Variabilidade da Pressão Arterial Pós-Operatória e Lesão Renal Aguda após Cirurgia de Revascularização do Miocárdio: Um Estudo MIMIC-IV

Postoperative Blood Pressure Variability and Acute Kidney Injury after CABG: A MIMIC-IV Study

Ling-Song Yao,[1] Yu-Chen Dai,[2,3] Qing-Ren Liu,[4] Jie Sun,[5] Yunfei Bai[6]

Southeast University – School of Biological Science and Medical Engineering,[1] Nanjing – China
Nanjing Stomatological Hospital – Department of Anesthesiology,[2] Nanjing – China
Nanjing University – Institute of Stomatology,[3] Nanjing – China
Xishan People's Hospital of Wuxi City – Department of Anesthesiology,[4] Wuxi – China
Southeast University – Department of Anesthesiology,[5] Nanjing – China
Southeast University – School of Biological Science and Medical Engineering,[6] Nanjing – China

Resumo

Fundamento: A variabilidade da pressão arterial (VPA) emergiu como um importante fator hemodinâmico associado a desfechos adversos após cirurgia cardíaca, incluindo lesão renal aguda (LRA). No entanto, o valor prognóstico da VPA pós-operatória em pacientes submetidos a cirurgia de revascularização do miocárdio (CRM) permanece insuficientemente caracterizado.

Objetivo: Investigar a associação entre a VPA pós-operatória e a LRA após CRM e avaliar o valor preditivo da VPA pós-operatória precoce para LRA.

Métodos: Realizamos um estudo de coorte retrospectivo utilizando dados de 5.070 pacientes adultos submetidos a CRM no banco de dados *Medical Information Mart for Intensive Care IV* (MIMIC-IV). A variabilidade da pressão arterial sistólica, da pressão arterial diastólica e da pressão arterial média durante as primeiras 24 horas após a admissão na UTI foi quantificada utilizando a variabilidade real média, a variação sucessiva, o desvio padrão e o coeficiente de variação. Modelos de regressão logística multivariável e de aprendizado de máquina, incluindo XGBoost, regressão logística, máquina de vetores de suporte, floresta aleatória e K-vizinhos mais próximos, foram desenvolvidos para predizer LRA pós-operatória. Todos os testes estatísticos foram bicaudais e um valor de $p < 0,05$ foi considerado estatisticamente significativo.

Resultados: Após ajuste para fatores de confusão relevantes, o aumento da VPA e a hipotensão cumulativa foram associados independentemente à LRA. Uma VPA mais elevada foi significativamente associada à LRA (OR, 1,005; IC 95%, 1,002–1,008), assim como uma maior carga hipotensiva definida pela área sob a curva da pressão arterial média < 65 mmHg (OR, 1,307; IC 95%, 1,220–1,400). Dentre todos os modelos, o XGBoost demonstrou o melhor desempenho preditivo.

Conclusão: A VPA nas primeiras 24 horas pós-operatórias é um preditor significativo de LRA após CRM. A integração da VPA em modelos preditivos pode melhorar a estratificação precoce de risco e auxiliar na tomada de decisões clínicas.

Palavras-chave: Revascularização Miocárdica; Injúria Renal Aguda; Aprendizado de Máquina; Modelos Preditivos de Aprendizagem.

Abstract

Background: *Blood pressure variability (BPV) has emerged as an important hemodynamic factor associated with adverse outcomes after cardiac surgery, including acute kidney injury (AKI). However, the prognostic value of postoperative BPV in patients undergoing coronary artery bypass grafting (CABG) remains insufficiently characterized.*

Objective: *To investigate the association between postoperative BPV and AKI after CABG and to evaluate the predictive value of early postoperative BPV for AKI.*

Methods: *We conducted a retrospective cohort study using data from 5,070 adult patients who underwent CABG in the Medical Information Mart for Intensive Care IV (MIMIC-IV) database. Systolic blood pressure (SBP), diastolic blood pressure (DBP), and mean arterial pressure (MAP)*

Correspondência: Yunfei Bai •
Southeast University – School of Biological Science and Medical Engineering – NO.2 Sipailou Nanjing, 210096 – China
E-mail: whitecf@seu.edu.cn
Artigo recebido em 27/03/2026, revisado em 26/06/2026, aceito em 29/07/2026
Editor responsável pela revisão: João Carlos Leal

DOI: https://doi.org/10.36660/abc.20260177

variability during the first 24 hours after ICU admission were quantified using average real variability (ARV), successive variation (SV), standard deviation (SD), and coefficient of variation (CV). Multivariable logistic regression and machine learning models, including XGBoost, logistic regression, support vector machine, random forest, and K-nearest neighbor, were developed to predict postoperative AKI. All statistical tests were two-sided, and a P value < 0.05 was considered statistically significant.

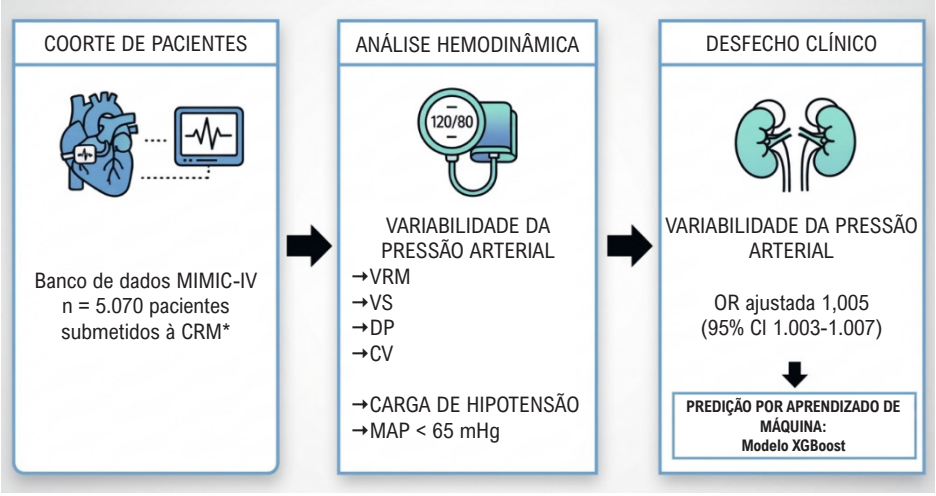
Results: *After adjustment for relevant confounders, increased BPV and cumulative hypotension were independently associated with AKI. Higher BPV was significantly associated with AKI (OR, 1.005; 95% CI, 1.002–1.008), as was greater hypotension burden defined by area under MAP <65 mmHg (OR, 1.307; 95% CI, 1.220–1.400). Among all models, XGBoost demonstrated the best predictive performance.*

Conclusion: *Postoperative BPV within the first 24 hours is a significant predictor of AKI after CABG. Integrating BPV into predictive models may improve early risk stratification and support clinical decision-making.*

Keywords: *Myocardial Revascularization; Acute Kidney Injury; Machine Learning; Predictive Learning Models.*

Full texts in English - https://abccardiol.org/en/

Figura Central: Variabilidade da Pressão Arterial Pós-Operatória e Lesão Renal Aguda após Cirurgia de Revascularização do Miocárdio: Um Estudo MIMIC-IV



Arq Bras Cardiol. 2026; 123(10):e20260177

Introdução

A lesão renal aguda (LRA) é uma complicação comum e grave após grandes cirurgias, particularmente em pacientes submetidos a cirurgia de revascularização do miocárdio (CRM). A incidência de LRA após CRM varia de 10% a 30%.,[1] com sérias consequências, incluindo internações hospitalares prolongadas, aumento da morbidade e maiores taxas de mortalidade.[2] Um dos principais fatores que influenciam a LRA nessa população é a instabilidade hemodinâmica, particularmente as flutuações da pressão arterial (PA), que são comumente observadas durante e após a cirurgia.[3,4]

A variabilidade da pressão arterial (VPA) se refere às flutuações da PA ao longo do tempo e é um importante indicador de instabilidade hemodinâmica. Estudos recentes têm destacado o papel potencial da VPA na predição de desfechos pós-operatórios adversos, incluindo LRA, uma vez que reflete a capacidade do sistema cardiovascular de manter a perfusão estável durante o estresse.[5,6] A VPA é frequentemente quantificada usando diversas métricas, como o desvio padrão (DP), o coeficiente de variação (CV) e a variabilidade real média (VRM), cada uma fornecendo informações únicas sobre os padrões e a extensão das flutuações da PA.[7,8] No entanto, a relação entre a VPA e a LRA no contexto da CRM permanece pouco compreendida, o que exige mais pesquisas sobre como a VPA afeta os resultados renais nesses pacientes.

A fisiopatologia da LRA após CRM é multifatorial, envolvendo lesão de isquemia-reperfusão, distúrbios microcirculatórios e hipoperfusão renal.[9,10] Alterações na homeostase da PA, particularmente hipotensão e grandes flutuações na PA, podem levar à perfusão renal comprometida e exacerbar a lesão renal.[11] Diversos estudos demonstraram uma correlação entre períodos de hipotensão, particularmente da pressão arterial sistólica (PAS) e da pressão arterial média (PAM) abaixo de

determinados limiares, e o desenvolvimento de LRA.[12,13] A VPA pode agravar ainda mais o risco, impedindo que os rins mantenham uma pressão de perfusão adequada, resultando em hipóxia renal e lesão isquêmica.[14]

Considerando essas preocupações, este estudo visa investigar a associação entre a VPA e a incidência de LRA em pacientes submetidos à CRM. Ao focar na VPA pós-operatória nas primeiras 24 horas, buscamos esclarecer se a VPA é um preditor independente de LRA nessa população de alto risco. Além disso, exploramos a utilidade de modelos de aprendizado de máquina na predição de LRA com base na VPA, o que pode fornecer ferramentas valiosas para a identificação precoce e intervenções direcionadas para mitigar a lesão renal nesse contexto.[15,16]

Os resultados deste estudo podem contribuir para uma compreensão mais profunda dos fatores hemodinâmicos envolvidos na LRA após CRM e podem orientar estratégias para o controle da PA, visando reduzir o risco de LRA. Além disso, ao incorporar técnicas preditivas avançadas, como aprendizado de máquina, esta pesquisa pode abrir caminho para um manejo mais personalizado e eficaz de pacientes de alto risco no período pós-operatório.

