



UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
DEPARTAMENTO DE CIÊNCIAS EXATAS E TECNOLOGIA DA INFORMAÇÃO
BACHARELADO EM SISTEMAS DE INFORMAÇÃO

VINICIUS LEONARDO DE OLIVEIRA

**USO DE TÉCNICAS DE *MACHINE LEARNING* PARA DIAGNÓSTICO DA
DEPRESSÃO PÓS-PARTO**

ANGICOS-RN

2025

VINICIUS LEONARDO DE OLIVEIRA

**USO DE TÉCNICAS DE *MACHINE LEARNING* PARA DIAGNÓSTICO DA
DEPRESSÃO PÓS-PARTO**

Trabalho de Conclusão de Curso apresentado à
Universidade Federal Rural do Semi-Árido como
requisito para cumprimento do componente
curricular Trabalho de Conclusão de Curso II.

Orientadora: Profa. Dra. Samara Martins
Nascimento Gonçalves

ANGICOS–RN

2025

© Todos os direitos estão reservados a Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996 e Direitos Autorais: Lei nº 9.610/1998. O conteúdo desta obra tomar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata. A mesma poderá servir de base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) sejam devidamente citados e mencionados os seus créditos bibliográficos.

O48u Oliveira, Vinicius Leonardo de.
 Uso de técnicas de machine learning para
 diagnóstico da depressão pós-parto / Vinicius
 Leonardo de Oliveira. - 2025.
 43 f. : il.

 Orientador: Samara Martins Nascimento Gonçalves.
 Monografia (graduação) - Universidade Federal
 Rural do Semi-árido, Curso de Sistemas de
 Informação, 2025.

 1. Depressão. 2. Pós-Parto. 3. Machine
 Learning. 4. Mulher. I. Gonçalves, Samara Martins
 Nascimento, orient. II. Título.

Ficha catalográfica elaborada por sistema gerador automático em conformidade
com AACR2 e os dados fornecidos pelo(a) autor(a).

Biblioteca Campus Angicos
Bibliotecário: Helder Romero Maia Duarte
CRB: 15/673

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.

VINICIUS LEONARDO DE OLIVEIRA

**USO DE TÉCNICAS DE *MACHINE LEARNING* PARA DIAGNÓSTICO DA
DEPRESSÃO PÓS-PARTO**

Trabalho de Conclusão de Curso apresentado à
Universidade Federal Rural do Semi-Árido como
requisito para cumprimento do componente
curricular Trabalho de Conclusão de Curso II.

Defendida em: 26/06/2025

BANCA EXAMINADORA

Prof. Dra. Samara Martins Nascimento Gonçalves (UFERSA)
Presidente

Prof. Dra. Joêmia Leilane Gomes de Medeiros (UFERSA)
Membro Examinador

Prof. Dra. Tathiana Cunha Navarro Diniz (UFERSA)
Membro Examinador

AGRADECIMENTOS

Primeiramente, devo agradecer a Deus, pois nele todas as coisas são possíveis. Somente Ele nos conhece em profundidade e sabe plenamente das dificuldades que enfrentei durante este semestre. Seja desmotivação, medo ou ansiedade, Ele sempre esteve vigilante. Deus é nossa base maior; devemos nos apegar a Ele em primeiro lugar. Creio, como diz o ditado: "Depois da tempestade, vem a bonança. Depois da chuva, o sol. Depois do inverno, a primavera." Deixo ainda um versículo que considero apropriado para refletir esta fase da minha vida: "Porque sou eu que conheço os planos que tenho para vocês", diz o Senhor, 'planos de fazê-los prosperar e não de causar dano, planos de dar a vocês esperança e um futuro.' Jeremias 29:11.

Agradeço o apoio incondicional da minha família, que sabe melhor do que ninguém as minhas peculiaridades e detalhes. Sempre posso contar com sua mão estendida nos momentos difíceis, com aquele puxão de orelha oportuno e com o devido conselho.

Agradeço veementemente o apoio da minha orientadora, que aceitou minha proposta de orientação meses atrás e, quando chegou o momento de trabalharmos juntos, nunca deixou a desejar em seus deveres. Além de tudo, ela não permitiu que eu fosse derrotado por mim mesmo. Mesmo nos finais de semana, estava comigo para o que fosse necessário. Ela nunca falhou, e, quando eu falhei, ela estava a postos!

Agradeço aos amigos que tomaram parte de seu tempo e usaram de sua consideração para me perguntar sobre notícias: "Como anda o trabalho?" "Como você está?" É sempre muito positivo ouvir questionamentos como esses, que revelam cuidado e preocupação.

Agradeço antecipadamente à banca examinadora que receberá este trabalho para avaliá-lo, tomando de seu tempo e seu conhecimento técnico para uma justa avaliação. Deixo aqui minhas palavras finais, foi e ainda será um desafio enorme, mas que com a graça de Deus será superado.

RESUMO

A depressão pós-parto deve ser vista sob uma perspectiva ampla, que envolve a saúde mental da mulher no contexto social, econômico e familiar. O diagnóstico precoce da depressão pós-parto é crucial para evitar consequências graves à saúde mental da mãe, à relação com o bebê e ao bem-estar da família. No entanto, sua identificação ainda é desafiadora, exigindo abordagens inovadoras. Neste sentido, este trabalho de pesquisa é proposto, adotando uma abordagem aplicada, descritiva e quali-quantitativa, que foi dividida em três etapas: concepção, planejamento e implementação. Na fase de concepção, analisou-se a viabilidade do uso de modelos preditivos com base em dados clínicos e comportamentais. O planejamento definiu as técnicas, ferramentas e a base de dados a ser utilizada, disponível na plataforma *Kaggle*, escolhida pela qualidade dos dados e presença de metadados. O público-alvo envolve mães no período pós-parto, além de profissionais de saúde que podem utilizar os resultados como apoio à decisão clínica. E, por fim, na etapa de implementação, os modelos *Random Forest*, KNN e SVM foram treinados, sendo testados em duas abordagens: com todas as características e com apenas as mais relevantes. Os resultados mostraram que o *Random Forest* teve o melhor desempenho, com 97,77% de acurácia, seguido do KNN com 93,53%, e do SVM com 78,79%.

Palavras – chave: Depressão. Pós-Parto. *Machine Learning*. Mulher.

ABSTRACT

Postpartum depression should be viewed from a broad perspective, encompassing the woman's mental health within social, economic, and family contexts. Early diagnosis of postpartum is crucial to prevent serious consequences for the mother's mental health, her relationship with her baby and the family's well-being. However, its identification remains challenging, requiring innovative approaches. In this context, this research work is proposed, adopting an applied, descriptive, and mixed-methods (qualitative and quantitative) approach, structured into three stages: conception, planning, and implementation. In the conception phase, the feasibility of using predictive models based on clinical and behavioral data was analyzed. The planning phase defined the techniques, tools, and dataset to be used, sourced from the Kaggle platform, selected for its data quality and availability of metadata. The target audience includes postpartum women, as well as healthcare professionals who may use the results to support clinical decision-making. In the implementation phase, Random Forest, KNN, and SVM models were trained and tested using two strategies: with all features and with only the most relevant ones. Results showed that Random Forest achieved the best performance, with 97.77% accuracy, followed by KNN with 93.53%, and SVM with 78.79%.

Keywords: Depression. Postpartum. Machine Learning. Woman.

LISTA DE ABREVIATURAS E SIGLAS

DPP	Depressão Pós-Parto
CAPS	Centros de Atenção Psicossocial
ML	Machine Learning
EPDS	Escala validada de Depressão Pós-Parto de Edimburgo
PRAMS	Pregnancy Risk Assessment Monitoring System
CDC	Centros de Controle e Prevenção de Doenças
PHQ-2	Patient Health Questionnaire-2
IMC	Índice de Massa Corporal
API	Application Programming Interface
LGPD	Lei Geral de Proteção aos Dados

LISTA DE FIGURAS

Figura 1 - Fluxo de execução do aprendizado não supervisionado.....	16
Figura 2 - Exemplo de fluxo do Aprendizado por Reforço.....	17
Figura 3 - Resultados de desempenho do KNN.....	27
Figura 4 - Matriz de Confusão com Todas as Características.....	29
Figura 5 - Matriz de Confusão com as 4 melhores características.....	29
Figura 6 - Configuração do Modelo SVM.....	30
Figura 7 - Resultados de desempenho do SVM.....	31
Figura 8 - Matriz de Confusão para Todas as Características.....	32
Figura 9 - Matriz de Confusão com as 4 Melhores Características.....	33
Figura 10 - Configuração do <i>Random Forest</i>	33
Figura 11 - Resultados de desempenho do <i>Random Forest</i>	34
Figura 12 - Matriz de Confusão Utilizando Todas as Características.....	36
Figura 13 - Matriz de Confusão com as 4 Melhores Características.....	36

SUMÁRIO

1. INTRODUÇÃO.....	10
1.1. Justificativa e Problemática.....	11
1.2. Objetivos.....	12
1.2.1 Objetivos Gerais.....	12
1.2.2 Objetivos Específicos.....	12
1.3. Organização do Trabalho.....	12
2. FUNDAMENTAÇÃO TEÓRICA.....	13
2.1 Saúde Mental.....	13
2.2 Técnicas de <i>Machine Learning</i>	14
2.2.1 Aprendizado Supervisionado.....	15
2.2.2 Aprendizado Não Supervisionado.....	16
2.2.1 Aprendizado Por Reforço.....	17
2.3 Trabalhos Relacionados.....	18
3. METODOLOGIA DE PESQUISA.....	21
4. RESULTADOS.....	24
4.1 Base de Dados e Pré-processamento.....	24
4.2 Resultados dos Modelos Implementados.....	25
4.2.1 Modelo KNN.....	25
4.2.2 Resultados do Modelo KNN - Utilizando Todas as Características.....	26
4.2.3 Resultados do Modelo KNN - Utilizando as Melhores Características.....	28
4.3 Modelo SVM.....	30
4.3.1 Resultados do Modelo SVM - Utilizando Todas as Características.....	30
4.3.2 Resultados do Modelo SVM - Utilizando as Melhores Características.....	31
4.4 Modelo Random Forest.....	33
4.4.1 Resultados do Modelo <i>Random Forest</i> - Utilizando Todas as Características.....	33
4.4.2 Resultados do Modelo <i>Random Forest</i> - Utilizando as Melhores Características....	34
4.5 Discussão dos Resultados.....	37
5. CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS.....	39
6. REFERÊNCIAS BIBLIOGRÁFICAS.....	41

1. INTRODUÇÃO

Segundo Gomes (2023), a gestação é um processo fisiológico-adaptativo, em que o corpo feminino se prepara para gerar um filho. Como se trata de um fenômeno natural, em sua maioria, a evolução gestacional ocorre sem nenhuma intercorrência e dura, em média, 40 semanas. Na fase gestacional, ocorrem inúmeras mudanças tanto sociais, físicas e hormonais, quanto mentais e emocionais, as quais tendem a se intensificar durante o período gestacional e pós-parto. Porém, cada mulher vive esse momento de forma diferente devido à intensidade do processo, sendo positivo ou negativo, gerando amadurecimento e mudanças no pensar.

