临床研究 DOI：10.13406/j.cnki.cyxb.004107

基于机器学习构建老年肌少性肥胖风险预测模型

范清清[1]，彭　朋[2]，李亚玲[3]，杨培基[1]，周艺林[2]，唐浩民[1]，毛霜严[1]，邓　丹[1]
（1.重庆医科大学公共卫生学院卫生统计教研室，重庆　400016；2.重庆市结核病防治所，重庆　400050；
3.重庆医科大学附属第一医院老年医学科，重庆　400016）

【摘　要】目的：基于机器学习探究老年住院患者肌少性肥胖的影响因素，构建较优的风险预测模型，为早期筛查肌少性肥胖提供工具。**方法：**回顾性收集2016年3月至2023年6月于重庆医科大学附属第一医院就诊的老年住院患者数据，基于单因素分析和最小绝对收缩和选择算子（least absolute shrinkage and selection operator，LASSO）回归筛选变量，多因素logistic回归探究肌少性肥胖影响因素，构建logistic回归、极端梯度提升（eXtreme gradient boosting，XGBoost）、随机森林（random forest，RF）和反向传播神经网络（back propagation neural network，BPNN）4种预测模型，识别最优模型，并采用沙普利值可加性解释（shapley additive explanation，SHAP）进行模型解释。**结果：**老年住院患者肌少性肥胖检出率为26.41%。衰弱前期[比值比（odds ratio，*OR*）=2.493]、衰弱（*OR*=4.091）、经年龄校正的共病指数（age-adjusted Charlson comorbidity index，aCCI）（*OR*=1.110）、认知障碍（*OR*=1.482）、体脂百分比（*OR*=1.114）和内脏脂肪面积（*OR*=1.014）是老年住院患者肌少性肥胖的独立危险因素（*P*<0.05）。BPNN的预测效能最优，模型测试集受试者工作特征曲线下面积（area under the curve，AUC）为0.842，Brier分数0.144，模型性能良好，临床决策曲线显示在阈值范围内，模型获益最大。SHAP可视化显示特征重要性前三依次是内脏脂肪面积、无衰弱和体脂百分比。**结论：**构建BPNN预测模型，为识别肌少性肥胖高危人群提供方法学参考。建议重点关注患有认知障碍、体脂百分比≥35%、内脏脂肪面积≥100 cm^2、衰弱评估异常的老年住院患者，并对高危人群开展综合性干预。

【关键词】肌少性肥胖；机器学习；预测模型；反向传播神经网络；沙普利值可加性解释
【中图分类号】R589.2　　**【文献标志码】**A

Construction of a risk prediction model for sarcopenic obesity in the elderly based on machine learning

Fan Qingqing[1], Peng Peng[2], Li Yaling[3], Yang Peiji[1], Zhou Yilin[2], Tang Haomin[1], Mao Shuangyan[1], Deng Dan[1]
(1.Department of Health Statistics, College of Public Health, Chongqing Medical University; 2.Chongqing Municipal Institute of Tuberculosis; 3.Department of Geriatrics, The First Affiliated Hospital of Chongqing Medical University)

【Abstract】*Objective*: To investigate the influencing factors for sarcopenic obesity in elderly inpatients based on machine learning, to construct an optimized risk prediction model, and to provide a tool for early screening of sarcopenic obesity. ***Methods*:** A retrospective analysis was performed for the data of the elderly inpatients who were treated in The First Affiliated Hospital of Chongqing Medical University from March 2016 to June 2023. The univariate analysis and the least absolute shrinkage and selection operator regression analysis were used to identify related variables, and the multivariate logistic regression analysis was used to investigate the influencing factors for sarcopenic obesity. Four predictive models were constructed, i.e., logistic regression model, eXtreme Gradient Boosting (XGboost) model, random forest (RF) model, and back propagation neural network (BPNN) model. The optimal model was identified, and Shapley Additive Explanation (SHAP) was used for model interpretation. ***Results*:** The detection rate of sarcopenic obesity was 26.41% among the elderly inpatients. Pre-frailty (odds ratio [*OR*]=2.493, *P*<0.05), frailty (*OR*=4.091, *P*<0.05), age-adjusted Charlson comorbidity index (*OR*=1.110, *P*<0.05), cognitive impairment (*OR*=1.482, *P*<0.05), percentage of body fat (*OR*=1.114, *P*<0.05), and visceral fat area (*OR*=1.014, *P*<0.05) were identified as independent risk factors for sarcopenic obesity in elderly inpatients. The BPNN model showed the best predictive performance, with an area under the receiver operating characteristic curve of 0.842 in the test set, and this model had a Brier score of 0.144, suggesting that it had good performance. The clinical decision curve analysis showed that the model achieved maximum net benefit within the threshold range. SHAP visualization showed that the top three features in terms of importance were visceral fat area, absence of frailty, and percentage of body fat. ***Conclusion*:** The BPNN predictive model is constructed to

作者介绍：范清清，Email：972475107@qq.com，
研究方向：卫生统计、人群健康决策。
通信作者：邓　丹，Email：100079@cqmu.edu.cn。
基金项目：重庆市妇幼保健院一般资助项目（编号：CQFYZC01003）。
优先出版：https://link.cnki.net/urlid/50.1046.R.20260427.1448.006
（2026-04-28）

provide a methodological reference for identifying the population at a high risk of sarcopenic obesity. It is recommended to focus on the elderly inpatients with cognitive impairment, percentage of body fat ≥35%, visceral fat area ≥100 cm^2, or abnormal frailty assessment, and to implement comprehensive interventions for these high-risk individuals.