Materiais e métodos

Fonte de dados e população do estudo

Os dados foram obtidos do banco de dados Medical Information Mart for Intensive Care IV versão 1.0 (MIMIC-IV v1.0),[17] que é um banco de dados de cuidados intensivos multiparamétrico com informações sobre pacientes em estado crítico no Beth Israel Deaconess Medical Center (Boston, MA, EUA) de 2001 a 2012. Nosso direito de acesso ao banco de dados foi aprovado após a conclusão do curso de treinamento online dos National Institutes of Health (NIH) (ID do registro 45636271).

Pacientes submetidos a CRM com base na nona ou décima revisão da Classificação Internacional de Doenças (CID-9/10).[18] Foram selecionados e incluídos neste estudo. A LRA foi definida de acordo com os critérios da KDIGO (*Kidney Disease: Improving Global Outcomes)* como um aumento na creatinina sérica de ≥0,3 mg/dL (≥26,5 μmol/L) em 48 horas ou um aumento para ≥1,5 vezes o valor basal em sete dias.[19] A creatinina basal foi definida como a medição pré-operatória mais recente antes da cirurgia. Apenas a primeira admissão na UTI foi incluída neste estudo. Pacientes que permaneceram menos de 48 horas na UTI foram excluídos. Pacientes com doença renal em estágio terminal e que desenvolveram LRA antes da cirurgia também foram excluídos deste estudo.

Neste estudo, coletamos dados de uma série consecutiva de 11.326 pacientes submetidos à CRM entre 2001 e 2012 no banco de dados MIMIC-IV. Os critérios de exclusão foram os seguintes: (1) registros de aferição da PA ausentes (n = 274); (2) óbito nas primeiras 24 horas de internação na UTI pós-operatória (n = 6); (3) tempo de internação na UTI inferior a 24 horas (n = 188); (4) PA aferida menos de 10 vezes nas primeiras 24 horas de internação na UTI pós-operatória (n = 28); e (5) pacientes com aferições de PA anormais (mais de 1.000 vezes) (n = 2). Ao final, um total de 5.070 pacientes foram incluídos na população do estudo (Figura 1).

Foram selecionados aleatoriamente 3.396 pacientes para constituir o conjunto de treinamento, incluindo 824 pacientes com LRA e 2.572 pacientes sem LRA. Os 1.674 pacientes restantes constituem o conjunto de teste, que contém 405 pacientes com LRA e 1.296 pacientes sem LRA.

Extração de características

Para melhor distinguir pacientes com LRA de pacientes sem LRA, extraímos 106 características, incluindo (1) dados demográficos: idade, sexo, altura, peso, índice de massa corporal (IMC), tipo de admissão, local de alta, idioma, estado civil e etnia; (2) comorbidades, incluindo infarto do miocárdio (IM), insuficiência cardíaca congestiva, doença vascular periférica, doença cerebrovascular, demência, doença pulmonar obstrutiva crônica, doença reumática, úlcera péptica, doença hepática leve, diabetes mellitus com ou sem complicação, paraplegia, doença renal, câncer maligno, doença hepática grave, tumor sólido metastático, síndrome da imunodeficiência adquirida (AIDS) e o Índice de Comorbidade de Charlson (CCI) calculado; (3) escores de terapia intensiva: APS III (*Acute Physiology Score III)*, OASIS (*Oxford acute severity of illness score)*, SAPS II (*Simplified Acute Physiology Score II)* e SOFA (*Sequential Organ Failure Assessment)*; (4) sinais vitais após a admissão na UTI nas primeiras 24 horas: PAS, pressão arterial diastólica (PAD), PAM, frequência cardíaca (FC), frequência respiratória (FR) e saturação percutânea de oxigênio (SpO_2); (5) uso de agentes vasoativos, incluindo dobutamina, dopamina, epinefrina, norepinefrina, fenilefrina e vasopressina; (6) dados laboratoriais médios: hematócrito, hemoglobina, plaquetas, leucócitos (WBC), ânion gap, bicarbonato, ureia, cálcio, cloreto, creatinina, glicose, sódio, potássio, basófilos, eosinófilos, linfócitos, monócitos, neutrófilos, fibrinogênio, razão normalizada internacional (RNI), tempo de protrombina (TP), tempo de tromboplastina parcial (TTP); e (7) terapia de substituição renal contínua (TSRC), tempo de internação hospitalar, tempo de internação na UTI e mortalidade hospitalar.

Calculamos a VPA para avaliar a PAM, PAS e PAD nas primeiras 24 horas de internação na UTI. A VPA foi avaliada utilizando os seguintes parâmetros: VRM,[20] variação sucessiva (VS),[21] desvio padrão (DP)[22] e CV[23] Essas medidas foram definidas da seguinte forma:

$$VRM = \left(\frac{1}{n-1}\right)\sum_{(i=1)}^{(n-1)}|PA_{i+1} - PA_I|,$$

$$VS = \sqrt{(1/(n-1))\sum_{(i=1)}^{(n-1)}(PA_{i+1} - PA_i)^2}$$

$$DP = \sqrt{\left(\frac{1}{n-1}\right)\sum_{(i=1)}^{(n)}(PA_i - PA_{mean})^2}$$

$$CV = \left(\frac{DP}{PA_{mean}}\right) * 100$$

A existência de hipotensão foi definida como PAS inferior a 100 mmHg e PAM inferior a 65 mmHg.[12,24] Ao

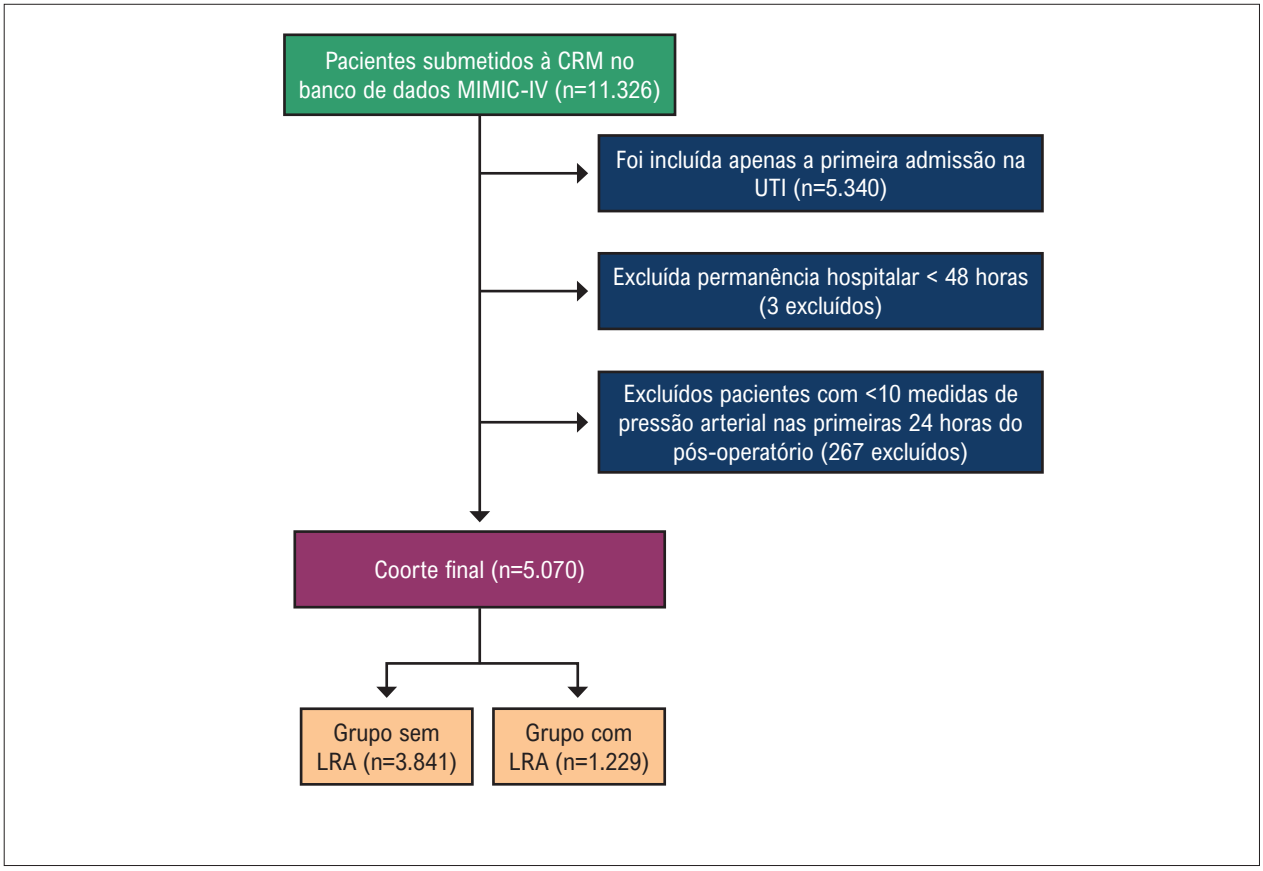


Figura 1 – *Fluxograma de filtragem de dados: Os dados foram coletados do banco de dados MIMIC e pré-processados para obter 5.070 pacientes. CRM: cirurgia de revascularização do miocárdio; LRA: lesão renal aguda.*

comparar a hipotensão sistólica e a hipotensão arterial média, exploramos qual das duas definições de hipotensão é mais sensível à LRA. A gravidade da hipotensão também foi avaliada medindo-se a área sob a curva (AUC) da PAM abaixo de 65 mmHg e a duração da PAM abaixo de 65 mmHg, registrada como área da PAM. A área da PAS também foi medida em limiares de 100 mmHg.

Métodos de análise estatística

Os dados das variáveis contínuas foram expressos como média ± desvio padrão (DP) ou mediana [intervalo interquartil (IIQ)], conforme apropriado. A normalidade das variáveis contínuas foi avaliada pelo teste de Shapiro-Wilk. Para variáveis contínuas com distribuição normal, as diferenças entre os grupos foram comparadas pelo teste-t de Student para amostras independentes (não pareadas), enquanto o teste U de Mann-Whitney foi utilizado para variáveis sem distribuição normal. As variáveis categóricas foram expressas em número e porcentagem, e o teste qui-quadrado foi utilizado para comparações entre os grupos. As análises acima foram realizadas utilizando o software IBM SPSS Statistics versão 26.0 (IBM, Armonk, NY, EUA). As análises estatísticas foram realizadas utilizando testes bicaudais, com um valor de $p < 0,05$ considerado estatisticamente significativo.

