

· 论著 ·

比较多种机器学习模型预测肺移植术后受者生存

史灵芝 刘亚灵 严浩吉 喻赠玮 侯森林 刘明昭 杨航 吴波 田东 陈静瑜

【摘要】 **目的** 比较不同机器学习算法构建的预后模型在预测肺移植 (LTx) 受者生存期方面的性能和表现。**方法** 回顾性收集 483 例行 LTx 手术的受者资料, 所有受者按 7:3 的比例分为训练集和验证集, 将收集到的 24 个变量基于变量重要性 (VIMP) 进行筛选, 利用随机生存森林 (RSF) 和极端梯度提升树 (XGBoost) 构建预后模型, 使用综合曲线下面积 (iAUC) 和时间依赖曲线下面积 (tAUC) 进行模型性能评估。**结果** 训练集和验证集的各变量差异均无统计学意义。基于 VIMP 筛选排名前 15 的变量用于建模并确定重症监护室 (ICU) 住院时间为最重要的因素。与 XGBoost 模型相比, RSF 模型在预测受者生存期方面表现出更好的性能 (iAUC 0.773 比 0.723)。在预测受者 6 个月生存期 (tAUC_{6个月} 0.884 比 0.809, $P = 0.009$) 和 1 年生存期 (tAUC_{1年} 0.896 比 0.825, $P = 0.013$) 方面, RSF 模型也表现出更好的性能。基于两种算法的预测截断值, 将 LTx 术后受者分为高风险组和低风险组, 两种模型的生存分析结果均显示高风险组受者的生存率低于低风险组 ($P < 0.001$)。**结论** 与 XGBoost 相比, 基于 RSF 算法开发的机器学习预后模型可以更好地预测 LTx 受者的生存期。

【关键词】 肺移植; 机器学习; 预测模型; 随机生存森林; 极端梯度提升树; 生存期; 比例风险回归模型; 重症监护室

【中图分类号】 R617 **【文献标志码】** A **【文章编号】** 1674-7445 (2025) 02-0011-08

Comparison of multiple machine learning models for predicting the survival of recipients after lung transplantation

Shi Lingzhi*, Liu Yaling, Yan Haoji, Yu Zengwei, Hou Senlin, Liu Mingzhao, Yang Hang, Wu Bo, Tian Dong, Chen Jingyu. *Wuxi Medical Center, Nanjing Medical University, Wuxi People's Hospital, Lung Transplantation Center, the Affiliated Wuxi People's Hospital of Nanjing Medical University, Wuxi 214000, China

Corresponding author: Chen Jingyu, Email: chenjy@wuxiph.com

【Abstract】 **Objective** To compare the performance and efficacy of prognostic models constructed by different machine learning algorithms in predicting the survival period of lung transplantation (LTx) recipients. **Methods** Data from 483 recipients who underwent LTx were retrospectively collected. All recipients were divided into a training set and a validation set at a ratio of 7:3. The 24 collected variables were screened based on variable importance (VIMP). Prognostic models were constructed using random survival forest (RSF) and extreme gradient boosting tree (XGBoost). The performance of the models was evaluated using the integrated area under the curve (iAUC) and time-dependent area under the curve (tAUC). **Results** There were no significant statistical differences in the variables between the training set and the validation set. The top 15 variables ranked by VIMP were used for modeling and the length of stay in the intensive care unit (ICU) was determined as the most important factor. Compared with the XGBoost model, the RSF model

DOI: 10.12464/j.issn.1674-7445.2025018

基金项目: 国家自然科学基金 (82470104); 四川省医学科技创新项目 (YCH-KY-YCZD2024-227)

作者单位: 214000 江苏无锡, 南京医科大学无锡医学中心 无锡市人民医院 南京医科大学附属无锡市人民医院肺移植中心 (史灵芝、刘明昭、杨航、吴波、陈静瑜); 四川大学华西医院胸外科 (田东); 四川大学华西医院胸部肿瘤研究所肺移植研究室 (刘亚灵、严浩吉、喻赠玮、侯森林); 浙江大学医学院附属第二医院肺移植科 (陈静瑜)

作者简介: 史灵芝 (ORCID 0000-0002-4885-8685), 博士, 副主任医师, 研究方向为肺移植临床研究, Email: shilingzhi1979@126.com

通信作者: 陈静瑜 (ORCID 0000-0002-2127-1788), 博士, 教授, 研究方向为肺移植, Email: chenjy@wuxiph.com

demonstrated better performance in predicting the survival period of recipients (iAUC 0.773 vs. 0.723). The RSF model also showed better performance in predicting the 6-month survival period (tAUC_{6 months} 0.884 vs. 0.809, $P = 0.009$) and 1-year survival period (tAUC_{1 year} 0.896 vs. 0.825, $P = 0.013$) of recipients. Based on the prediction cut-off values of the two algorithms, LTx recipients were divided into high-risk and low-risk groups. The survival analysis results of both models showed that the survival rate of recipients in the high-risk group was significantly lower than that in the low-risk group ($P < 0.001$). **Conclusions** Compared with XGBoost, the machine learning prognostic model developed based on the RSF algorithm may preferably predict the survival period of LTx recipients.

