

基于 Transformer 编码器的脑血流速度重建模型研究

刘高城¹², 童嘉博³, 杨仕林¹², 王秋颖¹², 唐新宇¹⁴, 刘畅^{1*}, 刘嘉^{1*}

¹ (中国科学院深圳先进技术研究院, 深圳 518055)

² (中国科学院大学, 北京 100049)

³ (澳门科技大学, 中国澳门 999078)

⁴ (南方科技大学, 深圳 518055)

摘要: 脑血流速度 (Cerebral Blood Flow Velocity, CBFV) 重建在脑血管功能评估中具有重要作用, 尤其在脑血管疾病的早期诊断、治疗方案优化和脑卒中预防中起着关键作用。现有的 CBFV 重建方法在处理多变量时间序列信号时面临精度和效率的挑战, 尤其是在数据稀疏和复杂信号处理方面。该研究提出了一种基于 Transformer 编码器的多变量时间序列模型, 通过动脉血压 (Arterial Blood Pressure, ABP) 和 CO₂ 时间序列信号进行高精度的 CBFV 重建。模型设计结合了长短期记忆网络 (Long-short Time Memory, LSTM) 模块, 有效弥补了全局注意力机制处理局部信息的不足, 并增强了局部特征学习。同时, 采用混合损失函数优化局部波形误差, 提升了重建精度。此外, 为了应对目标域数据稀疏问题, 该研究引入了基于 ABP 与心电图 (Electrocardiogram, ECG) 信号关联的迁移学习策略, 减轻了数据不足对模型的影响。实验结果表明, 该模型在 CBFV 重建任务中的表现优于传统回归模型和深度学习模型, 皮尔逊相关系数为 0.518, 动态时间规整距离为 17.879, 互信息为 0.343, 且能在 0.04 秒内完成 200 个数据点的重建。研究验证了该方法在精准医疗中的有效性, 并为临床诊断、疾病预防和个性化治疗提供了创新性的解决方案, 具有广泛的应用前景, 尤其在医学信号处理、智能医疗和健康监测领域。

关键词: 脑血流速度重建; 迁移学习; Transformer; LSTM

A Transformer Encoder-Based Model for Cerebral Blood Flow Velocity Reconstruction

LIU Gaocheng¹², TONG Jiabo³, YANG Shilin¹², Wang Qiuying¹², TANG Xinyu¹⁴, LIU Chang^{1*}, LIU Jia^{1*}

¹ (Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)

² (University of Chinese Academy of Sciences, Beijing, 100049, China)

³ (Macau University of Science and Technology, Macau, 999078, China)

⁴ (Southern University of Science and Technology, Shenzhen, 518055, China)

来稿日期: yyyy-mm-dd 修回日期: yyyy-mm-dd

作者简介: 刘高城 (共同第一作者), 硕士研究生, 研究方向为深度学习; 童嘉博 (共同第一作者), 硕士研究生, 研究方向为人工智能 (共同第一作者); 杨仕林 (共同第二作者), 博士研究生, 研究方向为深度学习; 王秋颖 (共同第二作者), 博士研究生, 研究方向为深度学习; 唐新宇 (共同第二作者), 硕士研究生, 研究方向为深度学习; 刘畅 (共同通讯作者), 副教授, 研究方向为模式识别与智能系统, E-mail: chang.liu2@siat.ac.cn; 刘嘉 (共同通讯作者), 研究方向为脑血流自动调节、深度学习等, E-mail: jia.liu@siat.ac.cn。

Corresponding Author: LIU Chang, Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China, Email: chang.liu2@siat.ac.cn; LIU Jia, Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China, Email: jia.liu@siat.ac.cn;.

Abstract: Cerebral Blood Flow Velocity (CBFV) reconstruction plays a crucial role in evaluating cerebrovascular function, particularly in the early diagnosis of cerebrovascular diseases, optimizing treatment plans, and preventing strokes. Existing CBFV reconstruction methods face challenges in accuracy and efficiency when processing multivariate time-series signals, particularly in the context of data scarcity and complex signal processing. This study proposes a multivariate time-series model based on a Transformer encoder, which achieves high-precision CBFV reconstruction using Arterial Blood Pressure (ABP) and CO₂ time-series signals. The model design incorporates a Long Short-Term Memory (LSTM) module, effectively addressing the limitations of global attention mechanisms in handling local information and enhancing the learning of local features. Additionally, a hybrid loss function is employed to optimize local waveform errors, improving reconstruction accuracy. Furthermore, to address the issue of data scarcity in the target domain, this study introduces a transfer learning strategy based on the correlation between ABP and Electrocardiogram (ECG) signals, alleviating the impact of limited data on model performance. Experimental results demonstrate that the proposed model outperforms traditional regression and deep learning models in the CBFV reconstruction task, with a Pearson correlation coefficient of 0.518, a Dynamic Time Warping (DTW) distance of 17.879, and mutual information of 0.343, while completing the reconstruction of 200 data points in 0.04 seconds. The study validates the effectiveness of this method in precision medicine and provides innovative solutions for clinical diagnosis, disease prevention, and personalized treatment, with broad application prospects, particularly in medical signal processing, intelligent healthcare, and health monitoring.

Key words: reconstruction of CBFV; transfer learning; Transformer; LSTM;

1 引言

大脑是一个代谢高度活跃的器官，其正常功能依赖于持续且充足的氧气和营养供应，同时需要高效清除代谢废物。然而，由于脑细胞的能量储备有限，这些需求主要通过脑血流的供给来满足^[1]，因此相对稳定的脑血流对维持脑细胞的正常代谢至关重要。脑血流的调节主要由两个部分组成：脑血流自动调节^[2]和脑血管二氧化碳反应性^[3]。脑血流自动调节是指大脑对脑灌注压变化的响应。在正常情况下，脑血流自动调节和脑血管运动反应性通过调节远端微血管的直径，维持稳定的脑灌注。这些调节机制相互协作，在动态变化的外部条件下维持脑血流的稳定，通过多重机制实现对脑血流速度（Cerebral Blood Flow Velocity, CBFV）的精准控制，避免可能的脑损伤。鉴于脑血流在维持脑功能中的关键作用，准确测量脑血流对于脑血管功能评估、脑病诊断以及神经监测具有重要意义。

目前，由于技术条件限制，脑血流的测量具有挑战性，通常采用脑血流速度作为替代指标。脑血流速度的主要测量方法是经颅多普勒(Transcranial Doppler, TCD)^[4]。这是一种非侵入性且准确的技术。经颅多普勒具有高时间分辨率和精确性，但在长期连续监测和动态环境下的实时应用中存在显著局限性，例如患者移动、头部姿态改变或外界干扰导致探头难以长时间固定于颞窗位置，另外固定探头使得患者产生强烈的不适感也限制了其在移动和动态场景中的可用性。为应对这些挑战，研究者基于与 CBFV 密切相关且更易获取的替代生理信号，精确预测 CBFV。研究表明，动脉血压和二氧化碳分压是与脑血流速度高度相关的生理信号^[5-7]。动脉血压（Arterial Blood Pressure, ABP）是脑血流的重要驱动力，脑血管的自身调节能力能够响应血压波动并维持相对稳定的 CBFV^[8]。因此，在术中或床旁监测等环境中，可以基于 ABP-CBFV 动态关系间接估计 CBFV 变化趋势。另一方面，研究表明，CO₂分压显著影响脑血管的扩张和收缩^[9]。因此，ABP 和 CO₂均为影响 CBFV 变化的重要因素。在此背景下，本研究提出了一种基于 ABP 和 CO₂信号的实时重建 CBFV 的深度学习模型，以克服 TCD 在长期监测和动态环境中的局限性，为术中实时评估和持续日常监测提供更准确高效的解决方案。

