

Desenvolvimento de um modelo de aprendizado de máquina para prever a necessidade de transfusão sanguínea em pacientes

Development of a machine learning model to predict the need for blood transfusion in patients

Kelson Antonio O. Santos
Programa de Pós Graduação
em Engenharia Elétrica,
Universidade Federal do Piauí
- Teresina, Brasil
kelson.santos@ufpi.edu.br

Lidyane Rodrigues O.
Santos
Universidade Federal do
Piauí, Brasil
lidyane@yaho.com.br

Flávio Henrique D. Araújo
Programa de Pós Graduação
em Engenharia Elétrica,
Departamento de Sistemas de
Informação,
Universidade Federal do
Piauí, Brasil
flavio86@ufpi.edu.br

ABSTRACT

Blood is an exhaustible therapeutic resource. Studies show excessive consumption in clinical practice and a reduction in donations, which makes stock maintenance and patient safety regarding its use challenging. The use of intelligent systems can help professionals in the area to make decisions regarding the real need for blood transfusion. This study aims to use machine learning algorithms to help identify the need for blood transfusion. In this study, 220 medical records were used to evaluate the models: Neural networks, Random forest, Logistic regression. Models based on current international parameters for laboratory tests identified cases that were suitable and unsuitable for transfusion. The three models showed promise with an accuracy rate above 90%, with emphasis on Random Forest, which presented a rate of 99.4%.

Keywords

Machine learning, blood transfusion, risk factors

RESUMO

O sangue é um recurso terapêutico esgotável. Estudos evidenciam consumo excessivo na prática clínica e redução nas doações, o que torna desafiador a manutenção de estoque e a segurança do paciente quanto ao seu uso. A utilização de sistemas inteligentes pode auxiliar profissionais da área na tomada de decisão quanto a real necessidade de transfusão de sangue. Este estudo tem por objetivo utilizar algoritmos de aprendizagem de máquina para auxílio na identificação

da necessidade de transfusão de sangue. Neste estudo foram utilizados 220 prontuários médicos para avaliação dos modelos: Redes neurais, Floresta aleatória, Regressão logística. Os modelos baseados nos parâmetros internacionais vigentes de exames laboratoriais identificaram os casos que foram adequados e inadequados para transfusão. Os três modelos mostraram-se promissores com taxa de precisão acima de 90%, com destaque para Random Forest, que apresentou taxa de 99,4%.

Palavras-Chave

Aprendizado de máquina, transfusão de sangue, fatores de riscos

1. INTRODUÇÃO

A busca pela qualidade e segurança nos serviços de saúde estão cada vez mais solicitadas. Sistemas que auxiliem a prática clínica no que tange a assegurar procedimentos seguros e de qualidade favorecerem a utilização de recursos onerosos e escassos, como o uso indiscriminado do sangue. Segundo estudos internacionais, seu uso ocorre com mais frequência do que o recomendado. Disparadores de transfusão e o uso de protocolos tiveram efetividade na redução de riscos de sua utilização [3][28].

Observa-se no mundo conduta voltada para segurança do paciente, com práticas restritivas e gerenciamento do uso do sangue para fins de fato necessários. Nos países desenvolvidos, a Organização Mundial da Saúde recomenda, desde 2010, a aplicação do *Patient Blood Management* (PBM), que é um programa de gerenciamento do uso do sangue como estratégia para redução do número de hemácias transfundidas no mundo [26].

Esse programa consiste na aplicação, baseada em evidências científicas centrada no paciente, firmado em três pilares importantes: I - otimizar a massa eritrocitária e o estado de coagulação; II - minimizar a perda de sangue; e III - reduzir a tolerância à anemia. Ferramentas desenvolvidas com algoritmos de aprendizagem de máquina podem favorecer a utilização deste recurso, que ocorre de forma demasiada,

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee.

sem critérios bem definidos, na prática clínica. Nas últimas décadas, países subdesenvolvidos priorizaram pesquisas sobre segurança para doação e recepção do sangue, e aquelas que envolvem sua utilização, ainda são incipientes [3][12].

Estudos mostraram eficácia em identificar padrões o que auxiliará profissionais de saúde para melhor direcionar sua conduta. Dessa forma, técnicas de aprendizagem de máquinas podem favorecer melhorias nas condutas de toda equipe para o uso racional de tratamentos duráveis, visto já serem utilizadas em outras áreas de forma efetiva. Assim, este trabalho buscou a criação de um método para auxílio na predição da necessidade de transfusão de sangue com o uso de três algoritmos de aprendizagem de máquina: Regressão logística, Floresta Aleatória e Redes neurais(MLP). Para o estudo foram utilizadas prescrições médicas de 220 prontuários, analisados e classificados por um profissional experiente com base em exames laboratoriais associados aos fatores de riscos identificados na literatura e parâmetros conforme protocolos internacionais [3]. Após o pré-processamento a base de dados, continha 220 registros, distribuídos da seguinte forma: 37 registros de pacientes como adequados e 183 registros de pacientes como inadequados para transfusão de sangue.

