估。**结果:**本文模型的MSE为0.117,MAE为0.254, $R^2$ 为0.932,优于卷积神经网络(CNN)-BiLSTM、CNN-LSTM等对比模型。消融实验验证了改进模块对模型性能的关键作用。多模态数据实验进一步表明环境信息的引入提升了模型预测能力。**结论:**本文模型能够高效捕捉疼痛评分的时空特征,具备较高的预测精度和稳定性,为慢性疼痛评估建立了新方法。

**【关键词】**慢性疼痛;时空数据;深度学习;生理信号;环境信息;智能评估

**【中图分类号】**R318;TP311

**【文献标志码】**A

**【文章编号】**1005-202X(2025)09-1255-06

### A deep learning method for intelligent chronic pain assessment based on spatiotemporal data analysis

ZHENG Rui<sup>1</sup>, WANG Cuiling<sup>2</sup>

1. School of Medical Sciences, Shanxi Medical University, Taiyuan 030000, China; 2. Department of Outpatient, Shanxi Cancer Hospital, Shanxi Medical University, Taiyuan 030009, China

**Abstract: Objective** To construct a deep learning model using spatiotemporal data (including physiological signals and environmental information) to achieve accurate prediction of chronic pain scores and provide support for intelligent pain assessment. **Methods** A pain score prediction model based on a residual module with an improved channel attention mechanism and BiLSTM was developed. The improved channel attention mechanism extracted key features and reduced redundant information, while BiLSTM models the temporal sequence dependencies. Improved particle swarm optimization algorithm was integrated to optimize model's hyperparameters. In the experiment, the model performance was evaluated using 3 metrics: mean squared error (MSE), mean absolute error (MAE), and coefficient of determination ( $R^2$ ). **Results** The experimental results showed that the proposed model achieved an MSE of 0.117, an MAE of 0.254, and an  $R^2$  of 0.932, outperforming the comparison models such as CNN-BiLSTM and CNN-LSTM. Ablation experiment verified the critical role of the improved module in enhancing model performance, and the multimodal data experiment further demonstrated that the integration of environmental information improved the model's predictive capability. **Conclusion** The proposed model can efficiently capture the spatiotemporal characteristics of pain scores, with high prediction accuracy and stability, and thus establishing a new method for chronic pain assessment.

**Keywords:** chronic pain; spatiotemporal data; deep learning; physiological signal; environmental information; intelligent assessment

### 前言

慢性疼痛是一种常见的健康问题,其影响范围广泛,涉及躯体、心理及社会功能多个层面。世界卫生组织将慢性疼痛定义为持续超过3个月的疼痛,它不仅对患者的生活质量产生显著负面影响,还给医疗系统带来沉重负担。在临床护理中,准确评估慢性疼痛的程度对于制定个性化的干预策略至关重要。然而,传统的疼痛评估方法,如患者自述的模拟量表或数字评分量表,高度依赖患者的主观反馈,易

