

Análise Comparativa de Modelos Estatísticos e Redes Neurais na Detecção de Cistite a partir de Dados Clínicos

Rhyan Ximenes de Brito
 Campus Tianguá-CE
 Instituto Federal do Ceará (IFCE)
 Tianguá- CE, Brasil
 rxbrito@gmail.com

Janaide Nogueira de Sousa Ximenes
 Campus Óbidos - PA
 Instituto Federal do Pará (IFPA)
 Óbidos - PA, Brasil
 nogueirajanaide@gmail.com

Resumo—Este estudo avaliou a aplicação de algoritmos de Inteligência Artificial (IA) no apoio ao diagnóstico de cistite aguda, a partir de dados clínicos provenientes de um *dataset* público. O objetivo principal foi comparar o desempenho de classificadores supervisionados incluindo Redes Neurais Artificiais (RNAs) e métodos estatísticos na detecção de inflamações da bexiga urinária. A metodologia envolveu etapas de pré-processamento, balanceamento de classes, normalização e validação cruzada estratificada. O classificador *Linear Discriminant Analysis* (LDA) apresentou o melhor desempenho, com acurácia de 99,17%, precisão de 99,23%, *F1-Score* de 99,17%. Outros modelos com desempenho destacado foram *Radial Basis Function* (RBF), *Random Forest* (RF), *Quadratic Discriminant Analysis* (QDA), *Support Vector Machine* (SVM) com *kernel* RBF e *K-Nearest Neighbors* (K-NN), todos com acurácias superiores a 93%. O classificador *Extreme Learning Machine* (ELM) também demonstrou desempenho robusto, com acurácia de 95% e AUC de 98,89%. Em contrapartida, o *Multilayer Perceptron* (MLP) apresentou resultados inferiores entre as redes neurais artificiais, com acurácia de 74,17% e AUC de 86,09%. Modelos baseados em *boosting* como *XGBoost*, *CatBoost* e *AdaBoost* exibiram desempenho intermediário, com acurácias entre 77% e 89%, e AUCs superiores a 94%. Os resultados indicam que métodos discriminantes lineares e modelos de *ensemble* são mais eficazes que abordagens probabilísticas simples e redes neurais convencionais no apoio ao diagnóstico clínico da cistite aguda.

Palavras-chaves—classificadores, detecção, cistite, análise de dados.

I. INTRODUÇÃO

De acordo com [1], as infecções no trato urinário são processos infecciosos que podem ter diferentes causas, sendo as mesmas relacionadas a microrganismos como bactérias residentes na microbiota intestinal, fungos ou vírus que atacam o trato urinário baixo, assim sendo chamado de cistite ou pielonefrite se agredir o trato urinário alto, causando problemas nos rins.

Infecção no trato urinário baixo ou cistite é caracterizada principalmente quando ocorre a invasão de microrganismos na bexiga, levando a uma inflamação, por outro lado a pielonefrite é a infecção do trato urinário alto relacionada a invasão e

adesão de microrganismos nos rins, tendo sintomas variados desde febre, calafrios, dor na região dos flancos, náuseas e vômitos. É importante salientar que o agente patológico causal em grande maioria dos casos é a *Escherichia coli* com cerca de 75% dos casos [2].

Outro aspecto importante a ser ressaltado são os grupos mais acometidos, mulheres pela proximidade entre o ânus e a vagina e por apresentarem uretra mais curta que indivíduos do sexo masculino, crianças e principalmente lactantes [1].

Dada a elevada prevalência da cistite e a necessidade de diagnóstico precoce e eficiente, torna-se relevante o desenvolvimento de ferramentas auxiliares que possam apoiar profissionais da saúde no processo decisório. Muitas vezes, o diagnóstico é realizado com base apenas em sintomas autorrelatados, o que pode gerar incertezas e subdiagnósticos. Nesse cenário, métodos computacionais têm sido explorados como alternativa complementar para a triagem automatizada de condições clínicas [3].

Para [4] o reconhecimento de padrões é uma habilidade bastante desenvolvida tanto em seres humanos como em alguns animais, como no reconhecimento do próprio dono ou dos filhotes. Em termos computacionais, um sistema de reconhecimento de padrões aborda três etapas: (i) representação e mensuração dos dados de entrada; (ii) extração de características; e (iii) identificação e classificação do objeto estudado. Em suma, a primeira etapa trata da representação dos dados mensuráveis; a segunda envolve a seleção de atributos relevantes, reduzindo a dimensionalidade do vetor padrão; e a terceira corresponde à definição de um modelo capaz de realizar a classificação [4].

Nesse contexto, técnicas de Aprendizado de Máquina (AP) uma vertente da Inteligência Artificial (IA) vêm se consolidando como ferramentas eficazes para reconhecimento de padrões em dados clínicos. Esses métodos têm como objetivo desenvolver sistemas computacionais capazes de aprender com dados históricos e tomar decisões automatizadas com base em experiências anteriores [5]. A flexibilidade desses algoritmos

permite seu uso em cenários médicos reais, desde que acompanhados de uma curadoria metodológica adequada e validações rigorosas.

Em vista da importância da aplicação de técnicas de IA na área da saúde, este trabalho teve como finalidade o desenvolvimento de uma aplicação para reconhecimento de padrões voltada à predição de inflamações agudas da bexiga urinária, auxiliando, assim, na definição de condutas clínicas mais adequadas com base em uma diagnose presuntiva.

A principal contribuição deste estudo está na demonstração empírica da eficácia de um modelo estatístico simples, de fácil interpretação e baixo custo computacional, que superou técnicas mais complexas em um cenário real de diagnóstico de cistite. Assim evidenciando que a sofisticação algorítmica não é, necessariamente, sinônimo de melhor desempenho, sobretudo em conjuntos de dados com estrutura binária e baixa dimensionalidade. Ao destacar essa perspectiva, este trabalho oferece uma alternativa prática, acessível e eficiente, promovendo o uso consciente e fundamentado da IA em contextos médicos.

Este trabalho está organizado em 5 seções: A seção 2 apresenta os trabalhos relacionados abordando diferentes temáticas do reconhecimento de padrões aplicados à área de saúde. A seção 3 traz um aprofundamento a cerca dos principais conceitos utilizados no estudo; A seção 4 apresenta os materiais e métodos aplicados. A seção 5 versa sobre os resultados e discussões. A seção 6 apresenta as considerações finais e trabalhos futuros.

II. TRABALHOS RELACIONADOS

Esta seção exibe uma revisão bibliográfica com abordagem focada na utilização de técnicas de Inteligência Computacional em problemas na área de saúde. Assim observa-se que:

O estudo de [6] relacionou a importância do entendimento dos níveis de dor comparando nove arquiteturas de redes neurais convolucionais para reconhecimento de dor facial, utilizando três otimizadores e imagens do *dataset UNBC-McMaster*. Os resultados indicaram que a arquitetura *InceptionV3* obteve o melhor desempenho, com acurácia de 90,69%.

As doenças cardíacas causam 12 milhões de mortes anualmente, elas representaram um aumento de 53% nas fatalidades entre 2014 e 2019. Na Índia por exemplo, as mortes cardiovasculares variaram de 2,26 a 4,77 milhões entre 1990 e 2020, com prevalência entre 1,6% para 7,4% nas áreas rurais e 1% para 13,2% nas urbanas [7].

As infecções do trato urinário (ITUs) são as mais comuns em humanos, afetando principalmente a bexiga e a uretra. Se não tratadas, podem se espalhar para os rins, causando complicações graves. O estudo de [8] avaliou as causas das ITUs e a eficácia do aprendizado de máquina na previsão dessas infecções. Utilizando uma rede neural artificial e algoritmos como *Naive Bayes* e J48, o modelo atingiu uma precisão de aproximadamente 85,6% na previsão de ITUs.

O estudo de [9] propôs um modelo de Inteligência Artificial para prever infecções urinárias provocadas por bactérias resistentes, utilizando dados clínicos de 762 pacientes. A

rede neural desenvolvida demonstrou alto desempenho, com acurácia de 96,1% na detecção de enterobactérias produtoras de carbapenemase e 91,6% para aquelas com beta-lactamase de espectro estendido. Com elevada sensibilidade e especificidade, o sistema mostrou-se eficaz para apoiar o diagnóstico precoce, contribuir para a escolha de terapias mais assertivas e reduzir os custos com internações.

[10] desenvolveu um modelo de segmentação semântica para imagens do rim, explorando diferentes otimizadores, resoluções, transformações de dados e arquiteturas, a fim de identificar a melhor configuração. O resultado foi um modelo totalmente convolucional baseado em uma variação da U-Net, capaz de segmentar tecidos funcionais renais, com ênfase nos glomérulos. Com uma pontuação no Índice de Similaridade de Dice de 92,33% na competição *Hacking the Kidney*, o modelo superou 74% das submissões, demonstrando alto desempenho e potencial para aplicação em diagnósticos automatizados de doenças renais e outras áreas da medicina.

Já [11] realizou um estudo com dados hospitalares de 2015 a 2019, aplicando modelos supervisionados para prever infecções hospitalares, utilizando técnicas de *sobresampling* para lidar com o desbalanceamento. Após o processamento dos dados clínicos e demográficos, o *XGBoost* obteve os melhores resultados, com 98,80% de acurácia, AUROC de 97,33%, *F1-score* de 99,56% e *recall* de 99,60%. O *Random Forest* ficou em segundo lugar, com desempenho também elevado. Os resultados confirmam a eficácia de modelos baseados em árvores de decisão, com destaque para o *XGBoost*.

[12] propôs a aplicação de técnicas de Inteligência Artificial utilizando imagens públicas de radiografias torácicas. Assim foram extraídas características relevantes para o treinamento de modelos de classificação baseados em aprendizado de máquina. Os resultados demonstraram uma acurácia de 88% na distinção entre pneumonia viral e bacteriana, evidenciando o potencial da abordagem em apoiar o diagnóstico precoce e auxiliar profissionais de saúde na tomada de decisão clínica.

Em [13] avaliaram a eficácia de técnicas de segmentação e extração de atributos em imagens dermatoscópicas, utilizando algoritmos como *Otsu*, *Watershed* e *Chan-Vese*, além de métodos como GLCM, LBP e SCM. Para a classificação, foram aplicados *Random Forest*, KNN e MLP sobre o conjunto de dados PH2. Os modelos alcançaram resultados expressivos, com acurácia de 95%, precisão de 96%, revocação de 100%, especificidade de 92% e *F1-score* de 95%, demonstrando o potencial dessas abordagens para apoiar o diagnóstico preciso do melanoma em aplicações clínicas.

No estudo de [14], foram avaliados os algoritmos *Random Forest* e *Support Vector Machine* na tarefa de classificar níveis de obesidade, com base em dados sobre hábitos alimentares e condição física. Utilizando validação cruzada e divisão *hold-out*, o classificador *Random Forest* obteve acurácia média de 95,18%, superando a SVM, que atingiu 87,84%. A proposta demonstrou alta sensibilidade na detecção de sobrepeso e obesidade, especialmente nos estágios mais graves, destacando-se frente a estudos anteriores. Os resultados indicam que os modelos são promissores para o monitoramento e diagnóstico

da obesidade.