A gravidez é um período de transição considerado crítico, capaz de gerar instabilidade emocional em virtude de mudanças sociais, na rotina e no relacionamento familiar. Após o nascimento do filho, ocorre a mudança de foco para o bebê, no entanto, a mãe ainda precisa de cuidado devido à ansiedade que esse momento desperta (GOMES, 2023).

A melancolia maternal pode estar associada a uma combinação de perdas e adaptações vivenciadas pela puérpera, como as mudanças corporais, a experiência com o bebê real e a desconstrução do bebê imaginário, além das próprias necessidades, que não podem ser atendidas em razão das demandas da maternidade. Nesse cenário, é possível observar o surgimento de doenças, como a Depressão Pós-Parto (DPP), que abala as expressões afetivas e o temperamento da mulher, podendo requerer, em sintomatologias mais duradouras e graves, uma intervenção médica (WANG; ZHANG, 2019).

Segundo De Melo e Alves (2022), a atual situação de questões relacionadas à saúde mental tem ganhado evidência, mais especificamente sobre o cenário de transtornos mentais, quando se refere a patologias, como: depressão, ansiedade e estresse. Essa problemática pode ser evidenciada pela negligência do tratamento, encarando-o como dispensável, ou realizando-o de forma rápida, porém ineficaz.

No que tange ao mapeamento dos transtornos mentais, os psicólogos frequentemente utilizam uma variedade de sintomas para identificar patologias, como: dificuldades em ir ao trabalho, tendência crônica de desistir antes de tentar, alterações no sono, libido ou alimentação, e dificuldade para iniciar o dia ou cumprir ciclos de atividades (GOMES, 2023).

Segundo Wang e Zhang (2019), a depressão pós-parto não só está relacionada ao bem-estar emocional da mãe, mas também aos casos de comorbidade infantil e atrasos na capacidade cognitiva do bebê. Os autores destacam outros fatores, como: obesidade, ansiedade, transtornos depressivos e mentais, ameaças de aborto no primeiro trimestre, ganho de peso anormal, parto prematuro, dor muscular, dor abdominal, dor nas costas, transtornos hipertensivos, transtornos mentais, palpitações e outros, que podem, juntos ou separados, estar

associados a maiores chances de DPP. Além disso, outro fator associado ao surgimento da doença relaciona-se com o uso de antidepressivos durante a gravidez e anti-inflamatórios no segundo trimestre.

Diante do exposto, o diagnóstico e tratamento precoce apresentam-se como relevantes. Para isso, o uso de inteligência para apoiar a equipe de saúde com mais segurança torna-se interessante. Assim, surge uma questão norteadora para este trabalho: “*É possível usar técnicas de machine learning para prever o diagnóstico da depressão pós-parto?*”. Nesse sentido, propõe-se analisar e implementar técnicas de inteligência, que consigam prever sintomas relacionados à saúde mental da puérpera. Entende-se que compreender e tratar a doença de forma adequada, levando em conta os múltiplos fatores de risco, é essencial para garantir o bem-estar tanto das mães quanto de seus filhos.

1.1. Justificativa e Problemática

Segundo o Ministério da Saúde(a) (2024), a depressão pós-parto é uma condição de profunda tristeza, desespero e falta de esperança que acontece logo após o parto. Essa situação clínica traz inúmeras consequências ao vínculo da mãe com o bebê, sobretudo no que se refere ao aspecto afetivo. Estudos mostram que as mulheres têm uma maior probabilidade de desenvolver o transtorno depressivo, com uma proporção aproximada de 1,7 a 2,7 vezes maior do que os homens (DANIEL; LIMA; OPPENHEIMER, 2023).

A DPP varia entre 10 e 20% das mulheres puérperas e seus sintomas geralmente surgem entre a quarta e a oitava semana após o parto, quando o risco da doença aparecer é três vezes maior que nos outros períodos, e pode se estender por meses (SOUSA *et al.*, 2021; MULLER *et al.*, 2021; FEBRASGO, 2020).

Não existe uma única causa conhecida para DPP. Ela pode estar associada a fatores físicos, emocionais, estilo e qualidade de vida, além de ter ligação com histórico de outros problemas e transtornos mentais. Dentre os principais sintomas, destacam-se: ausência de forças para lidar com a rotina e muita tristeza, acompanhada de desespero constante; perda de interesse ou prazer em atividades diárias; perda de interesse ou prazer em atividades/coisas/pessoas que antes gostava; pensamento na morte ou suicídio; vontade súbita de prejudicar ou fazer mal ao bebê; vontade de comer mais ou menos do que o habitual; dormir muito ou não dormir o suficiente; insônia; sentimento de indignação ou culpa; entre outros (MINISTÉRIO DA SAÚDE(a), 2024).

Os modelos de *machine learning* oferecem vantagens para a previsão de várias doenças e têm sido aplicados em diferentes áreas da saúde, como: síndrome metabólica,

infarto cerebral, insuficiência cardíaca, *Alzheimer* e outros (SHIN, 2020). Diante deste cenário de saúde desafiador, relacionado à DPP, percebe-se que possivelmente o uso de técnicas de inteligência pode apoiar no diagnóstico precoce da doença, permitindo analisar e testar algoritmos preditivos para rastrear a depressão pós-parto. É neste cenário, que este trabalho é proposto.

1.2. Objetivos

1.2.1 Objetivos Gerais

O objetivo geral deste trabalho é investigar o uso de técnicas de *machine learning* para prever diagnósticos relacionados à depressão pós-parto.

1.2.2 Objetivos Específicos

Para atingir o propósito geral desta pesquisa, foram estabelecidos os seguintes objetivos específicos:

1. Fazer um levantamento da literatura, com a finalidade de identificar trabalhos relacionados a esta pesquisa;
2. Coletar e organizar dados relevantes sobre a saúde mental de puérperas com e sem depressão pós-parto;
3. Implementar técnicas de *machine learning*, a fim de prever diagnósticos de depressão usando o conjunto de dados do item (2);
4. Analisar os resultados obtidos, para propor recomendações acerca da previsibilidade da doença.

1.3. Organização do trabalho

Além da introdução, este trabalho apresenta os seguintes capítulos: a Fundamentação Teórica, no Capítulo 2, com levantamento de conceitos importantes para esta área de estudo, além de apresentar alguns trabalhos relacionados a esta pesquisa; o Capítulo 3, que descreve a Metodologia abordada neste trabalho; o Capítulo 4, que trata dos Resultados obtidos; e finaliza a discussão no Capítulo 5, com as Considerações Finais e Trabalhos Futuros.

2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, serão tratados conceitos utilizados para a construção desta proposta de pesquisa. Sendo assim, nas próximas seções serão elencadas as definições acerca de Saúde Mental e Técnicas de *Machine Learning*. Além disso, serão apresentados trabalhos relacionados a este para futuras comparações.

2.1. Saúde Mental

A saúde mental pode ser vista como uma rede de fatores relacionados. De acordo com a Organização Mundial de Saúde (OMS), a saúde mental é definida como um estado de bem-estar vivido pelo indivíduo, que possibilita o desenvolvimento de suas habilidades pessoais para responder aos desafios da vida e contribuir com a comunidade.

O bem-estar de uma pessoa não depende apenas do aspecto psicológico e emocional, mas também de condições fundamentais, como: saúde física, apoio social e condições de vida. Além dos aspectos individuais, a saúde mental é também determinada pelos aspectos sociais, ambientais e econômicos (MINISTÉRIO DA SAÚDE (b), 2024). Entender a saúde mental como algo que envolve o corpo, as emoções e a forma como interagimos ajuda a ver que todos têm um papel importante em cuidar do bem-estar de todos, cuidando de nós mesmos e apoiando uns aos outros.

A realidade social, econômica, política, cultural e ambiental impacta diretamente na saúde mental da população, não sendo um problema meramente individual. Dessa maneira, compreende-se que os problemas de saúde mental resultam da coletividade, demandando políticas públicas, redes de proteção, melhores condições de vida, segurança alimentar e suporte comunitário (GOMES, 2023).

Ao entender a saúde mental como uma questão coletiva, é possível analisar políticas públicas e redes de apoio sendo criadas para cuidar não só das mães, mas também de suas famílias, criando um ambiente que promova o bem-estar psicológico (MINISTÉRIO DA SAÚDE (b), 2024). Nesse sentido, a depressão pós-parto deve ser vista sob essa perspectiva ampla, que envolve o indivíduo, mas também o contexto social, econômico e familiar (MINISTÉRIO DA SAÚDE (a), 2024).