A seção 2 apresentará alguns trabalhos relacionados com estudos e investimentos em pesquisas sobre a utilização de aprendizagem de máquina para auxiliar no processo de decisão sobre a transfusão de sangue em países desenvolvidos. A seção 3 contém o detalhamento da metodologia proposta. Na seção 4 são apresentados os resultados obtidos e critérios de avaliação dos classificadores. Na seção 5 a discussão dos resultados. Na seção 6 são apresentados as principais conclusões e direcionamento para trabalhos futuros.

2. TRABALHOS RELACIONADOS

Países desenvolvidos investem em pesquisas sobre aprendizado de máquina no processo de decisão sobre a transfusão de sangue. A inteligência artificial e as tecnologias relacionadas são predominantes nos negócios e na sociedade e estão sendo cada vez mais usadas para estabelecer o fluxo de trabalho clínico, auxiliar no diagnóstico ou tratamento [7][2][15]. Como muitos hospitais em países desenvolvidos usam registros eletrônicos de saúde, a modelagem baseada em aprendizagem de máquina torna-se importante para prever as informações relevantes, por exemplo, se uma transfusão de sangue é necessária em uma intervenção clínica.

Na Austrália Ocidental, entre janeiro de 2008 e junho de 2017 foi realizado estudo em três hospitais terciários, que objetivou investigar a precisão de quatro algoritmos para prever transfusão: Neural network (NNs), Regression logistic (LR), Random forests (RFs) e Gradiente boosting (GB) trees. O uso dos modelos previu com precisão a transfusão de pelo menos 1 unidade de hemácia (sensibilidade para NN, LR, RF e GB: 0,898, 0,894, 0,584 e 0,872, respectivamente; especificidade: 0,958, 0,966, 0,964, 0,965).

Entretanto, a previsão dos quatro modelos de transfusão maciça teve menor sucesso (sensibilidade para NN, LR, RF e GB: 0,780, 0,721, 0,002 e 0,797, respectivamente; especificidade: 0,994, 0,995, 0,993, 0,995). E também mostrou imprecisão quanto a previsão do número total de concentrados de hemácias transfundidas [18]. O que pode direcionar melhor sua utilização na prática clínica.

Estudo realizado em hospitais na China comparou decisões médicas quanto adequação das transfusões realizadas

conforme preconização de protocolos, e alcançou taxa de precisão de 96,8% na correspondência do julgamento humano, o que aponta significativo percentual de acerto do algoritmo [27].

Outro estudo realizado no Hospital Geral Massachusetts, nos Estados Unidos em 7.265 pacientes consecutivos submetidos à artroplastia total primária do quadril, teve como objetivo desenvolver e validar novos modelos de aprendizado de máquina para a previsão de taxas de transfusão pós-cirurgia. O estudo revisou os prontuários dos pacientes manualmente para identificar a demografia e variáveis cirúrgicas que podem estar associadas às taxas de transfusão. Foram avaliados usando um único banco de dados de instituições terciárias de referência. As variáveis demográficas incluíram idade, sexo, índice de massa corporal (IMC), etnia, estado civil, status de seguro, pontuação do estado físico da American Society of Anesthesiologist (escore ASA), comorbidades médicas, bem como índice de comorbidade de Charlson (CCI). Com relação ao tabagismo e ao alcoolismo como comorbidades médicas, os pacientes classificados como fumantes ou etilistas consumiam ativamente cigarro ou álcool quando internados antes da ATQ primária. As variáveis cirúrgicas incluídas para análise foram lateralidade, tipo de anestesia, uso de ácido tranexâmico (1 mg por via intravenosa no início da cirurgia e 1 mg adicional no momento do fechamento), método de fixação do componente (cimentado vs não cimentado), abordagem cirúrgica (anterolateral vs posterior), taxas de transfusão e tempo de operação. Os modelos de aprendizado de máquina desenvolvidos e utilizados para prever com precisão necessidade de transfusão foram: redes neurais artificiais, aumento de gradiente estocástico, máquinas de vetores de suporte, e Regressão logística penalizada elástica. Todos os modelos de aprendizado de máquina alcançaram excelente desempenho em discriminação (AUC > 0,78), calibração e análise de curva de decisão[6].