O estudo de [15] comparou o desempenho das redes neurais MLP e ELM na classificação de adolescentes com e sem Transtorno do Espectro Autista (TEA), utilizando um conjunto de 99 amostras e validação cruzada *k-fold*. Os testes foram realizados com e sem normalização dos dados pelo método *z-score*. A MLP sem normalização apresentou a melhor performance, alcançando acurácia média de 89,70%, enquanto o pior resultado foi da ELM, também sem normalização, com 86,52%. Os resultados evidenciam a relevância do pré-processamento e destacam a MLP como uma abordagem promissora para a triagem de TEA.

[16] propuseram um estudo para avaliar o desempenho da arquitetura HRNet na segmentação de imagens de tomografia computadorizada de pacientes com tumores renais, utilizando o conjunto de dados KiTS19. Aplicando estratégias de otimização de modelos, os resultados demonstraram elevado desempenho, com *Dice score* de 91,4% para segmentação dos rins e 70,3% para os tumores, evidenciando o potencial da abordagem no auxílio ao diagnóstico do câncer renal.

[17] apresentou uma estratégia de redes neurais artificiais com taxa de aprendizado adaptativa, visando ao diagnóstico de inflamações agudas a partir de dados clínicos. Utilizando o conjunto *Acute Inflammations*, com 120 instâncias e seis atributos sintomáticos, o autor comparou dois algoritmos: o *Backpropagation* tradicional (BP) e o *Backpropagation with Adaptive Learning* (BPAL). No cenário de classificação de cistite e pielonefrite, o modelo BP alcançou até 92,5% de acurácia e 85% de sensibilidade, enquanto o BPAL atingiu 100% em todas as métricas, evidenciando ganhos relevantes na performance diagnóstica.

[18] propôs um modelo generativo que apresentou resultados satisfatórios na tarefa de descrição automática de imagens médicas, alcançando uma acurácia de 76,28% e um valor de BLEU-1 de 0,5387. Esses indicadores refletem um desempenho coerente na geração de textos alinhados às anotações originais, sugerindo que o modelo possui capacidade de produzir descrições relevantes e semanticamente próximas às referências humanas, mesmo considerando a diversidade presente no *dataset* ROCO.

Apesar dos avanços observados nos estudos revisados, muitas das abordagens apresentadas enfrentam limitações recorrentes. Alguns trabalhos concentram-se em tarefas específicas, como reconhecimento facial de dor [6] ou segmentação de imagens médicas [10], [16], restringindo sua aplicabilidade a domínios com dados visuais e infraestrutura computacional robusta. Outros estudos, como os de [8], [9], [17], utilizam algoritmos de aprendizado de máquina para a previsão de infecções urinárias, mas não exploram comparações entre diferentes paradigmas de classificação, tampouco discutem a interpretabilidade dos modelos, aspecto essencial na área da saúde. Além disso, há pouca padronização na validação cruzada e nos critérios de escolha de hiperparâmetros, o que pode comprometer a generalização dos resultados.

Dessa forma, o presente trabalho diferencia-se ao propor uma análise comparativa entre múltiplos algoritmos, incluindo

classificadores estatísticos e redes neurais artificiais, avaliados de forma sistemática sobre uma base pública de dados clínicos voltada à detecção de cistite. A proposta adota uma metodologia unificada, com pré-processamento padronizado, balanceamento de classes, *stratified k-fold cross-validation* e ajuste explícito de hiperparâmetros. Além disso, destaca-se a ênfase na simplicidade e transparência dos modelos, fornecendo alternativas viáveis e acessíveis para o apoio ao diagnóstico clínico, especialmente em cenários com baixa disponibilidade de recursos tecnológicos. Com isso, busca-se preencher lacunas deixadas por trabalhos anteriores, aliando desempenho preditivo, baixo custo computacional e responsabilidade ética no uso da inteligência artificial na saúde.

III. FUNDAMENTAÇÃO TEÓRICA

Esta seção traz um estudo sobre inflamação aguda da bexiga urinária em particular a cistite aguda, abordando também diversos classificadores *Multilayer Perceptron*, *Random Forest*, *Extreme Learning Machine*, *Naive Bayes* dentre outros. As subseções foram organizadas da seguinte forma: A. Inflamações Agudas da Bexiga Urinária; B. *Multilayer Perceptron*; C. *Radial Basis Function*; D. *Support Vector Machine*; E. *Random Forest*; F. *Naive Bayes*; G. *Extreme Learning Machine*; H. *K-Nearest Neighbor*; I. *Linear Discriminant Analysis*; J. *Quadratic Discriminant Analysis*; K. *Logistic Regression*; L. *Adaptive Boosting*; M. *Categorical Boosting*.

A. Inflamações Agudas da Bexiga Urinária

De forma genérica considera-se inflamação ou processo inflamatório a resposta do organismo a qualquer tipo de agressão sofrida, em se tratando do sistema renal, a inflamação participa de forma ativa dos mecanismos de progressão da lesão [19]. Assim sabe-se que a infecção do trato urinário tem como característica a invasão e multiplicação bacteriana, acometendo os rins e as vias urinárias [20].

Nessa perspectiva sabe-se que doenças como a pielonefrite que é uma inflamação renal que ocorre quando bactérias viventes no trato urinário sobem através dos ureteres e chegam até os rins, podem causar inflamações agudas e crônicas [21].

De acordo com Moura. et. al, (2021), a infecção do trato urinário é uma patologia que ocorre com frequência em diferentes faixas etárias do desenvolvimento humano, desde o neonato ao idoso, com a mulher tendo maior fragilidade devido à uretra mais curta e a maior proximidade do ânus com o vestíbulo vaginal e uretra.

Existem diferentes tipos de infecções do trato urinário, entre elas podem ser citadas: (i) cistite, causada pela aderência bacteriana na bexiga; (ii) pielonefrite aguda, que afeta os rins e suas estruturas; (iii) bacteriúria de baixa contagem, geralmente por *Escherichia coli* ou *Staphylococcus saprophyticus*; (iv) bacteriúria assintomática, com bactérias na urina sem sintomas; (v) síndrome piúria; e (vi) contaminação com baixas contagens bacterianas ou múltiplos microrganismos [22], [23].

B. Multilayer Perceptron (MLP)

As Redes Neurais Artificiais (RNAs) são sistemas que processam funções matemáticas, generalizando conhecimento e extraindo características dos dados. Amplamente utilizadas no reconhecimento de padrões, destacam-se pela eficiência na manipulação de grandes volumes de dados sem pressupor distribuições específicas [24]–[27].

Nessa perspectiva uma Rede *Multilayer Perceptron* (MLP) é um modelo *feedforward* totalmente conectado, composto por uma camada de entrada, uma ou mais ocultas e uma de saída. Seus neurônios utilizam funções de ativação não lineares e diferenciáveis, permitindo a separação de padrões complexos e o ajuste dos pesos durante o treinamento [28].

Segundo [29], as redes MLP são eficazes para problemas complexos com alta não linearidade. Seu treinamento supervisionado utiliza o algoritmo de retropropagação do erro, que ajusta os pesos para minimizar erros.

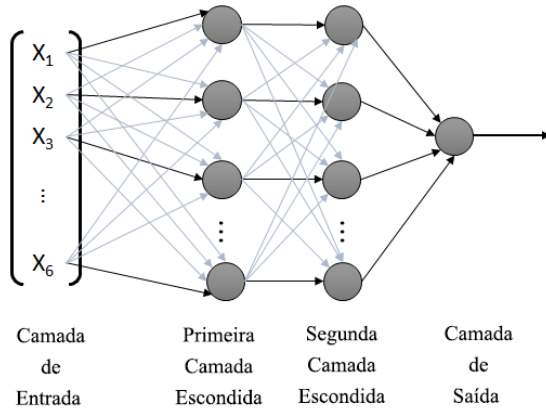


Figura 1. Arquitetura de Uma Rede Neural MLP

A Figura 1 mostra a estrutura básica de uma RNA do tipo MLP, usada em classificação, regressão, previsão e modelagem de séries temporais em áreas como controle, diagnósticos e *data mining* [30], [31].

C. Radial Basis Function (RBF)

Para [32] as RBFs são modelos de redes neurais artificiais baseados na capacidade de certos neurônios biológicos de responder de forma seletiva a estímulos específicos. Essas células, presentes em diversas regiões dos sistemas nervosos biológicos, são ativadas por características determinadas dentro de áreas limitadas do espaço de entrada dos sinais.

A estrutura típica de uma rede de função de base radial consiste em três camadas: uma camada de entrada, responsável por receber diretamente os dados; uma única camada oculta, onde funções de ativação de base radial realizam uma transformação não linear do espaço de entrada; e uma camada de saída linear, que gera a resposta correspondente ao padrão aplicado [31].

A Figura 4 apresenta a estrutura básica de uma rede neural RBF. Sabe-se que assim como as redes neurais MLP, as RBF são utilizadas para aproximação de funções e classificação de padrões em espaços de alta dimensionalidade. Seus neurônios




Figura 2. Arquitetura de Uma Rede Neural RBF

de saída realizam uma combinação linear das funções base, que são computadas pelos neurônios da camada intermediária [33].

D. Support Vector Machine (SVM)

As Máquinas de Vetores de Suporte são uma técnica de aprendizado amplamente estudada, frequentemente superando outros algoritmos, como as RNAs. São aplicadas com sucesso em áreas como categorização de textos, análise de imagens e Bioinformática [34].

As SVMs, baseadas na teoria de aprendizado estatístico de Vapnik, buscam criar classificadores com boa generalização. Elas determinam limites de decisão que maximizam a separação entre classes, minimizando erros, sendo amplamente utilizadas no reconhecimento de padrões [34], [35].

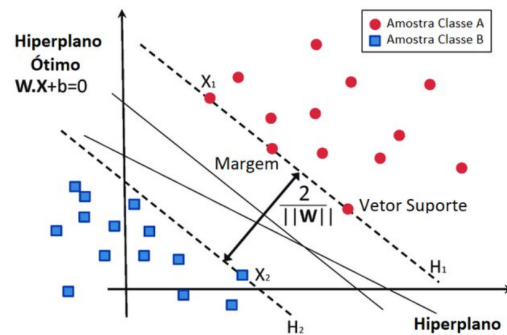


Figura 3. Exemplo de Classificação com SVM

A Figura 3 ilustra o conceito de Máquinas de Vetores de Suporte, um algoritmo de aprendizado de máquina para classificação. Este método é amplamente utilizado para classificação em problemas de aprendizagem de máquina devido a sua capacidade de generalização [34], [36].

A função *kernel* neste classificador torna-se fundamental no processo de localização de limites entre classes que formam regiões com algum grau de complexidade. Nessa perspectiva sabe-se da importância da escolha de uma função de *kernel* adequada com seus respectivos valores apropriados de parâmetros, podendo assim afetar consideravelmente a performance do SVM [37].