【 Key words 】 Lung transplantation; Machine learning; Prediction model; Random survival forest; Extreme gradient boosting tree; Survival period; Proportional hazards regression model; Intensive care unit

肺移植 (lung transplantation, LTx) 是针对终末期肺部疾病唯一经过临床验证的有效治疗策略^[1-2], 然而, 相较于其它的实体器官移植, LTx 术后受者的生存并不理想, 中位生存期仅为 6.7 年^[3]。开发能预测 LTx 临床预后的模型不仅可以基于受者的临床特征精准评估风险, 还能有效辅助临床医师制定个性化的治疗方案, 为现有供肺分配制度的改进提供重要的参考依据, 这对于进一步改善 LTx 受者的生存率至关重要^[4-6]。机器学习通过处理大量复杂的临床数据, 能够识别其潜在的模式和关联, 综合多种数据源并提供个性化的预测, 在构建临床预后模型方面具有显著的优势^[7]。本团队既往研究表明, 基于随机生存森林 (random survival forest, RSF) 算法开发的预后模型在预测 LTx 术后受者总生存期方面具有良好的表现性能^[8]。目前已有一些研究致力于建立临床预测模型, 以评估 LTx 受者的预后^[5, 9-12], 然而, 这些研究仅采用单一的机器学习算法来预测 LTx 术后受者的生存期, 缺乏对不同算法间效果的系统比较, 这种研究设计的局限性使得我们难以全面了解各类机器学习方法在该领域的实际表现。不同算法具有各自独特的优势和不足, 单一算法的应用可能无法捕捉到数据的复杂性和多样性, 引入其他不同算法能够进一步优化模型的预测性能和泛化能力^[13-14]。因此, 进一步探索和评估不同算法在 LTx 受者总生存期预测中的表现, 不仅有助于识别与临床结果相关的关键特征, 还能为临床实践提供更加准确和可靠的工具。

极端梯度提升树 (extreme gradient boosting, XGBoost) 是一种基于梯度提升框架的高效机器学习算法, 能够处理复杂的特征交互关系, 提供高度精准的风险评估^[15]。其强大的预测能力使得它在临床数据分析中表现突出, 能够辅助临床医师识别高风险受者并制定个性化的治疗方案, 从而显著改善受者的预后^[16-17]。因此, 本研究比较了基于 RSF 算法与 XGBoost 算法构建的预后模型在 LTx 术后受者生存

期预测方面的性能, 旨在探索一种更适合预测 LTx 术后生存期的算法, 以便为后续开发更加精准的预后模型提供参考。

1 资料与方法

1.1 一般资料

回顾性收集了 2017 年 1 月至 2019 年 12 月在无锡市人民医院接受 LTx 手术的 523 例受者的临床资料。纳入标准为随访记录完整的 LTx 成年受者 (年龄 > 18 岁)。排除标准为受者年龄 < 18 岁、受者再次行 LTx 手术、受者资料严重缺失和受者失访。根据纳入排除标准, 在排除 6 例再次 LTx 受者、7 例儿童 LTx 受者、6 例数据严重缺失受者和 21 例失访受者后, 最终纳入 483 例受者用于后续的建模和分析。本单中心、回顾性观察性研究的方案由研究者所在机构的机构审查委员会批准 (批号: No. 2020 [374]), 由于研究的回顾性性质, 书面知情同意的要求被豁免。本研究遵循个体预后或诊断多变量预测模型透明报告指南^[18]。

1.2 变量收集和选择

本研究使用的所有数据均通过查阅受者病历进行收集, 共收集到 24 个变量, 包括 4 个受者因素、1 个供者因素、4 个移植程序因素和 15 个移植后因素。总生存期是本研究的目标变量, LTx 术后 3~5 周进行患者随访, 因受者个体差异随访次数不定, 本研究的最后 1 次随访发生在 2024 年 7 月 24 日。使用 R 语言中的 “mice” 包对受者资料的缺失值进行多重插补。

变量选择过程基于变量重要性 (variable importance, VIMP) 实现。VIMP 是 RSF 的一种内部统计量, 可以评估各个变量对模型预测性能的贡献程度。通过网格搜索进行超参数调整 (包括树的数量、每个节点可能分割的变量数量、终端节点的大小) 后

建立 RSF 模型并计算各变量的重要性, 将 VIMP 排名前 15 的变量纳入后续的建模和分析。

1.3 模型的开发与验证

研究的建模与分析均使用 R 语言 (4.4.1 版本) 完成。使用“留出法”(hold-out) 进行模型的建立和验证, 使用“caret”R 包将所有入组受者随机按 7:3 分为训练集和验证集。使用“randomForestSRC”R 包和“XGBoost”R 包分别拟合 RSF 模型和 XGBoost 模型, 根据纳入的变量和最优超参数组合预测 LTx 术后受者的总生存期。此外, 使用“rms”包拟合 Cox 回归模型作为基准模型。将训练成功的所有模型在验证集上进行独立评估, 在没有特别声明的情况下, 所有性能统计数据均基于验证集计算。

使用综合曲线下面积 (integrated area under the curve, iAUC) 和时间依赖曲线下面积 (time-dependent area under the curve, tAUC) 来评价模型的区分能力, AUC 值越接近 1, 预测模型的判别能力越好。本研究所建立的预测模型为每例受者分配了一个相应的预后预测值, 使用 R 包“survminer”中的“surv_cutpoint”函数计算出预测值的最佳截断值, 并根据截断值将所有受者分为高风险组和低风险组, 预后预测值低于截断值的受者为低风险组, 预后预测值高于截断值的受者为高风险组。

1.4 统计学方法

采用 R 语言进行统计分析。分类变量用率表示, 组间比较采用 χ^2 检验; 连续变量用均数±标准差表示, 组间比较采用独立样本 *t* 检验。使用 Kaplan-Meier 法计算高风险组和低风险组受者的生存率并基于 log-rank 检验比较上述两组受者的生存差异。使用 R 包“timeROC”中的“compare”函数基于 DeLong 检验比较不同时间节点 tAUC 的差异。 $P < 0.05$ 为差异有统计学意义。