Liu et al.[14] usaram modelos de aprendizado de máquina para explorar os fatores relacionados ao risco que influenciam a transfusão de sangue em 698 pacientes submetidos à cirurgia de válvula mitral. Neste estudo, foi utilizado o algoritmo CatBoost que utilizou 39 variáveis, entre outros parâmetros laboratoriais, que incluíram comorbidades, como hipertensão e diabetes, uso de anticoagulação oral, escore ASA, identificação do cirurgião ou resgate de células. A análise revelou que hematócrito (<37,81%), idade (>64 anos), peso corporal (<59,92 kg), índice de massa corporal (<22,56 kg/m²), hemoglobina (<122,6 g/L), altura (< 160,61 cm), contagem de plaquetas (>194,12 × 10⁹/L), contagem de hemácias (<4,08 × 10¹²/L) e sexo (feminino) foram os principais fatores que influenciaram a probabilidade de transfusão de sangue. O modelo alcançou um valor de área sob a curva de 0,922 (95% CI 0,883–0,956).

De forma semelhante, Wang et al. desenvolveram um método de aprendizagem de máquina para prever transfusões intraoperatória de hemácias em cirurgias cardiotorácica e utilizaram dados de 2.410 pacientes submetidos à cirurgia cardiotorácica e estabeleceram em uma primeira etapa um algoritmo de Random Forest para discriminar variáveis importantes. Das 10.622 variáveis potenciais, 202 foram selecionadas e incluídas na análise. Em uma segunda etapa, uma estrutura híbrida de aprendizado de máquina foi estabelecida e os autores compararam cinco algoritmos diferentes, dos quais o processo gaussiano mostrou o maior valor de área sob a curva (0,826) e melhor desempenho geral [25]

A Tabela 1 apresenta um resumo dos trabalhos relacionados. São descritos o objetivo, amostra, algoritmos e resultados. Conforme observado nos estudos, pesquisas apontam crescimento nesta temática e mostraram eficácia quanto a prever informações relevantes quanto a necessidade do uso do sangue.

Em [22] foi realizado estudo de menor magnitude no Brasil que objetivou analisar o perfil clínico e epidemiológico de pacientes pós-cirúrgicos que foram submetidos a transfusão. Estudo quantitativo, descritivo e retrospectivo, realizado na clínica cirúrgica de um hospital público, com amostra constituída por 31 prontuários de pacientes pós-cirúrgicos, maiores de 18 anos, com internação no período de março a maio de 2018, com permanência mínima de 24 horas, e fizeram uso de hemocomponentes. Dos 31 pacientes que receberam hemocomponentes, 36% tinham idade igual ou superior a 61 anos, 40% do sexo masculino, 42% pardos, com maior predominância de diagnóstico de fraturas em 18% e doença arterial periférica, 18%, média de hemoglobina para transfusão de 9,19, e média de tempo de internação de 23 dias. Identificou que o perfil dos pacientes que se submeteram ao tratamento não está em total acordo com critérios dos protocolos internacionais para transfusão. Neste trabalho, os autores sugeriram uma avaliação mais acurada de forma individualizada, para sua utilização com critérios de recomendações embasadas, assim como conhecimentos de práticas alternativas para atender os pilares para qualidade e segurança assistencial, que inclui redução de transfusões excessivas e desnecessárias e gestão do sangue do paciente. Estudos apontam falta de preparo na academia destes profissionais, que não dispõe de matéria específica na área, o que favorece muitas prescrições desnecessárias. Por ser o recurso mais caro do ambiente hospitalar, ferramentas que auxiliem na tomada de decisão favorece gerenciamento do sangue [3].

3. METODOLOGIA PROPOSTA

Tratou-se de um estudo metodológico, preditivo, analítico realizado a partir de prescrições médicas de transfusão de sangue em hospital de ensino entre 2015 e 2018.

Na etapa de coleta, todos os dados foram coletados no período de agosto a novembro de 2020 com amostragem final de 1.038 prontuários e 40 atributos coletados por meio de um sistema - *Modular Research System-Study Management System (Mrs-SMS)*. Somente aqueles que realizaram transfusão no período supracitado, a fim de identificar conduta liberal ou restritiva quanto a utilização do sangue. A coleta de dados foi realizada após a autorização da instituição participante e a aprovação do Comitê de Ética da Universidade Federal do Piauí, conforme Certificado de Apresentação para Apreciação Ética n°20218319.3.3001.5613. O diagrama da Figura 1 apresenta todos os passos realizados nesse trabalho, e detalhes sobre a execução de cada etapa são descritos a seguir.

