

# 机器学习算法构建不同模型预测突发性感音神经性聋伴高血压患者的预后

杨瑾,米彦芳

(郑州大学第二附属医院 耳鼻咽喉科,河南 郑州 450003)

**摘要:** **目的** 分析突发性感音神经性聋(SSNHL)伴高血压患者发生不良预后的影响因素,基于4种机器学习算法构建预测模型,比较不同模型的预测效果。**方法** 选取2023年2月1日—2024年5月31日就诊于郑州大学第二附属医院耳鼻咽喉科SSNHL合并高血压的患者作为研究对象。通过医院电子病历系统收集患者临床资料,根据治疗后听力恢复情况分为有效组和无效组,采用单因素分析、最小绝对收缩和选择算子(LASSO回归)和Boruta算法筛选预测变量。采用逻辑回归(LR)、随机森林(RF)、极端梯度提升树(XGBoost)和支持向量机(SVM)4种机器学习算法构建预测模型并进行验证,DeLong检验各模型在验证集中的曲线下面积(AUC),同时比较各模型在验证集中的评价指标以确定最佳模型,并使用Shapley加性解释(SHAP)算法对模型进行解释性分析。**结果** 232例患者纳入研究,共筛选出7个与无效预后密切相关的变量,包括听力损失程度、听力图类型、糖尿病、高血压病程等。对4种模型的预测性能进行验证,XGBoost模型整体预测性能最好,AUC(0.787)、准确度(78.56%)、精确度(78.95%)、召回率(71.43%)和F1分数(75%),且4种模型之间AUC的差异无统计学意义( $P>0.05$ )。**结论** 合并高血压的SSNHL患者不良预后的发生风险受患者初始听力水平、听力图类型、糖尿病、高血压病程、吸烟及高尿酸血症等因素影响。4种机器学习模型均具有良好的预测性能,其中XGBoost模型预测性能最优。

**关键词:** 突发性感音神经性聋;高血压;机器学习;预后模型

中图分类号:R764.43<sup>+1</sup>

## Machine learning algorithms to construct different models to predict prognosis in patients with sudden sensorineural hearing loss with hypertension

YANG Jin, MI Yanfang

(Department of Otorhinolaryngology, the Second Affiliated Hospital of Zhengzhou University, Zhengzhou 450003, China)

**Abstract:** **Objective** To analyze the influencing factors for the poor prognosis in patients with sudden sensorineural hearing loss (SSNHL) accompanied with hypertension, construct prediction models based on four machine learning algorithms, and compare the prediction effects of different models. **Methods** Patients with SSNHL combined with hypertension admitted to the Department of Otorhinolaryngology of the Second Affiliated Hospital of Zhengzhou University from February 1, 2023 to May 31, 2024 were selected as the research subjects. The clinical data of patients were collected through the hospital's electronic medical record system. According to the hearing recovery after treatment, the patients were divided into the effective group and the ineffective group. Univariate analysis, the least absolute shrinkage and selection operator (LASSO regression), and the Boruta algorithm were used to screen the predictive variables. Four machine learning algorithms, namely logistic regression (LR), random forest (RF), extreme gradient boosting (XGBoost), and support vector machine (SVM), were adopted to construct prediction models and conduct verification. The predictive performances of the four models were compared. The DeLong test was employed to compare the area under the curve (AUC) of the models in the validation set, and the evaluation indicators of each model in the validation set were compared

第一作者简介:杨瑾,女,在读硕士研究生。  
通信作者:米彦芳, Email: myf00079@126.com

to determine the optimal model. Moreover, the Shapley additive explanation (SHAP) algorithm was utilized to conduct explanatory analyses on the models. **Results** A total of 232 patients were included in this study, and 7 variables closely related to poor prognosis were screened out, including the degree of hearing loss, audiogram type, diabetes mellitus, and the course of hypertension. The predictive performance of the four models was verified. Among them, the XGBoost model demonstrated the best overall predictive performance, with an AUC of 0.787, an accuracy of 78.56%, a precision of 78.95%, a recall of 71.43%, and an F1 score of 75%. Moreover, there were no statistically significant differences in the AUC among the receiver operator characteristic curves of the four models ( $P > 0.05$ ). **Conclusions** The risk of poor prognosis in SSNHL patients with hypertension is affected by multiple factors, including initial hearing level, type of audiogram, diabetes mellitus, duration of hypertension, smoking and hyperuricemia. All the four machine learning models have good predictive performance, with the XGboost model being the optimal.