**【收稿日期】**2025-04-12

**【基金项目】**山西省自然科学基金(20230302123356)

**【作者简介】**郑锐,硕士研究生,研究方向:慢病疼痛, E-mail: 13530579124@163.com

**【通信作者】**王翠玲,硕士,教授,硕士生导师,研究方向:神经外科, E-mail: 460074054@qq.com

受情绪、认知及沟通能力的影响,难以实现客观性和实时性<sup>[1]</sup>。近年来,随着传感技术和数据分析技术的发展,基于生理信号的疼痛评估方法逐渐受到关注。这些方法利用患者的生理数据(如心率、血压)与行为特征,结合机器学习或深度学习模型,从多维度对疼痛进行分析,为客观化疼痛评估提供新的可能性<sup>[2]</sup>。然而,现有方法在捕捉时间动态模式以及环境影响方面仍存在不足。研究表明环境因素(如温度、湿度)对慢性疼痛的发生和程度具有重要影响,但这些数据往往未被充分利用<sup>[3]</sup>。此外,疼痛信号通常伴随大量冗余信息,如何有效提取与疼痛高度相关的特征是当前智能评估研究的关键问题之一。为此,本研究结合时空数据分析与深度学习技术,提出一种基于嵌入改进通道注意力机制的残差模块和双向长短时记忆网络(BiLSTM)的慢性疼痛智能评估方法。通过在特征提取阶段融入环境数据,模型能够更全面地捕捉疼痛特征。为提升模型性能,引入改进粒子群优化算法(IPSO),对模型的关键超参数进行自动优化。通过与慢性疼痛通用量表(BPI)的评估结果进行对比,本研究旨在验证所提方法的有效性,并为疼痛护理提供一种智能的评估方法。

## 1 资料与数据收集

### 1.1 一般资料

本研究于2019年1月至2024年9月在多家综合性医院住院部开展,研究对象为住院慢性疼痛患者,共纳入700例临床数据。所有患者疼痛持续时间已超过2个月,患者年龄18~75岁。研究重点收集住院期间患者的多模态数据,包括生理信号、环境信息及主观疼痛评分等内容,用于慢性疼痛的智能评估研究。所有纳入的患者均满足研究规定的入组标准,包括能够完成BPI量表的疼痛评估,且住院时间不少于7 d,能够接受佩戴监测设备以记录其生理信号,同时排除因急性疼痛的患者,以及因数据缺失或中途出院无法完成研究的情况。研究已经医院伦理委员会批准,审批号为200176。

### 1.2 数据收集

在研究期间,每位患者的住院时间和监测天数是不同的,监测时间范围7~30 d。其中,41%的患者住院时间7~13 d,37%的患者住院时间14~20 d,其余22%的患者住院时间超过21 d。数据采集内容包括患者的基本信息(包括性别、年龄、体质量指数及病史)、生理信号(包括心率、皮肤电导、血氧饱和度等)和环境信息(包括病房的温度、湿度、气压等)。同时每日定时记录BPI量表评分,生理信号与环境数据通过连续监测设备进行自动采集。

## 2 研究方法

本文提出一种基于时空数据分析的深度学习方法,结合改进通道注意力机制的残差模块、BiLSTM时间序列建模以及IPSO等3种方法,用于提升慢性疼痛智能评估的精度和稳定性。研究方法通过多模态数据的融合与时空特征的深度学习建模,有效减少冗余特征,并提高模型对疼痛状态的敏感性。具体步骤如下:在特征提取阶段引入改进的通道注意力机制,提取突出关键特征;利用BiLSTM建模时间序列的依赖关系,并将基本信息和环境数据融入模型中;采用IPSO优化模型的超参数,以提高模型的泛化能力和训练效率。

### 2.1 改进通道注意力机制的残差模块

在深度学习模型中,特征提取模块负责从输入数据中提取有用的信息。然而,传感器信号数据通常包含冗余或不相关的特征,因此如何有效地聚焦在关键特征上是提升模型性能的关键。本研究在传统的卷积神经网络残差模块<sup>[4]</sup>基础上,结合改进的通道注意力机制进行特征选择。改进的通道注意力机制能够在通道维度上自动学习不同特征的权重,提高模型对关键特征的识别能力。

在残差模块中,输入信号 $\mathbf{x} \in R^{C \times H \times W}$ (其中 $C$ 为通道数, $H$ 和 $W$ 为空间维度)通过卷积层进行特征提取,输出信号 $\mathbf{y} \in R^{C \times H \times W}$ 的计算公式为:

$$\mathbf{y} = \mathbf{x} + \mathcal{F}(\mathbf{x}, \{W_i\}) \quad (1)$$

式中, $\mathcal{F}(\mathbf{x}, \{W_i\})$ 为卷积操作, $W_i$ 为卷积核参数, $\mathbf{y}$ 为残差学习后的输出。

