



Escola Bahiana de Medicina e Saúde Pública

Curso de Graduação em Medicina

Trabalho de Conclusão de Curso

**INTELIGÊNCIA ESTATÍSTICA VERSUS INTELIGÊNCIA ARTIFICIAL
NA PREDIÇÃO DE EVENTOS EM SÍNDROMES CORONARIANAS AGUDAS**

Autor: Alleh K. S. Nogueira

Orientador: Prof. Dr. Luis C. L. Correia, MD, PhD, MPH

Coorientador: Prof. Dr. Mateus dos S. Viana, MD, PhD

Salvador, Bahia

Outubro de 2022

Alleh K. S. Nogueira

**INTELIGÊNCIA ESTATÍSTICA VERSUS INTELIGÊNCIA ARTIFICIAL
NA PREDIÇÃO DE EVENTOS EM SÍNDROMES CORONARIANAS AGUDAS**

Trabalho de Conclusão de Curso apresentado ao curso de graduação em Medicina da Escola Bahiana de Medicina e Saúde Pública como requisito parcial à obtenção do grau de Médico.

Orientador: Prof. Dr. Luis C. L. Correia,
MD, PhD, MPH

Coorientador: Prof. Dr. Mateus dos S. Viana,
MD, PhD

Salvador, Bahia
Outubro de 2022

Dedico este trabalho a Deus e minha família:
Jaqueline Santana Santos Nogueira,
Sérgio Luis Nogueira,
Ayllah Maryanna M. Santos Nogueira,
que pelo exemplo me ensinaram a maior das lições:

[...] amor não é amor
Se quando encontra obstáculos se altera
Ou se vacila ao mínimo temor.
Amor é um marco eterno, dominante,
Que encara a tempestade com bravura;
É astro que norteia a vela errante
Cujo valor se ignora, lá na altura.
Amor não teme o tempo, muito embora
Seu alfange não poupe a mocidade;
Amor não se transforma de hora em hora,
Antes se afirma, para a eternidade.

Se isto é falso, e que é falso alguém provou,
Eu não sou poeta, e ninguém nunca amou.
(SHAKESPEARE, 1609, Soneto 116)

AGRADECIMENTOS

Estou imensamente satisfeito de ter podido concluir este trabalho e de poder estar aqui hoje, nesta celebração que para mim é menos a de um cumprimento acadêmico que a da conclusão de uma parte, de uma etapa da tarefa que me cabe nesta vida. Direta ou indiretamente, muitos ajudaram-me a realizá-la:

Meus colegas do Registro de Síndromes Coronarianas Agudas, que, no seu mais elevado e ambicioso intuito, facilitaram-me remover os obstáculos mentais que hoje impedem que a racionalidade sensível, a criticidade honesta e a criatividade genuína possam florescer no ecossistema médico-científico.

Meus amigos Isabela Rodrigues, Daniel Lopes, João Almeida, João Porto, João Campos e Marllus Santos, que generosamente colaboraram na concepção, interpretação e revisão do presente estudo, dando-me todo o apoio, além de muitas sugestões valiosas.

Meus mentores, Profs. Luis Claudio L. Correia e Mateus dos Santos Viana, que não só me incentivaram incansável e brilhantemente a desenvolver minhas capacidades, como a saber utilizá-las nas situações mais oportunas — uma arte cujo domínio pleno está além desta vida.

Deus e meus familiares, Sérgio, Jaqueline e Ayllah Nogueira, que sempre me deram tudo em níveis acima do que eu jamais mereceria, e sem os quais nada disso faria sentido.

Essa obra pertence, por afeição e gratidão, um pouco a cada uma dessas pessoas.

Os casos vi que os rudes marinheiros,
Que têm por mestra a longa experiência,
Contam por certos sempre e verdadeiros,
Julgando as cousas só pela aparência,
E os que têm juízos mais inteiros,
Que só por puro engenho e por ciência
Vêem do Mundo os segredos escondidos,
Julgam por falsos ou mal entendidos.

(CAMÕES, Os Lusíadas, Canto V, Estrofe 17)

RESUMO

Referência: NOGUEIRA, A. K. S. **Inteligência Estatística versus Inteligência Artificial na Predição de Eventos em Síndromes Coronarianas Agudas**. Trabalho de Conclusão de Curso (Medicina) – Escola Bahiana de Medicina e Saúde Pública, Salvador, Bahia, 2022.

Fundamento: Modelos de predição clínica estimam a probabilidade de desfechos relevantes, potencializando a tomada de decisão clínica e o cuidado individualizado. Apesar de sua ampla disseminação, desconhece-se se modelos baseados em aprendizado de máquina superam aqueles desenvolvidos a partir de métodos estatísticos usuais, principalmente em cenários de dados tradicionais. **Objetivo:** Testar se o aprendizado de máquina aprimora a predição de desfechos clínicos quando comparado à modelagem estatística tradicional. **Métodos:** Aleatoriamente subdividimos uma coorte prospectiva de pacientes consecutivamente hospitalizados com critérios objetivos de síndrome coronariana aguda. Em 80% da coorte, desenvolvemos modelos baseados tanto em aprendizado de máquina quanto em regressão estatística. Nos 20% restantes, validamos internamente os modelos e os comparamos. **Resultados:** Entre setembro de 2011 e julho de 2019, avaliamos 1.314 pacientes hospitalizados em unidade coronariana intensiva por síndrome coronariana aguda. Treinamos algoritmos de *support vector machine* e *extreme gradient boosting* e estatisticamente ajustamos modelos de regressão logística para prever a ocorrência de eventos cardiovasculares adversos maiores e sangramento maior. Na predição de risco cardiovascular, não houve superioridade dos algoritmos baseados em *support vector machine* (estatística *c* [IC 95%], 0,69 [0,53–0,84] vs. 0,76 [0,64–0,87]; $P = 0,31$) nem daqueles baseados em *extreme gradient boosting* (0,65 [0,47–0,82] vs. 0,76 [0,64–0,87]; $P = 0,08$) quando comparados ao modelo estatístico. Também não houve superioridade de *support vector machine* (0,57 [0,38–0,75] vs. 0,77 [0,61–0,93]; $P = 0,36$) nem de *extreme gradient boosting* (0,67 [0,49–0,86] vs. 0,77 [0,61–0,93]; $P = 0,15$) para predição de sangramento maior. **Conclusão:** O presente estudo sugere que modelos preditivos baseados em aprendizado de máquina não necessariamente superam métodos estatísticos bem estabelecidos, especialmente em coortes epidemiológicas tradicionais.

Palavras-chave: Inteligência artificial; Modelos de predição clínica; Síndrome coronariana aguda

ABSTRACT

Reference: NOGUEIRA, A. K. S. **Statistical Intelligence versus Artificial Intelligence in Predicting Events in Acute Coronary Syndromes**. MD Thesis – Bahiana School of Medicine and Public Health, Salvador, Bahia, 2022.

Background: Clinical prediction models estimate the probability of relevant outcomes, enhancing clinical decision-making and individualized care. Despite its increasingly large dissemination, whether models based on machine learning outperform those developed upon usual statistical methods remains unknown, especially in traditional data settings. **Objective:** To test whether machine learning improves the risk prediction of clinical outcomes when compared to traditional statistical modeling. **Methods:** We randomly split a prospective cohort of consecutively hospitalized patients fulfilling objective criteria for acute coronary syndrome. In 80% of the cohort, we developed models based on both machine learning and statistical regression. For the remaining 20%, we internally validated these models and compared them. **Results:** Between September 2011 and July 2019, we evaluated 1,314 patients hospitalized in a coronary intensive care unit for acute coronary syndrome. We trained support vector machine and extreme gradient boosting algorithms and statistically fit logistic regression models to predict the occurrence of major adverse cardiovascular events and major bleeding. In predicting cardiovascular risk, there was no superiority of support vector machine-based algorithms (c statistic [95% CI], 0.69 [0.53–0.84] vs. 0.76 [0.64–0.87]; $P = 0.31$) nor of extreme gradient boosting (0.65 [0.47–0.82] vs. 0.76 [0.64–0.87]; $P = 0.08$) when compared to the statistical models. We also found no superiority of support vector machine (0.57 [0.38–0.75] vs. 0.77 [0.61–0.93]; $P = 0.36$) and extreme gradient boosting (0.67 [0.49–0.86] vs. 0.77 [0.61–0.93]; $P = 0.15$) for predicting major bleeding. **Conclusion:** The present study suggests that machine learning-based prediction models do not necessarily outperform long-established statistical methods, especially in traditional epidemiological cohort settings.

Keywords: Artificial intelligence; Clinical prediction models; Acute coronary syndrome

SUMÁRIO

1 INTRODUÇÃO	9
2 OBJETIVO	10
3 REVISÃO DE LITERATURA	11
3.1 Síndrome Coronariana Aguda	11
3.2 Modelos de Predição Clínica	12
3.3 Breve Digressão sobre Aprendizado de Máquina	12
4 MÉTODOS	14
4.1 Delineamento e Pacientes do Estudo	14
4.2 Coleta dos Dados e Definição dos Desfechos	14
4.3 Análise dos Dados	15
4.4 Cálculo Amostral	17
5 RESULTADOS	18
5.1 Características dos Pacientes	18
5.2 Desenvolvimento dos Modelos	20
5.3 Desempenhos Preditivos	20
6 DISCUSSÃO	29
6.1 Resultados Principais	29
6.2 Significância do Estudo	29
6.3 Vantagens e Limitações	30
7 CONCLUSÃO	31
ANEXO A — TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO	33
ANEXO B — PARECERES DE APROVAÇÃO DO COMITÊ DE ÉTICA EM PESQUISA	35
APÊNDICE A — CHECKLIST STROBE PARA ESTUDOS DE COORTE	40
APÊNDICE B — CHECKLIST TRIPOD PARA DESENVOLVIMENTO E VALIDAÇÃO DE MODELOS PREDITIVOS	43
APÊNDICE C — FICHA DE COLETA DO REGISTRO DE SÍNDROMES CORONARIANAS AGUDAS	44
APÊNDICE D — DESCRIÇÃO DOS DADOS FALTANTES E RESULTADOS DA IMPUTAÇÃO MÚLTIPLA	76

1 INTRODUÇÃO

Modelos de predição clínica estimam o risco de ocorrer certa doença (modelos diagnósticos) ou suas consequências (modelos prognósticos) a partir de características individuais, permitindo a personalização das decisões médicas.¹⁻³ São úteis sobretudo em condições nas quais o perfil de risco dos pacientes é bastante heterogêneo.³ É o caso da síndrome coronariana aguda, que inclui, em gravidade ascendente, indivíduos com angina instável, infarto sem supradesnível de segmento ST, e infarto com supradesnível de ST.³⁻⁵

A utilidade do modelo reflete seu desempenho preditivo.^{1,6} Apesar de classicamente empregar-se modelagem estatística em predições clínicas,^{1,2} avanços recentes na capacidade computacional e na complexidade dos dados reavivaram o interesse em explorar métodos de aprendizado de máquina.⁷⁻¹⁰ Admite-se que, em teoria, esses métodos superam a modelagem estatística devido à sua maior flexibilidade para se ajustar a padrões complexos de dados.^{7-9,11-14} No entanto, revisões sistemáticas não evidenciaram incremento preditivo, além do que há graves falhas na metodologia e apresentação das comparações entre os métodos.^{2,15}

Em especial, discute-se a existência dessa pretensa vantagem em situações de dados tradicionais — um termo que opõe-se aos cenários de megadados (*big data*) —⁷: em função da menor eficiência, métodos de aprendizado de máquina demandam mais dados para atingir um desempenho satisfatório, contrapesando sua maior flexibilidade em comparação aos métodos estatísticos há muito estabelecidos para desenvolvimento e validação de modelos de predição clínica.¹⁶ Essa preocupação intensifica-se pela paucidade de demonstrações de evidente benefício adicional dos métodos de inteligência artificial em Medicina, apesar de décadas de investigação nesse âmbito.^{2,15} Contudo, persistem o exagero e a euforia em desinformadamente concebê-los como absolutamente úteis ou mesmo superiores a abordagens tradicionais; concepções primariamente movidas pela relativa novidade desses métodos e pelo desconhecimento geral sobre suas capacidades e funcionamento.¹⁷

A teórica superioridade do aprendizado de máquina é, pois, controversa. A partir de uma coorte prospectiva de pacientes consecutivamente hospitalizados com critérios objetivos de síndrome coronariana aguda, testamos se o aprendizado de máquina aprimora a predição de desfechos clínicos quando comparado à modelagem estatística tradicional. Esperamos contribuir para o esclarecimento da sua real utilidade e adequação ao vigente entusiasmo.

2 OBJETIVO

Testar se o aprendizado de máquina aprimora a predição de desfechos clínicos quando comparado à modelagem estatística tradicional.

3 REVISÃO DE LITERATURA

3.1 Síndrome Coronariana Aguda

A cardiopatia isquêmica persiste globalmente como principal causa de morte e incapacidade, onerando demasiadamente os custos humanos e econômicos: estima-se uma perda anual de 9 milhões de vidas e 12% dos anos de vida ajustados para incapacidade¹⁸⁻²⁰; somente nos EUA, o gasto anual atribuível à cardiopatia isquêmica supera US\$ 228 bilhões.^{19,20}

Tipicamente, designamos síndrome coronariana aguda (SCA) a apresentação súbita de cardiopatia isquêmica.^{4,5} A SCA resulta principalmente de trombose coronariana, secundária à ruptura ou erosão de placa aterosclerótica.^{5,21,22} Seu espectro de risco é heterogêneo na medida em que os sintomas isquêmicos podem suceder desde uma angina benigna até um ominoso infarto.^{4,5} Em consequência da vultosa necrose miocárdica, o infarto diferencia-se da angina pela elevação significativa de biomarcadores séricos.^{4,5} Mesmo o prognóstico dos pacientes infartados pode diferir, especialmente, de acordo com a presença de supradesnivelamento do segmento ST à cardioscopia, indicando acometimento transmural da parede cardíaca.^{4,5}

Como pacientes em maior risco cardiovascular beneficiam-se sobretudo de medidas angiográficas e antitrombóticas intensivas, torna-se imprescindível a estratificação de risco em SCA.³⁻⁵ Anteriormente, inferia-se gravidade clínica apenas pela presença de infarto com supradesnível de ST ou por complicações francas, tais como instabilidade elétrica ou hemodinâmica, e refratariedade terapêutica.³⁻⁵ Contudo, uma insigne fração dos pacientes não contemplados nesses critérios também estava em alto risco, potencialmente beneficiando-se de estratégias terapêuticas mais agressivas.³⁻⁵

Modernamente, a implementação de modelos²³⁻²⁵ prognósticos amplamente validados possibilitou a identificação desses indivíduos, revolucionando o manejo da SCA.³⁻⁵ Mais que isso, espera-se que a importância dessas ferramentas aumente no futuro, acompanhando o crescimento na proporção de infartos sem supradesnível de ST.⁵ O que deve-se, em parte, pela tendência secular de redução⁵ do perfil de risco clínico causada por avanços no tratamento farmacológico e benéficas mudanças de estilo de vida em países desenvolvidos, e, em parte, pelo aumento na reclassificação²⁶ de pacientes — outrora erroneamente diagnosticados com angina instável — decorrente da progressiva disseminação de ensaios de troponina ultrasensível.

3.2 Modelos de Predição Clínica

Modelos preditivos são ubiquamente utilizados em Medicina — particularmente em Cardiologia.^{1,2} Essas ferramentas estimam o risco de ocorrer certa doença (modelos diagnósticos) ou suas consequências (modelos prognósticos) a partir de características individuais, permitindo a personalização das decisões médicas.^{2,3} Predições clínicas usualmente empregam técnicas tradicionais de modelagem estatística.^{1,2} Embora já estudados esporadicamente para predição de risco,^{27,28} modelos de aprendizado de máquina alastraram-se exponencialmente nos últimos anos.⁷⁻¹⁰ Recentes avanços técnicos, computacionais e na complexidade dos bancos de dados reavivaram o interesse por essa abordagem.⁷⁻¹⁰

A distinção entre aprendizado de máquina e modelagem estatística é controversa,²⁹ embora largamente discutida.³⁰ Avulta-se, todavia, uma clara divergência: modelos de aprendizado de máquina inferem direta e automaticamente a partir dos dados,³¹ enquanto os tradicionais modelos estatísticos fundamentam-se extensivamente em pressupostos e teorias.⁶ Por tal flexibilidade, o aprendizado de máquina teoricamente superaria a modelagem estatística.^{7-9,11-14} Mas tal prerrogativa não é endossada por revisões sistemáticas abrangentes, que, contudo, incluem bastantes estudos metodologicamente inadequados.^{2,15}

As revisões^{2,15} consentem em três conclusões: (i) quase metade das comparações entre aprendizado de máquina e modelagem estatística tem expressivo risco de viés; (ii) em estudos com baixo risco de viés, o aprendizado de máquina não aprimora predições clínicas quando comparado à modelagem estatística; (iii) não se avaliou a calibração da maioria dos modelos comparados. Ademais, preocupa a possibilidade de que o pretenso benefício da flexibilidade dos modelos de aprendizado de máquina amortize-se pela sua menor eficiência, que em vista disso chegam a ser retratados como “*data hungry*”.¹⁶ Portanto, a alegação de superioridade do aprendizado de máquina para predição clínica é inconsistente.

3.3 Breve Digressão sobre Aprendizado de Máquina

Aprendizado de máquina é um ramo da ciência da computação interessado na construção algorítmica de modelos estatísticos para predição ou reconhecimento de padrões.³¹⁻³⁴ Ele consiste em um tipo de inteligência artificial,³¹⁻³⁴ visto que emula o pensamento humano para resolver problemas práticos — embora a terminologia seja ontologicamente inapropriada na medida em que máquinas não pensam; “treinamento” ou “inferência” de máquina são mais corretos.³⁵

Um modelo típico de aprendizado de máquina constitui-se de três componentes fundamentais³²⁻³⁴: (i) um processo decisório, que delinea uma série de instruções para gerar previsões a partir da análise dos dados; (ii) uma função de erro, que estima estatisticamente a acurácia da previsão comparando-a ao valor observado; (iii) um processo de otimização, que delinea uma série de instruções para atualizar o processo de decisão, (i), de modo a minimizar o erro estimado por (ii). O aumento na acurácia preditiva a partir de sucessivas iterações algorítmicas parodia a forma como aprendemos.

Classicamente, há três tipos de aprendizado de máquina³²⁻³⁴: no aprendizado supervisionado, treina-se um algoritmo de classificação ou previsão a partir de exemplos previamente rotulados; no aprendizado não supervisionado, treina-se um algoritmo de classificação que identifique similaridades e diferenças em um conjunto de exemplos não rotulados; no aprendizado semissupervisionado, combina-se ambos os métodos: primeiro, treina-se um algoritmo de classificação ou agrupamento em um conjunto menor de exemplos rotulados, para, em seguida, utilizá-lo em um conjunto maior de exemplos não rotulados. Tipicamente emprega-se aprendizado supervisionado em previsão clínica.^{2,11,15} Fogem ao nosso escopo técnicas avançadas, tais como aprendizado de reforço e aprendizado profundo.

4 MÉTODOS

4.1 Delineamento e Pacientes do Estudo

Nosso registro de síndrome coronariana aguda (SCA) fora descrito em tantos estudos prévios.³⁶⁻⁴⁷ Brevemente, trata-se de uma coorte prospectiva de pacientes adultos (com idade ≥ 18 anos) consecutivamente hospitalizados em unidade coronariana intensiva entre setembro de 2011 e julho de 2019. Incluímos todos os indivíduos com quadro clínico sugestivo de SCA e que possuíam ao menos um dos seguintes critérios objetivos: (i) injúria miocárdica, definida pela elevação dinâmica dos níveis séricos de cardiotroponinas para acima do percentil 99^{48,49}; (ii) alterações isquêmicas de ST-T em pelo menos duas derivações eletrocardiográficas contíguas⁵⁰; (iii) coronariopatia pregressa, documentada ou por obstrução coronariana $\geq 70\%$ à cineangiocoronariografia em paciente com angina estável, ou por ondas Q patológicas em paciente com história sugestiva de infarto prévio. Pretendendo representar todos os pacientes com SCA, não estabelecemos critérios de exclusão.

Durante todo o estudo, nenhum investigador interferiu em quaisquer decisões clínicas. Obtivemos consentimento por escrito, livre e esclarecido de todo participante no momento da sua admissão (Anexo A). Em conformidade com regulamentações nacionais e internacionais,⁵¹ o comitê de ética em pesquisa local aprovou o protocolo deste estudo sob o certificado n.º 57161016.8.0000.5544 (Anexo B). Descrevemos este estudo segundo recomendações das declarações STROBE⁵² (*STrengthening the Reporting of OBservational studies in Epidemiology*) e TRIPOD⁵³ (*Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis*), vide Apêndices A e B.

4.2 Coleta dos Dados e Definição dos Desfechos

Sob a supervisão de médicos cardiologistas, pesquisadores treinados de nosso grupo coletaram direta e padronizadamente os dados dos pacientes, cuidando para não induzir suas respostas, e subsequentemente armazenando-os *on-line* (Apêndice C). Selecionamos 23 preditores tradicionais de eventos cardiovasculares adversos em SCA: idade, sexo, índice de

massa corpórea, tabagismo, hipertensão arterial sistêmica, diabetes mellitus, dislipidemia, arteriopatia oclusiva periférica, estenose carotídea, doença arterial coronariana (DAC), infarto prévio, história familiar de DAC prematura (em homens < 55 anos ou mulheres < 65 anos com 1 grau de parentesco), doença cerebrovascular, doença renal crônica, uso prévio de salicilato, frequência cardíaca, pressão arterial sistólica, classe de Killip, alterações isquêmicas ao eletrocardiograma, injúria miocárdica, e concentrações séricas de NT-pró-BNP, creatinina e hemoglobina. Derivamos modelos para prever a ocorrência de eventos cardiovasculares adversos maiores⁵⁴ — um composto de morte por todas as causas e reinfarto não fatal — e sangramento maior, definido pelos tipos 3 ou 5 segundo a classificação de BARC⁵⁵ (*Bleeding Academic Research Consortium*).

