

引用:阮开霞,李冰,冉宇,郑丰杰,姚舜宇.多种机器学习与反向传播神经网络模型在中医补益类方剂分类中的对比研究[J].中医导报,2025,31(7):232-237.

# 多种机器学习与反向传播神经网络模型 在中医补益类方剂分类中的对比研究\*

阮开霞<sup>1</sup>,李冰<sup>2</sup>,冉宇<sup>3</sup>,郑丰杰<sup>4</sup>,姚舜宇<sup>4</sup>

(1.北京中医药大学第二临床医学院东方医院,北京 100078;

2.北京中医药大学中药学院,北京 100029;

3.北京中医药大学生命科学院,北京 102400;

4.北京中医药大学中医学院,北京 100029)

[摘要] 目的:基于多种机器学习和反向传播神经网络(BPNN)构建中医补益类方剂分类模型,辅助中医补益类方剂自动化分类。方法:结合中医药理论与现代数据科学方法,收集并整理中医补益类方剂数据,选取四气、五味、归经等药性特征进行模型训练和验证。采用支持向量机(SVM)、随机梯度下降(SGD)、K最近邻(KNN)、随机森林(RF)、极限梯度提升(XGBoost)、轻量级梯度提升机(Light GBM)和BPNN算法,构建补气、补血、补阴和补阳4个类别的方剂分类模型,并使用沙普利加性解释(SHAP)对特征重要性进行解释和分析。结果:整理得到174个样本,其中43个补气方剂、45个补血方剂、50个补阴方剂、36个补阳方剂。经训练,各模型训练集的F1分数(F1-Score)分别为SVM 0.551 8、SGD 0.745 6、KNN 1.000 0、RF 0.893 2、XGBoost 1.000 0、Light GBM 0.914 1、BPNN 0.739 9;验证集的F1-Score分别为SVM 0.554 0、SGD 0.846 3、KNN 0.778 3、RF 0.710 5、XGBoost 0.552 1、Light GBM 0.710 1、BPNN 0.770 9;SHAP模型解释器分析的主要特征为肾经、脾经、肺经和甘味。结论:本研究构建了多个具有高预测精度的补益类方剂分类模型,其中BPNN模型在7个模型中整体分类性能最均衡;SHAP模型解释器得出的性味归经符合中医补益类方剂的特征,可辅助补益类方剂分类的解释。

[关键词] 补益类方剂;方剂分类;机器学习;反向传播神经网络;模型

[中图分类号] R2-03 [文献标识码] A [文章编号] 1672-951X(2025)07-0232-06

DOI:10.13862/j.cn43-1446/r.2025.07.040

## Comparative Study of Multiple Machine Learning and Backpropagation Neural Network Models in the Classification of Traditional Chinese Medicine Tonifying Prescriptions

RUAN Kaixia<sup>1</sup>, LI Bing<sup>2</sup>, RAN Yu<sup>3</sup>, ZHENG Fengjie<sup>4</sup>, YAO Shunyu<sup>4</sup>

(1.Second Clinical College, Dongfang Hospital, Beijing University of Chinese Medicine, Beijing 100078, China;

2.School of Chinese Materia Medica, Beijing University of Chinese Medicine, Beijing 100029, China;

3.School of Life Sciences, Beijing University of Chinese Medicine, Beijing 102400, China;

4.School of Traditional Chinese Medicine, Beijing University of Chinese Medicine, Beijing 100029, China)

[Abstract] Objective: To construct classification models for traditional Chinese medicine (TCM) tonifying prescriptions based on multiple machine learning and backpropagation neural network (BPNN), assisting the automatic classification of TCM tonifying prescriptions. Methods: By integrating TCM theory with modern data science methods, data on TCM tonifying prescription were collected and organized. Characteristics such as four natures, five flavors, and meridian tropism were selected as features for model training and validation. Support vector machine (SVM), stochastic gradient descent (SGD), K-nearest neighbor (KNN), random forest (RF), extreme gradient boosting (XGBoost), light gradient boosting machine (Light GBM), and BPNN algorithms were used to

\*基金项目:全国中医药高等教育学会创新创业教育研究会课题(1000041510153);北京市继续教育伤寒学优秀教学团队(BJJXTD2019-019)