2 结果

2.1 样本变量比较

本研究最终纳入 483 例 LTx 术后受者, 平均年龄为 55 岁, 其中 320 例 (66.3%) 受者为男性, 大部分受者被诊断为间质性肺纤维化 (54.5%), 其次为慢性阻塞性肺病 (19.0%)。将所有受者按照 7:3 的比例随机分为训练集 ($n = 339$) 和验证集 ($n = 144$), 且两组受者的各变量差异均无统计学意义 (均为 $P > 0.05$)。所有受者、训练集受者和验证集受者的详细变量见附件 1 表格 (扫描二维码可见)。

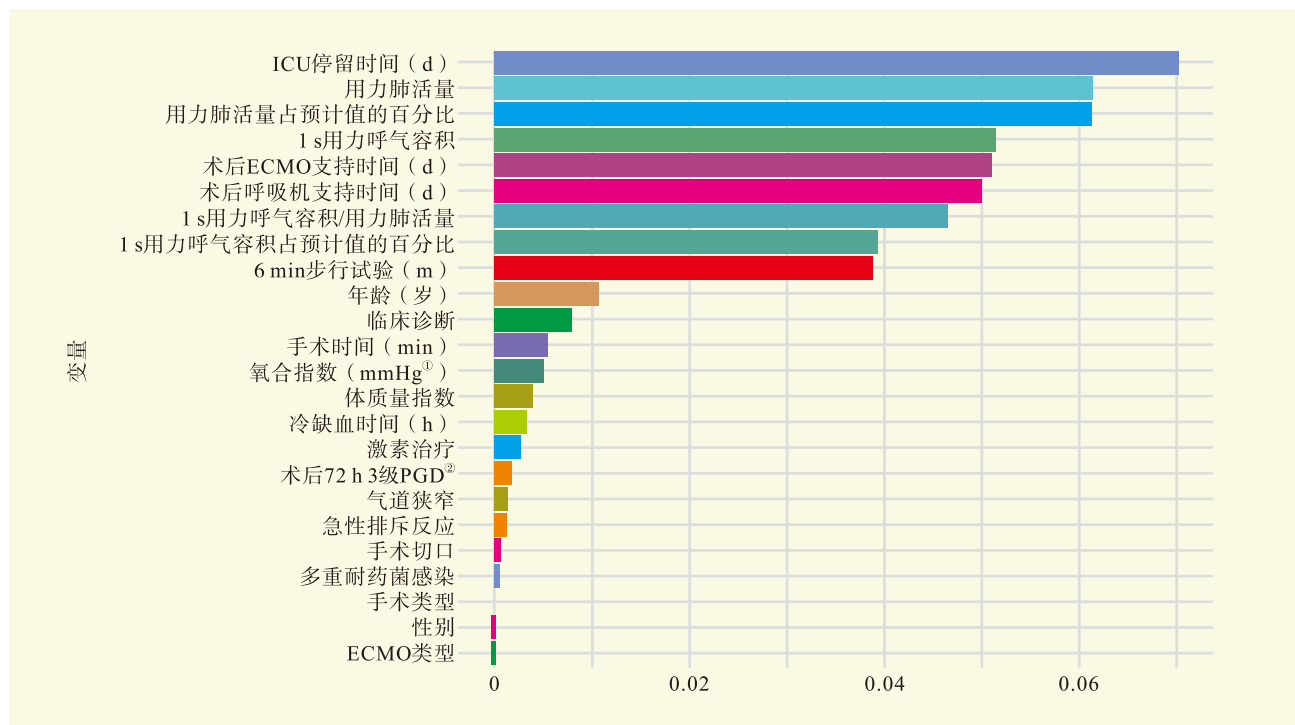


扫描二维码见附件 1

2.2 变量选择及模型构建

基于 VIMP 筛选排名前 15 个变量纳入后续的建模和分析, 包括 1 个供者因素 (氧合指数)、3 个受者因素 (年龄、临床诊断、体质量指数)、2 个移植程序因素 (手术时间、冷缺血时间) 和 9 个移植后因素 [重症监护室 (intensive care unit, ICU) 停留时间、1 s 用力呼气容积、1 s 用力呼气容积占预计值的百分比、用力肺活量、用力肺活量占预计值的百分比、1 s 用力呼气容积 / 用力肺活量、6 min 步行试验、术后体外膜肺氧合 (extracorporeal membrane oxygenation, ECMO) 支持时间、术后呼吸机支持时间], 基于这些变量建立模型并进行后续分析。所有变量的重要性见图 1, 其中 ICU 停留时间被确定为最重要的因素, VIMP 为 0.070。