本研究的主要贡献体现在以下三个方面：

(1) 创新的模型架构：本研究提出了一种新型的模型架构——多变量长短时跳跃编码器（Multivariate Long Short-Term Memory Skip Encoder, MLSTMSE），该模型结合了 Transformer 编码器模块和长短时记忆网络（LSTM）。传统的深度学习模型通常面临全局与局部特征之间的平衡问题，而 MLSTMSE 模型通过将 LSTM 子模块引入编码器架构中，强化了输入信号对输出结果的局部影响。LSTM 子模块通过其门控机制有力地捕捉到输入信号中的长期依赖关系，尤其在处理时序数据中的局部细节时表现突出，提升了 CBFV 重建的精度和稳定性。通过这种创新性的架构设计，MLSTMSE 不仅能够学习到信号的全局趋势，还能有效提取局部细节，从而克服了传统方法在复杂时序信号重建中常见的性能瓶颈。

(2) 混合损失函数设计：为了更好地评估模型重建的效果，本研究设计了一种混合损失函数，结合了均方误差（Mean Squared Error, MSE）和归一化互相关（Normalized Cross-Correlation, NCC）损失，从不同方面评估波形误差和统计误差。MSE 损失主要优化重建信号的幅值，NCC 损失优化波形形状的一致性，而面积损失则聚焦于信号的功率一致性。该混合损失函数在捕捉信号整体趋势和局部细节特征之间取得了平衡，有效解决了传统损失函数无法兼顾多维度误差的问题。通过精确控制各损失项的权重，模型不仅能够提高波形的重建精度，还能在复杂的生理信号处理任务中保持较高的鲁棒性。

(3) 迁移学习范式：针对目标域数据稀缺的问题，本文设计了一种基于迁移学习的训练策略。通过迁移学习，模型首先在源域信号上进行预训练，学习源域与目标域共同的

关键特征。之后，模型通过在目标域信号上的微调，进一步提高对目标任务的适应能力，显著改善模型的泛化能力。迁移学习策略不仅有效缓解了训练数据不足带来的困境，还使得模型能够更好地适应复杂且有限的目标域数据，提高了模型在实际应用中的可靠性和实用性。这一创新策略对数据稀缺问题的解决具有重要意义，尤其适用于医学信号重建、智能医疗等需要大规模数据支持的领域。

创新性与意义：本文所提出的 MLSTMSE 模型在算法架构上突破了传统模型的限制，结合了 Transformer 编码器的全局信息捕捉能力和 LSTM 对时序信息的有效学习，能够更精确地处理多变量时间序列数据，提升了 CBFV 重建的精度与效率。同时，混合损失函数的设计使得模型在全局趋势与局部特征之间达到了最佳平衡，进一步提高了重建效果的稳定性和可靠性。迁移学习范式的引入有效应对了数据稀缺问题，提升了模型的泛化能力，拓宽了该方法在数据不足环境中的应用前景。该研究不仅为脑血流速度重建提供了新的解决方案，还为其他领域的时序数据重建任务提供了借鉴，具有重要的学术价值和广泛的应用前景，尤其在医学信号处理、智能医疗、健康监测等领域具有显著的应用潜力。

2 国内外研究现状

最近，基于机器学习的生理信号重建已成为生理信号处理和症状分析领域的重要研究方向^{[11]-[13]}。这些方法通过分析 ABP^[14]、光电容积脉搏波信号 (Photoplethysmography, PPG)^[15] 和 CO₂^[16] 等易于获取的生理信号，重建难以持续获取的信号。现有的生理信号重建模型主要基于线性回归方法和深度学习方法。Panerai 等人^[16]提出了一种基于线性假设的多输入线性系统，用于分析 ABP 和 CO₂ 对 CBFV 的调节作用。该方法验证了基于 ABP 和 CO₂ 重建 CBFV 的可行性，为间接动态监测提供了理论支持。然而，其线性假设限制了对脑血流调节非线性特性的捕捉，且该方法仅在健康受试者中进行实验，缺乏对病理状态的适用性研究。同样，Marmarelis 等人^[17]提出了一种结合 PDM (Principal Dynamic Modes) 的线性输入输出模型。该模型利用 ABP 和呼气末二氧化碳水平估算 CBFV。虽然该研究成功重建了 CBFV，但其假设信号之间呈线性关系，而实际信号之间存在显著的非线性关系。此外，PDM 需要长时间序列数据以提取可靠的动态模式。在临床环境中，特别是急性或紧急情况下，这样的需求是难以被满足的。Al-Abed 等^[18]基于人工神经网络，通过 PPG 和血氧饱和度信号重建 CBFV，尽管取得了令人满意的重建精度，但该方法需要针对不同受试者重新训练网络，这限制了其大规模应用的能力并降低了模型的鲁棒性。此外，由于训练数据样本数量较少，该模型容易出现过拟合现象。标签数据不足是生理信号重建领域的重要挑战，尤其是在 CBFV 重建任务中。近年来，迁移学习在解决此问题上表现出了令人满意的性能^{[19]-[22]}。例如，Leitner 等人^[23]利用大量不同患者的成对 PPG 和 ABP 数据进行预训练，然后在少量目标患者数据上进行微调，从而通过迁移学习实现特定患者的 ABP 精确重建。Huang 等人^[25]提出了用于 ABP 信号重建的神经网络—ArterialNet。通过在源域数据上进行预训练，模型能够学习到 PPG 和心电图 (Electrocardiogram, ECG) 信号中与 ABP 波形相关的通用特征；在目标域上，将目标患者收集的 PPG 和 ABP 数据用于个性化预训练模型，使模型对于特定个体的生理特征和血压变化模式具有极强的泛化性。

近年来，Transformer 模型^[26]在处理时间序列信号方面展现了卓越的能力。通过同时考虑输入序列中每个元素的上下文信息（未来和过去的信息），Transformer 使得每个元素都能够为整体上下文贡献力量。其多头注意力机制设计能够捕捉输入元素之间多方面的相关性，这对时间序列数据的分析尤为有利。为克服现有 CBFV 重建算法的局限性，本文提出了一种基于 Transformer 架构结合长短时记忆网络的新型多变量时间序列模型——多变量长短时跳跃编码器 (Multivariate Long Short-Term Memory Skip Encoder, MLSTMSE) 模型。该模型以动脉血压和 CO₂ 信号为输入，能够实现脑血流速度的精确重建。通过引入

创新的多通道 LSTM 模块，MLSTMSE 将输入 ABP 和 CO₂信号的动态特征直接传播至模型输出，从而保留通道中的波动；所提出的损失函数有效缓解了生理信号极值重建困难的问题。此外，模型通过迁移学习训练过程，仅需少量样本即可实现有效训练。

3 数据预处理及 MLSTMSE 模型训练流程

本节详细介绍了所提框架的数据预处理（图 1）与模型架构（图 2）设计，旨在实现对 CBFV 信号的精确重建。数据准备环节通过多通道信号对齐、低通滤波与降采样、数据增强及归一化处理，将原始时间序列信号转换为适合模型输入的标准化格式，从而提高模型的适用性与预测精度。在此基础上，设计了一种结合 Transformer 编码器和多变量 LSTM 子模块的深度学习架构（MLSTMSE），通过对信号间依赖关系和时间特征的高效捕获，显著提升模型的重建能力。最后，通过混合损失函数的优化，确保重建信号在振幅和波形上的精确性。