Seleção de recursos

Como uma dimensão de características muito alta pode levar ao sobreajuste do classificador, será necessário selecionar características para remover as irrelevantes e redundantes. De fato, adotamos uma estratégia de seleção de características em duas etapas. Na primeira etapa, classificamos todas as características usando a Floresta Aleatória (FA).[25] Na segunda etapa, utilizamos a seleção sequencial direta (SSD).[26] Para obter um subconjunto de características ideal, comparamos os resultados com dois métodos comuns de seleção de características: Máxima Relevância e Mínima Redundância (mRMR) e (SSD). A seleção de características e o desenvolvimento do modelo foram realizados estritamente no conjunto de dados de treinamento. O conjunto de dados de teste foi utilizado apenas para a avaliação final do modelo.

Construção de modelos

Os dados foram divididos aleatoriamente, com 70% usados para treinamento e 30% para validação. Empregamos diversas técnicas de aprendizado de máquina supervisionado para construir modelos preditivos, incluindo o XGBoost (XGB).,[27] regressão logística (RL), máquina de vetores de suporte (MVS), floresta aleatória (FA) e K-vizinhos mais próximos (KNN).[28]

XGB é uma biblioteca de *Gradient Boosting* distribuída e otimizada, projetada para ser altamente eficiente, flexível e portátil. Ela implementa algoritmos de aprendizado de máquina sob a estrutura de *Gradient Boosting*. Utilizamos o método de busca em grade no conjunto de treinamento para ajustar os parâmetros e obter os parâmetros ótimos: *max_depth* = 5, *learning_rate* = 0.01, *n_estimators* = 400, *subsample* = 0.8 e *min_child_weight* = 1. Para evitar vazamento de dados, a seleção de características e o ajuste de hiperparâmetros foram realizados exclusivamente no conjunto de treinamento. Nenhuma informação do conjunto de teste foi utilizada durante o treinamento do modelo ou a seleção de características.

Critérios de avaliação

Utilizamos validação cruzada de dez vezes no conjunto de treinamento para seleção de características, a fim de obter as melhores características.[29] Utilizamos diversos critérios de avaliação, que incluem sensibilidade (SEN), especificidade (ESP), precisão (PRE), escore F1 (F1), acurácia (ACU) e coeficiente de correlação de Matthews (CCM). Essas medidas foram definidas da seguinte forma:

$$SEN = \frac{TP}{(TP + FN)}$$

$$ESP = \frac{TN}{(TN + FP)}$$

$$PRE = \frac{TP}{(TP + FP)}$$

$$F1 = \frac{2 \times SEN \times PRE}{SEN + PRE}$$

$$ACU = \frac{TP + TN}{TP + TN + FP + FN}$$

$$CCM = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

onde TP, FP, TN e FN representam o número de verdadeiros positivos (pacientes com LRA corretamente previstos), falsos positivos (pacientes sem LRA incorretamente previstos como portadores de LRA), verdadeiros negativos (pacientes sem LRA corretamente previstos) e falsos negativos (pacientes com LRA incorretamente previstos como não portadores de LRA), respectivamente. Para fins de completude, também calculamos a área sob a curva ROC, denominada AUC, para avaliar nosso desempenho.

Resultados

Características dos pacientes

Conforme demonstrado na Tabela 1, houve diferenças significativas em relação a sexo, idade e CCI entre o grupo sem LRA (n=3841) e o grupo com LRA (n=1229). A FC média, PAS, PAD e PAM foram significativamente menores, e os níveis de VPA foram significativamente maiores entre os pacientes com LRA nas primeiras 24 horas de internação na UTI. Os escores de gravidade da doença, incluindo SAPS III, OASIS, SAPS II e SOFA, foram significativamente maiores no grupo com LRA do que no grupo sem LRA. O uso de vasopressores e inotrópicos foi mais comum no grupo com LRA.

A ocorrência de hipotensão observada, definida por PAM < 65 mmHg ou PAS < 100 mmHg, foi significativamente maior no grupo com LRA. Quanto à gravidade da hipotensão, tanto a área sob a curva da PAS quanto a área sob a curva da PAM estavam notavelmente elevadas entre os pacientes do grupo com LRA (p < 0,001).

Tanto o tempo de internação hospitalar quanto o tempo de internação na UTI foram significativamente maiores no grupo com LRA em comparação com o grupo sem LRA.

Resultados da análise de regressão logística univariada e multivariada

Os resultados da análise de regressão logística univariada para LRA estão apresentados na Tabela 2, indicando que os pacientes do grupo LRA apresentaram associação com valores mais elevados de PAS-VRM (razão de chances [OR]: 1,106; intervalo de confiança [IC] de 95%: 1,024–1,195), CV-PAD (OR: 1,029; IC de 95%: 1,010–1,048) e lg (área da PAS) (OR: 1,359; IC de 95%: 1,149–1,608). As variáveis que apresentaram associação significativa com LRA, indicada por um valor de p inferior a 0,1, foram incluídas em um modelo de regressão logística multivariável com seleção de variáveis por eliminação retrógrada (Tabela 3). Como esperado, tanto a VPA, representada por CV-PAD (OR, 1,005; IC 95%, 1,002-1,008), quanto a gravidade da hipotensão, definida pelo logaritmo da área da PAM (OR, 1,307; IC 95%, 1,220-1,400), estiveram independentemente associadas à LRA.

Características selecionadas nos modelos

Com base na análise da contribuição das características pelo classificador Floresta Aleatória, identificamos as 20 características mais importantes do conjunto de dados. Estas incluíram bun_média, idade, IMC, CCI, OASIS, SAPS II, SOFA, PA (incluindo PAS_média, PAD_média), VPA (representada por CV-PAD, PAS-DP, CV-PAS) e diversos marcadores séricos. A importância das características é apresentada na Figura 2 e na Tabela 4. Um mapa de calor foi utilizado para representar visualmente a inter-relação entre as características, conforme ilustrado na Figura 3.

Comparação de modelos

Utilizamos cinco métodos de aprendizado de máquina (XGB, RL, MVS, FA, KNN) com 20 variáveis para prever LRA pós-operatória. As AUCs foram apresentadas na Figura 4. Na Tabela 5, a eficiência de previsão de vários modelos foi comparada.

Discussão

Os principais achados deste estudo estão resumidos na Ilustração Central. Este estudo teve como objetivo investigar a associação entre a VPA pós-operatória e LRA em pacientes submetidos à CRM. Nossos achados indicam que uma VPA

Tabela 1 – Características dos pacientes entre os grupos sem LRA e com LRA

	Sem LRA N = 3841	LRA N = 1229	Valor de p
Gênero			< 0,001
Masc.	3075 (80,1%)	873 (71,0%)	
Fem.	766 (19,9%)	356 (29,0%)	
Idade (anos)	67,82 ± 10,06	71,79 ± 9,91	< 0,001
IMC (kg/m²)	30,13 ± 5,52	30,40 ± 5,86	0,150
Índice de comorbidade de Charlson			
Comorbidades, n (%)	4,95 ± 1,97	6,38± 2,19	< 0,001
Infarto do miocárdio	1386/3841 (36,1%)	535/1229 (43,5%)	< 0,001
Insuficiência cardíaca congestiva	698/3841 (18,2%)	458/1229 (37,3%)	< 0,001
Doença vascular periférica	438/3841 (11,4%)	212/1229 (17,2%)	< 0,001
Doença cerebrovascular	345/3841 (9,0%)	167/1229 (13,6%)	< 0,001
Demência	16/3841 (0,4%)	8/1229 (0,7%)	0,297
Doença pulmonar crônica	677/3841 (17,6%)	275/1229 (22,4%)	< 0,001
Doença reumática	100/3841 (2,6%)	47/1229 (3,8%)	0,026
Doença ulcerosa péptica	23/3841 (0,6%)	13/1229 (1,1%)	0,095
Doença hepática leve	99/3841 (2,6%)	62/1229 (5,0%)	< 0,001
Diabetes sem complicações	1208/3841 (31,5%)	417/1229 (33,9%)	0,105
Diabetes com complicações	390/3841 (10,2%)	238/1229 (19,4%)	< 0,001
Paraplegia	20/3841 (0,5%)	14/1229 (1,1%)	0,021
Doença renal	456/3841 (11,9%)	406/1229 (33,0%)	< 0,001
Câncer	94/3841 (2,4%)	44/1229 (3,6%)	0,034
Doença hepática grave	4/3841 (0,1%)	6/1229 (0,5%)	0,017
Tumor sólido metastático	8/3841 (0,2%)	5/1229 (0,4%)	0,231
AIDS	2/3841 (0,1%)	2/1229 (0,2%)	0,249
Frequência cardíaca média	82,32 ± 9,09	81,64 ± 9,38	0,023
PAS_média	112,19 ± 7,57	111,40 ± 8,63	0,002
PAD_média	57,51 ± 6,29	55,19 ± 7,02	< 0,001
PAM_média	74,69 ± 5,84	72,98 ± 6,58	< 0,001
Frequência respiratória	17,42 (15,94, 19,07)	17,64 (16,05, 19,39)	0,005
Temperatura	36,71 (36,56, 36,89)	36,71 (36,51, 36,82)	< 0,001
SpO²	97,92 (97,00, 98,78)	98,00 (96,82, 98,94)	0,490
Glicose	128,55 (121,12, 137,31)	129,82 (121,60, 142,63)	< 0,001
apsii	36,82 ± 17,48	47,98 ± 21,91	< 0,001
oasis	30,74 ± 7,21	34,86 ± 7,87	< 0,001
sapsii	35,82 ± 10,90	41,98 ± 12,25	< 0,001
SOFA	5,00 ± 2,42	6,86 ± 3,17	< 0,001
PAM -VRM	7,00 (6,00, 9,00)	7,00 (6,00, 9,00)	0,006
PAM -VS	9,97 (7,95, 12,76)	10,38 (8,35, 14,35)	< 0,001
PAM -DP	8,73 (7,22, 10,92)	9,56 (7,72, 12,40)	< 0,001
PAM -CV	11,75 (9,80, 14,52)	13,16 (10,85, 16,76)	< 0,001