4.3 Análise dos Dados

Descrevemos variáveis categóricas por frequências absolutas e relativas, e variáveis contínuas por média e desvio padrão, quando normais, ou por mediana e intervalo interquartil, quando não normais. Avaliamos a normalidade combinando inspeção de histograma, cálculo de assimetria e curtose, e inferência pelo teste de Shapiro-Wilk. Estimamos diferenças entre grupos através de teste *t* não pareado, para variáveis contínuas paramétricas; teste *U* de Mann-Whitney, para variáveis contínuas não paramétricas; teste χ^2 , para variáveis categóricas; e teste exato de Fisher, para tabelas 2-por-2. Tratamos dados faltantes mediante imputação de 40 conjuntos de dados com 100 iterações para cada uma, concordantemente a robustas recomendações. Valores de *P* bicaudais inferiores a 0,05 indicam significância estatística. Conduzimos todas as análises pelo R versão 4.1.0 (*R Foundation for Statistical Computing*, Viena, Áustria). Modelos de aprendizado de máquina foram treinados e otimizados utilizando-se a biblioteca caret.⁵⁶

A fim de reproduzir pesquisas anteriores^{57,58} sobre aprendizado de máquina para predição clínica de risco que baseiam-se em eminentes recomendações³², dividimos aleatoriamente a coorte em dois subgrupos, na proporção de 4:1: em 80% dos pacientes, desenvolvemos tanto modelos de aprendizado de máquina quanto de regressão estatística; nos 20% restantes, validamos internamente os modelos e comparamos ambas estratégias de modelagem. Todos os 23 preditores foram incluídos nos modelos baseados em aprendizado de máquina, pois o método não restringe um máximo de preditores conforme a quantidade de desfechos observados.⁵⁹ Em contrapartida, selecionamos os preditores da regressão estatística segundo a

regra⁶⁰ de bolso de 10 desfechos por parâmetro preditor ao incluirmos as variáveis independentes com menor valor de P para associação com o desfecho na análise bivariada.⁶¹

Ajustamos um modelo de regressão logística e dois modelos de aprendizado de máquina para prever cada desfecho. Para escolha do modelo final de regressão, aplicamos um algoritmo *stepwise* com seleção bidirecional das variáveis que fundamentava-se na otimização do critério de informação de Akaike.⁶¹⁻⁶⁴ Utilizamos dois classificadores de aprendizado de máquina: *extreme gradient boosting*⁶⁵ e *support vector machine*⁶⁶. O *support vector machine* é simples, inveterado e bastante utilizado para predição clínica.^{11,32-34,66} Reciprocamente, o *extreme gradient boosting* é método moderno e pouco estabelecido,^{11,32-34,65} mas incluído neste estudo por mérito de evidências^{67,68} de superioridade em relação a outros classificadores. Pragmaticamente escolhemos a função de base radial como núcleo da *support vector machine* porque os dados advém de uma coorte tradicional.⁶⁹ O treino dos modelos de aprendizado de máquina foi otimizado com base em 10 validações cruzadas com 100 iterações para cada uma.^{32,56}

O resultado das regressões foi descrito pela razão de chances para cada preditor, seu respectivo intervalo de confiança e valor de P .^{6,62} No aprendizado de máquina, a importância relativa dos preditores foi expressa pela estimativa dimensionada de desempenho, calculada dividindo-se a estimativa absoluta de desempenho de cada preditor pela estimativa absoluta do preditor mais importante.^{32,56} Estimativas dimensionadas são relativas, variando de 0 a 100 e permitindo uma comparação direta entre a importância dos preditores em diferentes modelos.⁵⁶ Para cada modelo, calculamos estimativas de acurácia prognóstica — sensibilidade (Se), especificidade (Sp), valores preditivos e razões de probabilidade.^{70,71} Determinamos o ponto de corte ótimo (c^*) para classificação dicotômica com base no índice J de Youden, que indica a máxima acurácia efetiva ao integrar sensibilidade e especificidade em uma única medida: $J = \max_c \{Se + Sp - 1\}$.⁷² Diferentemente da sensibilidade e especificidade, os valores preditivos dependem da frequência dos desfechos e podem ser estimados, para qualquer incidência, bayesianamente multiplicando-se a chance do desfecho pela respectiva razão de probabilidade.⁷¹

Avaliamos o desempenho preditivo mediante estimativas de discriminação e calibração. Discriminação é a capacidade do modelo classificar corretamente quem terá ou não o desfecho, mensurada pelo índice de concordância c de Harrell — numericamente igual à área

sob a curva ROC (*Receiver Operator Characteristic*).^{6,62,73} Define-se c como a probabilidade de que o risco de desfecho atribuído a alguém em maior risco supere aquele atribuído a alguém em menor risco.^{6,62,73} A discriminação é perfeita se $c = 1$, nula se $c = 0$, e irrelevante se $c \leq 0,5$.^{6,62,73} Utilizamos os métodos de DeLong para comparar as discriminações entre as estratégias de modelagem.⁷⁴ Corrigimos para múltiplas comparações mediante ajuste de Bonferroni.⁷⁵

Calibração refere-se à concordância entre o risco observado e a predição do modelo.^{6,62,76} Inferimos a calibração média ao longo de toda a coorte, representada pelo intercepto da curva de calibração.⁷⁶ A dispersão das diferenças entre riscos preditos e observados foi estimada pela inclinação da curva de calibração. Idealmente, a curva de calibração é, efetivamente, uma reta com inclinação de 1 que intercepta o eixo y em 0.⁷⁶ Um intercepto negativo indica subestimativa geral do risco, enquanto um intercepto positivo indica superestimativa geral.⁷⁶ Uma inclinação inferior a 1 indica predições extremas, superestimando o risco de pacientes mais propensos a terem desfecho e subestimando o risco daqueles menos propensos; em contrapartida, inclinações acima de 1 indicam predições cálidas.⁷⁶

4.4 Cálculo Amostral

A coorte completou-se antes da concepção deste estudo.³⁶⁻⁴⁷ As incidências de eventos cardiovasculares adversos maiores e sangramento maior foram de 7% e 5%, respectivamente.³⁶⁻⁴⁷ Assumimos que, sob a hipótese nula, as discriminações dos modelos baseados em métodos distintos igualariam-se àquelas de dois escores validados em grandes coortes multicêntricas: o escore GRACE²³ (Global Registry of Acute Coronary Events), com c de 0,73 para predição de morte ou reinfarto não fatal em 6 meses; e o escore CRUSADE⁷⁷ (*Can Rapid risk stratification of Unstable angina patients Suppress ADverse outcomes with Early implementation of the ACC/AHA Guidelines*), com c de 0,71 para predição de sangramento maior. Com base nos métodos de Obuchowski,⁷⁸ concluímos que amostras de 1.017 e 1.047 pacientes seriam necessárias para detectar diferenças de 0,12 e 0,14 entre as estatísticas c para predição de eventos cardiovasculares adversos maiores e sangramento maior, respectivamente, considerando-se um poder estatístico de 0,80 e um nível de significância de 0,05.

5 RESULTADOS

5.1 Características dos Pacientes

Entre setembro de 2011 e julho de 2019, avaliamos prospectivamente 2.026 pacientes com dor torácica aguda. Desses, 1.314 preenchiam critérios para inclusão no Registro de Síndrome Coronariana Aguda (Figura 1). As características clínicas da coorte balancearam-se entre as amostras de desenvolvimento e validação dos modelos (Tabela 1). Demonstramos nas estratificadas pela ocorrência de cada desfecho nas Tabelas 2 e 3. À admissão, predominavam homens (60% [791/1.314]) de meia-idade ou idosos (65 ± 14 anos), sem coronariopatia previamente documentada (60% [793/1.311]), que apresentavam-se sem sinais de insuficiência cardíaca (87% [1.131/1.295]) a despeito evidências de injúria miocárdica (55% [714/1.309]), e isquemia ao eletrocardiograma (54% [706/1.297]). Ocorreram 3,5% (1.156/32.850) de dados faltantes, cuja distribuição detalhamos no Apêndice D junto aos diagnósticos de desempenho da imputação múltipla.

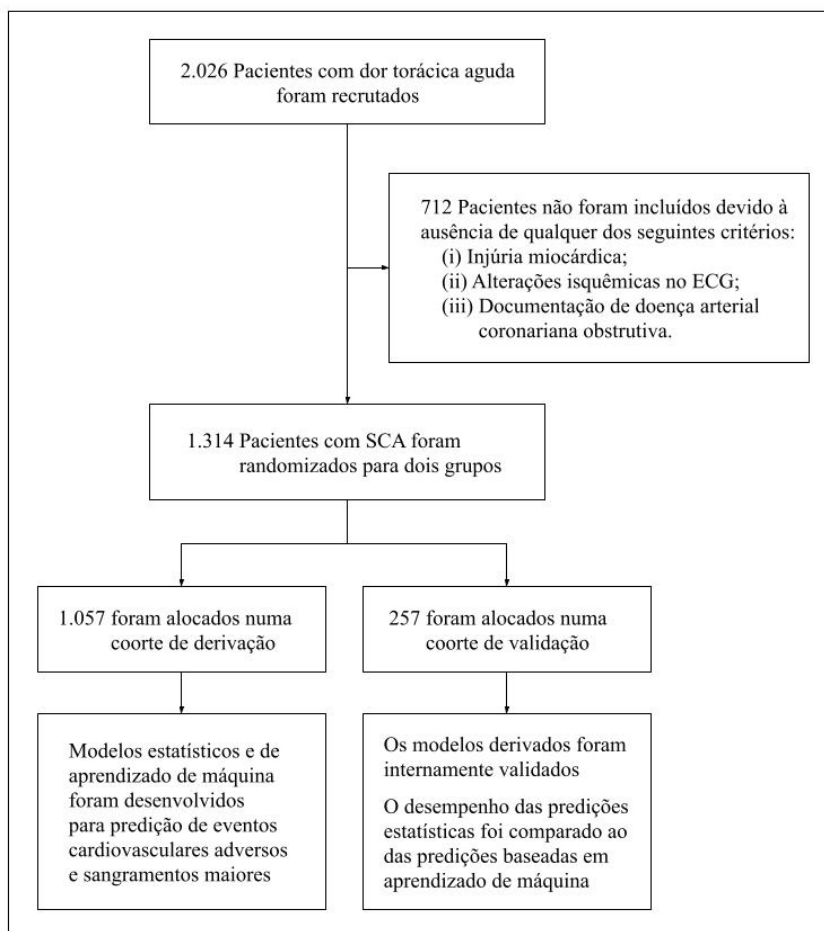


Figura 1. Admissão e Alocação dos Pacientes.

Característica	Derivação (N = 1.057)	Validação (N = 257)	Total (N = 1.314)
Idade média ± DP — anos	65 ± 14	65 ± 13	65 ± 14
Sexo masculino — n/N (%)	633/1.057 (60)	158/257 (61)	791/1.314 (60)
IMC médio ± DP — kg.m ²	27 ± 5,1	27 ± 5,3	27 ± 5,1
Tabagismo atual — n/N (%)	112/1.049 (11)	32/257 (12)	144/1.306 (11)
Dislipidemia — n/N (%)	666/1.049 (63)	162/256 (63)	828/1.305 (63)
Diabetes mellitus — n/N (%)	394/1.050 (38)	105/256 (41)	499/1.306 (38)
Hipertensão arterial sistêmica — n/N (%)	810/1.051 (77)	197/256 (77)	1.007/1.307 (77)
Doença renal crônica — n/N (%)	63/1.045 (6,0)	12/253 (4,7)	75/1.298 (5,8)
Doença arterial periférica — n/N (%)	54/1.042 (5,2)	20/253 (7,9)	74/1.295 (5,7)
Doença arterial carotídea — n/N (%)	76/1.043 (7,3)	16/253 (6,3)	492/1.296 (7,1)
Doença arterial coronariana — n/N (%)	425/1.055 (40)	93/256 (36)	518/1.311 (40)
História familiar de DAC prematura — n/N (%)	266/1.022 (26)	63/253 (25)	329/1.275 (26)
Infarto prévio — n/N (%)	241/1.052 (23)	62/251 (25)	303/1.303 (23)
Acidente vascular encefálico prévio — n/N (%)	91/1.047 (8,7)	26/254 (10)	117/1.301 (9,0)
Uso prévio de AAS — n/N (%)	427/1.042 (41)	103/251 (41)	530/1.293 (41)
Frequência cardíaca média ± DP — bpm	78 ± 18	77 ± 17	78 ± 18
Pressão arterial sistólica média ± DP — mm Hg	154 ± 31	149 ± 33	153 ± 31
Classe de Killip II-IV — n/N (%)	137/1.042 (13)	197/256 (11)	164/1.295 (13)
Alterações isquêmicas no ECG — n/N (%)	580/1.043 (56)	197/256 (50)	706/1.297 (54)
Injúria miocárdica — n/N (%)	579/1.053 (55)	197/256 (53)	714/1.309 (55)
NT pró-BNP mediano (IIQ) — pg.mL ⁻¹	508 (142–1.665)	318 (65–1.184)	451 (123–1.597)
Creatinina mediana (IIQ) — mg.dL ⁻¹	0,90 (0,80–1,2)	1,0 (0,80–1,2)	0,90 (0,80–1,2)
Hemoglobina média ± DP — g.dL ⁻¹	14 ± 1,9	14 ± 1,8	13 ± 1,9

Tabela 1. Características Clínicas à Admissão.

*DP denota desvio padrão; IMC, índice de massa corporal; DAC, doença arterial coronariana; AAS, ácido acetilsalicílico; bpm, batimentos por minuto; ECG, eletrocardiograma; IIQ, intervalo interquartil. Porcentagens podem não totalizar 100 devido ao arredondamento.

5.2 Desenvolvimento dos Modelos

Na coorte de desenvolvimento, ocorreram eventos cardiovasculares adversos maiores e sangramento maior em 73 (7,1%) e 50 (4,7%) pacientes, respectivamente. Sete preditores de eventos cardiovasculares e seis preditores de sangramento foram selecionados para os modelos estatísticos (Tabelas 2 e 3). Os modelos estatísticos finais (Tabela 4) não incluíram doença renal crônica como preditor de eventos cardiovasculares, nem hemoglobina como preditor de sangramento. As Tabelas 5 e 6 expressam a importância relativa dos preditores de cada desfecho dentre os modelos baseados em aprendizado de máquina.

5.3 Desempenhos Preditivos

Na coorte de desenvolvimento, os modelos para predição de eventos cardiovasculares obtiveram as seguintes estatísticas *c*: regressão estatística, 0,80 (intervalo de confiança de 95% [IC 95%], 0,74–0,86); *support vector machine*, 0,99 (IC 95%, 0,98–1,00); *extreme gradient boosting*, 0,95 (IC 95%, 0,93–0,97). Após validação interna dos modelos (Tabela 7), decaíram expressivamente as discriminações tanto da *support vector machine* (*c*, 0,69; IC 95%, 0,53–0,84) quanto do *extreme gradient boosting* (*c*, 0,65; IC 95%, 0,47–0,82); o modelo estatístico mostrou-se mais robusto (*c*, 0,76; IC 95%, 0,64–0,87). Não houve superioridade discriminativa da *support vector machine* ($P = 0,31$) nem do *extreme gradient boosting* ($P = 0,08$) em relação à regressão estatística (Figura 2).

Na predição de sangramento maior (Tabela 7), os modelos produziram as seguintes estatísticas *c* na coorte de desenvolvimento: regressão estatística, 0,83 (IC 95%, 0,77–0,88); *support vector machine*, 1,00 (IC 95%, 1,00–1,00); *extreme gradient boosting*, 1,00 (IC 95%, 1,00–1,00). Também caíram bastante as discriminações tanto da *support vector machine* (*c*, 0,57; IC 95%, 0,38–0,75) quanto do *extreme gradient boosting* (*c*, 0,67; IC 95%, 0,49–0,86), em comparação ao modelo estatístico (*c*, 0,77; IC 95%, 0,61–0,93). Nem a *support vector machine* ($P = 0,36$) nem o *extreme gradient boosting* ($P = 0,15$) superaram o modelo estatístico discriminatoriamente (Figura 2). Em todos os casos, a calibração do modelo estatístico aproximou-se mais do ideal quando comparada àquelas dos modelos baseados em aprendizado de máquina (Tabela 7; Figura 3).

Característica	Eventos Cardiovasculares Adversos Maiores		P
	Ocorreram (N = 73)	Não Ocorreram (N = 947)	
Idade média ± DP — anos	75 ± 14	65 ± 14	< 0,001 †
Sexo masculino — n/N (%)	35/73 (48)	575/947 (61)	0,03
IMC médio ± DP — kg.m ⁻²	28 ± 5,2	27 ± 5,1	0,68
Tabagismo atual — n/N (%)	5/71 (7,0)	104/942 (11)	0,29
Dislipidemia — n/N (%)	50/71 (70)	594/942 (63)	0,21
Diabetes mellitus — n/N (%)	37/72 (51)	343/942 (36)	0,01
Hipertensão arterial sistêmica — n/N (%)	62/72 (86)	724/943 (77)	0,07
Doença renal crônica — n/N (%)	11/71 (15)	51/938 (5,4)	0,003 †
Doença arterial periférica — n/N (%)	6/70 (8,6)	43/936 (4,6)	0,15
Doença arterial carotídea — n/N (%)	7/70 (10)	67/937 (7,2)	0,38
Doença arterial coronariana — n/N (%)	33/73 (45)	377/945 (40)	0,37
História familiar de DAC prematura — n/N (%)	11/66 (17)	244/920 (27)	0,08
Infarto prévio — n/N (%)	19/73 (26)	214/942 (23)	0,52
Acidente vascular encefálico prévio — n/N (%)	11/70 (16)	77/941 (8,2)	0,03
Uso prévio de AAS — n/N (%)	33/70 (47)	375/936 (40)	0,25
Frequência cardíaca média ± DP — bpm	86 ± 21	78 ± 18	0,001 †
Pressão arterial sistólica média ± DP — mm Hg	145 ± 32	154 ± 30	0,04
Classe de Killip II-IV — n/N (%)	30/71 (42)	105/934 (11)	< 0,001 †
Alterações isquêmicas no ECG — n/N (%)	45/71 (63)	512/935 (55)	0,16
Injúria miocárdica — n/N (%)	50/72 (69)	506/944 (54)	0,01
NT pró-BNP mediano (IIQ) — pg.mL ⁻¹	1.971 (274–6.569)	500 (144–1.391)	< 0,001 †
Creatinina mediana (IIQ) — mg.dL ⁻¹	1,1 (0,80–1,5)	0,90 (0,80–1,1)	0,001 †
Hemoglobina média ± DP — g.dL ⁻¹	12 ± 2,3	14 ± 1,9	< 0,001 †

Tabela 2. Preditores de Eventos Cardiovasculares Adversos Maiores Incluídos no Modelo Estatístico.

*DP denota desvio padrão; IMC, índice de massa corporal; DAC, doença arterial coronariana; AAS, ácido acetilsalicílico; bpm, batimentos por minuto; ECG, eletrocardiograma; IIQ, intervalo interquartil. Porcentagens podem não totalizar 100 devido ao arredondamento. †Os preditores das regressões estatísticas foram as variáveis com menor valor de P na associação univariada com cada desfecho. Para cada modelo, o número máximo de preditores foi previamente definido segundo a regra de bolso de 10 eventos por parâmetro predictor.

Característica	Sangramento Maior		P
	Ocorreu (N = 50)	Não Ocorreu (N = 1003)	
Idade média ± DP — anos	76 ± 12	65 ± 14	< 0,001 †
Sexo masculino — n/N (%)	23/50 (46)	607/1,003 (61)	0,04
IMC médio ± DP — kg.m ⁻²	26 ± 4,5	27 ± 5,1	0,30
Tabagismo atual — n/N (%)	4/47 (8,5)	108/999 (11)	0,61
Dislipidemia — n/N (%)	36/48 (75)	628/998 (63)	0,09
Diabetes mellitus — n/N (%)	20/47 (43)	372/1.000 (37)	0,46
Hipertensão arterial sistêmica — n/N (%)	38/48 (79)	769/1.000 (77)	0,72
Doença renal crônica — n/N (%)	5/46 (11)	58/996 (5,8)	0,19
Doença arterial periférica — n/N (%)	8/46 (17)	46/993 (4,6)	0,002
Doença arterial carotídea — n/N (%)	4/46 (8,7)	72/994 (7,2)	0,77
Doença arterial coronariana — n/N (%)	21/49 (43)	403/1.002 (40)	0,71
História familiar de DAC prematura — n/N (%)	10/46 (22)	255/973 (26)	0,50
Infarto prévio — n/N (%)	10/50 (20)	230/998 (23)	0,62
Acidente vascular encefálico prévio — n/N (%)	8/46 (17)	83/998 (8,3)	0,05
Uso prévio de AAS — n/N (%)	24/48 (50)	402/991 (41)	0,19
Frequência cardíaca média ± DP — bpm	87 ± 21	78 ± 18	0,003
Pressão arterial sistólica média ± DP — mm Hg	147 ± 33	154 ± 30	0,07
Classe de Killip II-IV — n/N (%)	20/49 (41)	117/989 (12)	< 0,001 †
Alterações isquêmicas no ECG — n/N (%)	30/48 (62)	550/991 (55)	0,34
Injúria miocárdica — n/N (%)	42/50 (84)	534/1.000 (53)	< 0,001 †
NT pró-BNP mediano (IIQ) — pg.mL ⁻¹	3.381 (750–12.464)	489 (136–1.445)	< 0,001 †
Creatinina mediana (IIQ) — mg.dL ⁻¹	1,1 (0,83–1,4)	0,90 (0,80–1,1)	0,003
Hemoglobina média ± DP — g.dL ⁻¹	12 ± 2,1	14 ± 1,9	< 0,001 †

Tabela 3. Preditores de Sangramento Maior Incluídos no Modelo Estatístico.

*DP denota desvio padrão; IMC, índice de massa corporal; DAC, doença arterial coronariana; AAS, ácido acetilsalicílico; bpm, batimentos por minuto; ECG, eletrocardiograma; IIQ, intervalo interquartil. Porcentagens podem não totalizar 100 devido ao arredondamento. †Os preditores das regressões estatísticas foram as variáveis com menor valor de P na associação univariada com cada desfecho. Para cada modelo, o número máximo de preditores foi previamente definido segundo a regra de bolso de 10 eventos por parâmetro preditor.

Preditor		Razão de Chances Ajustada (IC 95%)	P
<i>De eventos cardiovasculares</i>			
Classe de Killip II-IV		2,6 (2,0–3,3)	0,002
Idade — por ano		1,0 (1,0–1,1)	< 0,001
Frequência cardíaca — a cada bpm		1,0 (1,0–1,0)	0,04
NT pró-BNP — a cada pg.mL ⁻¹		1,0 (1,0–1,0)	0,03
Creatinina — a cada mg.dL ⁻¹		1,0 (0,70–1,30)	0,99
Hemoglobina — a cada g.dL ⁻¹		0,80 (0,70–1,0)	0,01
<i>De sangramento maior</i>			
Injúria miocárdica		3,8 (3,0–4,6)	0,001
Classe de Killip II-IV		2,2 (1,4–2,9)	0,03
Idade — a cada ano		1,0 (1,0–1,1)	< 0,001
NT pró-BNP — a cada pg.mL ⁻¹		1,0 (1,0–1,0)	0,01

Tabela 4. Resultados dos Modelos Estatísticos de Regressão.
 IC 95% denota intervalo de confiança ao nível de 95%.

Desempenho na Predição de Eventos Cardiovasculares †		
Preditor	Support Vector Machine	Extreme Gradient Boosting
NT pró-BNP	95 (49×10^{-3}) ‡	91 (16×10^{-2}) ‡
Idade	70 (36×10^{-3}) ‡	91 (15×10^{-2}) ‡
Classe de Killip II-IV	100 (52×10^{-3}) ‡	47 ($8,1 \times 10^{-2}$) ‡
Hemoglobina	49 (25×10^{-3}) ‡	59 (10×10^{-2}) ‡
IMC	5,8 ($3,0 \times 10^{-3}$)	100 (17×10^{-2}) ‡
Frequência cardíaca	37 (19×10^{-3}) ‡	51 ($8,7 \times 10^{-2}$) ‡
Pressão arterial sistólica	13 ($6,7 \times 10^{-3}$)	59 (10×10^{-2}) ‡
Creatinina	28 (14×10^{-3}) ‡	43 ($7,3 \times 10^{-2}$)
Doença renal crônica	32 (17×10^{-3}) ‡	0 (0×10^{-2})
Sexo masculino	11 ($6,2 \times 10^{-3}$)	6,1 ($1,0 \times 10^{-2}$)
Doença arterial coronariana	1,28 ($0,66 \times 10^{-3}$)	14 ($2,4 \times 10^{-2}$)
Diabetes mellitus	12 ($6,4 \times 10^{-3}$)	2,9 ($0,50 \times 10^{-2}$)
Injúria miocárdica	11 ($5,6 \times 10^{-3}$)	1,55 ($0,26 \times 10^{-2}$)
Hipertensão arterial sistêmica	8,3 ($4,3 \times 10^{-3}$)	3,1 ($0,53 \times 10^{-2}$)
Acidente vascular encefálico prévio	9,4 ($4,9 \times 10^{-3}$)	1,94 ($0,33 \times 10^{-2}$)
Uso prévio de AAS	2,8 ($1,4 \times 10^{-3}$)	8,6 ($1,5 \times 10^{-2}$)
Alterações isquêmicas no ECG	4,4 ($2,3 \times 10^{-3}$)	5,6 ($0,95 \times 10^{-2}$)
História familiar de DAC prematura	6,3 ($3,3 \times 10^{-3}$)	0 (0×10^{-2})
Doença arterial periférica	4,6 ($2,4 \times 10^{-3}$)	0 (0×10^{-2})
Dislipidemia	1,7 ($0,88 \times 10^{-3}$)	2,0 ($0,35 \times 10^{-2}$)
Tabagismo atual	1,4 ($0,71 \times 10^{-3}$)	0 (0×10^{-2})
Doença arterial carotídea	0,91 ($0,47 \times 10^{-3}$)	0 (0×10^{-2})
Infarto prévio	0,38 ($0,19 \times 10^{-3}$)	0 (0×10^{-2})

Tabela 5. Importância dos Preditores de Eventos Cardiovasculares nos Modelos de Aprendizado de Máquina.*

*IMC denota índice de massa corporal; DAC, doença arterial coronariana; AAS, ácido acetilsalicílico; bpm, batimentos por minuto; ECG, eletrocardiograma. †Em cada modelo, apresentamos as estimativas de desempenho dimensionadas de cada preditor. As estimativas dimensionadas são relativas, permitindo a comparação dos desempenhos preditivos entre os modelos, e estão expressas graficamente – azul representa support vector machine; vermelho, extreme gradient boosting. Entre parênteses estão as estimativas brutas de desempenho: R^2 do Loess, para classificadores support vector machine, e "XGBoost importance", para classificadores extreme gradient boosting. As estimativas dimensionadas são obtidas pela divisão da estimativa bruta de cada preditor pela estimativa bruta do preditor mais importante de cada modelo. ‡Destacam-se os sete preditores mais importantes de cada modelo baseado em aprendizado de máquina.

