

基于Co-LSTM-FC网络的糖尿病伴周围神经病变临床决策支持系统研究

刘玉良¹, 丁永川¹, 郭宇佳¹, 赵耕², 杨伟明¹

1. 天津科技大学电子信息与自动化学院, 天津 300202; 2. 天津医科大学代谢病医院检验科, 天津 300070

【摘要】为了实现辅助医生对糖尿病伴周围神经病变(DPN)进行早期诊断与决策,针对DPN早期预测提出一种基于Co-LSTM-FC网络的临床决策支持系统(DPN-CDSS)。Co-LSTM-FC网络模型使用FC-LSTM网络和ConvLSTM网络共同对患者的临床数据进行特征提取,减轻单一模型运算时出现的权重偏差,同时利用全连接神经网络对患病特征进行分类,提高预测模型准确率。本文方法的准确率、特异度、F1值、G-mean值和AUC值分别为95.51%、94.24%、95.06%、95.08%和94.37%,与对比模型相比获得的结果准确度更高。DPN-CDSS用户界面包括用户登录、数据输入和结果显示界面,方便医生和患者进行使用。该系统可提前筛查患者的得病情况,辅助医生进行初期诊断,提升诊疗效率。

【关键词】糖尿病伴周围神经病变;临床决策支持系统;FC-LSTM网络;ConvLSTM网络

【中图分类号】R318;R587.2

【文献标志码】A

【文章编号】1005-202X(2023)09-1174-08

Clinical decision support system for diabetic peripheral neuropathy based on Co-LSTM-FC network

LIU Yuliang¹, DING Yongchuan¹, GUO Yujia¹, ZHAO Geng², YANG Weiming¹

1. School of Electronic Information and Automation, Tianjin University of Science and Technology, Tianjin 300202, China; 2. Department of Laboratory, Metabolic Disease Hospital of Tianjin Medical University, Tianjin 300070, China

Abstract: A clinical decision support system (DPN-CDSS) based on Co-LSTM-FC network is proposed for the early prediction of diabetic peripheral neuropathy (DPN), thereby assisting doctors in the early DPN diagnosis and decision-making. Co-LSTM-FC network model innovatively uses FC-LSTM network and ConvLSTM network to jointly extract the features from the clinical data, which reduces the weight deviation that occurs in the calculation of a single model. Meanwhile, the fully connected neural network is adopted to classify the characteristics of the disease for improving the accuracy of the prediction model. The accuracy, specificity, F1 value, G-mean value and AUC value of the proposed method for DPN prediction are 95.51%, 94.24%, 95.06%, 95.08% and 94.37%, respectively, and the accuracy is higher as compared with other models. Moreover, DPN-CDSS user interface which includes user login, data input and result display interface is convenient for doctors and patients to use. The system can screen for DPN in advance, assist doctors in the initial diagnosis, and improve the efficiency of diagnosis and treatment.

Keywords: diabetic peripheral neuropathy; clinical decision support system; FC-LSTM network; ConvLSTM network

前言

临床决策支持系统(Clinical Decision Support

System, CDSS)利用先进且全面的临床技术、患者的个人资料以及疾病状况,帮助医生做出更明智的诊断,旨在有效地改善医疗质量,加强医疗相关的决策和行动,提升服务水平^[1-2]。临床数据通常指对病人身体指标如患者的体温、心率、体质量、白细胞数量等各项指标的记录,具有多样性、不完整性、冗余性、缺失性、保密性等特点。通过CDSS和临床知识库输入患者的临床数据进行决策,最后再提供给临床医生作决定。利用机器学习和深度学习技术实现自动化,不必依赖于传统的知识库^[3],有效帮助计算机学习过去的经验,并且可

【收稿日期】2023-05-10

【基金项目】国家自然科学基金(52378254);天津市科委技术创新引导专项(21YDTPJC00500)

【作者简介】刘玉良,博士,副教授,硕导,主要研究方向:智能装备制造,基于深度学习的临床疾病诊断,代谢组精确医学诊断, E-mail: ylliu@tust.edu.cn

【通信作者】杨伟明,高级实验师, E-mail: yangwm@tust.edu.cn

以在实际应用中发掘出独特的模型^[4]。随着互联网的发展和进步,人工智能技术在医疗领域的应用不断扩展,衍生出无需以知识库为基础的CDSS。无需知识库的CDSS允许计算机从过去的经验中学习或从临床数据中发现特有模式。这种学习模式无需行业内专家进行规则编写和专业的输入,可以有效减少人力成本^[5]。