通信作者:郑丰杰,男,教授,主任医师,研究方向为中医药经方治疗疑难病

construct prescription classification models for four categories: Qi-tonifying, blood-tonifying, Yin-tonifying, and Yang-tonifying. SHapley Additive exPlanations (SHAP) were applied to interpret and analyze feature importance. Results: A total of 174 samples were organized, including 43 Qi-tonifying prescriptions, 45 blood-tonifying prescriptions, 50 Yin-tonifying prescriptions, and 36 Yang-tonifying prescriptions. After training, the F1-Scores for the models on the training set were: SVM 0.551 8, SGD 0.745 6, KNN 1.000 0, RF 0.893 2, XGBoost 1.000 0, Light GBM 0.914 1, and BPNN 0.739 9. On the validation set, F1-Scores were: SVM 0.554 0, SGD 0.846 3, KNN 0.778 3, RF 0.710 5, XGBoost 0.552 1, Light GBM 0.710 1, BPNN 0.770 9. Major features identified by the SHAP model interpreter included kidney meridian, spleen meridian, lung meridian, and sweet flavor. Conclusion: This study constructed multiple highly accurate classification models for tonifying prescriptions, with the BPNN model demonstrating the most balanced performance among the seven models. Moreover, the major features identified by the SHAP model interpreter aligned with the characteristics of TCM tonifying prescriptions, aiding in the interpretability of the classification process.

[Keywords] tonifying prescriptions; prescription classification; machine learning; backpropagation neural network; model

中医药是中华民族几千年来防治疾病的瑰宝,其中方剂是中医运用中药防治疾病的主要形式和手段,是中医理、法、方、药体系中的重要组成部分。准确理解和掌握方剂的功效与分类对于提高中医临床诊疗效果至关重要<sup>[1]</sup>。然而,方剂的功效与其组成药物之间往往存在复杂的非线性关系。此外,方剂名称与实际功效的不完全对应<sup>[2]</sup>,甚至方剂名称与实际功效完全无关或相左,给方剂的现代科学研究和临床应用带来了挑战。加之面对海量的方剂数据,人工划分方剂类别在时间和经济成本上都较高且实现困难,且不同的现代方剂工具书之间对同一方剂的分类也存在矛盾之处。因此,如何客观、高效地划分方剂的归属类别,成为中医传承和现代化亟需解决的关键问题<sup>[3]</sup>。

随着人工智能技术的迅速发展,研究者们逐渐尝试将各算法模型应用于中药方剂的分类与分析。陈昭等<sup>[4]</sup>基于药性整体观构建了74味清热药的最小二乘-支持向量机(least squares-support vector machine, LS-SVM)分类模型,但纳入药物单一且数量不足。郭永坤等<sup>[5]</sup>基于神经网络构建了中药方剂功效预测模型,但仅纳入34个方剂,且纳入特征仅包括四气和五味,未涉及药物归经特征。GAO W Q等<sup>[6]</sup>构建了传统中医向量化模型(traditional Chinese medicine to vector, TCM2Vec)。该模型结合新的中药方剂特征提取方式预测方剂功效,提高了预测准确性,但缺乏可解释性。因此,为解决现有研究的不足,本研究基于多种机器学习和反向传播神经网络(back propagation neural network, BPNN)构建中医补益类方剂分类模型,并引入模型解释技术,以提高中医补益类方剂分类的准确性和可解释性。

## 1 资料与方法

1.1 数据来源 本研究所使用的中药材特征信息来源于2020年版《中华人民共和国药典》。补益类方剂来源于《中医方剂学》《中医方剂大辞典》等现代方剂工具书。

1.2 纳入标准 (1)中药的性味特征完整收录于2020年版《中华人民共和国药典》;(2)单一功效的方剂;(3)方剂出现频数 $\geq 3$ 。

1.3 中药特征的数值化处理 由两名研究者从2020年版《中华人民共和国药典》中提取所有中药材的四气、五味和归经3个维度的特征信息并对这些特征进行数字编码。四气、五味、归经的数字编码方式均按照“是”和“否”分别为“1”和“0”。

1.4 方剂特征的数值化处理 在对单味中药药性进行数字编码的基础上,根据其在方剂中的剂量比例加权计算,最终得到方剂的整体性味值。通过数值化处理的方法,对纳入的174个补益类方剂进行处理。五味数值化结果见表1。