PAS-VRM	11,62 ± 4,50	12,04 ± 3,56	0,003
PAS-VS	14,85 (12,20, 18,15)	15,58 (12,96, 18,93)	< 0,001
PAS-DP	12,94 (10,85, 15,36)	14,35 (12,17, 16,98)	< 0,001
PAS-CV	11,93 ± 5,04	13,08 ± 3,39	< 0,001
PAD-VRM	5,36 (4,39, 6,62)	5,41(4,40, 6,64)	0,386
PAD-VS	7,36 (5,92, 9,27)	7,56 (6,08, 9,57)	0,003
PAD-DP	6,96 (5,74, 8,53)	7,52 (6,15, 0,15)	< 0,001
PAD-CV	12.31 (10.30, 15.00)	13,96 (11,56, 16,83)	< 0,001
creatinina_min	0,80 (0,70, 1,00)	0,90 (0,70, 1,30)	< 0,001
creatinina_máx.	0,90 (0,80, 1,10)	1,10 (0,90, 1,60)	< 0,001
Mortalidade Hospitalar	9/3841 (0,2%)	47/1229 (3,8%)	< 0,001
TSRC	1/3841 (0,0%)	81/1229 (6,6%)	< 0,001
Ventilação mecânica	139/3841 (3,6%)	78/1229 (6,3%)	< 0,001
Dobutamina	16/3841 (0,4%)	32/1229 (2,6%)	< 0,001
Dopamina	12/3841 (0,3%)	27/1229 (2,2%)	< 0,001
Epinefrina	548/3841 (14,3%)	395/1229 (32,1%)	< 0,001
Norepinefrina	399/3841 (10,4%)	326/1229 (26,5%)	< 0,001
Fenilefrina	2709/3841 (70,5%)	882/1229 (71,8%)	0,406
Vasopressina	126/3841 (3,3%)	166/1229 (13,5%)	< 0,001
Glicose			< 0,001
<200	3815/3841 (99,3%)	1200/1229 (97,6%)	
≧200	26/3841 (0,7%)	29/1229 (2,4%)	
Anemia (hematócrito)	3797/3841 (98,9%)	1193/1229 (97,1%)	< 0,001
Anemia (hemoglobina)	3793/3841 (98,8%)	1197/1229 (97,4%)	< 0,001
Hematócrito	31,20 ± 3,91	30,13 ± 4,07	< 0,001
Hemoglobina	10,51 ± 1,39	10,04 ± 1,42	< 0,001
Plaquetas	157,50 (130,50, 190,50)	153,00 (124,25, 137,31)	0,022
Leucócitos	12,75 (10,25, 15,75)	12,80 (10,18, 16,20)	0,223
Ânion gap	11,54 ± 2,25	12,59 ± 2,75	< 0,001
Bicarbonato	23,56 ± 2,03	22,75 ± 2,37	< 0,001
BUN	15,50 (12,50, 19,00)	19,00 (14,50, 26,50)	< 0,001
Cálcio	8,36 ± 0,44	8,42 ± 0,54	< 0,001
Cloreto	106,82 ± 3,15	106,88 ± 4,13	0,598
Sódio	138,11 ± 2,46	138,44 ± 2,85	< 0,001
Potássio	4,38 ± 0,38	4,50 ± 0,51	< 0,001
Basófilos	1,09 (0,04, 1,09)	1,09 (0,04, 1,09)	0,683
Eosinófilos	5,07 (0,14, 5,07)	5,07 (0,14, 5,07)	0,640
Linfócitos	63,73 (2,20, 63,73)	63,73 (2,20, 63,73)	0,378
monócitos	11,96 (0,51, 11,96)	11,96 (0,50, 11,96)	0,934
Neutrófilos	308.21 (10.34, 308.21)	308.21 (10.41, 308.21)	0,467
Fibrinogênio	220,00 (180,00, 242,00)	221,15 (179,00, 249,00)	0,128
RNI	1,31 ± 0,23	1,36 ± 0,26	< 0,001

TP	14.20 (13.35, 15.20)	14,55 (13,50, 15,85)	< 0,001
aTTP	30,85 (28,05, 36,78)	33,05 (29,05, 42,00)	< 0,001
Temperatura (℃)			0,621
<37,2	3556/3841 (92,6%)	1143/1229 (93,0%)	
≧37,2	285/3841 (7,4%)	86/1229 (7,0%)	
SpO_2 (%)			
<95	72/3841 (1,9%)	54/1229 (4,4%)	< 0,001
≧95	3769/3841 (98,1%)	1175/1229 (95,6%)	
Frequência respiratória			0,026
<12	5/3841 (0,1%)	2/1229 (0,2%)	
12-20	3245/3841 (84,5%)	998/1229 (81,2%)	
>20	591/3841 (15,4%)	229/1229 (18,6%)	
Plaquetas			0,005
<150	1636/3841 (42,6%)	580/1229 (47,2%)	
150-400	2192/3841 (57,1%))	641/1229 (52,2%)	
>400	13/3841 (0,3%)	8/1229 (0,7%)	
Leucócitos			0,460
<5	25/3841 (0,7%)	5/1229 (0,4%)	
5-10	860/3841 (22,4%)	289/1229 (23,5%)	
>10	2956/3841 (77,0%)	935/1229 (76,1%)	
Ânion gap			< 0,001
<8	110/3841 (2,9%)	16/1229 (1,3%)	
8-16	3641/3841 (94,8%)	1114/1229 (90,6%)	
>16	90/3841 (2,3%)	99/1229 (8,1%)	
Bicarbonato			< 0,001
<23	1310/3841 (34,1%)	619/1229 (50,4%)	
23-30	2522/3841 (65,7%)	607/1229 (49,4%)	
>30	9/3841 (0,2%)	3/1229 (0,2%)	
BUN			< 0,001
<10	275/3841 (7,2%)	50/1229 (4,1%)	
10-20	2819/3841 (73,4%)	622/1229 (50,6%)	
>20	747/3841 (19,4%)	557/1229 (45,3%)	
Cálcio			0,002
<9	3519/3841 (91,6%)	1096/1229 (89,2%)	
9-10,5	316/3841 (8,2%)	125/1229 (10,2%)	
>10,5	6/3841 (0,2%)	8/1229 (0,7%)	
Cloreto			< 0,001
<95	10/3841 (0,3%)	15/1229 (1,2%)	
95-105	1104/3841 (28,7%)	349/1229 (28,4%)	
>105	2727/3841 (71,0%)	865/1229 (70,4%)	

Sódio			< 0,001
<135	275/3841 (7,2%)	99/1229 (8,1%)	
135-145	3560/3841 (92,7%)	1119/1229 (91,0%)	
>145	6/3841 (0,2%)	11/1229 (0,9%)	
Potássio			< 0,001
<3,5	17/3841 (0,4%)	15/1229 (1,2%)	
3,5-5	3608/3841 (93,9%)	1054/1229 (85,8%)	
>5	216/3841 (5,6%)	160/1229 (13,0%)	
Basófilos			0,275
0-0,5	1710/3841 (44,5%)	569/1229 (46,3%)	
>0,5	2131/3841 (55,5%)	660/1229 (53,7%)	
Eosinófilos			0,442
0-0,5	16460/3841 (42,9%)	542/1229 (44,1%)	
>0,5	21950/3841 (57,1%)	687/1229 (55,9%)	
Linfócitos			0,202
<0,77	43/3841 (1,1%)	21/1229 (1,7%)	
0,77-4,5	1568/3841 (40,8%)	514/1229 (41,8%)	
>4,5	2230/3841 (58,1%)	694/1229 (56,5%)	
Monócitos			0,013
<0,14	105/3841 (2,7%)	54/1229 (4,4%)	
0,14-1,3	1531/3841 (39,9%)	473/1229 (38,5%)	
>1,3	2205/3841 (57,4%)	702/1229 (57,1%)	
Neutrófilos			0,677
<2,6	24/3841 (0,6%)	9/1229 (0,7%)	
2,6-8,5	634/3841 (16,5%)	191/1229 (15,5%)	
>8,5	3183/3841 (82,9%)	1029/1229 (83,7%)	
Fibrinogênio			0,130
<200	1452/3841 (37,8%)	444/1229 (36,1%)	
200-400	2321/3841 (60,4%)	753/1229 (61,3%)	
>400	68/3841 (1,8%)	32/1229 (2,6%)	
RNI			0,018
0,8-1,2	1171/3841 (30,5%)	331/1229 (26,9%)	
>1,2	2670/3841 (69,5%)	898/1229 (73,1%)	
TP			0,065
<11	10/3841 (0,3%)	7/1229 (0,6%)	
11-13	652/3841 (17,0%)	183/1229 (14,9%)	
>13	3179/3841 (82,8%)	1039/1229 (84,5%)	
aTTP			< 0,001
<60	3670/3841 (95,5%)	1117/1229 (90,9%)	
60-70	55/3841 (1,4%)	45/1229 (3,7%)	
>70	116/3841 (3,0%)	67/1229 (5,5%)	