Dentre as políticas públicas e redes de apoio existentes, destacam-se os Centros de Atenção Psicossocial (CAPS), que oferecem serviços de saúde abertos para a comunidade. O CAPS conta com uma equipe diversificada, que trabalha em conjunto para atender às necessidades de saúde mental das pessoas (MINISTÉRIO DA SAÚDE (c), 2024). De forma geral, O CAPS desempenha um papel crucial no cuidado de pessoas com transtornos mentais,

oferecendo atendimento integral e comunitário a pacientes que enfrentam condições, como a depressão pós-parto.

Com base no exposto, é importante destacar que o cuidado com a saúde mental requer uma abordagem que vá além do indivíduo. No caso da depressão pós-parto, é fundamental que as mães recebam o suporte necessário tanto no nível familiar quanto comunitário. Assim, a integração de recursos tecnológicos com o cuidado humanizado fortalece a saúde mental de forma mais ampla e acessível, promovendo o bem-estar das mães e bebês.

2.2. Técnicas de *Machine Learning*

Em 1950, Alan Turing propôs o conhecido jogo da imitação, que consiste na interação entre três agentes: um agente interrogador e dois agentes respondentes, onde um dos agentes respondentes é um ser humano e outro uma máquina (computador). A pergunta enviada pelo agente interrogador é recebida por ambos os agentes respondentes, onde cada um deles deve enviar de volta a resposta. Com base nas respostas, o agente interrogador deve determinar quem é o humano e quem é a máquina, a partir do momento em que esse agente não consegue mais fazer essa diferenciação, é dito que a máquina passou no teste (TURING, 1950).

O teste de Turing, possivelmente, foi um ponto de partida para o que hoje conhecemos por Aprendizado de Máquina (ML - sigla do inglês, *Machine Learning*). A possibilidade de representar pensamentos em computadores, similares aos dos seres vivos, foi um grande marco na humanidade. Atualmente, esse conceito está sendo aplicado nas mais diversas áreas, tendo, em algumas tarefas, o desempenho superior ao dos seres humanos (ALPAYDIN, 2020).

O aprendizado de máquina é uma das principais subáreas da inteligência artificial, sendo composta por uma coleção de métodos criados a partir de modelos matemáticos, que são baseados na teoria estatística. Sua aplicabilidade permite que computadores automatizem tarefas com base na descoberta sistemática de padrões, utilizando conjuntos de dados disponíveis ou experiências passadas (BHAVSAR *et al.*, 2017; ALPAYDIN, 2020). Segundo a definição de Samuel (1959), um dos pioneiros do assunto, o aprendizado de máquina é um campo de estudo que oferece aos computadores a capacidade de aprender sem serem explicitamente programados.

O estudo de ML possibilita várias e diferentes tarefas. De forma geral, é possível encontrar na literatura um resumo de aplicabilidade para seu uso, como em problemas para os quais as soluções existentes exigem muita configuração manual ou longas listas de regras. Nesse caso, um algoritmo de ML geralmente simplifica e melhora o código. Além disso, pode

ser usado em problemas complexos, para os quais não existe uma boa solução quando é utilizada uma abordagem tradicional. As técnicas de ML podem encontrar uma solução adequada, possibilitando, inclusive, a adaptação do algoritmo de ML a novos dados; além de serem usados na compreensão de problemas complexos, que lidam com grandes quantidades de dados (GERON, 2019).

Dentro do estudo de ML, existem diferentes modelos de aprendizado, dentre os quais se destacam: o Aprendizado Supervisionado, o Não Supervisionado e Por Reforço. Todos eles são descritos a seguir.

2.2.1 Aprendizado Supervisionado

No aprendizado supervisionado, o modelo recebe um conjunto de entradas com suas respectivas saídas e busca encontrar uma função que estabeleça uma relação aproximada entre elas (ALMEIDA; CARVALHO; MENINO, 2020). Os parâmetros dos modelos baseados em aprendizado supervisionado são configurados com intuito de calibrar seu nível de assertividade e precisão. Dentre estes, é possível destacar o *bias* e a variância do modelo. O *bias* está relacionado à capacidade do modelo se ajustar aos dados e a variância é a variabilidade das previsões do modelo (ALMEIDA; CARVALHO; MENINO, 2020).

A complexidade do modelo aumenta à medida que ele vai se ajustando aos dados, em contrapartida vai perdendo também a sua capacidade de generalização, que faz com que a variância seja aumentada (GERON, 2019). O ajuste desbalanceado da complexidade do modelo pode acarretar nos problemas de *underfitting* (sub-ajuste) ou *overfitting* (superajuste). O *underfitting* é um problema associado à falta de capacidade do modelo representar os dados; já no *overfitting*, o modelo se ajusta muito aos dados e perde a sua capacidade de generalizar (ALMEIDA; CARVALHO; MENINO, 2020).

Os modelos de aprendizado supervisionado estão associados às tarefas de regressão e classificação. O filtro de *spam* é um exemplo de classificação onde ele é treinado com muitos exemplos de e-mails, e deve aprender a classificá-los (GERON, 2019). Alguns algoritmos de regressão podem ser aplicados para classificação, e vice-versa. Por exemplo, a regressão logística, que é comumente utilizada para classificação, produzindo um valor que corresponde à probabilidade de pertencer a uma determinada classe (por exemplo, 20% de chance de um e-mail ser *spam*).


Dentre os algoritmos de aprendizado supervisionado, é possível citar: *K-Nearest-Neighbors (KNN)*, *Linear Regression*, *Logistic Regression*, *Support Vector Machine (SVM)*, *Decision Tree*, *Neural Networks* e *Random Forests*.

2.2.2 Aprendizado Não Supervisionado

O aprendizado não supervisionado, diferente do aprendizado supervisionado, deve fazer inferências a partir de um conjunto de dados que não foi rotulado, classificado ou categorizado previamente (ALMEIDA; CARVALHO; MENINO, 2020). Este tipo de aprendizado é amplamente utilizado para a descoberta de padrões ocultos nos dados.

O fluxo seguido por esse modelo é mostrado na Figura 1, cuja proposta foi modificada a partir de Almeida, Carvalho e Menino (2023). Inicialmente, é recebida uma *Entrada dos Dados*, onde os dados brutos, sem rótulos, são coletados e inseridos no sistema para análise. Em seguida, ocorre a etapa de *Processamento dos Dados*, que inclui a preparação e transformação das variáveis, como a normalização e a limpeza de dados, para garantir que estejam em um formato adequado para o algoritmo. Na etapa de *Aplicação do Algoritmo*, um método de aprendizado não supervisionado é utilizado para identificar padrões e, após a execução do algoritmo, vem a *Interpretação dos Resultados*, onde os padrões descobertos são analisados e os *insights* são extraídos. Por fim, a *Saída dos Dados* apresenta os resultados de forma visual ou em relatórios, permitindo a compreensão dos padrões encontrados e facilitando a tomada de decisões ou novos ajustes no processo.

Figura 1 - Fluxo de execução do aprendizado não supervisionado



Fonte: ALMEIDA; CARVALHO; MENINO, 2020

O modelo de aprendizado não supervisionado inclui tarefas de agrupamento e redução de dimensionalidade. Essa abordagem também é amplamente utilizada para identificação de anomalias nos dados. Para as tarefas de agrupamento, o modelo recebe um conjunto de dados não rotulados, e a partir disso busca agrupá-lo com base em alguma característica de similaridade, por exemplo, a distância entre os pontos (SYANTIEN, 2023). Os sistemas de recomendações, geralmente presentes nas plataformas de entretenimento, é uma das principais aplicações que utilizam essa abordagem. A redução de dimensionalidade é uma técnica que utiliza o aprendizado não supervisionado para a redução do número de variáveis. Essa técnica

é utilizada para encontrar um número inferior de variáveis que melhor representam as características dos conjuntos de dados (ALMEIDA; CARVALHO; MENINO, 2020).


Dentre os exemplos de algoritmos de aprendizado não supervisionado, é possível citar: *K-means*, *Clustering Hierárquico*, *Análise de Componentes Principais*, *Apriori*, *Eclat* e *t-Distributed Stochastic Neighbor Embedding*.

2.2.3 Aprendizado por Reforço

No aprendizado por reforço, os modelos são treinados para tomarem uma sequência de decisões e um ambiente incerto e complexo. Nessa abordagem, os agentes possuem um estado que é alterado após realizar uma ação que é executada de forma aleatória, com base nessa ação, os agentes podem ser penalizados ou recompensados (ALMEIDA; CARVALHO; MENINO, 2020). Nessa abordagem o modelo pode utilizar a tentativa e erro de forma a maximizar suas recompensas.

A Figura 2 mostra o fluxo clássico da abordagem baseada no aprendizado por reforço. É possível observar a projeção de um ambiente, que corresponde ao local em que o agente pode interagir tomando suas decisões. *A priori* o agente não possui nenhuma informação a respeito do ambiente, mas ele vai o conhecendo no decorrer de suas experiências para evoluir seus estados. O estado diz respeito às condições atuais do agente e do ambiente. O estado do agente é atualizado com base em suas recompensas ou penalidades que são adquiridas após suas ações. A recompensa é um sinal positivo que é ativado reforçando uma ação do agente, já a penalidade, é um sinal negativo que faz com que a ação do agente seja esquecida (ALMEIDA; CARVALHO; MENINO, 2020).

Figura 2 - Exemplo de fluxo do Aprendizado por Reforço



Fonte: ALMEIDA; CARVALHO; MENINO, 2020

Em termos práticos, é possível exemplificar o uso onde muitos robôs implementam algoritmos de aprendizado por reforço para aprender a andar. Um exemplo é o programa *AlphaGo* da *DeepMind*, que apareceu nas manchetes em 2017, quando venceu o campeão mundial de Ke Jie. O robô apenas desenvolveu sua política vencedora analisando milhões de jogos e depois praticando muito contra si mesmo (ALPHAGO, 2024).

