

基于DBN-ELM的肝病诊断模型研究

谢双波

湖南科技学院智能制造学院, 湖南 永州

收稿日期: 2025年5月25日; 录用日期: 2025年6月18日; 发布日期: 2025年6月25日

摘要

肝病是一种具有高度传染性和致命性的疾病, 传统的肝病诊断方法通常是耗时或具有侵入性的成像技术和活检, 而深度学习提供了一种有效且无侵入性的检测途径。本研究基于UCI机器学习库的肝病公开数据集, 其包含416个健康样本和167个肝病样本以及10个血液检测临床特征。本研究使用主成分分析(Principal Component Analysis, PCA)提取了重要特征, 经过数据预处理后, 构建并训练了一个基于深度信念网络-极限学习机(Deep Belief Network-Extreme Learning Machine, DBN-ELM)的肝病检测模型, 该模型结合了DBN的无监督预训练和ELM的快速训练能力。DBN-ELM模型在肝病数据集上分别取得了87.31%的准确率、65.27%的敏感度、96.15%的特异性、72.73%的F1-Score和0.9188的受试者工作特征曲线下面积(Area under the Receiver Operating Characteristic Curve, AUC)。这些较好的性能表明, DBN-ELM可以有效地检测肝脏疾病, 帮助临床医生实现肝病的早期诊断。

关键词

肝病, 深度学习, DBN-ELM, 诊断模型

Research on Liver Disease Diagnosis Model Based on DBN-ELM

Shuangbo Xie

College of Intelligent Manufacturing, Hunan University of Science and Engineering, Yongzhou Hunan

Received: May 25th, 2025; accepted: Jun. 18th, 2025; published: Jun. 25th, 2025

Abstract

Liver disease is a highly contagious and deadly disease. Traditional diagnostic methods for liver disease are usually time-consuming or invasive imaging techniques and biopsies, while deep learning provides an effective and non-invasive detection pathway. This study is based on the liver disease public dataset of UCI machine learning library, which includes 416 healthy samples, 167 liver

disease samples, and 10 clinical features of blood tests. This study used Principal Component Analysis (PCA) to extract important features, and after data preprocessing, constructed and trained a liver disease detection model based on Deep Belief Network Extreme Learning Machine (DBN-ELM), which combines the unsupervised pre-training of DBN and the fast training ability of ELM. The DBN-ELM model achieved an accuracy of 87.31%, sensitivity of 65.27%, specificity of 96.15%, F1-Score of 72.73%, and Area under the Receiver Operating Characteristic Curve (AUC) of 0.9188 on the liver disease dataset. These good performances indicate that DBN-ELM can effectively detect liver diseases and help clinical doctors achieve early diagnosis of liver diseases.

Keywords

Liver Disease, Deep Learning, DBN-ELM, Diagnostic Model

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

肝脏中发生的病变可统称为肝脏疾病，其中最常见的是肝炎、脂肪肝、肝硬化和肝癌[1]。其中慢性肝炎危害最大，感染人数最多[2]。根据世界卫生组织的统计数据，全球约有4亿人患有慢性肝病，每年导致140万人死亡[3]。这是因为，一方面早期肝病患者一般没有明显的症状，因此很难发现，当患者发现身体异常时，他们通常已经患上了慢性肝炎。另一方面，即使临床检查中某些指标显示异常，也很难准确判断肝脏是否发生了病理变化，这给医生的诊断和治疗带来了巨大挑战。经过多年的发展和完善，临床实践中已经开发出一些评估肝病的模型，包括 Lille [4]模型、MELD [5]模型和相关的改进模型，然而，这些模型的诊断效率和准确性相对较低。因此，我们需要更高效、更准确的肝病诊断方法。

近年来，随着计算机技术的快速发展，机器学习(Machine Learning, ML)和深度学习(Deep Learning, DL)在医疗保健领域取得了显著成就。事实上，斯坦福大学的 Edward H. Shortliffe 教授于 1976 年开发了第一个医疗诊断系统，为医生救治病人提供诊断支持[6]。随后，越来越多的疾病诊断模型和系统被开发出来，为患者和医生带来了极大的便利。肝病作为一种常见的、有害的疾病，构建高度准确的肝病诊断模型和系统一直是热门研究课题。