糖尿病周围神经病变(Diabetic Peripheral Neuropathy, DPN)是糖尿病慢性并发症中最常见的一种^[6],会出现与周围神经功能障碍相关的症状,可累及感觉神经、运动神经和自主神经,严重影响了患者的生活质量,因此筛查高危患者对于疾病治疗至关重要^[7],及时采取高效的疾病诊断在一定程度上可以缓解医疗资源紧张的问题。侯伟等^[8]提出基于一维卷积神经网络的DPN预测模型,可自主学习数据的特征信息,DPN的诊断结果准确率较高,证明一维卷积神经网络对DPN的早期筛查起到辅助作用;桑祎莹等^[9]构建随机森林模型和误差反向传播神经网络模型,通过对比实验证明随机森林模型在判别DPN患病风险研究中具有更高的实用性;Liu等^[10]提出基于完全卷积神经网络处理的高频超声对二型糖尿病患者的DPN具有较高的诊断价值,表明高频超声可用于评估二型糖尿病患者周围神经的形态学变化。然而目前将DPN预测模型和用户界面结合的CDSS研究还较少。

本文设计一种基于深度学习方法的DPN临床决策支持系统(DPN-CDSS)。DPN-CDSS包括基于Co-LSTM-FC网络的疾病预测模型和DPN-CDSS用户界面(UI)设计。Co-LSTM-FC模型使用全连接长短期记忆(FC-LSTM)网络和卷积长短期记忆(ConvLSTM)网络共同对数据进行特征提取,一定程度上解决了梯度消失的问题,弥补了单一模型对数据计算时可能出现的权重偏差;使用全连接神经网络(Fully Connected Neural Network, FCNN)进行分类,表现出较高的鲁棒性。Co-LSTM-FC预测模型对DPN患病预测结果的准确率为95.51%,特异度为94.24%,F1值为95.06%、几何平均数(Geometric mean, G-mean)值为95.08%,曲线下面积(Area Under Curve, AUC)值为94.37%,预测结果的有效性较高。UI设计包括用户登录、临床数据输入和预测结果显示界面,保证用户使用系统的隐私,自动地完成提取输入数据的特征工作同时方便医生和患者使用决策系统,可辅助医生进行初期诊断,提升诊疗效率。

1 神经网络预测模型

图1为DPN预测模型的流程图。医疗临床数据来源于天津医科大学代谢病医院,记录了就诊人群的体征和临床指标;数据预处理结果包括独热编码和Z-score归一化;网络预测模型为Co-LSTM-FC模型;预测结果:预测患者是否患有DPN,具体介绍如下。




图1 DPN预测模型流程图

Figure 1 Flowchart of DPN prediction model

1.1 DPN临床数据

本文使用的DPN医疗临床数据来源于天津医科大学代谢病医院,数据采集时间为2017年12月15日~2018年1月20日。检验数据集经过脱敏处理后,总共包含898个数据样本,49个特征变量,记录了就诊人群的体征和临床指标。项目开展前得到了天津伦理委员会的许可,同时也获得了患者的书面知情同意书。在分析数据前,笔者对患者的姓名以及其他基本信息做了匿名处理。对原始数据进行分析整理,并对样本数据进行标定标签。实验中临床样本剔除了孕妇、哺乳期以及长期服用抑制高脂血症药物的患者数据。所有的血液学参数均由经过专业训练的检验科医生按照黄金标准获得。所有的诊断结果均由具有6~10年临床经验的代谢病科医师确定。

1.2 数据预处理

数据预处理过程如图2所示, I 代表每位患者的临床数据, I_1, I_2, \dots, I_{49} 表示该患者的每项检测指标值,其中离散型数据需要经过独热编码,将离散型数据转为可供网络计算的连续型数据;连续型数据进行Z-score归一化,将数据映射到 $[0, 1]$ 范围之内,最后将处理好的数据向量转化为可输入预测网络的矩阵 X ,为后续Co-LSTM-FC网络的训练和预测做准备。

1.2.1 独热编码 独热编码(One-Hot Encoding)又称“一位有效编码”^[11-12],其方法是使用 N 位状态寄存器来对 N 个状态进行编码,每个状态都有独立的寄存器位,并且在任意时候,只有一位有效。由于数据存在尿液颜色等离散型指标,因此采用独热编码技术将离散型数据转为001、010、100等可被计算机读取