**Keywords:** Sudden sensorineural hearing loss; Hypertension; Machine learning; Prognostic model

突发性感音神经性聋 (sudden sensorineural hearing loss, SSNHL) 是一种耳鼻咽喉科的常见疾病,其定义为在 72 h 内突发的、原因不明的感音神经性听力损失,至少在相邻的两个频率听力下降  $\geq 20$  dB HL<sup>[1]</sup>。据统计,SSNHL 的年患病率为每 100 000 人中出现 5 ~ 20 例<sup>[2]</sup>。高血压是 SSNHL 患者最常见的共患病之一,高血压患者循环血流量增多,血液流速减慢,血液黏稠度增加,可造成内耳微循环障碍<sup>[3]</sup>。已有研究表明,患有全身性动脉高压的 SSNHL 患者预后较差<sup>[4]</sup>。因此,探究合并高血压的 SSNHL 患者预后不良的相关因素对于临床医生了解其发病机制、制定预防和治疗措施具有重要意义。

机器学习作为一种新兴的统计分析方法,通过剖析多元因素与遴选关键变量构建优化模型以预测预后,近年来已被广泛应用于听力学领域<sup>[5]</sup>。利用机器学习算法,临床医生可实现数据的发掘及分类,能够更准确地诊断疾病及预测疗效<sup>[6]</sup>。本研究基于 2 种特征筛选方法识别潜在影响因子,采用逻辑回归 (logistic regression, LR)、随机森林 (random forest, RF)、极端梯度提升树 (extreme gradient boosting, XGBoost) 以及支持向量机 (support vector machine, SVM) 4 种机器学习算法构建合并高血压的 SSNHL 患者预后不良的预测模型,并比较不同模型的预测效果,以期对合并高血压的 SSNHL 患者的个体化治疗提供客观、量化的参考依据。

1 资料与方法

1.1 研究对象

选取 2023 年 2 月 1 日—2024 年 5 月 31 日就诊于郑州大学第二附属医院耳鼻咽喉科合并高血压的 SSNHL 患者 232 例为研究对象,纳入标准:①SSNHL 患者符合《突发性聋诊断和治疗指南 (2015)》诊断标准<sup>[1]</sup>;②高血压者符合《国家基层高血压防治管

理指南 2020 版诊断标准》<sup>[7]</sup>;临床资料数据完整。排除标准:①外耳、中耳病变或中耳手术史;②内耳畸形或蜗后占位病变;③临床资料不完善者。本研究经郑州大学第二附属医院医学伦理委员会审批通过 (伦理审批号:KY2024157)。

1.2 资料收集

收集患者的年龄、性别、患耳侧别、发病至就诊时间、高血压病程、症状体征、伴随疾病及治疗前后听力阈值等基本资料。收集患者的实验室检查指标:血常规、血生化、肝功能、肾功能等,计算中性粒细胞计数/淋巴细胞计数比值 (neutrophil to lymphocyte ratio, NLR)、血小板计数/淋巴细胞计数比值 (platelet to lymphocyte ratio, PLR)、纤维蛋白原/白蛋白比值 (fibrinogen to albumin ratio, FAR)、甘油三酯-葡萄糖指数等。

1.3 相关变量定义

听力图类型参考《突发性聋诊断和治疗指南 (2015)》。依据患者初次就诊时患耳受损频率的平均听阈值,听力损失程度分级基于以下标准进行<sup>[1]</sup>:轻度听力损失 (20 ~ 35 dB HL)、中度听力损失 (36 ~ 50 dB HL)、中重度听力损失 (51 ~ 65 dB HL)、重度听力损失 (66 ~ 80 dB HL)、极重度听力损失 (81 ~ 95 dB HL)、全聋 (>95 dB HL)。

1.4 治疗方案及疗效评估

根据《突发性聋诊断和治疗指南 (2015)》,本研究采用综合治疗方案,包括改善微循环药物 (如丹红注射液、银杏叶提取物)、激素治疗 (地塞米松、甲泼尼龙)、降纤治疗 (巴曲酶) 和神经营养药物 (鼠神经生长因子),1 个疗程为期 14 d。血压控制良好者延续原降压方案,控制不佳者监测血压并邀相关科室协助治疗;合并其他疾病患者亦由相关科室协助诊疗。1 个疗程结束时对所有患者行纯音测听评估疗效,如受影响频率听力阈值提升  $\geq 15$  dB HL 或接

近正常视为预后良好,否则为预后不良。

1.5 统计学方法

应用 SPSS 27.0 软件处理数据,正态分布资料以  $\bar{x} \pm s$  表示,组间比较采用  $t$  检验;非正态分布资料以  $M(P_{25}, P_{75})$  表示,组间比较采用秩检验;计数资料采用频数和频率描述,组间比较使用  $\chi^2$  检验。基于 R4.4.1 软件将 232 例患者按照 8:2 比例<sup>[8]</sup>随机拆分为训练集和验证集,设置随机种子数为 123,纳入特征筛选后的变量,采用 LR、RF、SVM 及 XGBoost 4 种模型进行建模,利用曲线下面积(area under curve, AUC)、准确度、F1 分数等评价模型预测能力,采用 Delong 检验比较 4 种模型的 AUC。检验水准  $\alpha=0.05$ 。