表1 补益类方剂五味数值化示表

方剂编号	酸	涩	苦	甘	淡	辛	咸
1	0.000	0.700	0.000	0.000	0.800	0.000	0.000
2	0.000	0.190	0.000	0.000	0.762	0.000	0.127
3	0.000	0.247	0.000	0.000	0.630	0.000	0.205
4	0.000	0.273	0.000	0.000	0.576	0.000	0.242
5	0.000	1.000	0.000	0.000	1.000	0.000	0.000
6	0.000	0.530	0.000	0.000	0.441	0.117	0.382
7	0.000	0.652	0.000	0.000	0.087	0.130	0.130
8	0.000	0.000	0.750	0.000	0.250	0.000	0.500
9	0.000	0.500	0.000	0.000	0.688	0.250	0.313
.....	.....	.....	.....	.....	.....	.....	.....
174	0.000	0.417	0.000	0.000	0.250	0.000	0.455

1.5 训练集与验证集的划分 利用Python将数据集以8:2的比例随机划分为训练集和验证集。通过设置参数stratify=y,确保训练集和测试集中各个分类数据的比例与按样本量比例抽样的原数据集保持一致<sup>[7]</sup>。然后,通过设置参数random=0,保证每次实验都使用相同的训练集和验证集,从而增加实验的可重复性<sup>[8]</sup>。

## 1.6 模型构建

1.6.1 机器学习算法 不同的机器学习模型具备不同的优势和适用范围。本研究通过构建并比较支持向量机(support vector machine, SVM)、随机梯度下降(stochastic gradient descent, SGD)、K最近邻(K-nearest neighbors, KNN)、随机森林(random forest, RF)、极限梯度提升(extreme gradient boosting,

XGBoost)、轻量级梯度提升机(light gradient boosting machine, Light GBM)等6种机器学习模型,评估其性能以选出特定任务中的最佳模型,并确保其在实际应用中的可靠性和解释性。

模型性能通过准确率、F1分数(F1-Score)、混淆矩阵和受试者工作特征曲线(receiver operating characteristic, ROC)下的面积(area under the curve, AUC)进行评估。同时,引入沙普利加性解释(shapley additive exPlanations, SHAP)模型解释器来解释模型分类的依据,并通过SHAP值图将各特征贡献度可视化。

**1.6.2 BPNN模型** 本研究在机器学习模型的基础上进一步采用BPNN作为深度学习模型进行比较和分析。BPNN是一种经典的前馈神经网络,具有强大的非线性拟合能力,能够有效捕捉复杂数据中的高维特征。BPNN已广泛应用于医学分类<sup>[9]</sup>、疾病预后<sup>[10]</sup>、辅助诊断<sup>[11]</sup>、发病率预测<sup>[12]</sup>、疾病影响因素探究<sup>[13]</sup>等领域,具有优异的预测性能。

BPNN可通过误差反向传播算法调整权重,实现从输入到输出的非线性映射,具有强大的建模复杂关系的能力。在训练过程中,研究引入了学习率调整、正则化等技术以优化模型性能并防止过拟合<sup>[14]</sup>,并采用准确率、F1-Score、混淆矩阵和ROC曲线评估模型的性能。

## 2 结果

**2.1 各模型评估指标结果** 6种机器学习模型及BPNN模型的准确率和F1-Score见表2。

KNN与XGBoost在训练集上表现最优,但验证集性能显著下降,提示存在严重过拟合;SGD验证集表现最优,泛化能力突出,但训练集表现一般,提示特征学习受限;RF与Light GBM训练集表现良好,但验证集泛化能力不足。SVM整体性能最差,不适用于本任务。BPNN在训练集和验证集性能均衡,未出现过拟合,综合表现最佳。

表2 各模型评估指标结果

模型	训练集		验证集	
	准确率	F1-Score	准确率	F1-Score
SVM	0.654 7	0.551 8	0.600 0	0.554 0
SGD	0.748 2	0.745 6	0.857 1	0.846 3
KNN	1.000 0	1.000 0	0.771 4	0.778 3
RF	0.892 1	0.893 2	0.714 3	0.710 5
XGBoost	1.000 0	1.000 0	0.542 9	0.552 1
Light GBM	0.913 7	0.914 1	0.714 3	0.710 1
BPNN	0.741 0	0.739 9	0.771 4	0.770 9

**2.2 训练集的混淆矩阵** KNN、Light GBM、RF、SGD、SVM、XGBoost模型在训练集上的混淆矩阵见图1。BPNN模型在训练集上的混淆矩阵见图2。

KNN与XGBoost模型中,所有类别的样本都被完全正确分类,过拟合显著,泛化能力差;Light GBM与RF模型中,训练集表现稳定,补气、补阳方剂正确率均高于90%,但Light GBM补血、补阴方剂错误分类较多,分别为3例和4例,RF补血、补阴方剂错误分类均为5例,类别间学习不平衡;SGD模型中,补血方剂错误分类15例,补阴方剂错误分类10例,分类能力弱,特征提取受限;SVM模型中,补阳方剂全误判,完全失效。补