【Key words】sarcopenic obesity; machine learning; predictive model; back propagation neural network; Shapley additive explanation

在当前人口老龄化和肥胖流行并行的背景下，肌少性肥胖（sarcopenic obesity，SO）作为一种肌少症与肥胖共存的新型临床代谢综合征，已成为影响老年人健康的重要公共卫生问题。数据显示，全球11%的老年人患有这种“双重负担”综合征，且随年龄增长呈显著上升趋势[1]。与单一的肌少症和肥胖相比，SO表现出更为复杂的协同病理效应，加剧患者代谢紊乱、认知功能障碍、躯体能力衰退及全因死亡风险，呈现“1+1>2”的健康损害[2-3]。而老年住院患者常具有多病共存、病情复杂、转归能力受限等临床特征。在这一人群中，SO会显著增加跌倒、感染、术后并发症等不良健康结局的发生风险，加重家庭照护负担与医疗卫生成本[4-6]。因此，明确老年住院患者SO的影响因素，开发效能优异的预测模型，为早期识别风险、制定针对性干预措施提供依据，对改善临床预后、优化医疗资源配置具有重要意义。

当前，肌少性肥胖的研究在国内外呈现不同的发展态势。国内相关研究尚处于初步探索阶段。相比之下，国际研究已形成较为系统的框架，多聚焦于肌少性肥胖的评估方法、风险因素、发病机制、多种重大健康结局的关联验证和干预措施等方面[7-11]。针对老年住院患者，多从疾病预后、不良结局、干预治疗等领域开展研究。然而，诊断标准不统一、机制不明、临床转化困难等仍制约临床早期识别及管理。尽管2022年的欧洲临床营养与代谢学会（European Society for Clinical Nutrition and Metabolism，ESPEN）/欧洲肥胖研究学会（European Association for the Study of Obesity，EASO）等国际共识已为肌少性肥胖的诊断提供了框架，评估工具在临床实践中的可及性仍然存在问题。目前影响因素多从单一维度分析，考虑到SO是衰老、神经内分泌、生活方式等多层面因素复杂交互作用的结果，对于多种影响因素如何共同作用的认识仍存在缺口。

因此，本研究在统一诊断框架下，探究影响老年住院患者肌少性肥胖的关键因素，基于机器学习开发并验证适用于临床实践的较优早期风险预测模型，以期改善老年住院患者的功能预后，减轻社会照护负担。

1 资料与方法

1.1 研究对象

本研究以2016年3月至2023年6月于重庆医科大学附属第一医院老年病科就诊，并参与身体成分测量的老年住院患者为研究对象，共纳入1 488例。纳入标准：①年龄≥65岁；②生命体征平稳，意识清醒，能够有效配合完成身体测量、问卷调查及基本功能评估；③签署知情同意书。排除标准：①因疾病或残疾（如严重关节炎、偏瘫、截肢）无法完成握力等骨骼肌功能测试；②存在严重认知障碍或精神障碍；③存在严重水肿、腹水、体腔积液或体内有金属物质植入；④处于疾病终末期。研究已通过重庆医科大学附属第一医院伦理医学会审批（伦理审批号：K2023-108）。

1.2 诊断标准

依据2022年ESPEN和EASO《肌肉减少性肥胖的定义和诊断标准共识》[1]，肌少性肥胖的诊断标准：①体质指数（body mass index，BMI）≥25 kg/m^2；②腰围（waist circumference，WC）男性≥97.6 cm，女性≥87.4 cm；③骨骼肌功能参数：取优势手握力（hand grip strength，HGS）3次最高值，男性<28 kg、女性<18 kg；④身体成分参数：生物电阻抗分析法测定脂肪量（fat mass，FM）升高，男性>29.7%，女性>37.2%；⑤体质量调整的总骨骼肌质量（skeletal muscle mass/weight，SMM/W）下降，男性<42.9%、女性<35.6%，符合上述①或②，③，④及⑤中相应标准的诊断为肌少性肥胖。

1.3 资料收集

收集患者年龄、性别、婚姻状况、文化程度、月收入等一般人口学特征；吸烟、饮酒、居住情况、体育锻炼等行为方式；经年龄校正的共病指数（age-adjusted Charlson comorbidity index，aCCI）、疾病史、抑郁、衰弱、日常生活能力、营养状况、认知功能等健康相关指标；身高、体质量、FM、SMM、BMI、体脂百分比（percent body fat，PBF）、腰臀比（waist-hip ratio，WHR）、内脏脂肪面积（visceral fat area，VFA）等身体成分测量指标。其中，身体成分采用Inbody230生物电阻抗装置测量；aCCI，基于患者所患16种常见共病情况和年龄阶段量化合并症风险[12]；抑郁采用老年抑郁量表（geriatric depression scale-5，GDS-5）评估[13]，总分5分，≥2分视为异常；衰弱采用Fried衰弱量表[14]评估，0分为无衰弱，1~2分为衰弱前期，>2分为衰弱；日常生活能力采用日常生活活动能力量表（activity of daily living scale，ADL）的Barthel指数评定[15]，100分表示无需依赖他人，61~99分表示轻度依赖，<61分表示中重度依赖；营养状况采用微型营养评估量表（mini nutritional

assessment，MNA）评估[16]，总分 30 分，<17 分判定为营养不良；认知功能采用简易智力状态检查（minimum mental state examination，MMSE）评估[17]，总分 30 分，对不同文化程度的群体，认知功能障碍的判定标准如下：文盲<17 分，小学文化<20 分，中学及以上文化<27 分。

1.4 数据处理

数据清洗阶段，本课题组对异常值与逻辑错误进行核查处理，以确保数据完整有效。本研究中，握力变量存在少量缺失，缺失率<10%。其主要原因为早期数据录入系统允许以“≥某值”或“<某值”的形式记录。经专家判断，该缺失类型为随机缺失。因此，采用基于性别分组并结合区间逻辑的均值填补法处理该部分缺失值。此外，为适应研究设计和分析需求，本研究对月收入、衰弱程度及日常生活能力等连续变量进行离散化处理，依据临床常用标准转换为分类变量。具体变量赋值见表 1。

