

基于多种机器学习模型对阿尔茨海默病与中重度脑小血管病的鉴别价值

郑欣¹, 唐秋¹, 杨茂¹, 卢廷勇¹, 柴云龙¹, 文明²

(1.重庆市潼南区中医院放射科, 重庆 402660; 2.重庆医科大学附属第一医院放射科, 重庆 400016)

【摘要】目的:分析不同机器学习模型对阿尔茨海默病(Alzheimer’s disease, AD)与中重度脑小血管病(cerebral small vessel disease, CSVD)的鉴别价值并进行验证。**方法:**分别收集 85 例 AD 和 98 例中重度 CSVD 患者的影像资料, 并对 2 组间影像特征进行对比。利用 logistic 分析筛查有价值的特征并建立不同的机器学习模型, 对比不同机器学习模型对鉴别 AD 与中重度 CSVD 的临床应用价值。**结果:**朴素贝叶斯模型的受试者工作特征曲线下面积(area under the curve, AUC)为 0.853, 95%CI=0.798~0.908; 极限梯度提升模型的 AUC 为 0.995, 95%CI=0.989~1.000; 递归分区模型的 AUC 为 0.878, 95%CI=0.827~0.929; 神经网络模型的 AUC 为 0.876, 95%CI=0.828~0.925; 随机森林模型的 AUC 为 0.944, 95%CI=0.913~0.975; 列线图模型的 AUC 为 0.854, 95%CI=0.800~0.910。利用沙普利加和解释(shapley additive explanations, SHAP)值对极限梯度提升模型进行解释, 各预测因子对诊断 AD 均为负向贡献; 其权重分别为海马体积>颞叶 ADC 值>岛叶体积>缘上回体积>顶上小叶体积。**结论:**机器学习模型可应用于 AD 与中重度 CSVD 的鉴别中, 其中极限梯度提升模型的综合诊断效能最佳; SHAP 值可对各预测因素进行识别, 提高模型透明度。

【关键词】脑小血管病; 阿尔茨海默病; 机器学习; 沙普利加和解释

【中图分类号】R74

【文献标志码】A

Value of various machine learning models in differentiating Alzheimer’s disease from moderate-to-severe cerebral small vessel disease

Zheng Xin¹, Tang Qiu¹, Yang Mao¹, Lu Tingyong¹, Chai Yunlong¹, Wen Ming²

(1.Department of Radiology, Chongqing Tongnan Hospital of Traditional Chinese Medicine;

2.Department of Radiology, The First Affiliated Hospital of Chongqing Medical University)

【Abstract】Objective: To investigate the value of various machine learning models in differentiating Alzheimer’s disease (AD) from moderate-to-severe cerebral small vessel disease (CSVD). **Methods:** Imaging data were collected from 85 patients with AD and 98 patients with moderate-to-severe CSVD, and radiological features were compared between the two groups. A logistic analysis was used to identify valuable data and establish different machine learning models, and the value of different machine learning models in differentiating AD from moderate-to-severe CSVD was compared. **Results:** The Naive Bayes model had an area under the ROC curve (AUC) of 0.853 (95%CI=0.798–0.908); the XGboost model had an AUC of 0.995 (95%CI=0.989–1.000); the recursive partitioning model had an AUC of 0.878 (95%CI=0.827–0.929); the neural network model had an AUC of 0.876 (95%CI=0.828–0.925); the random forest model had an AUC of 0.944 (95%CI=0.913–0.975); the nomogram model had an AUC of 0.854 (95%CI=0.800–0.910). The SHapley Additive exPlanations (SHAP) value was used to explain the XGboost model, and all predictive factors contributed negatively to the diagnosis of AD, among which hippocampal volume had the highest weight, followed by ADC value of temporal lobe, insular volume, supramarginal gyrus volume, and superior parietal lobule volume. **Conclusion:** Machine learning models can be used to differentiate AD from moderate-to-severe CSVD, and the XGboost model has the best comprehensive diagnostic performance. SHAP values can be

作者介绍: 郑欣, Email: 231304512@qq.com,

研究方向: 磁共振诊断。

通信作者: 文明, Email: 13883669699@163.com。

基金项目: 重庆市潼南区科研资助项目 (编号: TK-2025-8)。

优先出版: <https://link.cnki.net/urlid/50.1046.R.20251225.1636.008>

(2025-12-29)

used to identify various predictive factors, thereby enhancing the transparency of the model.