Depois dos registros descartados devidos ausência de dados, foi denominado Dataset HT, com 996 registros dos pacientes submetidos à hemotransfusão. Na amostra, houve distribuição equivalente entre os sexos, com discreta prevalência do feminino (54,7%). Concernente à faixa etária, a maioria foi de adultos entre 20 e 59 anos, com média de idade de 56 anos (55,61 ± 20,61). Sobre o perfil hematológico, ao analisar a presença do hemograma nas requisições, apenas 511(51,6%) apresentavam este exame descrito. Daqueles apresentados, a média de Hb foi de 10 (9,74±4,34) e

Ht 27,4 (25,48±15,28). Este perfil demonstra déficit significativo quanto ao preenchimento das requisições, haja vista que em 480 (48,4%) das requisições não constavam o exame que apresenta parâmetros necessários para tomada de decisão para transfusão [21]. O DataSet HT possuía 40 atributos, desse total muitos eram irrelevantes e não possuíam formato compatível com os algoritmos utilizados. Portanto, de posse do Dataset HT, foi realizado o pré-processamento e limpeza dos dados para melhorar a qualidade dos dados e diminuir a quantidade de informações irrelevantes. Estes foram feitos da seguinte forma:

- Excluíram-se 29 atributos sem correlação com fatores de riscos e sem preenchimento: Prontuário; Hospital; Data de Nascimento; Plaquetas; TTP/TTPa; Data da transfusão prévia; Data da transfusão; Tipo de requisição; Prescrição transfusional; Unidade solicitadas de plaquetas; Unidades de requisitadas de aférese; Unidade de concentrado de hemácias; Filtrado; Unidade de plasma fresco congelado requisitado; Unidade de plaqueta devolvido; Unidade de aférese; Unidade concentrado transfundido; Filtrado transfundido; Unidade de plasma transfundido; unidade de plaquetas que retornadas; Unidades aféreses retornadas; Unidade de concentrado retornadas; Pedido de transfusão devolvidos; Unidade de plasma devolvidos; Requisição por área; Transfusão área; Requisição por clínica; Requisição por tipo de cirurgia; Requisição por especialidade cirúrgica;
- As características selecionadas foram: idade; sexo; hemograma na requisição; hemoglobina (g/dl); hematócrito(%); diagnóstico; diagnóstico principal; diagnóstico transfusional; CID-10 e transfusão prévia;
- Foram excluídas 776 amostras que faltavam dados primordiais, como, hemoglobina (Hb), plaquetas, idade, sexo, hematócritos ou preenchidos com 999;
- De posse do Dataset PL, os atributos categóricos foram tratados, foram utilizadas duas técnicas para a padronização dos atributos categóricos, *Label encoder*, nos atributos (sexo, hemograma na requisição, Transfusão prévia) rotulados como 0 e 1, sendo 0 – para rotular não e 1 – para rotular sim. Os atributos (Diagnóstico, Diagnóstico principal, Diagnóstico transfusional, CID-10) que possuem mais de dois rótulos, foi utilizada técnica *OrdinalEncoder*, uma codificação ordinal que envolve o mapeamento de cada rótulo para valor inteiro. Com os atributos categóricos do Dataset PL tratados, foi utilizada a técnica *StandardScaler* para dimensionar as características, por meio da padronização. Esta é uma importante etapa de pré-processamento, visto que envolve redimensionar cada característica, de modo que, tenha um desvio padrão de 1 e uma média de 0. Mesmo que os modelos baseados em árvore (quase) não sejam afetados pelo dimensionamento, muitos outros algoritmos exigem que os recursos sejam normalizados, geralmente por diferentes razões: para facilitar a convergência; para criar um ajuste de modelo completamente diferente em comparação com o ajuste dos dados não dimensionados [20].

Superada todas as fases anteriores e de posse do Dataset Final, o passo seguinte consistiu na execução dos algoritmos de classificação.

Table 1: Resumo dos trabalhos relacionados

Trabalho	Objetivo	Amostras	Técnica	Resultado
[Mitterecker et al. 2020]	Investigar a precisão de quatro diferentes algoritmos para prever transfusões maciças e o número de transfusões em pacientes internados em um hospital.	206.271	Redes Neurais Regressão Logística Floresta Aleatória Aumento de Gradiente	VNP de 0,970 Especificidade de 0,966 AUC de 0,963 AUC de 0,966
[Y Yao et al 2019]	Criar um algoritmo de computador para examinar a adequação das decisões de transfusão de sangue usando a estratégia de aprendizado de máquina.	4.946	Redes Neurais	Precisão de 96,6%
[Cohen-Levy et al. 2023]	Desenvolver e validar novos modelos de aprendizado de máquina para a previsão de taxas de transfusão após artroplastia total de quadril primária.	7.265	Redes Neurais Aumento de gradiente estocástico Máquinas de vetores de suporte Regressão logística penalizada elástica	AUC > 0,78
[Liu et al 2021]	Usar modelos de aprendizado de máquina para prever a necessidade de transfusão de hemácias durante a cirurgia da válvula mitral para orientar a avaliação do cirurgião sobre a necessidade de transfusão sanguínea intraoperatória do paciente.	698	13 Algoritmos, o CatBoost apresentou melhor desempenho	AUC de 0,888
[Wang et al 2022]	Desenvolver um método de aprendizado de máquina (ML) para prever transfusões intraoperatórias de hemácias em cirurgia de TC.	2847	Árvore de Decisão Xgboost Floresta Aleatória Redes Neurais Processo Gaussiano	AUC de 0,826