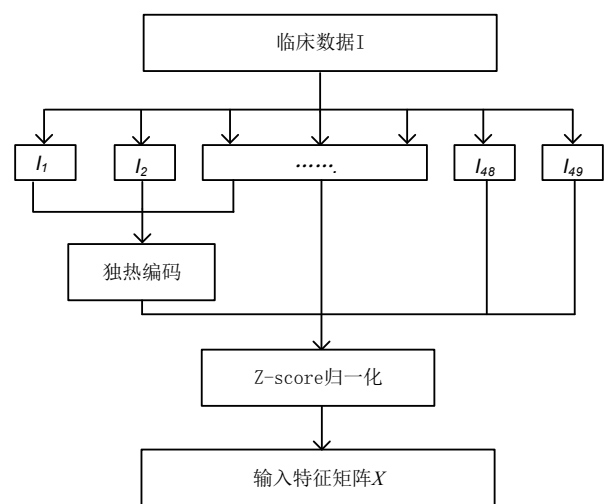


图2 临床数据预处理过程
Figure 2 Clinical data preprocessing

的数据,解决了分类器无法处理离散属性数据的问题。离散属性赋值如表 1 所示。其优点在于能够处理非连续型数值特征且易于设计实现,不需要解码器等操作,同时在一定程度上进行了特征的扩充。

1.2.2 Z-score数据归一化 临床医疗数据会存在指标标准不一样、异常值等问题,在这种情况下,如果直接将这些数据用来预测,可能在一定程度上导致预测正确率偏低^[13]。由于各指标间数值差异较大,为了更好的和模型进行结合,需要进行数据归一化处理。此外,DPN 诊断结果作为预测模型的因变量指标,其中1代表DPN患者,0代表非DPN患者。

特征归一化通过创建新值来保持原数据中的一般分布和比率,同时将值保持在模型中使用的所有数字列刻度范围内。采用Z-score进行特征归一化,

表1 离散型数据独热编码表
Table 1 Discrete data one-hot encoding

性别	男=01,女=10
尿白细胞	
尿红细胞	
尿亚硝酸盐	"-"=001
尿蛋白	"+/-"=010
尿葡萄糖	"+"=100
酮体	
尿胆原	
胆红素	
尿液颜色	浅黄色=0001 琥珀色=0010 棕色=0100 红色=1000

将所有值转换为z分数,转换公式如式(1)所示:

$$z = \frac{x - \text{mean}(x)}{\text{stdev}(x)}$$

(1)

其中,mean(x)为某一特征的总体平均值,stdev(x)为某一特征的总体标准差,x为某一特征的具体值。数据经过Z-score标准化处理以后各个特征的幅度控制在相同的范围内,这样可以节省模型计算的空间复杂度和时间成本。

1.3 Co-LSTM-FC预测网络

通过综合考虑预测精度和预测效率两方面因素,本文提出一种基于ConvLSTM网络、FC-LSTM网络和FCNN组合的Co-LSTM-FC预测模型对临床数据进行预测,数据预测过程如图3所示。