血、补阴方剂分类能力平庸,不适用本任务。(见图1)

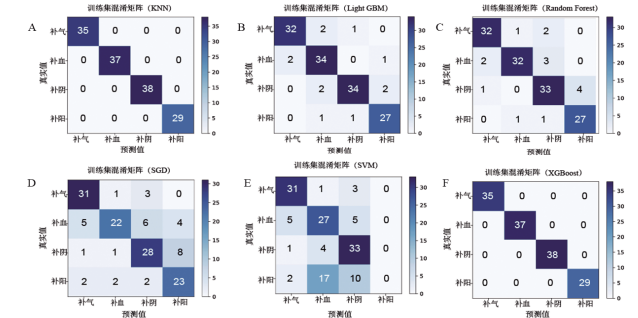


图1 各机器学习模型输出的训练集混淆矩阵

BPNN模型:补气正确分类31例,错误分类4例;补血方剂正确分类24例,错误分类13例;补阴方剂正确分类25例,错误分类13例;补阳方剂正确分类23例,错误分类6例。(见图2)




图2 BPNN模型的训练集混淆矩阵

**2.3 验证集的混淆矩阵** KNN、Light GBM、RF、SGD、SVM、XGBoost模型在验证集上的混淆矩阵见图3。BPNN模型在验证集上的混淆矩阵见图4。

KNN模型中,补阴与补阳方剂分类较优,分别正确分类9例和6例,但补气、补血方剂分类错误率较高,各2例,类别泛化不均;Light GBM模型中,补气、补血方剂分类稳定,各正确分类7例,但补阴与补阳方剂分类表现欠佳,各错误分类5例与3例,复杂类别学习能力弱。RF模型中,补气方剂分类全正确,但补阴与补阳误判显著,分别错误分类5例和3例,依赖局部特征,全局泛化不足;SGD模型中,补阴方剂分类最优,正确11例,仅1例错误,补阳次之,特定类别特征提取能力强,但补血方剂错误分类2例;SVM模型中,补阳方剂仅1例正确,完全失效;补阴与补血方剂分别错误分类5例、2例,分类平庸,不适用多类别任务;XGBoost模型中,补阴与补阳方剂分类误判严重,分别错误分类8例、5例,验证集性能远低于训练集,提示严重过拟合。(见图3)

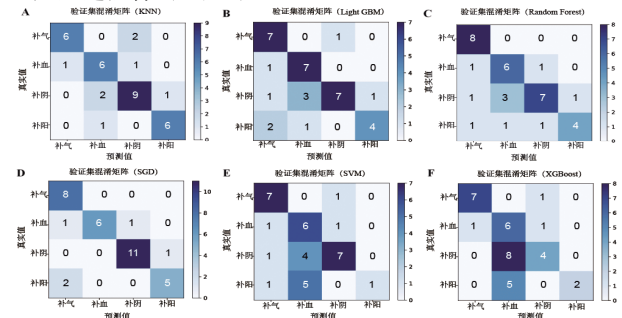


图3 各机器学习模型输出的验证集混淆矩阵

BPNN:补阴与补阳方剂分类最优,分别正确分类10例、6例,错误分类2例、1例;补血方剂正确分类6例,错误分类2例;补气方剂错误分类3例,但整体均衡。(见图4)




