

基于机器学习预测前列腺增生术后早期生化复发

高晓阳

大连交通大学基础部理学院, 辽宁 大连

收稿日期: 2025年4月21日; 录用日期: 2025年5月14日; 发布日期: 2025年5月21日

摘 要

前列腺增生的术后生化复发是困扰患者正常生活的难题之一, 其中尿失禁是最突出的问题。传统的统计学方法和逻辑回归算法在对术后尿失禁的预测上具有很大的局限性, 预测效果也不尽人意, 大大影响了对患者术后的治疗和术前的诊断。对于以上的问题, 文章构建了新的预测前列腺增生术后早期生化复发的模型, 主要目的是更准确、更有效地预测患者术后早期生化复发, 将该模型命名为“S-KFG”。在研究中, 模型主要是以软投票分类器作为集成算法, 将KNN、随机森林、梯度提升树组合形成。另外使用堆叠算法, 以随机森林算法为基模型、逻辑回归算法为元模型做集成模型, 命名为“Hancerforest”。并与一些传统的机器学习算法, 如随机森林、梯度提升树等, 以及传统的逻辑回归预测进行比较。基于大连医科大学附属第二医院泌尿外科的数据, S-KFG模型的结果显示: 模型的AUC值达到了0.888, Hancerforest模型的AUC值也达到了0.872, 与传统的逻辑回归预测模型相比, 本研究的模型具有更好的预测效果。

关键词

机器学习, 前列腺增生, 堆叠模型, 软投票分类器

Prediction of Early Biochemical Recurrence after Prostatic Hyperplasia Surgery Based on Machine Learning

Xiaoyang Gao

College of Science, Department of Basic Sciences, Dalian Jiaotong University, Dalian Liaoning

Received: Apr. 21st, 2025; accepted: May 14th, 2025; published: May 21st, 2025

文章引用: 高晓阳. 基于机器学习预测前列腺增生术后早期生化复发[J]. 建模与仿真, 2025, 14(5): 612-622.
DOI: 10.12677/mos.2025.145419

Abstract

Postoperative biochemical recurrence of prostatic hyperplasia is one of the problems that plague the normal life of patients, among which urinary incontinence is the most prominent problem. Traditional statistical methods and logistic regression algorithms have great limitations in predicting postoperative urinary incontinence, and the prediction effect is unsatisfactory, which greatly affects the postoperative treatment and preoperative diagnosis of patients. In order to solve the above problems, a new model for predicting early biochemical recurrence after prostatic hyperplasia was constructed, and the main purpose was to predict early biochemical recurrence in patients with prostatic hyperplasia more accurately and effectively, named "S-KFG". In this paper, the model mainly uses the soft vote classifier as the ensemble algorithm and combines KNN, random forest, and gradient-boosting trees to form a group. In addition, the stacking algorithm is used, the random forest algorithm is used as the base model, and the logistic regression algorithm is used as the metamodel to make the ensemble model, which is named "Hancerforest". It is also compared with some traditional machine learning algorithms such as random forest, gradient boosted tree, etc., as well as traditional logistic regression prediction. Based on the data of the Department of Urology, the Second Affiliated Hospital of Dalian Medical University, the results of the S-KFG model showed that the AUC value of the model reached 0.888, and the AUC value of the Hancerforest model also reached 0.872, which was better than the traditional logistic regression prediction model.

Keywords

Machine Learning, Prostatic Hyperplasia, Stacked Model, Soft Vote Classifier

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

良性前列腺增生(Benign Prostatic Hyperplasia, BPH)是中老年男性最常见的泌尿系统疾病之一,前列腺增生剜除术(如经尿道前列腺剜除术, HoLEP)是治疗良性前列腺增生(BPH)的有效方法,具有出血少、恢复快等优点。尽管手术技术不断进步,但术后尿失禁(Urinary Incontinence, UI)仍是影响患者生活质量的重要并发症,发生率约为 1%~15%。术后 UI 的预测与预防已成为临床研究的热点,其核心目标是通过术前精准评估和术中策略优化,降低尿失禁风险。传统上,术后 UI 的预测主要依赖于临床经验和统计模型,但预测精度有限,难以满足个性化医疗的需求。近年来,机器学习(ML)技术在医疗领域的应用为术后 UI 的精准预测提供了新的契机。机器学习能够从多维度临床数据中自动学习复杂模式,构建高精度预测模型,从而识别高危患者,优化手术策略,改善预后。目前,已有研究将 ML 算法应用于 HoLEP 术后 UI 的预测,并取得了一定进展。然而,该领域仍面临数据异质性、模型可解释性、外部验证不足等挑战。