与医学影像学相比，根据患者血液检测指标等临床检测数据诊断肝病更具普遍性和鉴别性，它可以在肝病的早期发现肝脏异常，为肝病的治疗提供宝贵的时间。Derya Avci [7]等人提出了一种基于遗传算法小波变换核极限学习机(GA-WK-ELM)的肝病诊断模型，该模型使用患者血液检测指标作为数据集。首先，使用遗传算法计算 ELM 模型参数的最优值和隐藏层数。然后，将小波变换核和 ELM 相结合，构建肝病诊断模型。

深度学习是由多伦多大学的 Geoffrey Hinton 教授[8]在 2006 年的《Science》杂志上提出的，它起源于人工神经网络，通过模拟人脑的机制从数据中学习。Anand [9]等人基于患者的临床数据建立了深度人工神经网络(Deep Neural Network, DNN)来预测肝脏疾病，该方法首先对指标特征数据进行预处理，然后使用粒子群优化算法对 DNN 进行全局优化，以解决 DNN 的缺点。Yao [10]等人提出了一种基于肝功能检查指标数据的紧密连接深度神经网络(Tightly Connected Deep Neural Network, DenseDNN)，该模型在传统 DNN 的基础上增加了直接连接，这意味着层之间的连接可以跳过中间层，以减少层之间的传播距离，减少梯度消失的问题，并增强网络之间特征信息的传播。

在本研究中，为了建立更准确的肝病诊断模型，首先有必要解决高维肝病数据的特征提取问题，然后解决肝病诊断的准确性问题。本研究使用 PCA 来提取肝病的重要特征，此外，将 DBN 算法的无监督预训练和 ELM 算法的快速学习的优点进行结合，构建了一个肝病诊断模型。

2. 材料和方法

2.1. 数据描述

本研究使用了 UCI 机器学习库中公开可用的肝病数据集，且该数据集不涉及个人敏感数据和隐私，因此不需要进行伦理审查。肝病数据集来源于 UCI 机器学习库，其数据源网站为 <https://doi.org/10.24432/C5D02C>。该数据集包含 416 个健康样本和 167 个肝病样本，主要来自印度当地医院的血液检测数据，它包含一个用于分类的标签(无论他们是否是肝病患者)。这个公共数据集通常用于验证和评估深度学习算法的性能，该数据集的参数和特征描述见表 1。

Table 1. Feature description of liver disease dataset

表 1. 肝病数据集中的特征描述

特征属性	取值范围	特征描述
Age	4~90	-
Gender	0 或 1	1: 男性, 0: 女性
Total bilirubin	0.4~75	准确反映黄疸程度, 正常参考值: 5.13~22.24 $\mu\text{mol/L}$
Direct bilirubin	0.1~19.7	判断黄疸的重要标准, 正常参考值: 0~7.32 $\mu\text{mol/L}$
Alkaline phosphatase	63~2110	肝细胞严重损伤导致增加, 女性的正常参考值为 50~135 U/L; 男性 45~125 U/L
Alanine kryptotransferase	10~2000	肝病可导致升高, 正常参考值为 0~35 U/L
Aspartate aminotransferase	10~4929	肝病可导致升高, 正常参考值为 0~40 U/L
Total protein	2.7~9.6	肝功能障碍可导致减少, 正常参考值为 60~80 g/L
Albumin	0.9~5.5	肝脏合成障碍等可导致减少, 正常参考值为 35~51 g/L
Albumin to globulin ratio	0.3~2.8	肝病可导致该比率下降, 正常参考值为 1.5~2.5

2.2. 数据预处理

根据缺失的数据类型，使用均值/中值或众数填充数据集中的空白。对于数值数据，只要缺少数据，就有必要使用该特征的均值或中值进行估计。在本研究中，估计了缺失值以提高诊断模型的性能，然后，剔除明显异常的部分。