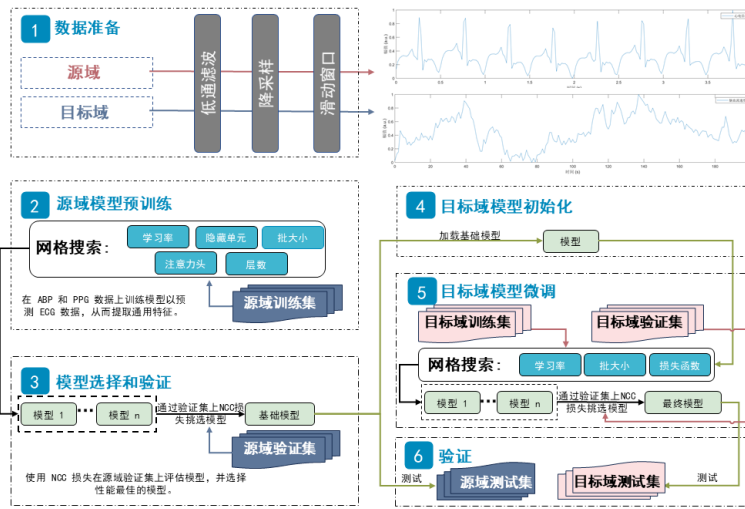


图 1 本研究提出的整体数据处理和训练流程

Fig. 1 The overall data processing and training process proposed in this study

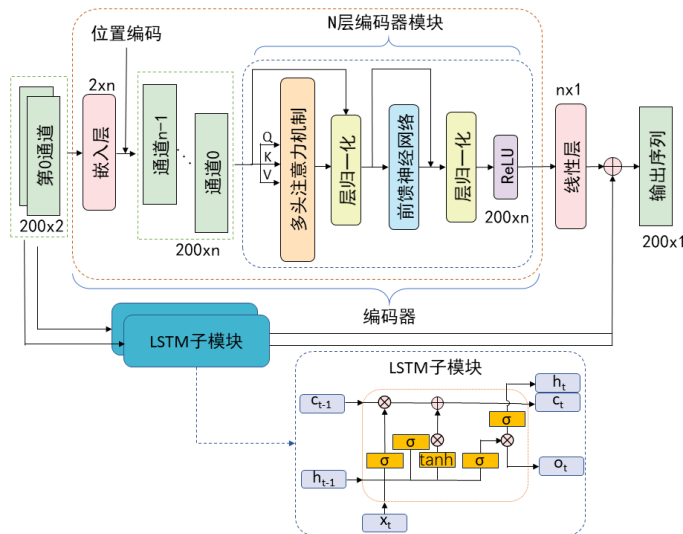


图 2 本研究提出的 MLSTMSE 模型

Fig. 2 The MLSTMSE model proposed in this study

3.1 数据预处理

为解决训练数据稀缺的问题，本研究引入迁移学习技术，通过在相关的大规模数据集上预训练模型以提升其初始特征学习能力。本研究以贝斯以色列女执事医疗中心的糖尿病脑血管调节数据集^{[29]、[30]}作为目标域数据，并以重症监护医学信息数据库 II 的波形数据集^{[27]、[28]}作为源域数据。其中，源域数据集包含约 1000 名重症监护室患者的 ABP、PPG 和 ECG 信号，其概览如表 1 所示；目标域数据集包含 50 名糖尿病患者和正常受试者共计 57 条的 ABP、CO₂ 和 CBFV 信号。

数据预处理过程包括以下步骤：首先，通过数据对齐实现多通道信号的时间同步，确保信号在时间维度上的一致性；其次，采用低通滤波与降采样策略，消除高频噪声并降低计算复杂度；随后，将长时间序列信号分割为适合模型输入的固定长度片段，便于模型处理与分析；最后，对信号进行 0-1 归一化处理，以统一数值范围，促进梯度平滑传播，提升模型的优化效果。

3.1.1 数据对齐

源域数据由 ABP、PPG 和 ECG 信号组成，这些信号来源于不同设备，从而具有一定时延。不对齐的生理信号可能会在重建结果中引入额外的噪声干扰，从而降低模型的重建精度。信号对齐可以确保时间一致性，使模型能够准确捕捉 ABP、PPG 和 ECG 信号之间的依赖关系，从而提高重建精度。根据文献^[31]中的对齐方法，我们通过调整时间轴，将 ABP 和 PPG 信号与 ECG 信号进行对齐，确保的 ABP 舒张末期压力点、PPG 的收缩峰以及 ECG 的 R 波峰在时间上准确匹配。目标域数据（包括 ABP、CO₂ 和 CBFV 信号）由于是从同一设备同步采集^[30]，因此无需额外的对齐处理。

3.1.2 低通滤波和降采样

滤波和降采样是数据预处理过程中的关键步骤，旨在通过降低信号的采样率，在保持信号完整性的同时平衡计算成本。通常，高频信号对应于噪声，适当降低采样率可以简化数据，同时保留其关键特征，使模型能够专注于有意义的时间特征。在本研究中，我们首先在源域使用截止频率为 25 Hz 的低通滤波器，然后将 ABP、PPG 和 ECG 信号从 125 Hz 降采样至 50 Hz^[32]。类似地，在目标域中，我们使用截止频率为 0.5 Hz 的低通滤波器，并将 ABP、CO₂ 和 CBFV 信号降采样至 1 Hz^[33]。降采样减少了计算成本，为准确、快速重建奠定了坚实的基础。

3.1.3 数据增强

数据增强通过生成更大、更具多样性的数据集来提升深度学习模型的性能，从而提高模型的准确性和稳定性，并缓解过拟合问题^{[34]、[35]}。为了实现这一目的，在降采样后，源域和目标域的训练集通过以下方式进行增强。对于源域，通过 4 秒的不重叠移动从原始信号序列中提取大量 ABP、PPG 和 ECG 实例。对于目标域，由于数据稀缺问题较为严重，从原始信号序列中以 200 秒的移动窗口和 50% 的重叠提取大量 ABP、CO₂ 和 CBFV 实例，从而有效地扩大目标域的训练集。最终，源域和目标域中的每个信号实例都包含 200 个数据点。该方法有效地将目标域训练集的可训练实例数翻倍，从而缓解了数据不足的问题。

3.1.4 归一化

对于源域和目标域数据，由于输入值存在显著的变异性，标准化处理是必要的。对两个域中的每个实例应用了 Z-score 标准化，随后进行了 0-1 归一化，有效地缓解了由于输入值大幅波动导致的网络训练中梯度爆炸的风险^{[36]、[37]}。经过前述处理后，最终的源域训练集包含 5,158 个实例，验证集包含 329 个实例，测试集包含 267 个实例。目标域数据集则包括 598 个训练实例，20 个验证实例和 26 个测试实例。

3.2 深度学习模型架构

完成数据准备后，处理后的时间序列数据被输入到所提出的深度学习模型 MLSTMSE

中, 如图所示。MLSTMSE 的架构由 Transformer 编码器和 LSTM 子模块组成。其中, LSTM 子模块专门设计用于学习 ABP 和 CO₂ 信号对 CBFV 的独立贡献以及信号的短期关系, 从而实现 CBFV 的精确重建; 同时, Transformer 编码器捕捉输入特征之间的全局关系。Transformer 编码器与 LSTM 子模块的输出通过加法操作进行融合, 从而使模型能够精确学习全局和局部以及通道内和通道间的关系, 提高模型对复杂生理信号的捕获与表征能力。

3.2.1 Transformer 编码器

Transformer 中的编码器由 n 个相同的编码器层堆叠而成。在 Transformer 的多头注意力机制中, 每个注意力头通过计算查询矩阵 (Query, Q)、键矩阵 (Key, K) 和值矩阵 (Value, V) 之间的关系, 捕捉输入序列中元素两两之间的关系。注意力机制的计算的计算方法如下:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V, \quad (1)$$

其中, d_k 表示键矩阵的维度。缩放因子 d_k 用于防止 QK^T 的值过大, 从而有助于平衡注意力分布, 第 i 个注意力头由线性变换后的 Q 、 K 和 V 矩阵生成, 其定义如下:

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V), \quad (2)$$

其中, W_i^Q 、 W_i^K 和 W_i^V 分别是用于 Q 、 K 和 V 矩阵线性变换的可学习权重矩阵。在多头注意力机制中, 多个注意力的输出会被拼接后再进行线性变换。该过程表述如下:

$$\text{Multihead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O, \quad (3)$$