1.5.1 特征指标筛选 通过单因素分析、最小绝对收缩和选择算子(least absolute shrinkage and selection operator, LASSO)以及 Boruta 特征选择算法(Boruta feature selection algorithm)3 种方法筛选特征变量,基于 R4.4.1 软件,使用 R 包“glmnet”(版本号 4.1.8)和“Boruta”(版本号 8.0.0)分别进行 LASSO 及 Boruta 特征选择,分析识别潜在预测因子。

1.5.2 机器学习模型构建 以疗效为因变量,筛选后的交叉变量为自变量纳入 4 种模型。基于 R 4.4.1 软件,通过“stats 包”(版本号 4.4.1)构建 LR 模型、通过“randomForest 包”(版本号 4.7.1.1)构建 RF 模型、通过“e1071 包”(版本号 1.7.14)构建 SVM 模型、通过“XGBoost 包”(版本号 1.7.7.1)构建 XGBoost 模型。

1.5.3 模型的解释 由 Shapley 加性解释(Shapley additive explanation, SHAP)执行,基于机器学习的模

型结果无法给出确定的数学解析式,即便模型预测性能较好但结果不易解释,SHAP 可精确计算每个变量对预测结局的贡献和影响,并通过 SHAP 值体现变量的贡献程度及性质<sup>[9]</sup>。

2 结果

2.1 一般情况

共纳入 232 例伴有高血压的 SSNHL 患者,男 125 例(53.88%),女 107 例(46.12%),预后良好组 132 例(56.90%),预后不良组 100 例(43.10%)。对训练集与验证集的资料进行比较,两数据集各指标间差异均无统计学意义( $P$  均  $>0.05$ )。见表 1。

对训练集中有效组( $n=106$ )和无效组( $n=80$ )两组资料行单因素分析,见表 2。结果显示,去除训练集和验证集中分布不平衡数据,最终得到白细胞计数、总胆固醇、低密度脂蛋白、FAR、听力图类型、初始听力损失程度、眩晕、糖尿病、高脂血症、高尿酸血症、饮酒、吸烟、年龄、高血压病程、发病至就诊时间共 15 个有统计学意义的变量。

2.2 变量筛选结果

最小绝对收缩和选择算子:筛选出 11 个变量,分别为白细胞、总胆固醇、FAR、听力图类型、听力损失程度、眩晕、糖尿病、吸烟、高血压病程、高尿酸血症、饮酒。Boruta 特征选择算法:筛选出 9 个变量,分别是高脂血症、吸烟、高血压病程、糖尿病、吸烟、听力图类型、听力损失程度、眩晕、发病至就诊时间。二者取交集,最终将吸烟、高血压病程、糖尿病、高尿酸血症、眩晕、听力损失程度和听力图类型 7 个变量纳入模型。见图 1、2。

表 1 训练集与验证集患者资料比较 [例(%)]

| 变量                                    | 训练集 ( $n=186$ )   | 验证集 ( $n=46$ )    | $t/Z/\chi^2$  | $P$   |
|---------------------------------------|-------------------|-------------------|---------------|-------|
| 白细胞计数( $\times 10^9/L$ ) <sup>*</sup> | 6.58 $\pm$ 1.53   | 6.20 $\pm$ 1.71   | $t=1.47$      | 0.144 |
| 低密度脂蛋白(g/L) <sup>*</sup>              | 2.59 $\pm$ 0.93   | 2.42 $\pm$ 0.93   | $t=1.10$      | 0.272 |
| 总胆固醇(mmol/L) <sup>#</sup>             | 4.39 (3.72, 5.24) | 4.23 (3.83, 4.89) | $Z=-0.53$     | 0.596 |
| FAR <sup>#</sup>                      | 0.07 (0.06, 0.08) | 0.07 (0.06, 0.08) | $Z=-0.95$     | 0.340 |
| 听力图类型                                 |                   |                   | $\chi^2=2.64$ | 0.451 |
| 低频下降型                                 | 59 (31.72)        | 20 (43.48)        |               |       |
| 高频下降型                                 | 67 (36.02)        | 12 (26.09)        |               |       |
| 平坦型                                   | 37 (19.89)        | 9 (19.56)         |               |       |
| 全聋型                                   | 23 (12.37)        | 5 (10.87)         |               |       |
| 眩晕                                    | 39 (20.97)        | 12 (26.09)        | $\chi^2=0.56$ | 0.453 |
| 糖尿病                                   | 80 (43.01)        | 15 (32.61)        | $\chi^2=1.65$ | 0.199 |
| 高脂血症                                  | 31 (16.67)        | 7 (15.22)         | $\chi^2=0.06$ | 0.812 |
| 高尿酸血症                                 | 31 (16.67)        | 5 (10.87)         | $\chi^2=0.95$ | 0.331 |
| 吸烟                                    | 57 (30.65)        | 10 (21.74)        | $\chi^2=1.42$ | 0.233 |