基于特征范围进行归一化，以消除特征大小差异的影响，从而促进后续的肝病诊断。使用以下表达式将数据值的范围统一转换为[0, 1]:

$$Y_{\text{norm}} = \frac{Y_i - Y_{\min}}{Y_{\max} - Y_{\min}} \quad (1)$$

2.3. 主成分分析

主成分分析(Principal Component Analysis, PCA)是一种从数据中提取重要特征的常用技术。在计算过程中，它考虑了原始数据的各种特征之间的相互关系，使用正交基变换来塑造新特征，并使用方差贡献

率来选择新特征的数量，从而实现了数据的降维。PCA 可以构造独立的新变量，降维后获得的新特征彼此独立，在尽可能保留原始数据信息的同时滤除原始数据中的噪声和冗余。该方法也可用于分析特征之间的相关性，并从整个肝病数据集中提取相关特征，其中碱性磷酸酶、天冬氨酸转氨酶、年龄是本研究中肝病诊断的相关特征。

2.4. 深度信念网络

深度信念网络(Deep Belief Network, DBN)是一种概率生成模型，包括多个隐藏层，并训练网络更新神经元之间的权重，该网络可以以最大概率生成训练的输入数据。DBN 可以将复杂的数据特征提取分解为不同的层次网络，获得具有层次结构的特征值。因此，它们具有很强的特征提取能力，可以解决数据特征提取中浅层网络具有单一层次结构的问题。

DBN 包含多个堆叠的受限玻尔兹曼机(Restricted Boltzmann Machines, RBM)，RBM 在网络的每一层底部调整参数。RBM 以最大似然将输入数据的特征属性传播到隐藏层，RBM 的下一个输入是从隐藏层提取的数据特征值。通过多个 RBM，基于贪婪算法逐层提取数据，最终获得更高级别的数据特征值。DBN 之上是一个 BP 分类器，标签连接到最高层。通过多个 RBM 提取的高级特征值被视为用于监督学习的 BP 算法的输入。因此，DBN 中的网络参数将基于反向传播进行优化，DBN 模型最终将构建完成。DBN 的结构如图 1 所示。




Figure 1. Structure of DBN
图 1. DBN 的结构构成

在给定初始权重的情况下，下一个 RBM 的输入是训练好的初始 RBM 的输出。在这种情况下，假设 RBM 可见层 v 和隐藏层 h 中的神经元是二元随机的，只取 0 或 1。此时，给定 (v, h) ，式(2)可以表示能量

函数。

$$E(v, h | \theta) = -\sum_{i=1}^m \sum_{j=1}^n v_i \omega_{ij} h_j - \sum_{i=1}^m a_i v_i - \sum_{j=1}^n b_j h_j \quad (2)$$

其中，连接权重为 ω_{ij} ，可见单元 i 和隐藏单元 j 的偏差参数分别为 a_i 和 b_j ；RBM 模型的参数 θ 为 $\{a_i, \omega_{ij}, b_j\}$ 。此时，基于能量函数计算可见和隐藏单元的联合概率分布函数。

$$P(v, h | \theta) = \frac{1}{Z_\theta} e^{-E(v, h | \theta)} \quad (3)$$

$$Z_\theta = \sum_v \sum_h e^{-E(v, h | \theta)} \quad (4)$$

式(4)中的归一化因子为 Z_θ 。

RBM 由两个神经网络组成：可见层 v 和隐藏层 h 。自 Hinton 于 2002 年提出对比散度作为 RBM 的快速学习算法以来，RBM 优越的无监督学习能力引起了研究人员的关注。RBM 的结构图如图 2 所示。