在改进的通道注意力机制中,引入了通道注意力权重 $\mathbf{A} \in R^{C \times 1}$ ,通过全局平均池化获得每个通道的全局描述,再利用一个全连接网络对每个通道的权重进行计算。具体步骤如下:

(1)对输入信号进行全局平均池化操作,得到每个通道的均值:

$$z_c = \frac{1}{H \times W} \sum_{h=1}^H \sum_{w=1}^W x_{c,h,w}, \quad z \in R^{C \times 1} \quad (2)$$

(2)通过一个全连接层学习通道的注意力权重:

$$\mathbf{A} = \sigma(W_a \cdot \mathbf{z} + \mathbf{b}_a) \quad (3)$$

式中, $W_a \in R^{C \times C}$ 为权重矩阵, $\mathbf{b}_a \in R^C$ 为偏置, $\sigma(\cdot)$ 为Sigmoid激活函数, $\mathbf{A}$ 为注意力权重。

(3)输出特征的计算公式为:

$$\mathbf{y} = \mathbf{x} + (\mathbf{A} \odot \mathcal{F}(\mathbf{x}, \{W_i\})) \quad (4)$$

式中, $\odot$ 为逐元素乘法, $\mathbf{A}$ 通过注意力机制调整特征图的通道重要性。

### 2.2 BiLSTM时间序列建模

慢性疼痛的状态随时间变化,具有明显的时序

性,因此捕捉时间序列数据中的依赖关系是研究的主要任务之一。为了建模疼痛状态随时间的动态变化,采用BiLSTM对时序数据进行建模<sup>[5]</sup>。BiLSTM由两个LSTM组成,即一个正向LSTM和一个反向LSTM,分别从时间序列的正向和反向进行处理,以捕捉序列的上下文信息<sup>[6]</sup>。

假设输入的时序数据为  $\mathbf{x} = [x_1, x_2, \dots, x_T]$ , 正向LSTM的目标是根据当前输入  $x_t$  和前一个时间步的隐状态  $\vec{h}_{t-1}$  以及细胞状态  $\vec{C}_{t-1}$ , 计算当前时间步的输出  $\vec{h}_t$  和细胞状态  $\vec{C}_t$ :

$$\begin{cases} \vec{f}_t = \sigma(\mathbf{W}_f x_t + \mathbf{U}_f \vec{h}_{t-1} + \mathbf{b}_f) \\ \vec{i}_t = \sigma(\mathbf{W}_i x_t + \mathbf{U}_i \vec{h}_{t-1} + \mathbf{b}_i) \\ \vec{C}_t = \vec{f}_t \odot \vec{C}_{t-1} + \vec{i}_t \odot \tanh(\mathbf{W}_c x_t + \mathbf{U}_c \vec{h}_{t-1} + \mathbf{b}_c) \\ \vec{o}_t = \sigma(\mathbf{W}_o x_t + \mathbf{U}_o \vec{h}_{t-1} + \mathbf{b}_o) \\ \vec{h}_t = \vec{o}_t \odot \tanh(\vec{C}_t) \end{cases} \quad (5)$$

式中,  $\tanh$  为双曲正切激活函数,  $\mathbf{W}$ 、 $\mathbf{U}$  以及  $\mathbf{b}$  为可学习的参数。

反向LSTM的处理过程与正向LSTM相同,唯一的区别在于它是从序列的末尾开始逐步处理数据,公式与正向LSTM一致,只是时间步的顺序相反<sup>[7]</sup>。

$$\begin{cases} \overleftarrow{f}_t = \sigma(\mathbf{W}_f x_t + \mathbf{U}_f \overleftarrow{h}_{t+1} + \mathbf{b}_f) \\ \overleftarrow{i}_t = \sigma(\mathbf{W}_i x_t + \mathbf{U}_i \overleftarrow{h}_{t+1} + \mathbf{b}_i) \\ \overleftarrow{C}_t = \overleftarrow{f}_t \odot \overleftarrow{C}_{t+1} + \overleftarrow{i}_t \odot \tanh(\mathbf{W}_c x_t + \mathbf{U}_c \overleftarrow{h}_{t+1} + \mathbf{b}_c) \\ \overleftarrow{o}_t = \sigma(\mathbf{W}_o x_t + \mathbf{U}_o \overleftarrow{h}_{t+1} + \mathbf{b}_o) \\ \overleftarrow{h}_t = \overleftarrow{o}_t \odot \tanh(\overleftarrow{C}_t) \end{cases} \quad (6)$$