表 1 变量赋值表

变量	变量名称	变量赋值
因变量	肌少性肥胖	否=0，是=1
自变量	性别	男=0，女=1
	婚姻状况	在婚=0，非在婚=1
	居住地	城市=0，农村=1
	教育程度	小学及以下=1，初中=2，高中及中专=3，大专及以上=4
	居住状态	和配偶居住=1，代际居住=2，独居=3，护理机构=4
	月收入	<3 000=1，3 000~5 000=2，≥5000=3
	吸烟	否=0，过去吸烟已戒=1，是=2
	饮酒	否=0，过去饮酒已戒=1，是=2
	室外锻炼	不参加=0，30 min/d=1，≥1 h/d=2
	参与家务	不做=0，有时做=1，经常做=2
	喜欢活动类型	无=0，静态活动=1，动态活动=2
	自评健康	差=1，一般=2，好=3
	衰弱	无衰弱=0，衰弱前期=1，衰弱=2
	抑郁	正常=0，异常=1
	营养状况	营养良好=0，营养不良=1
	日常生活能力	无需依赖=0，轻度依赖=1，中重度依赖=2
	认知功能	正常=0，异常=1
	冠心病	无=0，有=1
	高血压	无=0，有=1
	骨质疏松	无=0，有=1
	脑卒中	无=0，有=1
	糖尿病	无=0，糖尿病无并发症=1，糖尿病伴并发症=2
	年龄	连续型变量
	aCCI	连续型变量
	PBF	连续型变量
	WHR	连续型变量
	VFA	连续型变量

1.5 研究方法

1.5.1 最小绝对收缩和选择算子 最小绝对收缩和选择算法（least absolute shrinkage and selection operator，LASSO）是一种基于正则化的线性回归扩展方法。其核心是在最小二乘法的损失函数中加入惩罚项，通过调节正则化参数 λ，将部分回归系数压缩至零，从而在高维数据分析中同步实现变量筛选与模型复杂度控制，有效避免过拟合，提升模型泛化性能。

1.5.2 logistic 回归 logistic 回归作为一种经典的广义线性模型与监督学习方法，通过引入 Sigmoid 函数，将线性回归的输出映射至 0~1 区间，转化为表征概率的连续值，从而实现对二分类问题的预测。因其模型结构简洁、计算效率高且结果具有良好的可解释性，logistic 回归已成为处理二分类问题的常用有效建模工具。

1.5.3 极端梯度提升算法 极致梯度提升算法（eXtreme Gradient Boosting，XGBoost）是一种集成学习算法，通过迭代构建决策树来逼近复杂函数关系。每棵新树以前序模型的预测残差为学习目标，逐步提升整体预测性能。该算法在目标函数中显式引入正则化项以控制模型复杂度，从而在保证高预测精度的同时有效避免过拟合。此外，该算法在算法层面融合了缓存感知、数据压缩等工程优化技术，具有出色的计算效率，已成为处理结构化数据的主流建模工具。

1.5.4 随机森林 随机森林（random forest，RF）是一种基于决策树的集成学习算法，通过构建多棵决策树并集成其预测结果以提升模型性能与稳定性。其核心机制在于双重随机性：每棵树的训练采用 Bootstrap 抽样生成差异化样本，节点分裂时仅从随机特征子集中选择最优分裂特征。该设计有效增强了模型泛化能力，降低了过拟合风险。算法支持并行化训练，对高维数据与噪声数据具有良好的鲁棒性，因此在分类与回归任务中应用广泛。

1.5.5 反向传播神经网络 反向传播神经网络（back propagation neural network，BPNN）是一种采用误差反向传播算法训练的多层前馈神经网络。其结构包含输入层、隐藏层与输出层，通过加权连接实现层间非线性映射。训练过程首先进行前向传播计算输出，基于损失函数计算误差后，采用梯度下降法沿网络反向逐层传递误差，并利用链式法则更新权重，以逐步逼近目标函数最优解。该算法具备强大的非线性建模与特征学习能力，广泛应用于分类、回归及模式识别等复杂任务。

1.5.6 沙普利值可加性解释 沙普利值可加性解释（shapley additive explanation，SHAP）是一种基于合作博弈论的模型解释方法。它将预测值分解为基线值与各特征贡献之和，通过赋予每个特征一个 SHAP 值，量化其对单个预测样本的影响。该方法同时支持模型整体的特征重要性分析和个体预测的成因解读，从而揭示机器学习模型的决策依据。

1.6 统计学方法

研究采用 Excel 对数据进行预处理，利用 R 4.4.1 软件进行数据分析。计量资料依据是否满足正态分布，分别采用均数 ± 标准差（$\bar{x} \pm s$）或中位数（四分位间距）[$M_d(P_{25}, P_{75})$]表

示；计数资料采用频数和百分比表示。组间比较根据资料类型及分布特征，分别采用 t 检验、卡方检验、趋势卡方检验、Mann-Whitney U 检验，检验水准 α=0.05。

模型构建阶段，先通过单因素分析剔除与结局变量无关的变量，采用LASSO回归进行变量稀疏化筛选，以降低多重共线性影响。随后将数据集以7∶3比例随机划分为训练集和测试集，在训练集中采用逐步回归法建立logistic回归预测模型，并进一步引入XGBoost、RF、BPNN机器学习算法构建分类预测模型。模型性能以测试集的受试者工作特征曲线下面积（area under the curve，AUC）、混淆矩阵衍生指标（如精确率、召回率、灵敏度、特异度及F1值）综合评估，并绘制校准曲线、临床决策曲线。为增强模型可解释性，应用SHAP计算各特征贡献值，并借助特征重要性图、蜂群图、依赖图进行全局与局部解释。

2 结 果

2.1 单因素分析

共纳入1 488例老年住院患者，其中SO患者393例，非SO患者1 095例，肌少性肥胖检出率为26.41%。患者平均年龄为（78.43±7.54）岁。老年住院患者中，冠心病、高血压、骨质疏松、脑卒中、糖尿病患病率分别为41.87%、68.62%、30.58%、26.48%、35.89%；抑郁、营养不良、认知障碍检出率分别为24.06%、38.58%、21.44%。单因素分析结果显示，除居住地、月收入、冠心病史、骨质疏松外，其余变量在两组间的差异均有统计学意义（P<0.05）。见表2。

表2 单因素分析[n,%,$\bar{x}\pm s$;M_d(P_{25},P_{75})]