Figure 2. Composition of RBM
图 2. RBM 的构成

通过贝叶斯公式推导条件概率。

$$p(h_j = 1 | v) = \sigma(b_j + \sum_i \omega_{ij} v_i) \quad (5)$$

$$p(v_i = 1 | h) = \sigma(a_i + \sum_j \omega_{ij} h_j) \quad (6)$$

其中 $\sigma(x)$ 是逻辑函数

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

Hinton 提出了对比度发散算法，用于计算每个参数的更新方程。首先，基于输入数据初始化可见层。然后，通过条件概率公式和可见层值计算隐藏神经元的条件概率。最后，通过吉布斯抽样计算概率来提样本。使用样本重建可见层，通过重复此过程更新相关参数的规则。

$$\Delta a_i = \mathcal{E}(\langle V_i \rangle_{\text{data}} - \langle V_i \rangle_{\text{recon}}) \quad (8)$$

$$\Delta b_j = \mathcal{E}(\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}}) \quad (9)$$

$$\Delta W_{ij} = \mathcal{E}(\langle V_i h_j \rangle_{\text{data}} - \langle V_i h_j \rangle_{\text{recon}}) \quad (10)$$

学习率为 $\mathcal{E}$ ，数据本身和重建模型后的数学期望分别为 $\langle \cdot \rangle_{\text{data}}$ 和 $\langle \cdot \rangle_{\text{recon}}$ 。通过这种方法，我们可以获得适当的权重并使用这种方法，直到更新 RBM 的总权重。

2.5. 极限学习机

基于前馈神经网络，极限学习机(Extreme Learning Machine, ELM)还包括多层网络结构。在随机初始化输入偏移和权重后，获得相应的输出权重。ELM 具有学习速度快、泛化能力强的优点，可以提高预测模型的性能。

假设 (X_j, t_j) 表示 M 个样本，则包含 L 个隐藏层节点的神经网络可以用以下表达式表示：

$$\sum_{i=1}^L \beta_i g(W_i \cdot OX_j + b_i) = y_j, j = 1, \dots, M \quad (11)$$

在公式(11)中，隐藏层的激活函数为 $g(x)$ ，输入权重为 W_i ，输出权重为 β_i ，第 i 个隐藏层的偏移量为 b_i 。单个隐藏层神经网络的目标是计算最小输出误差。

$$\sum_{i=1}^L \beta_i g(W_i \cdot OX_j + b_i) = t_j, j = 1, \dots, M \quad (12)$$

隐藏层节点的输出为 O ，而预期输出为 H

$$O\beta = H \quad (13)$$

当使用 ELM 训练单个隐藏层神经网络时，参数 W_i 和 β_i 是随机的。通过确定两个参数，可以分别获取输出矩阵 T 。此时，通过训练整个网络求解线性系统，得到输出权重 β

$$\hat{\beta} = O^T H \quad (14)$$

2.6. 深度信念网络 - 极限学习机

Hinton 提出 DBN 后，它被用于降维、回归和分类等应用领域。DBN 中的无监督预训练解决了由于参数随机初始化而陷入局部最小值和收敛速度慢的问题，以及标记训练样本的设置问题。当使用无监督预训练样本时，训练和泛化的误差可以明显降低[11]。通过预训练初始化参数和 BP 算法对网络进行微调，提高分类效率和准确性。总体而言，DBN-ELM 模型包括用于特征提取的 DBN 和用于分类的 ELM，它结合了 DBN 中无监督特征提取预训练的优点和 ELM 的泛化和快速学习能力，从而提高了预测性能。

假设 DBN 包含 n 个隐藏层，通过贪婪预训练初始化 $n-1$ 层。ELM 计算从 $n-1$ 到 n 个隐藏层以及从 n 到下一层的偏移和权重。 $n-1$ 和 n 隐藏层中的神经元数量分别为 l 和 M 。

$$\sum_{i=1}^m \beta_i g(W_i \cdot O_{n-1} + b_i) = y_j, j = 1, \dots, l \quad (15)$$