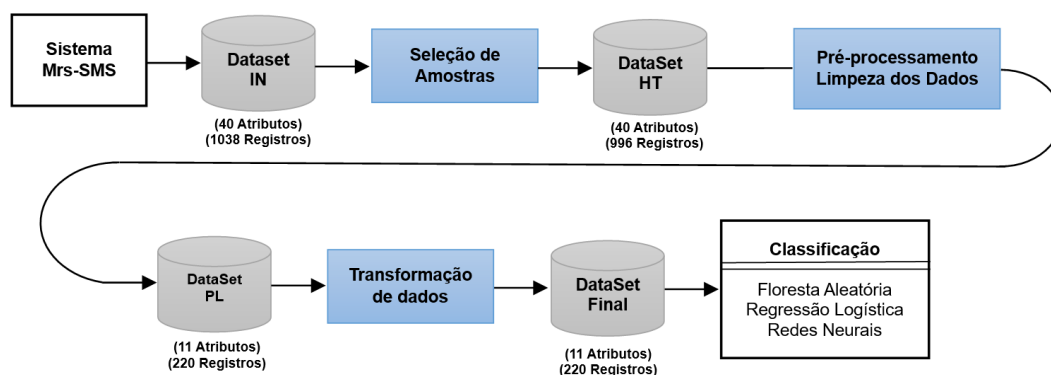


Figura 1: Diagrama que ilustra os passos realizados no trabalho

Para este estudo de classificação e comparação foram empregados três métodos de aprendizado de máquina: Floresta Aleatória [4], Regressão Logística e Redes Neurais [17].

- Floresta Aleatória é uma meta estimador que ajusta vários classificadores de árvore de decisão em várias subamostras do conjunto de dados e usa a média para melhorar a precisão preditiva e controlar o ajuste excessivo. O tamanho da subamostra é controlado com o parâmetro `max_samples` e `bootstrap=True` (padrão), caso contrário, todo o conjunto de dados é usado para construir cada árvore [20].
- A Regressão Logística é um processo de modelagem da probabilidade de um resultado discreto, dada uma variável de entrada. Os modelos de Regression Logistic, mais comuns, tem um resultado binário; algo que pode assumir dois valores, como verdadeiro/falso, sim/não, por exemplo. A Regression Logistic multinomial pode modelar cenários onde há mais de dois resultados discretos possíveis. A Regression Logistic é um método de análise útil para problemas de classificação, onde você está tentando determinar se uma nova amostra se encaixa melhor em uma categoria [9], é uma técnica importante no campo da inteligência artificial e aprendizagem de máquina.
- Redes Neurais são sistemas de computação com nós interconectados que funcionam como os neurônios do

cérebro humano. Usando algoritmos, eles podem reconhecer padrões escondidos e correlações em dados brutos, agrupá-los e classificá-los, e com o tempo aprender e melhorar continuamente. Nosso estudo foi criado uma rede neural perceptron multicamadas com 50 neurônios ocultos.

4. RESULTADOS

Na Base de Dados Final a quantidade de pacientes que foram classificados como inadequados para recebimento de transfusão de sangue foi bem maior que a quantidade de pacientes adequados para transfusão. Visando melhorar o desempenho dos algoritmos de classificação foi adotado procedimento de reamostragem, validação cruzada *5-fold* [8], pois o trabalho teve como objetivo avaliar a capacidade de generalização dos modelos de predição usados na pesquisa.

4.1 Critérios de Avaliação dos Classificados

Uma maneira de representar os resultados de um método de classificação de dados é através da chamada matriz de confusão. Ela indica a quantidade de ocorrências que o programa teve para cada uma das quatro classes [19]:

- Verdadeiro positivo (VP): quando o método diz que a classe é positiva e, ao verificar a resposta, vê-se que a classe era realmente positiva;
- Verdadeiro negativo (VN): quando o método diz que a classe é negativa e, ao verificar a resposta, vê-se que a classe era realmente negativa;

Table 2: Matriz de Confusão

Matriz de Confusão		Classe predita	
		Positiva	Negativa
Classe Original	Positiva	VP	FN
	Negativa	FP	VN

- Falso positivo (FP): quando o método diz que a classe é positiva, mas ao verificar a resposta, vê-se que a classe era negativa;
- Falso negativo (FN): quando o método diz que a classe é negativa, mas ao verificar a resposta, vê-se que a classe era positiva.