【Key words】 cerebral small vessel disease; Alzheimer’s disease; machine learning; SHapley Additive exPlanations

依据我国第7次人口普查的数据,我国60岁以上占总人口的比例已高达18.7%;而认知障碍(cognitive impairment, CI)作为老年人口常见的疾病,其主要表现为包含记忆、情感和智力等一系列神经功能受损,并有年轻化的趋势^[1]。而脑小血管病(cerebral small vessel disease, CSVD)与阿尔茨海默病(Alzheimer's disease, AD)均是引起老年人CI常见的病因,且临床工作中经常出现CSVD与AD共存的现象^[2]。AD是一种不可治愈的神经退行性病变,AD的治疗主要以缓解病情为主,药物治疗无法将病程根治或逆转。因此AD主要依靠早期诊断并及时临床介入,故在临床工作需要AD与CSVD进行鉴别。本研究拟基于临床工作中常用的临床-影像学指标来分析AD和中重度CSVD的差异,并建立不同的机器学习模型对2种疾病进行鉴别,以期提高影像学精准定性诊断并为临床诊疗提供参考。

1 资料与方法

1.1 研究对象

本研究回顾性收集2021年6月至2025年3月,在重庆医科大学附属第一医院接受磁共振成像(magnetic resonance imaging, MRI)检查的183例患者临床-影像学资料。85例确诊为AD,其中男41例,女44例,男女比例为1:1.07,年龄61~94岁,平均(76.40±7.09)岁;98例确诊为CSVD,其中男45例,女53例,男女比例为1:1.18,年龄60~88岁,平均(74.31±7.05)岁。

1.2 纳入及排除标准

纳入标准:①AD患者均为首次确诊且此前未接受针对性的系统性治疗;②CSVD患者的MRI负荷评分≥2分;③患者的MRI图像均由同一台设备采用相同参数扫描所得。排除标准:①近期有急性脑卒中病史(病史<14d);②有大范围的脑软化灶、颅内感染、颅脑肿瘤、乙醇性脑病、药物滥用等其他中枢神经系统疾病的患者。

1.3 临床诊断标准

1.3.1 AD与CSVD的诊断依据 所有AD患者均依据美国国立老化研究所和阿尔茨海默病协会(National Institute on Aging-Alzheimer's Association, NIA-AA)制定的AD诊断标准及相关实验室指标^[3]做出诊断;CSVD的诊断则依据《中国脑小血管病诊治指南2020》^[4]的诊断标准进行。依据Huijts M等^[5]研究中采用的“脑小血管病总负荷”评分系统计算所有患者的MRI负荷评分。

1.3.2 MRI负荷评分的判断方法 对所有患者的MRI负荷评分分别由8年和10年影像诊断经验的影像科医生进行判

断,当结果不一致由1名20年诊断经验的高年资影像诊断医师作出最终诊断。MRI负荷评分共被赋予4分,具体的评价指标包括:近期新发皮质下梗死、脑微小出血灶、白质高信号(white matter hyperintensities, WMH)和脑血管周围间隙扩大。评价方法如下:①腔隙性脑梗死≥1个,CSVD评分记1分;②基底节区域发现扩大的血管周围间隙≥10个,CSVD评分记1分;③深部脑微出血≥1个为1分;④依据Fazekas量表^[6]对脑室旁白质和深部白质改变进行评价,存在脑室旁者Flair高信号并延伸到白质和/或深部白质Flair高信号融合的情况时,CSVD评分记1分。将上述得分的和记为CSVD负荷总得分,当评分≥2分即纳入本研究的中重度CSVD组。