续表 1

| 变量          | 训练集 ( $n=186$ ) | 验证集 ( $n=46$ ) | $t/Z/\chi^2$  | $P$   |
|-------------|-----------------|----------------|---------------|-------|
| 饮酒          | 72 (38.71)      | 14 (30.43)     | $\chi^2=1.08$ | 0.298 |
| 年龄 (岁)      |                 |                | $\chi^2=1.05$ | 0.592 |
| 18~44       | 48 (25.81)      | 11 (23.91)     |               |       |
| 45~60       | 74 (39.78)      | 22 (47.83)     |               |       |
| >60         | 64 (34.41)      | 13 (28.26)     |               |       |
| 高血压病程 (年)   |                 |                | $\chi^2=2.04$ | 0.153 |
| ≤5          | 108 (58.06)     | 32 (69.57)     |               |       |
| >5          | 78 (41.94)      | 14 (30.43)     |               |       |
| 发病至就诊时间 (d) |                 |                | $\chi^2=2.04$ | 0.154 |
| ≤7          | 154 (82.80)     | 42 (91.30)     |               |       |
| >7          | 32 (17.20)      | 4 (8.70)       |               |       |
| 听力损失程度      |                 |                | $\chi^2=5.92$ | 0.314 |
| 轻度          | 16 (8.60)       | 5 (10.87)      |               |       |
| 中度          | 34 (18.28)      | 9 (19.57)      |               |       |
| 中重度         | 34 (18.28)      | 14 (30.43)     |               |       |
| 重度          | 43 (23.12)      | 6 (13.04)      |               |       |
| 极重度         | 30 (16.13)      | 8 (17.39)      |               |       |
| 全聋          | 29 (15.59)      | 4 (8.70)       |               |       |

注: \* 为  $\bar{x}\pm s$ ; # 为  $M(P_{25},P_{75})$ ; FAR (纤维蛋白原/白蛋白比值)。下同。

表 2 训练集有效组与无效组患者资料比较 [例(%)]

| 变量                          | 有效组 ( $n=106$ )  | 无效组 ( $n=80$ )   | $t/Z/\chi^2$   | $P$    |
|-----------------------------|------------------|------------------|----------------|--------|
| 白细胞计数 ( $\times 10^9/L$ ) * | 6.35 ± 1.57      | 6.88 ± 1.42      | $t=-2.37$      | 0.019  |
| 低密度脂蛋白 (g/L) *              | 2.46 ± 0.86      | 2.76 ± 1.00      | $t=-2.19$      | 0.030  |
| 总胆固醇 (mmol/L) #             | 4.33 (3.70,5.08) | 4.71 (3.81,5.48) | $Z=-1.98$      | 0.048  |
| FAR#                        | 0.06 (0.05,0.07) | 0.07 (0.06,0.08) | $Z=-2.32$      | 0.020  |
| 听力图类型                       |                  |                  | $\chi^2=40.65$ | <0.001 |
| 低频下降型                       | 49 (46.23)       | 10 (12.50)       |                |        |
| 高频下降型                       | 41 (38.68)       | 26 (32.50)       |                |        |
| 平坦型                         | 12 (11.32)       | 25 (31.25)       |                |        |
| 全聋型                         | 4 (3.77)         | 19 (23.75)       |                |        |
| 眩晕                          | 9 (8.49)         | 30 (37.50)       | $\chi^2=23.15$ | <0.001 |
| 糖尿病                         | 27 (25.47)       | 53 (66.25)       | $\chi^2=30.93$ | <0.001 |
| 高脂血症                        | 11 (10.38)       | 20 (25.00)       | $\chi^2=7.02$  | 0.008  |
| 高尿酸血症                       | 9 (8.49)         | 22 (27.50)       | $\chi^2=11.86$ | <0.001 |
| 吸烟                          | 24 (22.64)       | 33 (41.25)       | $\chi^2=7.43$  | 0.006  |
| 饮酒                          | 34 (32.08)       | 38 (47.50)       | $\chi^2=4.57$  | 0.033  |
| 年龄 (岁)                      |                  |                  | $\chi^2=9.58$  | 0.008  |
| 18~44                       | 35 (33.02)       | 13 (16.25)       |                |        |
| 45~60                       | 43 (40.57)       | 31 (38.75)       |                |        |
| >60                         | 28 (26.42)       | 36 (45.00)       |                |        |
| 高血压病程 (年)                   |                  |                  | $\chi^2=18.81$ | <0.001 |
| ≤5 年                        | 76 (71.70)       | 32 (40.00)       |                |        |
| >5 年                        | 30 (28.30)       | 48 (60.00)       |                |        |
| 发病至就诊时间 (d)                 |                  |                  | $\chi^2=13.14$ | <0.001 |
| ≤7                          | 97 (91.51)       | 57 (71.25)       |                |        |
| >7                          | 9 (8.49)         | 23 (28.75)       |                |        |
| 听力损失程度                      |                  |                  | $\chi^2=46.24$ | <0.001 |
| 轻度                          | 12 (11.32)       | 4 (5.00)         |                |        |
| 中度                          | 31 (29.25)       | 3 (3.75)         |                |        |
| 中重度                         | 26 (24.53)       | 8 (10.00)        |                |        |
| 重度                          | 21 (19.81)       | 22 (27.50)       |                |        |
| 极重度                         | 8 (7.55)         | 22 (27.50)       |                |        |
| 全聋                          | 8 (7.55)         | 21 (26.25)       |                |        |