Tabela I
EXEMPLOS DE *Kernels* E SUAS FUNÇÕES

Tipo de Kernel	Função
Polinomial com grau d	$K(x', x) = (\gamma \cdot x' \cdot x + y)^d$
Linear	$K(x', x) = x' \cdot x$
Sigmoide	$K(x', x) = \tanh(\gamma \cdot x' \cdot x + y)$
RBF	$K(x', x) = \exp(-\gamma \cdot \ x - x'\ ^2)$

Como pode ser observado na Tabela I, diferentes tipos de *kernels* são utilizados para transformar os dados em espaços de maior dimensionalidade, cada um com sua respectiva função e parâmetros. Essas funções determinam o comportamento do classificador, influenciando diretamente a forma como os dados são separados no espaço de decisão.

E. Random Forest (RF)

O *Random Forest* trata-se de um método estatístico não paramétrico que não requer suposições sobre a distribuição das variáveis explicativas em relação à variável resposta. Além disso, é uma técnica não linear robusta que otimiza a acurácia da predição ao realizar um ajuste sobre um conjunto de árvores, com o objetivo de estabilizar as estimativas do modelo [38].

De acordo com [39], o RF é um algoritmo de classificação baseado na construção de múltiplas árvores de decisão. Vale destacar que uma árvore de decisão é uma técnica de mineração de dados utilizada para identificar regras de classificação a partir da subdivisão dos dados em diferentes subconjuntos. Essas árvores representam de forma simples o conhecimento extraído, classificando exemplos em um número finito de classes.

[38] define o RF como um classificador composto por uma coleção de árvores de decisão $\{h_k(x) \mid k = 1, 2, \dots, L\}$, onde cada h_k representa uma árvore construída a partir de amostras aleatórias independentes e identicamente distribuídas. Cada árvore vota na classe mais frequente para uma entrada x . Para gerar essas árvores, é aplicado um método de amostragem com reposição, denominado *Bootstrap*, no qual novos conjuntos de atributos são selecionados aleatoriamente.

A Figura 4 representa o funcionamento do RF, um algoritmo de aprendizado de máquina baseado no conceito de *ensemble learning*, ou seja, no aprendizado em conjunto. Esse método combina múltiplas árvores de decisão para obter uma previsão mais precisa e robusta.

F. Naive Bayes (NB)

O classificador *Naive Bayes* utiliza as informações dos dados amostrais para estimar a probabilidade a priori que pode ser representada da seguinte forma $P(y \mid x)$, para cada classe y dado um objeto x . Assim podendo utilizá-lo para classificação ou suporte à decisão [40]. Ressalta-se que o classificador NB baseia-se na aplicação do Teorema de *Bayes* calculando as probabilidades necessárias para a classificação. Dessa forma para determinar a classe mais provável da nova instância, calcula-se a probabilidade de todas as possíveis classes e, no

fim, escolhe-se aquela com a maior probabilidade como rótulo da nova instância [41], [42].

Para [43], o Teorema de *Bayes* é uma fórmula usada para calcular a probabilidade de um evento A , dado que outro evento B já ocorreu. A fórmula é expressa como:

$$P(A \mid B) = \frac{P(B \mid A) \cdot P(A)}{P(B)} \quad (1)$$

Onde:

- $P(A \mid B)$ é a probabilidade de A dado B (probabilidade posterior);
- $P(B \mid A)$ é a probabilidade de B dado A (probabilidade condicional);
- $P(A)$ é a probabilidade a priori de A ;
- $P(B)$ é a probabilidade de B .

De acordo com [44] o teorema bayesiano permite, no contexto de decisões clínicas, atualizar a probabilidade de eventos a priori, com informações para obter uma probabilidade a posteriori. Sendo uma ferramenta importante para lidar com as incertezas que os clínicos enfrentam na prática diária.

G. Extreme Learning Machine (ELM)

As Máquinas de Aprendizado Extremo consistem em redes neurais do tipo *feedforward*, estruturalmente semelhantes às redes MLP tradicionais [29], porém com um diferencial relevante no processo de treinamento. Nas ELMs, os pesos da camada oculta são atribuídos de forma aleatória e permanecem fixos, enquanto apenas os pesos da camada de saída são ajustados por meio de uma solução fechada de mínimos quadrados. Essa abordagem elimina a necessidade de métodos iterativos tradicionais de retropropagação, proporcionando maior eficiência computacional [45].

As ELMs foram fundamentadas em uma demonstração matemática que comprova a viabilidade de escolha aleatória dos parâmetros da camada oculta, desde que se utilize funções de ativação infinitamente diferenciáveis. Os autores também estabeleceram a capacidade de aproximação universal das ELMs, evidenciando sua aptidão para modelar qualquer mapeamento não linear com erro arbitrariamente pequeno, tornando-as uma alternativa promissora para tarefas de classificação e regressão em larga escala [45].

A Figura 5 mostra uma rede neural do tipo *feedforward* com uma única camada oculta. As entradas X_1, X_2, \dots, X_n são conectadas a n_h neurônios da camada oculta, os quais aplicam funções de ativação não lineares. As saídas dessa camada são então combinadas por n_i neurônios na camada de saída, resultando nos valores finais y_1, y_2, \dots, y_i . Essa arquitetura é comumente utilizada em tarefas de classificação e regressão, sendo a base de modelos como o ELM.

H. K-Nearest Neighbors (K-NN)

O algoritmo dos k -vizinhos mais próximos é amplamente utilizado em tarefas de classificação supervisionada, sendo reconhecido por sua simplicidade e eficácia, especialmente em domínios com estrutura bem definida [46]. Trata-se de um método baseado em instâncias que classifica um novo

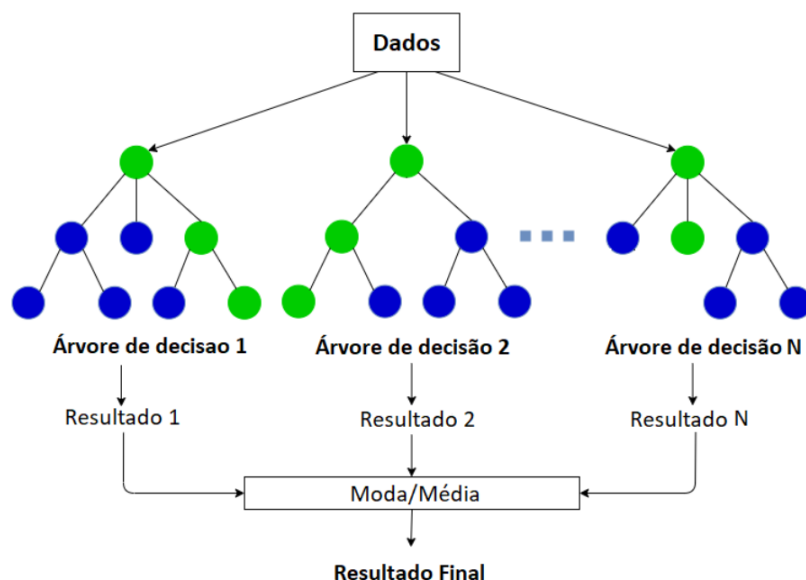


Figura 4. Exemplo de Classificação com RF




Figura 5. Rede Neural ELM

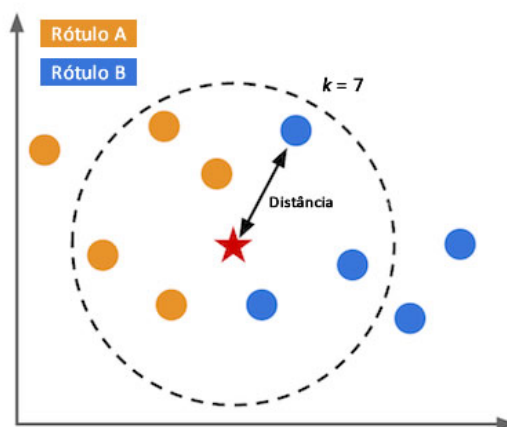


Figura 6. Representação do Classificador K-NN

exemplo com base nos k exemplos mais próximos em um espaço métrico. Sua aplicabilidade, no entanto, está diretamente relacionada à dimensionalidade e à complexidade dos dados, sendo necessário avaliar seu desempenho conforme as características específicas de cada conjunto de dados em um espaço \mathbb{R}^m [46].

Entre as principais propriedades do K-NN, destacam-se: (i) a simplicidade de implementação, exigindo apenas a definição do parâmetro k , correspondente ao número de vizinhos a serem considerados; (ii) a independência de suposições a priori sobre a distribuição dos dados; e (iii) a convergência, sob determinadas condições, para a solução ótima segundo o classificador bayesiano, o que reforça sua fundamentação estatística e robustez em problemas de classificação [47].

A Figura 6 representa um problema com duas classes definidas: o rótulo A, representado pelo círculo amarelo; o rótulo B, representado pelo círculo azul; e uma classe desconhecida, representada pela estrela.

1. Linear Discriminant Analysis (LDA)

A Análise Discriminante Linear é um método estatístico que visa maximizar a separação entre classes enquanto minimiza a variação interna dos dados em cada classe [48]. Considerada uma técnica clássica no reconhecimento de padrões, foi inicialmente desenvolvida por Ronald Fisher em 1936, sendo também conhecida como *Fisher's Linear Discriminant* (FLD) [49]. É amplamente utilizada tanto para tarefas de classificação quanto para redução de dimensionalidade.

A Análise Discriminante Linear consiste em uma técnica estatística que tem como objetivo encontrar uma combinação linear das variáveis preditoras que proporcione a maior separação possível entre dois ou mais grupos previamente estabelecidos. Essa combinação resulta em uma função discriminante, a qual busca maximizar a distância entre as médias

dos grupos, ao mesmo tempo em que minimiza a variabilidade dentro de cada grupo [50]. Sob uma perspectiva estatística, essa metodologia pode ser interpretada como uma forma especial de regressão linear, em que a variável dependente assume valores categóricos binários, representando a pertença da observação a um dos grupos analisados [49].

A função discriminante linear utilizada pelo classificador LDA pode ser expressa da seguinte forma [51]:

$$\delta_k(x) = x^T \Sigma^{-1} \mu_k - \frac{1}{2} \mu_k^T \Sigma^{-1} \mu_k + \ln \pi_k$$

onde cada termo é interpretado da seguinte maneira:

- x representa o vetor de atributos da amostra a ser classificada;
- μ_k é o vetor média dos atributos da classe k ;
- Σ é a matriz de covariância comum estimada a partir dos dados de todas as classes;
- Σ^{-1} é a inversa da matriz de covariância comum;
- π_k denota a probabilidade a priori da classe k , ou seja, a proporção de amostras pertencentes à classe k ;
- $\delta_k(x)$ é a função discriminante para a classe k , sendo que a amostra x será atribuída à classe com o maior valor de $\delta_k(x)$.