Preditor	Desempenho na Predição de Sangramento Maior †	
	Support Vector Machine	Extreme Gradient Boosting
NT pró-BNP	100 (80 × 10 ⁻³) ‡	100 (21 × 10 ⁻²) ‡
Idade	33 (27 × 10 ⁻³) ‡	53 (11 × 10 ⁻²) ‡
Classe de Killip II-IV	39 (31 × 10 ⁻³) ‡	8,4 (1,8 × 10 ⁻²)
Hemoglobina	18 (14 × 10 ⁻³) ‡	40 (8,3 × 10 ⁻²) ‡
IMC	12 (9,5 × 10 ⁻³)	82 (17 × 10 ⁻²) ‡
Frequência cardíaca	16 (13 × 10 ⁻³) ‡	62 (13 × 10 ⁻²) ‡
Pressão arterial sistólica	3,8 (3,0 × 10 ⁻³)	33 (6,8 × 10 ⁻²) ‡
Creatinina	3,6 (2,9 × 10 ⁻³)	21 (4,5 × 10 ⁻²) ‡
Doença renal crônica	3,8 (3,1 × 10 ⁻³)	0 (0 × 10 ⁻²)
Sexo masculino	4,9 (3,9 × 10 ⁻³)	1,6 (0,33 × 10 ⁻²)
Doença arterial coronariana	0,08 (0,07 × 10 ⁻³)	14 (3,0 × 10 ⁻²)
Diabetes mellitus	0,57 (0,45 × 10 ⁻³)	4,5 (0,93 × 10 ⁻²)
Injúria miocárdica	21 (17 × 10 ⁻³) ‡	21 (4,4 × 10 ⁻²)
Hipertensão arterial sistêmica	0,04 (0,03 × 10 ⁻³)	1,5 (0,32 × 10 ⁻²)
Acidente vascular encefálico prévio	6,7 (5,4 × 10 ⁻³)	3,0 (0,63 × 10 ⁻²)
Uso prévio de AAS	1,4 (1,1 × 10 ⁻³)	4,6 (0,96 × 10 ⁻²)
Alterações isquêmicas no ECG	1,6 (1,3 × 10 ⁻³)	3,4 (0,71 × 10 ⁻²)
História familiar de DAC prematura	0,54 (0,44 × 10 ⁻³)	6,2 (1,3 × 10 ⁻²)
Doença arterial periférica	20 (16 × 10 ⁻³) ‡	6,6 (1,4 × 10 ⁻²)
Dislipidemia	2,0 (1,6 × 10 ⁻³)	4,6 (0,96 × 10 ⁻²)
Tabagismo atual	0,05 (0,04 × 10 ⁻³)	2,7 (0,57 × 10 ⁻²)
Doença arterial carotídea	0,06 (0,05 × 10 ⁻³)	0,35 (0,05 × 10 ⁻²)
Infarto prévio	0,29 (0,24 × 10 ⁻³)	7,8 (1,6 × 10 ⁻²)

Tabela 6. Importância dos Preditores de Sangramento Maior nos Modelos de Aprendizado de Máquina.*

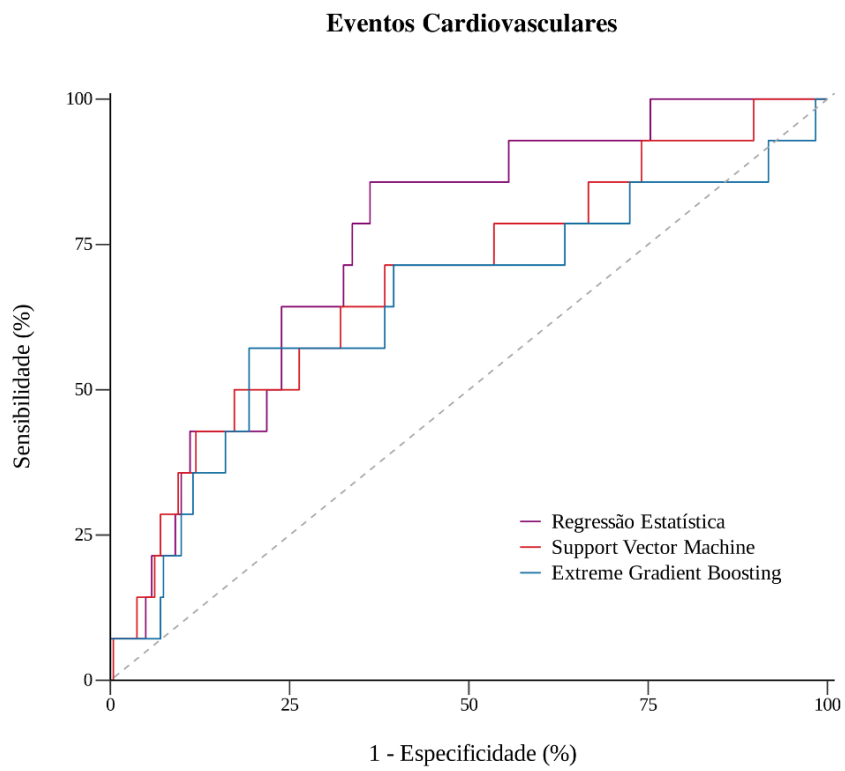
*IMC denota índice de massa corporal; DAC, doença arterial coronariana; AAS, ácido acetilsalicílico; bpm, batimentos por minuto; ECG, eletrocardiograma. †Em cada modelo, apresentamos as estimativas de desempenho dimensionadas de cada preditor. As estimativas dimensionadas são relativas, permitindo a comparação dos desempenhos preditivos entre os modelos, e estão expressas graficamente – azul representa support vector machine; vermelho, extreme gradient boosting. Entre parênteses estão as estimativas brutas de desempenho: R² do Loess, para classificadores support vector machine, e "XGBoost importance", para classificadores extreme gradient boosting. As estimativas dimensionadas são obtidas pela divisão da estimativa bruta de cada preditor pela estimativa bruta do preditor mais importante de cada modelo. ‡Destacam-se os sete preditores mais importantes de cada modelo baseado em aprendizado de máquina.

Métrica de Desempenho*	Regressão Estatística	Support Vector Machine†	Extreme Gradient Boosting‡
<i>Para predição de eventos cardiovasculares</i>			
Discriminação — Estatística <i>c</i>	0,76 (0,64–0,87)	0,69 (0,53–0,84)	0,65 (0,47–0,82)
Dispersão das predições — inclinação de calibração	0,89 (0,34–1,5)	0,76 (1,30–2,1)	0,47 (0,03–0,91)
Calibração média — intercepto de calibração	-0,05 (-0,61–0,50)	-0,24 (-0,78–0,31)	-0,06 (0,64–0,51)
Sensibilidade — %	86 (82–90)	71 (65–77)	57 (51–63)
Especificidade — %	64 (58–70)	62 (56–68)	81 (76–86)
Valor preditivo positivo — %	12 (8,0–16)	10 (6,3–14)	15 (11–19)
Valor preditivo negativo — %	99 (98–100)	97 (95–99)	97 (95–99)
Razão de probabilidades positiva	2,4 (0,52–4,3)	1,9 (0,21–3,5)	3,0 (0,91–5,1)
Razão de probabilidades negativa	0,22 (-0,35–0,79)	0,47 (-0,37–1,3)	0,53 (-0,36–1,4)
<i>Para predição de sangramento maior</i>			
Discriminação — Estatística <i>c</i>	0,77 (0,61–0,93)	0,57 (0,38–0,75)	0,67 (0,49–0,86)
Dispersão das predições — inclinação de calibração	0,94 (0,37–1,52)	0,46 (-0,15–1,07)	1,25 (0,65–1,85)
Calibração média — intercepto de calibração	0,43 (-0,13–0,98)	0,25 (-0,30–0,81)	0,38 (0,06–0,70)
Sensibilidade — %	86 (82–90)	29 (23–35)	57 (51–63)
Especificidade — %	75 (70–80)	94 (91–97)	86 (82–90)
Valor preditivo positivo — %	17 (12–22)	21 (16–26)	19 (14–24)
Valor preditivo negativo — %	99 (98–100)	96 (94–98)	97 (95–99)
Razão de probabilidades positiva	3,4 (1,2–5,7)	4,8 (2,2–7,4)	4,1 (1,7–6,5)
Razão de probabilidades negativa	0,19 (-0,34–0,72)	0,76 (-0,30–1,8)	0,50 (-0,36–1,4)

Tabela 7. Desempenho dos Modelos de Predição Clínica.

*Valores entre parênteses denotam os limites do intervalo de confiança ao nível de 95%. †Support vector machine e extreme gradient boosting são classificadores de aprendizado de máquina. ‡Valores preditivos devem ser interpretados cautelosamente, pois dependem da frequência de desfechos.

A



B

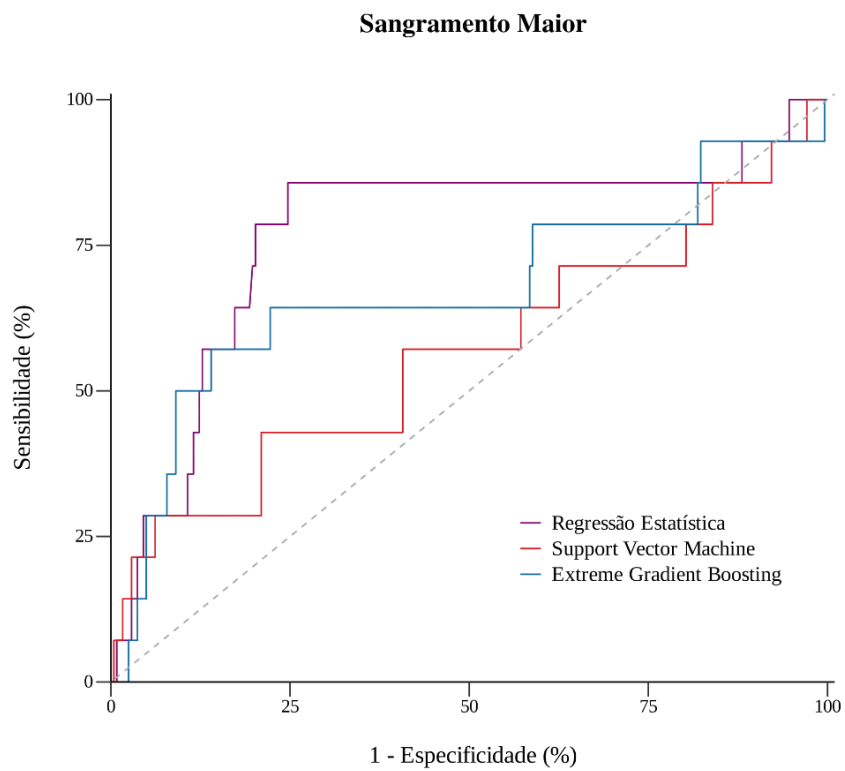
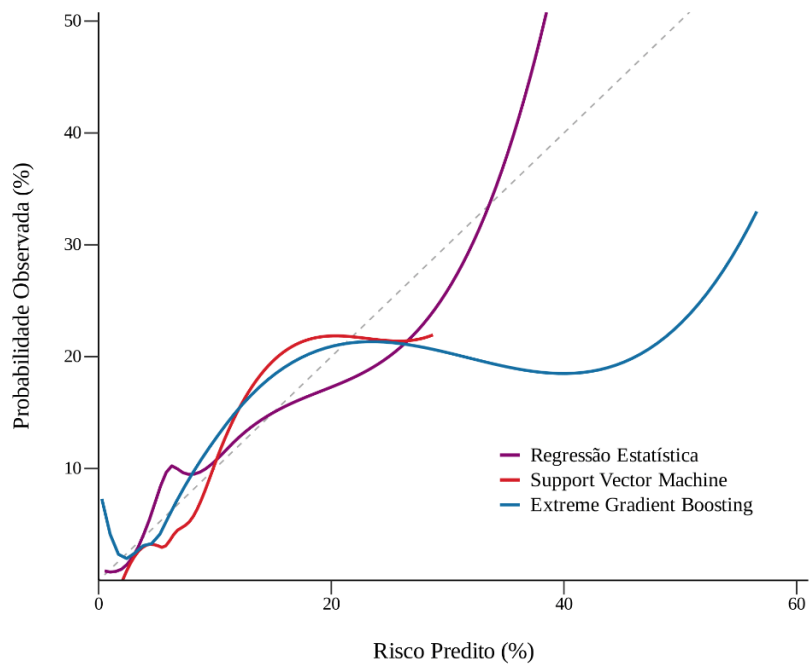
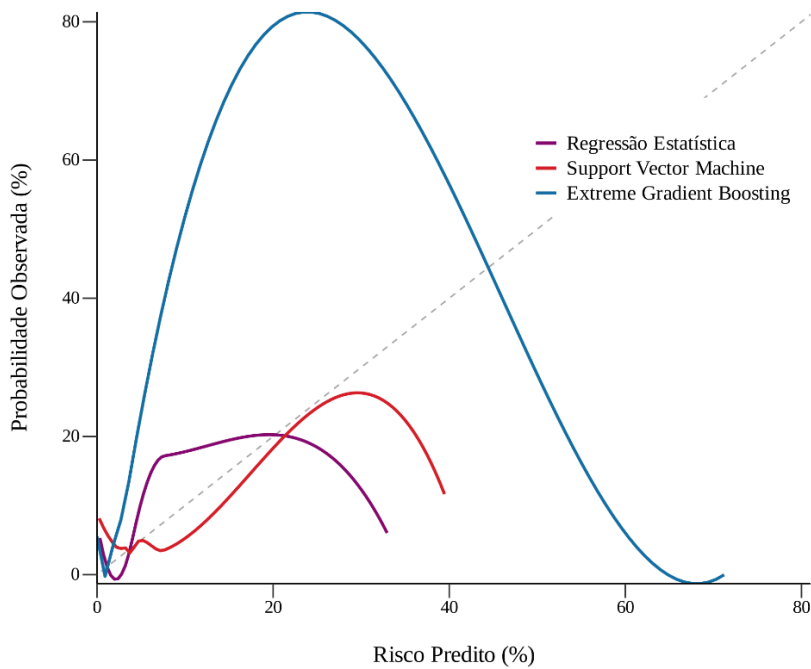


Figura 2. Curvas ROC dos Modelos Preditivos para Cada Desfecho.

A**Eventos Cardiovasculares****B****Sangramento Maior****Figura 3.** Curvas de Calibração dos Modelos Preditivos para Cada Desfecho.

6 DISCUSSÃO

6.1 Resultados Principais

Neste estudo, utilizamos dados de uma tradicional coorte prospectiva de pacientes com síndrome coronariana aguda para desenvolver, validar e comparar modelos prognósticos baseados em aprendizado de máquina e regressão estatística. Encontramos que (mesmo os mais modernos) métodos de aprendizado de máquina não superam a modelagem estatística em desempenho preditivo. Comparações entre coortes de validação e derivação evidenciaram maior sobreajuste dos modelos de aprendizado de máquina, comprometendo sua validade.

6.2 Significância do Estudo

Nossos resultados coadunam-se com duas revisões sistemáticas que compararam diversos algoritmos de aprendizado de máquina à regressão estatística. Após avaliarem 71 estudos em Medicina Geral, Christodoulou et al.² concluíram que o aprendizado de máquina somente supera a tradicional regressão dentre estudos com alto risco de vieses na validação preditiva, além de que $\frac{4}{5}$ dos estudos não descrevem a calibração dos modelos. Song et al.¹⁵ avaliaram 24 estudos em injúria renal aguda e também não demonstraram evidente superioridade do aprendizado de máquina.

Apesar de demonstrações de acurácia,⁷⁹ outras comparações entre aprendizado de máquina e modelagem estatística em coortes tradicionais de síndrome coronariana aguda produziram resultados discordantes. Três estudos^{43,80,81} não atestaram superioridade preditiva do aprendizado de máquina em coortes prospectivas com algumas centenas de pacientes. Embora quatro publicações^{58,82-84} concluíram superioridade do aprendizado de máquina, seus resultados podem ser explicados pelo fenômeno de múltiplas comparações, pois ao confrontarem — sem ajuste para múltiplas comparações — diversos modelos de aprendizado de máquina a um menor número de modelos de regressão, favorecem com que houvesse superioridade do aprendizado de máquina apenas por acaso.^{85,86} Os resultados discordantes de dois^{58,82} desses estudos ainda podem dever-se ao provável sobreajuste⁸⁷ nos modelos de aprendizado, que foram comparados não a regressões originalmente derivadas na própria coorte, mas a escores derivados em outras populações.

Em contrapartida, em cenários de megadados, é provável que modelos baseados em aprendizado de máquina sejam preferíveis às técnicas estatísticas tradicionais,⁷ visto que esses

teoricamente ajustam-se melhor a dados complexos, compensando as exigências de maior tamanho amostral, quantidade e complexidade de preditores. As evidências sustentadas pelas revisões supracitadas não refletem cenários de megadados, limitando suas validades a situações de coortes tradicionais — como a aqui apresentada. Implementações do aprendizado de máquina utilizando 735 preditores de 6.814 pacientes do estudo MESA (*Multi-Ethnic Study of Atherosclerosis*) indicam que tal técnica é promissora quando aplicada em megadados⁸⁸; resultados de estudos similares apontam no mesmo sentido.^{57,89} Nesses casos, métodos de inteligência artificial oferecem vantagens ao gerar previsões mais flexíveis, personalizadas, e em constante e automática atualização.^{7-9,11-14}

Em suma, estudos clínicos em inteligência artificial (IA) frequentemente possuem baixa qualidade metodológica e comunicacional²; portanto, o rigor científico sobre IA tem de evoluir tanto quanto seu escopo e capacidade computacional. Apesar de métodos de IA serem explorados há décadas em Medicina, há poucas demonstrações de evidente benefício adicional.^{2,15} Contudo, persistem o exagero e euforia em concebê-los como absolutamente úteis ou mesmo superiores a abordagens tradicionais devido à sua relativa novidade e à infamiliaridade com seu funcionamento e capacidades.¹⁷

6.3 Vantagens e Limitações

Nosso estudo tem limitações. Primeira, pela coorte ser unicêntrica e alocada em hospital terciário, reduz-se sua representatividade para populações diversas e menos favorecidas. Segunda, o tamanho amostral exíguo não só restringiu a precisão das estimativas de desempenho, mas também com que comparássemos mais estratégias de modelagem preditiva — especialmente, técnicas estatísticas mais modernas, tais como regressão Ridge e Lasso, e outros algoritmos de aprendizado de máquina amplamente utilizados em predição clínica, a exemplo de redes neurais artificiais e k-vizinhos mais próximos. Entretanto, nossos resultados fidedignam-se na medida em que utilizamos uma coorte bem desenhada, ajustamos para múltiplas comparações, e descrevemos transparente e abrangentemente os métodos e resultados das previsões clínicas em conformidade com recomendações internacionais.

7 CONCLUSÃO

O presente estudo demonstra a acurácia preditiva do aprendizado de máquina em coortes de dimensões típicas de estudos epidemiológicos, no entanto sugere que esta modalidade preditiva não é necessariamente superior à técnica estatística tradicional — regressão.