Tipo de admissão	305 (7,9%)	127 (10,3%)	< 0,001
eletiva	641 (16,7%)	229 (18,6%)	
emergência	1279 (33,3%)	326 (26,5%)	
internação cirúrgica no mesmo dia	1280 (33,3%)	439 (35,7%)	
Em observação	336 (8,7%)	108 (8,8%)	
Local de alta			< 0,001
lar	2689 (70,0%)	493 (40,1%)	
não residencial	1143 (29,8%)	689 (56,1%)	
óbito	9 (0,2%)	47 (3,8%)	
Idioma			0,552
Inglês	3485 (90,7%)	1122 (91,3%)	
não inglês	356 (9,3%)	107 (8,7%)	
Estado civil			< 0,001
solteiro	541 (14,1%)	193 (15,7%)	
casado	2745 (71,5%)	801 (65,2%)	
divorciado	261 (6,8%)	79 (6,4%)	
viúvo	294 (7,7%)	156 (12,7%)	
Etnia			0,081
Branco	2733 (71,2%)	914 (74,4%)	
Asiático	91 (2,4%)	23 (1,9%)	
Outro	1017 (26,5%)	292 (23,8%)	
Hipo PAS	3520 (91,6%)	1159 (93,5%)	0,037
Área PAS	6681,00 (2172,40, 14893,84)	8805,74 (3112.09, 17059.91)	< 0,001
Hipo PAM	3128 (81,4%)	1115 (90,7%)	< 0,001
Área PAM	225,31 (16,41, 886,26)	600,79 (114.27, 1833.01)	< 0,001
horas	9,78 (7,36, 13,06)	13.14 (9.18, 19.95)	< 0,001
TDI_hospital	6,80 (5,11, 9,07)	9.11 (6.38, 13.85)	< 0,001
TDI_UTI	1,36 (1,18, 2,30)	3,25 (2,08, 5,54)	< 0,001

AIDS: síndrome da imunodeficiência adquirida; BUN: ureia no sangue; IMC: índice de massa corporal; CV: coeficiente de variação; PAD: pressão arterial diastólica; UTI: Unidade de terapia intensiva; IIQ: intervalo interquartil; PAM: pressão arterial média; TP: tempo de protrombina; TTP: tempo de tromboplastina parcial; PAS: pressão arterial sistólica; SOFA: Avaliação Sequencial de Falência de Órgãos; SpO_2: saturação percutânea de oxigênio; VS: variação sucessiva.

Tabela 2 – Resultados da análise de regressão logística univariada para LRA

Variável	OR	IC de 95%	Valor de p
Gênero			
Masc.	1		
Fem.	1,214	0,991-1,489	0,062
Idade (anos)	1.010	0,993-1,027	0,267
IMC (kg/m²)	1,008	0,993-1,023	0,286

Índice de comorbidade de Charlson	1,135	0,935-1,377	0,200
Comorbidades			
Infarto do miocárdio	0,889	0,688-1,150	0,371
Insuficiência cardíaca congestiva	1,035	0,787-1,360	0,808
Doença vascular periférica	0,932	0,696-1,249	0,639
Doença cerebrovascular	0,884	0,649-1,205	0,436
Demência	1,044	0,392-2,780	0,931
Doença pulmonar crônica	0,873	0,665-1,147	0,330
Doença reumática	1,094	0,698-1,716	0,695
Doença ulcerosa péptica	0,682	0,278-1,674	0,404
Doença hepática leve	1.23	0,788-1,920	0,362
Diabetes sem complicações	1.116	0,875-1,423	0,378
Diabetes com complicações	1,026	0,678-1,554	0,903
Paraplegia	0,985	0,404-2,402	0,974
Doença renal	1,087	0,698-1,694	0,711
Câncer	1,067	0,599-1,901	0,826
Doença hepática grave	1,821	0,349-9,512	0,477
Tumor sólido metastático	0,699	0,147-3,336	0,654
AIDS	8.081	0,693-94,201	0,095
Frequência cardíaca média	1,008	0,993-1,023	0,286
PAS_média	0,996	0,986-1,005	0,396
PAD_média	0,993	0,977-1,010	0,424
PAM_média	1,009	0,986-1,033	0,456
Frequência respiratória	0,992	0,962-1,022	0,590
Temperatura	1.016	0,970-1,064	0,513
SpO_2	0,740	0,567-0,965	0,026
Glicose	0,952	0,887-1,022	0,178
apsii	0,993	0,987-0,999	0,015
oásis	1,004	0,997-1,010	0,265
sapsii	1,032	1,017-1,046	< 0,001
SOFÁ	0,982	0,970-0,994	0,004
PAM-VRM	0,921	0,836-1,016	0,100
PAM-VS	1.017	0,969-1,067	0,496
PAM-DP	1,033	0,929-1,149	0,548
PAM-CV	0,981	0,903-1,066	0,657
PAS-VRM	1.106	1,024-1,195	0,010
PAS-VS	0,923	0,876-0,973	0,003
PAS-DP	1,048	0,987-1,112	0,126
PAS-CV	1.031	0,961-1,106	0,396
PAD-VRM	1.040	0,976-1,109	0,228
PAD-VS	0,981	0,938-1,027	0,415
PAD-DP	0,999	0,932-1,070	0,977

PAD-CV	1,029	1,010-1,048	0,003
Ventilação mecânica	1,007	0,688-1,475	0,970
Dobutamina	1,435	0,687-2,999	0,337
Dopamina	2,639	1,131-6,154	0,025
Epinefrina	1.090	0,872-1,363	0,449
Norepinefrina	1,042	0,804-1,353	0,754
Fenilefrina	1,216	1.000-1.477	0,050
Vasopressina	1,458	1,041-2,041	0,028
Glicose			
<200	1		
≥200	1,609	0,625-4,144	0,324
Anemia (hematócrito)	2,552	1,105-5,894	0,028
Anemia (hemoglobina)	2.113	1,344-3,320	0,001
Hematócrito	0,992	0,928-1,059	0,805
Hemoglobina	0,936	0,776-1,13	0,492
Plaquetas	1.001	0,998-1,003	0,550
Leucócitos	1.001	0,987-1,016	0,856
Ânion gap	1,076	1,019-1,136	0,008
Bicarbonato	0,941	0,874-1,013	0,106
BUN	1,008	0,995-1,02	0,234
Cálcio	1.102	0,864-1,405	0,436
Cloreto	1.013	0,958-1,071	0,648
Sódio	1,051	0,997-1,109	0,067
Potássio	1,529	1,178-1,985	0,001
Basófilos	1.016	0,953-1,083	0,631
Eosinófilos	0,998	0,985-1,011	0,713
Linfócitos	1.001	1,000-1,003	0,076
Monócitos	0,998	0,989-1,006	0,583
Neutrófilos	1.000	0,999-1,000	0,454
Fibrinogênio	1.000	0,998-1,002	0,998
RNI	1.103	0,406-2,995	0,848
TP	1,004	0,912-1,106	0,931
aTTP	1,005	0,995-1,016	0,312
Temperatura (℃)			
<37,2	1		
≥37,2	1,239	0,859-1,786	0,252
SpO^2 (%)			
<95			
≥95	0,581	0,349-0,967	0,037
Frequência respiratória			0,523
<12	1		
12-20	0,612		0,581
>20	0,523		0,478

Plaquetas			0,824
<150	1		
150-400	0,935	0,746-1,172	0,562
>400	0,721	0,173-3,01	0,654
Leucócitos			0,258
<5	1		
5-10	2,526	0,837-7,623	0,100
>10	2,484	0,817-7,553	0,109
Ânion gap			0,600
<8	1		
8-16	1,34	0,723-2,484	0,352
>16	1,26	0,563-2,818	0,573
Bicarbonato			0,852
<23	1		
23-30	1,008	0,793-1,281	0,948
>30	0,611	0,098-3,824	0,599
BUN			0,008
<10	1		
10-20	0,972	0,681-1,388	0,878
>20	1,404	0,909-2,170	0,126
Cálcio			0,556
<9	1		
9-10,5	0,823	0,574-1,178	0,287
>10,5	0,652	0,122-3,495	0,618
Cloreto			0,065
<95	1		
95-105	0,273	0,092-0,812	0,020
>105	0,262	0,082-0,837	0,024
Sódio			0,217
<135	1		
135-145	0,835	0,583-1,196	0,325
>145	2.002	0,509-7,870	0,320
Potássio			0,023
<3,5	1		
3,5-5	0,287	0,113-0,733	0,009
>5	0,313	0,11-0,888	0,029
Basófilos			
0-0,5	1		
>0,5	1,007	0,531-1,909	0,982
Eosinófilos			
0-0,5	1		
>0,5	1,132	0,631-2,031	0,677

Linfócitos			0,030
<0,77	1		
0,77-4,5	1.201	0,612-2,359	0,594
>4,5	0,52	0,208-1,299	0,162
Monócitos			0,091
<0,14	1		
0,14-1,3	0,737	0,475-1,143	0,173
>1,3	1,265	0,632-2,532	0,506
Neutrófilos			0,420
<2,6	1		
2,6-8,5	1,185	0,471-2,981	0,718
>8,5	1,389	0,548-3,520	0,489
Fibrinogênio			0,673
<200	1		
200-400	0,923	0,733-1,161	0,491
>400	1,009	0,457-2,229	0,983
RNI			
0,8-1,2	1		
>1,2	0,953	0,744-1,222	0,705
TP			0,854
<11	1		
11-13	0,725	0,210-2,500	0,611
>13	0,755	0,216-2,644	0,661
aTTP			0,311
<60	1		
60-70	1,387	0,784-2,453	0,260
>70	0,868	0,455-1,655	0,668
Tipo de admissão			0,428
eletiva	1		
emergência	0,945	0,686-1,301	0,728
internação cirúrgica no mesmo dia	0,798	0,594-1,072	0,134
urgente	0,923	0,684-1,244	0,598
em observação	0,813	0,553-1,194	0,291
Local de alta			< 0,001
lar	1		
não residencial	3,288	2,873-3,762	< 0,001
óbito	28.484	13.871-58.493	< 0,001
Idioma			
Inglês	1		
não inglês	0,945	0,713-1,252	0,693

Estado civil			0,355
solteiro	1		
casado	0,855	0,687-1,065	0,162
divorciado	0,753	0,530-1,070	0,114
viúvo	0,921	0,674-1,259	0,607
Etnia			0,287
Branco	1		
Asiático	0,843	0,485-1,467	0,546
Outro	0,864	0,716-1,042	0,126
Hipo PAS	0,249	0,128-0,484	< 0,001
Lg área PAS	1,359	1,149-1,608	< 0,001
Hipo PAM	0,874	0,592-1,290	0,498
Lg área PAM	1,188	1,023-1,379	0,024
Mortalidade Hospitalar	16,93	8.273-34.647	< 0,001
TSRC	270,941	37.667-1948.914	< 0,001
horas	1.090	1,080-1,101	< 0,001
TDI_hospital	1,133	1,117-1,148	< 0,001
TDI_UTI	1,613	1,548-1,681	< 0,001

AIDS: síndrome da imunodeficiência adquirida; BUN: nitrogênio ureico no sangue; IMC: índice de massa corporal; IC: intervalo de confiança; TSRC: terapia contínua de substituição renal; CV: coeficiente de variação; PAD: pressão arterial diastólica; UTI: Unidade de terapia intensiva; IIQ: intervalo interquartil; PAM: pressão arterial média; OR: razão de chances; TP: Tempo de protrombina; TTP: tempo de tromboplastina parcial; PAS: pressão arterial sistólica; SOFA: Avaliação Sequencial de Falência Orgânica; SpO_2: saturação percutânea de oxigênio; VS: variação sucessiva.