其中, 权重矩阵 W^O 对多个注意力头拼接后的特征进行线性变换, 进一步聚合并提取每个注意力头捕获的多样化信息, 从而生成最终的多头注意力输出。该输出不仅关注输入序列的不同特征维度, 还能同时学习输入元素之间的多重关系, 从而显著增强对时间序列数据的建模能力。编码器利用多头注意力机制, 将两通道的输入时间序列数据转换为与输入长度相同的输出信号, 捕捉输入数据中的隐藏特征和内在关系。多头注意力机制通过多个注意力头的并行计算, 从不同子空间编码信息, 提升了模型的表达能力。这不仅克服了传统模型在编码过程中需要依赖序列顺序处理的局限性, 还在捕捉 ABP 和 CO₂ 信号的时间关系中发挥了关键作用。

3.2.2 多变量 LSTM 子模块

多变量 LSTM 子模块由两个独立的 LSTM 网络组成, 分别负责建模每个通道的动态特性。每个 LSTM 的输入特征维度为 1, 隐藏单元数为 1, 并堆叠了 2 层, 以捕捉信号的短期和长期依赖关系。在前向传播中, 两路输入信号分别被输入到对应的 LSTM 网络进行递归计算, 两个 LSTM 网络的输出特征通过逐元素相加实现融合, 实现了输入生理信号特征的综合表示。该子模块保证了在训练数据有限的情况下的信号重建精度。LSTM 网络通过遗忘门、输入门、输出门及记忆单元的状态更新机制, 完成对时间序列信号短期和长期依赖关系的建模。LSTM 网络遗忘门的计算公式如下:

$$f_t^{(k)} = \sigma(W_f^{(k)}x_t^{(k)} + U_f^{(k)}h_{t-1}^{(k)} + b_f^{(k)}), \quad (4)$$

其中 $f_t^{(k)} \in [0, 1]$ 表示遗忘门在 t 时刻关于第 k 个通道 ($k=0,1$) 的输出, 其表示记忆保留的比例; $x_t^{(k)}$ 为 t 时刻第 k 通道的输入; $h_{t-1}^{(k)}$ 表示第 k 通道在 $t-1$ 时刻的隐状态; $W_f^{(k)}$ 、 $U_f^{(k)}$ 、 $b_f^{(k)}$ 分别为遗忘门第 k 通道在 t 时刻步的输入权重矩阵、隐状态权重矩阵和偏置项。输入门负责决定当前时刻的输入信息对记忆单元状态的影响, 计算过程如下:

$$\tilde{c}_t^{(k)} = \tanh(W_c^{(k)}x_t^{(k)} + U_c^{(k)}h_{t-1}^{(k)} + b_c^{(k)}), \quad (5)$$

$$i_t^{(k)} = \sigma(W_i^{(k)}x_t^{(k)} + U_i^{(k)}h_{t-1}^{(k)} + b_i^{(k)}), \quad (6)$$

式 (5) 表示候选记忆内容生成的公式, 其中 $W_c^{(k)}$ 表示第 k 个通道的候选记忆单元权重矩阵, 用于对当前时刻输入 $x_t^{(k)}$ 和上一时刻隐状态 $h_{t-1}^{(k)}$ 进行线性变换, 生成候选记忆内容 $\tilde{c}_t^{(k)}$; $W_c^{(k)}$ 、 $U_c^{(k)}$ 、 $b_c^{(k)}$ 分别为第 k 通道在 t 时刻输入门的输入权重矩阵、隐状态权重矩阵和偏置

项； i_t 为输入门的权重，用于调节输入对记忆单元的更新程度。随后通过结合遗忘门和输入门的输出进行记忆单元状态更新，计算公式为：

$$C_t^{(k)} = f_t^{(k)} * C_{t-1}^{(k)} + i_t^{(k)} * \tilde{C}_{t-1}^{(k)}, \quad (7)$$

其中“*”表示矩阵的哈达玛积； $C_t^{(k)}$ 为第 k 通道当前时刻的记忆状态，结合了上一时刻的记忆特征和当前时刻的输入特征。输出门通过控制当前时刻的隐状态 h_t ，用于为后续层提供动态特征表示，其计算公式如下：

$$o_t^{(k)} = \sigma(W_o^{(k)} x_t^{(k)} + U_o^{(k)} h_{t-1}^{(k)} + b_o^{(k)}), \quad (8)$$

$$h_t^{(k)} = o_t^{(k)} * \tanh(C_t^{(k)}), \quad (9)$$

其中， $o_t^{(k)}$ 表示输出门的权重，决定记忆单元的内容对当前隐状态的贡献； $W_o^{(k)}$ 、 $U_o^{(k)}$ 、 $b_o^{(k)}$ 分别为第 k 通道在 t 时刻输出门的输入权重矩阵、隐状态权重矩阵和偏置项。最终，多变量 LSTM 子模块的输出结果 y_t 由两个 LSTM 网络输出结果相加得到，公式如下：

$$y_t = o_t^{(0)} + o_t^{(1)}. \quad (10)$$

LSTM 子模块利用两个 LSTM 网络动态捕捉两个信号的时间依赖特性，从而描述了 ABP 和 CO_2 对 CBFV 的不同影响。Transformer 通过提取信号间的全局关系，而 LSTM 子模块则分别提取各个信号内的局部关系，最后，LSTM 子模块和 Transformer 编码器的输出通过求和操作进行特征融合，使模型在 CBFV 重建任务中能够实现高精度和稳定的重建性能。

3.2.3 损失函数

为了实现对 CBFV 和 ECG 的精确重建，我们设计了一种混合损失函数对网络进行训练。该损失函数由 MSE 损失和 NCC 损失加权组成。以下将详细说明混合损失函数的组成部分。

为确保重建波形的振幅与真实值尽可能一致，我们在混合损失函数中引入了 MSE 损失，以优化重建误差。MSE 通过对振幅差异的平方求和进行量化，从而对较大的偏差施加更高的惩罚。MSE 损失函数定义如下：

$$L_{\text{MSE}}(T, P) = \frac{1}{n} \sum_{t=1}^n (T_t - P_t)^2, \quad (11)$$

其中， T 表示真实值， P 表示重建值， n 为时间序列的长度。此外，为优化重建波形与真实信号波形之间的一致性，我们引入了 NCC，其定义如下：

$$L_{\text{NCC}}(T, P) = 1 - \frac{\sum_{t=1}^n (T_t - \bar{T})(P_t - \bar{P})}{\sqrt{\sum_{t=1}^n (T_t - \bar{T})^2 (P_t - \bar{P})^2}}, \quad (12)$$

最终，混合损失函数由上述 2 种损失函数组成，其定义如下：

$$L_{\text{mix}}(T, P) = \alpha L_{\text{MSE}}(T, P) + \beta L_{\text{NCC}}(T, P), \quad (13)$$

$$\alpha + \beta = 1, \quad (14)$$

其中 α ， β 为权重系数，用于控制损失项在整体损失函数中的相对重要性。

4 实验及结果

4.1 MLSTMSE 模型的训练与评估

MLSTMSE 模型基于 Python 并使用 PyTorch^[24] 库实现。为评估所提出的 MLSTMSE 模型的有效性，实验对比了多种常用的时间序列模型，包括 Transformer^[26]、Encoder^[26]、LSTM^[10]、Arterial Net^[25] 以及 Panerai 的方法^[16]。深度学习模型的训练分为两个阶段：源域训练和目标域训练。在模型训练阶段，我们使用 NVIDIA 制造的 Tesla V100 GPU 进行加速优化。Tesla V100 配备了 32 GB 的 HBM2 显存和 5120 个 CUDA 核心。

表 1 目标域人口统计学数据

Table 1 Demographics for subjects in target domain

参数	均值±方差
研究对象数量 (位)	50
年龄 (岁)	62.32±7.08
体重 (千克)	75.67±13.01
身高 (厘米)	169.52±8.87
体重指数 (无单位)	26.33±4.19

