



ESCOLA BAHIANA DE MEDICINA E SAÚDE PÚBLICA
CURSO BIOMEDICINA

NATHÁLIA LISE PINHEIRO DOS SANTOS
TAINÉ NEVES ALMEIDA

**O PAPEL DA INTELIGÊNCIA ARTIFICIAL NA FERTILIZAÇÃO *IN-VITRO* E SEU
IMPACTO NA PREDIÇÃO DE NASCIDOS VIVOS: UMA REVISÃO SISTEMÁTICA**

SALVADOR – BA
2024

NATHÁLIA LISE PINHEIRO DOS SANTOS
TAINÉ NEVES ALMEIDA

**O PAPEL DA INTELIGÊNCIA ARTIFICIAL NA FERTILIZAÇÃO *IN-VITRO* E SEU
IMPACTO NA PREDIÇÃO DE NASCIDOS VIVOS: UMA REVISÃO SISTEMÁTICA**

Trabalho de Conclusão de Curso apresentado à
Escola Bahiana de Medicina e Saúde Pública,
como parte dos requisitos para obtenção do
título de Bacharel em Biomedicina.

Orientador: Prof^ª. Dra. Jéssica Fernandes dos
Santos

SALVADOR – BA

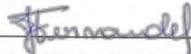
2024

NATHÁLIA LISE PINHEIRO DOS SANTOS
TAINÉ NEVES ALMEIDA

**O PAPEL DA INTELIGÊNCIA ARTIFICIAL NA FERTILIZAÇÃO *IN-VITRO* E
SEU IMPACTO NA PREDIÇÃO DE NASCIDOS VIVOS: UMA REVISÃO
SISTEMÁTICA**

Este Trabalho de Conclusão de Curso foi julgado adequado à obtenção do grau de Bacharel em Biomedicina e aprovada em sua forma final pelo Curso de Biomedicina da Escola Bahiana de Medicina e Saúde Pública.

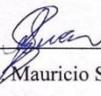
Salvador, 9 de novembro de 2024.



Prof.ª. Dra. Jéssica Fernandes dos Santos



Prof. Dr. Cinthia Vila Nova Santana
Escola Bahiana de Medicina e Saúde



Biomédico Esp. Mauricio Silva dos Santos

Dedicamos este trabalho a nossas mães e pais, que sempre foram a base do nosso sucesso e a fonte de amor e apoio. Por cada ensinamento, cada sacrifício e por acreditarem em nós.

Dedicamos também a nós mesmas, por nossa coragem, determinação e por termos chegado até aqui. Que essa realização seja o símbolo do nosso esforço e dedicação.

AGRADECIMENTOS

A Deus, pela força e sabedoria concedidas ao longo de nossa jornada acadêmica, por cada oportunidade e por nos guiar nos momentos de desafios e incertezas.

Aos nossos pais e familiares, que sempre estiveram ao nosso lado, apoiando cada escolha, torcendo por cada conquista e acreditando no nosso futuro. Vocês foram nossa base e motivação constante, e somos profundamente gratas pelo carinho e apoio incondicional.

À nossa panelinha da faculdade – Caio Marques, Gabriel Alves e Maria Luiza Nascimento –, amigos que tornaram essa caminhada muito mais leve e cheia de risadas. Obrigado pela amizade, pelas memórias que levaremos para a vida toda e por cada momento de descontração que tornou essa experiência inesquecível.

Aos professores, que com dedicação e paciência nos transmitiram conhecimentos valiosos. Suas aulas e ensinamentos contribuíram não só para a nossa formação acadêmica, mas também para nosso crescimento pessoal. E um agradecimento especial à nossa orientadora, que nos guiou com zelo e dedicação durante a realização deste trabalho. Sua orientação foi essencial para que chegássemos até aqui, e seremos sempre gratos pelo apoio e pelo incentivo.

A todos que de alguma forma fizeram parte dessa trajetória, nosso muito obrigado.