变量	分类	无肌少性肥胖（n=1 095）	肌少性肥胖（n=393）	χ^2/Z/t值	P值
性别	男	508(79.6)	130(20.4)	20.930	<0.001
	女	587(69.1)	263(30.9)		
婚姻状况	在婚	807(75.9)	256(24.1)	10.382	0.001
	非在婚	288(67.8)	137(32.2)		
居住地	城市	942(74.2)	327(25.8)	1.834	0.176
	农村	153(69.9)	66(30.1)		
教育程度	小学及以下	274(67.5)	132(32.5)	11.095[a]	0.001
	初中	253(74.2)	88(25.8)		
	高中及中专	258(75.0)	86(25.0)		
	大专及以上	310(78.1)	87(21.9)		
居住状态	和配偶居住	679(76.6)	207(23.4)	11.042	0.012
	代际居住	244(68.3)	113(31.7)		
	独居	126(71.2)	51(28.8)		
	护理机构	46(67.6)	22(32.4)		
月收入（元）	<3 000	212(68.6)	97(31.4)	1.130[a]	0.288
	3 000~5 000	415(75.9)	132(24.1)		
	>5 000	468(74.1)	164(25.9)		
吸烟	否	829(71.7)	329(28.3)	23.386	<0.001
	过去吸烟已戒	153(73.6)	55(26.4)		
	是	113(91.9)	10(8.1)		
饮酒	否	916(72.4)	350(27.6)	8.082	0.018
	过去饮酒已戒	88(77.2)	26(22.8)		
	是	91(84.3)	17(15.7)		
室外锻炼	基本不参加	557(68.4)	257(31.6)	26.022[a]	<0.001
	30 min/d	292(77.7)	84(22.3)		
	≥1 h/d	246(82.6)	52(17.4)		
参与家务	不做	310(63.0)	182(37.0)	38.777[a]	<0.001
	有时做	239(77.1)	71(22.9)		
	经常做	546(79.6)	140(20.4)		
喜欢活动类型	无	210(74.5)	72(25.5)	16.012	<0.001
	静态活动	437(68.6)	200(31.4)		
	动态活动	448(78.7)	121(21.3)		
自评健康	差	148(78.7)	40(21.3)	9.528[a]	0.002
	一般	484(76.2)	151(23.8)		

续表2

变量	分类	无肌少性肥胖（n=1 095）	肌少性肥胖（n=393）	$\chi^2/Z/t$ 值	P 值
	好	463(69.6)	202(30.4)		
衰弱	无衰弱	381(89.2)	46(10.8)	91.684[a]	<0.001
	衰弱前期	339(73.7)	121(26.3)		
	衰弱	375(62.4)	226(37.6)		
抑郁	正常	848(75.0)	282(25.0)	5.120	0.024
	异常	247(69.0)	111(31.0)		
营养状况	营养良好	643(70.4)	271(29.6)	12.786	<0.001
	营养不良	452(78.7)	122(21.3)		
日常生活能力	无需依赖	608(81.7)	136(18.3)	50.437[a]	<0.001
	轻度依赖	420(66.5)	212(33.5)		
	中重度依赖	67(59.8)	45(40.2)		
认知功能	正常	898(76.8)	271(23.2)	29.254	<0.001
	异常	197(61.8)	122(38.2)		
冠心病	无	642(74.2)	223(25.8)	0.423	0.515
	有	453(72.7)	170(27.3)		
高血压	无	387(82.9)	80(17.1)	30.161	<0.001
	有	708(69.3)	313(30.7)		
骨质疏松	无	765(74.1)	268(25.9)	0.380	0.538
	有	330(72.5)	125(27.5)		
脑卒中	无	821(75.0)	273(25.0)	4.513	0.034
	有	274(69.5)	120(30.5)		
糖尿病	无	741(77.7)	213(22.3)	25.372[a]	<0.001
	无并发症	66(73.3)	24(26.7)		
	有并发症	288(64.9)	156(35.1)		
年龄（岁）		77.69 ± 7.48	80.49 ± 7.31	−6.407[b]	<0.001
aCCI		5(4,6)	5(4,6)	−6.111[c]	<0.001
PBF		30.70(25.00,35.60)	38.20(34.75,41.75)	−17.632[c]	<0.001
WHR		0.89 ± 0.07	0.93 ± 0.06	−10.43[b]	<0.001
VFA		85.40(65.50,113.90)	132.50(107.80,154.50)	−18.381[c]	<0.001

注：a，采用趋势 χ^2 检验；b 采用 t 检验；c，采用 Z 检验，其余采用 χ^2 检验

2.2 肌少性肥胖影响因素分析

2.2.1 LASSO 变量筛选 排除居住地、月收入、冠心病史、骨质疏松 4 个单因素分析差异无统计学意义，将剩余变量纳入 LASSO 进行降维和去共线性处理。LASSO 通过逐步增大 λ 值，将部分特征系数压缩为零，实现特征选择。图 1 显示，λ_{min}=0.007 251 5 时，交叉验证误差最小。此时模型纳入 15 个变量，保留较多特征的同时保持较低误差；λ_{1se}=0.035 261 17 时，对应最小误差一个标准差范围内的最简模型。为进一步提升泛化能力，控制过拟合，达到降维与解释优化的目的，选择 λ_{1se}=0.035 261 17 时筛选的变量进入模型，包括年龄、衰弱、aCCI、认知功能，体脂百分比和内脏脂肪面积共 6 个变量。

2.2.2 多因素分析 多因素 logistic 逐步回归结果如表 3 显示，排除年龄变量后，衰弱前期[比值比（odds ratio，OR）=2.493，P<0.001]、衰弱（OR=4.091，P<0.001）、aCCI（OR=1.110，P=0.012）、认知障碍（OR=1.482，P=0.025）、PBF（OR=1.114，P<0.001）和 VFA（OR=1.014，P=0.001）均为老年住院患者肌少性肥胖的危险因素。