4.1.1 源域训练过程

我们使用 PyTorch 库中的 Adam 优化器^[41]来更新模型参数。对于 Transformer、Encoder、LSTM 和 MLSTMSE 模型，需要确定的三个超参数包括学习率、层数以及隐藏单元数。此外，对于 Transformer、Encoder 和 MLSTMSE 模型，还需额外确定注意力头的数量。在本研究中，学习率的候选值为{0.01, 0.001, 0.005, 0.0015}中选择，层数候选值为 1 到 14 的整数，隐藏单元数的候选值为{8, 16, 32, 128}，注意力头数的候选值为{1, 2, 4, 8}。Panerai 方法的卷积长度在 5 到 100 的范围内选择。我们通过网格搜索法遍历各深度学习模型所需的注意力头数、学习率、层数和隐藏单元数的所有组合（LSTM 不涉及注意力头数参数）。每种参数组合均进行 400 个训练周期，并采用早停策略选择最优的权重，最后使用 MSE 损失作为验证指标以确定最优超参数配置。随后，所有深度学习模型均使用最优超参数配置进行训练。对于 MLSTMSE 模型，在确定最优超参数后，进一步通过网格搜索法调整混合损失函数所需的权重 α 和 β ， α 和 β 的候选值从 0 到 1，步长为 0.05。类似地，每组权重组合均训练 400 个周期，并使用早停策略，将 NCC 作为验证指标以确定混合损失函数的最佳配置。该过程在图 1 中标注的步骤 1 至 3 进行展示。

4.1.2 目标域训练过程

在目标域中，深度学习模型以源域预训练权重进行初始化。我们采用与源域相同的方法选择目标域中模型的学习率，并且通过网格搜索法从集合{4, 8, 16, 32, 64}中选出最恰当的批量大小。此外，MLSTMSE 模型的混合损失函数权重通过与源域相同的方式进行调整。对于 Panerai 的方法的卷积长度，也采用了与源域相同的方法进行确定。图 1 中标注的步骤 4 至 6 展示了该过程。

4.1.3 评估指标

我们通过多种指标对所提出模型在 ECG 信号和 CBFV 重建任务中的性能进行了全面评估。常用的时间序列数据评估指标包括皮尔逊相关系数 (Pearson Correlation Coefficient, PCC)、MSE、对称平均绝对百分比误差 (symmetric mean absolute percentage error, SMAPE)、错误率 (error rate, ER)、动态时间规整距离 (dynamic time warping, DTW) 以及互信息 (mutual information, MI)。

PCC 衡量两个变量之间的线性相关性，取值范围为[-1,1]。PCC 值越接近 1 表示正相关性越强，越接近-1 表示负相关性越强。MSE (Mean Squared Error) 用于评估重建值与真实值之间的差异，其值越小表明重建精度越高，模型拟合效果更优。

SMAPE 是一种比例误差指标，用于衡量预测值与实际值的相对偏差，值越小说明模型更准确地捕捉了数据的真实变化，其计算公式如下：

$$SMAPE = \frac{1}{n} \sum_{i=1}^n \frac{|T_i - P_i|}{(|T_i| + |P_i|)/2} \times 100\% \quad (15)$$

其中， T_i 和 P_i 分别表示第 i 个时间步的真实值和重建值。

ER 定义为测试集中重建错误样本点所占的百分比。当重建误差超过预定义的容忍度时，该样本点被视为预测错误。在本实验中，真实值的标准差被用作容忍度，其中源域测试集的容忍度为 0.1783，目标域测试集的容忍度为 0.1704。ER 是一种负向性能指标，较

低的 ER 表明模型的重建结果更接近真实值。

DTW 用于衡量两个时间序列在非线性时间对齐下的相似性，其值越小表示序列间的相似性越高，是时序数据分析中的常用指标，其计算公式如下：

$$DTW(T, P) = \min_{\pi} \sum_{(i,j) \in \pi} d(T_i, P_j) \quad (16)$$

其中， π 代表最优对齐路径， $d(T_i, P_j)$ 表示第 i 个真实样本点与第 j 个重建样本点之间的欧几里得距离。DTW 值越小，说明两个时间序列在经过时间变换后具有更高的相似度。在本研究中，DTW 被用于评估模型在非线性时间变换情况下的重建能力。

MI 量化两个变量之间的互依赖程度，其值越大说明重建序列与真实序列之间的依赖关系越密切，信息传递效果越强，适用于评估非线性关系和变量间的信息共享程度，其计算公式如下：

$$MI(T, P) = \sum_i \sum_j p(T_i, P_j) \log \frac{p(T_i, P_j)}{p(T_i)p(P_j)} \quad (17)$$

其中， $p(T_i, P_j)$ 代表联合概率分布， $p(T_i)$ 和 $p(P_j)$ 分别代表各自的边际概率分布。MI 越大，说明两个信号之间的信息共享程度越高，即重建信号能够更好地恢复真实信号的内在特征。在 CBv 和 ECG 重建任务中，由于生理信号的复杂性，MI 指标在评估非线性依赖关系方面具有独特优势。

本研究中使用的所有评估指标分别从不同方面衡量预测值与真实值之间的差异，为模型性能提供了多维度的综合评估。

5 结果

5.1 MLSTMSE 在源域上的重建性能

在源域任务中，MLSTMSE 模型被用于重建 ECG 信号，输入信号为 ABP 和 PPG，其性能评估结果如表 2 所示。实验结果表明，MLSTMSE 模型在 PCC、ER 和 DTW 等关键指标上相较于其他模型展现出了优越的性能。其中，MLSTMSE 模型的 PCC 达到 0.45307，优于其他模型，表明其在捕捉重建信号整体趋势方面具有卓越能力。此外，MLSTMSE 模型的 ER 为 25.323%，低于其他模型，显示出更高的重建精度。在 DTW 指标上，MLSTMSE 模型的得分为 16.534，优于其他模型，体现了其在时间动态对齐方面的强大性能。

相比之下，Encoder 和 Transformer 在 MSE 指标上略优于本文所提模型（分别为 0.02803，0.02814 和 0.03251），但在 PCC、ER 和 DTW 等关键指标上表现不及 MLSTMSE。这表明，MLSTMSE 模型能够更准确地捕捉信号的整体模式和时间特性。而 LSTM 和 Arterial Net 在 PCC 和 DTW 指标上的表现尤其不佳，暴露了其在捕捉时间序列动态特性方面的局限性。Panerai 的方法的重建性能显示出不足，其 ER 和 SMAPE 均较高，进一步证明了其在处理复杂信号重建任务中的不足。

综上所述，MLSTMSE 模型在源域重建任务中展现了卓越的性能，尤其在 PCC、ER 和 DTW 等指标上优于对比方法。MLSTMSE 模型不仅能够准确重建 ECG 信号的整体趋势，还能精确对齐信号的时间动态特性。图(a)-(d)定性展示了所提出方法与对比模型在 ECG 重建任务中的结果。从图 (a)可以看出，MLSTMSE 和 Transformer 模型重建的波形与真实值高度一致，而其他 2 种模型（如图(b)、(d)所示）在重建波形上存在明显偏差。这些结果表明，MLSTMSE 模型在基于 ABP、PPG 重建 ECG 的任务中具有较好的准确性和特征学习能力。

表 2 模型在源域上的对比结果

Table 2 Comparison results of the models on source domain

模型	模型超参数				性能指标					
	学习率	层数	注意力数	隐藏单元数	MSE	PCC	SMAPE	ER (%)	DTW	MI
					(a. u.) ↓	(a. u.) ↑	(%) ↓	(%) ↓	(a. u.) ↓	(a. u.) ↑
MLSTMSE	0.001	7	8	16	0.03251	0.45307	54.697	25.323	16.534	0.20258
Encoder	0.001	3	2	32	0.02803	0.40152	55.351	27.524	17.376	0.18684
Transformer	0.001	3	1	16	0.02814	0.39425	55.819	27.610	18.496	0.17348
LSTM	0.005	1	4	128	0.3107	0.006732	53.983	25.408	23.171	0.03693
Arterial Net ^[25]	0.005	5	2	16	0.03575	0.00040	60.875	31.170	18.523	0.02491
Panerai ^[16]	-	-	-	-	0.055985	0.03755	88.012	32.082	24.330	0.37326