2.3 模型性能比较

使用准确度、精确度、召回率、F1 分数 4 种指标对模型性能进行评价<sup>[10]</sup>。

准确度反映了模型预测正确的样本数占总样本数的比例,验证集中 RF 模型和 XGBoost 模型的准确度较高,两种模型均具有较好的预测精度;精确度代表模型预测为阳性的样本中实际为阳性的比例(本研究中阳性事件定义为预后不良),验证集中 RF 模型的精确度最高,其他 3 组模型基本一致;召回率侧重体现模型对阳性样本的捕捉能力以减少漏诊可能,验证集中 RF 模型和 XGBoost 模型的召回率较高,LR 模型最低;F1 分数综合考虑精确率和召回率,是评估模型稳定性的重要指标,验证集中 RF 模型的 F1 值最高,但 RF 模型在验证集中的灵敏度和特异度较训练集显著降低,提示 RF 模型存在过拟合现象,模型稳定性偏低,推测原因在于,当阳性和阴性两种样本误判比例都增多时,经过 F1 分数计算过程的综合考量,误判所致的影响相互抵消,F1 分数基本不变<sup>[11]</sup>。见表 3。

模型 AUC 方面,LR、RF、XGBoost、SVM 模型的训练集与验证集受试者工作特征(receiver operating characteristic,ROC) AUC 均在 75% 以上,说明 4 种模型均具有良好的效果。验证集中,SVM 和 XGBoost 模型 AUC 较高,4 种模型的 AUC 差异无统计学意义。综合评估各项指标,XGBoost 模型性能均衡,表现可靠,能够准确识别预后不良的患者,同时可避免过度治疗,最适用于临床。见图 3、表 4。

基于 SHAP 对模型进行可解释性分析。对于每位患者,每个预测变量对最终结果的贡献均以 SHAP 值来表示,SHAP 值越大,意味着患者出现治疗无效结局的可能性越高。结果显示,对结局变量的贡献值从高到低依次排序为:听力损失程度、听力图类型、糖尿病、高血压病程、眩晕、吸烟史、高尿酸血症。见图 4。

3 讨论

SSNHL 的病因及疗效的影响因素尚不明确,如何实现理想的疗效和预后仍是临床防治中的难点。高血压可促进内耳微血管压力产生变化,导致耳蜗血液供应减少、耳蜗微循环障碍,最终引起听力损失<sup>[12]</sup>。本研究治疗有效率为 56.8%,低于以往关于 SSNHL 患者的治疗总有效率的报道,这可能是由于微血管病变致使耳蜗血液灌注减少,药物通过血液循环到达受损组织受阻,内毛细胞得不到有效修复<sup>[13]</sup>。

本研究结果与既往研究相符,无效组患者初始听力损失程度更严重<sup>[14]</sup>,听力图类型多呈现低频下降型与高频下降型,与宰雄跃等<sup>[15]</sup>的研究结果一致,推测其成因与内耳微循环障碍、缺氧及内耳出血等因素相关<sup>[16]</sup>。伴有眩晕症状的患者,常表明病变已累及耳蜗与前庭,受累范围较为广泛,预后状况欠佳<sup>[17]</sup>。对于同时罹患高血压与糖尿病的患者,糖尿病所涉及的潜在分子机制,如氧化应激、炎症反应以

表 3 4 种模型在训练集和验证集中评估性能比较 (%)

| 评价指标  | 训练集   |       |       |         | 验证集   |       |       |         |
|-------|-------|-------|-------|---------|-------|-------|-------|---------|
|       | LR    | RF    | SVM   | XGBoost | LR    | RF    | SVM   | XGBoost |
| 灵敏度   | 88.60 | 84.80 | 84.80 | 86.10   | 78.57 | 56.52 | 82.35 | 78.94   |
| 特异度   | 68.90 | 82.10 | 81.10 | 80.20   | 69.70 | 66.67 | 76.67 | 78.57   |
| 准确度   | 74.59 | 83.24 | 83.78 | 82.70   | 72.34 | 85.11 | 76.60 | 78.72   |
| 精确度   | 70.00 | 83.33 | 84.51 | 80.52   | 78.57 | 93.75 | 77.78 | 78.95   |
| 召回率   | 70.89 | 75.95 | 75.95 | 78.48   | 52.38 | 71.47 | 66.67 | 71.43   |
| F1 分数 | 70.44 | 79.47 | 80.00 | 79.49   | 62.86 | 81.08 | 71.79 | 75.00   |