Tabela 3 – Resultados da análise de regressão logística multivariável para LRA

Variável	OR	IC de 95%	Valor de p
CVPAD	1,005	1,002-1,008	0,004
Temperatura	0,734	0,598-0,900	0,003
Oasis	1,029	1,018-1,040	< 0,001
SOFA	1,136	1,102-1,171	< 0,001
Ânion gap	1,117	1,081-1,155	< 0,001
Sódio	1,033	1,001-1,067	0,046
Potássio	1,581	1,247-2,005	< 0,001
Dopamina	2,527	1,159-5,512	0,020
Vasopressina	1,863	1,393-2,491	< 0,001
Gênero	1,485	1,255-1,758	< 0,001
BUN			< 0,001
<10	1		
10-20	1,072	0,770-1,495	0,680
>20	2.082	1,465-2,958	< 0,001
Cloreto			0,029
<95	1		
95-105	0,315	0,120-0,827	0,019
>105	0,356	0,133-0,952	0,040

Potássio			0,004
<3,5	1		
3,5-5	0,254	0,107-0,605	0,002
>5	0,284	0,107-0,755	0,012
SpO²	0,483	0,315-0,739	0,001
Anemia (hematócrito)	2,574	1,514-4,377	< 0,001
Lg área PAM	1,307	1,220-1,400	< 0,001

BUN: nitrogênio ureico no sangue; CV: coeficiente de variação; PAD: pressão arterial diastólica; SOFA: Avaliação Sequencial de Falência de Órgãos; SpO_2: saturação percutânea de oxigênio.

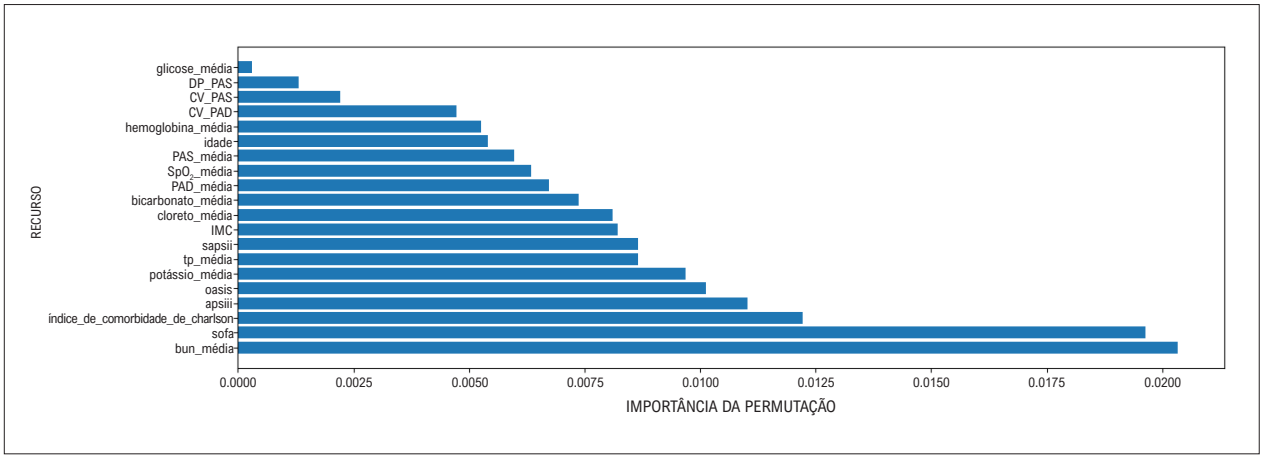


Figura 2 – *Gráfico de importância das características. O comprimento das colunas na figura indica o grau de contribuição da característica para o modelo.*

mais elevada durante as primeiras 24 horas após a cirurgia esteve independentemente associada a um risco aumentado de LRA pós-operatória. Além disso, uma maior carga hipotensiva, refletida pela área sob o limiar da PAM de 65 mmHg, também foi associada independentemente à LRA . Esses achados sugerem que a instabilidade hemodinâmica pós-operatória pode contribuir para a identificação de pacientes com maior risco de LRA. No entanto, dado o desenho observacional retrospectivo deste estudo, essas associações não devem ser interpretadas como evidência de uma relação causal. Adicionalmente, observamos que a gravidade da hipotensão, indicada pela AUC para PAM e PAS abaixo de limiares predefinidos, aumenta ainda mais o valor preditivo para LRA.

A associação entre a VPA e a LRA tem sido explorada em diversas populações cirúrgicas, com estudos anteriores destacando os efeitos prejudiciais das flutuações da PA na perfusão renal e na oxigenação tecidual.[5,6] Os mecanismos fisiopatológicos subjacentes a essa associação são complexos, mas provavelmente envolvem lesão por isquemia-reperfusão, hipóxia renal e mecanismos autorregulatórios disfuncionais, que são particularmente prevalentes em pacientes críticos.[9,10] Nosso estudo contribui para esse conjunto de literatura ao demonstrar o impacto da VPA pós-operatória especificamente em pacientes submetidos à CRM, um grupo de alto risco tanto para LRA quanto para instabilidade cardiovascular.[14]

A inclusão de métricas de VPA, como VRM, VS, DP e CV, neste estudo fornece uma abordagem abrangente para quantificar as flutuações da PA.[7] Dentre esses, descobrimos que o CV da PAD foi particularmente preditivo de LRA, em consonância com estudos anteriores que sugerem que a variabilidade da PAD é um fator chave nos desfechos renais.[6,22] Esses resultados reforçam a importância de considerar não apenas a PAM, mas também sua variabilidade ao avaliar o risco pós-operatório.[8]

Uma possível preocupação na interpretação desses achados é a causalidade reversa. O diagnóstico de LRA neste estudo se baseou nos critérios KDIGO, que dependem de alterações na creatinina sérica que são inerentemente tardias em relação ao início da lesão renal. Como resultado, uma lesão renal subclínica precoce pode já estar presente durante o período pós-operatório inicial, sem ainda atingir os limiares diagnósticos. Consequentemente, alguns pacientes classificados como não apresentando LRA nas primeiras 24 horas podem já ter apresentado disfunção renal progressiva, o que poderia contribuir para a instabilidade hemodinâmica e o aumento da VPA. Embora a VPA tenha sido calculada estritamente nas primeiras 24 horas após a admissão na UTI para preservar a precedência temporal, a

Tabela 4 – Dados de atributos classificados por peso (n = 20)

Atributo	Peso
1) apsii	0,032715
2) bun_média	0,031363
3) SOFA	0,025782
4) oasis	0,023938
5) SpO2_média	0,023863
6) sapsii	0,023449
7) idade	0,021028
8) pas_médio	0,020536
9) CVPAD	0,019943
10) bicarbonato_médio	0,019684
11) SDPAS	0,019534
12) glicose_média	0,019443
13) CVPAS	0,019186
14) Índice de comorbidade de Charlson	0,018627
15) ttp_média	0,018598
16) potássio_médio	0,018222
17) hemoglobina_média	0,018097
18) cloreto_médio	0,018042
19) IMC	0,017987
20) pad_média	0,017646

BUN: ureia no sangue; IMC: índice de massa corporal; CV: coeficiente de variação; PAD: pressão arterial diastólica; PAM: pressão arterial média; TTP: tempo de tromboplastina parcial; PAS: pressão arterial sistólica; SOFA: Avaliação Sequencial de Falência de Órgãos; SpO2: saturação percutânea de oxigênio.

causalidade reversa não pode ser completamente excluída neste estudo retrospectivo.

Técnicas de aprendizado de máquina foram empregadas para desenvolver um modelo preditivo para LRA, que demonstrou resultados promissores.[30,31] Dentre os métodos testados, o XGBoost superou os demais modelos em termos de precisão e poder preditivo, enfatizando o potencial de abordagens computacionais avançadas para aprimorar a tomada de decisões clínicas. A capacidade do modelo de integrar uma ampla gama de variáveis clínicas e laboratoriais, incluindo a VPA, aumenta ainda mais sua utilidade clínica. Os modelos de aprendizado de máquina desenvolvidos neste estudo demonstraram desempenho preditivo promissor, sugerindo que a VPA pós-operatória pode fornecer informações prognósticas adicionais para a estratificação precoce de risco após a CRM.[32] No entanto, esses modelos foram desenvolvidos e validados internamente usando um único banco de dados retrospectivo. Sua utilidade clínica deve, portanto, ser interpretada com cautela e requer validação externa e avaliação prospectiva antes da aplicação clínica de rotina.