2.3. Trabalhos Relacionados

Nesta seção, são apresentados alguns trabalhos de pesquisa relacionados a esta proposta. Diante disso, é possível destacar o trabalho de Gomes (2023), que construiu um instrumento de coleta de dados para obter informações de gestantes, tanto no contexto socioeconômico, com perguntas como: idade, estado civil, escolaridade e renda familiar; como no contexto de antecedentes obstétricos, como perguntas acerca de: presença ou ausência de sintomas depressivos, número de consultas pré-natal, peso ao nascer do último filho, filhos nascidos vivos, gestação planejada, pensamento ou tentativa de aborto, sexo da criança desejado, apoio paterno e apoio familiar.

Embora não se disponha de parâmetros fisiológicos para avaliar as manifestações clínicas da depressão, Gomes (2023) usou escalas de avaliação para medir e caracterizar os sintomas. Esses resultados não podem ser usados como critério para diagnósticos, mas ajudam a entender a saúde mental da paciente. Sendo assim, o autor usou a escala validada de Depressão Pós-Parto de Edimburgo (EPDS), que corresponde a um instrumento que mede a presença e intensidade de sintomas depressivos nos últimos sete dias. Esse instrumento é composto de dez enunciados, cujas opções são pontuadas de 0 a 3, de acordo com a presença e intensidade do sintoma. Seus itens cobrem sintomas psíquicos, como: humor depressivo (sensação de tristeza, autodesvalorização e sentimento de culpa, ideias de morte ou suicídio), perda do prazer em atividades anteriormente consideradas agradáveis, fadiga, diminuição da capacidade de pensar, de concentrar-se ou de tomar decisões, além de sintomas fisiológicos (insônia ou hipersônia) e alterações do comportamento (crises de choro).

O instrumento de coleta de dados de Gomes (2023) investigou a situação clínica de 236 mulheres. Os resultados alcançados indicaram que 32,2% atingiram escores iguais ou maiores que 10 o que significa um possível quadro depressivo. No contexto do perfil sociodemográfico, predominante as mulheres participantes são consideradas jovens adultas, com idade média de 25,7 anos, e sem associação à DPP. No entanto, o estudo em questão aponta uma incidência maior da sintomatologia naquelas mulheres que apresentam baixa escolaridade, comparando o Ensino Superior completo ao Ensino Médio incompleto. Além

disso, o autor destacou que a ausência de apoio paterno nos cuidados à criança, tanto física quanto emocional, aumenta o risco de DPP. Ou seja, mulheres que recebem apoio do companheiro tendem a apresentar menos sintomas depressivos; e mulheres sem parceiro fixo, ou que não planejaram a gestação, apresentaram maior incidência de DPP. A condição de ser mãe solteira ou mãe solo é associada a julgamentos sociais e desafios como criar os filhos sozinha, com dupla jornada de trabalho, levando a um esgotamento físico e mental.

Outro trabalho relacionado a esta pesquisa foi proposto por De Melo e Alves (2022), que construíram um instrumento de coleta de dados composto por 42 itens, que medem os níveis de depressão, ansiedade e estresse. Cada dimensão é avaliada separadamente, permitindo uma análise detalhada das condições psicológicas. Após isso, foram aplicados algoritmos de *machine learning*, no intuito de extrair conhecimento.

De Melo e Alves (2022), em sua proposta, realizaram o pré-processamento dos dados, no intuito de remover respostas inadequadas, dados faltantes, duplicados e colunas desnecessárias. Em seguida, selecionaram os atributos, além de promover a limpeza sobre os dados, no sentido de eliminar aqueles considerados irrelevantes ou redundantes. Após isso, os autores realizaram a divisão do conjunto de dados para treinamento e teste, aplicando os algoritmos KNN, *Random Forest* (RF), SVM e *Naive Bayes* (NB) para avaliar o desempenho dos modelos. Os resultados obtidos indicam que o SVM obteve os melhores resultados, com uma taxa de acurácia acima de 98% para os três sintomas, quando comparado aos demais.

Quando se investigado se as mulheres grávidas sofrem no período da pandemia da Covid-19, Qasrawi (2022) trouxe um relato sobre a incerteza da doença, juntamente com as medidas de distanciamento social, as quais afetaram negativamente a saúde mental de mulheres grávidas, aumentando os níveis de estresse, ansiedade e depressão. O autor realizou um estudo, usando técnicas de *machine learning*, para prever a depressão e ansiedade entre mulheres grávidas e puérperas, durante o *lockdown* da Covid-19.

O conjunto de dados usado por Qasrawi (2022) abrangeu mulheres residentes de países árabes, contando com uma amostra de 3.569 mulheres, sendo 1.939 grávidas e 1.630 puérperas. As participantes foram contatadas através das clínicas obstétricas e maternidades, sendo convidadas a responder um questionário. Após a obtenção e análise dos resultados, foram observados relatos de implicações negativas na saúde mental de mulheres gestantes, com diagnóstico de estresse durante toda a gravidez, problemas sociais e baixa autoestima.

Outro estudo que aplicou técnicas de *machine learning* para caracterizar a depressão pós-parto foi proposto por Shin (2020). O autor, em sua pesquisa, indicou alguns fatores de risco para o surgimento e fortalecimento da depressão pós-parto, incluindo histórico de

depressão ou doenças psiquiátricas, histórico familiar de transtorno afetivo, baixo suporte social, relacionamento conjugal ruim, complicações relacionadas à gravidez, incluindo cesarianas de emergência, gravidez não planejada ou não desejada, eventos estressantes durante a gravidez e parto prematuro. Em sua pesquisa, Shin (2020) usou dados via *Pregnancy Risk Assessment Monitoring System* (PRAMS) de 2012 a 2013, dos Centros de Controle e Prevenção de Doenças (CDC).

O PRAMS coleta dados específicos por estado, baseados na população, sobre características maternas e experiências antes, durante e após a gravidez. Os dados obtidos para pesquisa de Shin (2020) incluíram um total de 72.540 participantes, os quais passaram por uma etapa de pré-processamento. Após a limpeza das informações, foram selecionados 28.755 registros. Os resultados alcançados levaram como base o diagnóstico da depressão pós-parto sendo definido a partir da versão modificada do *Patient Health Questionnaire-2* (PHQ-2). Dois questionamentos foram levados às participantes: “*Desde que seu bebê nasceu, com que frequência você se sentiu triste, deprimida ou sem esperança?*” e “*Desde que seu bebê nasceu, com que frequência você teve pouco interesse ou prazer em fazer as coisas?*”. As mulheres que responderam “sempre” ou “frequentemente” a uma ou ambas essas perguntas foram consideradas “depressivas pós-parto”.

Para realização das análises, Shin (2020) utilizou nove algoritmos de *machine learnings*, incluindo KNN, *Decision Tree*, SVM, gradiente estocástico, *Random Forest*, rede neural, *Naïve Bayes*, regressão logística e *AdaBoost*. A modelagem preditiva baseada em *machine learning* incluiu vários recursos, como: idade da mulher, raça/etnia, nível de educação, número de nascimentos anteriores, fatores relacionados ao estresse, hábitos de exercícios antes da gravidez, histórico de depressão, consumo de álcool antes da gravidez, mudanças no comportamento de fumar nos últimos três meses de gravidez para o período pós-parto, Índice de Massa Corporal (IMC) da mãe antes da gravidez e outros fatores relacionados à saúde da mulher. Os resultados indicaram que o algoritmo *Random Forest* demonstrou o melhor desempenho para a previsão da doença.

3. METODOLOGIA DE PESQUISA

A pesquisa realizada neste trabalho se constitui de natureza aplicada, descritiva, com abordagem qualitativa, fundamentada no uso de técnicas de *machine learning* para diagnóstico da depressão pós-parto (NASCIMENTO,2016). A natureza aplicada visa propor uma solução prática ao problema do diagnóstico de depressão pós-parto; já o caráter descritivo, se propõe a analisar e descrever padrões comportamentais e clínicos, que são indicativos da depressão pós-parto. De forma geral, a proposta metodológica será abordada através das seguintes etapas: Concepção, Planejamento e Implementação dos modelos de *machine learning*.

A fase de concepção visa identificar a viabilidade da implementação proposta, analisando o escopo a ser alcançado, assim como o acesso ao conjunto de dados para treinamento e teste. Também, nesta fase, será realizada uma análise sobre a viabilidade de aplicação de modelos preditivos para obter diagnóstico da depressão pós-parto.

A fase de planejamento define o conjunto de dados a ser utilizado neste estudo e quais técnicas de experimento serão consideradas. O público alvo desta pesquisa relaciona-se com mulheres no período pós-parto. Pretende-se, com os resultados alcançados, que não apenas as mulheres puérperas se beneficiem do conhecimento, mas também os profissionais de saúde também, que podem promover uma intervenção prévia, antes mesmo de o problema acontecer. Nesse contexto, é possível apoiar a promoção de *insights*, que reflitam em tratamentos mais adequados para pacientes.

Uma das principais preocupações relacionada à fase de planejamento relaciona-se com a obtenção de uma base de dados adequada para a realização de experimentos. Os dados escolhidos estão disponíveis na plataforma *Kaggle*¹ e sua escolha é fundamentada por diversas razões, que garantem sua eficácia para o estudo, como: a especificidade dos dados, os quais garantem a construção de um modelo coerente e robusto; e a presença de metadados, que são as informações sobre os dados analisados, ajudando na interpretação e manipulação dos resultados.

Por fim, a etapa de implementação dos modelos de *machine learning* visa alcançar resultados de diagnóstico da depressão pós-parto. Os experimentos foram realizados em duas etapas: (i) usando todo o conjunto de dados; (ii) executando técnicas de inteligência para identificar quais os melhores dados para obtenção do diagnóstico.