图4 BPNN模型的验证集混淆矩阵

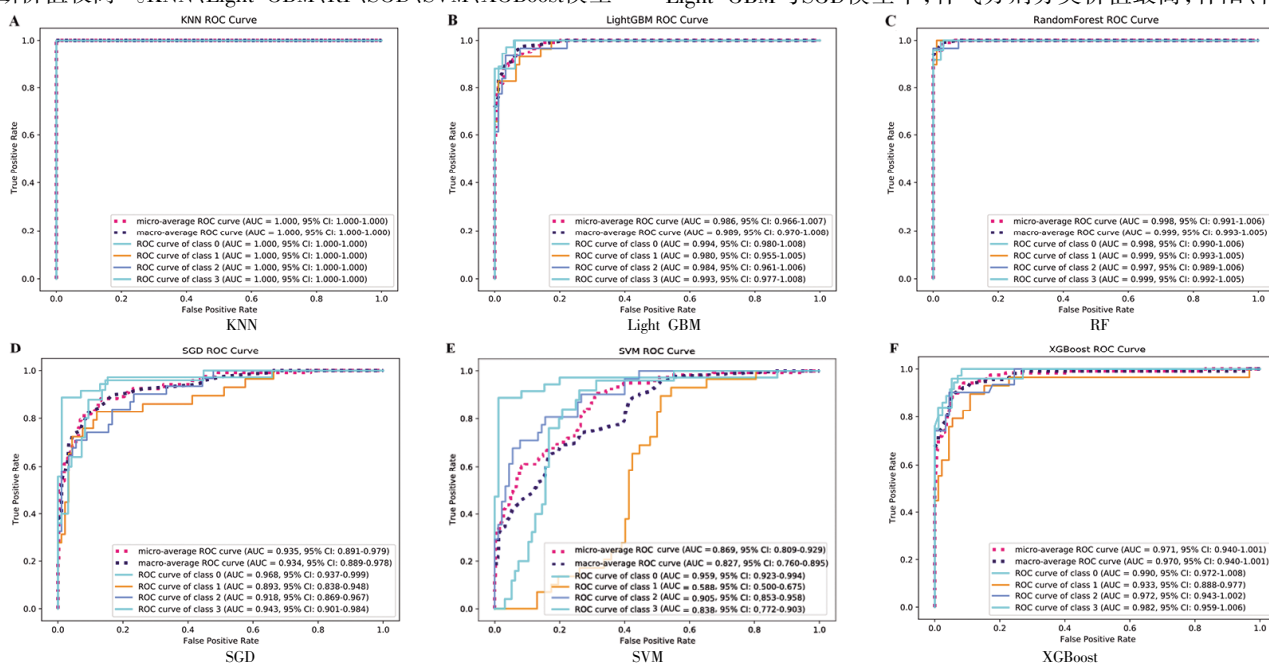
2.4 训练集的ROC曲线 本研究采用ROC曲线评估模型的预测性能<sup>[15]</sup>。AUC值表示ROC曲线下的面积，AUC值越接近1，模型性能越优越<sup>[16]</sup>。AUC为0.500~0.700，表示诊断价值较低；AUC为0.700~0.900，提示诊断价值中等；AUC $\geq$ 0.900，提示诊断价值较高<sup>[17]</sup>。KNN、Light GBM、RF、SGD、SVM、XGBoost模型

在训练集上的ROC曲线见图5。

KNN模型中，所有类别AUC=1.000，过拟合显著；Light-GBM、RF、XGBoost模型中，补气、补血、补阴、补阳方剂分类的AUC值均大于0.900，分类价值高，但AUC值趋于1.000提示可能出现过拟合；SGD模型中，补气、补阴、补阳方剂分类的AUC值均大于0.900，分类价值高，补血方剂次之；SVM模型中，在补气、补阴、补阳方剂上分类价值高，补血方剂分类较差。（见图5）

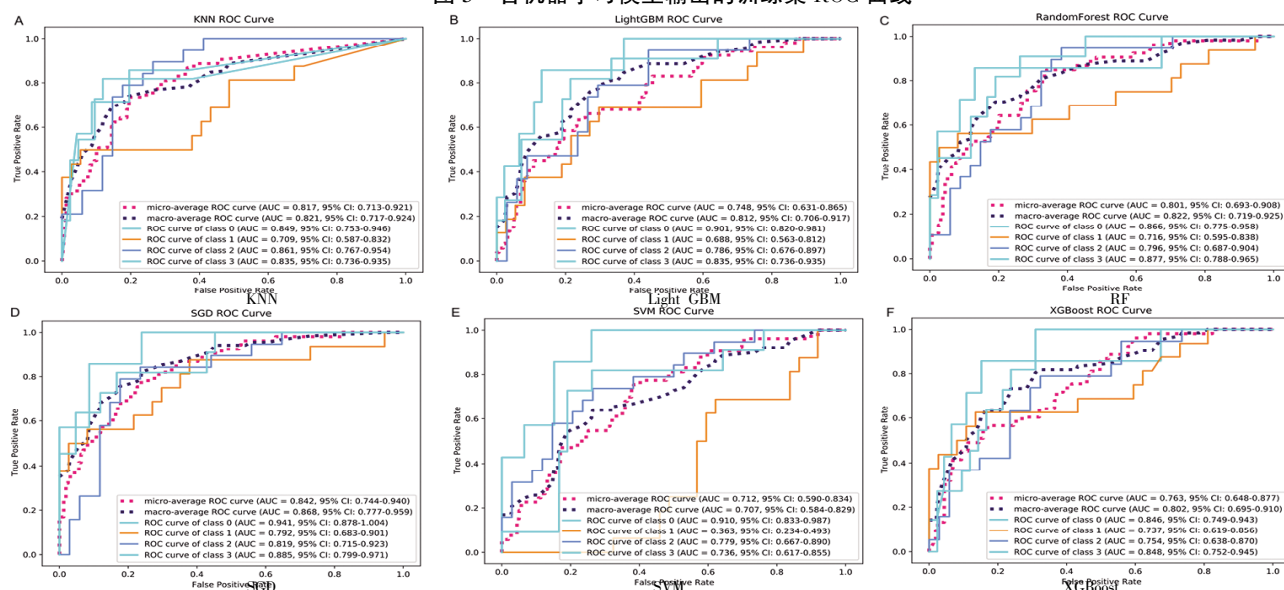
2.5 验证集的ROC曲线 KNN、Light GBM、RF、SGD、SVM、XGBoost模型在验证集上的ROC曲线见图6。