各模型性能指标在测试集中的评估结果见表 1。在预测 LTx 术后受者的总生存期方面, 基于机器学习算法开发的 RSF 模型 (iAUC 0.773, 95% CI 0.706~0.839) 和 XGBoost 模型 (iAUC 0.723, 95% CI 0.656~0.790) 均表现出较好的判别能力, 然而相比于 RSF, 基于 XGBoost 算法开发的模型 iAUC 和同时期的 tAUC 略有下降 (图 2)。基于机器学习算法开发模型的预测性能均优于基于传统回归算法开发的 Cox 模型 (iAUC 0.653, 95% CI 0.586~0.720, 表 1)。在预测 LTx 术后受者 6 个月的生存期方面, RSF 模型 (tAUC 0.884) 表现出比 XGBoost 模型 (tAUC 0.809) 更好的判别能力, 且经 DeLong 检验这种差异存在统计学意义 ($P = 0.009$, 图 3A)。在预测 LTx 术后受者 1 年生存期方面, RSF 模型 (tAUC 0.896) 也表现出比 XGBoost 模型 (tAUC 0.825) 更好的判别能力, 且经 DeLong 检验这种差异依然具有统计学意义 ($P = 0.013$, 图 3B)。无论预测 LTx 术后 6 个月还是 1 年的生存期, 基于机器学习算法开发的两种预后模型的性能均优于传统的 Cox 模型 (tAUC_{6个月} 0.694, tAUC_{1年} 0.695, 表 1)。



注: ①1 mmHg=0.133 kPa; ②PGD 为原发性移植物失功。

图 1 变量重要性

Figure 1 The variables importance

表 1 训练集和验证集的预测效能

Table 1 The predictive performance of training and validation sets

模型	训练集		验证集	
	预测时间	iAUC或tAUC (95% CI)	预测时间	iAUC或tAUC (95% CI)
RSF模型	1~50个月	0.776 (0.733~0.810) ^a	1~50个月	0.773 (0.706~0.839) ^a
Cox模型	1~50个月	0.691 (0.647~0.734) ^a	1~50个月	0.653 (0.586~0.720) ^a
XGBoost模型	1~50个月	0.762 (0.680~0.844) ^a	1~50个月	0.723 (0.656~0.790) ^a
RSF模型	6个月	0.903 (0.872~0.934) ^b	6个月	0.884 (0.831~0.937) ^b
Cox模型	6个月	0.752 (0.699~0.805) ^b	6个月	0.694 (0.608~0.780) ^b
XGBoost模型	6个月	0.882 (0.815~0.947) ^b	6个月	0.809 (0.735~0.883) ^b
RSF模型	1年	0.893 (0.860~0.926) ^b	1年	0.896 (0.847~0.945) ^b
Cox模型	1年	0.762 (0.711~0.813) ^b	1年	0.695 (0.608~0.780) ^b
XGBoost模型	1年	0.888 (0.823~0.953) ^b	1年	0.825 (0.754~0.896) ^b

注: a为iAUC (95% CI); b为tAUC (95% CI)。

2.3 生存分析

RSF模型和XGBoost模型的预测值及截断值见图4, 基于RSF模型的最佳生存差异(最佳截断值为39.89, 图4A、C), 将验证集中的受者分为高风险组和低风险组, 使用Kaplan-Meier法绘制两组受者的生存曲线, 高风险组受者的总生存期短于低风险组($P<0.001$, 图5A)。基于XGBoost模型的最佳生存差异(最佳截断值为1.9, 图4B、D), 将验证集

中的受者分为高风险组和低风险组, 使用Kaplan-Meier法绘制两组受者的生存曲线, 高风险组受者的生存率也低于低风险组($P<0.001$, 图5B)。

3 讨论

本研究采用多种机器学习算法来构建LTx术后受者预后模型以预测其生存期, 并对这些算法在模型建立过程中的性能进行了系统比较, 我们重点发现

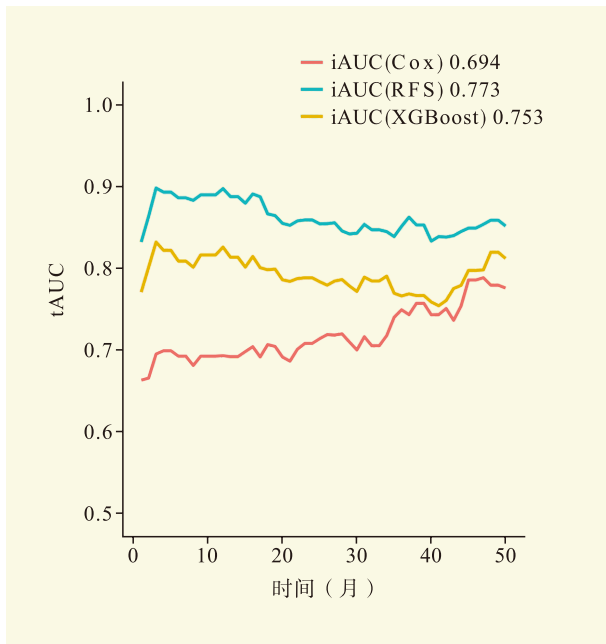


图2 RSF模型、XGBoost模型和传统Cox回归模型的性能比较


Figure 2 The performance comparison of RSF model, XGBoost model and traditional Cox regression model

在 24 个变量中，ICU 停留时间是预测总生存期的最关键因素；基于 RSF 算法开发的预后模型在预测 LTx 术后受者生存期方面的性能优于 XGBoost 算法；RSF 模型在预测 LTx 术后受者的特定时间点（6 个月和 1 年）生存结果方面表现也更出色。

ICU 住院时间是衡量 LTx 术后受者预后的一个关键因素，ICU 停留时间延长通常与更高的疾病发生率和病死率相关^[19]。本研究的结果进一步强调了

ICU 停留时间对 LTx 受者预后的关键影响，并从另一个角度证实了 ICU 停留时间的预后意义（VIMP 法）。然而，ICU 停留时间延长可能导致一系列严重的术后并发症，包括机械通气的使用时间延长、医院内感染的风险增加以及呼吸衰竭的发生率增加等^[20-23]，这些并发症不仅对 LTx 受者的即刻康复构成威胁，还可能对 LTx 受者的长期生存率产生深远的影响^[24-28]。因此，这些因素及其交互作用值得我们在未来进行更深入和系统的研究，以探索更有效的管理策略和优化受者预后的方法。

