

基于人工智能深度学习的 术后护理风险预测方法研究

文 ◆ 南京市江宁医院 季永康

引言

对于临床行手术治疗的患者来说，手术结束并不代表治疗结束。很多接受手术治疗的患者虽然顺利完成了手术治疗，但手术本身是一种有创治疗，在术后容易出现伤口感染、出血等并发症，给患者的术后康复带来消极影响。因此，在为手术患者进行术后护理干预的过程中，术后早期风险预测有助于医护人员提早评估患者术后可能出现的护理风险，并采取积极措施进行有效应对，以降低手术患者术后并发症的发生概率。然而，传统的手术患者术后风险评估主要基于医护人员的临床经验，这种评估方式有较高的主观性，且无法基于患者术后生命体征的变化及时调整护理干预方案^[1]。本文基于人工智能深度学习技术，围绕手术患者术后护理风险预测提出了一种融合多模态数据与注意力机制的深度学习预测模型。通过整合电子病历、生命体征时序数据以及医学影像，利用长短时记忆网络（LSTM）捕捉时序特征，卷积神经网络（CNN）提取影像特征，并结合 Transformer 的多头注意力机制实现数据间深度交互。实验结果表明，该模型在术后并发症预测任务中，AUC 值达到 0.94，较传统方法提升 18%，为临床术后精准护理提供了有效技术支撑。

1 基本需求分析

随着目前临床医学技术的发展，患者对临床护理干预工作提出了更高的要求。对于行手术治疗的患者来说，手术创口会导致手术患者在术后存在较高的并发症发生概率。并发症的发生不仅给患者带来了健康威胁，还会影响患者的康复进程。为此，针对行手术治疗的患者进行科学、有效的术后护理风险评估十分必要。

根据临床手术患者的术后护理风险评估现状，临床进行手术患者术后护理风险评估主要有两种方式。一种是依托医护人员丰富的临床护理经验，根据患者的病历资料以及手术信息对患者术后护理风险做出相应评估。另一种则是基于固定的评分量表（如 POSSUM、NSQIP）进行评估。两种方式均存在一定程度的不足，因此，为提升手术患者术后护理风险预测精准性，需要建立基于深度学习的术后护理风险预测模型。本

文提出的基于深度学习的术后护理风险预测模型在患者术后护理风险的预测上具有突出的准确性、及时性和可解释性，并能够根据不同患者的个体情况差异为患者提供个性化的术后护理风险防范方案。

2 基于深度学习的术后护理风险预测模型构建

2.1 数据采集和预处理

在构建基于深度学习的术后护理风险预测模型过程中，要想实现患者术后护理风险的精准预测，前提是要全面采集患者的个体信息，包括患者的病历资料信息、手术信息等。在全面获取患者的个人信息后，为确保多模态

【作者简介】季永康（1996—），男，江苏南京人，本科，研究方向：手术室护理。

数据的高效融合，需要对所有获取的数据进行标准化处理，从而确保所有获取的数据具有统一的格式，满足模型应用对数据格式的需求。

在电子病历数据的处理方面，对数据中存在的所有数值型数据进行归一化处理，如患者的年龄信息、性别信息以及患者的手术时间信息等。而对于部分其他类型的数据（如患者的既往病史、手术的类型等），则引入独热编码（One-Hot Encoding），将这些数据转换成统一的变量，以满足模型应用对数据格式的需求。

在数据采集过程中，由于数据采集的频率具有差异性，因此必须统一所有采样频率。在具体实践中，采取时间序列插值法，引入滑动窗口技术（窗口大小设为 12h）将连续数据分割为固定长度的序列，并将每个窗口作为一个独立的输入样本，具体的实现方式如下。

在对患者的生命体征时序数据（如患者的心率、血压以及血氧饱和度等）进行处理过程中，考虑到医院不同检测设备对应的采样频率差异，需要在进行重采样时引入线性插值法，确保所有数据采样保持统一的频率。

统一了所有的采样频率后，需要分割连续的时序数据，设定窗口是 12h（设定每分钟为一个数据点，共计为 720 个时间步），同时滑动步长设定为 1h（60 个时间步）。通过对窗口的不断滑动，分割长时序数据到不同固定长度子序列。

而在处理医学影像数据时，结合模型数据应用的需求，考虑到多数医学影像图像为彩色图像，首先需将所有彩色图像

转换为灰度图像，以简化后续计算流程。其次，对所有图像进行标准化处理，消除不同图像间的差异。最后，提取图像特征，完成二维图像到 256 维图像的特征向量转化。图像转换为灰度图像通过式（1）完成。

$$Gray=0.299 \times R+0.587 \times G+0.114 \times B \quad (1)$$

式（1）中， R 、 G 、 B 对应的是图像中单一像素点对应的红、绿、蓝通道值。通过式（1）完成彩色图像到灰度图像的转换，从而降低后续计算复杂度。在获取转换成功的灰度图像后，还要对图像进行标准化处理，即减去图像均值后除以标准差，从而确保获取图像的像素值处于特定阈值。具体而言，经过标准化处理后获取的像素值为 $\hat{x}$ 可以通过式（2）获取。

$$\hat{x} = \frac{x - \mu}{\sigma} \quad (2)$$

式（2）中， σ 为标准差， μ 为图像的像素均值， x 为原始图像的像素值。获取到 $\hat{x}$ ，则可以采取预训练的 ResNet-50 网络完成标准后图像的特征提取。

2.2 模型构建

本文给出的基于深度学习的术后护理风险预测包括 3 个主要模块，分别是特征提取模块、注意力融合模块以及护理风险预测模块。

（1）特征提取模块在运行时，生命体征时序数据的特征提取采用双向长短时记忆网络（Bi-LSTM）实现。通过双向传播机制捕捉数据的前后依赖关系，输出时序特征向量。医学影像特征提取则参考以上方式。