¹ <https://www.kaggle.com/datasets/parvezalmuqtadir2348/postpartum-depression/data>

Os modelos considerados para experimentação são os resultantes dos trabalhos relacionados a este, conforme mostrado na Tabela 1. Sendo assim, propõe-se uma comparação entre os melhores modelos já alcançados com melhor desempenho analisados nos trabalhos relacionados. O intuito é identificar qual desses modelos tem o resultado mais interessante para o conjunto de dados proposto nesta pesquisa.

Tabela 1 - Melhores Técnicas dos Trabalhos Relacionados.

Trabalho	Técnicas Analisadas	Melhor Técnica
DE MELO E ALVES (2022)	SVM, KNN, Random Forest e Naive Bayes	SVM
QASRAWI (2022)	SVM, Gradient Boosting, KNN, Random Forest e Naive Bayes	Random Forest
WANG E ZHANG (2019)	Decision Tree, SVM, Naive Bayes, Extreme Gradient Boosting	SVM
SHIN (2020)	SVM, KNN, Naive Bayes, Random Forest, AdaBoost	Random Forest

Fonte: Autoria própria.

Com base no exposto e observado a Tabela 1, é possível identificar que os modelos que tiveram uma melhor acurácia são: SVM e o *Random Forest*. Para esta pesquisa, foi considerada a implementação do KNN para apoiar na obtenção das melhores características do conjunto de dados. Sendo assim, é válido discutir brevemente cada modelo a ser implementado.

O KNN é um algoritmo de classificação, baseado em instâncias que atribui uma classe a uma nova amostra com base na maioria das classes dos seus k vizinhos mais próximos. Ele utiliza uma métrica de distância, geralmente a Euclidiana, para identificar os exemplos mais semelhantes no conjunto de treinamento. Por não fazer suposições sobre a distribuição dos dados, é simples e eficaz em muitos cenários. Contudo, seu desempenho pode ser prejudicado por dados desbalanceados ou irrelevantes. A escolha do valor de k é crucial para evitar sobreajuste ou subajuste (JAIN, 2020).

O modelo SVM trata-se de um algoritmo supervisionado, que busca encontrar um hiperplano ótimo que separe as classes com a maior margem possível. É eficaz em problemas lineares e não lineares, utilizando diferentes funções *kernel* para lidar com dados complexos (REMIGIO, 2020).

Já o modelo *Random Forest*, permite construir múltiplas árvores de decisão durante o treinamento e gera a predição final por votação. Cada árvore é construída a partir de uma amostra aleatória do conjunto de dados e, em cada divisão, é considerada apenas uma parte das variáveis. Essa aleatoriedade contribui para a redução de sobreajuste, promovendo uma maior generalização. O modelo é eficiente, robusto a ruídos e eficaz em problemas com dados desbalanceados e variáveis correlacionadas (SALMAN, 2024).

4. RESULTADOS

Neste capítulo, serão apresentados os resultados alcançados para esta pesquisa. Inicialmente, será explorada a estratégia de limpeza e pré-processamento dos dados e posteriormente, os resultados obtidos acerca dos experimentos realizados em cada modelo, além de ser elencada uma discussão sobre os mesmos.

4.1 Base de Dados e Pré-processamento

Para a execução dos experimentos, o primeiro trabalho realizado foi a busca de uma base de dados que atendesse às expectativas desta pesquisa. Nesse sentido, foi realizada uma investigação na plataforma *Kaggle* e encontrada a base de dados *Postpartum Depression*, cujas características atendiam o objetivo geral do trabalho.

A *Postpartum Depression* apresenta 1503 registros e tem como variável alvo a característica *Feeling Anxious*, sendo ela indicativa para a predição da depressão pós-parto. Apesar de um numeroso volume de dados, essa variável apresenta um desbalanceamento significativo, com 980 registros *Yes* (para depressão pós parto) e 523 registros *No* (sem o diagnóstico da depressão pós parto). Esse desbalanceamento pode comprometer a capacidade preditiva dos modelos, conforme afirmado por Ribeiro, Silva e Rabêlo (2023). Sendo assim, para garantir a qualidade dos dados, foram aplicadas técnicas de limpeza e pré-processamento, incluindo:

- Remoção de valores ausentes, evitando inconsistências na análise;
- Exclusão de colunas irrelevantes para o treinamento dos modelos, como *Timestamp*, que não contribui diretamente para a predição a ser realizada nesta proposta;
- Conversão de variáveis categóricas para numéricas, essencial para que os modelos de *machine learning* possam interpretar os dados corretamente. Sendo assim, respostas como: *Yes*, *No*, além de valores intermediários, como: *Sometimes* ou *Maybe* foram mapeados para valores numéricos (1, 0 e 0.5), garantindo que todas as informações fossem representadas de maneira quantitativa;
- Divisão dos dados em treino e teste, garantindo uma avaliação justa do modelo.

Para solucionar questões relacionadas ao desbalanceamento da base de dados, foi aplicado o *Synthetic Minority Over-sampling Technique* (SMOTE) no conjunto de treino, gerando novas amostras sintéticas da classe minoritária (*No*). Essa abordagem evita que o modelo aprenda um viés excessivo para a classe majoritária e melhora sua capacidade preditiva.

Todos os ajustes e implementação dos modelos, elencados anteriormente, estão disponíveis no *Github*² e, com base neles, foi possível preparar os dados para aplicação dos modelos de *machine learning*, garantindo maior precisão e generalização dos resultados.

No intuito de avaliar o potencial preditivo das implementações, foi conduzida uma análise do coeficiente de correlação entre as características e a variável alvo. Sendo assim, foi realizada uma análise das características que indicaram, isoladamente, uma correlação com a variável alvo.

Para a execução dos modelos, foram considerados dois cenários distintos: (i) usando todas as características; e (ii) usando apenas as melhores características. Isso foi importante para buscar melhorias nos resultados. Sendo assim, foi aplicada uma técnica de inteligência, chamada *SelectKBest*, que visa reduzir o número de características mantendo apenas as mais relevantes estatisticamente, para prever a variável alvo - ou aquelas que tinham maior correlação com a variável alvo. A seleção foi baseada em testes estatísticos, selecionando as três e quatro melhores características para a execução dos testes comparativos, em relação aos testes do caso base (isto é, o caso que considera todas as características).

4.2 Resultados dos Modelos Implementados

Considerando os trabalhos relacionados a esta pesquisa, observou-se uma oportunidade de análise para investigar, de forma comparativa, os resultados dos melhores modelos já alcançados na análise dos trabalhos relacionados. Sendo assim, para esta proposta, foram considerados os modelos com melhor desempenho, considerando: KNN, *Random Forest* e o SVM.

Em todas as abordagens, os modelos foram conduzidos com o objetivo de prever a variável alvo "*Feeling Anxious*" com base nas demais características da base de dados. As previsões foram geradas no conjunto de teste e a avaliação do desempenho foi realizada por meio da matriz de confusão, relatório de classificação e acurácia. Essas métricas possibilitam verificar a precisão, *recall* e *f1-score* do modelo, fornecendo uma visão completa da sua eficácia na predição da ansiedade pós-parto.

4.2.1 Modelo KNN

Nesta seção, serão elencados os resultados da aplicabilidade do Modelo KNN usando todas as características e usando o algoritmo *SelectKBest*, que permite selecionar apenas as melhores características.

² <https://github.com/Leogrimes25>

Em ambas as estratégias de implementação, foi utilizado o valor de $k = 3$, ou seja, o modelo classifica cada nova amostra com base nas três amostras mais próximas em termos de distância. Valores muito pequenos de k (como $k = 1$) tendem a resultar em um modelo mais sensível a ruídos nos dados, levando a uma alta variância e possível *overfitting* (isto é, quando o modelo se adapta aos dados de treinamento). Por outro lado, valores muito altos de k podem suavizar excessivamente a decisão, aumentando o viés e reduzindo a capacidade do modelo de capturar padrões locais.

O poder de generalização do modelo foi avaliado mediante validação cruzada com 5 *folds*, permitindo verificar a estabilidade e a capacidade do modelo de manter um bom desempenho em dados novos. Esse valor foi escolhido por proporcionar um equilíbrio entre a quantidade de dados de treino e teste em cada iteração, reduzindo a variabilidade dos resultados e evitando problemas como *overfitting* e *underfitting* (isto é, quando o modelo não consegue capturar padrões dos dados) (DATACAMP, 2023). Essa abordagem permite obter uma estimativa mais confiável do desempenho do modelo antes de aplicá-lo a novos dados, proporcionando, também, um equilíbrio eficaz entre a avaliação do modelo e a eficiência computacional.

4.2.2 Resultados do Modelo KNN - Utilizando Todas as Características


Ao se utilizar todas as características presentes na base de dados para o treinamento do modelo KNN, foram obtidos os resultados apresentados na Figura 3. Nesse cenário, o modelo apresentou como resultado uma acurácia geral de 93,53%, o que demonstra que o KNN conseguiu se comportar de maneira eficiente no contexto de predição da depressão pós-parto. No entanto, é de suma importância a análise de outras métricas para a compreensão do modelo, especialmente àquelas que buscam realizar a avaliação com base nas classes definidas pela variável alvo do conjunto de dados, como precisão, *recall* e F1-Score.

Conforme mostrado na Figura 3, os resultados alcançados a partir do relatório de classificação, é possível verificar uma alta precisão (*precision*) e revocação (*recall*) para ambas as Classes. A Classe "0" (ausência de ansiedade) obteve 88% de precisão e 93% de *recall*, enquanto a Classe "1" (presença de ansiedade) apresentou 97% de precisão e 94% de *recall*. Isso sugere que o modelo é capaz de identificar corretamente casos positivos e negativos, com um leve viés para identificar a classe majoritária.