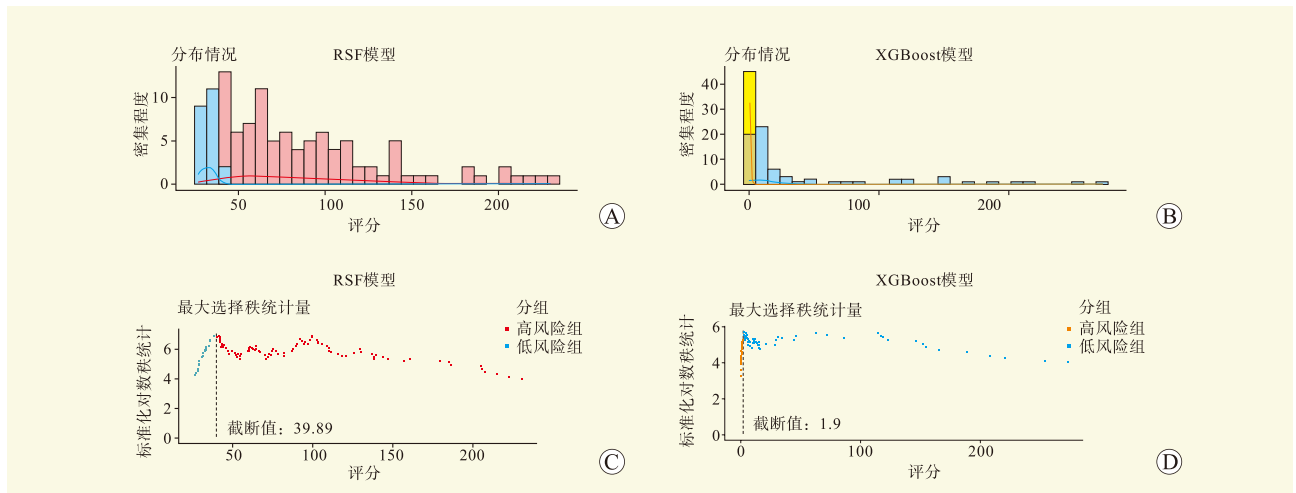
在过去的十年里，人工智能在预测 LTx 术后受者生存方面展现出巨大的潜力，逐步成为现代医学中不可或缺的工具^[29-32]。机器学习作为人工智能的重要分支，能整合各种预后因素并产生个体化的生存预测，从而为 LTx 受者生成更为准确的生存预测模型^[33]。对于 LTx 治疗的受者，目前已有一些研究致力于建立临床预测模型，以评估这些受者的预后^[4-5, 9, 11, 34-35]。本团队的前期研究利用人工智能的方法构建了 LTx 受者术后连续生存的预后模型，并且证明了 RSF 算法在预测 LTx 受者生存方面的优越性（iAUC 0.879）^[8]。然而，引入其他机器学习算法能否进一步提升模型对 LTx 受者生存的预测能力仍然是一个悬而未决的问题。XGBoost 算法是一种先进的梯度提升树框架，因其高效性、灵活性和准确性在众多机器学习任务中备受欢迎，在预测受者生存期的应用中，XGBoost 充分利用其强大的处理非线性关系和交互特征的能力，能够提升模型对复杂医疗数据集的适应性^[36-38]。因此，在本研究中，我们比较了基于两



注：A 图为 6 个月 ROC 曲线；B 图为 1 年 ROC 曲线。

图3 RSF模型和XGBoost模型6个月和1年的生存预测

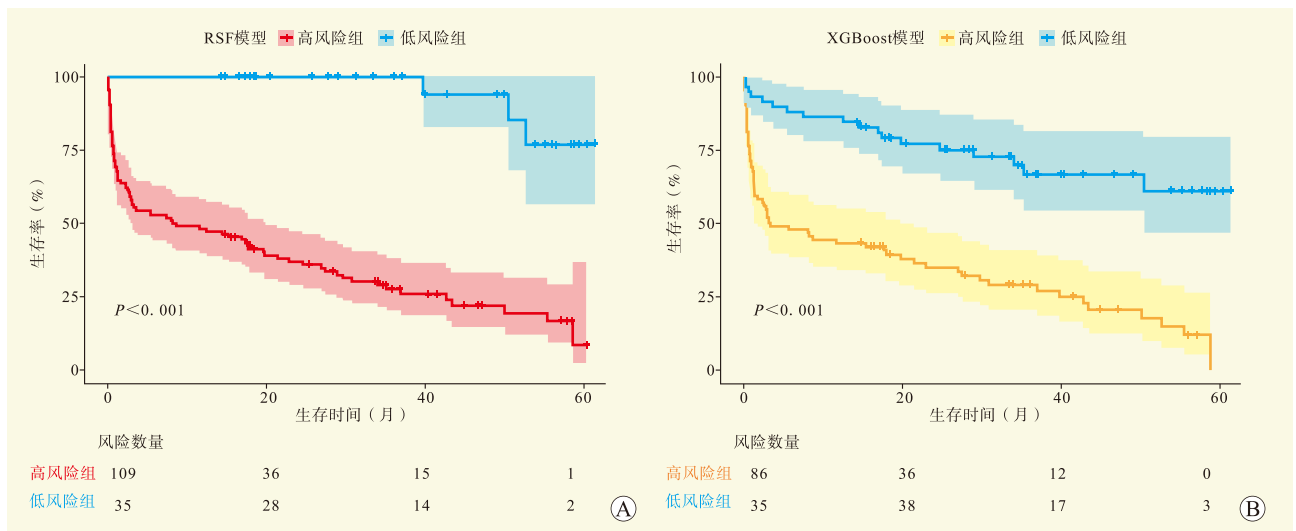
Figure 3 The 6 months and 1 year survival predictions of RSF model and XGBoost model