2. 研究现状

手术是治疗中重度良性前列腺增生的主要手段,然而,术后尿失禁(Urinary Incontinence, UI)作为常见并发症,发生率约为 5%~30%,严重影响患者的生活质量和心理健康。准确预测术后 UI 风险对于术前患者分层、优化手术方案和术后康复管理具有重要意义。早期术后 UI 的预测以临床观察为主导,依赖外科

医生的经验，如前列腺体积大、手术时间长被视为高风险因素[1]，但缺乏量化标准。手术方式也较为单一，开放前列腺切除术(Open Prostatectomy, OP)是主要术式，术后尿失禁发生率高达 10%~20%，主要原因是术中广泛切除前列腺组织损伤了尿道外括约肌(External Urethral Sphincter, EUS)，并且对尿道括约肌的解剖和功能缺乏深入认识，术中保护意识不足。之后随着 TURP 的普及，经尿道前列腺电切术(TURP)成为 BPH 治疗的金标准，术后尿失禁率降至 5%~10%。然而，电切镜的热损伤可能导致尿道括约肌去神经化，仍有改进的空间。而如今钬激光前列腺剜除术(HoLEP) [2]和铥激光剜除术(ThuLEP) [3]能够实现更精确的组织切割，术后尿失禁率进一步降至 1%~3%。术中超声引导和神经监测系统(如 NeuroVision®)的应用也能减少括约肌误伤风险。与此同时，研究者开始整合功能、手术参数等，术后 UI 的预测主要依赖于临床经验和统计学模型。常用的方法包括逻辑回归(Logistic Regression)、多元线性回归(Multiple Linear Regression)和 Cox 比例风险模型等。这些方法通常基于有限的临床变量(如年龄、前列腺体积、尿流率等)来构建预测模型。尽管操作简单，但其局限性显著，例如变量选择依赖人工经验，传统模型需手动筛选变量，可能遗漏潜在的重要预测因子(如影像学特征或基因标记)；非线性关系难以捕捉；临床数据中变量与 UI 风险的关系可能呈现非线性或交互作用，传统模型难以准确建模等。而且存在数据稀少、统计不完整、来源单一的限制，无法很好地捕捉有效特征，从而影响预测的准确率。随着机器学习的出现和发展，基于机器学习的算法已成为目前预测前列腺增生术后早期生化复发最适合的方法之一。

因此，本文致力于解决传统逻辑回归算法可解释性不足、预测效果不好等问题，使用多种机器学习的方法对前列腺增生术后尿失禁进行预测，并提出新模型 S-KFG 和堆叠模型 Hancerforest 来进行预测，以寻求更好的预测效果。其中，S-KFG 是由梯度提升树、随机森林、KNN 结合而成的软投票分类器集成模型；Hancerforest 模型是由 5 个不同配置的随机森林模型($n_{estimators}$ 从 100 到 500 递增)组成，通过参数差异引入多样性；元模型使用逻辑回归模型，负责融合基模型的输出概率进行最终预测。并且在特征选择时，先使用皮尔逊相关性分析，选取相关性值大于等于 0.10 的特征纳入单因素分析，再将单因素分析中具有统计学意义的特征($P < 0.05$)选取为参与预测的特征，以此来保证特征选择的合理性和可解释性；最后的预测结果表明，本文两种新模型比传统的逻辑回归、单独的随机森林、梯度提升树的预测效果要更好。