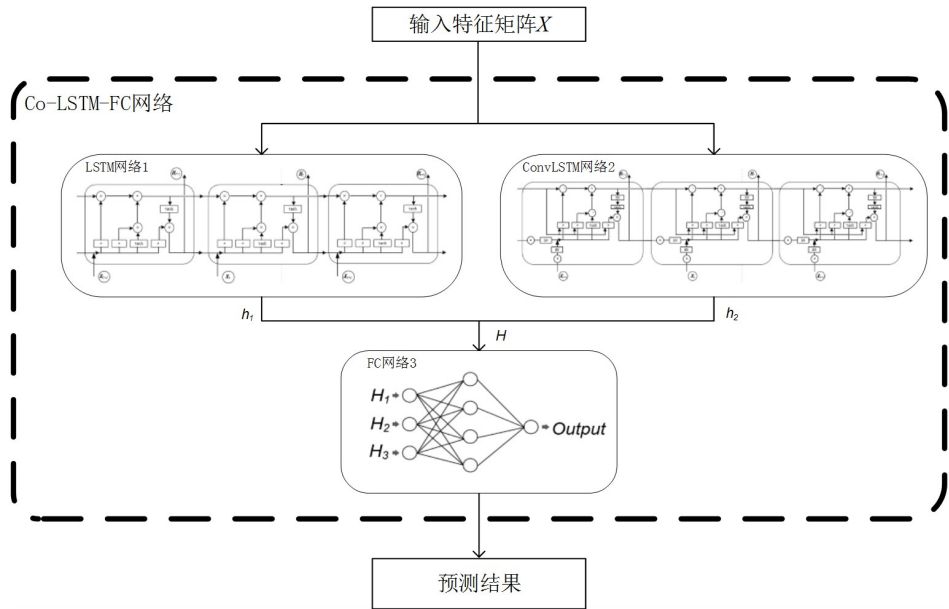


图3 Co-LSTM-FC网络模型
Figure 3 Co-LSTM-FC network model

临床数据经过预处理后同时输入FC-LSTM模块和ConvLSTM模块,可获得由FC-LSTM和ConvLSTM分析获得的特征,提取到的特征综合起来输入FCNN实现分类。Co-LSTM-FC模型弥补了单一模型对数据计算时可能出现的权重偏差,提高了对临床数据的预测精度,将两部分特征相乘融合计算提高了计算效率,减少了运算时间;模型融合能充分利用各模型的结构特点,融合后的模型精度及稳定性均更优。

1.3.1 FC-LSTM网络 FC-LSTM网络是一种特殊的RNN,是在长短期记忆(LSTM)网络基础上变换形成的方法^[14-15]。该模型克服了训练过程中出现梯度消失和梯度爆炸,解决了长期依赖问题,更好的实现了长时间序列的记忆能力。FC-LSTM网络神经单元结构如图4所示,一个单元当中被放置了3扇门,分别为输入门、遗忘门和输出门。信息进入FC-LSTM的网络中,通过“门”可以判断输入的信息是否有用,衡量序列中数据重要性,只有符合算法认证的信息才会留下,能够深入挖掘有限数据样本的长期依赖关系和趋势。

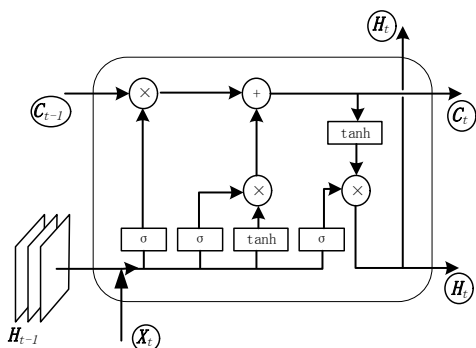


图4 FC-LSTM网络单元结构
Figure 4 FC-LSTM cell structure

FC-LSTM的更新递归公式如式(2)~式(6)所示:

输入门:

$$I_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + b_i) \quad (2)$$

遗忘门:

$$F_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + b_f) \quad (3)$$

输出门:

$$O_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + b_o) \quad (4)$$

记忆单元结构:

$$C_t = F_t * C_{t-1} + I_t * \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \quad (5)$$

$$H_t = O_t * \tanh(C_t) \quad (6)$$

其中, I_t 、 F_t 和 O_t 分别表示输入、遗忘门和输出门的门控信息;“ $*$ ”表示点乘操作; W 为权重矩阵, b 为偏差权重向量; σ 表示sigmoid激活函数。 H_t 表示 t 时刻的

输出值,结果通过非线性函数tanh转化为-1~1之间的值。 C_t 为细胞的长时状态,即LSTM神经网络的长时记忆。

1.3.2 ConvLSTM网络 ConvLSTM网络是在传统LSTM网络的基础上引入卷积操作^[16],在保留传统LSTM网络优点的同时,还可以保留数据信息的空间特征。其单元结构如图5所示。

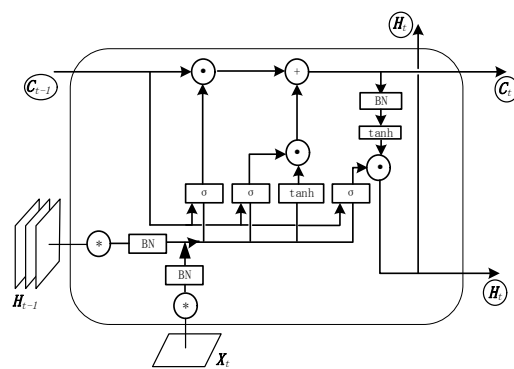


图5 ConvLSTM网络单元结构
Figure 5 ConvLSTM cell structure

ConvLSTM网络的更新递归公式如式(7)~式(11)所示:

输入门:

$$I_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} * C_{t-1} + b_i) \quad (7)$$

遗忘门:

$$F_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} * C_{t-1} + b_f) \quad (8)$$

输出门:

$$O_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} * C_{t-1} + b_o) \quad (9)$$

记忆单元结构:

$$C_t = F_t * C_{t-1} + I_t * \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \quad (10)$$

$$H_t = O_t * \tanh(C_t) \quad (11)$$

与LSTM网络的计算公式相比,ConvLSTM网络计算公式中 W 、 b 代表了可学习的卷积核参数;“ $*$ ”表示卷积运算符,“ \odot ”表示哈达玛(Hadamard)积, C_t 、 H_t 、 I_t 、 F_t 和 O_t 均是3维张量。ConvLSTM在输入到状态、状态到状态的转换中将LSTM的全连接网络替换为卷积运算,卷积结构相比于向量更加能够保留数据的局部特征及其之间的空间关系。

1.3.3 FCNN FCNN是一种端到端的连接网络,由神经元输入端的运算数据直接计算得到输出端的结果^[17]。FCNN可以很好的拟合复杂的函数表达式^[18-19],通过对多层神经网络的层数设置,把前边提取到的特征综合起来。

FCNN单元结构如图6所示。FCNN的前向传递,层与层之间神经元为全连接,将数据信息传入输

入层进行处理,处理后的数据经过 n 个隐含层后传到输入输出层,再将经过从输入输出层获得的实际结果和预期数据结果比较后得出偏差,反向传递利用梯度下降的效果由输入输出层经过隐含层后传到输入层。




图6 FCNN单元结构
Figure 6 FCNN cell structure

FCNN单元结构的更新公式为:

$$u = W_i X + b \tag{12}$$

$$H_{w,b}(x) = f(W_T X + b) \tag{13}$$

其中, X_1, X_2, \dots, X_N 表示上层神经网络单元节点的输出向量的各个分量,该神经单元节点与上层神经网络之间的权重用 $w = (W_1, W_2, \dots, W_N)$ 表示, u 对应上层节点的线性组合输出结果。

1.4 模型预测结果和分析

表2为不同模型的训练结果对比,组合模型获得了95.51%的准确率,94.24%的特异度,95.06%的F1值,95.08%的G-mean值和94.37%的AUC值,比其他网络模型结果更高,分类预测效果更好。

表2 不同模型结果对比(%)
Table 2 Comparison among different models (%)

指标	LSTM模型	ConvLSTM模型	FCNN模型	组合模型
准确率	88	82	78	95.51
特异度	91.67	84.62	56	94.24
F1值	91.67	93.30	81.97	95.06
G-mean值	89.79	88.99	74.83	95.08
AUC值	88.69	90.07	84.96	94.37

本次实验数据按 7:3 的比例划分训练集和测试集,训练集包含 817 个样本,测试集中包含 350 个样本,测试数据与训练数据完全独立,互不交叉。在训练过程中,小批量数据的规模为 20 条。Co-LSTM-FC 网络训练参数设置学习率为 0.000 13,迭代次数设置为 800,损失函数为均方误差损失函数,使用 Adam 算法优化全局参数。同时,预测是否患 DPN 为二分类任务,因此输出层使用 Sigmoid 函数,其余层都使用

ReLU 函数作为激活函数。
图7为 Co-LSTM-FC 网络经过 800 次训练迭代的训练损失值和准确率图。从曲线图可以看出,初期训练损失值不断衰减,准确率不断升高,迭代达到 200 次后,损失值在 0.04 附近浮动,准确率在 0.94 左右,说明模型达到较好的性能。




图7 训练集的训练损失值和准确率曲线图
Figure 7 Loss value and accuracy on training set

本次实验测试集共 350 个样本,其中正样本 165 例,负样本 185 例,正样本 154 例被正确区分,11 例被错误区分;负样本 180 例被正确区分,5 例被错误区分,分类准确率为 95.51%。图8为模型的分类受试者工作特性(ROC)曲线,其 AUC 为 94.37%。