2.3 4 种肌少性肥胖预测模型比较

将多因素分析中有意义的 5 个变量纳入 XGBoost 模型，随机森林和 BPNN 并计算测试集的灵敏度、特异度、准确度、阳性预测值、阴性预测值、F1 分数和 AUC，结果见表 4。BPNN 预测模型在测试集中的 AUC 最高，综合评估各模型，确认 BPNN 具有较好的预测效能，其中灵敏度 0.817，特异度 0.701，准确度 0.792，F1 分数 0.860，AUC 为 0.842，各模型 AUC 比较如图 2。

BPNN 预测模型 Nagelkerke 伪 R^2=0.454，Brier 分数=0.144，表明 BPNN 预测模型质量良好，具有较强的解释力。临床决策曲线显示，在所有合理的临床决策阈值范围内，BPNN 曲线均高于 All 和 None 曲线。在阈值 0.3 时，模型获益最大，提示模型具有较高的临床实用价值。校准曲线、决策曲线见图 3、图 4。

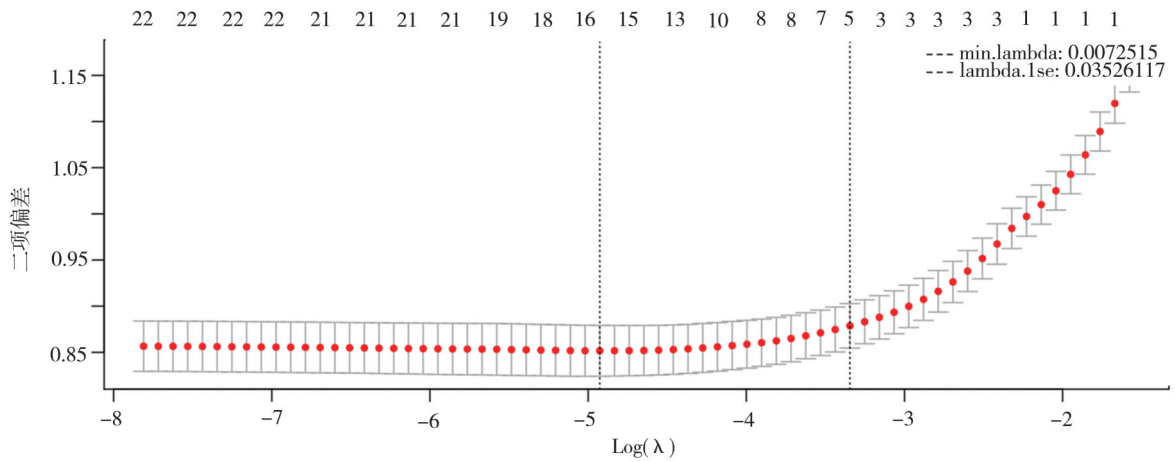


图1　LASSO 回归交叉验证图

表3　多因素分析

变量	偏回归系数	标准误	*Z*	*P*	*OR*（95%CI）
常量	−7.863	0.576	−13.662	<0.001	0.000 3（0.000 1~0.001 1）
衰弱前期	0.914	0.210	4.344	<0.001	2.493（1.661~3.793）
衰弱	1.409	0.216	6.535	<0.001	4.091（2.699~6.292）
aCCI	0.105	0.042	2.522	0.012	1.110（1.023~1.205）
认知障碍	0.394	0.176	2.236	0.025	1.482（1.049~2.093）
PBF	0.108	0.025	4.346	<0.001	1.114（1.061~1.170）
VFA	0.014	0.004	3.252	0.001	1.014（1.006~1.023）

注：Hosmer–Lemeshow 拟合优度检验中 χ^2=7.342，*P*=0.500；模型似然比检验 χ^2=466.56，*P*<0.001，Nagelkerke R^2=0.393，回归模型拟合效果较好

表4　多个预测模型效能比较

预测模型	灵敏度	特异度	准确度	阳性预测值	阴性预测值	F1 分数	AUC
Logistic	0.790	0.679	0.770	0.918	0.417	0.849	0.820
XGBoost	0.795	0.648	0.765	0.898	0.447	0.848	0.827
RF	0.911	0.432	0.770	0.793	0.671	0.848	0.837
BPNN	0.817	0.701	0.792	0.908	0.515	0.860	0.842

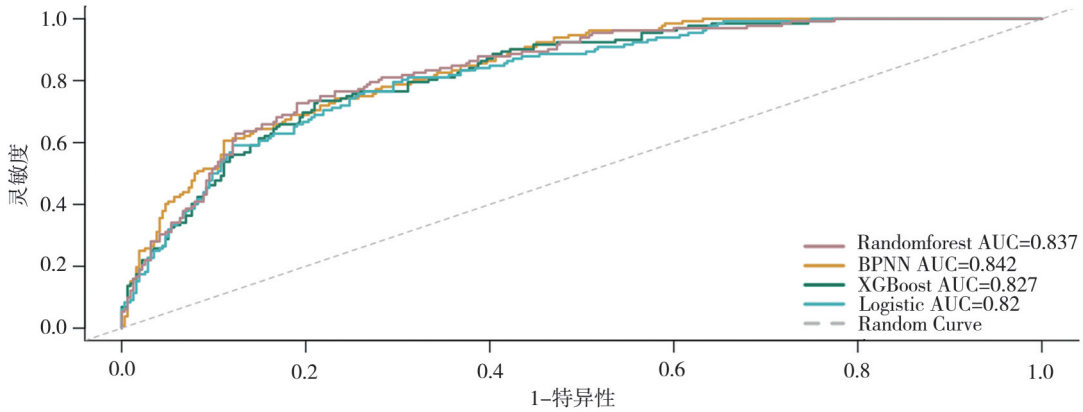


图2　多个模型测试集 AUC 比较

2.4　SHAP 解释最优 BPNN 模型

各特征对预测老年住院患者是否患肌少性肥胖的平均影响幅度如图 5 所示，特征的重要性依次为，VFA，无衰弱，PBF，认知障碍、衰弱、衰弱前期、共病指数。其中，VFA 是模型中最重要的特征，对预测结果贡献最大。SHAP 蜂群图显示 VFA 对模型预测具有双向作用，无衰弱的高 SHAP 值主要分布在负值区域，认知障碍、衰弱主要分布在正值区域（图 6）。VFA 特征依赖图显示，VFA 较低时具有保护作用，风险