No entanto, nosso estudo não está isento de limitações. Primeiramente, embora tenhamos utilizado um conjunto de dados amplo e diversificado do banco de dados MIMIC-IV, a natureza retrospectiva da análise introduz a possibilidade de fatores de confusão não mensurados. Embora tenhamos controlado diversas covariáveis importantes, pode haver outras variáveis que influenciam a relação entre a VPA e a LRA que não foram registradas no banco de dados. Além disso, diversas variáveis intraoperatórias importantes, conhecidas por influenciarem o risco de LRA associada à cirurgia cardíaca, incluindo a duração da circulação extracorpórea, o tempo de pinçamento aórtico, a perda sanguínea intraoperatória e o sangramento cirúrgico, não estavam consistentemente disponíveis no banco de dados MIMIC-IV e, portanto, não puderam ser incorporadas às nossas análises multivariáveis. Embora tenhamos ajustado para uma ampla gama de características demográficas, comorbidades, escores de gravidade da doença, parâmetros hemodinâmicos pós-operatórios, exames laboratoriais e uso de medicamentos vasoativos, não se pode excluir a possibilidade de confusão residual decorrente desses fatores intraoperatórios não mensurados. Estudos futuros utilizando registros dedicados à cirurgia cardíaca ou conjuntos de dados prospectivos com informações intraoperatórias abrangentes são necessários para validar ainda mais nossos achados. Além disso, embora o uso de modelos de aprendizado de máquina seja muito promissor, sua aplicação na prática clínica requer validação e aprimoramento adicionais, especialmente em relação à sua generalização para outras populações e contextos. Ademais, a VPA foi avaliada utilizando dados apenas das primeiras 24 horas pós-operatórias, e é possível que a variabilidade em fases posteriores do pós-operatório possa fornecer informações adicionais sobre o risco de LRA. Estudos futuros poderiam explorar as tendências da VPA a longo prazo e seu potencial impacto na recuperação da função renal e em outros desfechos pós-operatórios. Além disso, embora nosso estudo tenha se concentrado na VPA como preditor, pesquisas adicionais são necessárias para compreender os mecanismos subjacentes pelos quais as flutuações da PA contribuem para a LRA e se intervenções direcionadas para estabilizar a VPA poderiam melhorar os desfechos.

Conclusão

Em conclusão, a VPA pós-operatória se associou independentemente à LRA em pacientes submetidos à CRM. Esses achados sugerem que a VPA pode ter valor potencial para a estratificação de risco pós-operatória precoce. Contudo, dado o desenho observacional retrospectivo deste estudo, não é possível estabelecer causalidade. Estudos prospectivos adicionais e validação externa são necessários antes que esses achados possam ser incorporados à prática clínica de rotina.

Contribuição dos Autores

Concepção e desenho da pesquisa: Ling-Song Y, Yu-Chen D, Jie S, Yunfei B; Obtenção de dados: Yu-Chen D; Análise e interpretação dos dados e Análise estatística: Ling-Song Y; Obtenção de financiamento: Yu-Chen D, Yunfei B; Redação do manuscrito: Ling-Song Y, Yu-Chen D; Revisão crítica do manuscrito quanto ao conteúdo intelectual importante: Qing-Ren L, Jie S, Yunfei B.

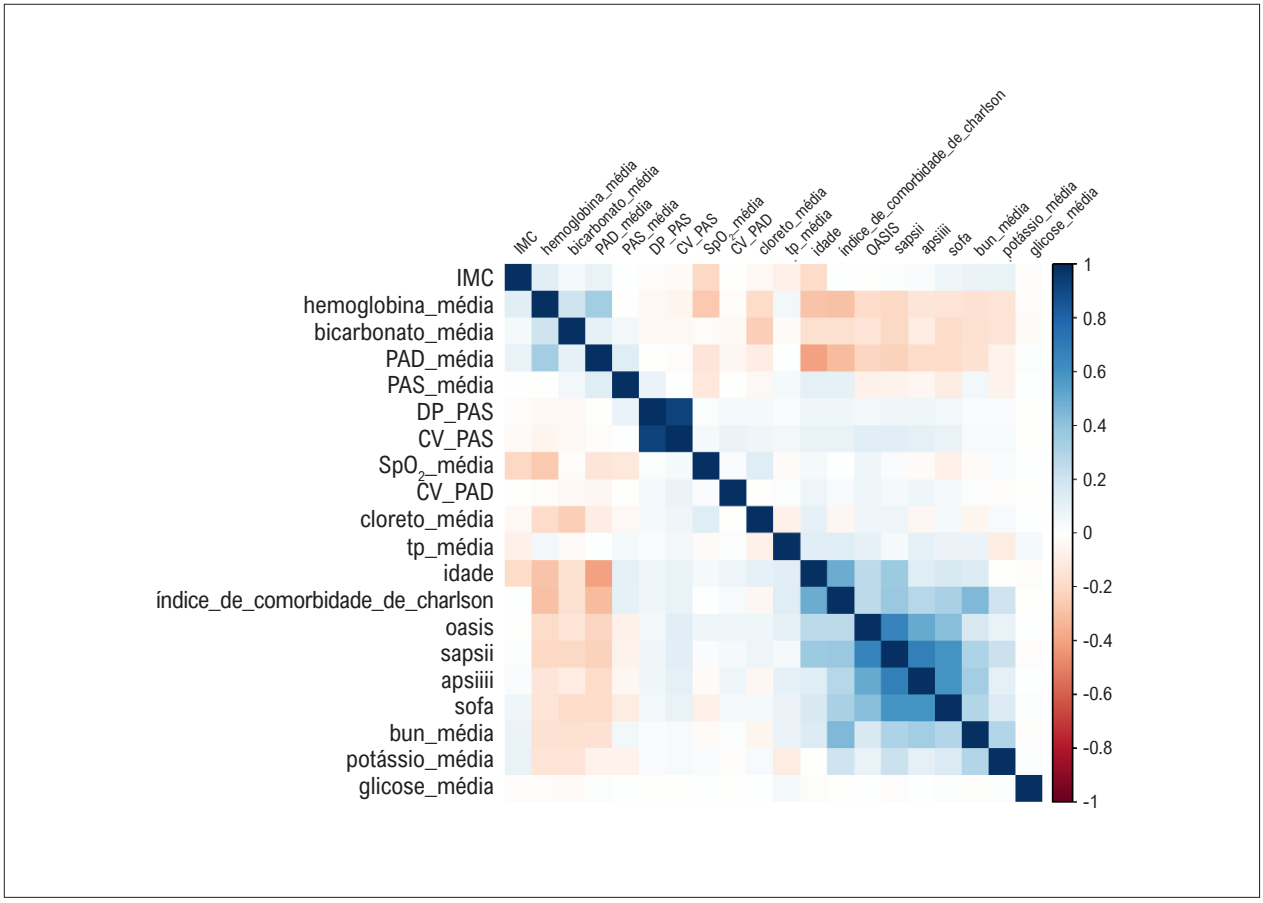


Figura 3 – *Gráfico de correlação de características. A cor indica o grau de correlação entre duas características.*

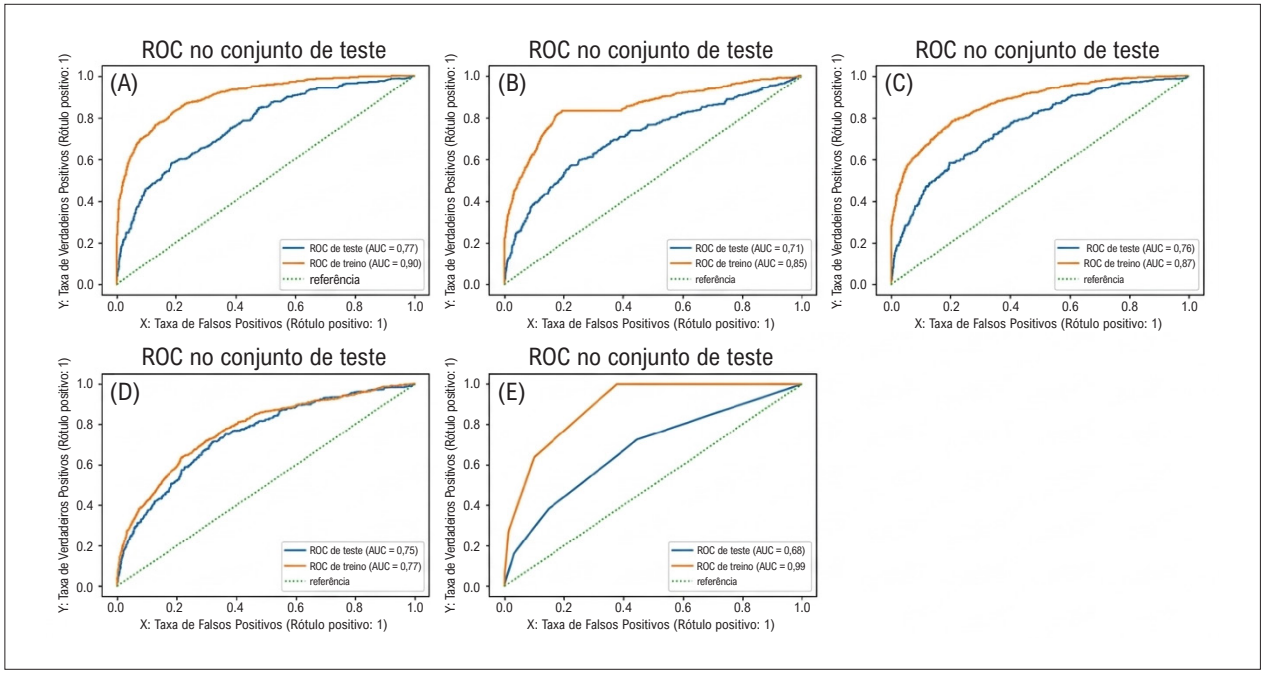


Figura 4 – *Resultados do conjunto de treinamento em diferentes modelos. MVS: Máquina de Vetores de Suporte; FA: Floresta Aleatória; RL: regressão logística; KNN: K-Nearest Neighbor.*

Tabela 5 - Comparação de eficiência de previsão entre os diferentes modelos

Modelo Nome	SEN	ESP	PRE	F1	CCM	ACU	AUC	Matriz de confusão
XGB	0,480	0,986	0,915	0,630	0,600	0,866	0,918	[1079 60; 269 113]
RL	0,316	0,949	0,658	0,428	0,355	0,798	0,776	[1079 60; 281 101]
MVS	0,365	0,982	0,865	0,513	0,482	0,835	0,850	[1101 38; 302 60]
FA	0,331	0,993	0,937	0,490	0,498	0,836	0,873	[1102 37; 296 86]
KNN	0,621	0,900	0,660	0,640	0,532	0,834	0,888	[1103 36; 320 62]

ACU: acurácia; AUC: área sob a curva; F1: escore F1; KNN: K-Nearest Neighbor; RL: regressão logística; CCM: coeficiente de correlação de Matthews; PRE: precisão; FA: Floresta Aleatória; SEM: sensibilidade; ESP: especificidade; MVS: máquina de vetores de suporte; XGB: XGBoost.