图8 ROC曲线
Figure 8 ROC curve

上述结果表明 Co-LSTM-FC 模型有较好的学习能力和泛化能力,有效对输入的临床数据进行分类,可提供对 DPN 疾病预测准确,快速的决策支持。

2 基于 Co-LSTM-FC 模型的 DPN-CDSS

2.1 CDSS 设计

本文设计的 DPN-CDSS 使用 Python 语言开发实

现^[20]。在 Windows10 的 64 位操作系统上进行开发。以深度学习基础平台 PyTorch 作为深度学习框架^[21], 训练数据存储部分使用 Oracle 数据库完成, 同时 Oracle 数据库创建用户信息管理数据库统一规范管理用户信息, 创建 GUI 应用程序的工具包 Tkinter 为人机交互界面开发库, 完成系统代码编写^[22]。表 3 为开发环境详细介绍。

表 3 开发环境	
Table 3 Development environment	
环境	参数
操作系统	Windows10, 64 Bit
处理器	Intel(R) Core(TM) i5-10200H CPU @ 2.40 GHz
显卡	NVIDIA GeForce RTX 2060
内存	16 G
开发语言	Python3.8
数据库	Oracle

CDSS 前期设计系统框架考虑的系统运行应该具备安全性、易用性、可扩展性等非功能性需求。针对以上需求设计医疗预测系统框架, 可实现用户登录, 临床数据录入和预测患病结果功能(图 9)。




图 9 DPN-CDSS 功能结构图
Figure 9 DPN-CDSS functional structure

针对 DPN-CDSS 框架设计功能模块, 如图 10 所示。用户登录注册模块: 包括用户登录和用户注册功能, 对用户的身份进行验证, 输入账号如没有注册, 则会跳转到注册界面。在注册界面用户填写相关注册信息, 如注册账号已经存在, 则该账号不能注册。保证用户信息的安全性, 防止出现信息泄露或数据丢失问题, 提高系统的信任度。临床数据录入模块: 实现登录用户的临床数据录入, 保证输入到预测网络模块的数据信息准确性和维度的标准, 为后续预测做好准备。如输入数据不满足输入特征维度, 则无法输入预测网络并在显示模块返回缺失数据项。该模块设计为独立接口, 保证升级扩展能力, 满足未来对新设备和算法的需求。结果预测和显示

模块: 用户点击“开始预测”按钮, 开始运行, 录入数据进行归一化和热编码处理, 并将特征矩阵录入组合神经网络模型中, 若录入信息准确, 将是否患 DPN 的预测结果返回文本框内; 若录入信息不准确, 将通过组合神经网络, 返回录入缺失项在文本框内。对用户来说系统的前端界面简单易懂, 无需复杂的操作交互逻辑, 可快速地理解操作流程, 轻松上手使用, 提升用户使用体验。

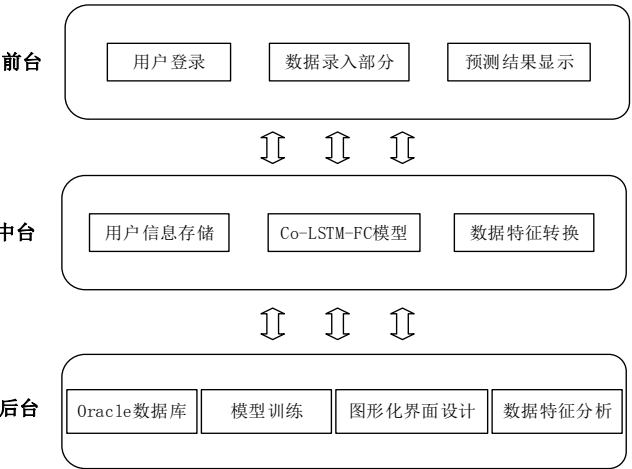


图 10 DPN-CDSS 总体架构图
Figure 10 DPN-CDSS overall architecture

2.2 用户界面展示

基于 Co-LSTM-FC 网络的 DPN-CDSS 采用 Python 自带的标准库 Tkinter 设计用户界面(UI)。图 11a 为系统登录界面, 输入账号和密码后登录, 并有弹窗提示登录成功(图 11b)。图 12 为临床数据录入部分与预测结果显示部分, 点击“开始诊断”按钮可将录入数据进行 DPN 患病诊断预测, 多次录入数据, 预测结果将按顺序显示在文本框内; 点击“清空日志”按钮可将文本框内所有结果删除, 再次录入数据进行预测, 结果将重新显示在文本框内。