注：符号“↑”表示指标值越大，性能越优；符号“↓”表示指标值越小，性能越差




图 3 源域上，MLSTMSE、Encoder、Transformer 和 Arterial Net 的重建心电信号效果对比
Fig. 3 Comparison of ECG reconstruction performance in the source domain using MLSTMSE, Encoder, Transformer, and Arterial Net, respectively

5.2 MLSTMSE 在目标域上的重建性能

5.2.1 多种模型在目标域上重建性能对比

在目标域任务中，我们验证了 MLSTMSE 模型基于 ABP 和 CO₂ 信号重建 CBFV 的性能。与源域一致，为了全面评估其在目标域的表现，我们将其与 Encoder、Transformer、LSTM、Arterial Net 和 Panerai 方法进行了比较。综上所述，MLSTMSE 模型在目标域任务中表现卓越，尤其在 PCC、ER 和 DTW 等定量指标上表现出强大优势。结合定量指标与定性波形分析结果，该模型在捕捉 CBFV 信号的时间模式及趋势对齐方面展现出明显的优越性。此外，MLSTMSE 模型具有较高的运行效率，仅需约 0.04 秒即可完成 200 个数据点的重建，充分满足实时性能需求。这些结果表明，MLSTMSE 模型在基于 ABP 和 CO₂ 信号重建 CBFV 中具有良好的鲁棒性与准确性，为探索 CBFV 重建任务提供新的见解与技术框架，具有广阔的应用前景。

表 3 总结了各模型的关键性能指标，包括 MSE、PCC、SMAPE、ER、DTW 和 MI。MSE 和 DTW 指标侧重于对全局特征的关注能力，表 3 的结果表明。引入注意力机制的

MLSTMSE、Transformer 和 Encoder 模型三个模型在 MSE 和 DTW 指标上均优于未使用注意力机制的模型，这表明注意力机制的引入，使得模型能够有效提取全局时间序列特征，从而提升重建性能。然而，当需要重建的波形表现出极大的变异性且长度较长时，对局部特征的关注显得尤为重要。通过引入 LSTM 子模块，模型能够有效聚焦于通道内的局部特征。因此，在更注重波形一致性的 PCC 指标上，MLSTMSE 模型表现出领先优势。结合图 3(a)和图 4(a)可见，包含 LSTM 子模块的 MLSTMSE 模型在处理局部信号剧烈变化的重建任务时表现出更强的能力。

实验结果表明，MLSTMSE 模型在 PCC、ER、DTW 和 MI 四个关键指标上优于其他模型，显示出其在 CBFV 重建任务中的卓越性能。具体而言，MLSTMSE 模型的 PCC 达到 0.51870，远高于其他模型，表明其在捕捉 CBFV 信号整体趋势方面表现优异。此外，MLSTMSE 模型的 ER 为 26.548%，低于其他模型，进一步验证了其在 CBFV 信号重建中的有效性。同时，MLSTMSE 模型的 DTW 为 17.879，低于其他模型，显示出其在时间对齐和动态特征捕捉方面的优越性能。

为了对不同模型的重建性能进行定性比较，图 4 (a)-(d)展示了各方法重建的 CBFV 波形与真实值的对比。可以观察到，MLSTMSE 模型重建的波形在整体趋势和局部细节的动态特征上与真实值具有高度一致性。尽管 Encoder 和 Transformer 模型在 MSE 上略优于本文模型（分别为 0.03085、0.03512 和 0.03205），但其重建的波形（见图 4 (b)和(c)）在某些时间段，尤其是在信号快速变化区域，与真实值存在较大差异，表明其在局部动态特征捕捉方面不足。此外，图 4 (d)显示，Arterial Net 模型在信号峰值和谷值处的偏差较大，重建误差显著，进一步凸显了其极值重建方面的局限性。

表 3 显示，Panerai 方法最快，仅需 0.03524 秒。然而，与 Encoder、Transformer 和 MLSTMSE 模型相比，其速度优势并不明显，这些模型的重建时间均约为 0.03 秒。而 LSTM 模型由于架构隐藏单元较多，重建时间明显较长，为 0.05256 秒。总体而言，MLSTMSE 模型展现了较强的实时性能，尽管不是最快的，但其综合表现仍满足实时应用需求。

综上所述，MLSTMSE 模型在目标域任务中表现卓越，尤其在 PCC、ER 和 DTW 等定量指标上表现出强大优势。结合定量指标与定性波形分析结果，该模型在捕捉 CBFV 信号的时间模式及趋势对齐方面展现出明显的优越性。此外，MLSTMSE 模型具有较高的运行效率，仅需约 0.04 秒即可完成 200 个数据点的重建，充分满足实时性能需求。这些结果表明，MLSTMSE 模型在基于 ABP 和 CO₂信号重建 CBFV 中具有良好的鲁棒性与准确性，为探索 CBFV 重建任务提供新的见解与技术框架，具有广阔的应用前景。

表 3 模型在目标域上的对比结果

Table 3 Comparison results of the models on target domain

模型	性能指标						
	MSE (a. u.) ↓	PCC (a. u.) ↑	SMAPE (%) ↓	ER (%) ↓	DTW (a. u.) ↓	MI (a. u.) ↑	Time (s) ↓
MLSTMSE	0.03205	0.51870	47.051	26.548	17.879	0.34375	0.03765
Encoder	0.03085	0.40157	36.092	36.324	18.713	0.32649	0.03562
Transformer	0.03512	0.38562	36.829	37.704	18.724	0.31223	0.03563
LSTM	0.03682	0.28328	53.983	38.869	23.171	0.03693	0.05256
Arterial Net ^[25]	0.04459	0.16958	39.397	47.307	23.964	0.16247	0.03528
Panerai 的方法 ^[16]	0.04826	0.29953	37.026	42.115	19.576	0.31805	0.03524

注：符号“↑”越大，性能越优；符号“↓”表示指标值越小，性能越差

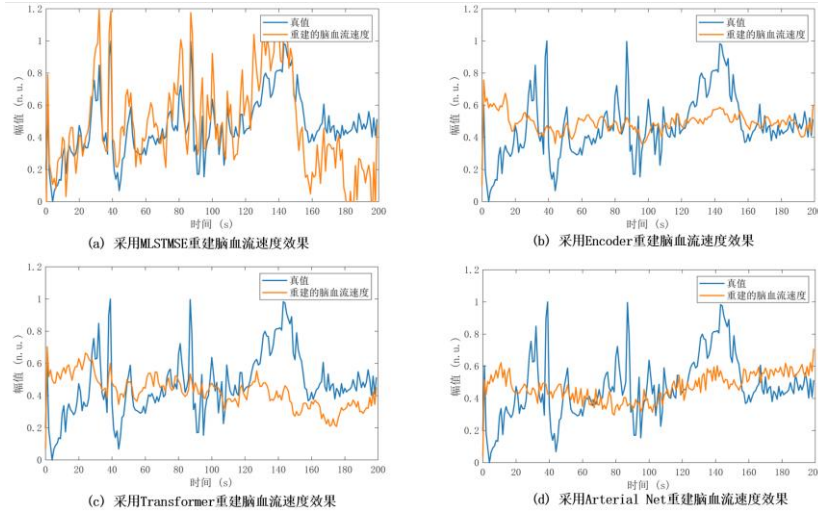


图 4 目标域上, MLSTMSE、Encoder、Transformer 和 Arterial Net 的重建脑血流速度信号效果对比
Fig. 4 Comparison of CBFV reconstruction performance in the target domain using MLSTMSE,