J. Quadratic Discriminant Analysis (QDA)

Segundo [51], assim como ocorre na Análise Discriminante Linear, a Análise Discriminante Quadrática parte do pressuposto de que as observações em cada classe K seguem uma distribuição normal multivariada, sendo as estimativas dos parâmetros obtidas com base no Teorema de Bayes. No entanto, diferentemente da LDA, na QDA cada classe possui sua própria matriz de covariância, ou seja, uma observação pertencente à classe k segue $X \sim \mathcal{N}(\mu_k, \Sigma_k)$, em que Σ_k representa a matriz de covariância específica da classe k . Com isso, o classificador bayesiano atribui a observação $X = x$ à classe cujo valor da função discriminante for máximo.

A função discriminante quadrática utilizada na QDA é dada por:

$$\delta_k(x) = -\frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} (x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k) + \ln \pi_k$$

onde:

- x é o vetor de atributos da amostra a ser classificada;
- μ_k é o vetor média da classe k ;
- Σ_k é a matriz de covariância da classe k ;
- $|\Sigma_k|$ representa o determinante da matriz de covariância da classe k ;
- π_k é a probabilidade a priori da classe k ;
- $\delta_k(x)$ é o valor da função discriminante da classe k , e a classe com maior $\delta_k(x)$ é escolhida como predição.

K. Logistic Regression (LR)

A LR é amplamente empregada em situações em que a variável dependente assume apenas dois possíveis resultados, como presença ou ausência de determinada condição, codificados geralmente como 0 e 1. Trata-se de um modelo estatístico

que descreve a relação entre essa variável binária e um conjunto de variáveis explicativas X_1, X_2, \dots, X_p , possibilitando a estimativa da probabilidade de ocorrência do evento de interesse, $P(Y = 1)$, por meio de uma função logística [52], [53]. Conforme pode ser observado a seguir:

$$P(Y = 1) = \frac{\exp(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)}{1 + \exp(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)}$$

em que os parâmetros $\beta_0, \beta_1, \dots, \beta_p$ são estimados pelo método da máxima verossimilhança.

A transformação central do modelo é a chamada *logit*, definida como:

$$g(x) = \log \left(\frac{P(Y = 1)}{1 - P(Y = 1)} \right) = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p$$

A transformação empregada no modelo logístico é linear em relação aos parâmetros, contínua e definida em todo o domínio real, variando de $-\infty$ a $+\infty$. Tal característica confere ao modelo vantagens relevantes, destacadas pelos autores, como a flexibilidade matemática e a simplicidade de implementação computacional. Além disso, a interpretação dos coeficientes estimados é considerada acessível e informativa, o que favorece análises explicativas consistentes e de fácil comunicação [52], [53].

L. Adaptive Boosting (AdaBoost)

O *AdaBoost* é um método de aprendizado supervisionado que constrói um modelo preditivo robusto a partir da combinação sequencial de múltiplos classificadores fracos. Por meio de um processo iterativo, o algoritmo ajusta os pesos atribuídos às instâncias do conjunto de treinamento, de modo que os exemplos incorretamente classificados em uma etapa passem a receber maior atenção nas iterações subsequentes [54]. Esse mecanismo adaptativo permite ao modelo capturar gradualmente padrões mais complexos, refinando sua capacidade de generalização. Ao término do processo, os classificadores individuais são agregados com pesos proporcionais à sua acurácia, resultando em um modelo final mais estável e menos suscetível a erros [54], [55].

O funcionamento do algoritmo *AdaBoost* fundamenta-se em um mecanismo adaptativo de atualização dos pesos atribuídos às amostras, aliado à atribuição de coeficientes de importância α_t a cada classificador fraco. Esses coeficientes são calculados com base na taxa de erro cometida por cada modelo durante as iterações, de modo que classificadores com melhor desempenho tenham maior influência na decisão final. A predição do modelo conjunto é obtida por meio de uma votação ponderada dos classificadores, conforme representado pela seguinte equação:

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right)$$

Essa estrutura torna o AdaBoost particularmente eficaz na redução do erro de generalização, mesmo quando os classificadores fracos apresentam baixa complexidade individual [54], [55].

M. Categorical Boosting (CatBoost)

O *CatBoost* é uma variação do algoritmo de *gradient boosting*, projetada para melhorar o desempenho em tarefas de modelagem preditiva, especialmente em cenários que envolvem variáveis categóricas [56]. Baseado na combinação sequencial de classificadores fracos, o *CatBoost* segue os princípios fundamentais do aumento de gradiente tradicional, ajustando iterativamente árvores de decisão que aprendem com os erros das árvores anteriores, o que permite a minimização progressiva da função de perda selecionada [57], [58].

Diferentemente das abordagens clássicas, o *CatBoost* introduz uma modificação no cálculo dos gradientes, buscando mitigar o viés gerado pelo uso das mesmas amostras tanto para estimar os gradientes quanto para treinar os modelos. A proposta consiste em um novo esquema para a seleção da estrutura das árvores durante o treinamento, mantendo o cálculo dos valores das folhas por meio de aproximação de gradiente, conforme adotado nos métodos convencionais [56]. Essa estratégia visa reduzir o sobreajuste e melhorar a capacidade de generalização dos modelos gerados, especialmente em tarefas de classificação e regressão com atributos categóricos de alta cardinalidade [58].

O algoritmo *CatBoost* é fundamentado no método de *gradient boosting*, que consiste na adição sequencial de modelos fracos para minimizar uma função de perda predefinida [59]. A cada iteração, o modelo preditivo é atualizado segundo:

$$F_m(x) = F_{m-1}(x) + \nu \cdot h_m(x),$$

em que $F_m(x)$ representa o modelo atualizado na iteração m , $h_m(x)$ é o classificador fraco ajustado ao gradiente negativo da função de perda, e ν é a taxa de aprendizado. O gradiente negativo é calculado como:

$$g_i^{(m)} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F=F_{m-1}}.$$

O *CatBoost* se destaca entre os métodos de *gradient boosting* por empregar um esquema ordenado no cálculo dos gradientes, o que reduz o viés decorrente da reutilização de dados. Além disso, adota uma estratégia otimizada na escolha das divisões das árvores, mantendo o cálculo das folhas com base na aproximação por gradiente [58].

N. eXtreme Gradient Boosting (XGBoost)

O *XGBoost* (eXtreme Gradient Boosting) é uma biblioteca de aprendizado de máquina projetada para oferecer alto desempenho e escalabilidade. Baseado no framework de *gradient boosting*, o método incorpora técnicas de regularização para controlar a complexidade dos modelos, reduzindo o risco de sobreajuste. Sua implementação eficiente suporta tarefas de

classificação, regressão e ordenação, com algoritmos otimizados tanto para árvores quanto para modelos lineares [60].

Uma das vantagens do *XGBoost* é sua capacidade de paralelizar o processo de seleção dos pontos de divisão das árvores, o que contribui significativamente para a redução do tempo de treinamento. O algoritmo também incorpora o mecanismo de *early stopping*, interrompendo o aprendizado quando o desempenho preditivo atinge um patamar satisfatório, otimizando o tempo de execução. Além disso, o modelo ajusta as contribuições das amostras com base nas derivadas de primeira e segunda ordem da função de perda, indicadas por g e h , o que refina a atualização dos modelos em cada iteração. Devido a essas características, o *XGBoost* tornou-se um dos métodos mais eficazes e amplamente utilizados em problemas de aprendizado supervisionado [61].

De acordo com [60], o *XGBoost* é composto por dois termos principais: a função de perda \mathcal{L} , que mede o erro entre a predição e o valor real, e o termo de regularização Ω , que penaliza a complexidade do modelo. A formulação geral é dada pela função objetivo denotada por:

$$\mathcal{O}[\Theta] = \sum_{i=1}^n \mathcal{L}(y_i, \hat{y}_i^{(t)}) + \sum_{k=1}^t \Omega(f_k),$$

em que:

- $\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i)$ representa a predição para a instância i após t iterações;
- $f_k \in \mathcal{F}$ é uma função de decisão (por exemplo, uma árvore de regressão);
- $\mathcal{F} = \{f(x) = w_{q(x)}\}$ define o espaço de funções, onde q mapeia uma instância para uma folha da árvore e w é o peso da folha;
- $\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2$ é o termo de regularização, em que T é o número de folhas, w os pesos das folhas, γ e λ são hiperparâmetros de regularização.

Para tornar a otimização mais eficiente, a função de perda é expandida em série de Taylor de segunda ordem:

$$\mathcal{O}[\Theta]^{(t)} \approx \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t(x_i)^2 \right] + \Omega(f_t),$$

onde $g_i = \partial_{\hat{y}^{(t-1)}} \mathcal{L}(y_i, \hat{y}^{(t-1)})$ e $h_i = \partial_{\hat{y}^{(t-1)}}^2 \mathcal{L}(y_i, \hat{y}^{(t-1)})$ são as derivadas de primeira e segunda ordem da função de perda.

A estrutura do modelo permite realizar a otimização de forma eficiente por meio de gradientes, ao mesmo tempo em que incorpora mecanismos explícitos de controle da complexidade, contribuindo para maior generalização e estabilidade do algoritmo [36], [60].

IV. MATERIAIS E MÉTODOS

Nesta seção são descritos os materiais utilizados e os procedimentos adotados para a realização deste estudo. A metodologia foi estruturada de forma a garantir a reprodutibilidade e a confiabilidade dos resultados.

Inicialmente, foram selecionados os materiais necessários, seguidos da escolha do *dataset*, tratamento e análise dos dados.

A. Ferramentas Utilizadas

Para o desenvolvimento deste estudo foi utilizada a linguagem de programação *Python* com as bibliotecas *scikitlearn* para a implementação dos modelos, *imblearn* para o balanceamento de dados via (SMOTE), e *Matplotlib* e *Seaborn* para visualização gráfica.

B. Seleção da Base de dados

Aquisição e utilização da base de dados pública intitulada *Acute Inflammations Dataset*, disponível para *download* em: <https://archive.ics.uci.edu/ml/datasets/Acute+Inflammations>, com finalidade de treinamento e teste de técnicas de reconhecimento de padrões e aprendizagem de máquina [62]. Este conjunto, criado por um especialista médico [63] para testar um sistema especialista baseado na Teoria dos Conjuntos Aproximados (*Rough Sets Theory*), contém 120 instâncias multivariadas e 6 atributos clínicos (temperatura corporal, ocorrência de náusea, dor lombar, urgência urinária, dor ao urinar e sintomas de ardor/inchaço/coceira na uretra). Além desses atributos, há duas variáveis-alvo binárias, representando diagnósticos presuntivos de inflamação aguda da bexiga urinária e nefrite aguda de origem pélvica renal.

No presente estudo, foi utilizada como classe de saída a variável “inflamação da bexiga urinária”, que apresenta 59 amostras “sim” e 61 amostras “não”, distribuídas de forma relativamente equilibrada. O segundo rótulo, não utilizado diretamente, corresponde à nefrite pélvica renal, com 50 amostras “sim” e 70 amostras “não”. O conjunto de dados não possui valores ausentes e encontra-se em formato `ASCII`, com atributos separados por tabulação.