BiLSTM的最终输出是正向LSTM和反向LSTM的隐状态拼接得到的:

$$h_t = [\overleftarrow{h}_t, \vec{h}_t] \quad (7)$$

BiLSTM的输出将作为后续层的输入,将进一步进行处理和分类<sup>[8]</sup>。

在研究中,除了生理信号数据外,环境信息和患者的基本信息对疼痛感知也具有影响。因此将这些非时序信息与BiLSTM的输出进行融合。通过全连接层将这些信息转换为低维向量,并与BiLSTM输出的时间序列特征结合。最终的特征表示为:

$$h_t^{\text{final}} = [h_t, \mathbf{b}, \mathbf{e}] \quad (8)$$

式中,  $\mathbf{b}$  和  $\mathbf{e}$  分别为基本信息和环境信息的嵌入向量,  $[h_t, \mathbf{b}, \mathbf{e}]$  为结合后的最终特征<sup>[9]</sup>。

图1给出了基于残差模块的BiLSTM的模型框架。




图1 基于残差模块的BiLSTM的模型框架

Figure 1 Model framework of BiLSTM based on a residual module

### 2.3 IPSO

粒子群优化算法(PSO)是一种基于群体智能的优化算法,模拟鸟群觅食或鱼群游动的行为,通过粒子在搜索空间中的位置和速度更新来寻找问题的最优解<sup>[10]</sup>。PSO通过每个粒子的位置和速度进行全局搜索,逐步趋近于最优解<sup>[11]</sup>。在深度学习模型的超参数优化中,PSO可以有效寻找合适的超参数组合,从而提高模型的性能。传统PSO的更新公式为:

$$v_i^{t+1} = wv_i^t + c_1 r_1 (P_{\text{best}_i} - x_i^t) + c_2 r_2 (g_{\text{best}} - x_i^t) \quad (9)$$

式中,  $v_i^{t+1}$  是第  $i$  个粒子在第  $t+1$  次迭代的速度;  $w$  是惯性权重;  $c_1$  和  $c_2$  是学习因子;  $r_1$  和  $r_2$  是均匀分布在  $[0, 1]$  区间的随机数;  $P_{\text{best}_i}$  是第  $i$  个粒子的历史最优位置;  $g_{\text{best}}$  是全体粒子中的全局最优位置<sup>[12]</sup>。

相应地,位置更新公式为:

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (10)$$

式中,  $x_i^t$  是第  $i$  个粒子在第  $t$  次迭代的当前位置<sup>[13]</sup>。每个粒子的位置和速度都会在每次迭代中根据这些公式更新,从而逐步逼近全局最优解。

尽管传统 PSO 在大多数优化问题中表现良好,但在某些复杂的问题中,粒子容易陷入局部最优解<sup>[14]</sup>。为了提高 PSO 的全局搜索能力,研究对 PSO 进行改进,提出 IPSO。图2是 IPSO 的流程图。