3. 材料和数据集

3.1. 数据集

Variables	β	S.E	Z	P	OR (95%CI)
术前脑部病史(1有 2无)					
0					1.00 (Reference)
1	-1.12	0.54	-2.07	0.038	0.33 (0.11 ~ 0.94)
酗酒史(1: 无)2: 有)					
0					1.00 (Reference)
1	1.11	0.60	1.86	0.064	3.02 (0.94 ~ 9.73)
手术方式(1等离子剜除/2激光剜除/3机器人剜除)					
0					1.00 (Reference)
0.5	-1.28	0.55	-2.31	0.021	0.28 (0.09 ~ 0.82)
1	-0.33	1.42	-0.23	0.819	0.72 (0.04 ~ 11.78)
前侧B厚度	-2.14	1.22	-1.75	0.081	0.12 (0.01 ~ 1.30)
中骨盆面积	2.71	1.31	2.07	0.039	15.02 (1.15 ~ 196.51)
移行带左右径	-1.83	1.30	-1.40	0.160	0.16 (0.01 ~ 2.06)
移行带前后径	-1.91	0.94	-2.03	0.042	0.15 (0.02 ~ 0.94)
最大尿流率	-1.86	1.31	-1.42	0.155	0.16 (0.01 ~ 2.02)
对角径	1.80	1.06	1.70	0.090	6.08 (0.75 ~ 48.95)
中骨盆前后径	1.66	0.93	1.77	0.076	5.25 (0.84 ~ 32.77)
右侧TP	1.48	0.96	1.54	0.124	4.38 (0.67 ~ 28.78)
膜部尿道长度	1.86	0.90	2.07	0.039	6.42 (1.10 ~ 37.52)
左侧B厚度	-4.05	1.28	-3.17	0.002	0.02 (0.00 ~ 0.21)

OR: Odds Ratio, CI: Confidence Interval

Figure 1. Univariate analysis
图 1. 单因素分析

Variables	Total (n = 157)
左侧 B 厚度(mm), Mean $\pm$ SD	6.89 $\pm$ 2.22
膜部尿道长度 (mm) , Mean $\pm$ SD	13.84 $\pm$ 4.23
移行带前后径(mm), Mean $\pm$ SD	36.67 $\pm$ 10.40
中骨盆面积 (mm ²) , Mean $\pm$ SD	9152.09 $\pm$ 1074.28
手术方式(1 等离子剝除/2 激光剝除/3 机器人剝除), n(%)	
1	137 (87.26)
2	18 (11.46)
3	2 (1.27)
术前脑部病史(1 有 2 无), n(%)	
1	21 (13.38)
2	136 (86.62)
尿失禁 (0 是 1 否) , n(%)	
0	71 (45.22)
1	86 (54.78)

SD: standard deviation

Figure 2. Statistical characteristics of the data**图 2.** 数据统计学特征

数据集来源于大连医科大学附属第二医院近些年来收集的患者数据。针对这些数据，本研究先是通过皮尔逊相关性分析，选取与前列腺术后尿失禁相关性较高(相关性值大于等于 0.10)的前十五个特征，如膜部尿道长度、手术方式、术前是否有脑部病史等，再对这些特征进行单因素分析，将在统计学上意义显著的特征纳入分析($P < 0.05$)，分析结果如图 1 所示，单因素分析出来的特征信息如图 2。并对原有数据通过生成对抗网络进行数据增强。

3.2. 生成对抗网络

对于前列腺增生术后尿失禁研究中常见的数据缺乏、质量不高的问题，本文使用生成对抗网络来进行数据增强，从而进一步扩充数据，以保证数据样本的充足。在使用生成对抗网络进行数据增强时，对模型中的参数均采用默认参数，将 epochs 设置为 30000 进行训练，从而生成可靠的数据。

3.2.1. GAN 的基本组成

GAN 包含两个核心组件：

生成器(Generator, G): 输入为随机噪声向量 z (通常从均匀分布或正态分布采样)，输出为合成数据 $G(z)$ 。其目标是生成与真实数据 x 难以区分的样本。