通过使用式(16)最小化输出误差来计算最佳预测结果

$$\sum_{j=1}^m \|y_j - t_j\| = 0 \quad (16)$$

得到的 β_i 使式(17)成立

$$\sum_{i=1}^m \beta_i O_{n,j} = t_j, j = 1, \dots, l \quad (17)$$

该公式可以转换为以下方程式

$$O_n \beta = H \quad (18)$$

其中， O_n 是从第 $n-1$ 层到第 n 层的输出，由式(19)表示

$$O_n(W_{1,\dots,W_m}, b_1, \dots, b_m, O_{n-1,1}, \dots, O_{n-1,l}) = \begin{bmatrix} g(W_1 \cdot O_{n-1,l} + b_1) & \dots & g(W_m \cdot O_{n-1,l} + b_m) \\ \vdots & \ddots & \vdots \\ g(W_1 \cdot O_{n-1,l} + b_1) & \dots & g(W_m \cdot O_{n-1,l} + b_m) \end{bmatrix} \quad (19)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_m^T \end{bmatrix}, H = \begin{bmatrix} H_1^T \\ \vdots \\ H_m^T \end{bmatrix} \quad (20)$$

通过训练网络，我们可以得到一个特殊的 $\hat{W}_i$, $\hat{b}_i$, $\hat{\beta}$

$$\|O_m(\hat{W}_i, \hat{b}_i)\hat{\beta} - H\| = \min_{W,b,\beta} \|O_n(\hat{W}_i, \hat{b}_i)\hat{\beta} - H\| \quad (21)$$

我们随机确定网络最后一层的参数 W_i 和 β_i 。在确定这两个网络的参数时，只获得输出 H 。DBN 的输出权重解释如下：

$$\hat{\beta} = O_m^T H \quad (22)$$

DBN-ELM 的训练步骤如图 3 所示。




Figure 3. The training process of DBN-ELM model
图 3. DBN-ELM 模型训练过程

首先，DBN 执行无监督预训练来提取特征。之后，使用 ELM 确定 DBN 中最终隐藏层和输出层之间的权重，认为模型的输出矩阵与最终 RBM 获得的权重矩阵相同。最后，获得误差，完成 DBN-ELM 模型训练。

在本研究中，构建了一个具有 4 层 RBM 的深度信念网络用于特征提取。由于 RBM 对学习率敏感，小值保证稳定性，RBM 无监督预训练的学习率设置为 0.05；对比度发散算法需充分采样，迭代次数设置为 500 次。反向传播阶段的学习率为 0.25，这是因为大于预训练值，加速有监督优化；通过早停机制(验证集监控)限制过拟合，迭代次数为 200；批大小为 64~128。ELM 隐层节点为 500，通过高维投影增强线性可分性；激活函数为 ReLU 函数，可以通过稀疏激活提升特征选择性。

3. 结果和讨论

3.1. 评估指标

应用多个指标来评估分类器的性能。此时，应用混淆矩阵来评估分类器，该分类器记录了正确和不正确分类的类别标签。混淆矩阵见表 2。评价指标说明详见表 3。

Table 2. Confusion Matrix of classification model

表 2. 分类模型的混淆矩阵

混淆矩阵	预测为肝病	预测为健康
实际为肝病	真阳性(TP, 肝病样本被正确预测)	假阴性(FN, 肝病样本未正确预测)
实际为健康	假阳性(FP, 未正确预测健康样本)	真阴性(TN, 健康样本被正确预测)

Table 3. Evaluation indicators

表 3. 评估指标

评估指标	计算公式	含义
Sensitivity/Recall	$Sensitivity = TP / (TP + FN)$	真正检测到的早期糖尿病的比例
Specificity	$Specificity = TN / (TN + FP)$	真实检测到的实际健康比例
Accuracy	$Accuracy = (TP + TN) / (TP + TN + FP + FN)$	所有样本中正确检测到的样本比例
Precision	$precision = TP / (TP + FP)$	所有预测样本中实际早期糖尿病的比例
F1-Score	$F1 = (2recall \cdot precision) / (recall + precision)$	准确率和召回率的综合评价指标

假阳性率或 1-特异性是 ROC 曲线的横轴，而真阳性率或灵敏度是纵轴。ROC 曲线和坐标轴包围的面积是 AUC。通常，AUC 值越接近 1，分类算法的性能就越好。