Encoder, Transformer, and Arterial Net, respectively

表 4 MLSTMSE 在目标域上的不同损失函数对比结果

Table 4 Comparison results of different loss functions for MLSTMSE on target domain

模型	性能指标					
	MSE (a. u.) ↓	PCC (a. u.) ↑	SMAPE (%) ↓	ER (%) ↓	DTW (a. u.) ↓	MI (a. u.) ↑
MSE + NCC	0.03205	0.51870	47.051	26.548	17.879	0.34375
MSE	0.03885	0.40157	36.092	36.324	18.713	0.32649
NCC	0.65375	0.46947	90.413	85.367	102.629	0.33268

注: 符号“↑”表示指标值越大, 性能越优; 符号“↓”表示指标值越小, 性能越差

5.2.2 MLSTMSE 使用不同损失函数的性能对比

在所提出的框架中, 我们设计了一种混合损失函数, 将 MSE 损失和 NCC 损失相结合。为了验证该损失函数的作用, 我们使用前文中提到的评估指标作为基准。在目标域测试集上, 对框架分别采用单一损失函数和不同的混合损失函数进行了测试, 其评估结果如表 4 所示。

高频模式对于准确重建细粒度或局部细节至关重要。MSE 损失函数最小化 LSTM 子模块和 Encoder 特征融合后输出的整体误差, 但会削弱模型捕捉数据中高频模式的能力^[42], 出现此问题的原因是 MSE 本质上侧重于降低整体误差幅度, 而不是强调数据的局部特征。因此只采用 MSE 损失函数的 Transformer, Encoder 和 Arterial Net 模型在重建波形整体上较为平稳, 但未能重建 ECG 信号中的 R 峰 (见图 3 (b)-(d)) 和 CBFV 中的波动剧烈的局部信号 (见图 4 (b)-(d))。NCC 能够捕捉局部波形特征, 从而 MSE+NCC 的混合损失函数训练的模型与仅用 MSE 损失函数训练的模型相比, 在多种评估指标上表现出优越的性能, 见表 4。

由 MSE 损失和 NCC 损失组成的混合损失函数在各项指标之间实现了良好的平衡, 具体表现为皮尔逊相关系数为 0.51870, 较单独使用 NCC 作为损失函数的模型提高了 9.49%; ER 为 26.548%, 较单独使用 NCC 作为损失函数的模型降低了 35.59%; DTW 距离为 17.879, 较单独使用 MSE 作为损失函数的模型降低了 4.46%; 互信息为 0.37775, 较单独使用 NCC 作为损失函数的模型提高了 9.49%。单独使用 MSE 损失时, MSE 为 0.03885, 与混合损失函数的表现相近, 但 ER 上升至 36.324%, 同时 DTW 距离增加, MI 值降低了 13.5%。仅使用 NCC 损失时, 模型在各项指标上的表现均不理想, MSE 高达 0.65375, SMAPE 为 90.413%, ER 为 85.367%, DTW 距离为 102.629。进一步表明单一损失函数的局限性。

这些结果表明, 将 MSE 损失和 NCC 损失相结合的混合损失函数在信号相关性的捕捉上更加有效, 从而验证了所提出混合损失函数的有效性。

6 总结

基于 ABP 和 CO₂ 信号的 CBFV 重建在脑血管调节评估、缺血性疾病诊断以及术中监测等领域具有重要作用。通过 ABP 和 CO₂ 信号实时重建 CBFV 信息可支持脑血管自动调节功能的评估, 并为重症患者、ICU 患者以及慢性呼吸系统疾病患者的脑健康管理提供帮助。然而, CBFV 重建面临着挑战。ABP 和 CO₂ 信号中存在的噪声及个体差异增加了对模型鲁棒性的需求, 增加了精准重建的复杂性。此外, 现有 CBFV 数据集规模有限, 导致训练数据不足, 限制了模型的泛化能力。这些挑战使得实现高精度 CBFV 重建成为一项艰巨任务。

本文提出了一种基于 Transformer 编码器的单任务深度学习框架, 用于 CBFV 的重建, 相较于现有方法具有多项优势。首先, 该框架无需大规模 CBFV 数据集进行训练。其次, 模型展现出更优越的 CBFV 重建精度。第三, 通过引入 LSTM 子模块, 弥补了 Encoder 全局注意力分散的弱点^[43], 强化了局部特征重建的细节。最后, 设计了混合损失函数, 在保证全局重建精度的同时, 也控制了局部波形重建的误差。所提出的框架包括三个主要组成部分: 数据预处理、源域的预训练以及目标域的微调。首先, 在数据预处理中, 信号被归一化到 [0, 1] 范围内, 有效减少了因输入值大幅波动而引发网络训练过程中梯度爆炸的风险。其次, 在预训练阶段, 模型在源域数据集上进行充分训练, 从而为目标域训练提供关于 ABP 的先验知识。最后, 在目标域微调阶段, 根据 NCC 指标选择最佳学习率、批量大小和损失函数权重比例, 进一步优化模型性能。我们在源域和目标域数据集上对 MLSTMSE 模型进行了评估。评估结果显示, 与传统的线性回归模型以及多种深度学习方法相比, 所提出的框架在脑血流重建任务中展现出更高的性能。

我们在表 4 中比较了目标域中不同损失函数组合的重建性能。MLSTMSE 模型使用多种损失函数组合进行了训练, 并基于 MSE、PCC、SMAPE、ER、DTW 和 MI 等指标进行了评估。结果表明, 由 MSE 损失和 NCC 损失组成的混合损失函数在 PCC、ER 和 MI 等关键指标上表现最佳, 优于单一损失函数。

然而, CBFV 的调节不仅受到 ABP 和 CO₂ 所参与的脑自动调节和 CO₂ 血管反应性机制的影响, 还受到其他多种生理机制的调控, 仅依赖这两种信号难以全面捕捉其复杂的动态变化特征。因此, 在未来的研究工作中, 我们将考虑增加额外的通道 (如血氧饱和度) 作为参与重建的生理信号, 从而为重建 CBFV 提供更多信息。另外, 针对受试者 CBFV 的个体差异, 我们未来的研究将重点优化模型的鲁棒性和泛化性, 以应对更广泛的 CBFV 重建应用场景。