1.4 影像学检查方法

患者平卧接受检查,检查设备为联影公司(中国-上海)的1.5T MRI扫描仪,设备型号为uMR 580,采用16通道头部线圈。MRI检查选择横断位扫描,序列选择为:T1WI、T2WI、T2FLAIR、DWI及SWI。其中T1WI序列扫描参数:TR 6167 ms, TE 14.92 ms, NEX 1,层厚1.5 mm,间距2 mm, FOV 230 mm × 230 mm; T2WI为:TR 8000 ms, TE 95.26 ms, NEX 2,层厚5 mm,间距2 mm, FOV 230 mm × 230 mm; DWI序列为:TR 3740 ms, TE 87 ms, NEX 1,层厚5 mm,间距1 mm, FOV 230 mm × 230 mm,表观扩散系数(apparent diffusion coefficient, ADC)图选择的b值为0 s/mm²和1 000 s/mm²。

1.5 观察指标

1.5.1 本研究的ADC值测量方法 患者检查结束后,将扫描图像传送至联影影像后处理工作站后,本课题组参考Aktas F等^[7]研究自行制定的ADC值测量方法:分别在患者的ADC图上设置额叶、顶叶、颞叶、枕叶、丘脑、脑干及小脑半球感兴趣区(region of interest, ROI)并测量ADC值(图1A~G)。为确保ROI范围的一致性,本研究的MRI技师均接受了培训,统一规范了扫描时头骨定位的设计及扫描定位线的放置;为避免运动伪影影响,以基底节区结构清晰显示作为图像的入组标准^[8]。研究团队严格标准化了ROI的具体位置和尺寸,诊断医师在测量同一部位的ROI时,其大小和形态的选择尽量保持一致;将双侧测量数据的平均值记为最终结果。

1.5.2 人工智能脑分割的测量方法 利用联影智能的MR脑结构智能分析系统(uAI Discover Brain)以T1WI序列为基础,测量双侧大脑半球中系统默认解剖部位的体积(见图1H),取其测量数据的平均值作为最终结果;2位医师共同对分割软件的结果进行复核,当发现明显偏差时手动修正测量范围,并由系统重新计算测量结果。

1.6 统计学方法

数据的预处理采用SPSS 26.0软件。符合正态分布的计量资料以均数±标准差($\bar{x} \pm s$)标示,采用独立样本t检验;计数资料以百分率(%)标示,采用卡方检验。以多因素Logistic回归筛选有价值的变量,随后将筛出的变量基于R语言(版本为4.5.0)进行模型的构建;使用naivebayes包建立朴素贝叶斯模型;使用xgboost包建立极限梯度提升模型;使用rpart