注:LR(逻辑回归);RF(随机森林);XGBoost(极端梯度提升树);SVM(支持向量机)。下同。

表 4 训练集和验证集中 4 种模型的 AUC 比较及 Delong 检验结果

| 模型      | 训练集                |       | 验证集                 |       |
|---------|--------------------|-------|---------------------|-------|
|         | AUC(95% CI)        | P     | AUC(95% CI)         | P     |
| LR      | 0.865(0.815~0.915) | —     | 0.763(0.608~0.918)  | —     |
| RF      | 0.924(0.889~0.960) | 0.000 | 0.7625(0.615~0.910) | 1.000 |
| XGBoost | 0.923(0.887~0.959) | 0.000 | 0.787(0.642~0.931)  | 0.440 |
| SVM     | 0.913(0.871~0.955) | 0.090 | 0.796(0.662~0.929)  | 0.436 |

注:AUC(曲线下面积)。下同。

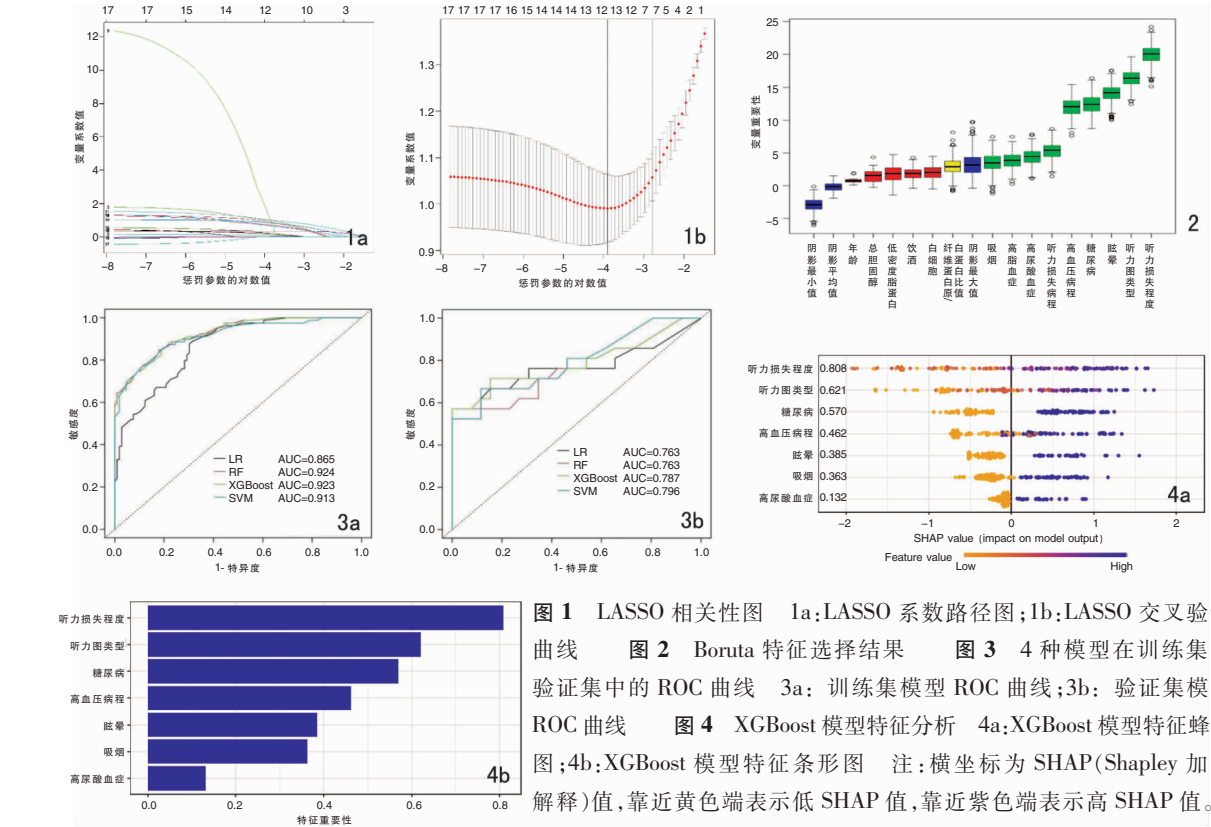


图1 LASSO相关性图 1a:LASSO系数路径图;1b:LASSO交叉验证曲线 图2 Boruta特征选择结果 图3 4种模型在训练集与验证集中的ROC曲线 3a:训练集模型ROC曲线;3b:验证集模型ROC曲线 图4 XGBoost模型特征分析 4a:XGBoost模型特征蜂群图;4b:XGBoost模型特征条形图 注:横坐标为SHAP(Shapley加性解释)值,靠近黄色端表示低SHAP值,靠近紫色端表示高SHAP值。