判别器(Discriminator, D): 输入为真实数据 x 或生成数据 $G(z)$ ，输出一个标量概率值 $D(\cdot) \in [0,1]$ ，表示输入数据来自真实分布的概率。其目标是正确区分真实数据与生成数据。

3.2.2. 对抗训练的数学原理

GAN 的训练过程是一个极小化极大博弈(Minimax Game)，目标函数如下：

$$\min_G \max_D V(D, G) = E_{x \sim P_{data}(x)} [\log D(x)] + E_{z \sim P_z(z)} [\log (1 - D(G(z)))] \quad (1)$$

判别器的目标：最大化 $V(D, G)$ ，即同时提升对真实数据的判别能力(最大化 $\log D(x)$)和生成数据的识别能力(最大化 $\log (1 - D(G(z)))$)。

生成器的目标：最小化 $V(D, G)$ ，即让生成数据尽可能被判别器误判为真实(最小化 $\log (1 - D(G(z)))$)。

3.2.3. 损失函数的具体形式

判别器的损失函数：

$$L_D = -E_{x \sim p_{data}} [\log D(x)] - E_{z \sim p_z} [\log (1 - D(G(z)))] \quad (2)$$

通过梯度上升更新判别器参数，最大化真实数据的得分并最小化生成数据的得分。

生成器的损失函数原始形式：

$$L_G = E_{z \sim p_z} [\log (1 - D(G(z)))] \quad (3)$$

实际训练中，由于梯度消失问题，常改用以下形式： $L_G = -E_{z \sim p_z} [\log D(G(z))]$ 。

通过梯度下降更新生成器参数，直接最大化生成数据被判别器判为真实的概率。

3.2.4. 训练过程

- 1) 固定生成器，更新判别器：对判别器进行 k 次(通常 $k=1$)梯度上升，使其更好地区分真实与生成数据。
- 2) 固定判别器，更新生成器：对生成器进行梯度下降，使其生成的样本更接近真实数据分布。
- 3) 交替迭代，直至达到纳什均衡(判别器无法区分真实与生成数据，即 $D(G(z))=0.5$)。

3.3. 软投票分类器

3.3.1. 模型设计

本文首先构建由梯度提升树(GBDT)、随机森林和 K 近邻(KNN)组成的软投票集成模型 S-KFG，通过概率融合来进行预测，并以此来提升预测性能。反复进行超参数的调整和尝试(如将梯度提升树分别设置为 100、150、200、250、300，学习率分别设为 0.01、0.015、0.02，最大深度分别设为 2、3、4、5)，最后将梯度提升树模型设置为 200 棵树、学习率设为 0.02、最大深度设为 2；再对 K 近邻模型进行设置，使用默认参数($k=5$ ，尝试设置为 2、3、4、5)，接着调整随机森林模型，设置为 200 棵树(分别尝试设置为 100、150、200、250、300)，在其他使用默认参数时，本文的模型在最后取得了最佳的预测效果。对于数据集执行数据划分(70%训练集/30%测试集)、模型训练及评估。评估指标涵盖准确率、AUC-ROC (衡量分类器整体性能)、马修斯相关系数(MCC)、F1 分数和敏感度(召回率)。

3.3.2. 核心步骤和数学公式

软投票分类器其核心思想是利用各个基分类器对样本属于不同类别的概率估计，进行加权平均后选择概率最高的类别作为最终预测结果。

假设有 M 个(本文中为三个)基分类器，每个分类器对输入样本 x 预测其属于类别 k 的概率为 $P_i(y=k|x)$ ，其中 $i=1,2,\dots,M$ 。对于本文中的二分类问题，每个基分类器输出两个概率值： $P_i(y=0|x)$ 和 $P_i(y=1|x)$ ，满足 $P_i(y=0|x) + P_i(y=1|x) = 1$ 。

软投票分类器对每个类别 k 的概率进行加权平均。假设基分类器的权重为 w_i (满足 $\sum_{i=1}^M w_i = 1$ 且 $w_i \geq 0$)，则集成后的概率为： $P_{\text{ensemble}}(y=k|x) = \sum_{i=1}^M w_i \cdot P_i(y=k|x)$ 。最后选择具有最高集成概率的类别作为最终预测概率： $y_{\text{pred}} = \arg \max_k (P_{\text{ensemble}}(y=k|x))$ 。