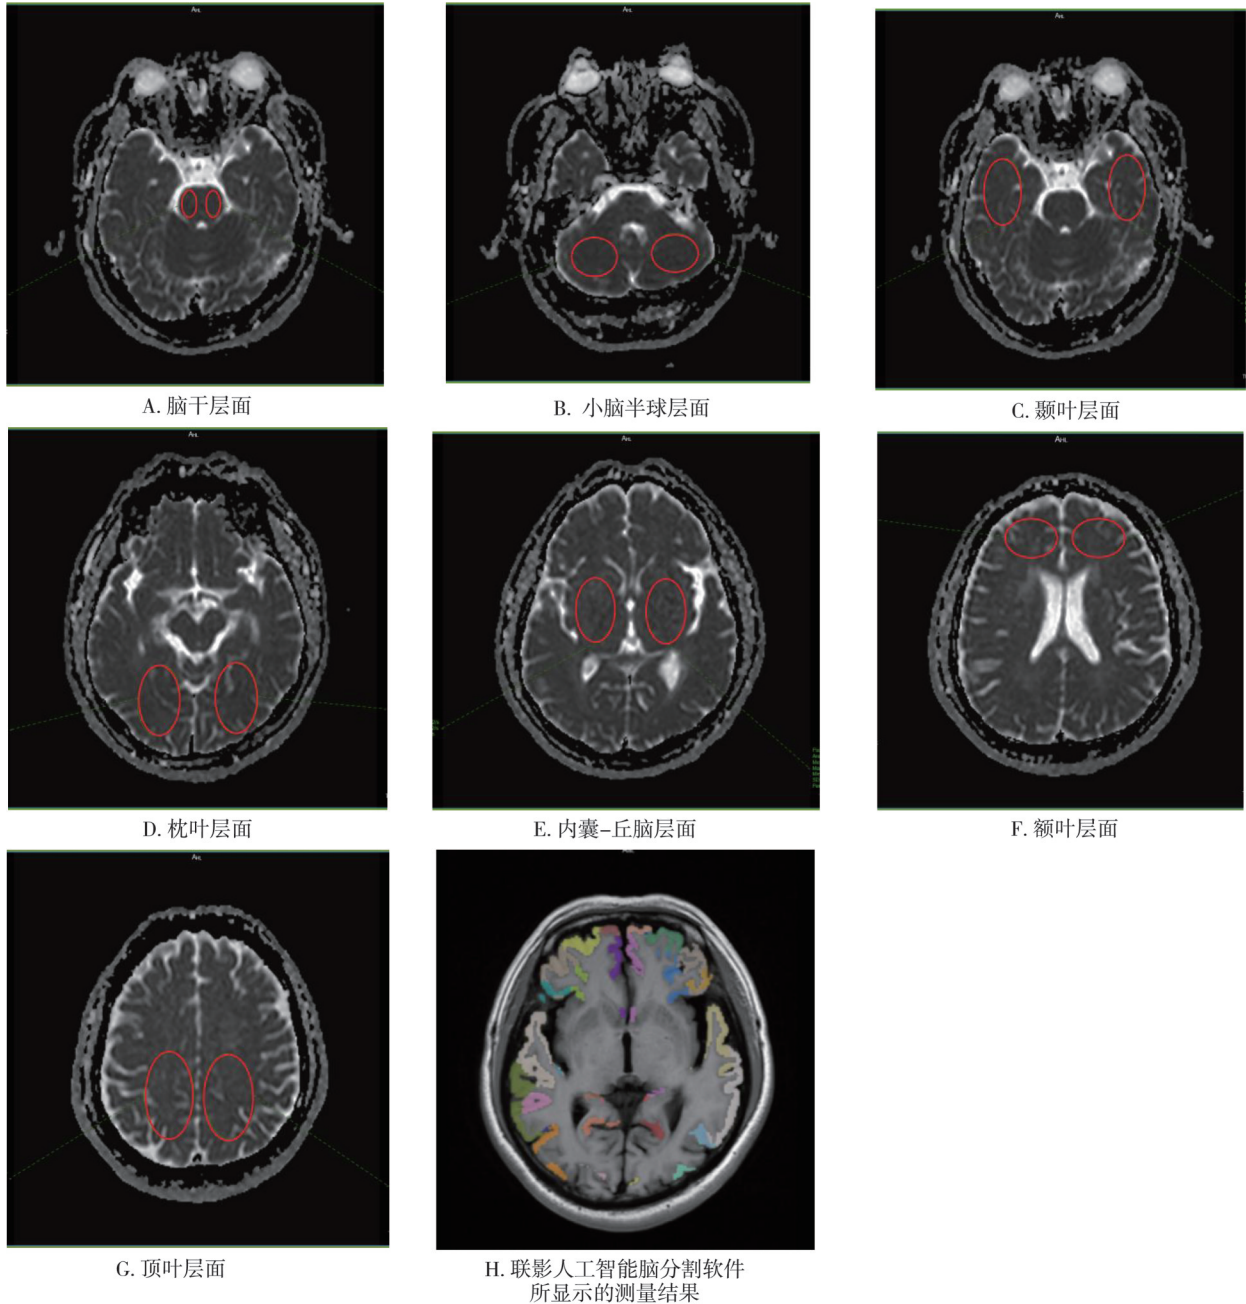


图1 本研究所采用的ADC值及大脑体积的测量方法

包建立递归分区模型;使用 nnet 包建立神经网络模型;使用 randomForest 包建立随机森林模型,使用 rms 包建立列线图模型;所有模型均进行了 5 折交叉验证。利用受试者工作特征曲线对各种模型的诊断收益进行对比;并使用 SHAP 值对模型中各变量进行解释并计算贡献度。检验水准 $\alpha=0.05$ 。