A partir das classes algumas taxas estatísticas podem ser calculadas para avaliar o desempenho dos classificadores. As taxas de Precisão, Acurácia, Sensibilidade, F1- score, Especificidade [13][24] são calculadas respectivamente pelas equações 1, 2, 3, 4, 5:

$$Precisao = \frac{VP}{VP + FP} \quad (1)$$

$$Acuracia = \frac{VP + VN}{VP + VN + FP + FN} \quad (2)$$

$$Sensibilidade = \frac{VP}{VP + FN} \quad (3)$$

$$f1 - score = \frac{precisao * sensibilidade}{precisao + sensibilidade} \quad (4)$$

$$Especificidade = \frac{VN}{VN + FP} \quad (5)$$

E a outra medida utilizada foi a Área Sob a Curva ROC (AUC). A AUC é a representação da sensibilidade de um classificador dada pela taxa de VP e função da taxa de FP. Quanto maior a AUC mais preciso é o classificador [11, 16].

4.2 Avaliação dos Classificadores

Nos modelos Redes Neurais e Floresta Aleatória foram feitos ajustes nos parâmetros, de acordo com o comportamento dos resultados obtidos em cada processamento. No modelo Regressão Logística não houve alteração de nenhum parâmetro.

E analisando os resultados da matriz de confusão, o algoritmo Redes Neurais teve uma taxa de precisão de 96,6%. O que mostra que a cada 100 amostras, 97 foram de acordo com o julgamento humano quanto à decisão ou não de transfundir.

No modelo Floresta Aleatória a taxa de precisão foi de 99,4% conforme os resultados da matriz de confusão. O que mostra que a cada 100 amostras, 99 foram de acordo com o julgamento humano quanto à decisão ou não de transfundir.

O desempenho do modelo Regressão Logística foi inferior em relação aos demais testados. Embora taxa de precisão foi de 95,2%. O que mostra que em 100 amostras, 95 foram de acordo com o julgamento humano quanto à decisão ou não de transfundir.

A Tabela 3 mostra uma comparação entre os resultados da taxa de Precisão, Acurácia, Sensibilidade, F1- score, Especificidade para os algoritmos testados e utilizando DataSet

Final. A Figura 2 mostra a comparação dos algoritmos na área sob a curva de características operacionais do receptor. Os valores em negrito são os mais melhores para cada métrica, respectivamente.

5. DISCUSSÃO

Existem protocolos clínicos que indicam transfusões para pacientes críticos e instáveis. Entretanto, a transfusão de sangue é realizada por julgamento de rotina do profissional médico na maioria dos casos. Entidades internacionais buscam padronizar condutas baseadas em evidências científicas para direcionar melhor conduta médica para segurança do paciente, tendo em vista que estudos apontam conduta liberal no uso deste insumo.

O estudo em questão verificou que, o algoritmo de aprendizado de máquina tem condições de reconhecer padrões de diagnóstico usando conjunto de dados estratificados dos pacientes, baseados nos fatores de riscos, identificando se o indivíduo precisa receber transfusão ou uma outra escolha de tratamento. Os modelos de aprendizado de máquina apresentados incorporaram muitas variáveis que foram previamente identificadas como fatores de risco para transfusões de sangue. Idade [10][23][1], hematócrito pré-operatório [10][1] e sexo[5] [23][1] foram previamente identificados como fatores de risco para transfusão pós-operatória.

Essa tecnologia ajudará a identificar casos apropriados para transfusão de sangue com precisão. Os estudos nos países desenvolvidos estão bastante avançados e dessa forma, necessita-se avançar nessa vertente e aprofundar pesquisas com maior número amostral e qualidade dos dados necessários para acurácia da ferramenta.

Neste sentido, mais estudos desta natureza precisam ser realizados, visto que embora o algoritmo de aprendizado de máquina tenha capacidade de mensurar possíveis pacientes de risco, ainda é difícil levar variáveis dinâmicas para o processo de tomada de decisão como especialistas humanos.

Dessa forma, o objetivo do uso de algoritmos inteligentes para identificar casos apropriados para transfusão de sangue não é para substituir o especialista médico, mas auxiliá-lo em sua análise para tomada de decisão clínica. Assim, é notório o valor da tecnologia da informação para verificar a necessidade de transfusão de sangue, o que favorece além da segurança do paciente, economia de recursos e facilita decisão.