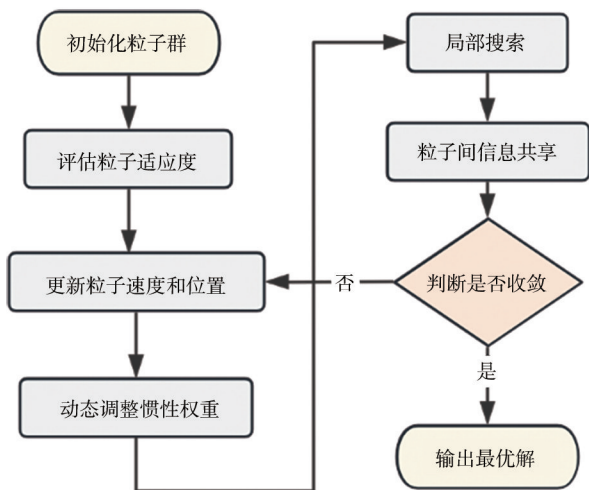


图2 IPSO 的流程图  
Figure 2 IPSO flowchart

具体改进包括:

(1)在传统 PSO 中,速度更新公式中的惯性权重  $w$  通常是固定的,这有可能导致在搜索过程中出现过度探索或过早收敛的问题<sup>[15]</sup>。为了提高粒子群的搜索能力,引入自适应速度更新机制<sup>[16]</sup>,动态调整惯性权重。在自适应更新机制中,惯性权重随着迭代次数变化:

$$w_t = w_{\max} - (w_{\max} - w_{\min}) \times \frac{t}{T} \quad (11)$$

式中,  $w_{\max}$  和  $w_{\min}$  分别为惯性权重的最大值和最小值;  $t$  为当前的迭代次数;  $T$  为最大迭代次数。

(2)为了进一步提高 PSO 在复杂高维空间中的搜索能力,引入了局部搜索策略<sup>[17-18]</sup>。在每一轮迭代中,当粒子的速度低于某一阈值时,表示粒子进入了收敛阶段,此时可以进行局部搜索。具体的局部搜索更新公式如下:

$$v_i^{t+1} = v_i^t + \alpha \cdot (g_{\text{best}} - x_i^t) + \beta \cdot N(0, 1) \quad (12)$$

式中,  $\alpha$  控制粒子向全局最优解的方向更新;  $\beta$  控制粒子探索的随机性;  $N(0, 1)$  为从标准正态分布中采样的随机噪声。通过局部搜索策略,粒子能够在局部最优解附近进行精细优化,提高全局搜索能力和收敛速度。

(3)在传统 PSO 中,每个粒子主要依靠自己的历史最优解 ( $P_{\text{best}}$ ) 和全局最优解 ( $g_{\text{best}}$ ) 进行搜索<sup>[19-20]</sup>。

这种单纯依赖个体和全局最优解的信息可能导致群体的多样性不足,从而影响搜索效果<sup>[21-22]</sup>。为了克服这一问题,引入了粒子间信息共享机制。该机制有效避免整个粒子群陷入局部最优解。粒子间信息共享的更新公式如下:

$$v_i^{t+1} = wv_i^t + c_1r_1(P_{\text{best}_i} - x_i^t) + c_2r_2(g_{\text{best}} - x_i^t) + \sum_{j \in N_i} \gamma \cdot (x_j^t - x_i^t) \quad (13)$$

式中,  $N_i$  表示粒子  $i$  的邻居粒子集合;  $x_j^t$  是粒子  $j$  在第  $t$  次迭代的位置;  $\gamma$  是信息共享因子,控制信息共享的强度。

### 3 结果与分析

#### 3.1 实验环境

实验在 Python 3.8 环境中进行,搭建基于深度学习的模型运行框架,主要使用 TensorFlow 2.6 和 PyTorch 1.10 等深度学习工具库。硬件环境包括一台配备 NVIDIA Tesla V100 GPU 的高性能计算服务器,32 GB 显存和 128 GB 内存,用于训练和优化。

#### 3.2 评价指标

本文所用的评价指标,包括均方误差(MSE)、平均绝对误差(MAE)与决定系数( $R^2$ )。具体公式如下:

MSE 表示预测值与真实值的平方误差平均值,公式为:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (14)$$

式中,  $y_i$  为真实疼痛评分,  $\hat{y}_i$  为预测疼痛评分,  $N$  为样本数。

MAE 表示预测值与真实值的平均绝对偏差,公式为:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (15)$$