及纤维化等,致使内耳血管功能障碍及损伤进一步加剧<sup>[18]</sup>。与李倩等<sup>[19]</sup>的研究结论一致,高血压病史较长的患者预后相对较差。长期高血压状态可对血管内皮细胞造成损害,降低动脉壁弹性,致使脑血流量减少,脑血流自动调节机制受阻,机体应对血压波动的调节能力随之下降<sup>[20]</sup>。此外,尿酸水平升高可能通过内毛细胞的氧化应激、免疫机制、血管功能失调以及炎症反应等途径加重内毛细胞损害,进而影响预后<sup>[21]</sup>。

吸烟对SSNHL预后的影响尚未达成一致。本研究中,吸烟对SSNHL患者的预后具有负面影响,在Umesawa等<sup>[22]</sup>调研中,揭示了吸烟频率与SSNHL严重程度间呈正相关,吸烟可诱发内耳动脉硬化以及微血栓形成,进而减少内耳的血液灌注。然而,Zhu等<sup>[23]</sup>研究则显示,SSNHL患者的吸烟史与良好听力预后之间存在微弱的正相关。

本研究中年龄和发病至就诊时间对SSNHL预后的影响并未体现,这与Mattox等<sup>[24]</sup>结论一致,另有研究表明高龄及延误治疗时机可致预后变差<sup>[25]</sup>。

相较于传统统计学分析手段,机器学习方法于SSNHL预后预测方面展现出更优效能<sup>[26]</sup>。Park等<sup>[27]</sup>纳入32项变量并运用5种机器学习算法构建预测模型,对227例SSNHL患者治疗1个月后受损

听力恢复状况予以评估,发现SVM的预测准确率最高。Lee等<sup>[28]</sup>借助递归特征消除实施特征筛选,进而采用LR、轻度梯度提升机、XGBoost、SVM和多层感知器5种机器学习算法构建模型,结果显示轻度梯度提升机模型综合表现最优且精度平衡。Uhm等<sup>[29]</sup>对6种机器学习方法展开对比,确定深度神经网络模型( $AUC = 0.944$ )为最佳预测模型,并运用深度神经网络方法计算变量重要性。本研究构建的4种模型预测性能与既往研究存在一定差异,这可能源于样本量差异、研究人群不同以及特征筛选方法的多样性。

综上所述,本研究所构建的4种模型均具有较好的预测性能,其中XGBoost模型性能表现最为优异,能够较准确地预测合并高血压的SSNHL患者预后,利于临床医生面对具有不同特征因素的患者实现个体化治疗。机器学习在挖掘临床复杂且分布特征未知数据的潜在规律方面独具优势,基于其构建的预测模型与实际情况的契合度更为理想<sup>[30]</sup>,研究的不足之处在于,本研究为回顾性、单中心研究,样本量相对较小,难免存在偏倚,模型未进行外部验证,未来应考虑纳入更全面的特征因素,以更大样本量、更多中心研究来验证,以提高模型的适用性和外推性。