3 结 论

本文提出一种基于 Co-LSTM-FC 网络的 DPN-CDSS。本系统的 Co-LSTM-FC 网络将 FC-LSTM 与 ConvLSTM 网络共同预测 DPN 患者的临床数据特征, 避免了单一模型分类运算时出现的权重偏差结果。其核心任务是针对 DPN 的诊断预测, 其目的是根据患者的医疗数据预测当前患者是否患有 DPN, 可为医生和患者提供辅助诊断和参考。DPN-CDSS 系统可自动判定是否患有 DPN 疾病, 并将结果在显示界面中输出, 为 DPN 患者早期预测提供一种新方



图 11 登录和成功界面

Figure 11 Login interface



图 12 智能诊断系统界面

Figure 12 Intelligent diagnosis system interface

法,可用于辅助医生进行初期诊断,提前筛查患者的得病情况,提升医生的诊疗效率。

后续的Co-LSTM-FC模型改进方向将致力于提高预测模型准确率以及增强Co-LSTM-FC模型预测结果的可解释性;UI设计改进方向为加强用户使用系统的操作简洁性,使界面更美观,提高DPN-CDSS的可使用性。此外,未来的研究方向将也将研究如何将更多类型的参数,如患者的病史等加入到预测模型中;同时收集更多健康状态的样本,以期达到进

一步提升模型性能的目的。CDSS更多后续功能开发,如针对患者后续治疗或预防DPN的诊疗建议也将加入CDSS中,为医生和患者提供更有针对性的建议以及更有效的帮助。

【参考文献】

[1] 李桃,郑西川,蒋伏松. 基于知识库的临床决策支持系统的设计与应用[J]. 医疗卫生装备, 2019, 40(5): 29-32.

Li T, Zheng XC, Jiang FS. Design and application of clinical decision support system based on knowledge base [J]. Chinese