$R^2$  用于衡量模型拟合优度,公式为:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (16)$$

式中,  $\bar{y}$  为真实疼痛评分的平均值。

在研究中, MSE、MAE 和  $R^2$  这 3 个评价指标分别从不同角度验证模型的预测性能。MSE 能够敏感捕捉慢性疼痛评分预测中的显著偏差; MAE 则更稳健地反映预测评分与真实评分的平均差异,在存在个体差异的疼痛数据中更具参考价值;  $R^2$  从模型解释的角度,量化了特征对慢性疼痛评分的贡献程度,为临床可解释性提供依据。三者结合可全面评估模型在时空维度上的预测稳定性与有效性。

### 3.3 对比研究

为了验证提出模型的有效性,与现有的主流时序建模方法进行对比,包括卷积神经网络(CNN)-BiLSTM、CNN-LSTM、CNN-BiGRU、CNN-GRU、CNN-ResNet共5种模型。所有对比模型均在相同数据集和实验设置下进行训练,模型性能从MSE、MAE和 $R^2$ 这3个指标进行评估。图3展示提出模型在训练集和测试集的损失函数值的变化曲线。对比结果如表1所示。

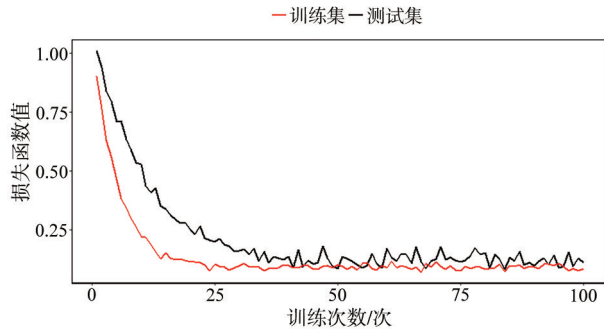


图3 本文提出模型的损失函数值变化图

Figure 3 Loss function value variation diagram for the proposed model

表1 不同方法的评价指标对比结果

Table1 Comparison results of evaluation metrics across different methods

模型	MSE	MAE	$R^2$
CNN-BiLSTM	0.201	0.332	0.895
CNN-LSTM	0.303	0.477	0.871
CNN-BiGRU	0.214	0.359	0.882
CNN-GRU	0.328	0.482	0.856
CNN-ResNet	0.159	0.306	0.907
本文模型	0.117	0.254	0.932

如图3所示,本文提出的模型在训练过程中,损失函数值随迭代次数增加呈现稳定下降趋势,并快速收敛至稳定状态。这一优化过程体现了模型架构的优势:一方面,改进的通道注意力机制有效过滤冗余噪声,加速了关键特征的提取;另一方面,BiLSTM层对时序依赖关系的建模能力,使模型能够精准捕捉慢性疼痛评分的动态变化。IPSO算法优化的超参数进一步协调了模型的效率,从而避免了训练震荡,实现收敛。

根据表1可以看到,本文模型在所有指标上均优于对比模型,特别是在MSE和MAE上表现尤为突出,表明其预测疼痛评分的误差更低,同时 $R^2$ 值最高,说明模型拟合优度更高,能够更准确地预测患者的疼痛评分。

### 3.4 消融实验

为验证本文提出的关键模块对模型性能的贡献,建立以下消融实验:(1)模型1(无残差注意力模块):去除残差注意力模块,仅使用卷积;(2)模型2(无BiLSTM):去除BiLSTM模块,仅使用传统LSTM;(3)模型3(无IPSO):去除IPSO优化,使用随机搜索优化超参数。

根据表2可以看到,去除残差注意力模块后,模型的MSE显著上升至0.216, $R^2$ 下降至0.871,说明残差注意力模块在特征提取和冗余信息过滤方面起到了重要作用。去除BiLSTM模块后,模型的时间序列建模能力减弱,导致预测误差增大,表明BiLSTM能够更有效地捕获疼痛评分的时间序列特性。去除IPSO优化后,模型超参数调优效果变差,MSE升至0.194, $R^2$ 也显著下降,验证了IPSO在优化超参数方面的优越性。