3.4. 堆叠集成模型

3.4.1. 模型设计

本文的第一种堆叠模型 Hancerforest 的基模型使用了 5 个不同配置的随机森林模型($n_estimators$ 从 100 到 500 递增，随机种子数从 1~5 递增，其余均为默认参数，这时模型取得了最佳效果)，通过参数差异引入多样性；元模型使用逻辑回归模型，负责融合基模型的输出概率进行最终预测，然后使用 StackingCVClassifier 实现交叉验证堆叠，5 折交叉验证生成元特征，避免数据泄漏和过拟合。另外一种堆

叠模型 HancerKNN 是基模型为 5 个不同参数($n_neighbors$ 从 2~6 递增, p 值均设为 1, 此时模型效果最好)的 KNN 分类器, 元模型为使用 L2 正则化的多分类逻辑回归。同时也使用 10 折交叉验证生成元特征, 使用基模型的预测概率作为元特征, 并设置随机种子确保可复现; 读取数据, 分离特征和目标变量, 划分 70% 训练集和 30% 测试集。训练堆叠模型并进行预测。

3.4.2. 核心步骤

基学习器的训练与预测生成:

输入数据: 训练集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, 其中 x_i 为特征, y_i 为标签;

基学习器: 选择个 M 个不同的基模型 $\{h_1, h_2, \dots, h_M\}$ (如随机森林、KNN);

生成元特征: 为避免数据泄露, 通常通过 K 折交叉验证(K-Fold CV)生成基学习器的预测结果:

1) 将训练集 D 划分为 K 个子集 $D_1, D_2, \dots, D_K$ 。

2) 对每个基学习器 h_m : 1) 对于第 k 折: 用 $D \setminus D_k$ 训练 h_m , 在 D_k 上预测结果 $\hat{y}_m^{(k)}$ 。2) 合并所有折的预测结果, 得到 h_m 在整个训练集上的元特征向量 $Z_m = [\hat{y}_m^{(1)}, \hat{y}_m^{(2)}, \dots, \hat{y}_m^{(n)}]$ 。

3.4.3. 构建元训练集

元特征矩阵: 将所有基学习器的预测结果拼接为矩阵 $Z \in \mathbb{R}^{n \times M}$, 其中每行对应一个样本的 M 个基模型预测值。

可选增强: 可将原始特征 X 与 Z 合并, 形成增强的元特征矩阵 $Z' = [X \| Z] \in \mathbb{R}^{n \times (d+M)}$, 但需注意防止过拟合。

元标签: 使用原始标签 $Y = [y_1, y_2, \dots, y_n]$ 。

3.4.4. 元学习器训练

使用元训练集 (Z, Y) 或 (Z', Y) 训练元模型 g , 学习从基模型预测到最终标签的映射关系: $g: Z \rightarrow Y$ 或 $g: Z' \rightarrow Y$ 。

元学习器可以是任意监督模型(如线性回归、梯度提升树等)。

3.4.5. 最终预测

对新样本 x_{new} :

基学习器生成预测:

$$\{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_M\} = \{h_1(x_{\text{new}}), h_2(x_{\text{new}}), \dots, h_M(x_{\text{new}})\} \quad (4)$$

元学习器整合预测: $\hat{y}_{\text{final}} = g([\hat{y}_1, \hat{y}_2, \dots, \hat{y}_M])$ 或 $\hat{y}_{\text{final}} = g([x_{\text{new}} \| \hat{y}_1, \hat{y}_2, \dots, \hat{y}_M])$ 。

4. 结果与讨论

4.1. 评价指标

在本文中采用了以下几个评价指标来评估模型, 如 AUC 值、F1 分数、马修斯相关系数(MCC)和灵敏度(Sen)。这些评价指标的公式如下:

ACC (准确率): 用于衡量模型整体预测正确的比例, 公式如下:

$$\text{ACC} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

AUC: ROC 曲线下面积, 反映模型对正负样本的区分能力。ROC 曲线以真阳率(TPR)为纵轴, 假阳率(FPR)为横轴。

$$TPR = \frac{TP}{TP + FN}, FPR = \frac{FP}{FP + TN}$$

MCC(马修斯相关系数):

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

F1 分数: 精确率(Precision)和召回率(Recall)的调和平均数, 公式如下:

$$F1 = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}, \text{ 其中 } \begin{cases} Precision = \frac{TP}{TP + FP} \\ Recall = \frac{TP}{TP + FN} \end{cases}$$

Sen (灵敏度):

$$Sen = \frac{TP}{TP + FN}$$

其中 TP 为真阳性, FP 为假阳性, TN 为真阴性, FN 为假阴性。

4.2. 结果

本文将设计的模型与传统的逻辑回归算法以及常用的随机森林算法进行比较, 可以发现本文的模型 S-KFG 在 ACC 值(0.833)、AUC 值(0.888)、F1 分数(0.860)、MCC 值(0.663)、Sen (0.915)都比传统的逻辑回归要更好, 与单一的机器学习算法相比, S-KFG 虽然 Sen 值略低于随机森林, 但是其他的评价指标值均优于随机森林, 各项评价指标均优于梯度提升树算法。另外本文设计的 Hancerforest 模型也取得了优于传统方法的效果, ACC 值(0.833)、AUC 值(0.872)、F1 分数(0.857)、MCC 值(0.661)、Sen (0.894), 同样的远超传统逻辑回归的预测效果, 也只在 Sen 值上略低于随机森林, 其他的评价值也均高于随机森林, 因此可以得出, 本文设计的模型取得了更好的预测效果。模型预测结果见表 1, 各模型 ROC 曲线图见图 3。

另外本文对选取的各特征在模型上进行了消融实验, 从表 2、表 3 可以看出, 在使用了选取的所有特征时模型效果最好, 这也说明了本文特征选取的有效性。从表中结果可以看出, 左侧 B 厚度、膜部尿道长度、移行带前后径和中骨盆面积对模型效果的影响较为突出, 手术方式 1、手术方式 2 和脑部病史虽然对模型效果影响不如前面四个突出, 但也可以说明对模型最后预测效果的贡献。特征有效性分析的 ROC 曲线图如图 4 所示。

Table 1. The effect of each model on the dataset
表 1. 各个模型在数据集上的效果

	ACC	AUC	F1 Score	MCC	Sen
S-KFG	0.833	0.888	0.860	0.663	0.915
梯度提升树	0.826	0.822	0.839	0.619	0.902
随机森林	0.808	0.869	0.848	0.628	0.936
HancerKNN	0.821	0.783	0.811	0.539	0.872
Hancerforest	0.833	0.872	0.857	0.661	0.894
逻辑回归	0.723	0.822	0.747	0.450	0.723




Figure 3. ROC plot of the model

图 3. 模型的 ROC 曲线图




Figure 4. Feature effectiveness analysis

图 4. 特征有效性分析

Table 2. The feature validity was verified on the S-KFL model
表 2. 在 S-KFG 模型上验证特征有效性

	ACC	AUC	F1 Score	MCC	Sen
S-KFG	0.833	0.912	0.86	0.663	0.915
-左侧 B 厚度	0.714	0.726	0.76	0.415	0.809
-膜部尿道长度	0.773	0.856	0.791	0.546	0.766
-移行带前后径	0.762	0.757	0.804	0.516	0.872
-中骨盆面积	0.786	0.839	0.819	0.564	0.872
-手术方式 1	0.831	0.895	0.859	0.661	0.913
-手术方式 2	0.821	0.899	0.851	0.639	0.914
-脑部病史	0.821	0.908	0.851	0.640	0.915

其中“-”代表没有该特征，手术方式 1 是等离子剝除，手术方式 2 是激光剝除。

Table 3. The feature validity was verified on the Hancerforest model
表 3. 在 Hancerforest 模型上验证特征有效性