Potencial Conflito de Interesse

Declaro não haver conflito de interesses pertinentes.

Fontes de Financiamento

O presente estudo foi financiado por National Key Research and Development Program of China [grant number: 2022YFA1205802] and the National Natural Science Foundation of China (grant number: 61871121).

Vinculação Acadêmica

Não há vinculação deste estudo a programas de pós-graduação.

Aprovação Ética e Consentimento Informado

Este artigo não contém estudos com humanos ou animais realizados por nenhum dos autores.

Uso de Inteligência Artificial

Os autores não utilizaram ferramentas de inteligência artificial no desenvolvimento deste trabalho.

Disponibilidade de Dados

Todo o conjunto de dados que dá suporte aos resultados deste estudo está disponível mediante solicitação ao autor correspondente.

Referências

1. Thiele RH, Isbell JM, Rosner MH. AKI Associated with Cardiac Surgery. Clin J Am Soc Nephrol. 2015;10(3):500-14. doi: 10.2215/CJN.07830814.
2. Hu J, Chen R, Liu S, Yu X, Zou J, Ding X. Global Incidence and Outcomes of Adult Patients with Acute Kidney Injury after Cardiac Surgery: A Systematic Review and Meta-Analysis. J Cardiothorac Vasc Anesth. 2016;30(1):82-9. doi: 10.1053/j.jvca.2015.06.017.
3. Aronson S, Stafford-Smith M, Phillips-Bute B, Shaw A, Gaca J, Newman M, et al. Intraoperative Systolic Blood Pressure Variability Predicts 30-Day Mortality in Aortocoronary Bypass Surgery Patients. Anesthesiology. 2010;113(2):305-12. doi: 10.1097/ALN.0b013e3181e07ee9.
4. Nadim MK, Forni LG, Bihorac A, Hobson C, Koyner JL, Shaw A, et al. Cardiac and Vascular Surgery-Associated Acute Kidney Injury: The 20th International Consensus Conference of the ADQI (Acute Disease Quality Initiative) Group. J Am Heart Assoc. 2018;7(11):e008834. doi: 10.1161/JAHA.118.008834.
5. Parolari A, Pesce LL, Pacini D, Mazzanti V, Salis S, Sciacovelli C, et al. Risk Factors for Perioperative Acute Kidney Injury after Adult Cardiac Surgery: Role of Perioperative Management. Ann Thorac Surg. 2012;93(2):584-91. doi: 10.1016/j.athoracsur.2011.09.073.
6. Jinadasa SP, Mueller A, Prasad V, Subramaniam K, Heldt T, Novack V, et al. Blood Pressure Coefficient of Variation and Its Association with Cardiac Surgical Outcomes. Anesth Analg. 2018;127(4):832-9. doi: 10.1213/ANE.0000000000003362.
7. Stevens SL, Wood S, Koshiaris C, Law K, Glasziou P, Stevens RJ, et al. Blood Pressure Variability and Cardiovascular Disease: Systematic Review and Meta-Analysis. BMJ. 2016;354:i4098. doi: 10.1136/bmj.i4098.
8. Parati G, Stergiou GS, Dolan E, Bilo G. Blood Pressure Variability: Clinical Relevance and Application. J Clin Hypertens. 2018;20(7):1133-7. doi: 10.1111/jch.13304.
9. Wang Y, Bellomo R. Cardiac Surgery-Associated Acute Kidney Injury: Risk Factors, Pathophysiology and Treatment. Nat Rev Nephrol. 2017;13(11):697-711. doi: 10.1038/nrneph.2017.119.

10. Vives M, Hernandez A, Parramon F, Estanyol N, Pardina B, Muñoz A, et al. Acute Kidney Injury after Cardiac Surgery: Prevalence, Impact and Management Challenges. Int J Nephrol Renovasc Dis. 2019;12:153-66. doi: 10.2147/IJNRD.S167477.

11. Sun LY, Wijeysundera DN, Tait GA, Beattie WS. Association of Intraoperative Hypotension with Acute Kidney Injury after Elective Noncardiac Surgery. Anesthesiology. 2015;123(3):515-23. doi: 10.1097/ALN.0000000000000765.

12. Salmasi V, Maheshwari K, Yang D, Mascha EJ, Singh A, Sessler DI, et al. Relationship between Intraoperative Hypotension, Defined by Either Reduction from Baseline or Absolute Thresholds, and Acute Kidney and Myocardial Injury after Noncardiac Surgery: A Retrospective Cohort Analysis. Anesthesiology. 2017;126(1):47-65. doi: 10.1097/ALN.0000000000001432.

13. Wesselink EM, Kappen TH, Torn HM, Slooter AJC, van Klei WA. Intraoperative Hypotension and the Risk of Postoperative Adverse Outcomes: A Systematic Review. Br J Anaesth. 2018;121(4):706-21. doi: 10.1016/j.bja.2018.04.036.

14. Saito S, Uchino S, Takinami M, Uezono S, Bellomo R. Postoperative Blood Pressure Deficit and Acute Kidney Injury Progression in Vasopressor-Dependent Cardiovascular Surgery Patients. Crit Care. 2016;20:74. doi: 10.1186/s13054-016-1253-1.

15. Feng Y, Wang AY, Jun M, Pu L, Weisbord SD, Bellomo R, et al. Characterization of Risk Prediction Models for Acute Kidney Injury: A Systematic Review and Meta-Analysis. JAMA Netw Open. 2023;6(5):e2313359. doi: 10.1001/jamanetworkopen.2023.13359.

16. Lei VJ, Luong T, Shan E, Chen X, Neuman MD, Eneanya ND, et al. Risk Stratification for Postoperative Acute Kidney Injury in Major Noncardiac Surgery Using Preoperative and Intraoperative Data. JAMA Netw Open. 2019;2(12):e1916921. doi: 10.1001/jamanetworkopen.2019.16921.

17. Johnson AEW, Bulgarelli L, Shen L, Gayles A, Shammout A, Horng S, et al. MIMIC-IV, a Freely Accessible Electronic Health Record Dataset. Sci Data. 2023;10(1):1. doi: 10.1038/s41597-022-01899-x.

18. Quan H, Sundararajan V, Halfon P, Fong A, Burnand B, Luthi JC, et al. Coding Algorithms for Defining Comorbidities in ICD-9-CM and ICD-10 Administrative Data. Med Care. 2005;43(11):1130-9. doi: 10.1097/01.mlr.0000182534.19832.83.

19. Kidney Disease: Improving Global Outcomes (KDIGO) CKD Work Group. KDIGO 2024 Clinical Practice Guideline for the Evaluation and Management of Chronic Kidney Disease. Kidney Int. 2024;105(4S):S117-S314. doi: 10.1016/j.kint.2023.10.018.

20. Mena L, Pintos S, Queipo NV, Aizpúrua JA, Maestre G, Sulbarán T. A Reliable Index for the Prognostic Significance of Blood Pressure Variability. J Hypertens. 2005;23(3):505-11. doi: 10.1097/01.hjh.0000160205.81652.5a.

21. Hansen TW, Thijs L, Li Y, Boggia J, Kikuya M, Björklund-Bodegård K, et al. Prognostic Value of Reading-to-Reading Blood Pressure Variability Over 24 Hours in 8938 Subjects from 11 Populations. Hypertension. 2010;55(4):1049-57. doi: 10.1161/HYPERTENSIONAHA.109.140798.

22. Parati G, Ochoa JE, Lombardi C, Bilo G. Assessment and Management of Blood-Pressure Variability. Nat Rev Cardiol. 2013;10(3):143-55. doi: 10.1038/nrcardio.2013.1.

23. Rothwell PM, Howard SC, Dolan E, O'Brien E, Dobson JE, Dahlöf B, et al. Prognostic Significance of Visit-to-Visit Variability, Maximum Systolic Blood Pressure, and Episodic Hypertension. Lancet. 2010;375(9718):895-905. doi: 10.1016/S0140-6736(10)60308-X.

24. Walsh M, Devereaux PJ, Garg AX, Kurz A, Turan A, Rodseth RN, et al. Relationship between Intraoperative Mean Arterial Pressure and Clinical Outcomes after Noncardiac Surgery: Toward an Empirical Definition of Hypotension. Anesthesiology. 2013;119(3):507-15. doi: 10.1097/ALN.0b013e3182a10e26.

25. Breiman L. Random Forests. Mach Learn. 2001;45:5-32. doi: 10.1023/A:1010933404324.

26. Kohavi R, John GH. Wrappers for Feature Subset Selection. Artif Intell. 1997;97:273-324. doi: 10.1016/S0004-3702(97)00043-X.

27. Chen T, Guestrin C. XGBoost: A Scalable Tree Boosting System. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16); 2016 Aug 13-17; San Francisco, CA, USA. New York: Association for Computing Machinery; 2016. p. 785-794. doi: 10.1145/2939672.293978.

28. Efron B. Machine Learning and the James–Stein Estimator. Jpn J Stat Data Sci. 2024;7:257-66. doi: 10.1007/s42081-023-00209-y.

29. Kohavi R. A Study Of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. In: Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI 1995); 1995 Aug 20-25; Montreal, Canada. San Francisco: Morgan Kaufmann; 1995. p. 1137-1143.

30. Ryan CT, Zeng Z, Chatterjee S, Wall MJ, Moon MR, Coselli JS, et al. Machine Learning for Dynamic and Early Prediction of Acute Kidney Injury after Cardiac Surgery. J Thorac Cardiovasc Surg. 2023;166(6):e551-64. doi: 10.1016/j.jtcvs.2022.09.045.

31. Jiang J, Liu X, Cheng Z, Liu Q, Xing W. Interpretable Machine Learning Models for Early Prediction of Acute Kidney Injury after Cardiac Surgery. BMC Nephrol. 2023;24(1):326. doi: 10.1186/s12882-023-03324-w.

32. Gulamali FF, Sawant AS, Nadkarni GN. Machine Learning for Risk Stratification in Kidney Disease. Curr Opin Nephrol Hypertens. 2022;31(6):548-52. doi: 10.1097/MNH.0000000000000832.

Este é um artigo de acesso aberto distribuído sob os termos da licença de atribuição pelo Creative Commons