注：A 图为 RSF 模型预测值分布；B 图为 XGBoost 模型预测值分布；C 图为 RSF 模型截断值；D 图为 XGBoost 模型截断值。

图 4 RSF 模型和 XGBoost 模型的预测值及其分布情况

Figure 4 The predicted value and distribution of RSF model and XGBoost model



注：A 图为 RSF 模型的 Kaplan-Meier 法；B 图为 XGBoost 模型的 Kaplan-Meier 法。

图 5 不同风险 LTx 受者的生存分析

Figure 5 The survival analysis of LTx recipients at different risk levels

种不同机器学习算法——RSF 和 XGBoost 开发的模型，尽管二者在生存分析方面均表现出优秀的结果，但基于 RSF 算法开发的机器学习模型在预测受者总生存期方面的表现更佳 (iAUC 0.773 比 0.723)，说明 XGBoost 在预测 LTx 受者总生存期的任务中，性能仍未能超过 RSF，这表明在此特定应用背景下，RSF 可能是更为适合的预测工具，并进一步支持了 RSF 在生存分析领域，特别是在预测 LTx 受者总生存期中的潜在优势。此外，我们还将这些机器学习模型与传统的 Cox 回归模型进行了对比，以全面评估各模

型在生存期预测中的有效性和准确性。我们发现无论使用 RSF 算法还是 XGBoost 算法，基于机器学习算法开发的预后模型性能均显著优于传统的 Cox 回归模型 (iAUC 0.653)。通过对比不同模型，我们能够更好地理解各种算法在实际应用中的优缺点。

本研究还在两个特定的时间点 (6 个月和 1 年生存期) 利用 tAUC 量化了机器学习算法的预测能力，并利用 Delong 检验比较了不同机器学习算法在这些时间点的 tAUC，而非单纯地根据数值大小确定它们的监测能力。6 个月生存期反映了 LTx 受者的短期预后，

而 1 年生存期则反映 LTx 受者的长期预后。我们发现 RSF 算法在这两个时间点的预测能力均强于 XGBoost 算法, 且经 Delong 检验后这种优越性均存在统计学差异, 这表明在生存分析的背景下, RSF 算法在处理生存数据方面更具有有效性和优势, 其捕捉相关预测因子上的的一致性和稳定性有助于全面评估 LTx 受者的预后, 从而辅助临床医师在治疗和干预策略上做出更合理的选择。

本研究仍存在一定局限性。首先, 由于单中心回顾性的研究设计以及纳入研究的受者例数相对有限, 样本的选择可能会受到单中心受者特征的影响, 从而导致结果缺乏外部效度, 这可能会限制我们的结论在其他不同医疗环境中的推广应用; 其次, 本研究的模型仅通过内部验证集进行验证, 而对于机器学习模型, 多中心的外部验证数据对于验证其泛化能力至关重要, 这可能会导致我们的模型无法适应不同临床场景和受者特征, 将影响其在实际应用中的效果和可靠性; 最后, 本研究仅纳入 24 个变量来构建机器学习模型, 一些可能与 LTx 受者预后相关的潜在因素未被纳入本研究中, 有限的变量集合可能导致模型对特定风险或预后结果的捕捉能力不足, 进而影响临床决策。因此, 未来亟需开展大规模的多中心研究, 并且致力于研发更为强大和有效的机器学习算法, 以增强预后模型的可信度。

综上所述, 本研究比较了不同机器学习算法预测 LTx 术后受者总生存期的效能, 为构建更加精准的预测工具提供了重要的参考依据。

参考文献:

- [1] YOUNG K A, DILLING D F. The future of lung transplantation[J]. *Chest*, 2019, 155(3): 465-473. DOI: 10.1016/j.chest.2018.08.1036.
- [2] 陈雨霁, 宋陈婉秋, 黄桁, 等. 中国肺移植现状与挑战[J]. *生物医学转化*, 2023, 4(3): 14-20. DOI: 10.12287/j.issn.2096-8965.20230303.
CHEN Y X, SONG C W Q, HUANG H, et al. Current status and challenges of lung transplantation in China[J]. *Biomed Transform*, 2023, 4(3): 14-20. DOI: 10.12287/j.issn.2096-8965.20230303.
- [3] CHAMBERS D C, CHERIKH W S, HARHAY M O, et al. The International Thoracic Organ Transplant Registry of the International Society for Heart and Lung Transplantation: thirty-sixth adult lung and heart-lung transplantation report-2019; focus theme: donor and recipient size match[J]. *J Heart Lung Transplant*, 2019, 38(10): 1042-1055. DOI: 10.1016/j.healun.2019.08.001.
- [4] GRIES C J, RUE T C, HEAGERTY P J, et al. Development of a predictive model for long-term survival after lung transplantation and implications for the lung allocation score[J]. *J Heart Lung Transplant*, 2010, 29(7): 731-738. DOI: 10.1016/j.healun.2010.02.007.
- [5] BRAHMBHATT J M, WAI T H, GOSS C H, et al. The lung allocation score and other available models lack predictive accuracy for post-lung transplant survival[J]. *J Heart Lung Transplant*, 2022, 41(8): 1063-1074. DOI: 10.1016/j.healun.2022.05.008.
- [6] 顾美蓉, 刘民强, 戴韬寅, 等. 肺源分配评分与特发性肺纤维化受者肺移植术后早期死亡风险的相关性分析[J]. *器官移植*, 2024, 15(2): 251-256. DOI: 10.3969/j.issn.1674-7445.2023200.
GU M R, LIU M Q, DAI T Y, et al. Correlation between lung allocation score and early death risk of patients with idiopathic pulmonary fibrosis after lung transplantation[J]. *Organ Transplant*, 2024, 15(2): 251-256. DOI: 10.3969/j.issn.1674-7445.2023200.
- [7] HANDELMAN G S, KOK H K, CHANDRA R V, et al. eDoctor: machine learning and the future of medicine[J]. *J Intern Med*, 2018, 284(6): 603-619. DOI: 10.1111/joim.12822.
- [8] TIAN D, YAN H J, HUANG H, et al. Machine learning-based prognostic model for patients after lung transplantation[J]. *JAMA Netw Open*, 2023, 6(5): e2312022. DOI: 10.1001/jamanetworkopen.2023.12022.
- [9] RUSSO MJ, DAVIES RR, HONG KN, et al. Who is the high-risk recipient? predicting mortality after lung transplantation using pretransplant risk factors[J]. *J Thorac Cardiovasc Surg*, 2009, 138(5): 1234-1238. DOI: 10.1016/j.jtcvs.2009.07.036.
- [10] MORO A, JANJUA H M, ROGERS M P, et al. Survival tree provides individualized estimates of survival after lung transplant[J]. *J Surg Res*, 2024, 299: 195-204. DOI: 10.1016/j.jss.2024.04.017.
- [11] ZAFAR F, HOSSAIN M M, ZHANG Y, et al. Lung transplantation advanced prediction tool: determining recipient's outcome for a certain donor[J]. *Transplantation*, 2022, 106(10): 2019-2030. DOI: 10.1097/TP.0000000000004131.
- [12] TIAN D, ZUO Y J, YAN H J, et al. Machine learning model predicts airway stenosis requiring clinical intervention in patients after lung transplantation: a retrospective case-controlled study[J]. *BMC Med Inform Decis Mak*, 2024, 24(1): 229. DOI: 10.1186/s12911-024-02635-8.
- [13] GÓMEZ D, ROJAS A. An empirical overview of the no free lunch theorem and its effect on real-world machine learning classification[J]. *Neural Comput*, 2016, 28(1): 216-228. DOI: 10.1162/NECO_a_00793.
- [14] TIAN D, YAN H J, SHIYA H, et al. Machine learning-based radiomic computed tomography phenotyping of thymic epithelial tumors: predicting pathological and survival outcomes[J]. *J Thorac Cardiovasc Surg*, 2023, 165(2): 502-516. e9. DOI: 10.1016/j.jtcvs.2022.05.046.
- [15] THEDINGA K, HERWIG R. Gradient tree boosting and network propagation for the identification of pan-cancer survival networks[J]. *STAR Protoc*, 2022, 3(2): 101353. DOI: 10.1016/j.xpro.2022.101353.
- [16] KINOSHITA F, TAKENAKA T, YAMASHITA T, et al. Development of artificial intelligence prognostic model for surgically resected non-small cell lung cancer[J]. *Sci Rep*, 2023, 13(1): 15683. DOI: 10.1038/s41598-023-42964-8.
- [17] YAN H, NIIMI T, MATSUNAGA T, et al. Preoperatively predicting survival outcome for clinical stage IA pure-solid non-small cell lung cancer by