较低，VFA 超过约 100 cm^2后，风险随 VFA 增加而上升，VFA 在 140~190 cm^2对风险的贡献最大（图 7）。PBF 依赖图显示 35% 是本研究中预测肌少性肥胖风险的重要临界参考值（图 8）。

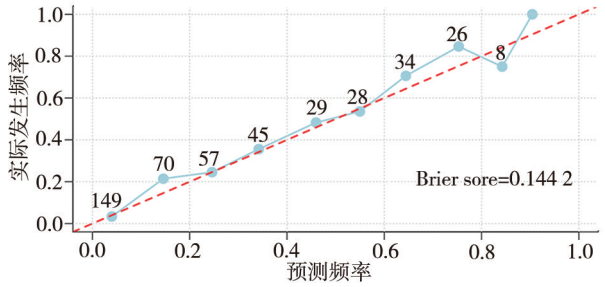


图 3　BPNN 测试集校准曲线

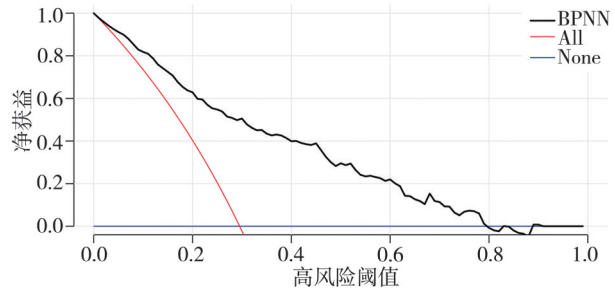


图 4　BPNN 测试集临床决策曲线

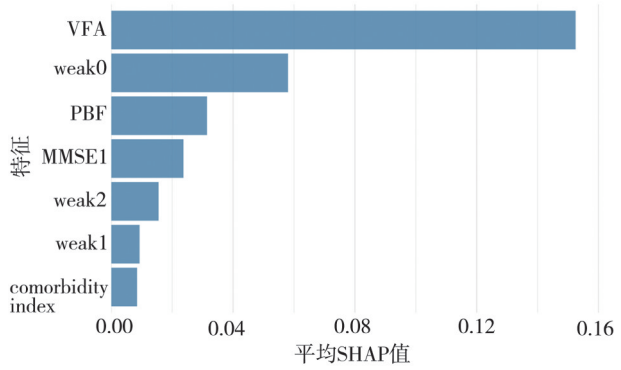


图 5　BPNN 模型特征重要性

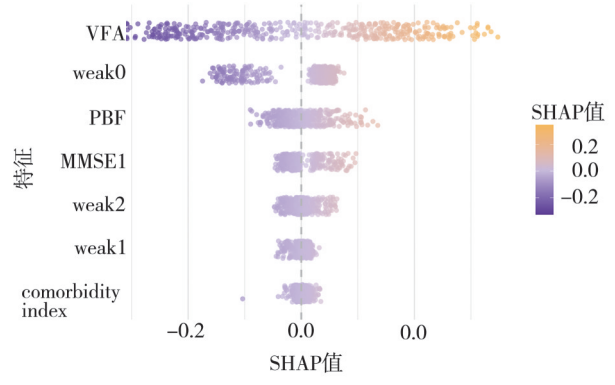


图 6　BPNN 模型蜂群图

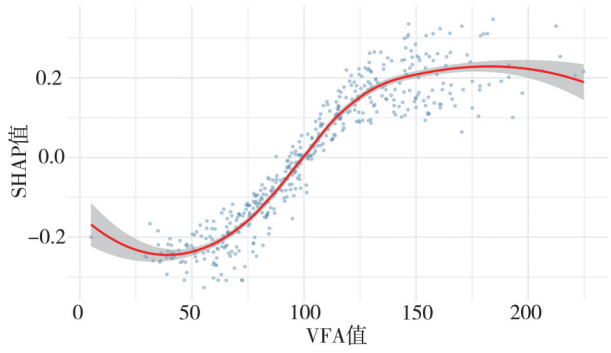


图 7　VFA 特征依赖图

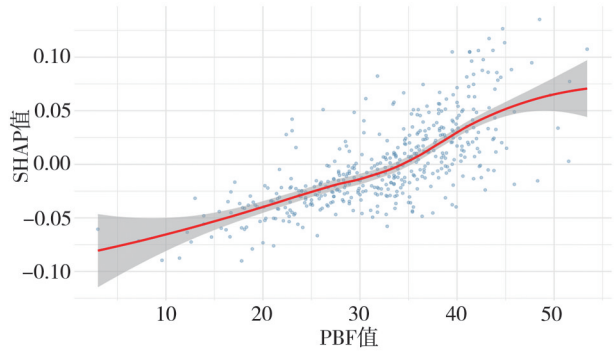


图 8　PBF 特征依赖图

3　讨　论

本研究中老年住院患者肌少性肥胖检出率为 26.41%，与国内 Li H 等[18]（27.67%）和土耳其 Silay K 和 Selvi Oztorun H[8]（24.5%）同类住院患者研究结果相近，但高于基于社区老年人群的世界报告率（11%）及大型公共数据库，如美国国家健康与营养调查（National Health and Nutrition Examination Survey，NHANES）[19]（20.3%）、中国健康与养老追踪调查（China Health and Retirement Longitudinal Study，CHARLS）[20]（14.3%）。提示相较于社区老年人，老年住院患者发生肌少性肥胖的风险更高，多种住院相关因素共同加剧了肌肉流失和脂肪异常累积并存的状况，应重点关注该人群。

衰弱前期（*OR*=2.493，*P*<0.001）、衰弱（*OR*=4.091，*P*<0.001）均为老年住院患者肌少性肥胖的危险因素，与多数研究结果一致。随着衰弱程度加重，肌少性肥胖的罹患风险显著增加[9]。1 项 meta 分析显示肌少性肥胖的老年人也更易衰弱，提示二者之间存在双向关联[21-22]。衰弱状态常伴随活动能力减退、营养摄入不足、慢性炎症水平升高及多重共