REFERÊNCIAS

1. Wessler BS, Lai YH L, Kramer W, Cangelosi M, Raman G, Lutz JS, et al. Clinical Prediction Models for Cardiovascular Disease: Tufts Predictive Analytics and Comparative Effectiveness Clinical Prediction Model Database. *Circ Cardiovasc Qual Outcomes*. 2015;8:368–75.
2. Christodoulou E, Ma J, Collins GS, Steyerberg EW, Verbakel JY, Van Calster B. A systematic review shows no performance benefit of machine learning over logistic regression for clinical prediction models. *J Clin Epidemiol*. 2019;110:12–22.
3. Timmis A. Coronary disease: Acute coronary syndromes: risk stratification. *Heart*. 2000;83:241–6.
4. Bhatt DL, Lopes RD, Harrington RA. Diagnosis and treatment of acute coronary syndromes: a review. *JAMA*. 2022;327:662–75.
5. Bergmark BA, Mathenge N, Merlini PA, Lawrence-Wright MB, Giugliano RP. Acute coronary syndromes. *The Lancet*. 2022;399:1347–58.
6. Steyerberg EW. Applications of prediction models. In: *Clinical prediction models*. Springer; 2009. p. 11–31.
7. Beam AL, Kohane IS. Big Data and Machine Learning in Health Care. *JAMA*. 2018;319:1317.
8. Chen JH, Asch SM. Machine Learning and Prediction in Medicine — Beyond the Peak of Inflated Expectations. *N Engl J Med*. 2017;376:2507–9.
9. Goldstein BA, Navar AM, Carter RE. Moving beyond regression techniques in cardiovascular risk prediction: applying machine learning to address analytic challenges. *Eur Heart J*. 2016;ehw302.
10. van Smeden M, Heinze G, Van Calster B, Asselbergs FW, Vardas PE, Bruining N, et al. Critical appraisal of artificial intelligence-based prediction models for cardiovascular disease. *Eur Heart J*. 2022;43:2921–30.
11. Deo RC. Machine Learning in Medicine. *Circulation*. 2015;132:1920–30.
12. Pochet NLMM, Suykens JAK. Support vector machines versus logistic regression: improving prospective performance in clinical decision-making. *Ultrasound Obstet Gynecol*. 2006;27:607–8.
13. Rajkomar A, Oren E, Chen K, Dai AM, Hajaj N, Hardt M, et al. Scalable and accurate deep learning with electronic health records. *Npj Digit Med*. 2018;1:18.
14. Luo W, Phung D, Tran T, Gupta S, Rana S, Karmakar C, et al. Guidelines for Developing and Reporting Machine Learning Predictive Models in Biomedical Research: A Multidisciplinary View. *J Med Internet Res*. 2016;18:e323.
15. Song X, Liu X, Liu F, Wang C. Comparison of machine learning and logistic regression models in predicting acute kidney injury: A systematic review and meta-analysis. *Int J Med Inf*. 2021;151:104484.
16. van der Ploeg T, Austin PC, Steyerberg EW. Modern modelling techniques are data hungry: a simulation study for predicting dichotomous endpoints. *BMC Med Res Methodol*. 2014;14:137.
17. Horgan J. Will artificial intelligence ever live up to its hype. *Sci Am*. 2020;
18. Nowbar AN, Gitto M, Howard JP, Francis DP, Al-Lamee R. Mortality from ischemic heart disease: Analysis of data from the World Health Organization and coronary artery disease risk factors From NCD Risk Factor Collaboration. *Circ Cardiovasc Qual Outcomes*. 2019;12:e005375.
19. Vos T, Lim SS, Abbafati C, Abbas KM, Abbasi M, Abbasifard M, et al. Global burden of 369 diseases and injuries in 204 countries and territories, 1990–2019: a systematic

- analysis for the Global Burden of Disease Study 2019. *The Lancet*. 2020;396:1204–22.
20. Tsao CW, Aday AW, Almarzooq ZI, Alonso A, Beaton AZ, Bittencourt MS, et al. Heart disease and stroke statistics—2022 update: a report from the American Heart Association. *Circulation*. 2022;145:e153–639.
 21. Libby P. Molecular bases of the acute coronary syndromes. *Circulation*. 1995;91:2844–50.
 22. Libby P. The changing landscape of atherosclerosis. *Nature*. 2021;592:524–33.
 23. Fox KA, Dabbous OH, Goldberg RJ, Pieper KS, Eagle KA, Van de Werf F, et al. Prediction of risk of death and myocardial infarction in the six months after presentation with acute coronary syndrome: prospective multinational observational study (GRACE). *bmj*. 2006;333:1091.
 24. Antman EM, Cohen M, Bernink PJ, McCabe CH, Horacek T, Papuchis G, et al. The TIMI risk score for unstable angina/non–ST elevation MI: a method for prognostication and therapeutic decision making. *Jama*. 2000;284:835–42.
 25. Morrow DA, Antman EM, Charlesworth A, Cairns R, Murphy SA, de Lemos JA, et al. TIMI risk score for ST-elevation myocardial infarction: a convenient, bedside, clinical score for risk assessment at presentation: an intravenous nPA for treatment of infarcting myocardium early II trial substudy. *Circulation*. 2000;102:2031–7.
 26. Mumma BE, Casey SD, Dang RK, Polen MK, Kaur JC, Rodrigo J, et al. Diagnostic reclassification by a high-sensitivity cardiac troponin assay. *Ann Emerg Med*. 2020;76:566–79.
 27. Kononenko I. Machine learning for medical diagnosis: history, state of the art and perspective. *Artif Intell Med*. 2001;23:89–109.
 28. Lisboa PJ, Taktak AFG. The use of artificial neural networks in decision support in cancer: A systematic review. *Neural Netw*. 2006;19:408–15.
 29. Moons KGM, de Groot JAH, Bouwmeester W, Vergouwe Y, Mallett S, Altman DG, et al. Critical Appraisal and Data Extraction for Systematic Reviews of Prediction Modelling Studies: The CHARMS Checklist. *PLoS Med*. 2014;11:e1001744.
 30. Breiman L. Statistical Modeling: The Two Cultures (with comments and a rejoinder by the author). *Stat Sci [Internet]*. 2001 [cited 2022 Oct 10];16. Available from: <https://projecteuclid.org/journals/statistical-science/volume-16/issue-3/Statistical-Modeling--The-Two-Cultures-with-comments-and-a/10.1214/ss/1009213726.full>
 31. Mitchell TM, Mitchell TM. *Machine learning*. Vol. 1. McGraw-hill New York; 1997.
 32. Hastie T, Tibshirani R, Friedman JH, Friedman JH. *The elements of statistical learning: data mining, inference, and prediction*. Vol. 2. Springer; 2009.
 33. James G, Witten D, Hastie T, Tibshirani R. *An introduction to statistical learning*. Vol. 112. Springer; 2013.
 34. Burkov A. *The hundred-page machine learning book*. Vol. 1. Andriy Burkov Quebec City, QC, Canada; 2019.
 35. Penrose R, Mermin ND. *The emperor’s new mind: Concerning computers, minds, and the laws of physics*. American Association of Physics Teachers; 1990.
 36. Carvalhal MC, Souza TMB de, Suerdieck J, Lopes F, Correia VC de A, Lacerda YF, et al. Behavioral Influence of Known Prognostic Markers on the Cardiologist’s Decision following Acute Coronary Syndrome: the GRACE Score Paradox. *Arq Bras Cardiol*. 2019;112:721–6.
 37. Cerqueira Junior AM dos S, Pereira LG dos S, Souza TMB de, Correia VC de A, Alexandre FKB, Sodr e GS, et al. Prognostic accuracy of the grace score in octogenarians and nonagenarians with acute coronary syndromes. *Arq Bras Cardiol*. 2018;110:24–9.
 38. Correia LC, Sodr e F, Garcia G, Sabino M, Brito M, Kalil F, et al. Relation of severe deficiency of vitamin D to cardiovascular mortality during acute coronary syndromes.

- Am J Cardiol. 2013;111:324–7.
39. Correia LCL, Vasconcelos I, Garcia G, Kalil F, Ferreira F, Silva A, et al. Does C-reactive protein add prognostic value to GRACE score in acute coronary syndromes? *Arq Bras Cardiol.* 2014;102:449–55.
 40. Correia LC, Ferreira F, Kalil F, Silva A, Pereira L, Carvalhal M, et al. Comparison of ACUITY and CRUSADE scores in predicting major bleeding during acute coronary syndrome. *Arq Bras Cardiol.* 2015;105:20–7.
 41. Correia LCL, Cerqueira M, Carvalhal M, Ferreira F, Garcia G, Silva AB da, et al. A Multivariate Model for Prediction of Obstructive Coronary Disease in Patients with Acute Chest Pain: Development and Validation. *Arq Bras Cardiol.* 2017;108:304–14.
 42. Correia LCL, Esteves FP, Carvalhal M, Souza TMB de, Sá N de, Correia VC de A, et al. Zero calcium score as a filter for further testing in patients admitted to the coronary care unit with chest pain. *Arq Bras Cardiol.* 2017;109:97–102.
 43. Correia L, Lopes D, Porto JV, Lacerda YF, Correia VC, Bagano GO, et al. Validation of an Artificial Intelligence Algorithm for Diagnostic Prediction of Coronary Disease: Comparison with a Traditional Statistical Model. *Arq Bras Cardiol.* 2021;117:1061–70.
 44. Filgueiras PHC, Cerqueira Junior AM, Bagano GO, Correia VC de A, Lopes FO de A, Souza TMB de, et al. Does Advanced Age Reduce the Typicality of Clinical Presentation in Patients with Acute Chest Pain Related to Coronary Artery Disease? *Arq Bras Cardiol.* 2021;116:1039–45.
 45. Lacerda YF, Sá NC de, Suerdieck JG, Fonseca L, Lopes F, Sodr e GS, et al. Option for the Radial versus Femoral Access in Coronary Intervention in Acute Coronary Syndromes: A Risk-Treatment Paradox. *Int J Cardiovasc Sci.* 2018;31:562–8.
 46. Souza T, Cerqueira Jr AMS, Suerdieck JG, S a NC de, Sodr e GS, Correia VC, et al. Prognostic Value of NT-proBNP versus Killip Classification in Patients with Acute Coronary Syndromes. *Arq Bras Cardiol.* 2020;114:666–72.
 47. Viana MS, Correia VC, Ferreira FM, Lacerda YF, Bagano GO, Fonseca LL, et al. Prognostic contrast between anatomical and clinical models regarding fatal and non-fatal outcomes in acute coronary syndromes. *Arq Bras Cardiol.* 2020;115:219–25.
 48. ESC Committee for Practice Guidelines (). Third universal definition of myocardial infarction. *J Am Coll Cardiol.* 2012;60:1581–98.
 49. Thygesen K, Alpert JS, Jaffe AS, Chaitman BR, Bax JJ, Morrow DA, et al. Fourth universal definition of myocardial infarction (2018). *J Am Coll Cardiol.* 2018;72:2231–64.
 50. Wagner G, Macfarlane P, Wellens H, Josephson M, Gorgels A, Mirvis D, et al. American Heart Association Electrocardiography and Arrhythmias Committee, Council on Clinical Cardiology. American College of Cardiology Foundation. Heart Rhythm Soc AHAACCFHRS Recomm Stand Interpret Electrocardiogram Part VI Acute Ischemia/infarction Sci Statement Am Heart Assoc Electrocardiogr Arrhythm Comm Counc Clin Cardiol. 2009;1003–11.
 51. General Assembly of the World Medical Association (). World Medical Association Declaration of Helsinki: ethical principles for medical research involving human subjects. *J Am Coll Dent.* 2014;81:14–8.
 52. Von Elm E, Altman DG, Egger M, Pocock SJ, G otzsche PC, Vandenbroucke JP, et al. The Strengthening the Reporting of Observational Studies in Epidemiology (STROBE) statement: guidelines for reporting observational studies. *Ann Intern Med.* 2007;147:573–7.
 53. Collins GS, Reitsma JB, Altman DG, Moons KG. Transparent reporting of a multivariable prediction model for individual prognosis or diagnosis (TRIPOD): the TRIPOD statement. *J Br Surg.* 2015;102:148–58.

54. Bosco E, Hsueh L, McConeghy KW, Gravenstein S, Saade E. Major adverse cardiovascular event definitions used in observational analysis of administrative databases: a systematic review. *BMC Med Res Methodol*. 2021;21:241.
55. Mehran R, Rao SV, Bhatt DL, Gibson CM, Caixeta A, Eikelboom J, et al. Standardized bleeding definitions for cardiovascular clinical trials: a consensus report from the Bleeding Academic Research Consortium. *Circulation*. 2011;123:2736–47.
56. Kuhn M. Building predictive models in R using the caret package. *J Stat Softw*. 2008;28:1–26.
57. D’Ascenzo F, De Filippo O, Gallone G, Mittone G, Deriu MA, Iannaccone M, et al. Machine learning-based prediction of adverse events following an acute coronary syndrome (PRAISE): a modelling study of pooled datasets. *The Lancet*. 2021;397:199–207.
58. VanHouten JP, Starmer JM, Lorenzi NM, Maron DJ, Lasko TA. Machine learning for risk prediction of acute coronary syndrome. *AMIA Annu Symp Proc AMIA Symp*. 2014;2014:1940–9.
59. Hua J, Xiong Z, Lowey J, Suh E, Dougherty ER. Optimal number of features as a function of sample size for various classification rules. *Bioinformatics*. 2005;21:1509–15.
60. Peduzzi P, Concato J, Kemper E, Holford TR, Feinstein AR. A simulation study of the number of events per variable in logistic regression analysis. *J Clin Epidemiol*. 1996;49:1373–9.
61. Heinze G, Wallisch C, Dunkler D. Variable selection—a review and recommendations for the practicing statistician. *Biom J*. 2018;60:431–49.
62. Hosmer Jr DW, Lemeshow S, Sturdivant RX. *Applied logistic regression*. Vol. 398. John Wiley & Sons; 2013.
63. Bozdogan H. Model selection and Akaike’s Information Criterion (AIC): The general theory and its analytical extensions. *Psychometrika*. 1987;52:345–70.
64. Cavanaugh JE, Neath AA. The Akaike information criterion: Background, derivation, properties, application, interpretation, and refinements. *WIREs Comput Stat [Internet]*. 2019 [cited 2022 Oct 10];11. Available from: <https://onlinelibrary.wiley.com/doi/10.1002/wics.1460>
65. 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*. 2016. p. 785–94.
66. Hearst MA, Dumais ST, Osuna E, Platt J, Scholkopf B. Support vector machines. *IEEE Intell Syst Their Appl*. 1998;13:18–28.
67. Ramón A, Torres AM, Milara J, Cascón J, Blasco P, Mateo J. eXtreme Gradient Boosting-based method to classify patients with COVID-19. *J Investig Med*. 2022;70:1472–80.
68. Theerthagiri P. Predictive analysis of cardiovascular disease using gradient boosting based learning and recursive feature elimination technique. *Intell Syst Appl*. 2022;16:200121.
69. Ding X, Liu J, Yang F, Cao J. Random radial basis function kernel-based support vector machine. *J Frankl Inst*. 2021;358:10121–40.
70. Akobeng AK. Understanding diagnostic tests 1: sensitivity, specificity and predictive values. *Acta Paediatr*. 2007;96:338–41.
71. Akobeng AK. Understanding diagnostic tests 2: likelihood ratios, pre-and post-test probabilities and their use in clinical practice. *Acta Paediatr*. 2007;96:487–91.
72. Schisterman EF, Perkins NJ, Liu A, Bondell H. Optimal cut-point and its corresponding Youden Index to discriminate individuals using pooled blood samples. *Epidemiology*.

- 2005;73–81.
73. Uno H, Cai T, Pencina MJ, D’Agostino RB, Wei LJ. On the C-statistics for evaluating overall adequacy of risk prediction procedures with censored survival data. *Stat Med*. 2011;30:1105–17.
 74. DeLong ER, DeLong DM, Clarke-Pearson DL. Comparing the areas under two or more correlated receiver operating characteristic curves: a nonparametric approach. *Biometrics*. 1988;837–45.
 75. Armstrong RA. When to use the Bonferroni correction. *Ophthalmic Physiol Opt*. 2014;34:502–8.
 76. Van Calster B, McLernon DJ, Van Smeden M, Wynants L, Steyerberg EW. Calibration: the Achilles heel of predictive analytics. *BMC Med*. 2019;17:1–7.
 77. Subherwal S, Bach RG, Chen AY, Gage BF, Rao SV, Newby LK, et al. Baseline risk of major bleeding in non–ST-segment–elevation myocardial infarction: the CRUSADE (can rapid risk stratification of unstable angina patients suppress ADverse outcomes with early implementation of the ACC/AHA guidelines) bleeding score. *Circulation*. 2009;119:1873–82.
 78. Obuchowski NA. ROC analysis. *Am J Roentgenol*. 2005;184:364–72.
 79. Iannattone PA, Zhao X, VanHouten J, Garg A, Huynh T. Artificial Intelligence for Diagnosis of Acute Coronary Syndromes: A Meta-analysis of Machine Learning Approaches. *Can J Cardiol*. 2020;36:577–83.
 80. Al-Zaiti S, Besomi L, Bouzid Z, Faramand Z, Frisch S, Martin-Gill C, et al. Machine learning-based prediction of acute coronary syndrome using only the pre-hospital 12-lead electrocardiogram. *Nat Commun*. 2020;11:3966.
 81. Takeda M, Oami T, Hayashi Y, Shimada T, Hattori N, Tateishi K, et al. Prehospital diagnostic algorithm for acute coronary syndrome using machine learning: a prospective observational study. *Sci Rep*. 2022;12:14593.
 82. de Carvalho LSF, Gioppato S, Fernandez MD, Trindade BC, Silva JCQ e, Miranda RGS, et al. Machine Learning Improves the Identification of Individuals With Higher Morbidity and Avoidable Health Costs After Acute Coronary Syndromes. *Value Health*. 2020;23:1570–9.
 83. Juan-Salvadores P, Veiga C, Jiménez Díaz VA, Guitián González A, Iglesia Carreño C, Martínez Reglero C, et al. Using Machine Learning Techniques to Predict MACE in Very Young Acute Coronary Syndrome Patients. *Diagnostics*. 2022;12:422.
 84. Green M, Björk J, Forberg J, Ekelund U, Edenbrandt L, Ohlsson M. Comparison between neural networks and multiple logistic regression to predict acute coronary syndrome in the emergency room. *Artif Intell Med*. 2006;38:305–18.
 85. Austin PC, Mamdani MM, Juurlink DN, Hux JE. Testing multiple statistical hypotheses resulted in spurious associations: a study of astrological signs and health. *J Clin Epidemiol*. 2006;59:964–9.
 86. Bender R, Lange S. Adjusting for multiple testing—when and how? *J Clin Epidemiol*. 2001;54:343–9.
 87. Ying X. An overview of overfitting and its solutions. In: *Journal of physics: Conference series*. IOP Publishing; 2019. p. 022022.
 88. Ambale-Venkatesh B, Yang X, Wu CO, Liu K, Hundley WG, McClelland R, et al. Cardiovascular Event Prediction by Machine Learning: The Multi-Ethnic Study of Atherosclerosis. *Circ Res*. 2017;121:1092–101.
 89. Emakhu J, Monplaisir L, Aguwa C, Arslanturk S, Masoud S, Nassereddine H, et al. Acute coronary syndrome prediction in emergency care: A machine learning approach. *Comput Methods Programs Biomed*. 2022;225:107080.

ANEXO A — TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Termo de Consentimento Livre e Esclarecido – Dor Torácica

Descrição do Estudo

O Serviço de Cardiologia do Hospital São Rafael tem como um de seus objetivos pesquisar as características e acompanhar a evolução dos nossos pacientes, com o objetivo de melhorar o conhecimento sobre as doenças de nosso meio e a qualidade de nossos serviços. Especificamente, o objetivo deste trabalho é identificar características clínicas e laboratoriais que ajudem os médicos a fazer o diagnóstico e prognóstico dos pacientes com dor torácica de possível origem isquêmica. Este tipo de estudo é exclusivamente observacional, não havendo nenhuma interferência na condução clínica que o seu médico estabelecer. O senhor (a) não receberá nenhum tratamento experimental ou deixará de receber nenhum tratamento pelo fato de estar no estudo.

Se o senhor (a) aceitar que seus dados estejam disponíveis para análise no nosso banco de dados, serão coletadas informações do seu prontuário médico e através de entrevistas complementares. O estudo possui uma fase de avaliação após alta hospitalar e o senhor (a) será contactado por um dos membros da equipe, para que possa fornecer informações sobre sua evolução. Depois das análises bioquímicas usuais, ao invés de desprezado, seu sangue será congelado para posteriores dosagem que se tornarem necessárias no protocolo de pesquisa.

Caso você concorde, será realizada uma tomografia de tórax para medida da calcificação coronária, a fim de avaliar a importância clínica dessa informação. Tomografia é um método que traz radiação, sendo que esta modalidade é semelhante à radiação de uma tomografia de crânio, e uma mamografia ou de 10 radiografias do tórax. O risco de prejuízo com esse exame é ínfimo (incidência de neoplasias), mas você pode optar por não realizar mesmo que entre no estudo.

Participação Voluntária

A sua decisão de participar deste estudo clínico é completamente voluntária. Se em qualquer momento ou por qualquer razão senhor (a) decidir não mais participar do estudo, deverá entrar em contato com o coordenador do estudo e o seu registro será imediatamente excluído.

Confidencialidade

As informações médicas obtidas a seu respeito serão confidenciais e estarão disponíveis apenas ao coordenador do estudo, a quem caberá o armazenamento dos dados. A partir de sua inclusão no banco de dados

do estudo você será identificado somente por um número de registro, não havendo, acesso a informações sobre seu nome.

Utilidade das Informações

As informações geradas pelo estudo serão utilizadas em publicações em revistas médicas e apresentação em eventos científicos com o objetivo de expandir os conhecimentos sobre as doenças cardiovasculares. Este estudo não oferece nenhum tipo de remuneração ou outras vantagens diretas aos pacientes participantes ou ao pesquisador.

Aspectos Éticos

O Registro de Pacientes do Serviço de Cardiologia do Hospital São Rafael está eticamente aprovado pelo Comitê de Ética em Pesquisa (segundo as Resoluções 196/96 e 251/97 do Conselho Nacional de Saúde).

Declaração Voluntária de Entendimento e Anuência

Eu li (ou foi lido para mim) as informações sobre o Registro de Pacientes do Serviço de Cardiologia do Hospital São Rafael, tive a oportunidade de fazer perguntas e receber respostas para todas elas e recebi uma cópia deste Termo de Consentimento. Sou livre para sair deste estudo a qualquer momento e esta decisão não irá afetar minha futura assistência médica nesta instituição. Dou meu consentimento voluntário para fazer parte deste estudo clínico.

Salvador, de _____ de 2013

Nome do paciente (ou representante legal): _____


Assinatura: _____

Nome da pessoa que obteve o consentimento: _____

Assinatura da pessoa que obteve o consentimento: _____

Coordenadores: Luís Correia (9971-1032) e Cláudio das Virgens (8802-4246).

ANEXO B — PARECERES DE APROVAÇÃO DO COMITÊ DE ÉTICA EM PESQUISA

	COMUNICAÇÃO INTERNA		Data: 25/07/11
			Nº: 36/11
De: CEP - Comitê de Ética em Pesquisa	Para: Dr. Luis Cláudio Lemos Correia		
Ref. Projeto de Pesquisa Nº 35/11	Pesquisador(a) Responsável		

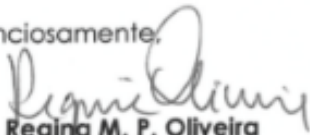
Ref.: Aprovação do Projeto de pesquisa nº 35/11, intitulado "Marcadores de Risco em Síndromes Coronarianas Agudas: Projeto Temático"

Prezado(a) pesquisador(a):

Cumpre-nos cientificá-lo(a) que o estudo supracitado, que tem V.Sª como pesquisador(a) responsável, foi apreciado, na 140ª reunião ordinária do Comitê de Ética em Pesquisa – Monte Tabor / Hospital São Rafael, de 20/07/2011, e considerado **aprovado**.

Reiteramos a necessidade de serem encaminhados os relatórios periódicos, a cada seis meses, a partir da data da aprovação. Caso o projeto seja concluído antes do vencimento de novo período semestral, favor encaminhar o relatório final, o mais breve possível. Estamos à disposição para os esclarecimentos que se fizerem necessários, através do telefone 3281-6484 e 3281-6259 ou pelo e-mail cep@hsr.com.br.

Atenciosamente,


Dra. Regina M. P. Oliveira
Coordenadora do CEP / HSR



ESCOLA BAHIANA DE
MEDICINA E SAÚDE PÚBLICA -
FBDC



PARECER CONSUBSTANCIADO DO CEP

DADOS DA EMENDA

Título da Pesquisa: Frequência do Uso Inapropriado de Pesquisa de Doença Coronariana Obstrutiva em Avaliações Pré-Operatórias para Cirurgias Não Cardíacas.

Pesquisador: Luís C. L. Correia

Área Temática:

Versão: 3

CAAE: 57161016.8.0000.5544

Instituição Proponente: Fundação Bahiana para Desenvolvimento das Ciências - FUNDECI

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 2.030.855

Apresentação do Projeto:

Os autores ressaltam para a importância do uso de recursos apropriados na saúde. Tomam como objeto de estudo o possível uso inadequado de exames para diagnóstico de doença coronariana obstrutiva em pré-operatório de cirurgia não cardíaca.

Objetivo da Pesquisa:

Objetivo Primário:

Descrever a frequência do uso inapropriado de pesquisa pré-operatória de doença coronariana obstrutiva em amostras de conveniência de dois hospitais em Salvador-BA.

Objetivo Secundário:

Identificar os preditores do uso inapropriado de pesquisa pré-operatória de doença coronariana obstrutiva com foco especial no tipo de assistência médica, cobertura pública ou privada.

Endereço: AVENIDA DOM JOÃO VI, 275

Bairro: BROTAS

UF: BA

Município: SALVADOR

Telefone: (71)3276-8225

CEP: 40.290-000

E-mail: cep@bahiana.edu.br



ESCOLA BAHIANA DE
MEDICINA E SAÚDE PÚBLICA -
FBDC



Continuação do Parecer: 2.030.855

Avaliação dos Riscos e Benefícios:

Como risco previsível, vislumbramos apenas a possibilidade de identificação e publicização acidental dos dados obtidos dos prontuários, violando, assim, o direito do participante às suas privacidade e intimidade, risco que será minimizado com a não inclusão dos nomes destes nos bancos de dados, apenas de números de prontuários e letras iniciais dos nomes. Não existe previsão de contato direto com os pacientes pela equipe de pesquisa que se aterá apenas aos prontuários destes.