KNN模型中，补阴、补气、补阳方剂分类较高，AUC均大于0.800，但补血方剂分类表现一般，类别泛化能力不均；Light GBM与SGD模型中，补气方剂分类价值最高，补阳、补



注:0:补气;1:补血;2:补阴;3:补阳。

图5 各机器学习模型输出的训练集 ROC 曲线



注:0:补气;1:补血;2:补阴;3:补阳。

图6 各机器学习模型输出的验证集 ROC 曲线



阴方剂次之,补血方剂分类最差,提示复杂类别捕捉不足;RF与XGBoost模型中,补气、补血、补阴、补阳方剂分类价值均为中等;SVM模型中,补气方剂分类价值最高,补阴、补阳方剂分类价值中等,补血分类价值最低,AUC为0.363。(见图6)

**2.6 SHAP值图** 本研究采用SHAP值图量化特征的重要性,明确每个特征对模型输出的影响,从而为模型解释性提供支持。

KNN模型中,肾经、脾经和肺经对模型输出贡献度最高;LightGBM模型中,甘味、胃经和肾经对模型输出贡献度最高;RF模型中,甘味、肝经和胃经对模型输出贡献度最高。(见图7)




图7 KNN、Light GBM、RF模型的SHAP值图

SGD模型中,肾经、脾经、脾经对模型输出贡献度最高;SVM模型中,脾经、肾经和寒性对模型输出贡献度最高;XGBoost模型中,心包经、甘味和肝经对模型输出贡献度最高。(见图8)




图8 SGD、SVM、XGBoost模型的SHAP值图

### 3 讨论

中医药的国际标准化是中医药迈向世界的必经之路,也是中医药领域需要解决的重要难题<sup>[18]</sup>。然而中医语言的模糊性、临床用药的多变性及处方思维的主观性均给中医药的标准化带来了挑战<sup>[19]</sup>。在这样的背景下,人工智能技术的引入,尤其是机器学习与深度学习技术,为解决这一问题提供了新的可能性。机器学习能够将中医药的复杂信息转化为可解释的数学模型,有助于从模糊性诊疗过渡到更精确的诊疗<sup>[20]</sup>。高质量的分类是科学研究的重要议题。客观地对中医方剂进行分类是开展中医人工智能研究的重要基础,有助于中医药标准化的推进。本研究通过引入SVM、SGD、KNN、RF、XGBoost、Light GBM等6种机器学习和BPNN模型,对中医补益类方剂的分类进行了系统分析。

本研究通过分析准确率和F1-Score发现,SVM和XGBoost模型在验证集上表现较差,在补益类方剂分类上泛化能力不足;KNN模型在训练集上表现完美,但在验证集上的表现显著下降,提示出现过拟合问题。增加数据样本、降低模型复杂度、进行数据增强等方式,可缓解过拟合现象。RF和Light GBM模型虽然在训练集上有较高的准确率,但验证集上的表现没

有显著优势。SGD模型在验证集上的表现较好,但其在训练集上的准确率相对较低,表明该模型在数据处理上可能较为依赖于验证集的特性,存在一定的不稳定性。相比之下,BPNN在训练集和验证集上的准确率差距较小,两者的F1-Score也保持一致性,表明BPNN在训练过程中更好地控制了过拟合,并在验证集上展现出较强的泛化能力。BPNN模型在训练集和验证集上的性能较为均衡,既避免了过拟合问题,也展现出较强的泛化能力,整体性能最佳。这一优势主要得益于其强大的非线性建模和自动特征学习能力,使其在复杂任务中表现尤为突出。但它需要更多的计算资源,且训练时间较长。