	ACC	AUC	F1 Score	MCC	Sen
Hancerforest	0.833	0.866	0.857	0.661	0.894
-左侧 B 厚度	0.714	0.770	0.755	0.416	0.787
-膜部尿道长度	0.726	0.812	0.753	0.446	0.745
-移行带前后径	0.726	0.800	0.851	0.441	0.851
-中骨盆面积	0.750	0.805	0.788	0.489	0.83
-手术方式 1	0.821	0.864	0.848	0.637	0.893
-手术方式 2	0.809	0.865	0.836	0.612	0.872
-脑部病史	0.821	0.864	0.848	0.637	0.894

其中“-”代表没有该特征，手术方式 1 是等离子剝除，手术方式 2 是激光剝除。

4.3. 讨论

本文通过设计了一个由 KNN、随机森林、梯度提升树组合而成的软投票分类器集成模型和一个由 5 个不同配置构成的随机森林模型，以及元模型为逻辑回归的堆叠模型来在大连医科大学附属泌尿外科的前列腺增生患者数据集上进行预测，其预测效果优于传统的逻辑回归和单一的机器学习算法：随机森林和梯度提升树。对于传统逻辑回归本身作为预测模型的缺点，如无法捕捉复杂模式、分类效果差、泛化性能一般以及系数难以解释等，本文提出的集成模型对此有着更好的处理，也具有更好的预测能力和泛化能力。对比于单一的机器学习算法，S-KFG 和 Hancerforest 也有更好的预测性能以及对数据集更好的处理能力。

另外本文所使用的特征符合医学上的研究意义，如左侧 B 厚度通常指经直肠超声(TRUS)或磁共振成像(MRI)测量的前列腺尖部或尿道周围组织的厚度。较厚的组织可能提供更好的尿道支撑，降低术中神经血管束损伤风险，而较薄的组织可能导致术后尿道闭合功能减弱，前列腺尖部解剖结构(包括左侧 B 厚度)是早期尿控恢复的关键预测因素[4]；术前膜部尿道长度(Membranous Urethral Length, MUL)是术后尿控的

主要预测因子之一[5]。保留更长的膜部尿道可维持括约肌功能和神经支配[6]；移行带增生可能导致前列腺体积增大，增加手术难度和尿道括约肌损伤风险[7]，体积较大的移行带可能挤压尿道，术中需更广泛的切除，影响括约肌功能。而骨盆狭窄可能限制手术视野，增加术中操作难度，导致盆底肌群或神经损伤[8]。从生物力学角度解释，骨盆解剖影响手术路径选择和功能保留。另外神经系统疾病可能破坏膀胱-括约肌协调性，导致神经源性尿失禁，术前已存在的神经损伤可能加剧术后括约肌功能障碍。其中技术优势(3D 视野、机械臂灵活性)也有利于减少组织创伤，降低尿失禁风险[9]。总的来说，解剖因素(MUL、B 厚度、骨盆面积)直接影响尿道支撑和手术难度，是核心预测变量；手术技术通过减少创伤改善预后；患者特征(脑部病史)反应神经功能基线状态，需要术前进行评估。

5. 结语

综上所述，本文不论是在模型的预测效果上还是在模型的可解释性方面，都要优于传统的逻辑回归算法和单一的机器学习算法，在特征的选取上也同样符合医学和统计学的意义。本文设计的模型为预测前列腺增生患者术后尿失禁提供了更强有力的预测工具，能够更好地帮助医生诊断病情并为患者提供更精准更优质的服务。除此之外，未来的研究方向应努力于精准解剖和分子靶点，结合单细胞测序技术解析括约肌损伤后的分子修复机制；并考虑对患者进行分层治疗，基于基因组学预测 UI 风险并制定个体化方案。要结合影像组学、基因组学[10][11]和临床参数进行预测，提升模型的泛化能力，也应该多中心合作，制定统一的影像采集协议和 UI 定义，推动数据共享。将患者的数据纳入电子健康记录和患者结局报告，从而增强模型的现实适用性。未来需通过多学科协作、技术创新和真实世界数据验证，达到更加精准的预测、更加有针对性的治疗，最终实现“零尿失禁”的理想目标。