6. CONCLUSÃO

Os resultados apontam para confiabilidade da utilização dos modelos para prever riscos de transfusão de sangue. Realidade já verificada nos países desenvolvidos e ainda insipiente no Brasil. O uso de algoritmo de aprendizado de máquina mostra-se como potencial ferramenta para agregar valores aos protocolos que visam implementar programa de gerenciamento de sangue e auxiliará na identificação de casos apropriados para transfusão de sangue com precisão, diminuindo custo e favorecendo a segurança do paciente.

As limitações do estudo incluem a quantidade e qualidade dos dados, atributos insuficientes, erros no preenchimento que podem ter ocasionado divergências entre julgamento humano e os algoritmos. Os trabalhos que embasaram este estudo tiveram seus dados coletados em registros eletrônicos, realidade ainda não observada em diversos locais, como no estudo.

Table 3: Resultados de Auc, acurácia, precisão, sensibilidade, especificidade e F1 score dos modelos Redes neurais, Floresta Aleatória e Regressão Logística.

Método	Métricas					
	AUC	Acurácia	Precisão	Sensibilidade	Especificidade	F1 Score
Redes neurais	0,894	0,932	0,966	0,837	0,95	0,957
Floresta Aleatória	0,97	0,986	0,994	0,945	0,994	0,994
Regressão Logística	0,867	0,94	0,952	0,756	0,978	0,964

Abreviaturas: Auc, área sob a curva ROC.

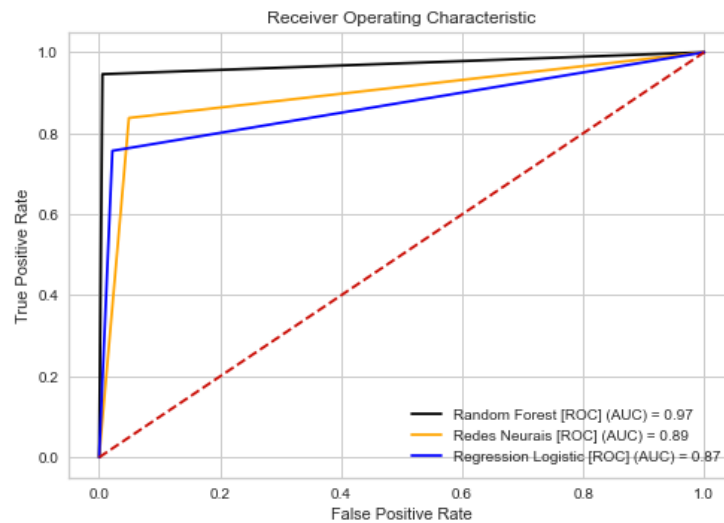


Figura 2: Desempenho dos modelos Redes neurais, Florestas aleatórias e Regressão Logística Para ROC curve (AUC)

Como trabalhos futuros sugerem-se estudos com bases de dados mais extensas, triagem mais acurada, com características e fatores de riscos que não limitem as análises. Outros estudos estão sendo feitos tendo como público puerperas e grávidas. E para interpretar quais os atributos que estão sendo mais importantes na predição será usado Floresta aleatória como processo de seleção de fatores de riscos que levam a transfusão de sangue.

7. REFERENCES

- [1] Previsão de transfusão perioperatória em artroplastia eletiva de quadril e joelho: um modelo preditivo validado. 127.
- [2] J. Bajwa, U. Munir, A. Nori, and B. Williams. Artificial intelligence in healthcare: transforming the practice of medicine. *Future healthcare journal*, 8(2):e188, 2021.
- [3] R. Bittencourt, J. Costa, J. E. d. O. Lobo, and F. C. Aguiar. Consciously transfusion of blood products. systematic review of indicative factors for blood components infusion's trigger. *Revista Brasileira de Anestesiologia*, 62:406–410, 2012.
- [4] L. Breiman. Random forests. *Machine Learning 2001 45:1*, 45:5–32, 10 2001.
- [5] R. A. Burnett, N. A. Bedard, D. E. DeMik, Y. Gao, S. S. Liu, and J. J. Callaghan. Recent trends in blood utilization after revision hip and knee arthroplasty. *The Journal of arthroplasty*, 32(12):3693–3697, 2017.
- [6] W. B. Cohen-Levy, C. Klemt, V. Tirumala, J. C. Burns, A. Barghi, Y. Habibi, and Y.-M. Kwon. Artificial neural networks for the prediction of transfusion rates in primary total hip arthroplasty. *Archives of Orthopaedic and Trauma Surgery*, 143(3):1643–1650, 2023.
- [7] T. Davenport and R. Kalakota. The potential for artificial intelligence in healthcare. *Future healthcare journal*, 6(2):94, 2019.
- [8] T. G. Dietterich. Approximate statistical tests for comparing supervised classification learning algorithms. *Neural computation*, 10(7):1895–1923, 1998.
- [9] T. Edgar and D. Manz. *Research methods for cyber security*. Syngress, 2017.
- [10] H.-C. Erben, F. Hess, J. Welter, N. Graf, M. P. Steuerer, T. A. Neff, R. Zettl, and A. Dullenkopf. Perioperative blood transfusions in hip and knee arthroplasty: a retrospective assessment of combined risk factors. *Archives of Orthopaedic and Trauma Surgery*, pages 1–6, 2021.
- [11] P. A. Flach. *ROC Analysis*, pages 1109–1116. Springer US, Boston, MA, 2017.
- [12] G. Flausino, F. F. Nunes, J. G. M. Cioffi, and A. B. de Freitas. O ciclo de produção do sangue e a transfusão: o que o médico deve saber. *Rev Med Minas Gerais*, 25(2):269–279, 2015.
- [13] R. Kohavi. Glossary of terms special issue on