Por se tratar de uma base pública e anonimizada, não há informações pessoais identificáveis, atendendo, portanto, a critérios de conformidade ética para pesquisas com dados clínicos. Ainda assim, o repositório fornece a descrição médica detalhada de cada condição, assegurando a relevância clínica e a validade do conjunto para estudos supervisionados de classificação [63].

C. Pré-processamento dos Dados

Nessa etapa os dados passaram por um pré-processamento o que incluiu a limpeza dos dados para remoção de duplicatas, correção de inconsistências, etc.; normalização (*z-score*) onde os atributos são escalados de forma a possuírem uma média 0 e desvio padrão 1 e balanceamento (SMOTE) para resolver problemas de desbalanceamento de classes. Esse processo foi realizado com intuito de prepará-los para o treinamento e teste com os classificadores.

D. Métricas de Avaliação

As métricas de avaliação utilizadas no trabalho foram: (A), precisão (P), revocação (R), especificidade (E) e *F1-score* (FS) [64]. Fazendo-se necessários saber que:

- **Acurácia (A):** é o percentual de previsões corretas em relação ao total de [65];
- **Precisão (P):** é a razão entre verdadeiros positivos e todas as previsões positivas [65];

- **Revocação (R):** utilizada para medir a capacidade do modelo de identificar corretamente as previsões positivas [66];
- **F1-Score (FS):** calcula a média harmônica entre precisão e revocação, utilizada quando há um equilíbrio entre falsos positivos e falsos negativos [66];
- **Área sob a Curva ROC (AUC-ROC):** ela mede a capacidade de separação entre as classes [67];
- **Sensibilidade (S):** afere a capacidade do modelo de identificar corretamente os verdadeiros positivos entre todas as instâncias pertencem à classe positiva [68].

E. Treinamento e Teste

Neste trabalho, foram selecionados algoritmos de classificação que abrangem distintos paradigmas do aprendizado de máquina, a fim de possibilitar uma comparação abrangente entre técnicas com diferentes níveis de complexidade, estratégias de modelagem e critérios de tomada de decisão. O conjunto inclui modelos baseados em redes neurais artificiais, como o *Multilayer Perceptron* (MLP), a *Radial Basis Function Network* (RBF) e a *Extreme Learning Machine* (ELM); classificadores de natureza estatística, como a Análise Discriminante Linear (LDA), Análise Discriminante Quadrática (QDA), Regressão Logística e o *Naive Bayes*; métodos fundamentados em instâncias, como o *K-Nearest Neighbors* (KNN) e a *Support Vector Machine* (SVM); além de abordagens de aprendizado por comitê (*ensemble learning*), representadas pelos algoritmos *Random Forest*, *AdaBoost*, *CatBoost* e *XGBoost*. Essa diversidade metodológica contribui para ampliar a compreensão sobre o desempenho dos modelos no contexto do problema analisado.

Tabela II
HIPERPARÂMETROS USADOS NOS CLASSIFICADORES

Classificador	Hiperparâmetro
MLP	1 camada oculta com 20 neurônios, $max_iter = 200$, $alpha = 0,1$, <i>early stopping</i> ativado, $random_state = 40$
Naive Bayes	Classificador <i>GaussianNB</i> , $var_smoothing$ padrão = 1×10^{-9}
Random Forest	$n_estimators = 10$, $max_depth = 2$, $random_state = 20$
SVM (RBF)	Kernel RBF, $C = 0,03$, <i>probability</i> ativado, $random_state = 12$
RBF Neural	$n_hidden = 20$, $alpha = 1,0$
ELM	$n_hidden = 6$, $alpha = 0,02$, função de ativação: <i>tanh</i>
LDA	<i>Linear Discriminant Analysis</i> padrão
QDA	$reg_param = 1$, $tol = 10^{-4}$
KNN	$n_neighbors = 15$, $weights =$ uniforme, $p = 2$
Regressão Logística	$max_iter = 118$, $penalty = 'l1'$, $C = 0,04$, $solver = 'liblinear'$
AdaBoost	$n_estimators = 20$, $learning_rate = 0,02$
CatBoost	$iterations = 20$, $learning_rate = 0,01$, $depth = 1$, $verbose = 0$
XGBoost	$n_estimators = 5$, $max_depth = 2$, $learning_rate = 0,02$

A Tabela II apresenta as configurações adotadas para cada classificador. A definição dos hiperparâmetros envolveu uma etapa exploratória com *grid search*, *random search*, aliada a diretrizes da literatura e à adaptação às características de cada algoritmo. Essa abordagem buscou maximizar desempenho e capacidade de generalização, controlando a complexidade, mitigando sobreajuste e assegurando reprodutibilidade e comparabilidade dos resultados.

No que se refere à validação cruzada, optou-se por utilizar o método *stratified k-fold cross-validation* com $k = 5$, embaralhamento e *random state* fixo, visando estimar de forma precisa o desempenho dos classificadores e reduzir os efeitos do *overfitting*. Essa estratégia preserva a proporção das classes em cada subdivisão e apresentou resultados consistentes, com maior estabilidade e menor variabilidade nas métricas obtidas.

Para a MLP, adotou-se uma arquitetura simplificada, com 20 neurônios na camada oculta, regularização moderada ($\alpha = 0,1$) e utilização do recurso de parada antecipada, com o intuito de mitigar o sobreajuste. O classificador *Naive Bayes* foi mantido com sua configuração padrão, assumindo distribuição gaussiana das variáveis e aplicando suavização mínima para evitar instabilidades numéricas. No caso do *Random Forest*, limitou-se a 10 árvores com profundidade máxima de 2 níveis, estratégia adotada para reduzir a variância e simplificar a estrutura do modelo. Para o SVM com *kernel* RBF, definiu-se um valor reduzido para o parâmetro de penalidade ($C = 0,03$) e habilitou-se a estimativa de probabilidades, visando a posterior aplicação de métricas baseadas em escores probabilísticos.

Para as redes neurais artificiais RBF e ELM, foram adotadas configurações distintas quanto à quantidade de neurônios ocultos e taxa de aprendizado: a RBF utilizou 20 unidades ocultas com α ajustado para 1,0, enquanto a ELM operou com 6 unidades e taxa reduzida ($\alpha = 0,02$), utilizando a função de ativação hiperbólica tangente (*tanh*) para promover não linearidade. A LDA foi utilizada com seus parâmetros padrão, uma vez que demonstrou desempenho estável nas validações preliminares. Já a QDA foi submetida à regularização ($reg_param = 1$), combinada com tolerância numérica reduzida para maior estabilidade computacional. No algoritmo K-NN, definiu-se o uso de 15 vizinhos mais próximos, com distância euclidiana ($p = 2$) e pesos uniformes entre as instâncias. Por fim, a Regressão Logística foi parametrizada com penalização do tipo L1, associada ao otimizador *liblinear*, o qual é indicado para conjuntos de dados com quantidade moderada de atributos e demanda por modelos esparsos.

Nos modelos baseados em *ensemble learning*, adotaram-se configurações voltadas à redução do risco de sobreajuste e à promoção da estabilidade preditiva. O algoritmo *AdaBoost* foi configurado com 20 estimadores fracos e uma taxa de aprendizado reduzida, a fim de suavizar as atualizações dos pesos e evitar flutuações excessivas durante o treinamento. Para o *CatBoost*, definiram-se 20 iterações, profundidade unitária e taxa de aprendizado de 0,01, buscando um modelo conservador com menor propensão ao *overfitting*. Já o *XGBoost* utilizou-se 5 árvores de baixa profundidade ($max_depth = 2$)

e taxa de aprendizado moderada, priorizando a capacidade de generalização mesmo em cenários com amostras limitadas. Essas definições refletem uma estratégia equilibrada entre desempenho e controle da variância, em consonância com a aplicação de *stratified k-fold cross-validation* e técnicas de balanceamento de classes adotadas neste estudo.

V. RESULTADOS E DISCUSSÕES

A análise realizada neste trabalho teve como base a aplicação de uma abordagem experimental que contemplou a utilização de diversos algoritmos de aprendizado de máquina, selecionados de forma a representar distintas correntes metodológicas. Entre os modelos empregados, destacam-se aqueles baseados em redes neurais artificiais, como o *Multilayer Perceptron* (MLP), a Rede de Função de Base Radial (RBF) e a *Extreme Learning Machine* (ELM); os classificadores estatísticos, incluindo a Análise Discriminante Linear (LDA), Análise Discriminante Quadrática (QDA), Regressão Logística e o *Naive Bayes*; os métodos baseados em instâncias, como o *K-Nearest Neighbors* (KNN) e a Máquina de Vetores de Suporte (SVM) com *kernel* RBF; bem como técnicas baseadas em aprendizado por comitê (*ensemble learning*), como o *Random Forest*, *AdaBoost*, *CatBoost* e *XGBoost*.

Essa diversidade de algoritmos possibilitou uma comparação abrangente entre diferentes estratégias de modelagem, contribuindo para a identificação de padrões de desempenho e oferecendo subsídios para uma avaliação crítica sobre a eficácia de cada abordagem diante do problema proposto.

A Tabela III sintetiza os resultados comparativos entre os classificadores quanto às principais métricas de desempenho, acompanhadas de seus respectivos desvios padrão. Dessa forma observa-se que os modelos baseados em árvores e métodos *ensemble*, como *Random Forest*, *XGBoost*, *CatBoost* e *AdaBoost*, apresentaram desempenho notavelmente superior nas métricas avaliadas, com destaque para o *Random Forest*, que atingiu acurácia de 95,83%, evidenciando estabilidade e excelente capacidade discriminativa. O modelo LDA apresentou acurácia de 99,17% e baixa variabilidade entre os *folds* de validação, indicando desempenho consistente no conjunto de dados avaliado, inclusive para problemas com separabilidade linear.

No grupo das redes neurais, a arquitetura RBF superou o MLP e a ELM, obtendo 96,67% de acurácia, enquanto o MLP apresentou desempenho inferior com acurácia de 74,17%, além de maior desvio padrão, indicando instabilidade relativa nas repetições de validação cruzada. Modelos estatísticos clássicos como *Naive Bayes*, QDA e Regressão Logística demonstraram desempenho razoável, com a vantagem de serem mais interpretáveis e computacionalmente eficientes.