参考文献

- [1] Bracko O, Jean C Cruz Hernández, Park L, et al. Causes and consequences of baseline cerebral blood flow reductions in Alzheimer's disease:[J].*Journal of Cerebral Blood Flow & Metabolism*, 2021, 41(7):1501-1516.DOI:10.1177/0271678X20982383.
- [2] Claassen JAHR, Thijssen DHJ, Panerai RB, et al. Regulation of cerebral blood flow in humans: physiology and clinical implications of autoregulation[J]. *Physiological reviews*, 2021, 101(4): 1487-1559.
- [3] Ogoh S, Ainslie PN. Cerebral blood flow during exercise: mechanisms of regulation.[J].*Journal of Applied Physiology*, 2009, 107(5):1370.DOI:10.1152/jappphysiol.00573.2009.
- [4] Aaslid R, Markwalder TM, Nornes H. Noninvasive transcranial Doppler ultrasound recording of flow velocity in basal cerebral arteries[J]. *Journal of neurosurgery*, 1982, 57(6): 769-774.
- [5] Panerai RB, Eyre M, Potter JF. Multivariate modeling of cognitive-motor stimulation on neurovascular coupling: transcranial Doppler used to characterize myogenic and metabolic influences[J]. *American Journal of Physiology-Regulatory, Integrative and Comparative Physiology*, 2012, 303(4): R395-R407.
- [6] Panerai RB, Minhas JS, Llwyd O, et al. The critical closing pressure contribution to dynamic cerebral autoregulation in humans: influence of arterial partial pressure of CO₂[J]. *The Journal of Physiology*, 2020, 598(24): 5673-5685.
- [7] Panerai RB, Moody M, Eames PJ, et al. Cerebral blood flow velocity during mental activation: interpretation with different models of the passive pressure-velocity relationship[J]. *Journal of Applied Physiology*, 2005, 99(6): 2352-2362.
- [8] Liu J, Simpson DM, Kouchakpour H, et al. Rapid pressure-to-flow dynamics of cerebral autoregulation induced by instantaneous changes of arterial CO₂[J]. *Medical engineering & physics*, 2014, 36(12): 1636-1643.
- [9] Ringelstein EB, Sievers C, Ecker S, et al. Noninvasive assessment of CO₂-induced cerebral vasomotor response in normal individuals and patients with internal carotid artery occlusions[J]. *Stroke*, 1988, 19(8): 963-969.
- [10] Graves A, Graves A. Long short-term memory[J]. *Supervised sequence labelling with recurrent neural networks*, 2012: 37-45.
- [11] Lan YT, Ren K, Wang Y, et al. Seeing through the brain: image reconstruction of visual perception from human brain signals[J]. *arXiv preprint arXiv:2308.02510*, 2023.
- [12] Tang Q, Chen Z, Ward R, et al. Subject-based model for reconstructing arterial blood pressure from Photoplethysmogram[J]. *Bioengineering*, 2022, 9(8): 402.
- [13] Mahmud S, Ibtihaz N, Khandakar A, et al. NABNet: A Nested Attention-guided BiConvLSTM network for a robust prediction of Blood Pressure components from reconstructed Arterial Blood Pressure waveforms using PPG and ECG signals[J]. *Biomedical Signal Processing and Control*, 2023, 79: 104247.
- [14] Lei X, Pan F, Liu H, et al. An end-to-end deep learning framework for accurate estimation of intracranial pressure waveform characteristics[J]. *Engineering Applications of Artificial Intelligence*, 2024, 130: 107686.
- [15] Chu Y, Tang K, Hsu Y C, et al. Non-invasive arterial blood pressure measurement and SpO₂ estimation using PPG signal: A deep learning framework[J]. *BMC Medical Informatics and Decision Making*, 2023, 23(1): 131.

-
- [16] Panerai RB, Simpson DM, Deverson ST, et al. Multivariate dynamic analysis of cerebral blood flow regulation in humans[J]. *IEEE transactions on biomedical engineering*, 2000, 47(3): 419-423.
- [17] Marmarelis VZ, Shin DC, Zhang R. Linear and nonlinear modeling of cerebral flow autoregulation using principal dynamic modes[J]. *The open biomedical engineering journal*, 2012, 6: 42.
- [18] Al-Abed MA, Al-Bashir AK, Al-Rawashdeh A, et al. Estimation of cerebral blood flow velocity during breath-hold challenge using artificial neural networks[J]. *Computers in biology and medicine*, 2019, 115: 103508.
- [19] Singla A, Bertino E, Verma D. Overcoming the lack of labeled data: Training intrusion detection models using transfer learning[C]//2019 IEEE International Conference on Smart Computing (SMARTCOMP). IEEE, 2019: 69-74.
- [20] Jung I, Lim J, Kim HK. PF-TL: Payload feature-based transfer learning for dealing with the lack of training data[J]. *Electronics*, 2021, 10(10): 1148.
- [21] Zhuang F, Qi Z, Duan K, et al. A comprehensive survey on transfer learning[J]. *Proceedings of the IEEE*, 2020, 109(1): 43-76.
- [22] Ponzio F, Urgese G, Ficarra E, et al. Dealing with lack of training data for convolutional neural networks: The case of digital pathology[J]. *Electronics*, 2019, 8(3): 256.
- [23] Leitner J, Chiang PH, Dey S. Personalized blood pressure estimation using photoplethysmography: A transfer learning approach[J]. *IEEE Journal of Biomedical and Health Informatics*, 2021, 26(1): 218-228.
- [24] Paszke A, Gross S, Massa F, et al. Pytorch: An imperative style, high-performance deep learning library[J]. *Advances in neural information processing systems*, 2019, 32.
- [25] Huang S, Jafari R, Mortazavi BJ. ArterialNet: Arterial Blood Pressure Reconstruction[C]//2023 IEEE EMBS International Conference on Biomedical and Health Informatics (BHI). IEEE, 2023: 1-4.
- [26] Vaswani A. Attention is all you need[J]. *Advances in Neural Information Processing Systems*, 2017.
- [27] Kachuee M, Kiani MM, Mohammadzade H ,et al. Cuff-less high-accuracy calibration-free blood pressure estimation using pulse transit time[C]//IEEE International Symposium on Circuits & Systems.IEEE, 2015:1006-1009.DOI:10.1109/ISCAS.2015.7168806.
- [28] Kachuee M, Kiani MM, Mohammadzade H, et al. Cuff-less Blood Pressure Estimation Algorithms for Continuous Health-Care Monitoring[J].*IEEE Trans Biomed Eng*, 2017, PP(4):859-869.DOI:10.1109/TBME.2016.2580904.
- [29] Novak V, Mendez L. Cerebral vasoregulation in diabetes (version 1.0. 0)[J]. *PhysioNet*, 2020.
- [30] Novak V, Last D, Alsop DC, et al. Cerebral blood flow velocity and periventricular white matter hyperintensities in type 2 diabetes[J]. *Diabetes care*, 2006, 29(7): 1529-1534.
- [31] Zhu Q, Tian X, Wong CW, et al. ECG reconstruction via PPG: A pilot study[C]//2019 IEEE EMBS international conference on biomedical & health informatics (BHI). IEEE, 2019: 1-4.
- [32] Ajdaraga E, Gusev M. Analysis of sampling frequency and resolution in ECG signals[C]//2017 25th Telecommunication Forum (TELFOR). IEEE, 2017: 1-4.
- [33] Kuo TBJ, Chern CM, Sheng WY, et al. Frequency domain analysis of cerebral blood flow velocity and its correlation with arterial blood pressure[J]. *Journal of Cerebral Blood Flow & Metabolism*, 1998, 18(3): 311-318.
- [34] Lashgari E, Liang D, Maoz U. Data augmentation for deep-learning-based

-
- electroencephalography[J]. *Journal of Neuroscience Methods*, 2020, 346: 108885.
- [35] Wong SC, Gatt A, Stamatescu V, et al. Understanding data augmentation for classification: when to warp?[C]//2016 international conference on digital image computing: techniques and applications (DICTA). IEEE, 2016: 1-6.
- [36] Ioffe S. Batch normalization: Accelerating deep network training by reducing internal covariate shift[J]. *arXiv preprint arXiv:1502.03167*, 2015.
- [37] Bjorck J, Gomes C, Selman B. Understanding Batch Normalization[J]. 2018.DOI:10.48550/arXiv.1806.02375.
- [38] Saeed M, Villarroel M, Reisner AT, et al. Multiparameter Intelligent Monitoring in Intensive Care II: a public-access intensive care unit database[J]. *Critical care medicine*, 2011, 39(5): 952-960.
- [39] Kachuee M, Kiani MM, Mohammadzade H, et al. Cuff-less high-accuracy calibration-free blood pressure estimation using pulse transit time[C]//2015 IEEE international symposium on circuits and systems (ISCAS). IEEE, 2015: 1006-1009.
- [40] Goldberger AL, Amaral LAN, 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.
- [41] Kingma D P. Adam: A method for stochastic optimization[J]. *arXiv preprint arXiv:1412.6980*, 2014.
- [42] Wang X, Ghasedi Dizaji K, Huang H. Conditional generative adversarial network for gene expression inference[J]. *Bioinformatics*, 2018, 34(17): i603-i611.
- [43] Hu X, Zhu M, Feng Z, et al. Re-perceive Global Vision of Transformer for Remote Sensing Images Weakly Supervised Object Localization[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024.