2 结果

2.1 2 组病例间一般临床资料的对比

对比 2 组间临床资料,发现(表 1)患者的性别、年龄、吸烟史、高血压病史及糖尿病史,差异无统计学意义(均 $P>$

0.05)。

2.2 2 组病例间影像学资料的对比

对比 2 组间的影像资料,发现患者额叶 ADC 值、顶叶 ADC 值、颞叶 ADC 值、丘脑 ADC 值、小脑 ADC 值、海马体积、中央前回体积、额极体积、顶上小叶体积、顶下小叶体积、楔前叶体积、缘上回体积、后扣带回体积、岛叶体积、丘脑体积差异有统计学意义(均 $P<0.05$);其余影像指标差异无统计学意义(均 $P>0.05$)(表 2)。检验水准 $\alpha=0.05$ 。

2.3 多因素 logistic 回归筛查预测因子

以临床诊断是否为 AD 作为结局变量(是=1,否=0),将上述阳性结果纳入多因素 logistic 回归分析,结果发现颞叶

ADC 值、海马体积、缘上回体积、岛叶体积及顶上小叶体积可作为 AD 的独立预测因子(表 3)。

2.4 机器学习对鉴别 AD 与中重度 CSVD 的应用价值

基于颞叶 ADC 值、海马体积、缘上回体积、岛叶体积及顶上小叶体积的数据建立机器学习模型;研究发现极限梯度提升模型在鉴别 AD 和中重度 CSVD 时,综合应用价值最高,AUC 为 0.833,F1 值为 0.965,精确率-召回率曲线平均精度

(average precision, AP)为 0.985(表 4、图 2)。

2.5 极限梯度提升模型的 SHAP 值解释

各预测因子中海马体积、缘上回体积、岛叶体积、顶上小叶体积和颞叶 ADC 值对诊断 AD 均为负向贡献(图 3);其权重分别为海马体积>颞叶 ADC 值>岛叶体积>缘上回体积>顶上小叶体积。绝对 SHAP 值分别为:0.331、0.256、0.234、0.214、0.068。

表 1 AD 和中重度 CSVD 病例间一般临床资料的对比($\bar{x} \pm s; n, \%$)

项目	AD 组(n=85)	CSVD 组(n=98)	χ^2/t 值	P 值
性别/男性	41(48.24)	45(45.92)	0.098	0.754
年龄(岁)	76.23 ± 7.15	74.31 ± 7.05	1.816	0.071
高血压	45(52.94)	47(47.96)	0.452	0.501
糖尿病	39(45.88)	38(38.78)	0.943	0.331

表 2 AD 和中重度 CSVD 病例间影像资料的对比($\bar{x} \pm s$)