## 参考文献:

- [1] 中华耳鼻咽喉头颈外科杂志编辑委员会,中华医学会耳鼻咽喉头颈外科学分会. 突发性聋诊断和治疗指南(2015)[J]. 中华耳鼻咽喉头颈外科杂志,2015,50(6):443-447.
- [2] Tripathi P, Deshmukh P. Sudden sensorineural hearing loss: a review[J]. Cureus, 2022,14(9):e29458.
- [3] Saba ES, Swisher AR, Ansari GN, et al. Cardiovascular risk factors in patients with sudden sensorineural hearing loss: A systematic review and meta-analysis[J]. Otolaryngol Head Neck Surg, 2023,168(5):907-921.
- [4] Penido Nde O, Ramos HV, Barros FA, et al. Clinical, etiological and progression factors of hearing in sudden deafness[J]. Braz J Otorhinolaryngol,2005,71(5):633-638.
- [5] Shon S, Lim K, Chae M, et al. Predicting sudden sensorineural hearing loss recovery with patient-personalized seigel's criteria using machine learning[J]. Diagnostics (Basel), 2024,14(12):1296.
- [6] 侯思源,王振霖. 机器学习在垂体腺瘤研究中的应用进展[J]. 中国耳鼻咽喉颅底外科杂志, 2023,29(3):40-44.
- [7] 国家心血管病中心,国家基本公共卫生服务项目基层高血压管理办公室,国家基层高血压管理专家委员会. 国家基层高血压防治管理指南 2020 版[J]. 中国循环杂志,2021,36(3):209-220.
- [8] Wang S, Zhang L, Liu X, et al. Optimization of multidimensional feature engineering and data partitioning strategies in heart disease prediction models[J]. Alex Eng J,2024,107(11):932-949.
- [9] Li J, Liu S, Hu Y, et al. Predicting mortality in intensive care unit patients with heart failure using an interpretable machine learning model: retrospective cohort study[J]. J Med Internet Res, 2022,24(8):e38082.
- [10] 谢琴琴,季欢欢,杨雅,等. 基于机器学习构建儿童抗结核药物肝损伤风险预测模型[J]. 中国现代应用药学,2024,41(24):3447-3455.
- [11] Japkowicz N, Shah M. Performance measures[M]. New York: Cambridge University Press, 2014: 41-88.
- [12] Savoia C, Battistoni A, Calvez V, et al. Microvascular alterations in hypertension and vascular aging[J]. Curr Hypertens Rev, 2017,13(1):16-23.
- [13] Hou Y, Liu B. Relationship between hypertension and hearing Loss: analysis of the related factors[J]. Clin Interv Aging,2024,19:845-856.
- [14] He J, Jin L, Yao J, et al. Clinical characteristics of patients diagnosed with bilateral sudden sensorineural hearing loss[J]. Front Neurol, 2024,15:1378017.
- [15] 宰雄跃,孔瑶,李昌增,等. 肾小球滤过率与突发性聋预后的相关性研究[J]. 中国耳鼻咽喉颅底外科杂志,2024,30(2):85-89.
- [16] Caragli V, Franz L, Incognito A, et al. Prognostic factors in idiopathic sudden sensorineural hearing loss: the experience of two audiology tertiary referral centres[J]. Medicina(Kaunas), 2024,60(7):1130.
- [17] 吴旋,刘敏,庄惠文,等. 极重度突发性聋患者耳蜗和前庭功能特点及预后差异性分析[J]. 中华耳鼻咽喉头颈外科杂志, 2020,55(5):472-478.
- [18] 刘宁,张伟华. 糖尿病合并高血压加重血管病变的研究进展[J]. 基础医学与临床, 2020, 40(7): 990-994.
- [19] 李倩,王大勇,王洪阳,等. 突发性聋合并高血压患者的纯音测听特征与疗效分析[J]. 临床耳鼻咽喉头颈外科杂志,2015,29(8):748-752.
- [20] 覃仙菲,赵翔翥,孙秀梅. 常见基础疾病影响突聋疗效的研究进展[J]. 中华耳科学杂志,2024,22(2):275-278.
- [21] Sahin A, Kilic K, Sakat MS, et al. Early hearing loss detection in gout using extended high-frequency audiometry[J]. Clin Otolaryngol, 2022,47(5):577-582.
- [22] Umesawa M, Kobashi G, Kitoh R, et al. Relationships among drinking and smoking habits, history of diseases, body mass index and idiopathic sudden sensorineural hearing loss in Japanese patients[J]. Acta Otolaryngol,2017,137(sup565):S17-S23.
- [23] Zhu Y, He S, Liao K, et al. Clinical profiles and prognoses of adult patients with full-frequency sudden sensorineural hearing loss in combination therapy[J]. J Clin Med,2023,12(4):1478.
- [24] Mattox DE, Simmons FB. Natural history of sudden sensorineural hearing loss[J]. Ann Otol Rhinol Laryngol,1977,86(4 Pt 1):463-480.
- [25] Li KH, Chien CY, Tai SY, et al. Prognosis prediction of sudden sensorineural hearing loss using ensemble artificial intelligence learning models[J]. Otol Neurotol,2024,45(7):759-764.
- [26] Bogaz EA, Maranhão AS, Inoue DP, et al. Variables with prognostic value in the onset of idiopathic sudden sensorineural hearing loss[J]. Braz J Otorhinolaryngol,2015,81(5):520-526.
- [27] Park KV, Oh KH, Jeong YJ, et al. Machine learning models for predicting hearing prognosis in unilateral idiopathic sudden sensorineural hearing loss[J]. Clin Exp Otorhinolaryngol, 2020, 13(2):148-156.
- [28] Lee MK, Jeon ET, Baek N, et al. Prediction of hearing recovery in unilateral sudden sensorineural hearing loss using artificial intelligence[J]. Sci Rep,2022,12(1):3977.
- [29] Uhm TW, Yi S, Choi SW, et al. Hearing recovery prediction and prognostic factors of idiopathic sudden sensorineural hearing loss: a retrospective analysis with a deep neural network model[J]. Braz J Otorhinolaryngol,2023,89(4):101273.
- [30] 杨安妮,李琦,李湘平. 突发性聋预后研究进展[J]. 中华耳科学杂志, 2021, 19(2):306-310.

(收稿日期:2024-10-07)

**本文引用格式:**杨瑾,米彦芳. 机器学习算法构建不同模型预测突发性感音神经性聋伴高血压患者的预后[J]. 中国耳鼻咽喉颅底外科杂志, 2025,31(2):30-36. DOI:10.11798/j.issn.1007-1520.202524393

**Cite this article as:**YANG Jin, MI Yanfang. Machine learning algorithms to construct different models to predict prognosis in patients with sudden sensorineural hearing loss with hypertension[J]. Chin J Otorhinolaryngol Skull Base Surg, 2025,31(2):30-36. DOI:10.11798/j.issn.1007-1520.202524393