参考文献

- [1] Sataa, S. (2017) Predictive Factors of Urinary Incontinence after Radical Prostatectomy: Systematic Review. *La Tunisie Medicale*, **95**, 229-235.
- [2] Ficarra, V. and Cavalleri, S. (2007) Editorial Comment On: Holmium Laser Enucleation versus Transurethral Resection of the Prostate: 3-Year Follow-Up Results of a Randomized Clinical Trial. *European Urology*, **52**, 1464. <https://doi.org/10.1016/j.eururo.2007.04.055>
- [3] 封志强, 郑玲, 林盛强, 等. 经尿道钬激光前列腺剜除术治疗良性前列腺增生的临床疗效分析[J]. 中国医疗器械信息, 2024, 30(19): 153-155.
- [4] Iacovelli, V., Carilli, M., Sandri, M., Forte, V., Cipriani, C., Bertolo, R., *et al.* (2022) The Role of Preoperative Prostatic Shape in the Recovery of Urinary Continence after Robotic Radical Prostatectomy: A Single Cohort Analysis. *Prostate Cancer and Prostatic Diseases*, **26**, 374-378. <https://doi.org/10.1038/s41391-022-00563-0>
- [5] Matsushita, K., Kent, M.T., Vickers, A.J., von Bodman, C., Bernstein, M., Touijer, K.A., *et al.* (2015) Preoperative Predictive Model of Recovery of Urinary Continence after Radical Prostatectomy. *BJU International*, **116**, 577-583. <https://doi.org/10.1111/bju.13087>
- [6] Negrean, C., Alam, A., Hickling, D., Vigil, H.R., Lavallée, L.T., Mallick, R., *et al.* (2025) Preoperative Magnetic Resonance Imaging Membranous Urethral Length as a Predictor of Urinary Continence after Radical Prostatectomy: A Systematic Review and Meta-Analysis. *European Urology Focus*. <https://doi.org/10.1016/j.euf.2025.02.002>
- [7] Pietro, C., Simone, F., Giulio, L., *et al.* (2023) Management of Urinary Incontinence Following Radical Prostatectomy: Challenges and Solutions. *Therapeutics and Clinical Risk Management*, **19**, 43-56.
- [8] Large, T., Borofsky, M.S. and Lingeman, J.E. (2016) Re: Photoselective Vaporization of the Prostate for Benign Prostatic Hyperplasia Using the 180 Watt System: Multicenter Study of the Impact of Prostate Size on Safety and Outcomes and Re: Greenlight™ Laser (XPS) Photoselective Vapo-Enucleation versus Holmium Laser Enucleation of the Prostate for the Treatment of Symptomatic Benign Prostatic Hyperplasia: A Randomized Controlled Study. *Journal of Urology*, **195**, 228-231. <https://doi.org/10.1016/j.juro.2015.07.107>
- [9] Froehner, M. and Wirth, M.P. (2013) Re: Vincenzo Ficarra, Giacomo Novara, Raymond C. Rosen, *et al.* Systematic Review and Meta-Analysis of Studies Reporting Urinary Continence Recovery after Robot-Assisted Radical Prostatectomy.

- Eur Urol 2012;62:405-17. *European Urology*, **63**, e38. <https://doi.org/10.1016/j.eururo.2012.11.037>
- [10] Thakur, M., Tomar, V.S., Dale, E., Gomella, L.G., Solomides, C., Kolesnikov, O., *et al.* (2024) Targeting Genomic Receptors in Voided Urine for Confirmation of Benign Prostatic Hyperplasia. *BJUI Compass*, **5**, 789-794. <https://doi.org/10.1002/bco2.362>
- [11] Makedon, A.M., Sempson, S.X., Hargis, P. and Lloyd, G.L. (2023) Genetic, Genomic, and Heritable Components of Benign Prostatic Hyperplasia. *Current Bladder Dysfunction Reports*, **18**, 154-164. <https://doi.org/10.1007/s11884-023-00697-4>