病，这些因素共同促使肌肉蛋白质合成减少、分解代谢增强，直接加速肌肉流失。与此同时，活动量下降及代谢紊乱可进一步促进脂肪异常积聚与异位分布，尤其是内脏脂肪堆积与肌肉内脂肪浸润，最终共同导致肌少性肥胖的发生[9,23]。

本研究多因素分析发现，校正认知功能后，ADL受损与肌少性肥胖的关联无统计学意义，而认知障碍保持独立的强相关性（*OR*=1.482，*P*=0.025）[24-26]。该结果与既往研究中认知障碍在肌少性肥胖影响ADL路径中起中介作用的模型一致[18]。提示认知障碍可能不仅是肌少性肥胖导致功能下降的中间环节，其本身或是驱动肌少性肥胖发生与进展的更强上游风险因素。日常生活活动能力受损在此复杂关联中，可能仅作为下游表现或伴随状态存在。此外，研究发现aCCI升高与老年住院患者肌少性肥胖发生风险呈正相关[27]。这一关联可能与aCCI所反映的慢性低度炎症状态及由此引发的营养物质消耗密切相关。

现有研究表明，PBF和VFA是识别和评估肌少性肥胖的关键身体成分指标。目前多数研究主要围绕PBF作为诊断肌少性肥胖的界值进行探索[10,28-29]。本研究进一步证实PBF（*OR*=1.114，*P*<0.001）与VFA（*OR*=1.014，*P*=0.001）均为老年住院患者发生肌少性肥胖的独立危险因素，印证了脂肪过量积累在该综合征中的核心作用。值得注意的是，一项基于养老机构老年人的前瞻性队列研究提示，以PBF定义的肌少性肥胖与死亡风险显著相关，而基于BMI、WC等传统指标的定义则未见类似关联，表明PBF在识别具有临床不良结局风险的肌少性肥胖亚型中的独特价值[29]。另有研究表明，由骨矿物质含量、PBF、VFA及四肢骨骼肌指数构成的综合指标在诊断肌少性肥胖时具有较高的判别效能。这表明，临床评估中联合脂肪与肌肉参数能更全面评估身体成分异常，有助于早期识别高危个体并开展干预。

本研究构建的BPNN模型在测试集中AUC值为0.842，显著高于Guo JL等[19]报道的神经网络模型（AUC=0.654），且后者构建的最优模型为梯度提升机（Gradient Boosting Machine，GBM）。上述性能差异可能与2项研究在肌少性肥胖的定义标准及纳入的预测变量特征不同有关。此外，本研究基于SHAP可解释性分析显示，该神经网络模型中特征重要性排序前三的依次为内脏脂肪面积、无衰弱状态和体脂百分比，三者累计贡献率达80%。其中，VFA低于100 cm^2，PBF低于35%可能有助于降低肌少性肥胖风险，该结果可为后续探讨肌少性肥胖临床诊断界值提供参考。

尽管本研究通过多种机器学习方法探索了老年住院患者肌少性肥胖风险的最佳预测模型，但仍存在一定局限性。首先，肌少性肥胖尚无统一的诊断标准；其次，本研究数据来源于单中心，且以回顾性收集的量表数据为主，可能存在信息偏倚；此外，收集的特征主要基于问卷调查和身体成分测量数据，未纳入实验室指标，限制了对该疾病病理生理机制的探讨。未来有必要开展前瞻性、多中心研究，在内部与外部验证评估模型预测效能的基础上，适当补充实验室指标特征进行分析，以提升模型的全面性与临床适用性。

利益冲突 所有作者声明不存在利益冲突

作者贡献声明 范清清：研究方案设计、分析数据、论文撰写；彭朋：统计分析、初稿撰写；李亚玲：研究实施；杨培基：数据收集；周艺林：论文修改；唐浩民：数据整理；毛霜严：数据清洗；邓丹：研究提供指导与质量把关

参 考 文 献

[1] 刘妍慧，陈树春. 2022年欧洲临床营养与代谢学会和欧洲肥胖研究学会《肌肉减少性肥胖的定义和诊断标准共识》解读及启示[J]. 中国全科医学，2023，26(12)：1422-1428.
Liu YH，Chen SC. Interpretation and clinical significance of the definition and diagnostic criteria for sarcopenic obesity：ESPEN and EASO consensus statement[J]. Chin Gen Pract，2023，26(12)：1422-1428.

[2] Evans K，Abdelhafiz D，Abdelhafiz AH. Sarcopenic obesity as a determinant of cardiovascular disease risk in older people：a systematic review[J]. Postgrad Med，2021，133(8)：831-842.

[3] Atkins JL，Whincup PH，Morris RW，et al. Sarcopenic obesity and risk of cardiovascular disease and mortality：a population-based cohort study of older men[J]. J Am Geriatr Soc，2014，62(2)：253-260.

[4] Xu YH，Song TR，Cao L，et al. Impact of sarcopenic obesity on postoperative outcomes in patients with IBD after bowel resection surgery：a retrospective cohort study[J]. Dis Colon Rectum，2026，69(1)：53-63.

[5] Xia MF，Chen LY，Wu L，et al. Sarcopenia，sarcopenic overweight/obesity and risk of cardiovascular disease and cardiac arrhythmia：a cross-sectional study[J]. Clin Nutr，2021，40(2)：571-580.

[6] Öztürk ZA，Türkbeyler İH，Abiyev A，et al. Health-related quality of life and fall risk associated with age-related body composition changes；sarcopenia，obesity and sarcopenic obesity[J]. Intern Med J，

2018,48(8):973-981.

[7] Seo HS, Lee H, Kim S, et al. Paravertebral muscles as indexes of sarcopenia and sarcopenic obesity: comparison with imaging and muscle function indexes and impact on cardiovascular and metabolic disorders [J]. AJR Am J Roentgenol,2021,216(6):1596-1606.

[8] Silay K, Selvi Oztorun H. Sarcopenic obesity is linked to worse clinical outcomes than sarcopenia or obesity alone in hospitalized older adults[J]. BMC Geriatr,2025,25(1):443.