O K-NN e o SVM com *kernel* RBF apresentaram respectivamente 93,33% de acurácia, 95,06% de precisão e 95,83% de acurácia e 96,99% de precisão, com seus desvios padrão levemente mais elevados nas métricas de classificação, o que pode estar relacionado à sensibilidade desses algoritmos à escolha de hiperparâmetros e à distribuição dos dados em

Tabela III
COMPARAÇÃO DAS MÉTRICAS ENTRE OS CLASSIFICADORES (COM DESVIO PADRÃO)

Classificador	Acurácia	Precisão	Revocação	F1-Score	AUC
MLP	0,7417 ± 0,0667	0,7836 ± 0,0670	0,7417 ± 0,0667	0,7320 ± 0,0711	0,8609 ± 0,0594
<i>Naive Bayes</i>	0,8250 ± 0,0808	0,8759 ± 0,0435	0,8250 ± 0,0808	0,8156 ± 0,0913	1,0000 ± 0,0000
<i>Random Forest</i>	0,9583 ± 0,0833	0,9699 ± 0,0602	0,9583 ± 0,0833	0,9556 ± 0,0889	1,0000 ± 0,0000
SVM (<i>Kernel RBF</i>)	0,9583 ± 0,0833	0,9699 ± 0,0602	0,9583 ± 0,0833	0,9556 ± 0,0889	1,0000 ± 0,0000
RBF <i>Neural</i>	0,9667 ± 0,0667	0,9750 ± 0,0500	0,9667 ± 0,0667	0,9657 ± 0,0686	1,0000 ± 0,0000
ELM	0,9500 ± 0,0667	0,9524 ± 0,0656	0,9500 ± 0,0667	0,9499 ± 0,0667	0,9889 ± 0,0136
LDA	0,9917 ± 0,0167	0,9923 ± 0,0154	0,9917 ± 0,0167	0,9917 ± 0,0167	1,0000 ± 0,0000
QDA	0,9583 ± 0,0833	0,9699 ± 0,0602	0,9583 ± 0,0833	0,9556 ± 0,0889	1,0000 ± 0,0000
KNN	0,9333 ± 0,0858	0,9506 ± 0,0623	0,9333 ± 0,0858	0,9310 ± 0,0892	1,0000 ± 0,0000
Regressão Logística	0,7833 ± 0,1190	0,8277 ± 0,1134	0,7833 ± 0,1190	0,7743 ± 0,1238	0,9444 ± 0,0644
<i>AdaBoost</i>	0,7750 ± 0,1074	0,8211 ± 0,1062	0,7750 ± 0,1074	0,7659 ± 0,1119	0,9444 ± 0,0639
<i>CatBoost</i>	0,8167 ± 0,1550	0,8550 ± 0,1390	0,8167 ± 0,1550	0,8078 ± 0,1607	0,9639 ± 0,0722
<i>XGBoost</i>	0,8917 ± 0,0500	0,9136 ± 0,0338	0,8917 ± 0,0500	0,8894 ± 0,0520	0,9764 ± 0,0129

cada partição da validação cruzada. Por fim, observa-se que a maioria dos classificadores avaliados apresentou AUC de 100%, o que indica separação completa entre as classes. Contudo, esse resultado deve ser analisado considerando as características do conjunto de dados e a possibilidade de sobreajuste em alguns modelos.

No grupo das redes neurais artificiais, a RBF apresentou métricas superiores a 96%. A ELM obteve valores ligeiramente inferiores, enquanto a MLP registrou acurácia e *F1-Score* próximos de 74%, sendo a de menor desempenho entre as redes testadas.

Nos modelos baseados em árvores, *Random Forest* e *XGBoost* apresentaram *F1-Score* superior a 88% e AUC igual ou próxima de 100%. Já *AdaBoost* e *CatBoost* registraram métricas abaixo de 82%, configurando menor estabilidade nas medidas obtidas em relação aos demais modelos do grupo.

No conjunto dos modelos estatísticos, o LDA foi o destaque absoluto, com desempenho bastante considerável em todas as métricas e mínima variação, evidenciando sua robustez. O QDA apresentou resultados similares, ainda que ligeiramente inferiores. A regressão logística, embora do mesmo grupo, ficou abaixo dos demais, com desempenho intermediário.

Por fim, nos modelos baseados em distância e probabilidade, a SVM com kernel RBF e o K-NN demonstraram alta eficácia, com métricas acima de 93%. O *Naive Bayes*, apesar de alcançar AUC com 100%, teve métricas inferiores nas demais categorias, revelando limitações no equilíbrio geral.

Conforme os resultados apresentados na Tabela III, o algoritmo LDA destacou-se entre os modelos avaliados, obtendo desempenho consistentemente superior nos testes realizados, seguido pela rede neural RBF, SVM e o *Random Forest*.

A partir da análise dos trabalhos listados na Tabela IV, observa-se que este estudo apresenta uma contribuição relevante ao evidenciar que algoritmos estatísticos tradicionais, como o LDA, podem superar modelos mais complexos comumente empregados na literatura. O LDA, ao alcançar uma acurácia de 99,17% na detecção de cistite, demonstrou desempenho superior ao *XGBoost* adotado por [11], o qual, mesmo com a utilização de técnicas modernas de *oversampling* e validação cruzada, obteve acurácia inferior. Tal resultado

reforça que, em domínios clínicos com dados tabulares bem estruturados, abordagens estatísticas simples e interpretáveis podem oferecer vantagens significativas em termos de precisão e robustez.

Vale ressaltar o estudo de [17], responsável pela elaboração do conjunto de dados *Acute Inflammations*, no qual foram comparados dois modelos de redes neurais artificiais: o *Backpropagation* tradicional (BP) e sua variação com taxa de aprendizado adaptativa (BPAL). Embora o BPAL tenha alcançado 100% tanto em acurácia quanto em sensibilidade, sua avaliação limitou-se exclusivamente a essas duas métricas. A ausência de indicadores adicionais, como precisão, *F1-score* e AUC, comprometendo uma comparação mais abrangente com estudos recentes aqui realizado. Além disso, o autor não relatou o uso de técnicas como por exemplo balanceamento ou outras, o que pode ter influenciado positivamente os resultados obtidos, especialmente em um conjunto de dados pequeno e desbalanceado.

Outros estudos relevantes, como os de [14] e [15], exploraram algoritmos amplamente reconhecidos, incluindo *Random Forest*, SVM, MLP e ELM, em cenários relacionados à saúde. No entanto, os desempenhos registrados por esses modelos situaram-se abaixo daquele obtido pelo LDA, com acurácias variando entre 86% e 95%. Da mesma forma, o estudo conduzido por [9], focado na predição de infecções urinárias resistentes por meio de redes neurais, alcançou acurácias de até 96,1%, mas ainda aquém do desempenho do modelo estatístico avaliado neste trabalho.

Esses achados ressaltam a importância de realizar comparações criteriosas entre diferentes abordagens de aprendizado de máquina, considerando não apenas o grau de sofisticação algorítmica, mas também a aderência do modelo às características estruturais dos dados. Em aplicações biomédicas, onde o volume amostral de dados tende a ser limitado e a complexidade das variáveis relativamente baixa, a adoção de modelos estatísticos robustos e interpretáveis pode resultar em soluções mais eficazes. A compatibilidade entre o modelo e a natureza dos dados deve portanto, ser considerada um princípio central para garantir a confiabilidade, a estabilidade e a aplicabilidade dos resultados obtidos em

Tabela IV
COMPARAÇÃO ENTRE O MELHOR MODELO DESTA ESTUDO E TRABALHOS RELACIONADOS, ORGANIZADOS POR TIPO DE DADO

Trabalhos (por autor(es))	Descrição e Melhor Resultado
Dados clínicos/tabulares	
Autores deste trabalho (LDA)	Detecção de cistite com dados clínicos simples. Aplicação de 13 classificadores com validação cruzada e SMOTE. Acurácia: 99,17%
[17]	Diagnóstico de cistite e pielonefrite com redes neurais artificiais aplicadas ao conjunto <i>Acute Inflammations</i> , com 120 instâncias e 6 atributos clínicos. Comparação entre os modelos BP e BPAL. BP: Acurácia: 92,5%, Sensibilidade: 85% BPAL: Acurácia e Sensibilidade: 100%
[11]	Previsão de infecção hospitalar com dados clínicos e demográficos (2015 a 2019), utilizando <i>oversampling</i> . O modelo <i>XGBoost</i> foi o mais eficaz. Acurácia: 98,80%, AUROC: 97,33%, F1-score: 99,56%, Recall: 99,60%
[14]	Classificação de níveis de obesidade com dados sobre hábitos alimentares e condição física. Foram comparados os algoritmos <i>Random Forest</i> e SVM. Acurácia: 95,18% (RF), 87,84% (SVM)
[15]	Triagem de adolescentes com e sem TEA com redes neurais MLP e ELM, usando base pública com 99 amostras. Validação cruzada <i>k-fold</i> , com/sem <i>z-score</i> . Acurácia: 89,70% (MLP), 86,52% (ELM)
[8]	Previsão de ITUs com <i>Naive Bayes</i> , J48 e RNA, utilizando atributos clínicos. Precisão: 85,6%
[9]	Predição de infecções urinárias resistentes com RNA (dados de 762 pacientes). Acurácia: 96,1% (Carbapenemase) e 91,6% (beta-lactamase de espectro estendido)
Imagens médicas	
[18]	Geração automática de descrições para imagens médicas utilizando modelo generativo baseado em transformadores e redes convolucionais. Avaliação no conjunto ROCO. Acurácia: 76,28%, BLEU-1: 0,5387
[16]	Segmentação de tumores renais e rins em tomografias com a arquitetura HRNet, utilizando o conjunto de dados KiTS19. Dice: 91,4% (rins), 70,3% (tumores)
[13]	Diagnóstico de melanoma com imagens dermatoscópicas. Utilizou segmentação (<i>Otsu</i> , <i>Watershed</i> , <i>Chan-Vese</i>) e classificadores como RF, KNN e MLP. Acurácia: 95%, F1-score: 95%, Revocação: 100%, Precisão: 96%, Especificidade: 92%
[12]	Diagnóstico de pneumonia com radiografias torácicas. Modelos de aprendizado de máquina foram usados para diferenciar pneumonia viral e bacteriana. Acurácia: 88%
[10]	Segmentação de tecidos renais com CNN (U-Net), avaliada na competição HuBMAP. Dice: 92,33%
[6]	Reconhecimento de dor em expressões faciais com CNNs (<i>InceptionV3</i>) e três otimizadores sobre a base UNBC-McMaster. Acurácia: 90,69%

cenários reais.

A. Desempenho e Interpretabilidade do Modelo de Regressão Logística

A Regressão Logística penalizada (L1) foi ajustada utilizando o procedimento de validação cruzada descrito na Subseção IV-E. A penalização L1 foi escolhida por sua capacidade de realizar seleção de variáveis, atribuindo coeficiente zero a preditores menos relevantes. O valor de $C = 0,04$ foi adotado para controlar o grau de regularização, equilibrando a complexidade do modelo e a estabilidade das estimativas.

A métrica ROC-AUC (Tabela V) foi empregada por fornecer uma medida robusta de discriminação, independente do limiar de decisão, adequada para cenários de triagem que exigem equilíbrio entre sensibilidade e especificidade.

Tabela V
CONFIGURAÇÃO E DESEMPENHO DA REGRESSÃO LOGÍSTICA (REFIT = ROC-AUC)

Métrica/Parâmetro	Valor
ROC-AUC médio	0,8417
Penalização	L1
C	0,04
Solver	liblinear
Iterações máximas	118

Observando a Tabela VI, os coeficientes indicam que *urgência urinária* ($\beta = 26,03$) e *dor ao urinar* ($\beta = 18,81$) apresentaram forte associação positiva com o diagnóstico de cistite, enquanto *temperatura corporal* ($\beta = -3,42$), *dor lombar* ($\beta = -19,41$) e *ardência/inchaço/coceira uretral* ($\beta = -3,39$) exibiram associação negativa no conjunto amos-

tral. A magnitude elevada dos erros-padrão e a amplitude dos intervalos de confiança sugerem instabilidade nas estimativas, possivelmente decorrente de tamanho amostral reduzido e quase-separação, recomendando cautela na interpretação quantitativa dos coeficientes.