项目	AD 组(n=50)	CSVD 组(n=98)	t 值	P 值
额叶 ADC 值($10^{-9} \text{mm}^2/\text{s}$)	0.955 ± 0.076	0.986 ± 0.086	2.196	0.029
顶叶 ADC 值($10^{-9} \text{mm}^2/\text{s}$)	0.959 ± 0.065	1.001 ± 0.093	3.563	<0.001
颞叶 ADC 值($10^{-9} \text{mm}^2/\text{s}$)	0.916 ± 0.053	0.957 ± 0.094	3.982	<0.001
枕叶 ADC 值($10^{-9} \text{mm}^2/\text{s}$)	0.892 ± 0.071	0.913 ± 0.084	1.669	0.097
丘脑 ADC 值($10^{-9} \text{mm}^2/\text{s}$)	0.851 ± 0.046	0.875 ± 0.081	2.265	0.009
脑干 ADC 值($10^{-9} \text{mm}^2/\text{s}$)	0.782 ± 0.057	0.777 ± 0.068	1.360	0.175
小脑 ADC 值($10^{-9} \text{mm}^2/\text{s}$)	0.746 ± 0.035	0.751 ± 0.056	2.289	0.023
海马体积(cm^3)	2.183 ± 0.682	2.850 ± 0.749	6.262	<0.001
中央前回体积(cm^3)	8.314 ± 0.750	8.744 ± 0.937	3.395	0.001
额极体积(cm^3)	1.230 ± 0.239	1.297 ± 0.306	1.617	0.108
顶上小叶体积(cm^3)	9.158 ± 0.589	9.338 ± 0.570	2.090	0.038
顶下小叶体积(cm^3)	9.755 ± 1.186	10.575 ± 1.257	4.417	<0.001
楔前叶体积(cm^3)	6.610 ± 0.878	7.240 ± 1.074	3.928	<0.001
缘上回体积(cm^3)	6.918 ± 1.186	7.802 ± 1.012	5.167	<0.001
前扣带回体积(cm^3)	1.764 ± 0.301	1.850 ± 0.405	1.609	0.109
后扣带回体积(cm^3)	2.024 ± 0.356	2.237 ± 0.404	3.491	0.001
岛叶体积(cm^3)	4.439 ± 0.649	5.075 ± 0.742	5.787	<0.001
壳核体积(cm^3)	3.864 ± 0.577	4.036 ± 0.720	1.762	0.080
丘脑体积(cm^3)	5.367 ± 0.730	5.738 ± 0.780	3.311	0.001

表 3 AD 和中重度 CSVD 组间多因素 logistic 回归分析

变量	回归系数	标准误差	Wald χ^2	OR	95%CI	P 值
颞叶 ADC 值($10^{-9} \text{mm}^2/\text{s}$)	-7.940	3.390	5.486	0.000	0.000~0.274	<0.001
海马体积(cm^3)	-0.787	0.294	7.162	0.455	0.256~0.810	0.007
缘上回体积(cm^3)	-0.579	0.228	6.435	0.560	0.358~0.877	0.011
岛叶体积(cm^3)	-1.162	0.345	11.344	0.313	0.159~0.615	0.001
顶上小叶体积(cm^3)	-0.872	0.378	5.326	0.418	0.199~0.877	0.021

表 4 机器学习模型对鉴别 AD 和中重度 CSVD 的价值

项目	朴素贝叶斯	极限梯度提升	递归分区	神经网络	随机森林	列线图
敏感度 (%)	75.51	97.96	80.61	78.57	89.80	82.65
特异度 (%)	84.71	94.12	83.53	78.82	85.88	77.65
阳性预测值 (%)	82.06	95.05	84.95	81.05	88.80	81.00
阴性预测值 (%)	75.00	97.56	78.89	76.14	87.95	79.52
总准确率	0.798	0.818	0.820	0.787	0.880	0.803
AUC	0.853	0.995	0.878	0.876	0.944	0.854
95%CI	0.798~0.908	0.989~1.000	0.827~0.929	0.828~0.925	0.913~0.975	0.800~0.910
F1 值	0.800	0.965	0.827	0.798	0.889	0.818
AP	0.831	0.985	0.859	0.863	0.932	0.822




图 2 机器学习模型预测 AD 的 ROC 曲线




图 3 极限梯度提升模型鉴别 AD 的 SHAP 散点图

3 讨论

3.1 本研究鉴别 AD 和中重度 CSVD 方案的特点
CSVD 是脑内的小血管病理改变导致临床和影

像的综合征;而 AD 则是一种神经性退行性病变,早期进行有效干预可延缓病程的进展。现阶段评价 AD 与 CSVD 多采用磁共振弥散张量成像(diffusion tensor imaging, DTI),如 Hong H 等^[2]发现 DTI 可用来评价 AD 与 CSVD 的发病机制。但 DTI 对于设备的要求较高,DTI 对白质纤维的微结构区分度有限、DTI 指标(如 FA 值)的解读对临床医师要求更高等,限制了该技术在基层医院的应用。弥散加权成像(diffusion-weighted imaging, DWI)技术已经广泛应用于临床诊断中,为评价 CSVD 及 AD 提供了广泛的潜在应用空间;如 Dewenter A 等^[9]发现 MRI 弥散成像可用来评价 CSVD 和 AD 白质损伤时的关键特征。