表2 消融实验的对比结果

Table 2 Comparison results of ablation experiments

模型	MSE	MAE	$R^2$
本文模型	0.117	0.254	0.932
模型1(无残差注意力模块)	0.216	0.372	0.871
模型2(无BiLSTM)	0.168	0.302	0.914
模型3(无IPSO)	0.194	0.336	0.892

### 3.5 不同模态对比实验

为研究多模态数据对疼痛评分预测的贡献,分别设计不同模态和多模态融合的实验。根据图4可以看到,多模态融合显著提升模型性能(MSE从不同模态的0.213/0.471降低至0.172),说明环境信息与生理信号的协同建模能够更准确地反映慢性疼痛的动态变化。




图4 不同模态的对比结果

Figure 4 Comparison results of different modes

## 4 结论

本研究提出的基于改进通道注意力机制和BiLSTM的深度学习模型,在慢性疼痛智能评估领域展现出显著的技术优势。通过创新性地融合通道注意力机制与BiLSTM网络,模型不仅能够自动识别生理信号中的关键特征,还能有效捕捉环境因素与疼痛评分的时空关联性。实验结果表明该模型在预测精度和稳定性方面均优于现有方法,特别是在处理复杂多模态数据时表现出更强的鲁棒性。IPSO算法的引入进一步优化模型参数配置,有效提升计算效率。

本研究虽然在慢性疼痛智能评估方面取得一定成果,但仍存在若干可优化的方向。随着医疗数据规模的不断扩大和深度学习的持续发展,本方法有望在临床应用中获得更广泛的推广。特别是模型采用的轻量化网络结构设计<sup>[23-24]</sup>,使其能够便捷地部署在各类医疗物联网设备中<sup>[25]</sup>,这将为慢性疼痛患者提供更加精确、实时且个性化的评估服务,并为后续精准干预方案制定奠定基础。