Ainda com relação a Tabela VI os *odds ratios* (OR) revelam que *urgência urinária* ($OR = 2,02 \times 10^{11}$) e *dor ao urinar* ($OR = 1,48 \times 10^8$) estiveram fortemente associadas ao aumento da chance de cistite, enquanto *temperatura corporal* ($OR = 3,27 \times 10^{-2}$), *dor lombar* ($OR \approx 0$) e *ardência/inchaço/coceira uretral* ($OR = 3,38 \times 10^{-2}$) indicaram associação inversa. A amplitude infinita dos intervalos de confiança e os elevados valores de *p* sugerem instabilidade estatística, possivelmente relacionada ao tamanho amostral reduzido e à presença de quase-separação nos dados.

Ao analisar a Tabela VII importância por permutação, evidenciou que *urgência urinária* apresentou a maior contribuição para o desempenho do modelo ($0,2605 \pm 0,0422$), seguida por *dor ao urinar* ($0,1178 \pm 0,0235$) e *dor lombar* ($0,0289 \pm 0,0058$). As demais variáveis (*temperatura corporal*, *ocorrência de náusea* e *ardência/inchaço/coceira uretral*) não apresentaram impacto mensurável sobre a métrica ROC–AUC, sugerindo baixa relevância preditiva neste conjunto de dados.

Em síntese, as Tabelas V, VI e VII evidenciam o desempenho preditivo, a interpretação estatística e a relevância prática da Regressão Logística penalizada. A importância por permutação apontou *urgência urinária* como principal preditor ($0,2605 \pm 0,0422$), seguida por *dor ao urinar* ($0,1178 \pm 0,0235$) e *dor lombar* ($0,0289 \pm 0,0058$), enquanto as demais variáveis não apresentaram impacto mensurável na métrica ROC–AUC. Esses resultados reforçam que, além de apresentar boa capacidade discriminativa, o modelo fornece interpretações consistentes e aplicáveis ao contexto clínico do diagnóstico de cistite.

VI. CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

O presente trabalho conduziu uma análise comparativa abrangente entre diferentes algoritmos de classificação, utilizando um conjunto de dados previamente balanceado por meio da técnica *Synthetic Minority Oversampling Technique* (SMOTE) e avaliado com *stratified k-fold cross-validation*. Essa abordagem metodológica possibilitou uma avaliação robusta e comparável entre os modelos, revelando variações expressivas de desempenho e reforçando a importância da escolha criteriosa do classificador em problemas supervisionados.

Dentre os modelos testados, o *Linear Discriminant Analysis* (LDA) destacou-se por alcançar os melhores resultados em acurácia, precisão, revocação, *F1-score* e AUC, apresentando também baixa variabilidade entre as execuções. Esse comportamento confirma o LDA como o classificador mais robusto e estável dentro do cenário experimental adotado. Outros métodos com desempenho expressivo incluíram a Rede Neural RBF, o *Random Forest*, o SVM com *kernel RBF*, o QDA e o K-NN, todos demonstrando consistência e métricas

competitivas, configurando-se como alternativas viáveis para tarefas similares de classificação.

Por outro lado, modelos como MLP, Regressão Logística convencional, *AdaBoost* e *CatBoost* apresentaram resultados mais modestos, embora ainda aceitáveis no contexto da aplicação proposta. O *Naive Bayes*, apesar de manter AUC elevada e estável, mostrou menor equilíbrio entre as demais métricas, ocupando uma posição intermediária no conjunto de classificadores avaliados.

Um aspecto relevante observado foi que os modelos com melhor desempenho também exibiram menor dispersão nas métricas ao longo das execuções, indicando maior estabilidade durante o processo de validação. A integração entre balanceamento de dados, ajuste de hiperparâmetros e validação cruzada reforçou a confiabilidade e a solidez dos achados.

É importante destacar que, embora a modelagem por *Regressão Logística* penalizada não tenha apresentado o melhor desempenho em termos absolutos quando comparada a outros algoritmos, sob a perspectiva da interpretabilidade dos dados ela se mostra particularmente valiosa. O modelo permitiu identificar, de forma transparente e fundamentada, os sintomas de maior relevância clínica para a predição de cistite. Entre os preditores analisados, a *urgência urinária* e a *dor ao urinar* emergiram como variáveis de maior impacto na capacidade discriminativa, reforçando sua importância em contextos de triagem e apoio à decisão clínica. Por outro lado, algumas variáveis apresentaram associação inversa ou baixa relevância, possivelmente refletindo características específicas da amostra analisada.

Como sugestão de trabalhos futuros, destaca-se o potencial de exploração de abordagens híbridas, especialmente arquiteturas *neuro-fuzzy*, que aliam capacidade de aprendizado e interpretabilidade, fator crucial em aplicações clínicas e cenários que demandam decisões sensíveis. Recomenda-se, ainda, a investigação de novas técnicas de balanceamento, a aplicação de métodos automáticos de seleção de atributos, a validação em bases externas e a expansão da análise para tarefas de classificação multiclasse ou regressão. A incorporação de métodos de *Explainable Artificial Intelligence* (XAI) representa um eixo estratégico, permitindo maior transparência e adaptabilidade dos modelos em ambientes práticos e complexos.

REFERÊNCIAS

- [1] B. N. Mengati and S. M. Hoffmann, "Exames laboratoriais para diagnósticos das infecções do trato urinário," *Revista Mato-grossense de Saúde*, vol. 1, no. 1, pp. 16–30, 2023.
- [2] J. Pagnonceli and J. Colacite, "Infecção urinária em gestantes: revisão de literatura," *Uningá Review*, vol. 26, no. 2, 2016.
- [3] J. H. Chen and S. M. Asch, "Machine learning and prediction in medicine — beyond the peak of inflated expectations," *The New England Journal of Medicine*, vol. 376, no. 26, pp. 2507–2509, 2017.
- [4] A. A. M. De Castro and P. P. L. do Prado, "Algoritmos para reconhecimento de padrões," *Revista Ciências Exatas*, vol. 8, no. 2002, 2002.
- [5] M. C. Monard and J. A. Baranauskas, "Conceitos sobre aprendizado de máquina," *Sistemas inteligentes-Fundamentos e aplicações*, vol. 1, no. 1, p. 32, 2003.

Tabela VI
COEFICIENTES (LOG-ODDS), odds ratios (OR) E IC95% DO MODELO

Variável	Coef. (log-odds)	OR	IC95% (OR)	p
const	1,4433	4,2344	[0, +∞)	1,0000
temperatura_corporal	-3,4190	$3,27 \times 10^{-2}$	[0, +∞)	1,0000
ocorrendia_de_nausea	6,2877	$5,3791 \times 10^2$	[0, +∞)	1,0000
dor_lombar	-19,4148	0,0	[0, +∞)	1,0000
urgencia_urinaria	26,0303	$2,0176 \times 10^{11}$	[0, +∞)	1,0000
dor_ao_urinar	18,8110	$1,4774 \times 10^8$	[0, +∞)	0,9998
ardencia_inchaco_coceira_uretra	-3,3865	$3,38 \times 10^{-2}$	[0, +∞)	1,0000

Tabela VII
IMPORTÂNCIA POR PERMUTAÇÃO (ROC-AUC) DAS VARIÁVEIS

Variável	Importância (média)	Desvio-padrão
urgencia_urinaria	0,2605	0,0422
dor_ao_urinar	0,1178	0,0235
dor_lombar	0,0289	0,0058
temperatura_corporal	0,0000	0,0000
ocorrendia_de_nausea	0,0000	0,0000
ardencia_inchaco_coceira_uretra	0,0000	0,0000