脑结构分析已应用在 AD 和 CSVD 的诊疗中,如 Schirge PM 等^[10]利用脑分割工具对 AD 与脑血管病患者 WMH 与认知障碍的关系;Tomassini S 等^[11]发现结构磁共振成像(structural magnetic resonance imaging, SMRI)可应用于包括 AD 在内的认知障碍性疾病。无论是基于图像自动分割算法的 MR 成像或 SMRI 对于设备的要求较高,广泛普及该技术的难度较大。脑分割系统则具有自动分割、处理速度快和结果准确的特点^[12],本研究基于 ADC 值与脑分割建立机器学习模型来预测 AD,具有硬件要求较低和临床操作简单的特点,相较于 SMRI 等花费巨大才能实现的检查技术,更易在基层医院临床工作中进行普及。

3.2 机器学习模型在 CSVD 与 AD 诊断及鉴别的应用价值

机器学习属于人工智能的分支,而人工智能联合预测模型来准确地预测疾病结果是现阶段发展的一个方向,如 Nallapu BT 等^[13]发现机器学习模型可以改进预测 AD 认知能力下降的试验设计;Ding HT 等^[14]关注于 AD 的动态终身风险预测建立和更新

评估,为患者提供终身准确的风险评估。但尚未有研究通过机器学习模型对 CSVD 与 AD 进行鉴别,为临床精准诊断提供参考;本研究分析了 6 种不同的机器学习模型对 2 种疾病鉴别临床应用价值,笔者查阅文献尚未发现相关报道。本研究发现极限梯度提升模型鉴别 AD 与中重度 CSVD 临床应用价值更高。

本研究基于 SHAP 值发现海马体积对于诊断 AD 价值更重要,可能是 AD 的主要病理特征为 β 淀粉样蛋白沉积,并引起神经元凋亡^[15],导致相应结构体积改变;AD 患者过磷酸化的 tau 蛋白升高,是神经原纤维缠结的结构基础。学习和记忆的结构基础是海马,当海马功能发生损害时会出现学习和记忆功能的丧失。Bouwman MMA 等^[16]发现海马萎缩程度越严重,认知功能损害越明显;AD 患者海马亚区的体积均小于对照组,tau 蛋白高于对照组。上述结论也与本研究海马体积对诊断 AD 价值更高的结果重合,也证明了海马体积对 AD 诊断的重要性。

本研究的不足之处:①入组病例数目较少,并且样本不平衡可能影响模型的性能,今后将继续加大样本量深入探讨;②本研究采用的是单中心样本,缺乏多中心样本的进一步验证,望后续通过多中心研究验证模型效能,并推动其临床转化应用。

总之 AD 与中重度 CSVD 患者的影像学指标间存在差异;利用极限梯度提升模型用来预测 AD 时其综合诊断效能最好;SHAP 值可对各预测因素进行识别,提高模型透明度。