3.2. 实验结果

使用十折交叉验证划分肝病数据集。DBN-ELM 诊断模型的肝病数据集分别给出了 65.27%的敏感性、96.15%的特异性、87.31%的准确性、74.66%的 F1 评分和 0.9188 的 AUC。在训练和测试集中，DBN-ELM 分别达到 87.71%和 86.36%的准确率、65.81%和 64%的敏感性、96.55%和 95.24%的特异性、75.49%和 72.73%的 F1 评分、AUC 0.9301 和 0.8905。DBN-ELM 的评价指标见表 4，其 ROC 曲线如图 4 所示。DBN-ELM 模型包括用于特征提取的 DBN 和用于分类的 ELM，它结合了 DBN 中无监督特征提取预训练的优点和 ELM 的泛化和快速学习能力，当使用无监督预训练样本时，训练和泛化的误差可以明显降低，同时结合极限学习机的优点，从而有效地提高了预测性能。

3.3. 消融实验

为了探索 DBN-ELM 模型的每个组成部分对肝脏疾病诊断性能的贡献，本文进行了消融实验。DBN-

ELM 模型由 DBN 算法和 ELM 技术组成,将逐步移除以评估其对模型性能的影响。本文提出了以下消融实验方案:

- (1) 完整的 DBN-ELM 模型,包括 DBN 算法和多种 ELM 技术;
- (2) 没有 ELM 技术的 DBN 算法:从 DBN-ELM 模型中删除 ELM 技术,只保留 DBN 算法;
- (3) ELM 技术:从 DBN-ELM 模型中删除 DBN 算法,保留 ELM 技术。消融实验的结果见表 4。

由表 4 可以推断,在 DBN 算法失去了 ELM 的快速学习和泛化能力后,肝病诊断的性能远非良好。同样,在失去 DBN 的无监督预训练能力后,ELM 的肝病诊断性能下降。通过将 DBN 的无监督预训练与 ELM 的快速学习和泛化能力相结合,DBN-ELM 提高了肝病的诊断性能。




Figure 4. ROC curve of DBN-ELM diagnostic model

图 4. DBN-ELM 诊断模型的 ROC 曲线

Table 4. Comparison of ablation experiment results

表 4. 消融实验结果比较

诊断模型	阶段	Sensitivity	Specificity	Accuracy	Precision	F1 score	AUC
DBN-ELM	Training	65.81%	96.55%	87.71%	88.51%	75.49%	0.9301
	Testing	64%	95.24%	86.36%	84.21%	72.73%	0.8905
DBN	Training	58.97%	76.29%	71.15%	50%	54.12%	-
	Testing	52%	77.6%	70.29%	48.15%	50%	-
ELM	Training	62.39%	94.86%	85.57%	82.95%	71.21%	-
	Testing	54%	78.23%	71.26%	50%	51.92%	-

3.4. 讨论

肝病的早期识别对患者的身心健康至关重要,因为它是一种高度传染性和致命性的疾病。因此,在

肝病数据的基础上, 利用 ML 和 DL 技术建立一个高度准确和广泛的肝病诊断模型, 帮助医生准确评估和预测患者的病情, 将对肝病的诊断和治疗产生积极影响。然而, 目前的肝病诊断模型还不够成熟, 仍有许多问题需要解决。首先, 肝病数据量大, 维度高。如何使用模型从中提取重要和有价值的特征信息是一个需要考虑的问题。其次, 肝病诊断模型的准确性还不够高, 有必要考虑如何提高肝病诊断的准确性。

4. 结论

本研究使用主成分分析提取了重要特征, 其中, 肝病数据集中的碱性磷酸酶、天冬氨酸转氨酶和年龄是我们研究中肝病诊断的重要特征。经过填充缺失值并删除了异常值等数据预处理步骤后, 构建并训练了一个基于 DBN-ELM 的肝病检测模型, 该模型结合了 DBN 的无监督预训练和 ELM 的快速训练能力。DBN-ELM 模型在肝病数据集上分别取得了 87.31% 的准确率、65.27% 的敏感度、96.15% 的特异性、72.73% 的 F1-Score 和 0.9188 的 AUC 值。这些较好的性能表明, DBN-ELM 模型可用于检测肝脏疾病, 并从临床数据中准确识别肝脏疾病, 从而帮助医生更好地诊断疾病。