本研究通过分析各模型的混淆矩阵发现,各模型在不同类别上的表现有显著差异:SGD模型的误分类少,整体分类均衡,表现较好;RF模型分类效果良好,但在补阴方剂中存在较多误分类;XGBoost和Light GBM模型虽然在补气方剂分类上表现优异,在补阴方剂分类中表现稍逊,误分类较为显著;SVM在补气和补血方剂中误分类较少,但在补阴方剂分类中的表现较差;KNN模型在补阴方剂上的误分类较多,效果逊于SGD和RF模型;BPNN模型整体分类均衡,尤其在补阴和补阳方剂中的分类效果较好。

各模型的ROC曲线显示,补气和补阳方剂的分类效果最为稳定,AUC值较高,说明模型能够较好地地区分这两类方剂。而补血方剂的分类效果普遍较差,尤其是在SVM和Light GBM模型中,AUC值偏低,表明模型难以有效捕捉补血类方剂特征。可能原因是补血类方剂的特征较为复杂,且与其他类别重叠性较高,导致分类难度增加。在各模型表现中,SGD和RF表现最佳,分类均衡且AUC值较高。SVM表现最不稳定,补血分类几乎无效。KNN、Light GBM和XGBoost表现中等,但仍需针对补血方剂分类进行优化。后续的模型优化可通过尝试更多的特征工程和集成方法来优化模型的性能,提升整体分类性能,尤其是补血方剂的分类。

与现有研究<sup>[21]</sup>相比,本研究不仅对这6个模型的性能进行了横向对比,还进一步分析了模型的可解释性,使得模型的输出结果更加透明和易于理解,这在复杂的中医药理论体系中尤为重要。

SHAP值图显示,肾经、脾经、胃经、甘味和肺经等性味、归经在所构建的补益类方剂分类模型中普遍表现出较高的贡献度。这表明这些特征在补益类方剂分类中可能具有较大的影响力。“肾者主水,受五脏六腑之精而藏之。”<sup>[22]</sup>肾为先天之本,肾中精血元气是人体形成和生长发育的基础<sup>[23]</sup>,肾寓元阴元阳。脾胃为气血生化之源。肺主一身之气。补益类方剂常涉及肺、脾、肾三脏。味甘之品多具有补益之功<sup>[24]</sup>。肺、脾、肾共司水液的运化等。这些特征与中医理论中补益类方剂的特征属性高度吻合,表明各模型能够有效捕捉中医药中复杂的内部联系,并进行正确分类。此外寒性、肝经等性味、归经也是影响补益类方剂分类的重要特征。

本研究仍有一些不足。首先,数据集规模和多样性有限,可能影响模型泛化。未来研究应探索更轻量的模型结构并采用更大规模数据集,以提升适用性和效率。此外,本研究仅选取补益类方剂,缺乏普适性。未来的研究可引入更多类别方剂,丰富特征维度,结合先进算法等以优化模型性能。