Os benefícios dizem respeito ao diagnóstico em dois hospitais da cidade do Salvador-BA, um público e outro privado, da frequência de pesquisa inapropriada de doença arterial coronariana em pacientes eletivamente considerados para cirurgias não cardíacas, despertando para a eventual necessidade de mudança de postura institucional no sentido de afastar a prescrição excessiva de exames desnecessários neste elevado grupo de pacientes, evitando gastos financeiros sem efetividade na dispendiosa área de saúde, assim como, aumento dos riscos relativos à realização de exames médicos sem benefícios e do excesso de diagnósticos adicionais que não mudam o prognóstico dos pacientes.

Comentários e Considerações sobre a Pesquisa:

Trata-se de estudo retrospectivo com dados colhidos a partir de prontuários médicos de pacientes submetidos a procedimento cirúrgico em dois hospital de Salvador no ano de 2015. Serão incluídos indivíduos internados no HUPES e no HJV para realização de cirurgias eletivas, submetidos à consulta pré-anestésica com prescrição de avaliação cardiológica pré-operatória, com capacidade funcional (atividades entre 01 e 04 MET são: andar em volta da casa, vestir-se, comer, tomar banho, entre outras atividades diárias. Entre 05 e 09 MET, considera-se subir pelo menos um lance de escada, andar dois quarteirões em passos "rápidos" ou subir uma pequena ladeira; apesar de grande variação individual, a atividade sexual em geral situa-se nesta faixa. Acima de 10 MET está a maior parte dos esportes, como caminhadas e ciclismo, além de determinadas profissões, como pedreiro e estivador) maior ou igual a 04 equivalentes metabólicos (MET), mesmo com a presença de fatores de risco cardíaco cirúrgico (DAC, insuficiência cardíaca (IC) compensada, doença cerebrovascular, diabetes mellitus e insuficiência renal), e programados para cirurgias de pequeno risco (procedimentos endoscópicos, procedimentos superficiais, cirurgia de catarata, cirurgia de mama e cirurgia ambulatorial) e de médio risco (cirurgia intraperitoneal e intratorácica, endarterectomia carotídea, cirurgia de

Endereço: AVENIDA DOM JOÃO VI, 275

Bairro: BROTAS

UF: BA

Telefone: (71)3276-8225

Município: SALVADOR

CEP: 40.290-000

E-mail: cep@bahiana.edu.br

Página 02 de 04



ESCOLA BAHIANA DE
MEDICINA E SAÚDE PÚBLICA -
FBDC



Continuação do Parecer: 2.030.855

cabeça e pescoço, cirurgia ortopédica e cirurgia de próstata).

Na emenda, o pesquisador declara que os dados obtidos serão os sócio-demográficos, o estado físico segundo a ASA, a existência de co-morbidades, a capacidade funcional, o tipo de cirurgia e exames complementares.

Considerações sobre os Termos de apresentação obrigatória:

1. Folha de rosto: totalmente preenchida e assinada pelo responsável institucional;
2. Cronograma: discrimina as fases da pesquisa com início da coleta previsto para agosto de 2017;
3. Orçamento: adequado;
4. Riscos e benefícios: adequados;
5. Cartas de anuência: apresenta anuência das instituições envolvidas no projeto,
6. TCLE: propõe dispensa por ser pesquisa retrospectiva, em prontuário.

Conclusões ou Pendências e Lista de Inadequações:

Após análise bioética da emenda submetida a este protocolo de pesquisa referente a coleta de novas variáveis e inclusão de pesquisador assistente, não identificamos alteração significativa que colocasse em riscos a integridade biopsicosocial dos participantes.

Considerações Finais a critério do CEP:

Atenção : o não cumprimento à Res. 466/12 do CNS abaixo transcrita implicará na impossibilidade de avaliação de novos projetos deste pesquisador.

XI DO PESQUISADOR RESPONSÁVEL

XI.1 - A responsabilidade do pesquisador é indelegável e indeclinável e compreende os aspectos éticos e legais.

XI.2 - Cabe ao pesquisador: a) e b) (...)

- c) desenvolver o projeto conforme delineado;
- d) elaborar e apresentar os relatórios parciais e final;
- e) apresentar dados solicitados pelo CEP ou pela CONEP a qualquer momento;
- f) manter os dados da pesquisa em arquivo, físico ou digital, sob sua guarda e responsabilidade, por um período de 5 anos após o término da pesquisa;
- g) encaminhar os resultados da pesquisa para publicação, com os devidos créditos aos pesquisadores associados e ao pessoal técnico integrante do projeto; e
- h) justificar fundamentadamente, perante o CEP ou a CONEP, interrupção do projeto ou a não publicação dos resultados

Endereço: AVENIDA DOM JOÃO VI, 275

Bairro: BROTAS

UF: BA

Telefone: (71)3276-8225

Município: SALVADOR

CEP: 40.290-000

E-mail: cep@bahiana.edu.br



ESCOLA BAHIANA DE
MEDICINA E SAÚDE PÚBLICA -
FBDC



Continuação do Parecer: 2.030.855

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_880035_E1.pdf	08/04/2017 18:56:33		Aceito
Outros	PROTOCOLO_BAHIANA.pdf	08/04/2017 18:51:03	Antonio Carlos Cerqueira Oliveira	Aceito
Outros	Emenda.pdf	08/04/2017 18:39:49	Antonio Carlos Cerqueira Oliveira	Aceito
Projeto Detalhado / Brochura Investigador	Projeto_Bahiana.pdf	17/08/2016 11:31:49	Antonio Carlos Cerqueira Oliveira	Aceito
Declaração de Instituição e Infraestrutura	UFBA_2.pdf	12/08/2016 11:57:54	Antonio Carlos Cerqueira Oliveira	Aceito
Declaração de Instituição e Infraestrutura	HJV.pdf	03/06/2016 17:12:41	Antonio Carlos Cerqueira Oliveira	Aceito
Declaração de Instituição e Infraestrutura	UFBA.pdf	03/06/2016 17:12:23	Antonio Carlos Cerqueira Oliveira	Aceito
Folha de Rosto	Rosto.pdf	03/06/2016 17:11:15	Antonio Carlos Cerqueira Oliveira	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

SALVADOR, 25 de Abril de 2017

Assinado por:
Roseny Ferreira
(Coordenador)

Endereço: AVENIDA DOM JOÃO VI, 275

Bairro: BROTAS

UF: BA

Município: SALVADOR

Telefone: (71)3276-8225

CEP: 40.290-000

E-mail: cep@bahiana.edu.br

APÊNDICE A — CHECKLIST STROBE PARA ESTUDOS DE COORTE

STROBE Statement—Checklist of items that should be included in reports of *cohort studies*

	Item No	Recommendation	Page No
Title and abstract	1	(a) Indicate the study’s design with a commonly used term in the title or the abstract	6
		(b) Provide in the abstract an informative and balanced summary of what was done and what was found	6
Introduction			
Background/rationale	2	Explain the scientific background and rationale for the investigation being reported	9, 11-13
Objectives	3	State specific objectives, including any prespecified hypotheses	10
Methods			
Study design	4	Present key elements of study design early in the paper	14
Setting	5	Describe the setting, locations, and relevant dates, including periods of recruitment, exposure, follow-up, and data collection	14
Participants	6	(a) Give the eligibility criteria, and the sources and methods of selection of participants. Describe methods of follow-up	14
		(b) For matched studies, give matching criteria and number of exposed and unexposed	NA
Variables	7	Clearly define all outcomes, exposures, predictors, potential confounders, and effect modifiers. Give diagnostic criteria, if applicable	14-15
Data sources/measurement	8*	For each variable of interest, give sources of data and details of methods of assessment (measurement). Describe comparability of assessment methods if there is more than one group	14-15
Bias	9	Describe any efforts to address potential sources of bias	14-15
Study size	10	Explain how the study size was arrived at	17
Quantitative variables	11	Explain how quantitative variables were handled in the analyses. If applicable, describe which groupings were chosen and why	15
Statistical methods	12	(a) Describe all statistical methods, including those used to control for confounding	15-17
		(b) Describe any methods used to examine subgroups and interactions	14-17
		(c) Explain how missing data were addressed	15

		(d) If applicable, explain how loss to follow-up was addressed	NA
		(e) Describe any sensitivity analyses	NA
Results			
Participants	13*	(a) Report numbers of individuals at each stage of study—eg numbers potentially eligible, examined for eligibility, confirmed eligible, included in the study, completing follow-up, and analysed	18
		(b) Give reasons for non-participation at each stage	18
		(c) Consider use of a flow diagram	18
Descriptive data	14*	(a) Give characteristics of study participants (eg demographic, clinical, social) and information on exposures and potential confounders	18-19
		(b) Indicate number of participants with missing data for each variable of interest	19
		(c) Summarise follow-up time (eg, average and total amount)	NA
Outcome data	15*	Report numbers of outcome events or summary measures over time	20

Main results	16	(a) Give unadjusted estimates and, if applicable, confounder-adjusted estimates and their precision (eg, 95% confidence interval). Make clear which confounders were adjusted for and why they were included	23
		(b) Report category boundaries when continuous variables were categorized	23
		(c) If relevant, consider translating estimates of relative risk into absolute risk for a meaningful time period	NA
Other analyses	17	Report other analyses done—eg analyses of subgroups and interactions, and sensitivity analyses	18,20
Discussion			
Key results	18	Summarise key results with reference to study objectives	29
Limitations	19	Discuss limitations of the study, taking into account sources of potential bias or imprecision. Discuss both direction and magnitude of any potential bias	30
Interpretation	20	Give a cautious overall interpretation of results considering objectives, limitations, multiplicity of analyses, results from similar studies, and other relevant evidence	29-30
Generalisability	21	Discuss the generalisability (external validity) of the study results	29-30
Other information			
Funding	22	Give the source of funding and the role of the funders for the present study and, if applicable, for the original study on which the present article is based	NA

*Give information separately for exposed and unexposed groups.

Note: An Explanation and Elaboration article discusses each checklist item and gives methodological background and published examples of transparent reporting. The STROBE checklist is best used in conjunction with this article (freely available on the Web sites of PLoS Medicine at <http://www.plosmedicine.org/>, Annals of Internal Medicine at <http://www.annals.org/>, and Epidemiology at <http://www.epidem.com/>). Information on the STROBE Initiative is available at <http://www.strobe-statement.org>.

APÊNDICE B — CHECKLIST TRIPOD PARA DESENVOLVIMENTO E VALIDAÇÃO DE MODELOS PREDITIVOS



TRIPOD Checklist: Prediction Model Development and Validation

Section/Topic	Item		Checklist Item	Page
Title and abstract				
Title	1	D;V	Identify the study as developing and/or validating a multivariable prediction model, the target population, and the outcome to be predicted.	1
Abstract	2	D;V	Provide a summary of objectives, study design, setting, participants, sample size, predictors, outcome, statistical analysis, results, and conclusions.	6
Introduction				
Background and objectives	3a	D;V	Explain the medical context (including whether diagnostic or prognostic) and rationale for developing or validating the multivariable prediction model, including references to existing models.	9, 11-13
	3b	D;V	Specify the objectives, including whether the study describes the development or validation of the model or both.	10
Methods				
Source of data	4a	D;V	Describe the study design or source of data (e.g., randomized trial, cohort, or registry data), separately for the development and validation data sets, if applicable.	14
	4b	D;V	Specify the key study dates, including start of accrual; end of accrual; and, if applicable, end of follow-up.	14
Participants	5a	D;V	Specify key elements of the study setting (e.g., primary care, secondary care, general population) including number and location of centres.	14
	5b	D;V	Describe eligibility criteria for participants.	14
	5c	D;V	Give details of treatments received, if relevant.	NA
Outcome	6a	D;V	Clearly define the outcome that is predicted by the prediction model, including how and when assessed.	14-15
	6b	D;V	Report any actions to blind assessment of the outcome to be predicted.	NA
Predictors	7a	D;V	Clearly define all predictors used in developing or validating the multivariable prediction model, including how and when they were measured.	14-15
	7b	D;V	Report any actions to blind assessment of predictors for the outcome and other predictors.	NA
Sample size	8	D;V	Explain how the study size was arrived at.	17
Missing data	9	D;V	Describe how missing data were handled (e.g., complete-case analysis, single imputation, multiple imputation) with details of any imputation method.	18
Statistical analysis methods	10a	D	Describe how predictors were handled in the analyses.	15
	10b	D	Specify type of model, all model-building procedures (including any predictor selection), and method for internal validation.	15, 16
	10c	V	For validation, describe how the predictions were calculated.	15, 16
	10d	D;V	Specify all measures used to assess model performance and, if relevant, to compare multiple models.	15-17
	10e	V	Describe any model updating (e.g., recalibration) arising from the validation, if done.	NA
Risk groups	11	D;V	Provide details on how risk groups were created, if done.	NA
Development vs. validation	12	V	For validation, identify any differences from the development data in setting, eligibility criteria, outcome, and predictors.	NA
Results				
Participants	13a	D;V	Describe the flow of participants through the study, including the number of participants with and without the outcome and, if applicable, a summary of the follow-up time. A diagram may be helpful.	18
	13b	D;V	Describe the characteristics of the participants (basic demographics, clinical features, available predictors), including the number of participants with missing data for predictors and outcome.	18
	13c	V	For validation, show a comparison with the development data of the distribution of important variables (demographics, predictors and outcome).	19
Model development	14a	D	Specify the number of participants and outcome events in each analysis.	19-22
	14b	D	If done, report the unadjusted association between each candidate predictor and outcome.	21, 22
Model specification	15a	D	Present the full prediction model to allow predictions for individuals (i.e., all regression coefficients, and model intercept or baseline survival at a given time point).	23
	15b	D	Explain how to use the prediction model.	29-31
Model performance	16	D;V	Report performance measures (with CIs) for the prediction model.	26
Model-updating	17	V	If done, report the results from any model updating (i.e., model specification, model performance).	NA
Discussion				
Limitations	18	D;V	Discuss any limitations of the study (such as nonrepresentative sample, few events per predictor, missing data).	29-31
Interpretation	19a	V	For validation, discuss the results with reference to performance in the development data, and any other validation data.	29
	19b	D;V	Give an overall interpretation of the results, considering objectives, limitations, results from similar studies, and other relevant evidence.	29-31
Implications	20	D;V	Discuss the potential clinical use of the model and implications for future research.	29-31
Other information				
Supplementary information	21	D;V	Provide information about the availability of supplementary resources, such as study protocol, Web calculator, and data sets.	NA
Funding	22	D;V	Give the source of funding and the role of the funders for the present study.	NA

*Items relevant only to the development of a prediction model are denoted by D, items relating solely to a validation of a prediction model are denoted by V, and items relating to both are denoted D;V. We recommend using the TRIPOD Checklist in conjunction with the TRIPOD Explanation and Elaboration document.


APÊNDICE C — FICHA DE COLETA DO REGISTRO DE SÍNDROMES CORONARIANAS AGUDAS

01/03/2020

RESCA/RDT | REDCap

Bahiana School of Medicina and Public Health
Bahiana School of Medicina and Public Health

RESCA/RDT

 Codebook ▾

Data Dictionary Codebook

01.03.2020 18:45

#	Variable / Field Name	Field Label <i>Field Note</i>	Field Attributes (Field Type, Validation, Choices, Calculations, etc.)												
Instrument: RESCA/RDT (rescardt)															
1	record_id	Record ID	text												
2	nome	Nome	text, Required, Identifier												
3	iniciais	Centro	radio <table border="1"> <tr> <td>1</td> <td>Hospital Aliança</td> </tr> </table>	1	Hospital Aliança										
1	Hospital Aliança														
4	registro	Registro	text (number), Required, Identifier												
5	at_uci	At UCI	text (number), Identifier												
6	at_ue	At UE	text (number), Identifier												
7	coleta	Coleta	radio <table border="1"> <tr> <td>0</td> <td>HSR RDT</td> </tr> <tr> <td>1</td> <td>HSR RESCA</td> </tr> <tr> <td>2</td> <td>HSR RDT e RESCA</td> </tr> <tr> <td>3</td> <td>HA RDT</td> </tr> <tr> <td>4</td> <td>HA RESCA</td> </tr> <tr> <td>5</td> <td>HA RDT e RESCA</td> </tr> </table>	0	HSR RDT	1	HSR RESCA	2	HSR RDT e RESCA	3	HA RDT	4	HA RESCA	5	HA RDT e RESCA
0	HSR RDT														
1	HSR RESCA														
2	HSR RDT e RESCA														
3	HA RDT														
4	HA RESCA														
5	HA RDT e RESCA														
8	nascimento	Data de Nascimento	text (date_dmy, Min: 1900-01-01, Max: 3000-12-31), Identifier												
9	idade	Idade	text (number, Min: 0, Max: 200), Required, Identifier												
10	sexo	Sexo	radio, Required, Identifier <table border="1"> <tr> <td>0</td> <td>Feminino</td> </tr> <tr> <td>1</td> <td>Masculino</td> </tr> </table> Custom alignment: RH	0	Feminino	1	Masculino								
0	Feminino														
1	Masculino														

	11	cor	Raça Autorreferida	radio <table border="1"> <tr><td>0</td><td>preto</td></tr> <tr><td>1</td><td>moreno</td></tr> <tr><td>2</td><td>branco</td></tr> <tr><td>3</td><td>amarelo</td></tr> <tr><td>4</td><td>vermelho</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	preto	1	moreno	2	branco	3	amarelo	4	vermelho	9999	9999								
0	preto																							
1	moreno																							
2	branco																							
3	amarelo																							
4	vermelho																							
9999	9999																							
	12	escolaridade	Escolaridade	radio <table border="1"> <tr><td>1</td><td>analfabeto</td></tr> <tr><td>2</td><td>< 1º grau</td></tr> <tr><td>3</td><td>1º grau</td></tr> <tr><td>4</td><td>2º grau</td></tr> <tr><td>5</td><td>3º grau</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	1	analfabeto	2	< 1º grau	3	1º grau	4	2º grau	5	3º grau	9999	9999								
1	analfabeto																							
2	< 1º grau																							
3	1º grau																							
4	2º grau																							
5	3º grau																							
9999	9999																							
	13	escore_de_fragilidade	Escore de Fragilidade	radio <table border="1"> <tr><td>1</td><td>1 (Very Fit)</td></tr> <tr><td>2</td><td>2 (Well)</td></tr> <tr><td>3</td><td>3 (Managing Well)</td></tr> <tr><td>4</td><td>4 (Vulnerable)</td></tr> <tr><td>5</td><td>5 (Mildly Frail)</td></tr> <tr><td>6</td><td>6 (Moderately Frail)</td></tr> <tr><td>7</td><td>7 (Severely Frail - Completely dependent for personal care)</td></tr> <tr><td>8</td><td>8 (Very Severely Frail)</td></tr> <tr><td>9</td><td>9 (Terminally Ill)</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	1	1 (Very Fit)	2	2 (Well)	3	3 (Managing Well)	4	4 (Vulnerable)	5	5 (Mildly Frail)	6	6 (Moderately Frail)	7	7 (Severely Frail - Completely dependent for personal care)	8	8 (Very Severely Frail)	9	9 (Terminally Ill)	9999	9999
1	1 (Very Fit)																							
2	2 (Well)																							
3	3 (Managing Well)																							
4	4 (Vulnerable)																							
5	5 (Mildly Frail)																							
6	6 (Moderately Frail)																							
7	7 (Severely Frail - Completely dependent for personal care)																							
8	8 (Very Severely Frail)																							
9	9 (Terminally Ill)																							
9999	9999																							
	14	data_internamento	Data de Internamento	text (date_dmy, Min: 1900-01-01, Max: 3000-12-31) Custom alignment: RH																				
	15	hora	Hora do Atendimento na Emergência	text																				
	16	data_alta	Data Alta	text (date_dmy, Min: 1900-01-01, Max: 3000-12-31) Custom alignment: RH																				
	17	dias_i	Dias de Internamento	text (number, Min: 1, Max: 1000)																				
	18	tempo_total	Tempo Total de Internamento <i>em horas</i>	text (number)																				
	19	procedencia	Procedência	radio <table border="1"> <tr><td>1</td><td>Emergência</td></tr> <tr><td>2</td><td>Transferência de setor</td></tr> <tr><td>3</td><td>Transferido de hospital</td></tr> </table>	1	Emergência	2	Transferência de setor	3	Transferido de hospital														
1	Emergência																							
2	Transferência de setor																							
3	Transferido de hospital																							

	20	minoca	MINOCA	radio <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> </table> Custom alignment: RH	0	Não	1	Sim								
0	Não															
1	Sim															
	21	diagnostico	Diagnóstico	radio <table border="1"> <tr> <td>0</td> <td>Angina Instável</td> </tr> <tr> <td>1</td> <td>IAM sem EST</td> </tr> <tr> <td>2</td> <td>IAM com EST</td> </tr> <tr> <td>9999</td> <td>Outro</td> </tr> </table>	0	Angina Instável	1	IAM sem EST	2	IAM com EST	9999	Outro				
0	Angina Instável															
1	IAM sem EST															
2	IAM com EST															
9999	Outro															
	22	trombose_de_stent	Trombose de Stent	radio <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Aguda (< 24 horas)</td> </tr> <tr> <td>2</td> <td>Subaguda (1 - 30 dias)</td> </tr> <tr> <td>3</td> <td>Tardia (1 - 12 meses)</td> </tr> <tr> <td>4</td> <td>Muito tardia (> 1 ano)</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Aguda (< 24 horas)	2	Subaguda (1 - 30 dias)	3	Tardia (1 - 12 meses)	4	Muito tardia (> 1 ano)	9999	9999
0	Não															
1	Aguda (< 24 horas)															
2	Subaguda (1 - 30 dias)															
3	Tardia (1 - 12 meses)															
4	Muito tardia (> 1 ano)															
9999	9999															
	23	alteracao_ecg	Section Header: <i>Critério de Inclusão do RESCA</i> Alteração no ECG	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Sim	9999	9999						
0	Não															
1	Sim															
9999	9999															
	24	elevacao_mnm	Elevação de MNM	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Sim	9999	9999						
0	Não															
1	Sim															
9999	9999															
	25	dac_previa	DAC Prévia	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Sim	9999	9999						
0	Não															
1	Sim															
9999	9999															
	26	cate	CATE Obstrutivo	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Sim	9999	9999						
0	Não															
1	Sim															
9999	9999															
	27	peso	Section Header: <i>Apresentação Clínica</i> Peso	text (number) Custom alignment: RH												
	28	alt	Altura	text (number) Custom alignment: RH												
	29	pas	Pressão Arterial Sistólica	text (number)												
	30	pad	Pressão Arterial Diastólica	text (number)												

	31	fc	Frequência Cardíaca	text (number)								
	32	killip	Classificação de Killip	radio <table border="1"> <tr><td>1</td><td>1</td></tr> <tr><td>2</td><td>2</td></tr> <tr><td>3</td><td>3</td></tr> <tr><td>4</td><td>4</td></tr> </table> Custom alignment: RH	1	1	2	2	3	3	4	4
1	1											
2	2											
3	3											
4	4											
	33	tipo_s	Tipo do Sintoma	radio <table border="1"> <tr><td>0</td><td>Equivalente</td></tr> <tr><td>1</td><td>Dor Torácica</td></tr> </table>	0	Equivalente	1	Dor Torácica				
0	Equivalente											
1	Dor Torácica											
	34	data_ini_sint	Data do Início do Sintoma <i>DD-MM-AAAA</i>	text (date_dmy) Custom alignment: RH								
	35	hora_ini_sint	Hora do Início do Sintoma <i>em horas</i>	text Custom alignment: RH								
	36	data_cheg_hosp	Data de Chegada no Hospital <i>DD-MM-AAAA</i>	text (date_dmy) Custom alignment: RH								
	37	hora_cheg_hosp	Hora de Chegada no Hospital <i>em horas</i>	text Custom alignment: RH								
	38	tempo_sp	Tempo Sintoma-Porta <i>em horas</i>	text (number)								
	39	faseaguda	Fase Aguda do IAM <i>< 12 horas do início do sintoma</i>	radio <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Custom alignment: RH	0	Não	1	Sim	9999	9999		
0	Não											
1	Sim											
9999	9999											
	40	pcr_na_add	PCR na Admissão	radio <table border="1"> <tr><td>1</td><td>Sim</td></tr> <tr><td>0</td><td>Não</td></tr> </table> Custom alignment: RH	1	Sim	0	Não				
1	Sim											
0	Não											
	41	sintomatico	Sintomático na Chegada	radio <table border="1"> <tr><td>1</td><td>Sim</td></tr> <tr><td>0</td><td>Não</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	1	Sim	0	Não	9999	9999		
1	Sim											
0	Não											
9999	9999											
	42	dor_prec	Section Header: <i>Características da Dor</i> Dor Precordial	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999		
0	Não											
1	Sim											
9999	9999											