- Medical Equipment Journal, 2019, 40(5): 29-32.
- [2] Kushwaha S, Bahl S, Bagha AK, et al. Significant applications of machine learning for COVID-19 pandemic[J]. Journal of Industrial Integration and Management, 2020, 5(4): 453-479.
- [3] 李翔云, 叶庆, 邓朝华. 临床决策支持系统功能及其应用态势分析[J]. 中国医院, 2020, 24(10): 35-38.
Li XY, Ye Q, Deng CH. The function of clinical decision support system and its application situation analysis[J]. Chinese Hospitals, 2020, 24(10): 35-38.
- [4] 王艳萍, 焦敬义, 井立强, 等. 医院临床决策知识库系统的设计与应用[J]. 中国卫生信息管理杂志, 2018, 15(1): 74-77.
Wang YP, Jiao JY, Jing LQ, et al. Research and application of knowledge base system clinical decision in hospital[J]. Chinese Journal of Health Information Management, 2018, 15(1): 74-77.
- [5] 陈佳. 基于深度学习的儿科临床辅助诊断算法研究[D]. 兰州: 兰州大学, 2018.
Chen J. Research on pediatric clinical assistant diagnosis algorithm based on Deep learning[D]. Lanzhou: Lanzhou University, 2018.
- [6] 姚君厘, 杨永平. 2型糖尿病患者HbA1c与神经传导速度关系探讨[J]. 中华内分泌代谢杂志, 1994, 10(4): 232-233.
Yao JL, Yang YP. Study on the relationship between HbA1c and nerve conduction velocity in Type 2 diabetes mellitus[J]. Chinese Journal of Endocrinology and Metabolism, 1994, 10(4): 232-233.
- [7] Xu WF, Zhang JX, Zhang Q, et al. Risk prediction of type II diabetes based on random forest model[C]//3rd International Conference on Advances in Electrical. IEEE, 2017: 382-386.
- [8] 侯伟, 赵耕, 刘玉良, 等. 基于一维卷积神经网络的糖尿病周围神经病变预测模型研究[J]. 中国医学物理学杂志, 2022, 39(1): 127-132.
Hou W, Zhao G, Liu YL, et al. Prediction model of diabetic peripheral neuropathy based on one-dimensional convolutional neural network[J]. Chinese Journal of Medical Physics, 2022, 39(1): 127-132.
- [9] 桑祎莹, 黄仕鑫, 易静, 等. 基于随机森林和误差反向传播神经网络的糖尿病性周围神经病变患病风险研究[J]. 解放军医学杂志, 2018, 43(10): 877-881.
Sang YY, Huang SX, Yi J, et al. Risk study of diabetic peripheral neuropathy based on random forest and BP neural network[J]. Medical Journal of Chinese People's Liberation Army, 2018, 43(10): 877-881.
- [10] Liu X, Zhou H, Wang Z, et al. Fully convolutional neural network deep learning model fully in patients with type 2 diabetes complicated with peripheral neuropathy by high-frequency ultrasound image[J]. Comput Math Methods Med, 2022. Doi: 10.1155/2022/5466173.
- [11] 梁杰, 陈嘉豪, 张雪芹, 等. 基于独热编码和卷积神经网络的异常检测[J]. 清华大学学报(自然科学版), 2019, 59(7): 521-529.
Liang J, Chen JH, Zhang XQ, et al. One-hot encoding and convolutional neural network based anomaly detection[J]. Journal of Tsinghua University (Science and Technology), 2019, 59(7): 521-529.
- [12] Wang W, Sheng Y, Wang J, et al. HAST-IDS: learning hierarchical spatial-temporal features using deep neural networks to improve intrusion detection[J]. IEEE Access, 2018, 6(99): 1792-1806.
- [13] 程顺达, 祝捷, 夏芳. 基于深度学习的医疗辅助诊断数据分析方法[J]. 电子设计工程, 2022, 30(7): 72-76.
Cheng SD, Zhu J, Xia F. Data analysis method of medical assistant diagnosis based on deep learning[J]. Electronic Design Engineering, 2022, 30(7): 72-76.
- [14] Jia YW, Xu Y, Zhang Y, et al. Short-term residential load forecasting based on LSTM recurrent neural network[J]. IEEE Trans Smart Grid, 2019, 10(1): 841-851.
- [15] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Comput, 1997, 9(8): 1735-1780.
- [16] 唐伦, 蒲昊, 汪智平. 基于注意力机制ConvLSTM的UAV节能预部署策略[J]. 电子与信息学报, 2022, 44(3): 960-968.
Tang L, Pu H, Wang ZP. Energy-efficient predictive deployment strategy of UAVs based on ConvLSTM with attention mechanism[J]. Journal of Electronics & Information Technology, 2022, 44(3): 960-968.
- [17] 潘蕾, 倪冰苇, 赵鸿. 融合堆叠自编码神经网络算法和全连接神经网络算法的化合物成药性预测模型[J]. 中国新药杂志, 2021, 30(14): 1309-1315.
Pan L, Ni BW, Zhao H. Prediction model of the probability of a lead compound becoming a drug based on Stacked AutoEncoder and Fully Connected Neural Network[J]. Chinese Journal of New Drugs, 2021, 30(14): 1309-1315.
- [18] 杨俊豪, 李东升, 陈春晓, 等. 基于生成对抗网络的乳腺癌组织病理图像样本均衡化[J]. 生物医学工程研究, 2020, 39(2): 161-166.
Yang JH, Li DS, Chen CX, et al. Generative adversative nets based sample equalization of breast tumor tissue slice[J]. Journal of Biomedical Engineering Research, 2020, 39(2): 161-166.
- [19] 李仪, 林建君, 朱习军. 基于改进DNN的糖尿病预测模型设计[J]. 计算机工程与设计, 2021, 42(5): 1418-1424.
Li Y, Lin JJ, Zhu XJ. Diabetes prediction model design based on improved DNN[J]. Computer Engineering and Design, 2021, 42(5): 1418-1424.
- [20] Muller AC, Guido S. Python 机器学习基础教程[M]. 北京: 人民邮电出版社, 2018.
Muller AC, Guido S. Introduction to machine learning with Python[M]. Beijing: Posts & Telecom Press, 2018.
- [21] 郭静. 基于PyTorch的儿童阻塞性睡眠呼吸暂停综合征的辅助诊断研究[D]. 太原: 中北大学, 2021.
Guo J. PyTorch-based diagnostic study of obstructive sleep apnea syndrome in children[D]. Taiyuan: North University of China, 2021.
- [22] 周春吟. 基于Python语言图形用户界面设计的研究[J]. 科学技术创新, 2022(35): 81-85.
Zhou CY. Research on graphical user interface design based on Python[J]. Innovation in Science and Technology, 2022(35): 81-85.

(编辑: 薛泽玲)