- [6] L. P. Lima, "Comparação de desempenho de redes neurais convolutivas no reconhecimento de expressões de dor." Trabalho de Conclusão de Curso, 2024. Monografia (Graduação em Ciência da Computação) – Universidade Federal do Amazonas, Brasil.
- [7] N. N. Bharathi, M. F. Shaik, T. Poojita, T. Sravanthi, M. Rafi, and I. R. Raja, "Heart attack prediction using artificial neural networks," in *2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS)*, vol. 1, pp. 304–308, 2023.
- [8] V. V. M and R. M, "Analysis of urinary tract infections using machine learning based prediction and classification," in *2024 7th International Conference on Circuit Power and Computing Technologies (ICCPCT)*, vol. 1, pp. 1176–1182, 2024.
- [9] B. Orlandin, R. S. Lins, L. M. R. Lins, L. L. Corso, et al., "Software com aplicação de inteligência artificial para prever infecções do trato urinário causadas por bactérias multirresistentes," *Interfaces Científicas-Humanas e Sociais*, vol. 12, no. 3, pp. 131–146, 2025.
- [10] F. S. Bonetto, "Redes neurais convolucionais para segmentação de unidades de tecidos funcionais do rim," 2022.
- [11] P. P. M. Mendes, *Modelo preditivo de infecção hospitalar utilizando aprendizado de máquina*. PhD thesis, Universidade de São Paulo, 2023.
- [12] G. J. C. Mahesse, "Detecção e classificação de pneumonia com base na análise de imagens de radiografia torácica: caso de estudo - hospital central de maputo," dissertação de mestrado, Universidade Eduardo Mondlane, Maputo, Moçambique, 2023.
- [13] C. D. Silva, R. X. de Brito, M. A. V. Neto, S. A. F. de Oliveira, and J. N. de Sousa Ximenes, "Análise de lesões cutâneas para detecção de melanoma: explorando o potencial da visão computacional," *Conexões-Ciência e Tecnologia*, vol. 18, pp. e022028–e022028, 2024.
- [14] L. F. Lopes, A. C. de Oliveira, R. X. de Brito, S. A. F. de Oliveira, and L. T. R. Neto, "Estimativa dos níveis de obesidade com base em hábitos alimentares e condição física através de técnicas de aprendizado de máquina," in *Conference on Graphics, Patterns and Images (SIBGRAPI)*, pp. 154–157, SBC, 2021.
- [15] R. de Brito, C. A. Fernandes, and J. de Sousa Ximenes, "Avaliação de rnas durante treinamento supervisionado para classificação de adolescentes com autismo," in *Escola Regional de Computação do Ceará, Maranhão e Piauí (ERCEMAPI)*, pp. 53–60, SBC, 2020.
- [16] G. P. Esteve, "Analisando Redes Neurais HRNet para Segmentação de Rins e Tumores em Imagens de Tomografia Computadorizada," 2023.
- [17] H. Kahramanli, "Determining the acute inflammations using back propagation algorithm with adaptive learning coefficients," in *Proceedings of the International Conference on Recent Trends in Engineering and Technology, Hyderabad, India*, pp. 25–27, 2016.
- [18] A. G. Barreto, "Um novo modelo generativo para descrições textuais de imagens médicas utilizando transformadores reforçados com redes neurais convolucionais," dissertação de mestrado, Universidade Federal do Ceará - UFC, Fortaleza - CE, 2023.
- [19] H. R. Vianna, C. M. B. M. Soares, M. S. Tavares, M. M. Teixeira, and A. C. S. Silva, "Inflamação na doença renal crônica: papel de citocinas," *Brazilian Journal of Nephrology*, vol. 33, pp. 351–364, 2011.
- [20] E. B. Guidoni and J. Toporovski, "Infecção urinária na adolescência," *Jornal de Pediatria*, vol. 77, no. 2, pp. 165–169, 2001.
- [21] J. W. D. S. Maciel and R. D. D. F. F. Brito, "Comparação da cintilografia renal dinâmica e estática em relação a outras técnicas de imagem tradicionais na avaliação da pielonefrite," 2021. Acesso em: 31 mar. 2023.
- [22] L. E. Nicolle, "Epidemiology of urinary tract infections," *Clinical Microbiology Newsletter*, vol. 24, no. 18, pp. 135–140, 2002.
- [23] I. P. Heilberg and N. Schor, "Abordagem diagnóstica e terapêutica na infecção do trato urinário: Itu," *Revista da Associação Médica Brasileira*, vol. 49, pp. 109–116, 2003.
- [24] Z. L. Kovács, *Redes neurais artificiais*. Editora Livraria da Física, 2006.
- [25] R. X. De Brito, C. A. R. Fernandes, and M. A. B. Amora, "Análise de desempenho com redes neurais artificiais, arquiteturas mlp e rbf para um problema de classificação de crianças com autismo," *Histórico da iSys-Brazilian Journal of Information Systems (SERVIDOR ANTIGO-UNIRIO)*, vol. 13, no. 1, pp. 60–76, 2020.
- [26] A. Braga, A. P. de Leon F. Carvalho, and T. B. Ludermit, *Redes Neurais Artificiais: Teoria e Aplicações*. Rio de Janeiro: Editora LTC - Livro Técnico e Científico, 2000.
- [27] P. M. Atkinson and A. R. Tatnall, "Introduction neural networks in remote sensing," *International Journal of remote sensing*, vol. 18, no. 4, pp. 699–709, 1997.
- [28] F. N. Bonifácio, "Comparação entre as redes neurais artificiais mlp, rbf e lvq na classificação de dados," trabalho de conclusão de curso, Universidade Estadual do Oeste do Paraná – Centro de Ciências Exatas e Tecnológicas (CCET), Brasil, 2010.
- [29] S. Haykin, *Redes neurais: princípios e prática*. Bookman Editora, 2001.
- [30] A. Ferreira et al., "Um estudo sobre previsão da demanda de encomendas utilizando uma rede neural artificial," *Blucher Marine Engineering Proceedings*, vol. 2, no. 1, pp. 353–364, 2016.
- [31] R. Ximenes de Brito, C. A. Rolim Fernandes, and M. A. Baima Amora, "Análise de Desempenho com Redes Neurais Artificiais, Arquiteturas MLP e RBF Para um Problema de Classificação de Crianças com Autismo," *iSys - Brazilian Journal of Information Systems (servidor antigo)*, vol. 13, p. 60–76, dez. 2019.
- [32] M. H. Hassoun, *Fundamentals of artificial neural networks*. MIT press, 1995.
- [33] M. Nakai, H. G. Junior, P. Aguiar, E. Bianchi, and D. Spatti, "Neural tool condition estimation in the grinding of advanced ceramics," *IEEE Latin America Transactions*, vol. 13, no. 1, pp. 62–68, 2015.
- [34] A. C. Lorena and A. C. P. L. F. De Carvalho, "Uma introdução às support vector machines," *Revista de Informática Teórica e Aplicada*, vol. 14, no. 2, pp. 43–67, 2007.
- [35] R. F. F. Nascimento et al., "O algoritmo support vector machines (svm): avaliação da separação ótima de classes em imagens ccd-cbers-2," in *Simpósio Brasileiro de Sensoriamento Remoto*, vol. 14, pp. 2079–2086, 2009.
- [36] T. Hastie, R. Tibshirani, J. Friedman, et al., "The elements of statistical learning," 2009.
- [37] D. Bonesso, "Estimação dos parâmetros do kernel em um classificador svm na classificação de imagens hiperespectrais em uma abordagem multiclasse," dissertação de mestrado, Universidade Federal do Rio Grande do Sul, Porto Alegre - RS, 2013.

- [38] L. Breiman, "Random forests," *Machine learning*, vol. 45, pp. 5–32, 2001.
- [39] C. Apté and S. Weiss, "Data mining with decision trees and decision rules," *Future generation computer systems*, vol. 13, no. 2-3, pp. 197–210, 1997.
- [40] G. I. Webb, E. Keogh, and R. Miikkulainen, "Naïve bayes.," *Encyclopedia of machine learning*, vol. 15, no. 1, pp. 713–714, 2010.
- [41] T. Brant-Ribeiro *et al.*, "Uma análise comparativa entre os classificadores adaboost e naive bayes utilizando logs de navegação na identificação de web bots," *16º JORNADA CIENTÍFICA E TECNOLÓGICA E 13º SIMPÓSIO DE PÓS-GRADUAÇÃO DO IFSULDEMINAS*, vol. 16, no. 3, 2024.
- [42] T. A. S. Pardo and M. das Graças Volpe Nunes, "Aprendizado bayesiano aplicado ao processamento de línguas naturais," *Tech. Rep. 180*, Instituto de Ciências Matemáticas e de Computação (ICMC), Universidade de São Paulo, 2002.
- [43] R. Roza and *et al.*, "Uma proposta de metodologia de ensino do problema de monty hall e teorema de bayes para os professores da educação básica," *dissertação de mestrado*, Universidade Federal do Rio Grande do Sul, 2023.
- [44] L. M. de Assunção, F. B. Teixeira, G. Z. F. de Lima, G. M. de Souza, I. F. de Freitas, J. K. dos Santos, L. S. Gomes, V. Q. Silva, C. V. B. Brito, *et al.*, "Método de bayes como base na tomada de decisão médica-uma revisão bibliográfica," *Revista da Sociedade Brasileira de Clínica Médica*, vol. 21, no. Edição Esp, pp. 15–26, 2023.
- [45] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: theory and applications," *Neurocomputing*, vol. 70, no. 1-3, pp. 489–501, 2006.
- [46] B. E. Z. Buani, *Aplicação da Lógica Fuzzy kNN e análises estatísticas para seleção de características e classificação de abelhas*. PhD thesis, Universidade de São Paulo, 2010.
- [47] P. H. O. d. Silva, "Um comparativo entre a modularidade knn e a medida de estabilidade para extração ótima de grupos a partir de hierarquia de grupos." *Monografia (Graduação em Ciência da Computação) – Universidade Federal do Ouro Preto, MG*, 2024.
- [48] C. G. Tramontina, M. C. F. Castro, and D. E. Elétrica, "Estudo da análise de discriminantes lineares como um classificador estatístico de sinais mioelétricos," *XXIII Congresso Brasileiro em Engenharia Biomédica – XXIII CBEB*, pp. 1879–1893, 2012.
- [49] A. R. d. Santos, *Identificação de faces humanas através de PCA-LDA e redes neurais SOM*. PhD thesis, Universidade de São Paulo, 2005.
- [50] G. J. McLachlan, *Discriminant analysis and statistical pattern recognition*. John Wiley & Sons, 2005.
- [51] L. L. A. d. Azevêdo, "Métodos estatísticos em aprendizado de máquinas para problemas de classificação," *dissertação de mestrado*, Universidade Federal do Rio Grande do Norte, Natal, RN, 2018.
- [52] D. W. Hosmer Jr, S. Lemeshow, and R. X. Sturdivant, *Applied logistic regression*. John Wiley & Sons, 2013.
- [53] H. R. Bittencourt, "Regressão logística politômica: revisão teórica e aplicações," *Acta Scientiae*, vol. 5, no. 1, pp. 77–86, 2003.
- [54] A. M. G. d. Santos, "Um estudo sobre a extração de características em dados do twitter na tarefa de detecção de depressão," *dissertação de mestrado*, Universidade Federal de Sergipe, São Cristóvão-SE, 2024.
- [55] Y. Freund and R. E. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," *Journal of computer and system sciences*, vol. 55, no. 1, pp. 119–139, 1997.
- [56] V. S. Matias Junior, "Metodologia para avaliação de transformadores de até 24,2 kv através de técnicas de aprendizado de máquina para determinação do índice de saúde," *dissertação de mestrado*, Universidade Estadual Paulista (Unesp), São Paulo - SP, 2023.
- [57] J. H. Friedman, "Greedy function approximation: a gradient boosting machine," *Annals of Statistics*, vol. 29, no. 5, pp. 1189–1232, 2001.
- [58] L. Prokhorenkova, G. Gusev, A. Vorobev, A. V. Dorogush, and A. Gulin, "Catboost: unbiased boosting with categorical features," in *Proceedings of the 32nd International Conference on Neural Information Processing Systems (NeurIPS)*, pp. 6639–6649, 2018.
- [59] P. Beja-Battais, "Overview of adaboost: Reconciling its views to better understand its dynamics," *arXiv preprint arXiv:2310.18323*, 2023.
- [60] T. Chen and C. Guestrin, "Xgboost: A scalable tree boosting system," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 785–794, ACM, 2016.
- [61] W. Zhao, J. Li, J. Zhao, D. Zhao, J. Lu, and X. Wang, "Xgb model: Research on evaporation duct height prediction based on xgboost algorithm," *Radioengineering*, vol. 29, no. 1, pp. 81–93, 2020.
- [62] J. Czerniak, "Acute Inflammations." UCI Machine Learning Repository, 2003. DOI: <https://doi.org/10.24432/C5V59S>.
- [63] J. Czerniak and H. Zarzycki, "Application of rough sets in the presumptive diagnosis of urinary system diseases," in *Artificial Intelligence and Security in Computing Systems: 9th International Conference, ACS'2002 Miedzzydroje, Poland October 23–25, 2002 Proceedings*, pp. 41–51, Springer, 2003.
- [64] M. Harrison, *Machine Learning—Guia de referência rápida: trabalhando com dados estruturados em Python*. Novatec Editora, 2019.
- [65] W. I. D. Mining, "Data mining: Concepts and techniques," *Morgan Kaufmann*, vol. 10, no. 559-569, p. 4, 2006.
- [66] D. M. Powers, "Evaluation: from precision, recall and f-measure to roc, informedness, markedness and correlation," *arXiv preprint arXiv:2010.16061*, 2020.
- [67] T. Fawcett, "An introduction to roc analysis," *Pattern recognition letters*, vol. 27, no. 8, pp. 861–874, 2006.
- [68] P.-N. Tan, M. Steinbach, and V. Kumar, "Data mining cluster analysis: basic concepts and algorithms," *Introduction to data mining*, vol. 487, no. 533, p. 58, 2013.