	43	dor_comp	Dor Compressiva	radio (Matrix) 0 Não 1 Sim 9999 9999
	44	int_severa	Intensidade Severa	radio (Matrix) 0 Não 1 Sim 9999 9999
	45	irrad_mse	Irradiação para MSE	radio (Matrix) 0 Não 1 Sim 9999 9999
	46	irrad_pesc	Irradiação para Pescoço	radio (Matrix) 0 Não 1 Sim 9999 9999
	47	alt_pos	Altera com Posição	radio (Matrix) 0 Não 1 Sim 9999 9999
	48	alt_palp	Altera com Palpação	radio (Matrix) 0 Não 1 Sim 9999 9999
	49	mov_braco	Altera com Movimento do Braço	radio (Matrix) 0 Não 1 Sim 9999 9999
	50	sint_vagais	Presença de Sintomas Vagais	radio (Matrix) 0 Não 1 Sim 9999 9999
	51	dor_pleur	Dor Pleurítica	radio (Matrix) 0 Não 1 Sim 9999 9999

	52	melh_nit	Melhora com Nitrato	<table border="1"> <tr><td colspan="2">radio (Matrix)</td></tr> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> <p>Field Annotation: se assintomático na chegada = 9999</p>	radio (Matrix)		0	Não	1	Sim	9999	9999																		
radio (Matrix)																														
0	Não																													
1	Sim																													
9999	9999																													
	53	dias_ant	Desconforto em Dias Anteriores	<table border="1"> <tr><td colspan="2">radio (Matrix)</td></tr> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	radio (Matrix)		0	Não	1	Sim	9999	9999																		
radio (Matrix)																														
0	Não																													
1	Sim																													
9999	9999																													
	54	simi_isq	Similar a Evento Isquêmico Prévio	<table border="1"> <tr><td colspan="2">radio (Matrix)</td></tr> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	radio (Matrix)		0	Não	1	Sim	9999	9999																		
radio (Matrix)																														
0	Não																													
1	Sim																													
9999	9999																													
	55	prod_vir	Pródromo Viral	<table border="1"> <tr><td colspan="2">radio (Matrix)</td></tr> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	radio (Matrix)		0	Não	1	Sim	9999	9999																		
radio (Matrix)																														
0	Não																													
1	Sim																													
9999	9999																													
	56	intensidade_referida	Intensidade Referida 0 - 10	<table border="1"> <tr><td colspan="2">radio</td></tr> <tr><td>9999</td><td>9999</td></tr> <tr><td>0</td><td>0</td></tr> <tr><td>1</td><td>1</td></tr> <tr><td>2</td><td>2</td></tr> <tr><td>3</td><td>3</td></tr> <tr><td>4</td><td>4</td></tr> <tr><td>5</td><td>5</td></tr> <tr><td>6</td><td>6</td></tr> <tr><td>7</td><td>7</td></tr> <tr><td>8</td><td>8</td></tr> <tr><td>9</td><td>9</td></tr> <tr><td>10</td><td>10</td></tr> </table>	radio		9999	9999	0	0	1	1	2	2	3	3	4	4	5	5	6	6	7	7	8	8	9	9	10	10
radio																														
9999	9999																													
0	0																													
1	1																													
2	2																													
3	3																													
4	4																													
5	5																													
6	6																													
7	7																													
8	8																													
9	9																													
10	10																													
	57	atividade_sintoma	Atividade no Início do Sintoma	<table border="1"> <tr><td colspan="2">radio</td></tr> <tr><td>1</td><td>Repouso Vigil</td></tr> <tr><td>2</td><td>Sono</td></tr> <tr><td>3</td><td>Atividade Física</td></tr> <tr><td>4</td><td>Atividade Sexual</td></tr> <tr><td>5</td><td>Emoção</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	radio		1	Repouso Vigil	2	Sono	3	Atividade Física	4	Atividade Sexual	5	Emoção	9999	9999												
radio																														
1	Repouso Vigil																													
2	Sono																													
3	Atividade Física																													
4	Atividade Sexual																													
5	Emoção																													
9999	9999																													

	58	n_dor	Número de Episódios	text (number)								
	59	dur_dor	Maior Duração do Episódio <i>em horas</i>	text (number)								
	60	forte_dor	Duração do Episódio Mais Forte <i>em minutos</i>	text (number)								
	61	autopercepcao	Section Header: <i>Impressão do Paciente</i> Autopercepção da Dor	radio <table border="1"> <tr> <td>9999</td> <td>9999</td> </tr> <tr> <td>0</td> <td>Outra</td> </tr> <tr> <td>1</td> <td>Infarto</td> </tr> </table>	9999	9999	0	Outra	1	Infarto		
9999	9999											
0	Outra											
1	Infarto											
	62	auto_probabilidade	Probabilidade de Infarto	radio <table border="1"> <tr> <td>9999</td> <td>9999</td> </tr> <tr> <td>0</td> <td>Baixa Probabilidade</td> </tr> <tr> <td>1</td> <td>Moderada Probabilidade</td> </tr> <tr> <td>2</td> <td>Alta Probabilidade</td> </tr> </table>	9999	9999	0	Baixa Probabilidade	1	Moderada Probabilidade	2	Alta Probabilidade
9999	9999											
0	Baixa Probabilidade											
1	Moderada Probabilidade											
2	Alta Probabilidade											
	63	conhece_diagnostico	Já Conhece o Diagnóstico?	radio <table border="1"> <tr> <td>9999</td> <td>9999</td> </tr> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> </table>	9999	9999	0	Não	1	Sim		
9999	9999											
0	Não											
1	Sim											
	64	tabagismo_atual	Section Header: <i>Antecedentes Médicos</i> Tabagismo Atual	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Sim	9999	9999		
0	Não											
1	Sim											
9999	9999											
	65	tabagismo_passado	Tabagismo Passado	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Sim	9999	9999		
0	Não											
1	Sim											
9999	9999											
	66	sedentarismo	Sedentarismo	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table> Field Annotation: < 3x/semana	0	Não	1	Sim	9999	9999		
0	Não											
1	Sim											
9999	9999											
	67	dm	DM	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Sim	9999	9999		
0	Não											
1	Sim											
9999	9999											
	68	has	HAS	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Sim	9999	9999		
0	Não											
1	Sim											
9999	9999											

	69	dislipidemia	Dislipidemia	radio (Matrix) 0 Não 1 Sim 9999 9999
	70	dac	DAC prévia	radio (Matrix) 0 Não 1 Sim 9999 9999
	71	avc_prev	AVC prévio	radio (Matrix) 0 Não 1 Sim 9999 9999
	72	icc	ICC	radio (Matrix) 0 Não 1 Sim 9999 9999
	73	doenca_carotidea	Doença Carotídea	radio (Matrix) 0 Não 1 Sim 9999 9999
	74	arterio_peri	Arteriopatia Periférica	radio (Matrix) 0 Não 1 Sim 9999 9999
	75	iam	IAM	radio (Matrix) 0 Não 1 Sim 9999 9999
	76	stent	Passado de stent	radio (Matrix) 0 Não 1 Sim 9999 9999
	77	icp_stent_conv	ICP - stent convecional	radio (Matrix) 0 Não 1 Sim 9999 9999

	78	icp_stent_farm	ICP - stent farmacológico	radio (Matrix) 0 Não 1 Sim 9999 9999
	79	icp_stent_desc	ICP - stent desconhecido	radio (Matrix) 0 Não 1 Sim 9999 9999
	80	crm	CRM	radio (Matrix) 0 Não 1 Sim 9999 9999
	81	hf_dac	HF DAC	radio (Matrix) 0 Não 1 Sim 9999 9999
	82	sangramento	Sangramento prévio	radio (Matrix) 0 Não 1 Sim 9999 9999
	83	infeccao	Infecção recente (≤ 3 meses)	radio (Matrix) 0 Não 1 Sim 9999 9999
	84	neoplasia	Neoplasia	radio (Matrix) 0 Não 1 Sim 9999 9999
	85	hipotireoidismo	Hipotireoidismo	radio (Matrix) 0 Não 1 Sim 9999 9999
	86	irc	IRC	radio (Matrix) 0 Não 1 Sim 9999 9999

	87	dialise	Diálise	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Sim	9999	9999				
0	Não													
1	Sim													
9999	9999													
	88	menopausa	Menopausa	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Sim	9999	9999				
0	Não													
1	Sim													
9999	9999													
	89	trh	TRH	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Não	1	Sim	9999	9999				
0	Não													
1	Sim													
9999	9999													
	90	plantonista	Section Header: <i>Plantonista</i> Nome do plantonista	text										
	91	conheciacate	Plantonista conhecia CATE?	radio <table border="1"> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>2</td> <td>Não</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table> Custom alignment: RH	1	Sim	2	Não	9999	9999				
1	Sim													
2	Não													
9999	9999													
	92	probdac	Probabilidade de DAC	text Custom alignment: RH										
	93	prob3grupos	Probabilidade de DAC por grupo de risco	radio <table border="1"> <tr> <td>0</td> <td>Baixa</td> </tr> <tr> <td>1</td> <td>Moderada</td> </tr> <tr> <td>2</td> <td>Alta</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table> Custom alignment: RH	0	Baixa	1	Moderada	2	Alta	9999	9999		
0	Baixa													
1	Moderada													
2	Alta													
9999	9999													
	94	tipodador	Tipo da dor	radio <table border="1"> <tr> <td>0</td> <td>A</td> </tr> <tr> <td>1</td> <td>B</td> </tr> <tr> <td>2</td> <td>C</td> </tr> <tr> <td>3</td> <td>D</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table> Custom alignment: RH	0	A	1	B	2	C	3	D	9999	9999
0	A													
1	B													
2	C													
3	D													
9999	9999													

	95	tipicidade	Tipicidade da dor	radio <table border="1"> <tr> <td>0</td> <td>atípica</td> </tr> <tr> <td>1</td> <td>típica</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table> Custom alignment: RH	0	atípica	1	típica	9999	9999										
0	atípica																			
1	típica																			
9999	9999																			
	96	ecg	Section Header: <i>Eletrocardiograma</i> Eletrocardiograma	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>Normal</td> </tr> <tr> <td>1</td> <td>Onda T invertida</td> </tr> <tr> <td>2</td> <td>Infra de ST</td> </tr> <tr> <td>3</td> <td>Supra de ST</td> </tr> <tr> <td>4</td> <td>BRE</td> </tr> <tr> <td>5</td> <td>MP</td> </tr> <tr> <td>6</td> <td>ARV</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Normal	1	Onda T invertida	2	Infra de ST	3	Supra de ST	4	BRE	5	MP	6	ARV	9999	9999
0	Normal																			
1	Onda T invertida																			
2	Infra de ST																			
3	Supra de ST																			
4	BRE																			
5	MP																			
6	ARV																			
9999	9999																			
	97	ecg_isq	ECG Isquêmico	radio <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table> Custom alignment: RH	0	Não	1	Sim	9999	9999										
0	Não																			
1	Sim																			
9999	9999																			
	98	mutabilidade	Mutabilidade	radio <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table> Custom alignment: RH	0	Não	1	Sim	9999	9999										
0	Não																			
1	Sim																			
9999	9999																			
	99	magnitude	Magnitude	text (number) Custom alignment: RH																
	100	paredes_acomet	Parede acometida	radio <table border="1"> <tr> <td>1</td> <td>Anterior</td> </tr> <tr> <td>2</td> <td>Lateral</td> </tr> <tr> <td>3</td> <td>Inferior</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table> Custom alignment: RH	1	Anterior	2	Lateral	3	Inferior	9999	9999								
1	Anterior																			
2	Lateral																			
3	Inferior																			
9999	9999																			

101	zei	ZEI	radio <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Anterior</td></tr> <tr><td>2</td><td>Lateral</td></tr> <tr><td>3</td><td>Inferior</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Anterior	2	Lateral	3	Inferior	9999	9999
0	Não												
1	Anterior												
2	Lateral												
3	Inferior												
9999	9999												
102	parede_ant_iamcsst	Parede anterior IAMSSST <i>parede anterior acometida no iam sem supra</i>	radio <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Custom alignment: RH	0	Não	1	Sim	9999	9999				
0	Não												
1	Sim												
9999	9999												
103	num_paredes_acomet	Número de paredes acometidas	text (number) Custom alignment: RH										
104	supra_difuso	Supra de ST Difuso	radio <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Custom alignment: RH	0	Não	1	Sim	9999	9999				
0	Não												
1	Sim												
9999	9999												
105	supra_avr	Supra em AVR	radio <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Custom alignment: RH	0	Não	1	Sim	9999	9999				
0	Não												
1	Sim												
9999	9999												
106	tsintsang	Section Header: <i>Exames Laboratoriais</i> Tempo sintoma primeira coleta	text Custom alignment: RH										
107	tempo_d_d	Tempo Sintoma - D-Dímero	text (number) Custom alignment: RH										
108	tempo_cholest	Tempo Sintoma - Colesterol	text (number) Custom alignment: RH										
109	tni1	Troponina I (admissão) <i>< 0,012 = 0</i>	text (number)										
110	tnip	Pico da Troponina I	text (number)										
111	deltapicotni	Delta Tni <i>pico - admissão</i>	text (number)										
112	mbjo1	CK-MB (admissão)	text (number)										
113	mbjop	Pico da CK-MB	text (number)										
114	creata	Creatinina (admissão)	text (number)										
115	creatp	Pico da Creatinina	text (number)										
116	glica	Glicemia da Emergência	text (number)										

117	hb1	Hb (admissão)	text (number)										
118	hbnadir	Nadir da Hb	text (number)										
119	plaqad	Plaquetas (admissão) <i>add três zeros</i>	text (number)										
120	plaqnadir	Nadir das Plaquetas <i>add três zeros</i>	text (number)										
121	ct1	Colesterol Total	text (number)										
122	hdl1	HDL	text (number)										
123	ldl1	LDL	text (number)										
124	tg1	Triglicerídeos	text (number)										
125	leuco_ad	Leucócitos <i>multiplica por 1000</i>	text (number)										
126	neut_ad	Neutrófilos	text (number)										
127	baso_ad	Basófilos	text (number)										
128	eos_ad	Eosinófilos	text (number)										
129	linf_tip_ad	Linfócitos	text (number)										
130	ddimero	D-Dímero	text (number)										
131	probnb	Pro-BNP <i>se < 20, colocar 0</i>	text (number)										
132	pcruss	PCR-UNF <i>se > 15, colocar 15</i>	text (number)										
133	funcao_sistolica	Section Header: <i>Ecocardiograma</i> Função Sistólica	radio (Matrix) <table border="1"> <tr><td>0</td><td>Normal</td></tr> <tr><td>1</td><td>Disfunção Leve</td></tr> <tr><td>2</td><td>Disfunção Moderada</td></tr> <tr><td>3</td><td>Disfunção Grave</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Normal	1	Disfunção Leve	2	Disfunção Moderada	3	Disfunção Grave	9999	9999
0	Normal												
1	Disfunção Leve												
2	Disfunção Moderada												
3	Disfunção Grave												
9999	9999												
134	funcao_diastolica	Função Diastólica	radio (Matrix) <table border="1"> <tr><td>0</td><td>Normal</td></tr> <tr><td>1</td><td>Disfunção Leve</td></tr> <tr><td>2</td><td>Disfunção Moderada</td></tr> <tr><td>3</td><td>Disfunção Grave</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Normal	1	Disfunção Leve	2	Disfunção Moderada	3	Disfunção Grave	9999	9999
0	Normal												
1	Disfunção Leve												
2	Disfunção Moderada												
3	Disfunção Grave												
9999	9999												
135	contratilidade_seg	Contratilidade Segmentar	radio <table border="1"> <tr><td>0</td><td>Sem Alteração</td></tr> <tr><td>1</td><td>Alteração Segmentar da Contratilidade</td></tr> <tr><td>2</td><td>Alteração Difusa da Contratilidade</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Sem Alteração	1	Alteração Segmentar da Contratilidade	2	Alteração Difusa da Contratilidade	9999	9999		
0	Sem Alteração												
1	Alteração Segmentar da Contratilidade												
2	Alteração Difusa da Contratilidade												
9999	9999												
136	fe	Fração de Ejeção	text (number)										

	137	metodo	Método	radio <table border="1"> <tr> <td>0</td> <td>Simpson</td> </tr> <tr> <td>1</td> <td>Teichholz</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Simpson	1	Teichholz	9999	9999		
0	Simpson											
1	Teichholz											
9999	9999											
	138	diamae	Diâmetro do AE	text (number)								
	139	volae	Volume do AE	text (number)								
	140	teste_ergometrico	Section Header: <i>Teste Isquêmico</i> Teste Ergométrico	radio (Matrix) <table border="1"> <tr> <td>9999</td> <td>9999</td> </tr> <tr> <td>0</td> <td>Normal</td> </tr> <tr> <td>1</td> <td>Pouco Positivo</td> </tr> <tr> <td>2</td> <td>Muito Positivo</td> </tr> </table>	9999	9999	0	Normal	1	Pouco Positivo	2	Muito Positivo
9999	9999											
0	Normal											
1	Pouco Positivo											
2	Muito Positivo											
	141	eco_estresse	Eco Estresse	radio (Matrix) <table border="1"> <tr> <td>9999</td> <td>9999</td> </tr> <tr> <td>0</td> <td>Normal</td> </tr> <tr> <td>1</td> <td>Pouco Positivo</td> </tr> <tr> <td>2</td> <td>Muito Positivo</td> </tr> </table>	9999	9999	0	Normal	1	Pouco Positivo	2	Muito Positivo
9999	9999											
0	Normal											
1	Pouco Positivo											
2	Muito Positivo											
	142	cintilograf	Cintilografia	radio (Matrix) <table border="1"> <tr> <td>9999</td> <td>9999</td> </tr> <tr> <td>0</td> <td>Normal</td> </tr> <tr> <td>1</td> <td>Pouco Positivo</td> </tr> <tr> <td>2</td> <td>Muito Positivo</td> </tr> </table>	9999	9999	0	Normal	1	Pouco Positivo	2	Muito Positivo
9999	9999											
0	Normal											
1	Pouco Positivo											
2	Muito Positivo											
	143	resutcsc	Tomografia	radio (Matrix) <table border="1"> <tr> <td>9999</td> <td>9999</td> </tr> <tr> <td>0</td> <td>Normal</td> </tr> <tr> <td>1</td> <td>Pouco Positivo</td> </tr> <tr> <td>2</td> <td>Muito Positivo</td> </tr> </table>	9999	9999	0	Normal	1	Pouco Positivo	2	Muito Positivo
9999	9999											
0	Normal											
1	Pouco Positivo											
2	Muito Positivo											
	144	rnm_perf	RNM de Perfusão	radio (Matrix) <table border="1"> <tr> <td>9999</td> <td>9999</td> </tr> <tr> <td>0</td> <td>Normal</td> </tr> <tr> <td>1</td> <td>Pouco Positivo</td> </tr> <tr> <td>2</td> <td>Muito Positivo</td> </tr> </table>	9999	9999	0	Normal	1	Pouco Positivo	2	Muito Positivo
9999	9999											
0	Normal											
1	Pouco Positivo											
2	Muito Positivo											
	145	estrategia_sca_sem_supra	Section Header: <i>SCA sem Supra de ST</i> Estratégia SCA sem supra	radio <table border="1"> <tr> <td>0</td> <td>Conservadora</td> </tr> <tr> <td>1</td> <td>Invasiva</td> </tr> <tr> <td>6666</td> <td>Não se aplica</td> </tr> </table>	0	Conservadora	1	Invasiva	6666	Não se aplica		
0	Conservadora											
1	Invasiva											
6666	Não se aplica											

146	indiccate	Section Header: <i>Coronariografia</i> Indicação do CATE	radio <table border="1"> <tr> <td>0</td> <td>Não indicado CATE</td> </tr> <tr> <td>1</td> <td>CAT seria indicado, porém impossibilidade clínica de realizar</td> </tr> <tr> <td>2</td> <td>CAT indicado, porém paciente se recusou</td> </tr> <tr> <td>3</td> <td>Houve CAT</td> </tr> </table>	0	Não indicado CATE	1	CAT seria indicado, porém impossibilidade clínica de realizar	2	CAT indicado, porém paciente se recusou	3	Houve CAT						
0	Não indicado CATE																
1	CAT seria indicado, porém impossibilidade clínica de realizar																
2	CAT indicado, porém paciente se recusou																
3	Houve CAT																
147	tempopcat	Tempo Porta-CATE	text (number)														
148	tempo_sc	Tempo Sintoma-CATE	text														
149	obstr	Variáveis de Obstrução	radio <table border="1"> <tr> <td>0</td> <td>Normal</td> </tr> <tr> <td>1</td> <td>Obstrução < 50%</td> </tr> <tr> <td>2</td> <td>Obstrução 50-70%</td> </tr> <tr> <td>3</td> <td>Obstrução > 70%</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Normal	1	Obstrução < 50%	2	Obstrução 50-70%	3	Obstrução > 70%	9999	9999				
0	Normal																
1	Obstrução < 50%																
2	Obstrução 50-70%																
3	Obstrução > 70%																
9999	9999																
150	padraocate	Padrão do CATE	radio <table border="1"> <tr> <td>0</td> <td>Uniarterial</td> </tr> <tr> <td>1</td> <td>Biarterial</td> </tr> <tr> <td>2</td> <td>Triarterial</td> </tr> <tr> <td>3</td> <td>TCE sem CD</td> </tr> <tr> <td>4</td> <td>TCE + CD</td> </tr> <tr> <td>5</td> <td>Normal</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	Uniarterial	1	Biarterial	2	Triarterial	3	TCE sem CD	4	TCE + CD	5	Normal	9999	9999
0	Uniarterial																
1	Biarterial																
2	Triarterial																
3	TCE sem CD																
4	TCE + CD																
5	Normal																
9999	9999																
151	catagudo	Número de Artérias Acometidas de Forma Aguda no CATE <i>verificar artérias angioplastadas pelo evento agudo</i>	radio <table border="1"> <tr> <td>0</td> <td>0</td> </tr> <tr> <td>1</td> <td>1</td> </tr> <tr> <td>2</td> <td>2</td> </tr> <tr> <td>3</td> <td>3</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table> Custom alignment: RH	0	0	1	1	2	2	3	3	9999	9999				
0	0																
1	1																
2	2																
3	3																
9999	9999																
152	tce	TCE	radio <table border="1"> <tr> <td>0</td> <td>Não</td> </tr> <tr> <td>1</td> <td>Sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table> Custom alignment: RH	0	Não	1	Sim	9999	9999								
0	Não																
1	Sim																
9999	9999																