Vale ressaltar que, para esses valores mostrados na Figura 3, foi utilizado o valor do parâmetro *test size* de 30%, que foi definido como padrão e escolhido após a realização de

testes comparativos, buscando encontrar o melhor parâmetro, cuja variação compreendeu 20%, 30% e 40%.

Figura 3 - Resultados de desempenho do KNN



Fonte: Autoria própria.

A Tabela 2 mostra os resultados comparativos para o *test size*. Conforme mostrado, para o valor do *test size* = 40%, a acurácia foi de 94,30%; e já para 20%, a acurácia foi de 93,31%. O valor de 30% foi adotado por proporcionar um desempenho consistente e representar um meio-termo entre uma amostra de teste suficientemente grande para avaliar a generalização do modelo e uma amostra de treino robusta para garantir um bom aprendizado. Esses valores demonstram que, embora pequenas variações na divisão dos dados possam influenciar a performance do modelo, o KNN manteve um desempenho consistente.

Tabela 2 - Resultados da Variação do Test Size

Valor de <i>Test Size</i>	Acurácia
20%	93.31%
30%	93.53%
40%	94.30%

Fonte: Autoria própria.

4.2.3 Resultados do Modelo KNN - Utilizando as Melhores Características


Considerando o contexto de seleção das melhores características do conjunto de dados, conforme o que foi identificado durante o processo de extração de características, percebeu-se que o modelo KNN sofreu uma leve baixa relacionada ao desempenho geral, como visto na Figura 3.

Para o cenário das três melhores características destaca-se uma precisão (*precision*) de 81% para a Classe 0 e 86% para a Classe 1. Isso significa que, quando o modelo prevê que um indivíduo não sente ansiedade (Classe 0), ele acerta 81% das vezes, enquanto, ao prever que um indivíduo sente ansiedade (Classe 1), a taxa de acerto é 86%. Já o *recall*, foi de 71% para a classe 0 e 91% para a Classe 1, indicando que 71% dos casos realmente negativos foram corretamente identificados, enquanto 91% dos casos positivos foram corretamente classificados. Esse comportamento sugere que o modelo está melhor em detectar casos positivos.

A avaliação do modelo KNN utilizando as quatro melhores características demonstrou uma leve melhora em relação ao cenário com três, com uma acurácia final de 85,49%, seguindo o mesmo padrão do *test size* = 30%. No relatório de classificação, a precisão (*precision*) para a Classe 0 foi de 81%, enquanto para a Classe 1 foi de 87%. Já o *recall* foi de 74% para a classe 0 e 91% para a Classe 1, indicando que o modelo conseguiu identificar corretamente 74% dos casos negativos e 91% dos casos positivos. Em comparação com o cenário de três características, houve um pequeno aumento na capacidade do modelo de detectar corretamente os casos negativos, reduzindo ligeiramente os falsos positivos.


De forma geral, o uso de quatro características resultou em uma melhor performance preditiva em relação ao uso de três, mostrando que a inclusão de uma variável adicional trouxe informações relevantes para a classificação. No entanto, o desempenho ainda ficou abaixo dos testes que utilizaram todas as características (Figura 3).

Para complementar as análises acerca dos resultados do KNN, é válido mencionar sobre os resultados relacionados à matriz de confusão. Conforme visto da Figura 4, percebe-se que utilizando todas as características são alcançados 142 verdadeiros negativos (amostras corretamente classificadas como classe 0) e 277 verdadeiros positivos (amostras corretamente classificadas como classe 1). Já os erros do modelo são representados por 10 falsos positivos (amostras de classe 0 classificadas erroneamente como classe 1) e 19 falsos negativos (amostras de classe 1 classificadas erroneamente como classe 0). Esses resultados indicam que o modelo possui um bom desempenho na distinção entre as classes, com uma taxa de erro relativamente baixa.

Figura 4 - Matriz de Confusão com Todas as Características

Fonte: Autoria própria.

Ao utilizar as 4 melhores características, observa-se um aumento nos erros de classificação, conforme visto na Figura 5. O número de verdadeiros negativos reduz para 113, enquanto o número de verdadeiros positivos também diminui levemente para 270. Já os erros aumentam significativamente, com 39 falsos positivos e 26 falsos negativos. Esse comportamento sugere que, ao reduzir o número de características, o modelo perde parte da sua capacidade de discriminação, classificando incorretamente mais instâncias da classe 0 como 1. Esse aumento nos falsos positivos pode indicar que a informação perdida ao descartar algumas características estava contribuindo para uma melhor separação entre as classes.


Figura 5 - Matriz de Confusão com as 4 melhores características.

Fonte: Autoria própria.

4.3 Modelo SVM

O modelo SVM (Support Vector Machine) foi implementado utilizando a configuração padrão (default) da biblioteca Scikit-Learn, com kernel linear, parâmetro $C = 1.0$ para regularização e $\gamma = 'scale'$, que ajusta automaticamente a influência dos pontos de suporte com base na dispersão dos dados, conforme o código mostrado na Figura 6. O kernel linear foi escolhido por sua eficiência computacional e pela adequação a dados linearmente separáveis. O parâmetro C , com valor default de 1.0, representa o equilíbrio entre a maximização da margem de separação e a minimização dos erros, evitando o overfitting sem comprometer a capacidade de generalização. Já o $\gamma = 'scale'$, também padrão na biblioteca, adapta-se dinamicamente à variabilidade dos dados, promovendo maior estabilidade ao modelo. Essa configuração inicial foi suficiente para alcançar um desempenho preditivo competitivo, sem a necessidade de ajustes manuais nos hiperparâmetros. Por fim, para garantir a generalização do modelo, foi aplicada validação cruzada com 5 folds, permitindo avaliar sua estabilidade e capacidade de manter um bom desempenho em novos dados.

Figura 6 - Configuração do Modelo SVM



```
[25] 1 svm = SVC(kernel='linear', C=1.0, gamma='scale', random_state=42)

[26] 1 cv_scores = cross_val_score(svm, X_train_resampled, y_train_resampled, cv=5, scoring='accuracy')
```

Fonte: Autoria própria.


4.3.1 Resultados do Modelo SVM - Utilizando Todas as Características

Ao se utilizar todas as características presentes na base de dados para o treinamento do modelo SVM, foram obtidos os resultados apresentados na Figura 7. Nesse cenário, o modelo apresentou uma acurácia geral de 78,79%, indicando um desempenho satisfatório na predição da depressão pós-parto. No entanto, assim como no modelo KNN, a análise de métricas complementares se faz necessária para avaliar a capacidade do modelo em classificar corretamente ambas as classes.

Conforme graficamente explorado na Figura 7, os resultados do relatório de classificação evidenciam que a Classe "0" (ausência de ansiedade) obteve 65% de precisão e 80% de *recall*, enquanto a Classe "1" (presença de ansiedade) apresentou 88% de precisão e 78% de *recall*. Esses resultados indicam que o SVM possui uma boa capacidade de identificar corretamente os casos positivos, mas demonstra uma maior dificuldade em classificar

corretamente os casos negativos, cometendo mais erros ao prever a ausência de sintomas. Vale ressaltar que os valores obtidos utilizaram o parâmetro *test size* de 30%, definido como padrão para todos os modelos após experimentação anterior realizada.

Figura 7 - Resultados de desempenho do SVM



Fonte: Autoria própria.

4.3.2 Resultados do Modelo SVM - Utilizando as Melhores Características

Considerando a seleção das melhores características do conjunto de dados, observou-se que o modelo SVM apresentou um leve aumento no desempenho geral quando comparado ao uso de todas as variáveis, conforme ilustrado na Figura 7. Ao utilizar apenas as três melhores características, os resultados obtidos foram de 82,14%. Já para o cenário com as quatro melhores características, os valores de acurácia foram 83,48%. Esses resultados indicam que a redução do número de variáveis pode impactar positivamente a performance do modelo, sugerindo que o uso do conjunto completo pode ser menos adequado para a predição da variável alvo "*Feeling Anxious*".

Para o cenário com as três melhores características, o modelo SVM apresentou uma precisão de 71% para a Classe 0 e 89% para a Classe 1. Isso significa que, ao prever que um indivíduo não sente ansiedade (Classe 0), o modelo acerta em 71% dos casos, enquanto para a Classe 1, a taxa de acerto é de 89%. Já o *recall* foi de 80% para a Classe 0 e 83% para a


Classe 1, indicando que 80% dos casos realmente negativos foram corretamente identificados, enquanto 83% dos casos positivos foram classificados corretamente. Esse comportamento sugere que o modelo é mais eficiente em detectar casos positivos de ansiedade.

A avaliação do modelo SVM utilizando as quatro melhores características demonstrou uma melhora discreta em relação ao cenário com três, apresentando uma acurácia final de 83,48%. No relatório de classificação, a precisão para a Classe 0 foi de 74%, enquanto para a Classe 1 foi de 89%. O *recall* foi de 79% para a Classe 0 e 86% para a Classe 1, demonstrando que o modelo conseguiu identificar corretamente 79% dos casos negativos e 86% dos positivos. Comparado ao cenário de três características, houve uma pequena melhoria na capacidade do modelo de identificar casos negativos corretamente, reduzindo ligeiramente os falsos positivos (Figura 7).

De maneira geral, o uso das quatro melhores características resultou em um melhor desempenho preditivo em relação ao uso de apenas três, sugerindo que a adição de uma variável trouxe informações adicionais relevantes. Por fim, os resultados obtiveram maior acurácia em relação ao uso de todas as características.

Ao analisar a Figura 8, percebe-se que a matriz de confusão do SVM, ao utilizar todas as características, apresenta 121 verdadeiros negativos e 232 verdadeiros positivos, com 31 falsos positivos e 64 falsos negativos. Esse resultado revela um bom desempenho geral, mas com destaque para o número relativamente elevado de falsos negativos, o que indica que o modelo teve dificuldade em identificar corretamente alguns casos positivos.