## 参考文献

- [1] 陈飞,韩洁茹,姜德友.方剂临床分类与择用思维[J].吉林中医药,2021,41(11):1409-1411.
- [2] 朱玲,李思迪,叶祖光,等.从中医经典名方命名解析古代方剂命名规律[J].中医杂志,2018,59(15):1291-1294.
- [3] 黄辛迪,李亚春,黄群富.基于词向量和神经网络的方剂分类模型研究[J].信息与电脑(理论版),2022,34(17):63-66.
- [4] 陈昭,曹燕凤,何帅兵,等.基于药性理论的清热药功效分类模型研究[J].中华中医药杂志,2017,32(5):2107-2111.
- [5] 郭永坤,章新友,刘莉萍,等.基于神经网络的中药方剂功效预测系统研究[J].时珍国医国药,2019,30(2):493-495.
- [6] GAO W Q, CHENG N, XIN G J, et al. TCM2Vec: A detached feature extraction deep learning approach of traditional Chinese medicine for formula efficacy prediction[J]. Multimed Tools Appl, 2023, 82(17):26987-27004.
- [7] 张明琪,邓鑫.基于集成学习后融合神经网络算法构建肝纤维化代偿期中医智能辨证模型的探讨[J].广州中医药大学学报,2023,40(10):2650-2660.
- [8] 姚帅君,闫敬来,杜彩凤,等.基于集成学习构建围绝经期综合征中医智能诊断模型[J].中医杂志,2023,64(6):572-580.
- [9] 刘晨沁,林高藏,周晶晶,等.基于BP神经网络和支持向量机的心房颤动分类方法研究[J].中国医疗器械杂志,2023,47(3):258-263.
- [10] 陆艺展,周学志.基于深度学习的计算病理学在结直肠癌预后预测和疗效评估中的研究进展[J].新乡医学院学报,2024,41(7):609-613.
- [11] 张岁霞,王亚勇,姜丹,等.基于BP神经网络的肝包虫CT图像的定量研究[J].北京生物医学工程,2023,42(5):448-455.
- [12] 江会运,朱海虹,宋灿磊,等.不同预测模型在金山区手足口病发病率预测中的应用[J].医学动物防制,2025,41(4):370-374.
- [13] 陈琳,冯慧芬,屈质,等.构建并验证反向传播神经网络模型对筛选重症手足口病影响因素的性能[J].安徽医科大学学报,2024,59(12):2222-2229.
- [14] 杨斌,李成华,江小平,等.一种用于提升深度学习分类模型准确率的正则化损失函数[J].中南民族大学学报(自然科学版),2020,39(1):74-78.
- [15] BRADLEY A P. The use of the area under the ROC curve in the evaluation of machine learning algorithms[J]. Pattern Recognit, 1997,30(7):1145-1159.
- [16] 杨杏丽.分类学习算法的性能度量指标综述[J].计算机科学,2021,48(8):209-219.
- [17] 张文彤.SPSS统计分析基础教程[M].3版.北京:高等教育出版社,2017:203-204.
- [18] 李德俊,黄永祥.以人工智能技术助推新时代中医药国际传播探析[J].传媒论坛,2024,7(14):53-56.
- [19] 杨涛,任海燕,周作建,等.人工智能赋能中医学高质量发展面临的问题与挑战[J].南京中医药大学学报,2024,40(12):1285-1290.
- [20] 李新龙,王世华,赵欣然,等.从“模糊性与精确性”探讨中医辨证诊断的智能化思路[J].中医杂志,2024,65(15):1555-1558,1564.
- [21] 赵丹宁,卢海霞,白森.基于图卷积神经网络的中药方剂功效分类与自动推荐[J].中草药,2024,55(18):6298-6304.
- [22] 王冰.重广补注黄帝内经素问[M].北京:中医古籍出版社,2015.
- [23] 张艳,张国霞.李中梓“肾为先天本,脾为后天本论”探析[J].湖南中医杂志,2015,31(4):143-144.
- [24] 刘晓燕,崔亚东,田合禄.中医四气五味理论与脏腑补泻关系的探讨[J].世界中医药,2021,16(1):121-124,129.

(收稿日期:2024-10-04 编辑:蒋凯彪)

(上接第131页)43-45.

- [25] 魏宇娇.基于眼压曲线的POAG生物节律紊乱机制及乌梅丸的干预作用研究[D].北京:中国中医科学院,2023.
- [26] 张倩,李春英,黄褐斑:流行病学、发病风险评估及机制探究[J].皮肤科学通报,2022,39(5):383-387.
- [27] 车琬钰,陶芳标,伍晓艳.昼夜节律紊乱与青少年焦虑抑郁共病的关联[J].中华预防医学杂志,2023,57(9):1469-1474.
- [28] 张凌媛,丁珊珊,康洁,等.围绝经期综合征肝郁证大鼠主要时钟基因表达的昼夜节律[J].中华中医药杂志,2021,36(5):2953-2956.
- [29] 乔明亮,梁硕,孟毅,等.柴胡皂苷A调节cAMP/PKA/CREB信号通路对失眠大鼠的改善作用及机制研究[J].中药新药与临床药理,2024,35(5):633-638.
- [30] 刘玉凤,黄枚,南丽红,等.古方半夏秫米汤对正常小鼠最大给药量及其对失眠模型大鼠作用的实验研究[J].中药药理与临床,2023,39(8):12-18.
- [31] 张保国,梁晓夏,刘庆芳.桂枝汤现代药效学研究[J].中国中药杂志,2007,32(7):557-561.
- [32] 林玮华,郭丽媛,蔡玲玲,等.张丰川教授治疗黄褐斑的辨证思路及临床经验总结[J].中医临床研究,2019,11(24):1-3.
- [33] 邓梦琪,林爽,丁慧.丁慧根据“月经周期”论治女性黄褐斑[J].中华中医药杂志,2019,34(10):4643-4645.
- [34] 黄蜀.电鍍针与子午流注选穴治黄褐斑对照观察[J].四川中医,1993,11(3):47-48.

(收稿日期:2024-11-25 编辑:时格格)