153	pontmioc	Ponte Miocárdica	radio <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Custom alignment: RH	0	Não	1	Sim	9999	9999				
0	Não												
1	Sim												
9999	9999												
154	reestst	Reestenose Intrastent	radio <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Custom alignment: RH	0	Não	1	Sim	9999	9999				
0	Não												
1	Sim												
9999	9999												
155	hb_pre_cate	Hb pré-CATE	text (number) Custom alignment: RH										
156	hb_pos_cate	Hb pós-CATE 1 dia após o CATE	text (number) Custom alignment: RH										
157	creat_pre_cate	Creatinina pré-CATE	text (number) Custom alignment: RH										
158	creat_pos_cate	Creatinina pós-CATE 2 dias após o CATE	text (number) Custom alignment: RH										
159	acesso	Acesso	radio <table border="1"> <tr><td>0</td><td>Femoral</td></tr> <tr><td>1</td><td>Radial</td></tr> <tr><td>2</td><td>Braquial</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Femoral	1	Radial	2	Braquial	9999	9999		
0	Femoral												
1	Radial												
2	Braquial												
9999	9999												
160	icp	Section Header: ICP ICP	radio <table border="1"> <tr><td>0</td><td>não houve ICP</td></tr> <tr><td>1</td><td>houve ICP</td></tr> </table>	0	não houve ICP	1	houve ICP						
0	não houve ICP												
1	houve ICP												
161	indica_icp	Indicação ICP	radio <table border="1"> <tr><td>0</td><td>não indicado</td></tr> <tr><td>1</td><td>indicado mas com impossibilidade clínica</td></tr> <tr><td>2</td><td>indicado mas com impossibilidade anatômica</td></tr> <tr><td>3</td><td>indicado mas recusado</td></tr> <tr><td>4</td><td>houve ICP</td></tr> </table>	0	não indicado	1	indicado mas com impossibilidade clínica	2	indicado mas com impossibilidade anatômica	3	indicado mas recusado	4	houve ICP
0	não indicado												
1	indicado mas com impossibilidade clínica												
2	indicado mas com impossibilidade anatômica												
3	indicado mas recusado												
4	houve ICP												

162	tempo_cate_icp Show the field ONLY if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	Tempo CATE-ICP <i>em horas</i>	text (number)								
163	icp_art_culp Show the field ONLY if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	ICP arteria culpada	radio <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>ICP da artéria culpada pelo evento agudo</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	ICP da artéria culpada pelo evento agudo	9999	9999		
0	não										
1	ICP da artéria culpada pelo evento agudo										
9999	9999										
164	icp_comp Show the field ONLY if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	ICP completa	radio <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>ICP de todas as lesões ≥ 70% ou ≥ 50% do TCE</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	ICP de todas as lesões ≥ 70% ou ≥ 50% do TCE	9999	9999		
0	não										
1	ICP de todas as lesões ≥ 70% ou ≥ 50% do TCE										
9999	9999										
165	num_art_abord Show the field ONLY if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	Número de artérias abordadas	text (number)								
166	tipo_de_icp Show the field ONLY if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	Tipo de ICP	radio <table border="1"> <tr> <td>0</td> <td>balão</td> </tr> <tr> <td>1</td> <td>stent convencional</td> </tr> <tr> <td>2</td> <td>stent farmacológico</td> </tr> <tr> <td>9999</td> <td>não</td> </tr> </table>	0	balão	1	stent convencional	2	stent farmacológico	9999	não
0	balão										
1	stent convencional										
2	stent farmacológico										
9999	não										
167	tropo_i_pre_icp Show the field ONLY if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	Troponina I pré-ICP	text (number)								

168	tropo_i_p_s_icp Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	Troponina I pós-ICP	text (number)
169	ck_mb_johnson_pre Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	CK-Mb pré-ICP	text (number)
170	ck_mb_johnson_p_s_icp Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	CK-MB pós-ICP	text (number)
171	hb_pre_icp Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	Hb pré-ICP	text (number)
172	hb_pos_icp Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	Hb pós-ICP <i>1 dia após a angioplastia</i>	text (number)
173	plaq_pre_icp Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'	Plaquetas pré-ICP <i>add três zeros</i>	text (number)

174	<p>plaq_pos_icp</p> <p>Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'</p>	<p>Plaquetas pós-ICP <i>add três zeros</i></p>	text (number)						
175	<p>crea_pre_icp</p> <p>Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'</p>	<p>Creatinina pré-ICP</p>	text (number)						
176	<p>crea_pos_icp</p> <p>Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'</p>	<p>Creatinina pós-ICP <i>2 dias após a angioplastia</i></p>	text (number)						
177	<p>iam_p_s_icp</p> <p>Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'</p>	<p>IAM pós-ICP <i>se diagnóstico for IAM EST = 9999</i></p>	<p>radio</p> <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	sim	9999	9999
0	não								
1	sim								
9999	9999								
178	<p>iam_enzi_pos_icp</p> <p>Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'</p>	<p>IAM Enzimático pós-ICP <i>se diagnóstico for IAM EST = 9999</i></p>	<p>radio</p> <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	sim	9999	9999
0	não								
1	sim								
9999	9999								
179	<p>iam_onda_q_icp</p> <p>Show the field ONL Y if: [indica_icp] = '4' or [indica_icp] = '3' or [indica_icp] = '2' or [indica_icp] = '1' or [indica_icp] = '0'</p>	<p>IAM com onda Q pós-ICP</p>	<p>radio</p> <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	sim	9999	9999
0	não								
1	sim								
9999	9999								

180	houve_rm	Section Header: <i>Revascularização Miocárdica</i> Houve RM	radio <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>sim</td> </tr> </table> Field Annotation: data:	0	não	1	sim						
0	não												
1	sim												
181	indica_o_rm	Indicação da RM	radio <table border="1"> <tr> <td>0</td> <td>não indicado</td> </tr> <tr> <td>1</td> <td>indicado mas com impossibilidade clínica</td> </tr> <tr> <td>2</td> <td>indicado mas com impossibilidade anatômica</td> </tr> <tr> <td>3</td> <td>indicado mas recusado</td> </tr> <tr> <td>4</td> <td>houve RM</td> </tr> </table>	0	não indicado	1	indicado mas com impossibilidade clínica	2	indicado mas com impossibilidade anatômica	3	indicado mas recusado	4	houve RM
0	não indicado												
1	indicado mas com impossibilidade clínica												
2	indicado mas com impossibilidade anatômica												
3	indicado mas recusado												
4	houve RM												
182	crm_completa Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	CRM completa	radio <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	sim	9999	9999				
0	não												
1	sim												
9999	9999												
183	num_mam_rias Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	Número de mamas	text (number)										
184	num_sanfenas Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	Número de safenas	text (number)										
185	usou_cec Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	Usou CEC	radio <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	sim	9999	9999				
0	não												
1	sim												
9999	9999												
186	usou_clopidogrel Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	Uso do Clopidogrel	radio <table border="1"> <tr> <td>0</td> <td>suspensão</td> </tr> <tr> <td>1</td> <td>mantido</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	suspensão	1	mantido	9999	9999				
0	suspensão												
1	mantido												
9999	9999												
187	clopidogrel_dias_suspensa Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	Clopidogrel quantos dias suspensão	text (number)										

188	uso_ticagrelor Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	Uso do ticagrelor	radio <table border="1"> <tr> <td>0</td> <td>suspensão</td> </tr> <tr> <td>1</td> <td>mantido</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	suspensão	1	mantido	9999	9999
0	suspensão								
1	mantido								
9999	9999								
189	ticagrelor_dias_suspensão Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	Ticagrelor dias suspensão	text (number)						
190	uso_aas Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	Uso do AAS	radio <table border="1"> <tr> <td>0</td> <td>suspensão</td> </tr> <tr> <td>1</td> <td>mantido</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	suspensão	1	mantido	9999	9999
0	suspensão								
1	mantido								
9999	9999								
191	aas_dias_suspensão Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	AAS quantos dias suspensão	text (number)						
192	iam_pos_crm	Section Header: <i>Desfechos pós CRM</i> IAM pós-CRM	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	sim	9999	9999
0	não								
1	sim								
9999	9999								
193	iam_onda_q	IAM Onda Q pós-CRM	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	sim	9999	9999
0	não								
1	sim								
9999	9999								
194	iam_enzima	IAM Enzimático pós-CRM	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	sim	9999	9999
0	não								
1	sim								
9999	9999								
195	avc_p_s_crm Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	AVC pós-CRM	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	sim	9999	9999
0	não								
1	sim								
9999	9999								
196	sang_4_pos_crm Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	Sangramento tipo 4 pós-CRM	radio (Matrix) <table border="1"> <tr> <td>0</td> <td>não</td> </tr> <tr> <td>1</td> <td>sim</td> </tr> <tr> <td>9999</td> <td>9999</td> </tr> </table>	0	não	1	sim	9999	9999
0	não								
1	sim								
9999	9999								

197	nec_reopera Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	Necessidade de Reoperação	radio (Matrix) 0 não 1 sim 9999 9999
198	bito_pos_crm Show the field ONLY if: [houve_rm] = '1' or [houve_rm] = '0'	Óbito pós-CRM	radio (Matrix) 0 não 1 sim 9999 9999
199	indicacao_de_reperfusao	Section Header: <i>IAM com Supra de ST</i> Indicação de Reperusão no IAM com EST	radio 0 Indicação de reperusão 1 Sem indicação de reperusão por chegada tardia 2 Sem indicação de reperusão por melhora clínica 3 Contra-indicação 9999 9999
200	reperfusao	Reperusão	radio 0 Ausência de estratégia de reperusão 1 CAT primário, sem angioplastia 2 Angioplastia primária 3 Trombólise 9999 9999
201	resolucao_da_dor	Resolução da dor após angioplastia ou trombólise	radio 1 Sim 0 Não 9999 9999 Custom alignment: RH
202	tamanho_da_st_antes	Tamanho do Segmento ST antes da Reperusão	text (number) Custom alignment: RH
203	tamanho_do_st_apos_60_min	Tamanho do Segmento ST após 60 min da Reperusão	text (number) Custom alignment: RH
204	timi_pre_atc	TIMI pré-ATC	text (number) Custom alignment: RH
205	timi_pos_atc	TIMI pós-ATC	text (number) Custom alignment: RH

	206	angioplastia_tardia	Angioplastia Tardia	radio <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>De artéria ocluída</td></tr> <tr><td>2</td><td>De artéria aberta</td></tr> <tr><td>3</td><td>Resgate</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	De artéria ocluída	2	De artéria aberta	3	Resgate	9999	9999				
0	Não																	
1	De artéria ocluída																	
2	De artéria aberta																	
3	Resgate																	
9999	9999																	
	207	atraso	Atraso	radio <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Custom alignment: RH	0	Não	1	Sim	9999	9999								
0	Não																	
1	Sim																	
9999	9999																	
	208	obitot	Section Header: <i>Óbito</i> Óbito Total	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> </table>	0	Não	1	Sim										
0	Não																	
1	Sim																	
	209	obito_cv	Óbito Cardiovascular	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> </table>	0	Não	1	Sim										
0	Não																	
1	Sim																	
	210	obitocvdireto	Óbito Cardiovascular Direto	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> </table>	0	Não	1	Sim										
0	Não																	
1	Sim																	
	211	obitocvindireto	Óbito Cardiovascular Indireto	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> </table>	0	Não	1	Sim										
0	Não																	
1	Sim																	
	212	obitonaocv	Óbito Não Cardiovascular	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> </table>	0	Não	1	Sim										
0	Não																	
1	Sim																	
	213	tipoobito	Tipo de Óbito	radio <table border="1"> <tr><td>9999</td><td>Não</td></tr> <tr><td>1</td><td>1. Falência do VE</td></tr> <tr><td>2</td><td>2. Arritmia</td></tr> <tr><td>3</td><td>3. RM</td></tr> <tr><td>4</td><td>4. Sangramento</td></tr> <tr><td>5</td><td>5. IRA</td></tr> <tr><td>6</td><td>6. Infecção</td></tr> </table>	9999	Não	1	1. Falência do VE	2	2. Arritmia	3	3. RM	4	4. Sangramento	5	5. IRA	6	6. Infecção
9999	Não																	
1	1. Falência do VE																	
2	2. Arritmia																	
3	3. RM																	
4	4. Sangramento																	
5	5. IRA																	
6	6. Infecção																	
	214	iamssst	Section Header: <i>Desfecho Intra-Hospitalar</i> IAM SSST	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> </table>	0	Não	1	Sim										
0	Não																	
1	Sim																	

215	iamcsst	IAM CSST	radio (Matrix) 0 Não 1 Sim
216	angrecorr	Angina Recorrente	radio (Matrix) 0 Não 1 Sim
217	angref	Angina Refratária	radio (Matrix) 0 Não 1 Sim
218	avci	AVC Isquêmico	radio (Matrix) 0 Não 1 Sim
219	avch	AVC Hemorrágico	radio (Matrix) 0 Não 1 Sim
220	ive	Nova IVE	radio (Matrix) 0 Não 1 Sim
221	pcr	PCR	radio (Matrix) 0 Não 1 Sim
222	icpurgente	ICP Urgente	radio (Matrix) 0 Não 1 Sim
223	trombsubagudast	Trombose Subaguda de Stent	radio (Matrix) 0 Não 1 Sim
224	trombagudast	Trombose Aguda de Stent	radio (Matrix) 0 Não 1 Sim
225	cirurgrm	RM Urgente	radio (Matrix) 0 Não 1 Sim
226	momento	Momento do Desfecho	radio 9999 Não 0 Antes da ATC ou Cirurgia 1 Após ATC ou Cirurgia

227	sangrumentoo	Section Header: <i>Sangramento</i> Sangramento	radio (Matrix) 0 Não 1 Sim
228	sangmaior	Sangramento Maior	radio (Matrix) 0 Não 1 Sim
229	sangrobito	Óbito por Sangramento	radio (Matrix) 0 Não 1 Sim
230	tiposang Show the field ONL Y if: [sangrumentoo] = '1' or [sangrumentoo] = '0'	Tipo de Sangramento	radio 0 Não 1 1 2 2 3a 3a 3b 3b 3c 3c 4 4 5 5
231	hematoma	Section Header: <i>Sangramentos</i> Hematoma	radio (Matrix) 0 Não 1 Sim
232	sangfatal	Sangramento Fatal	radio (Matrix) 0 Não 1 Sim
233	sangih	Sangramento com Instabilidade Hemodinâmica	radio (Matrix) 0 Não 1 Sim
234	sangtampo	Tamponamento Cardíaco	radio (Matrix) 0 Não 1 Sim
235	sangtransf	Necessidade de Transfusão Sanguínea	radio (Matrix) 0 Não 1 Sim
236	sanghb3	Transfusão com Hb entre 3 e 5	radio (Matrix) 0 Não 1 Sim

	237	sanghb5	Transusão com Hb \geq 5	radio (Matrix) 0 Não 1 Sim
	238	iamsang	IAM secundário a sangramento	radio (Matrix) 0 Não 1 Sim
	239	suspdroga	Necessidade de suspensão de drogas AT	radio (Matrix) 0 Não 1 Sim
	240	deltahb	Delta Hb	text (number)
	241	sitiosang	Sítio de Sangramento	radio 9999 Não 1 CATE 2 ICP 3 Digestivo 4 Nasal 5 Cerebral 6 Intraocular 7 Retroperitoneal 8 Via Aérea 9 Outros
	242	sangcat	Sangramento no CATE	radio (Matrix) 0 Não 1 Sim
	243	sangicp	Sangramento na ICP	radio (Matrix) 0 Não 1 Sim
	244	ira	Section Header: <i>Função Renal</i> IRA	radio (Matrix) 0 Não 1 Sim Field Annotation: \geq 0,3 em 48h OU \geq 1,5x em 7 dias OU DU < 0,5 por 6h
	245	iracontrast	IRA relacionada a contraste	radio (Matrix) 0 Não 1 Sim
	246	oliguria	Oligúria	radio (Matrix) 0 Não 1 Sim

	247	dialiseh	Diálise	radio (Matrix) 0 Não 1 Sim
	248	persistente	IR Persistente	radio (Matrix) 0 Não 1 Sim
	249	delta_cr	Delta Creatinina	text (number)
	250	pericardite	Section Header: <i>Pericardite</i> Pericardite	radio (Matrix) 0 Não 1 Sim 9999 9999
	251	rmcpos	RM cardíaca positiva	radio (Matrix) 0 Não 1 Sim 9999 9999
	252	ecopos	Ecocardiograma positivo	radio (Matrix) 0 Não 1 Sim 9999 9999
	253	cateneg	CATE negativo para DACO	radio (Matrix) 0 Não 1 Sim 9999 9999
	254	diagperi	Forma de Diagnóstico de Pericardite	radio 1 RMC positiva + ECG negativo para isquemia 2 ECO positivo + ECG negativo para isquemia 3 CATE normal na ausência de diagnóstico mais provável 9999 9999
	255	dacobstr	Section Header: <i>Diagnóstico</i> DAC Obstrutiva	radio (Matrix) 0 Não 1 Sim 9999 9999
	256	dacclini	DAC Clínica	radio (Matrix) 0 Não 1 Sim 9999 9999

	257	cateee	Fez CATE	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999														
0	Não																							
1	Sim																							
9999	9999																							
	258	cintilo	Fez Cintilo	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999														
0	Não																							
1	Sim																							
9999	9999																							
	259	diag	Diagnóstico Final	radio <table border="1"> <tr><td>1</td><td>Angina Instável</td></tr> <tr><td>2</td><td>Infarto</td></tr> <tr><td>3</td><td>Indefinido</td></tr> <tr><td>4</td><td>Gastro-intestinal</td></tr> <tr><td>5</td><td>Osteomuscular</td></tr> <tr><td>6</td><td>Pneumonia</td></tr> <tr><td>7</td><td>TEP</td></tr> <tr><td>8</td><td>Dissecção de Aorta</td></tr> <tr><td>9</td><td>Pericardite</td></tr> <tr><td>10</td><td>Outro</td></tr> </table>	1	Angina Instável	2	Infarto	3	Indefinido	4	Gastro-intestinal	5	Osteomuscular	6	Pneumonia	7	TEP	8	Dissecção de Aorta	9	Pericardite	10	Outro
1	Angina Instável																							
2	Infarto																							
3	Indefinido																							
4	Gastro-intestinal																							
5	Osteomuscular																							
6	Pneumonia																							
7	TEP																							
8	Dissecção de Aorta																							
9	Pericardite																							
10	Outro																							
	260	exameddiag	Exame para Diagnóstico	radio <table border="1"> <tr><td>0</td><td>MNM</td></tr> <tr><td>1</td><td>ECO-estresse</td></tr> <tr><td>2</td><td>Cintilografia</td></tr> <tr><td>3</td><td>RNM</td></tr> <tr><td>4</td><td>TC</td></tr> <tr><td>5</td><td>CATE</td></tr> <tr><td>6</td><td>ECG</td></tr> <tr><td>7</td><td>Outro</td></tr> <tr><td>8</td><td>ECO-função</td></tr> </table>	0	MNM	1	ECO-estresse	2	Cintilografia	3	RNM	4	TC	5	CATE	6	ECG	7	Outro	8	ECO-função		
0	MNM																							
1	ECO-estresse																							
2	Cintilografia																							
3	RNM																							
4	TC																							
5	CATE																							
6	ECG																							
7	Outro																							
8	ECO-função																							
	261	aasp	Section Header: <i>Medicamentos Crônicos</i> AAS	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999														
0	Não																							
1	Sim																							
9999	9999																							
	262	clopip	Clopidogrel	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999														
0	Não																							
1	Sim																							
9999	9999																							

263	ticagp	Ticagrelor	radio (Matrix) 0 Não 1 Sim 9999 9999
264	sinvap	Estatina	radio (Matrix) 0 Não 1 Sim 9999 9999
265	aase	Section Header: <i>Medicamentos na Emergência</i> AAS	radio (Matrix) 0 Não 1 Sim 9999 9999
266	clopie	Clopidogrel	radio (Matrix) 0 Não 1 Sim 9999 9999
267	brilintae	Ticagrelor	radio (Matrix) 0 Não 1 Sim 9999 9999
268	aasuci	Section Header: <i>Medicamentos na UCI</i> AAS	radio (Matrix) 0 Não 1 Sim 9999 9999
269	clopiuci	Clopidogrel	radio (Matrix) 0 Não 1 Sim 9999 9999 Field Annotation: Plavix
270	brilinuci	Ticagrelor	radio (Matrix) 0 Não 1 Sim 9999 9999 Field Annotation: Brilinta

	271	hnfuci	HNF	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									
	272	hbpucci	HBP (Enoxaparina)	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Field Annotation: Clexane	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									
	273	fondauci	Foundaparinux	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Field Annotation: Arixtra	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									
	274	tirouci	Tirofiban	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									
	275	abiciuci	Abciximabe	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									
	276	bbloquci	Betabloqueador	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Field Annotation: Concor, Selozok	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									
	277	ntuci	Nitrato	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Field Annotation: Tridil	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									

	278	estatuci	Estatina	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table> Field Annotation: Lipitor, Crestor	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									
	279	lasixivuci	Lasix Intravenoso	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									
	280	dobuuci	Dobutamina	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									
	281	biauci	Balão Intra-Aórtico (BIA)	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									
	282	norauci	Noradrenalina	radio (Matrix) <table border="1"> <tr><td>0</td><td>Não</td></tr> <tr><td>1</td><td>Sim</td></tr> <tr><td>9999</td><td>9999</td></tr> </table>	0	Não	1	Sim	9999	9999
0	Não									
1	Sim									
9999	9999									
	283	rescardt_complete	Section Header: <i>Form Status</i> Complete?	dropdown <table border="1"> <tr><td>0</td><td>Incomplete</td></tr> <tr><td>1</td><td>Unverified</td></tr> <tr><td>2</td><td>Complete</td></tr> </table>	0	Incomplete	1	Unverified	2	Complete
0	Incomplete									
1	Unverified									
2	Complete									
Instrument: Protocolo HA (protocolo_ha)										
	284	nomee	Nome	text						
	285	idadee	Idade	text (number)						
	286	sexoo	Sexo	radio <table border="1"> <tr><td>1</td><td>Feminino</td></tr> <tr><td>2</td><td>Masculino</td></tr> </table>	1	Feminino	2	Masculino		
1	Feminino									
2	Masculino									
	287	prontuario	Prontuário	text (number)						
	288	chegada	Horário de Chegada <i>HH:MM</i>	text (time)						
	289	horariocadastro	Horário de Cadastro <i>HH:MM</i>	text (time)						
	290	atendimento	Horário do Atendimento <i>HH:MM</i>	text (time)						

	291	altapa	Horário de Alta do Setor (PA) <i>HH:MM</i>	text (time)						
	292	fechamentoconta	Horário de Fechamento de Conta <i>HH:MM</i>	text (time)						
	293	permanencia	Tempo de Permanência no PA <i>horas</i>	text (number)						
	294	portaecg	Tempo Porta-ECG <i>horas</i>	text (number)						
	295	horarioecg	Horário do Eletrocardiograma <i>HH:MM</i>	text (time)						
	296	ecglaudo	Tempo ECG-Laudos <i>horas</i>	text (number)						
	297	custopa	Custo no PA <i>reais</i>	text (number)						
	298	custointernamento	Custo no Internamento <i>reais</i>	text (number)						
	299	protocolo_ha_compl ete	Section Header: <i>Form Status</i> Complete?	dropdown <table border="1"> <tr> <td>0</td> <td>Incomplete</td> </tr> <tr> <td>1</td> <td>Unverified</td> </tr> <tr> <td>2</td> <td>Complete</td> </tr> </table>	0	Incomplete	1	Unverified	2	Complete
0	Incomplete									
1	Unverified									
2	Complete									

APÊNDICE D — DESCRIÇÃO DOS DADOS FALTANTES E RESULTADOS DA IMPUTAÇÃO MÚLTIPLA

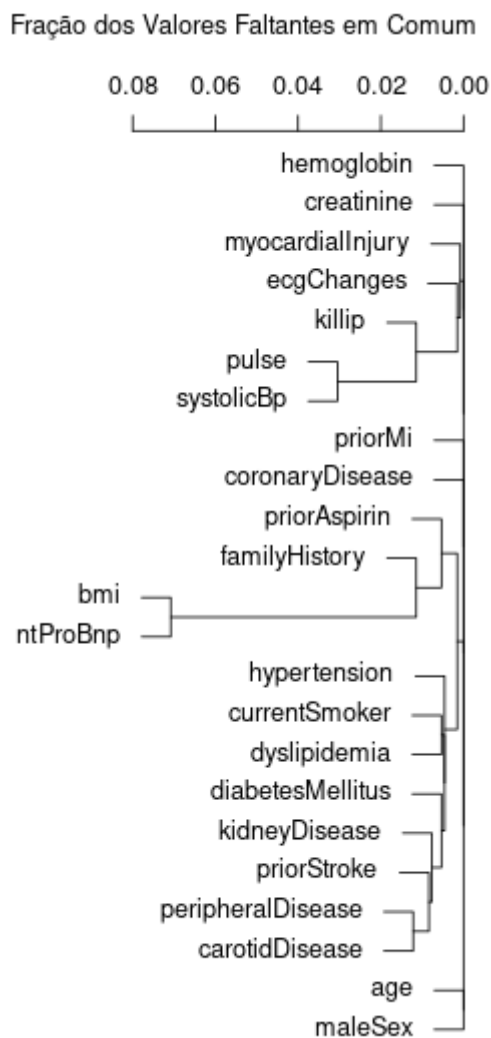


Figura Suplementar 1. Fração de Valores Faltantes em Comum para Cada Variável.