- applications of machine learning and the knowledge discovery process. 30:271–274, 1998.
- [14] S. Liu, R. Zhou, X.-Q. Xia, H. Ren, L.-Y. Wang, R.-R. Sang, M. Jiang, C.-C. Yang, H. Liu, L. Wei, et al. Machine learning models to predict red blood cell transfusion in patients undergoing mitral valve surgery. *Annals of Translational Medicine*, 9(7), 2021.
- [15] A. J. Londres. Inteligência artificial na medicina: superando ou recapitulando desafios estruturais para melhorar o atendimento ao paciente? *Cell Reports Medicine*, page 100622, 2022.
- [16] D. S. Luz, T. J. Lima, R. R. Silva, D. M. Magalhães, and F. H. Araujo. Automatic detection metastasis in breast histopathological images based on ensemble learning and color adjustment. *Biomedical Signal Processing and Control*, 75:103564, 2022.
- [17] W. S. McCulloch and W. Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, 1943.
- [18] A. Mitterecker, A. Hofmann, K. M. Trentino, A. Lloyd, M. F. Leahy, K. Schwarzbauer, T. Tschoellitsch, C. Böck, S. Hochreiter, and J. Meier. Machine learning-based prediction of transfusion. *Transfusion*, 60(9):1977–1986, 2020.
- [19] N. Moura, R. Veras, K. Aires, V. Machado, R. Silva, F. Araújo, and M. Claro. Combining abcd rule, texture features and transfer learning in automatic diagnosis of melanoma. In *2018 IEEE Symposium on Computers and Communications (ISCC)*, pages 00508–00513, 2018.
- [20] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830, 2011.
- [21] L. R. O. Santos. Análise do uso das transfusões de sangue em hospital terciário: subsídios para prática transfusional segura, 2021. Tese (Doutorado em Enfermagem) - Universidade Federal do Piauí.
- [22] L. R. O. Santos, L. O. Cruz, P. N. dos Santos Marques, K. A. de Oliveira Santos, M. T. A. Ferreira, T. L. de Barros, G. R. F. da Silva, I. L. de Carvalho Silva, A. de Sousa Mourão, A. B. de Araújo, L. de Macedo Sousa Frazão, and P. F. L. Veras. *Perfil Clínico E Epidemiológico de Pacientes Pós-Cirúrgicos Submetidos a Hemotransfusão*. Editora Omnis Scientia, 2021.
- [23] J. Slover, J. A. Lavery, R. Schwarzkopf, R. Iorio, J. Bosco, and H. T. Gold. Incidence and risk factors for blood transfusion in total joint arthroplasty: analysis of a statewide database. *The Journal of arthroplasty*, 32(9):2684–2687, 2017.
- [24] K. M. Ting. *Confusion Matrix*. Springer US, 2017.
- [25] Z. Wang, S. Zhe, J. Zimmerman, C. Morrissey, J. E. Tonna, V. Sharma, and R. A. Metcalf. Development and validation of a machine learning method to predict intraoperative red blood cell transfusions in cardiothoracic surgery. *Scientific Reports*, 12(1):1355, 2022.
- [26] WHO et al. National standards for blood transfusion service edition 1-2013 blood safety program, health care and diagnostic division department of medical services ministry of health thimphu: Bhutan. 2013.
- [27] Y. Yao, J. Cifuentes, B. Zheng, and M. Yan. Computer algorithm can match physicians’ decisions about blood transfusions. *Journal of Translational Medicine*, 17, 10 2019.
- [28] B. Yudelowitz, J. Scribante, H. Perrie, and E. Oosthuizen. Knowledge of appropriate blood product use in perioperative patients among clinicians at a tertiary hospital. *Health SA Gesondheid*, 21:309–314, 12 2016.