利益冲突 所作者声明不存在利益冲突

作者贡献声明 郑欣:研究实施及文章撰写;唐秋、卢廷勇:图像分析;杨茂:病例收集及数据分析;柴云龙:患者的规范化扫描;文明:研究设计并审阅文章

参 考 文 献

- [1] Loi SM, Pijnenburg Y, Velakoulis D. Recent research advances in young-onset dementia[J]. *Curr Opin Psychiatry*, 2023, 36(2): 126-133.
- [2] Hong H, Hong LW, Luo X, et al. The relationship between amyloid pathology, cerebral small vessel disease, glymphatic dysfunction, and cognition: a study based on Alzheimer's disease continuum participants[J]. *Alzheimers Res Ther*, 2024, 16(1): 43.
- [3] Jack CR Jr, Andrews JS, Beach TG, et al. Revised criteria for diagnosis and staging of Alzheimer's disease: Alzheimer's Association Workgroup[J]. *Alzheimers Dement*, 2024, 20(8): 5143-5169.
- [4] 中华医学会神经病学分会, 中华医学会神经病学分会脑血管病学组. 中国脑小血管病诊治指南 2020[J]. *中华神经科杂志*, 2022, 55(8): 807-818.
- [5] Chinese Society of Neurology, Chinese Stroke Society (CSS). Chinese guideline for diagnosis and treatment of cerebral small vessel disease 2020[J]. *Chin J Neurol*, 2022, 55(8): 807-818.
- [6] Huijts M, Duits A, van Oostenbrugge RJ, et al. Accumulation of MRI markers of cerebral small vessel disease is associated with decreased cognitive function. a study in first-ever lacunar stroke and hypertensive patients[J]. *Front Aging Neurosci*, 2013, 5: 72.
- [7] Liu XY, Li T, Diao SS, et al. The global burden of cerebral small vessel disease related to neurological deficit severity and clinical outcomes of acute ischemic stroke after IV rt-PA treatment[J]. *Neurol Sci*, 2019, 40(6): 1157-1166.
- [8] Aktas F, Özmen Z. Diffusion MRI in intracranial hypertension: quantitative assessment[J]. *Curr Med Imaging*, 2024, 20: e110822207405.
- [9] 郑建刚, 梅莉, 许建兴, 等. 刀锋伪影校正技术在头部运动伪影纠正的应用[J]. *中国医学计算机成像杂志*, 2010, 16(6): 539-543.
- [10] Zheng JG, Mei L, Xu JX, et al. Clinical application of MR BLADE techniques in correcting head motion artifacts[J]. *Chin Comput Med Imag*, 2010, 16(6): 539-543.
- [11] Dewenter A, Jacob MA, Cai MF, et al. Disentangling the effects of Alzheimer's and small vessel disease on white matter fibre tracts[J]. *Brain*, 2023, 146(2): 678-689.
- [12] Schirge PM, Perneczky R, Taoka T, et al. Perivascular space and white matter hyperintensities in Alzheimer's disease: associations with disease progression and cognitive function[J]. *Alzheimers Res Ther*, 2025, 17(1): 62.
- [13] Tomassini S, Sbröllini A, Covella G, et al. Brain-on-Cloud for automatic diagnosis of Alzheimer's disease from 3D structural magnetic resonance whole-brain scans[J]. *Comput Methods Programs Biomed*, 2022, 227: 107191.
- [14] Wu JJ, Xia YW, Wang XC, et al. uRP: An integrated research platform for one-stop analysis of medical images[J]. *Front Radiol*, 2023, 3: 1153784.
- [15] Nallapu BT, Petersen KK, Qian TC, et al. A machine learning approach to predict cognitive decline in Alzheimer disease clinical trials[J]. *Neurology*, 2025, 104(8): e213490.
- [16] Ding HT, Ye ZH, Paschalidis A, et al. Dynamic lifetime risk prediction of Alzheimer's disease with longitudinal cognitive assessment measurements[J]. *Alzheimers Dement*, 2025, 21(3): e70055.
- [17] McDade EM. Alzheimer disease[J]. *Continuum*, 2022, 28(3): 648-675.
- [18] Bouwman MMA, Frigerio I, Lin CP, et al. Hippocampal subfields: volume, neuropathological vulnerability and cognitive decline in Alzheimer's and Parkinson's disease[J]. *Alzheimers Res Ther*, 2025, 17(1): 121.

(收稿: 2025-09-17; 修回: 2025-11-20; 录用: 2025-12-01)

(责任编辑: 李青颖)

本文引用格式:

郑欣, 唐秋, 杨茂, 等. 基于多种机器学习模型对阿尔茨海默病与中重度脑小血管病的鉴别价值[J]. *重庆医科大学学报*, 2026, 51(2): 216-221.