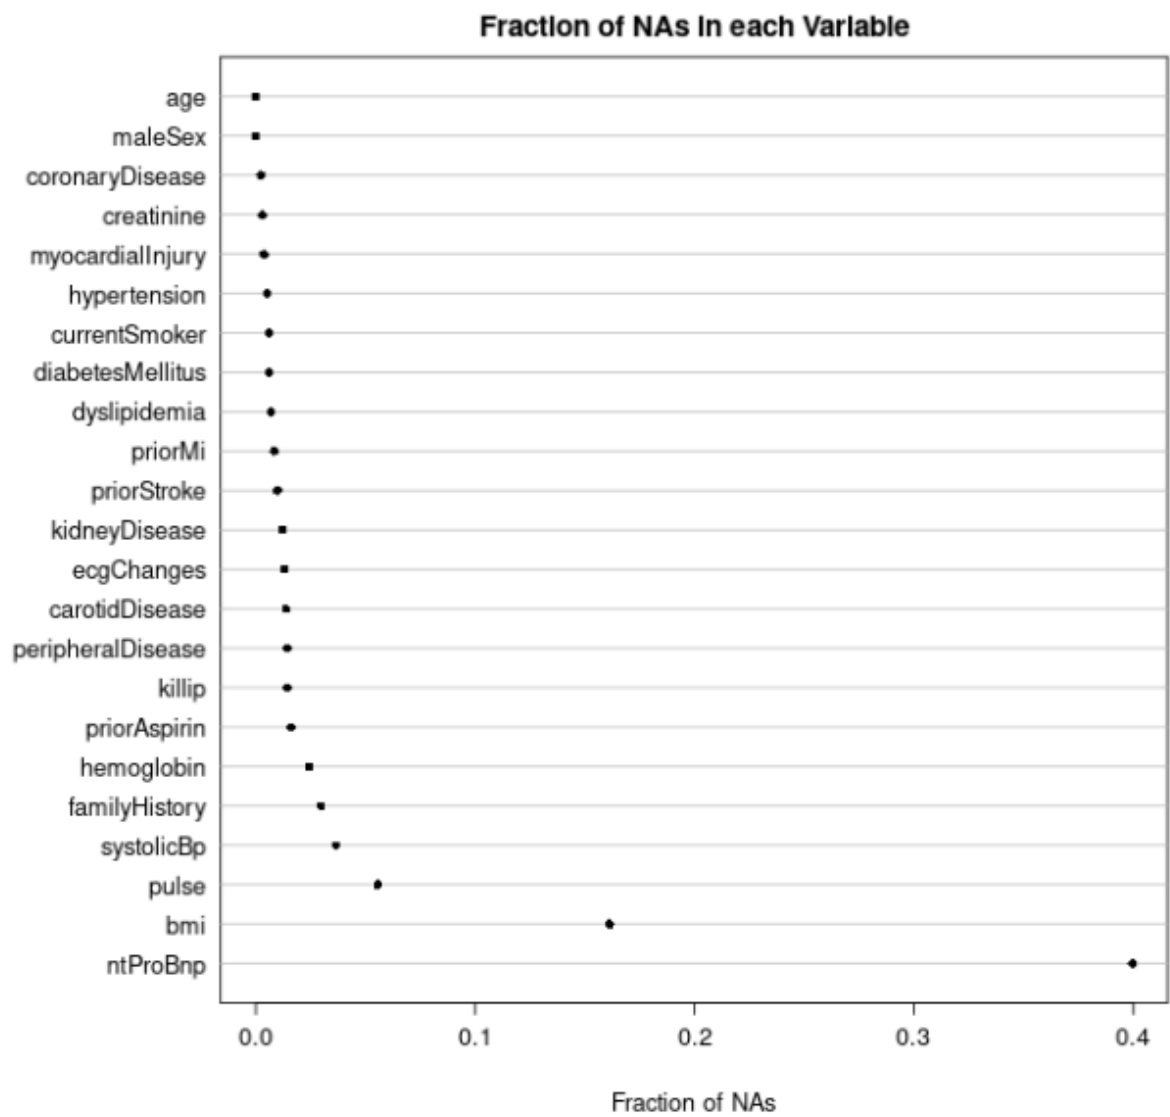


Figura Suplementar 2. Fração de Valores Faltantes por Variável.

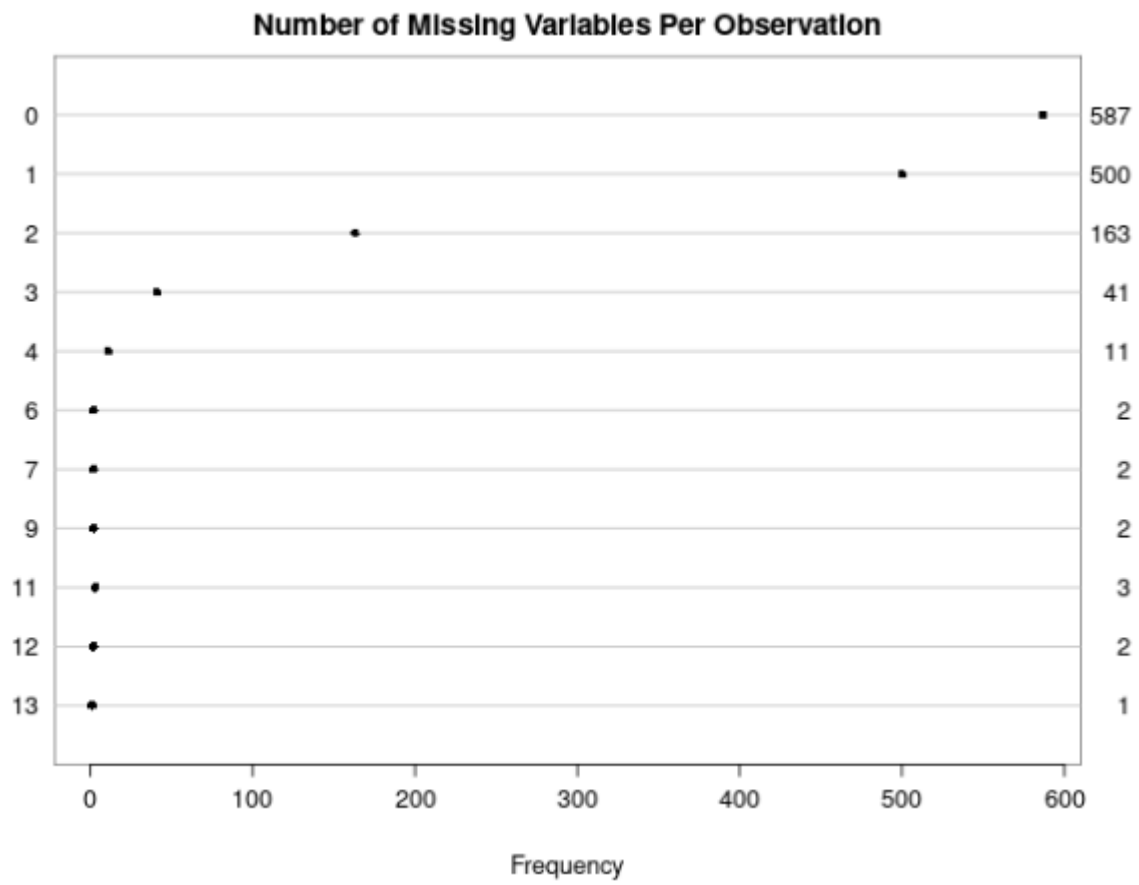


Figura Suplementar 3. Número de Valores Faltantes por Paciente.

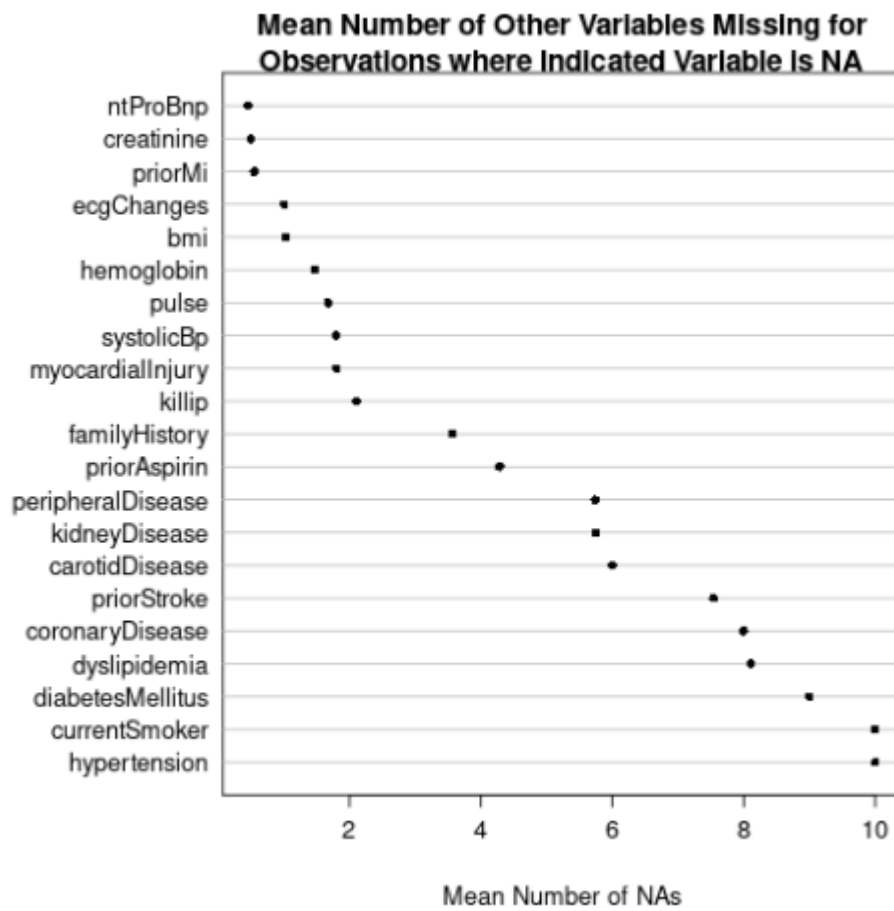


Figura Suplementar 4. Quantidade Média de Outras Variáveis Faltantes Quando a Variável Indicada Faltava.




Figura Suplementar 5. Frequência das Combinações de Variáveis Conforme Seu Estado de Falta.

Variáveis completas são indicadas em vermelho, enquanto as faltantes são indicadas em azul. Cada coluna representa uma combinação observada das variáveis conforme elas faltavam ou não. O gráfico de barras de baixo representa a proporção de cada combinação dos estados de falta das variáveis. O gráfico de barras ao lado representa a proporção de valores faltantes para cada variável.

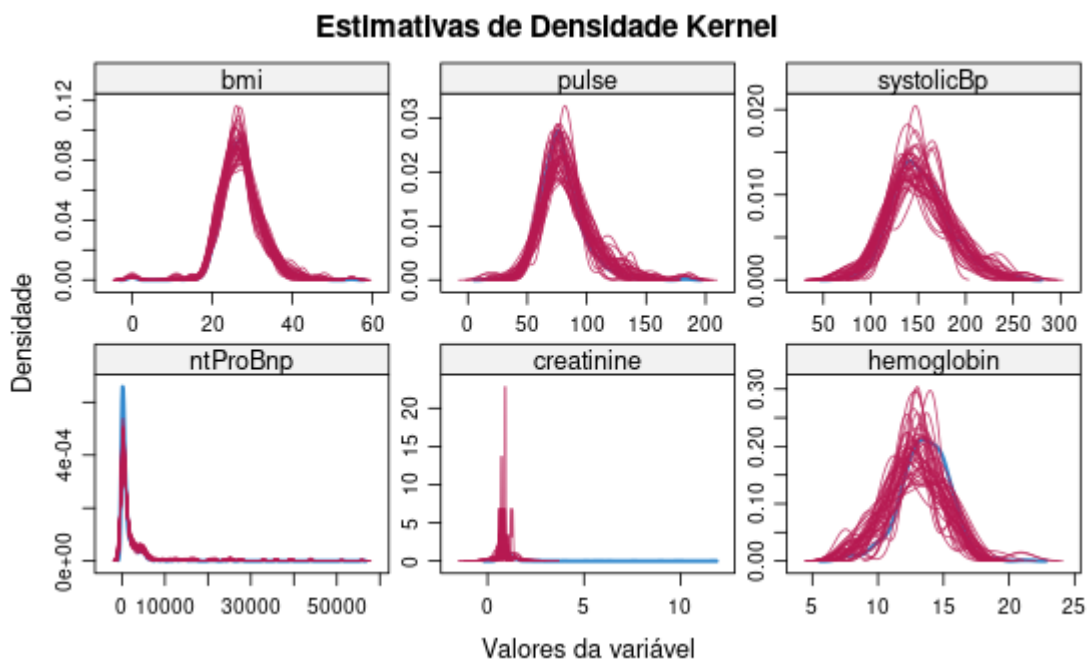


Figura Suplementar 6. Estimativas de Densidade Kernel para Variáveis Numéricas Após Imputação da Coorte de Desenvolvimento.

Em azul demarca-se a distribuição observada das variáveis; em vermelho, a distribuição em cada conjunto de dados imputado. Os gráficos mostram a semelhança nas distribuições entre os valores observados e imputados.

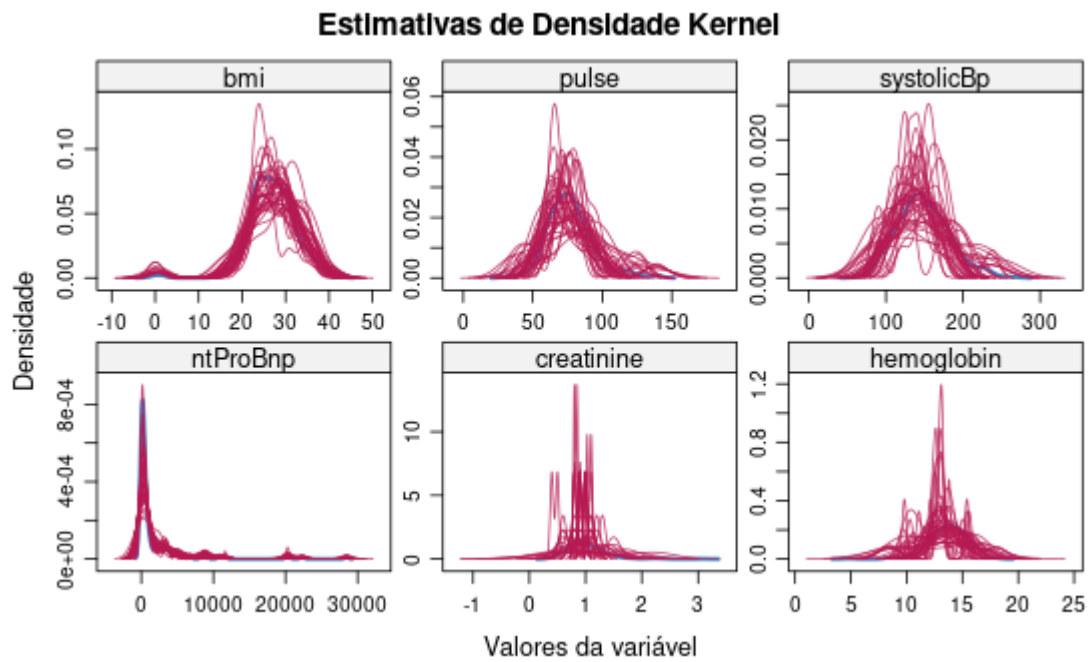


Figura Suplementar 7. Estimativas de Densidade Kernel para Variáveis Numéricas Após Imputação da Coorte de Validação Interna.

Em azul demarca-se a distribuição observada das variáveis; em vermelho, a distribuição em cada conjunto de dados imputado. Os gráficos mostram a semelhança nas distribuições entre os valores observados e imputados.

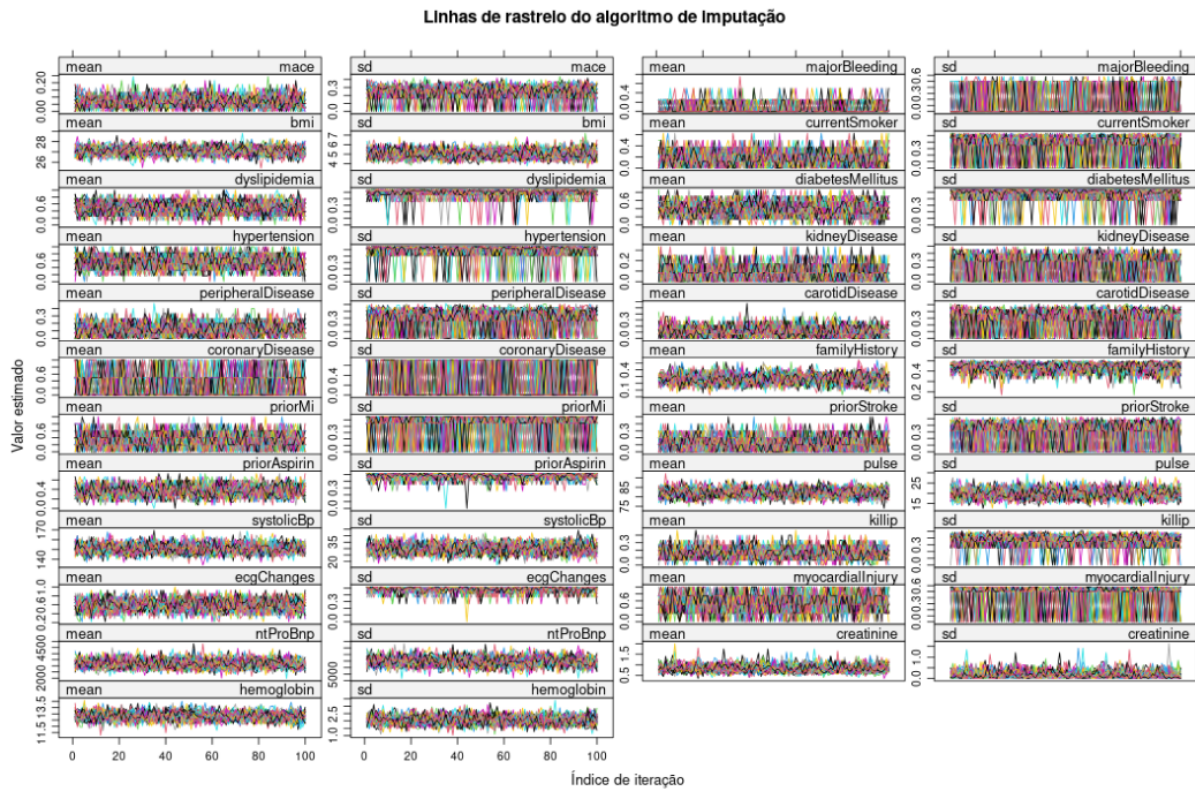


Figura Suplementar 8. Traços da Imputação Múltipla na Coorte de Desenvolvimento pelo Método de Monte Carlo via Cadeias de Markov.

Esses gráficos mostram a consistência nas iterações das imputações. Há indicativo de bom desempenho quando os traços inter cruzam-se conforme avança-se nas abscissas, e assumem direções divergentes nas iterações finais.

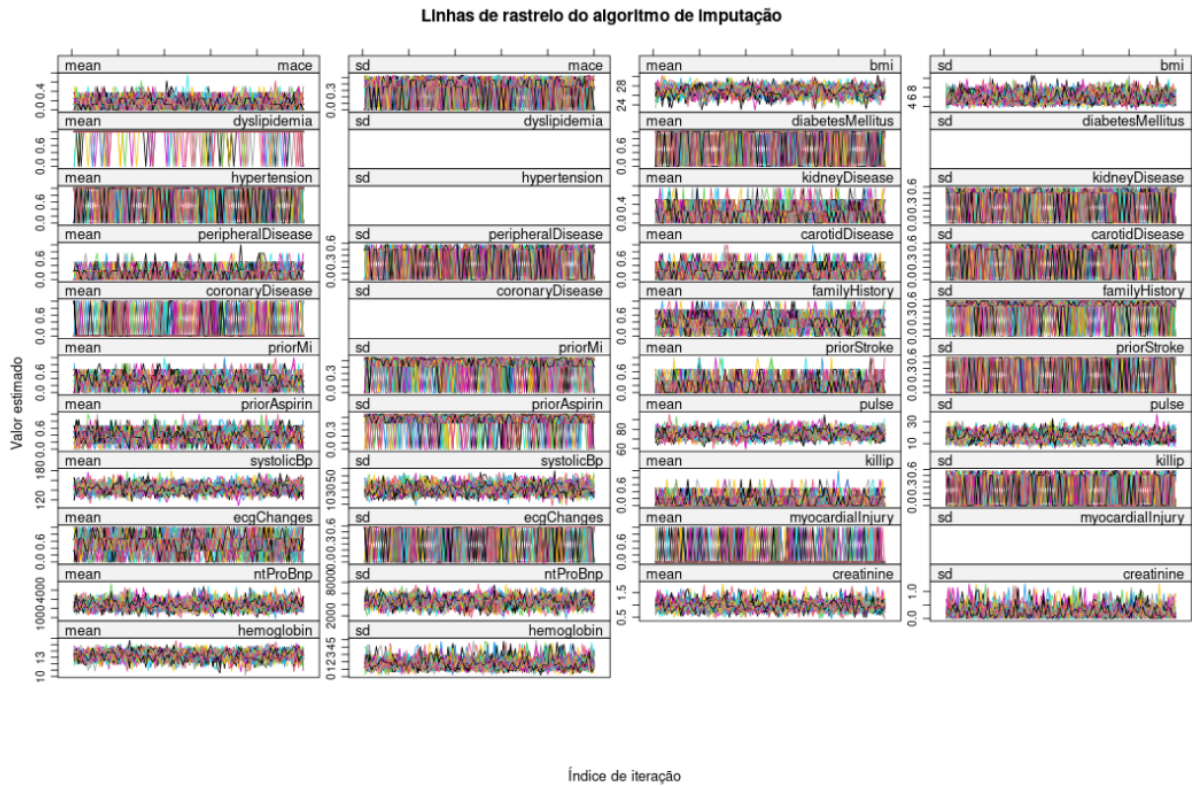


Figura Suplementar 9. Traços da Imputação Múltipla na Coorte de Validação Interna pelo Método de Monte Carlo via Cadeias de Markov.

Esses gráficos mostram a consistência nas iterações das imputações. Há indicativo de bom desempenho quando os traços inter cruzam-se conforme avança-se nas abscissas, e assumem direções divergentes nas iterações finais.