在未来的工作中, 将在模型中引入深度条件生成对抗网络等新方法, 并引入肝病图像等新数据以获得更丰富的数据信息, 从而提高模型的整体性能。最后, 我们将进一步探索深度学习在肝病辅助诊断中的应用。

基金项目

湖南省教育厅科研项目 - 一般项目(24C0477); 永州市指导性科技计划项目 - 一般项目(2024YZ018); 湖南科技学院校级科研项目(23XKYZZ10)。

参考文献

- [1] Anderson, A., Huttenlocher, D., Kleinberg, J. and Leskovec, J. (2014) Engaging with Massive Online Courses. *Proceedings of the 23rd International Conference on World Wide Web*, Seoul, 7-11 April 2014, 687-698. <https://doi.org/10.1145/2566486.2568042>
- [2] Li, C., He, Q., Gao, D., Li, R., Zhu, Y., Li, H., *et al.* (2017) Idiosyncratic Drug-Induced Liver Injury Linked to Polygonum Multiflorum: A Case Study by Pharmacognosy. *Chinese Journal of Integrative Medicine*, **23**, 625-630. <https://doi.org/10.1007/s11655-017-2543-9>
- [3] Allen, A.M., Van Houten, H.K., Sangaralingham, L.R., Talwalkar, J.A. and McCoy, R.G. (2018) Healthcare Cost and Utilization in Nonalcoholic Fatty Liver Disease: Real-world Data from a Large U.S. Claims Database. *Hepatology*, **68**, 2230-2238. <https://doi.org/10.1002/hep.30094>
- [4] Louvet, A., Diaz, E., Texier, F., Dharancy, S., Boitard, J., Biron, N., *et al.* (2006) 92 Prediction of Mortality in Severe Alcoholic Hepatitis: Validation of Lille Model and Comparison to Other Prognostic Scores. *Journal of Hepatology*, **44**, S41. [https://doi.org/10.1016/s0168-8278\(06\)80093-0](https://doi.org/10.1016/s0168-8278(06)80093-0)
- [5] Kamath, P.S., Wiesner, R.H., Malinchoc, M., Kremers, W., Therneau, T.M., Kosberg, C.L., *et al.* (2001) A Model to Predict Survival in Patients with End-stage Liver Disease. *Hepatology*, **33**, 464-470. <https://doi.org/10.1053/jhep.2001.22172>
- [6] Wang, X., Luo, Z., He, R. and Shao, Y. (2023) Novel Medical Question and Answer System: Graph Convolutional Neural Network Based with Knowledge Graph Optimization. *Expert Systems with Applications*, **227**, Article ID: 120211. <https://doi.org/10.1016/j.eswa.2023.120211>
- [7] Avci, D. (2016) An Automatic Diagnosis System for Hepatitis Diseases Based on Genetic Wavelet Kernel Extreme Learning Machine. *Journal of Electrical Engineering and Technology*, **11**, 993-1002. <https://doi.org/10.5370/jeet.2016.11.4.993>
- [8] Hinton, G.E. and Salakhutdinov, R.R. (2006) Reducing the Dimensionality of Data with Neural Networks. *Science*, **313**, 504-507. <https://doi.org/10.1126/science.1127647>
- [9] Anand, L. and Neelanarayanan, V. (2019) Liver Disease Classification Using Deep Learning Algorithm. *International Journal of Innovative Technology and Exploring Engineering*, **8**, 5105-5111. <https://doi.org/10.35940/ijitee.I2747.1081219>

-
- [10] Yao, Z., Li, J., Guan, Z., Ye, Y. and Chen, Y. (2020) Liver Disease Screening Based on Densely Connected Deep Neural Networks. *Neural Networks*, **123**, 299-304. <https://doi.org/10.1016/j.neunet.2019.11.005>
- [11] Chen, X., Hai-Yue, Y., Wun, J., Wu, C., Wang, C. and Li, L. (2020) Power Load Forecasting in Energy System Based on Improved Extreme Learning Machine. *Energy Exploration & Exploitation*, **38**, 1194-1211. <https://doi.org/10.1177/0144598720903797>