[9] Hirani V, Naganathan V, Blyth F, et al. Longitudinal associations between body composition, sarcopenic obesity and outcomes of frailty, disability, institutionalisation and mortality in community-dwelling older men: The Concord Health and Ageing in Men Project[J]. Age Ageing,2017,46(3):413-420.

[10] Luo X, Cai B, Jin WW. The prevalence rate of adult sarcopenic obesity and correlation of appendicular skeletal muscle mass index with body mass index, percent body fat, waist-hip ratio, basal metabolic rate, and visceral fat area[J]. Metab Syndr Relat Disord,2023,21(1):48-56.

[11] Jiang ML, Ren X, Han LY, et al. Associations between sarcopenic obesity and risk of cardiovascular disease: a population-based cohort study among middle-aged and older adults using the CHARLS[J]. Clin Nutr,2024,43(3):796-802.

[12] Charlson M, Szatrowski TP, Peterson J, et al. Validation of a combined comorbidity index[J]. J Clin Epidemiol,1994,47(11):1245-1251.

[13] Brañez-Condorena A, Soriano-Moreno DR, Navarro-Flores A, et al. Accuracy of the Geriatric Depression Scale(GDS)-4 and GDS-5 for the screening of depression among older adults: a systematic review and meta-analysis[J]. PLoS One,2021,16(7):e0253899.

[14] 刘 蓓. 基于综合评估的高龄老人的临床特点分析[D]. 重庆：重庆医科大学,2019.

Liu B. Analysis of advanced ages' clinical characteristics based on comprehensive geriatric assessment[D]. Chongqing: Chongqing Medical University,2019.

[15] 赵元萍,丁 睿,谢 红. 中国版日常生活活动能力量表编制与信效度验证[J]. 实用老年医学,2022,36(12):1215-1219.

Zhao YP, Ding R, Xie H. Development and validation of reliability and validity of Chinese version of activities of daily living scale[J]. Pract Geriatr,2022,36(12):1215-1219.

[16] 周文婷,侯韦莲,李 毅. 微型营养评价对高龄住院病人生存结局的预测价值研究[J]. 肠外与肠内营养,2024,31(6):321-328.

Zhou WT, Hou WL, Li Y. The predictive value of mini-nutritional assessment on survival outcome of elderly inpatients[J]. Parenter Enter Nutr,2024,31(6):321-328.

[17] Jia XF, Wang ZH, Huang FF, et al. A comparison of the Mini-Mental State Examination (MMSE) with the Montreal Cognitive Assessment (*MoCA*) for mild cognitive impairment screening in Chinese middle-aged and older population: a cross-sectional study[J]. BMC Psychiatry,2021,21(1):485.

[18] Li H, Shen HF, Yu L, et al. Cognitive impairment mediates the association between sarcopenic obesity and daily living ability in the frail older population[J]. Exp Gerontol,2025,209:112833.

[19] Guo JL, He QH, Li YH. Machine learning-based online web calculator predicts the risk of sarcopenic obesity in older adults[J]. Aging Clin Exp Res,2025,37(1):210.

[20] Peng L, Xiang QW, Jia G, et al. Association between sarcopenic obesity and dementia in the Chinese elderly using different definitions of obesity: evidence from the CHARLS[J]. Front Aging Neurosci,2025,17:1540272.

[21] Yao GX, Ma XH, Wan XY, et al. Association between sarcopenic obesity and risk of frailty in older adults: a systematic review and meta-analysis[J]. Age Ageing,2025,54(1):afae286.

[22] Wei SB, Nguyen TT, Zhang Y, et al. Sarcopenic obesity: epidemiology, pathophysiology, cardiovascular disease, mortality, and management[J]. Front Endocrinol,2023,14:1185221.

[23] Feng ZY, Xia JY, Yu JH, et al. Pathophysiological mechanisms underlying sarcopenia and sarcopenic obesity: a systematic review and meta-analysis of biomarker evidence[J]. Int J Mol Sci,2025,26(11):5113.

[24] Tang CB, Song Y, Tao FR, et al. Association of sarcopenic obesity with cognitive dysfunction and dementia: a systematic review and meta-analysis[J]. Aging Clin Exp Res,2025,37(1):318.

[25] Someya Y, Tamura Y, Kaga H, et al. Sarcopenic obesity is associated with cognitive impairment in community-dwelling older adults: The Bunkyo Health Study[J]. Clin Nutr,2022,41(5):1046-1051.

[26] Wang H, Hai S, Liu YX, et al. Associations between sarcopenic obesity and cognitive impairment in elderly Chinese community-dwelling individuals[J]. J Nutr Health Aging,2019,23(1):14-20.

[27] 袁维霞,敖盼盼,马 芸,等. 年龄校正的Charlson合并症指数对老年患者肌少症的预测价值研究[J]. 中国全科医学,2026,29(13):1673-1681.

Yuan WX, Ao PP, Ma Y, et al. Predictive Value of Age-adjusted Charlson Comorbidity Index for Sarcopenia in Elderly Patients[J]. Chinese General Practice,2026,29(13):1673-1681.

[28] Deguchi N, Tanaka R, Akita T. Association between sarcopenic obesity and frailty risk in community-dwelling older women with locomotive syndrome: a cross-sectional survey[J]. Cureus,2024,16(7):612-620.

[29] 陈小燕,李 梅,黄 莎,等. 肌少性肥胖与养老机构老年人死亡风险：基于六种肥胖指标的前瞻性队列研究[J]. 中华老年医学杂志,2025,44(7):943-950.

Chen XY, Li M, Huang S, et al. Sarcopenic obesity and mortality risk in nursing home residents: a prospective cohort study based on six obesity indicators[J]. Chin J Geriatr,2025,44(7):943-950.

（收稿：2026-01-21；修回：2026-04-07；录用：2026-04-08）

（责任编辑：周一青）

本文引用格式：

范清清,彭 朋,李亚玲,等. 基于机器学习构建老年肌少性肥胖风险预测模型[J]. 重庆医科大学学报,2026,51(6):867-875.