（2）注意力融合模块则基于 Transformer 的多头注意力机制（Multi-Head Attention）的应用，采取 Query-Key-Value 对患者的个人病历特征、时序特征以及影像学特征的注意力权重进行计算，实现对不同模态数据中关键信息的聚焦，以确保数据的深度交互和融合^[2]。

（3）护理风险预测模块的作用是实现手术患者术后护理风险预测。在提取所有数据特征后，首先将相应的数据直接输入全局平均池化层（Global Average Pooling），降低数据维度。其次，通过全连接层与 Softmax 函数，输出术后并发症发生的概率。最后，根据手术患者术后护理风险的评级，分为高、中、低三类风险。

2.3 模型训练与优化

模型训练采用交叉熵损失函数作为优化目标，优化器选择 Adam（Adaptive Moment Estimation，自适应矩估计），初始学习率设为 0.001，并通过学习率衰减策略防止过拟合。为提高模型的泛化能力，采用五折交叉验证方法划分训练集与验证集，在训练过程中动态调整超参数（如注意力头数、LSTM 隐藏层维度等），最终以受试者工作特征曲线下面积（AUC）、准确率、召回率作为模型性能的评估指标^[3]。

2.3.1 定义损失函数

优化模型时，设定目标函数为交叉熵损失函数（Cross-Entropy Loss）。就术后护理风险预测而言，输出的是患者术后风险（高、中、低风险）发生概率。其本质是多酚类问题，为此损失函数的定义如式（3）所示。

$$L = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C y_{ij} \log(p_{ij}) \quad (3)$$

式（3）中， N 为样本数量，共计有 C （ $C=3$ ，即对应高、中、低风险）

个类别，对应第 i 个样本属于 j 类的真实标签，用 y_{ij} 表述，模型预测的第 i 个样本为 j 类的概率是 p_{ij} 。基于此能够确保模型最终的输出与真实标签最为贴近。

2.3.2 优化器选择和参数设置

模型训练使用 Adam 优化器完成。其能够自适应调整每个参数的学习率，在加速收敛的同时避免陷入局部最优解。设定初始学习率是 0.001，该值在实验初期通过网格搜索（Grid Search）进行初步筛选，并在后续训练过程中根据模型表现实现动态调整。Adam 优化器的核心参数如下。 β_1 用于计算梯度的一阶矩估计，默认值设为 0.9； β_2 用于计算梯度的二阶矩估计，默认值设为 0.999； ε 是一个非常小的常数（ $1e-8$ ），用于防止分母为零。

2.3.3 学习率衰减

为避免模型在训练后期出现过拟合的情况，同时适当提升收敛速度，需要引入指数衰减法（Exponential Decay），如式（4）所示。

$$learning_rate = initial_rate \times decay_rate^{\frac{global-step}{decay-steps}} \tag{4}$$

式（4）中，初始学习率为 $initial_rate$ ，取值为 0.001；衰减率为 $decay_rate$ ，此处取值 0.96，同时当前训练对应步数是 $global-step$ ，衰减步数为 $decay-steps$ ，将衰减步数设定为 1000 步学习率进行一次衰减。基于此不断减少学习率，从而促使模块快速完成学习，并在后续实现局部参数的针对性调整。

3 基于深度学习的术后护理风险预测模型的测试

本研究从某三甲医院电子病历系统、生命体征监测系统以及影像归档系统中，采集 2023—2024 年间 100 例术后患者数据，涵盖普外科（35 例）、骨科（28 例）、胸外科（220 例）、泌尿外科（15 例）等多个科室。将数据集按照 7:3 的比例划分为训练集（700 例）和测试集（300 例），并通过分层抽样确保各科室、风险等级的样本分布均衡。测试结果显示，该模型的 AUC 值为 0.94，准确率为 90.2%，召回率为 88.6%。模型应用于不同科室的预测效果如表 1 所示。

表 1 模型应用于不同科室的预测效果

科室	AUC	准确率	召回率
普外科	0.93	89.5%	87.8%
骨科	0.92	88.9%	86.7%
胸外科	0.95	91.2%	89.3%
泌尿外科	0.94	90.8%	88.9%

表 1 结果表明，本文给出的术后护理风险预测模型在不同手术科室中均保持较高预测精度，验证了其在多样化临床场景中的适用性。

此外，实验结果表明，MAFN 模型在各项指标均显著优于对比模型。其中，AUC 值较传统 Logistic 回归提升 18%，证明该模型能够更准确地地区分高风险与低风险患者；召回率的显著提高（达到 88.6%），意味着

模型能够有效识别潜在风险，减少漏报情况，为临床护理提供更可靠的预警支持。

结语

本文针对传统术后护理风险评估的局限性，提出一种融合多模态数据与注意力机制的深度学习模型。通过整合电子病历、生命体征时序数据与医学影像，结合 LSTM、CNN 与 Transformer 架构，实现了术后并发症的精准预测。实验结果验证了该模型在性能上的优越性，为临床个性化护理方案的制定提供了科学依据。

引用

[1] 陈永平.基于深度学习的实时大数据流处理框架优化与性能分析[J].中国信息界,2025(1):138-140.

[2] 徐鸣.人工智能深度学习算法在信息化数据分类中的应用与性能提升研究[J].中国战略新兴产业,2025(12):27-29.

[3] 马欣雨,王爽,程环毓,等.老年髋膝关节置换术后患者亚谵妄综合征风险预测模型的构建及验证[J].护理学杂志,2025,40(8):31-35.