- radiomics-based machine learning[J]. 2025, 169(1): 254-266. DOI: 10.1016/j.jtcvs.2024.05.010.
- [18] COLLINS G S, REITSMA J B, ALTMAN D G, et al. Transparent reporting of a multivariable prediction model for individual prognosis or diagnosis (TRIPOD): the TRIPOD statement[J]. *BMJ*, 2015, 350: g7594. DOI: 10.1136/bmj.g7594.
- [19] YUSEN R D, EDWARDS L B, KUCHERYAVAYA A Y, et al. The registry of the International Society for Heart and Lung Transplantation: thirty-first adult lung and heart-lung transplant report—2014; focus theme: retransplantation[J]. *J Heart Lung Transplant*, 2014, 33(10): 1009-1024. DOI: 10.1016/j.healun.2014.08.004.
- [20] HADJILIADIS D, STEELE M P, GOVERT J A, et al. Outcome of lung transplant patients admitted to the medical ICU[J]. *Chest*, 2004, 125(3): 1040-1045. DOI: 10.1378/chest.125.3.1040.
- [21] BANGA A, SAHOO D, LANE C R, et al. Characteristics and outcomes of patients with lung transplantation requiring admission to the medical ICU[J]. *Chest*, 2014, 146(3): 590-599. DOI: 10.1378/chest.14-0191.
- [22] HORAI T, SHIGEMURA N, GRIES C, et al. Lung transplantation for patients with high lung allocation score: single-center experience[J]. *Ann Thorac Surg*, 2012, 93(5): 1592-1597. DOI: 10.1016/j.athoracsur.2011.09.045.
- [23] VERMEIJDEN J W, ZIJLSTRA J G, ERASMUS M E, et al. Lung transplantation for ventilator-dependent respiratory failure[J]. *J Heart Lung Transplant*, 2009, 28(4): 347-351. DOI: 10.1016/j.healun.2009.01.012.
- [24] SINGER J P, BLANC P D, HOOPEES C, et al. The impact of pretransplant mechanical ventilation on short- and long-term survival after lung transplantation[J]. *Am J Transplant*, 2011, 11(10): 2197-2204. DOI: 10.1111/j.1600-6143.2011.03684.x.
- [25] GAO R, WANG W, QIAN T, et al. Pulmonary bacterial infection after lung transplantation: risk factors and impact on short-term mortality[J]. *J Infect*, 2024, 89(5): 106273. DOI: 10.1016/j.jinf.2024.106273.
- [26] FREISCHLAG K, LYNCH TJ, IEVLEV V, et al. A matched survival analysis of lung transplant recipients with coronavirus disease 2019-related respiratory failure[J]. *Ann Thorac Surg*, 2023, 116(4): 819-828. DOI: 10.1016/j.athoracsur.2022.09.039.
- [27] 王泓懿, 李益行, 赵恒, 等. 肺移植术后新型冠状病毒感染四例[J]. *中国胸心血管外科临床杂志*, 2024, 31(11): 1697-1702. DOI: 10.7507/1007-4848.202306010.
- WANG H Y, LI Y X, ZHAO H, et al. COVID-19 after lung transplantation: four case reports[J]. *Chin J Clin Thorac Cardiovasc Surg*, 2024, 31(11): 1697-1702. DOI: 10.7507/1007-4848.202306010.
- [28] 中华人民共和国国家卫生健康委员会. 新型冠状病毒感染诊疗方案(第十版)[J]. *中华临床感染病杂志*, 2023, 16(1): 1-9. DOI: 10.3760/cma.j.issn.1674-2397.2023.01.001.
- National Health Commission of the People's Republic of China. Diagnosis and treatment plan for COVID-19 (10th edition)[J]. *Chin J Clin Infect Dis*, 2023, 16(1): 1-9. DOI: 10.3760/cma.j.issn.1674-2397.2023.01.001.
- [29] 刘敏, 李小婉, 王逸峰, 等. COUNT 评分对于特发性肺纤维化病人肺移植早期预后的预测价值[J]. *肠外与肠内营养*, 2024, 31(3): 135-142. DOI: 10.16151/j.1007-810x.2024.03.002.
- LIU M, LI X W, WANG Y F, et al. The predictive value of controlling the nutritional status score for the early prognosis of lung transplantation in patients with idiopathic pulmonary fibrosis[J]. *Parenter Enter Nutr*, 2024, 31(3): 135-142. DOI: 10.16151/j.1007-810x.2024.03.002.
- [30] 仇桑桑, 许琴芬, 陈静瑜, 等. 基于限制性立方样条模型分析肺移植受者多重耐药菌感染的危险因素[J]. *器官移植*, 2023, 14(4): 578-584. DOI: 10.3969/j.issn.1674-7445.2023.04.015.
- QIU S S, XU Q F, CHEN J Y, et al. Analysis of risk factors of multidrug-resistant organism infection in lung transplant recipients based on restricted cubic spline model[J]. *Organ Transplant*, 2023, 14(4): 578-584. DOI: 10.3969/j.issn.1674-7445.2023.04.015.
- [31] FOROUTAN F, MALIK A, CLARK K E, et al. Predictors of 1-year mortality after adult lung transplantation: systematic review and meta-analyses[J]. *J Heart Lung Transplant*, 2022, 41(7): 937-951. DOI: 10.1016/j.healun.2022.03.017.
- [32] RAM S, VERLEDEN S E, KUMAR M, et al. Computed tomography-based machine learning for donor lung screening before transplantation[J]. *J Heart Lung Transplant*, 2024, 43(3): 394-402. DOI: 10.1016/j.healun.2023.09.018.
- [33] MOONS K G, ROYSTON P, VERGOUWE Y, et al. Prognosis and prognostic research: what, why, and how?[J]. *BMJ*, 2009, 338: b375. DOI: 10.1136/bmj.b375.
- [34] CHAN E Y, NGUYEN D T, KALEEKAL T S, et al. The Houston methodist lung transplant risk model: a validated tool for pretransplant risk assessment[J]. *Ann Thorac Surg*, 2019, 108(4): 1094-1100. DOI: 10.1016/j.athoracsur.2019.03.108.
- [35] HUANG J, LIN J, ZHENG Z, et al. Risk factors and prognosis of airway complications in lung transplant recipients: a systematic review and meta-analysis[J]. *J Heart Lung Transplant*, 2023, 42(9): 1251-1260. DOI: 10.1016/j.healun.2023.04.011.
- [36] GUAN X, DU Y, MA R, et al. Construction of the XGBoost model for early lung cancer prediction based on metabolic indices[J]. *BMC Med Inform Decis Mak*, 2023, 23(1): 107. DOI: 10.1186/s12911-023-02171-x.
- [37] HUANG T, LE D, YUAN L, et al. Machine learning for prediction of in-hospital mortality in lung cancer patients admitted to intensive care unit[J]. *PLoS One*, 2023, 18(1): e0280606. DOI: 10.1371/journal.pone.0280606.
- [38] LIM J, JEON H G, SEO Y, et al. Survival prediction model for patients with hepatocellular carcinoma and extrahepatic metastasis based on XGBoost algorithm[J]. *J Hepatocell Carcinoma*, 2023, 10: 2251-2263. DOI: 10.2147/JHC.S429903.

(收稿日期: 2024-12-01)

(本文编辑: 谢诗韵 吴秋玲)