## 【参考文献】

- [1] 尹金瑜,陈香萍,劳月文,等. ICU转出患者慢性疼痛评估与预测工具的研究进展及启示[J]. 中华急危重症护理杂志, 2024, 5(10): 926-931.  
Yin JY, Chen XP, Lao YW, et al. Research progress and enlightenment of evaluation and prediction tools for chronic ICU-related pain[J]. Chinese Journal of Emergency and Critical Care Nursing, 2024, 5(10): 926-931.
- [2] Singh SK, Rastogi V, Singh SK. Pain assessment using intelligent computing systems[J]. Proc Natl Acad Sci India Sect A Phys Sci, 2016, 86(3): 285-295.
- [3] Bushnell MC, Case LK, Ceko M, et al. Effect of environment on the long-term consequences of chronic pain[J]. Pain, 2015, 156(Suppl 1): S42-S49.
- [4] Kattenborn T, Leitloff J, Schiefer F, et al. Review on convolutional neural networks (CNN) in vegetation remote sensing[J]. ISPRS J Photogramm Remote Sens, 2021, 173: 24-49.
- [5] Singla P, Duhan M, Saroha S. An ensemble method to forecast 24-h ahead solar irradiance using wavelet decomposition and BiLSTM deep learning network[J]. Earth Sci Inform, 2022, 15(1): 291-306.
- [6] Lu WJ, Li JZ, Wang JY, et al. A CNN-BiLSTM-AM method for stock price prediction[J]. Neural Comput Appl, 2021, 33(10): 4741-4753.
- [7] Aslan MF, Unlarsen MF, Sabanci K, et al. CNN-based transfer learning-BiLSTM network: a novel approach for COVID-19 infection detection[J]. Appl Soft Comput, 2021, 98: 106912.
- [8] Woźniak M, Wiczorek M, Silka J. BiLSTM deep neural network model for imbalanced medical data of IoT systems[J]. Future Gener Comput Syst, 2023, 141: 489-499.
- [9] Challa SK, Kumar A, Semwal VB. A multibranch CNN-BiLSTM model for human activity recognition using wearable sensor data[J]. Vis Comput, 2022, 38(12): 4095-4109.
- [10] Jain M, Saihjal V, Singh N, et al. An overview of variants and advancements of PSO algorithm[J]. Appl Sci, 2022, 12(17): 8392.
- [11] Ramírez-Ochoa DD, Pérez-Domínguez LA, Martínez-Gómez EA, et al. PSO, a swarm intelligence-based evolutionary algorithm as a decision-making strategy: a review[J]. Symmetry, 2022, 14(3): 455.
- [12] Moazen H, Molaei S, Farzinavash L, et al. PSO-ELPM: PSO with elite learning, enhanced parameter updating, and exponential mutation operator[J]. Inf Sci, 2023, 628: 70-91.
- [13] Zhu Y, Li GP, Wang R, et al. Intelligent fault diagnosis of hydraulic piston pump combining improved LeNet-5 and PSO hyperparameter optimization[J]. Appl Acoust, 2021, 183: 108336.
- [14] Balyan AK, Ahuja S, Lillhore UK, et al. A hybrid intrusion detection model using EGA-PSO and improved random forest method[J]. Sensors (Basel), 2022, 22(16): 5986.
- [15] Cheng XZ, Li JM, Zheng CY, et al. An improved PSO-GWO algorithm with chaos and adaptive inertial weight for robot path planning[J]. Front Neurobot, 2021, 15: 770361.
- [16] Choudhary S, Sugumaran S, Belazi A, et al. Linearly decreasing inertia weight PSO and improved weight factor-based clustering algorithm for wireless sensor networks[J]. J Ambient Intell Human Comput, 2023, 14(6): 6661-6679.
- [17] Qaraad M, Amjad S, Hussein NK, et al. Quadratic interpolation and a new local search approach to improve particle swarm optimization: solar photovoltaic parameter estimation[J]. Expert Syst Appl, 2024, 236: 121417.
- [18] Rosso MM, Cucuzza R, Aloisio A, et al. Enhanced multi-strategy particle swarm optimization for constrained problems with an evolutionary-strategies-based unfeasible local search operator[J]. Appl Sci, 2022, 12(5): 2285.
- [19] Daviran M, Maghsoudi A, Ghezlbash R. Optimized AI-MPM: application of PSO for tuning the hyperparameters of SVM and RF algorithms[J]. Comput Geosci, 2025, 195: 105785.
- [20] Peng SM, Zhu JC, Wu TZ, et al. Prediction of wind and PV power by fusing the multi-stage feature extraction and a PSO-BiLSTM model[J]. Energy, 2024, 298: 131345.
- [21] Kocak O, Erkan U, Toktas A, et al. PSO-based image encryption scheme using modular integrated logistic exponential map[J]. Expert Syst Appl, 2024, 237(Part A): 121452.
- [22] Li F, Zuo W, Zhou K, et al. State of charge estimation of lithium-ion batteries based on PSO-TCN-attention neural network[J]. J Energy Storage, 2024, 84(Part A): 110806.
- [23] Liu Y, Xue JH, Li DX, et al. Image recognition based on lightweight convolutional neural network: recent advances[J]. Image Vis Comput, 2024, 146: 105037.
- [24] Wang YL, Zhang T, Zhao LJ, et al. RingMo-lite: a remote sensing lightweight network with CNN-transformer hybrid framework[J]. IEEE Trans Geosci Remote Sens, 2024, 62: 1-20.
- [25] Ariana R, Majma MR, Jassbi SJ. Improving the efficacy of continuous monitoring of patients with Parkinson's disease through the use of an intelligent computing architecture within the medical internet of things[J]. Int J Comput Intell Syst, 2024, 17(1): 132.

(编辑:黄开颜)