Figura 8 - Matriz de Confusão para Todas as Características



Fonte: Autoria própria.

Ao considerar a matriz de confusão do SVM utilizando as 4 melhores características, nota-se 254 casos de verdadeiros positivos e 42 falsos negativos, conforme mostrado na Figura 9. No entanto, há uma pequena piora na classificação dos negativos, com 120 verdadeiros negativos e um leve aumento nos falsos positivos para 32.

Figura 9 - Matriz de Confusão com as 4 Melhores Características.



Fonte: Autoria própria.

4.4 Modelo *Random Forest*

O modelo *Random Forest* foi configurado mediante parâmetro *n_estimators* onde é definido o número de árvores na floresta, conforme mostrado na Figura 10. Um valor maior tende a aumentar a precisão do modelo, reduzindo a variância e tornando-o mais robusto contra *overfitting*. Nesse cenário, o valor 100 é um padrão amplamente utilizado. Além disso, foi configurado o parâmetro *random_state* = 42, que serve para garantir a reprodutibilidade dos resultados, controlando a aleatoriedade do processo de criação das árvores e permitindo que o modelo produza sempre o mesmo resultado ao ser executado múltiplas vezes.

Figura 10 - Configuração do *Random Forest*

```
rf = RandomForestClassifier(n_estimators=100, random_state=42)
rf.fit(X_train_resampled, y_train_resampled)
```


Fonte: Autoria própria.

4.4.1 Resultados do Modelo *Random Forest* - Utilizando Todas as Características

Ao se utilizar todas as características disponíveis na base de dados para o treinamento do modelo *Random Forest*, foram obtidos os resultados apresentados na Figura 11. Nesse cenário, o modelo apresentou uma acurácia geral de 97,77% para um *test size* de 30%, indicando um desempenho altamente eficiente na predição da depressão pós-parto. Esse resultado demonstra que o *Random Forest* conseguiu capturar padrões relevantes nos dados, proporcionando uma classificação precisa.

No relatório de classificação, observa-se uma alta precisão e *recall* para ambas as classes, como visto graficamente na representação da Figura 11. A Classe "0" (ausência de ansiedade) obteve 98% de precisão e 96% de *recall*, enquanto a Classe "1" (presença de ansiedade) apresentou 98% de precisão e 99% de *recall*. Esses valores sugerem que o modelo é capaz de identificar corretamente tanto os casos positivos quanto os negativos, apresentando um desempenho equilibrado entre as classes.

Figura 11 - Resultados de desempenho do *Random Forest*



Fonte: Autoria própria.

4.4.2 Resultados do Modelo *Random Forest* - Utilizando as Melhores Características

Ao analisar o impacto da seleção das melhores características no desempenho do modelo *Random Forest*, observou-se uma leve variação na acurácia quando comparado ao uso


de todas as características (Figura 11). No cenário em que foram utilizadas apenas as três melhores características, os resultados obtidos foram: 86,38%; já o cenário com as quatro melhores características, os valores de acurácia foram de 86,83%. Esses resultados sugerem que, apesar da redução das variáveis, o modelo manteve um desempenho competitivo, com uma leve melhora ao adicionar uma quarta variável.

No cenário com as três melhores características, o modelo *Random Forest* apresentou uma precisão de 78% para a Classe 0 e 91% para a Classe 1. Isso significa que, ao prever que um indivíduo não sente ansiedade (Classe 0), o modelo acerta em 78% dos casos, enquanto para a Classe 1, a taxa de acerto é de 91%. Já o *recall* foi de 83% para a Classe 0 e 88% para a Classe 1, indicando que 83% dos casos realmente negativos foram corretamente identificados, enquanto 88% dos casos positivos foram classificados corretamente. Esse comportamento sugere que o modelo está bem equilibrado na detecção de ambas as classes.

A avaliação do modelo *Random Forest* utilizando as quatro melhores características demonstrou uma leve melhora em relação ao cenário com três, apresentando uma acurácia final de 86,83%. No relatório de classificação, a precisão para a Classe 0 foi de 82%, enquanto para a Classe 1 foi de 91%. O *recall* foi de 82% para a Classe 0 e 91% para a Classe 1, indicando que o modelo conseguiu identificar corretamente 82% dos casos negativos e 91% dos positivos. Comparado ao cenário de três características, houve uma pequena melhoria na capacidade do modelo de identificar casos negativos corretamente, reduzindo ligeiramente os falsos positivos.


De maneira geral, o uso das quatro melhores características resultou em um desempenho ligeiramente superior em relação ao uso de apenas três, sugerindo que a adição de uma variável trouxe informações adicionais relevantes. No entanto, os resultados ainda ficaram abaixo dos testes que utilizaram todas as características, reforçando que o conjunto completo pode ser a melhor opção para maximizar a performance também deste modelo.

A matriz de confusão do modelo *Random Forest* utilizando todas as características demonstra um desempenho altamente eficiente. Conforme visto na Figura 12, o modelo apresenta 146 verdadeiros negativos (amostras corretamente classificadas como classe 0) e 292 verdadeiros positivos (amostras corretamente classificadas como classe 1), indicando uma excelente capacidade de diferenciação entre as classes. Além disso, há apenas 6 falsos positivos (amostras de classe 0 classificadas erroneamente como classe 1) e 4 falsos negativos (amostras de classe 1 classificadas erroneamente como classe 0), valores extremamente baixos. Esse resultado sugere que o modelo é robusto e consegue realizar previsões precisas com um erro mínimo.

Figura 12 - Matriz de Confusão Utilizando Todas as Características

Fonte: Autoria própria.

Já na matriz de confusão do *Random Forest* utilizando as 4 melhores características, observa-se um impacto significativo na precisão da classificação. A Figura 13 mostra que os verdadeiros negativos diminuíram para 118, e os verdadeiros positivos reduziram para 271, indicando que o modelo passou a errar mais na identificação correta das classes. Além disso, os falsos positivos aumentaram para 34, e os falsos negativos cresceram para 25, demonstrando que a exclusão de algumas características prejudicou a capacidade do modelo de separar corretamente as classes.

Figura 13 - Matriz de Confusão utilizando as 4 Melhores Características

Fonte: Autoria própria.

4.5 Discussão dos Resultados

Com base nos resultados alcançados, é possível observar diferenças significativas entre os modelos KNN, SVM e *Random Forest*, as quais são mostradas de forma comparativa na Tabela 3.

Observando o desempenho de cada modelo, percebe-se que o modelo *Random Forest* demonstrou melhor desempenho em todas as métricas avaliadas, apresentando alta precisão, *recall* e *f1-score* para ambas as Classes (0 e 1), além do valor de acurácia ter chegado a 97.77% ao utilizar todas as características, superando os outros modelos por uma margem considerável (Tabela 3).

Tabela 3 - Comparativo Geral das Métricas dos Modelos

Modelos	Todas as Características			3 Melhores			4 Melhores		
	Precisão (0/1)	Recall (0/1)	F1-Score (0/1)	Precisão (0/1)	Recall (0/1)	F1-Score (0/1)	Precisão (0/1)	Recall (0/1)	F1-Score (0/1)
KNN	88% (0)	93%(0)	91%(0)	81%(0)	71%(0)	76%(0)	81%(0)	74%(0)	78%(0)
	97% (1)	94%(1)	95%(1)	86%(1)	91%(1)	89%(1)	87%(1)	91%(1)	89%(1)
SVM	65%(0)	80%(0)	72%(0)	71%(0)	80%(0)	75%(0)	74%(0)	79%(0)	76%(0)
	88%(1)	78%(1)	83%(1)	89%(1)	83%(1)	86%(1)	89%(1)	86%(1)	87%(1)
Random Forest	97%(0)	96%(0)	97%(0)	78%(0)	83%(0)	81%(0)	83%(0)	78%(0)	80%(0)
	98%(1)	99%(1)	98%(1)	91%(1)	88%(1)	90%(1)	89%(1)	92%(1)	90%(1)

Fonte: Autoria própria.

Quando observado o modelo que pior performou, a partir do valor da acurácia, verifica-se o desempenho do SVM, que apresentou um resultado de 78.79%, conforme mostrado na Tabela 4, quando todas as características foram consideradas. A intuição por trás pode estar relacionada à dificuldade do SVM em encontrar um hiperplano ótimo para separar as classes no conjunto de dados.

Observando a Tabela 4, percebe-se que o KNN teve excelente desempenho com todas as características (93,53%) e uma leve queda ao usar apenas as melhores características (84,38% com 3 e 85,49% com 4). Quando comparado a trabalhos relacionados, seus resultados apresentaram desempenho significativamente melhor que Shin (2020), com 64%, e foram próximos aos de De Melo e Alves (2022), que obtiveram 86,8%.

O SVM apresentou 78,79% de acurácia com todas as características e melhorou ao focar nas melhores características (82,14% com 3 e 83,48% com 4), demonstrando que a

seleção de atributos foi benéfica. Quando comparado, Shin (2020) obteve 78%, próximo ao modelo completo, enquanto De Melo e Alves (2022) apresentaram desempenho significativamente melhor, com 99%.

Já o Random Forest teve o melhor desempenho geral, com 97,77% usando todas as características e cerca de 86% ao usar as melhores características (com leve redução). Comparado aos trabalhos relacionados, apresentou desempenho significativamente melhor do que Qasrawi (2022), com 81,3%, e Shin (2020), com 79%.

Tabela 4 - Comparação da Acurácia entre os resultados dos Modelos

Modelo	Acurácia(Todas as Características)	Acurácia (Melhores Características)	Trabalhos Relacionados(Acurácia)
KNN	93.53%	84.38% (3 Melhores Características) e 85.49% (4 Melhores Características).	De Melo e Alves (2022) : 86.8%
			SHIN (2020) : 64%
SVM	78.79%	82.14% (3 Melhores Características) e 83.48% (4 Melhores Características).	SHIN (2020) : 78%
			De Melo e Alves (2022) : 99%
Random Forest	97.77%	86.38% (3 Melhores Características) e 86.83% (4 Melhores Características).	QASRAWI (2022) : 81.3%
			SHIN (2020) : 79%

Fonte: Autoria própria.

Com base no exposto, é possível afirmar que o modelo KNN apresentou um desempenho superior ao SVM, mas ainda inferior ao *Random Forest*, ficando em segundo lugar na análise sobre o melhor modelo de predição para depressão pós-parto, considerando o conjunto de dados trabalhados nesta pesquisa.

5. CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

A gestação é um processo complexo que envolve mudanças físicas, emocionais e sociais, podendo desencadear transtornos mentais como a DPP, cuja prevalência atinge entre 10% e 20% das mulheres.

A DPP afeta não apenas o bem-estar da mãe, mas também o desenvolvimento do bebê, sendo associada a fatores como histórico de transtornos, alterações hormonais, estilo de vida e uso de medicamentos durante a gestação. Seus sintomas incluem tristeza intensa, desesperança, insônia, pensamentos suicidas e rejeição ao bebê.

A ausência de diagnóstico precoce e o tratamento ineficaz da DPP agravam o problema. Diante disso, torna-se relevante buscar soluções tecnológicas que ofereçam suporte à equipe médica. Neste contexto, este trabalho propõe o uso de modelos de *machine learning* para auxiliar na predição da doença, promovendo uma abordagem mais segura e preventiva à saúde mental materna. A proposta visa unir a compreensão clínica dos sintomas com o potencial preditivo de algoritmos inteligentes.

Dada a sensibilidade do tema abordado, é fundamental ressaltar a importância de considerar princípios éticos durante todas as etapas da pesquisa. Trabalhar com dados relacionados à saúde da mulher exige respeito, responsabilidade e compromisso com a confidencialidade, mesmo quando os dados são anonimizados. Questões como estigmatização, vulnerabilidade das pacientes e impactos sociais devem ser cuidadosamente observadas. Assim, a utilização de técnicas de inteligência artificial deve ocorrer de forma ética, garantindo que os modelos desenvolvidos não substituam o julgamento clínico, mas sirvam como ferramentas auxiliares para apoiar decisões mais informadas e seguras.

É essencial frisar que os modelos de *machine learning* apresentados neste estudo devem ser compreendidos como instrumentos de apoio à equipe médica, e não como ferramentas decisórias autônomas. Sua aplicação deve ocorrer sempre em conjunto com a avaliação clínica, servindo como complemento à expertise dos profissionais de saúde. Além disso, todo o processamento e uso dos dados utilizados respeitam a Lei Geral de Proteção de Dados (LGPD), garantindo a privacidade e os direitos dos envolvidos, mesmo com o uso de bases públicas. A LGPD reforça que a coleta, o tratamento e a análise de dados sensíveis devem estar alinhados a princípios como finalidade, necessidade e segurança da informação.

A metodologia deste trabalho foi planejada, analisada e executada com base em uma abordagem aplicada, descritiva e qualitativa. Nesse sentido, este trabalho foi estruturado em três etapas principais: concepção, planejamento e implementação. Na fase de concepção, avaliou-se a viabilidade do uso de modelos preditivos, bem como a disponibilidade e

adequação dos dados. No planejamento, foram definidos os públicos de interesse — mães no pós-parto e profissionais de saúde — e selecionada uma base de dados da plataforma *Kaggle*, escolhida pela sua especificidade e presença de metadados. E, na fase de implementação, os modelos foram aplicados em dois ciclos: primeiro com todo o conjunto de dados e, em seguida, com dados otimizados, permitindo comparar os resultados e identificar a abordagem mais eficaz para o diagnóstico da depressão pós-parto.

Os resultados obtidos evidenciam diferenças relevantes entre os modelos avaliados, sendo o *Random Forest* o modelo com melhor desempenho geral, cujas métricas apresentaram-se elevadas para ambas as classes e acurácia de 97,77% ao utilizar todas as características. Ainda foi possível observar que o SVM foi o modelo com pior desempenho, possivelmente devido à dificuldade na separação das classes, alcançando apenas 78,79% de acurácia. Já o KNN demonstrou performance intermediária, superando o SVM, mas abaixo do *Random Forest*, ocupando a segunda posição na predição da depressão pós-parto.

Como trabalhos futuros, pretende-se: realizar novos experimentos com outros conjuntos de dados e testar novos modelos para fins de comparação. Com base no alcance do modelo com melhor desempenho, será proposta uma *Application Programming Interface* (API) e, com ela, será possível construir uma ferramenta de propósito geral para apoiar a equipe de saúde no diagnóstico da doença.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, Adriano; CARVALHO, Felipe; MENINO, Felipe. *Introdução ao Machine Learning*. Revista Grupo DataAt. INPE-Instituto Nacional de Pesquisas Espaciais. Brasil, 2020.

ALPHAGO. Inteligência artificial do Google, vence desafio de go contra melhor jogador do mundo. 2017. Disponível em: <https://g1.globo.com/tecnologia/noticia/alphago-inteligencia-artificial-do-google-vence-desafio-de-go-contr-melhor-jogador-do-mundo.ghtml>. Acesso em: 23 set. 2024.

DANIEL, Bruna Della Rocca; LIMA, Letícia Silva; OPPENHEIMER, Drauzio. *Fatores de risco associados à depressão pós-parto*. Research, Society and Development, v. 12, n. 11, p. e68121143678-e68121143678, 2023.

DATA CAMP. *A Comprehensive Guide to K-Fold Cross Validation*. Disponível em: <https://www.datacamp.com/tutorial/k-fold-cross-validation>. Acesso em: 27/03/2025.

DE MELO, Ana Laura Barros; ALVES, André Luiz Firmino. *Aplicação de Técnicas de Aprendizagem de Máquina para Diagnóstico de Depressão, Ansiedade e Estresse*. In: Encontro Nacional de Computação dos Institutos Federais (ENCompIF). SBC, 2022. p. 13-16.

GÉRON, Aurélien. *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow*. 2. ed. Sebastopol: O'Reilly Media, 2019.

GOMES, Bruna Katerine Godinho et al. *Prevalência da sintomatologia de depressão pós-parto e fatores associados*. Research, Society and Development, v. 12, n. 1, p. e0812139183-e0812139183, 2023.

JAIN, Priyanka. *K-Nearest Neighbors – Classification technique in Machine Learning*. Medium, 28 dez. 2020. Disponível em: <https://medium.com/analytics-vidhya/k-nearest-neighbors-classification-technique-in-machine-learning-2b8d22b99979>. Acesso em: 25 abr. 2025.

Ministério da Saúde. *Depressão Pós-Parto*. Portal Gov.br. 2024. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/d/depressao-pos-parto>. Acesso em: 27 set. 2024.

Ministério da Saúde. *Saúde Mental*. Portal Gov.br. 2024. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/s/saude-mental>. Acesso em: 27 set. 2024.

Ministério da Saúde. *Centros de Atenção Psicossocial (CAPS)*. 2024. Portal Gov.br. Disponível em: <https://www.gov.br/saude/pt-br/composicao/saes/desmad/raps/caps>. Acesso em: 27 set. 2024.

NASCIMENTO, Francisco Paulo do; SOUSA, F. L. Classificação da Pesquisa. Natureza, método ou abordagem metodológica, objetivos e procedimentos. Metodologia da Pesquisa Científica: teoria e prática—como elaborar TCC. Brasília: Thesaurus, 2016

QASRAWI, Radwan et al. *Machine learning techniques for predicting depression and anxiety in pregnant and postpartum women during the COVID-19 pandemic: a cross-sectional regional study*. F1000Research, v. 11, 2022.

REMIGIO, Matheus. *Máquina de Vetores de Suporte — SVM*. Medium, 24 ago. 2020. Disponível em: <https://medium.com/@msremigio/m%C3%A1quinas-de-vetores-de-suporte-svm-77bb114d02fc>. Acesso em: 25 abr. 2025.

RIBEIRO, Hector Batista; SILVA, Leandro Oliveira da; RABÊLO, Ricardo de Andrade Lira. *Estratégias para Lidar com Desbalanceamento de Dados em Aprendizado de Máquina*. In: LAGO, Nívio Ziviani do; SANTOS, Rafael Dueire Lins dos (Org.). *Aprendizado de Máquina: Fundamentos e Aplicações*. Porto Alegre: Sociedade Brasileira de Computação, 2023. p. 79-102. Disponível em: <https://books-sol.sbc.org.br/index.php/sbc/catalog/download/152/654/1174?inline=1>. Acesso em: 27/03/2025.

SALMAN, Hasan Ahmed; KALAKECH, Ali; STEITI, Amani. *Random forest algorithm overview*. Babylonian Journal of Machine Learning, v. 2024, p. 69-79, 2024.

SHIN, Dayeon et al. *Machine learning-based predictive modeling of postpartum depression*. Journal of Clinical Medicine, v. 9, n. 9, p. 2899, 2020.

SYANTIEN. *Unsupervised learning: including clustering, dimensionality reduction, and anomaly detection*. Medium, 29 ago. 2023. Disponível em:

<https://medium.com/@syantien/unsupervised-learning-including-clustering-dimensionality-reduction-5669438cace6>. Acesso em: 20 maio 2025.

WANG, Shuojia; PATHAK, Jyotishman; ZHANG, Yiye. *Using electronic health records and machine learning to predict postpartum depression*. In: MEDINFO 2019: Health and Wellbeing e-Networks for All. IOS Press, 2019. p. 888-892.