“Descobrir consiste em olhar para o que todo mundo está vendo e pensar uma coisa diferente”. (Roger Von Oech)

RESUMO

Introdução: Nos últimos anos, a inteligência artificial (IA) tem crescido como uma ferramenta importante para otimizar os processos da fertilização *in vitro* (FIV), oferecendo novas perspectivas no que diz respeito à predição de nascidos vivos. **Objetivo:** Revisar sistematicamente a função da IA na FIV, avaliando seu impacto na predição de nascidos vivos. **Métodos:** O presente trabalho consiste em revisão sistemática cujo objeto de análise é a produção científica veiculada em periódicos indexados nos bancos de dados da Literatura Latino-americana e do Caribe em Ciências da Saúde (Lilacs), Biblioteca Cochrane (COCHRANE), PubMed (United States National Library of Medicine) e Scientific Eletronic Library Online (SciELO). **Resultados:** A partir da análise comparativa dos modelos de algoritmos utilizados para prever o nascimento vivo após FIV, é evidente que a escolha do modelo impacta diretamente o desempenho preditivo. **Conclusão:** Esses achados sugerem a importância de selecionar o modelo correto de algoritmo dependendo do contexto clínico. Além disso, apontam para a crescente relevância da IA no aprimoramento da personalização e predição de tratamentos de fertilização *in vitro*, impactando diretamente as práticas clínicas.

Palavras-chave: Inteligência artificial, fertilização *in vitro*, nascidos vivos.

ABSTRACT

Introduction: In recent years, artificial intelligence (AI) has emerged as a powerful tool for optimizing in vitro fertilization (IVF) processes, offering new perspectives on predicting live births. **Objective:** To systematically review the role of AI in IVF, assessing its impact on predicting live births. **Methods:** This study consists of a systematic review whose object of analysis is the scientific production published in journals indexed in the databases of Latin American and Caribbean Literature in Health Sciences (Lilacs), Cochrane Library (COCHRANE), PubMed (United States National Library of Medicine) and Scientific Electronic Library Online (SciELO). **Results:** From the comparative analysis of the algorithm models used to predict live birth after IVF, it is evident that the choice of model directly impacts predictive performance. **Conclusion:** These findings suggest the importance of selecting the correct algorithm model depending on the clinical context. Furthermore, they point to the growing relevance of AI in improving the personalization and prediction of in vitro fertilization treatments, directly impacting clinical practices.

Keywords: Artificial intelligence, in vitro fertilization, live births.

SUMÁRIO

1. ARTIGO CIENTÍFICO.....	10
2. PROPOSTA DE SUBMISSÃO	24
2.1. REVISTA.....	24
2.2. REGRAS DE SUBMISSÃO.....	24

1. ARTIGO CIENTÍFICO



O papel da inteligência artificial na fertilização *in vitro* e seu impacto na predição de nascidos vivos: Uma revisão sistemática

The role of artificial intelligence in *in vitro* fertilization and its impact on live birth prediction: A systematic review

El papel de la inteligencia artificial en la fertilización *in vitro* y su impacto en la predicción de nacidos vivos: una revisión sistemática

Nathália Lise Pinheiro dos Santos

Graduanda em Biomedicina

Instituição de formação: Escola Bahiana de Medicina e Saúde Pública

Endereço: Salvador, Bahia, Brasil

E-mail: nathalialisepinheiro@gmail.com

Taine Neves Almeida

Graduanda em Biomedicina

Instituição de formação: Escola Bahiana de Medicina e Saúde Pública

Endereço: Salvador, Bahia, Brasil

E-mail: ataine163@gmail.com

Jéssica Fernandes dos Santos

Doutorado em Medicina e Saúde Pública

Instituição: Universidade Federal da Bahia

Endereço: Salvador, Bahia, Brasil

E-mail: fernandess.j@hotmail.com

RESUMO

Introdução: Nos últimos anos, a inteligência artificial (IA) tem crescido como uma ferramenta importante para otimizar os processos da fertilização *in vitro* (FIV), oferecendo novas perspectivas no que diz respeito à predição de nascidos vivos. **Objetivo:** Revisar sistematicamente a função da IA na FIV, avaliando seu impacto na predição de nascidos vivos. **Métodos:** O presente trabalho consiste em uma revisão sistemática cujo objeto de análise é a produção científica veiculada em periódicos indexados nos bancos de dados da Literatura Latino-americana e do Caribe em Ciências da Saúde (Lilacs), Biblioteca Cochrane (COCHRANE), PubMed (United States National Library of

Medicine) e Scientific Electronic Library Online (SciELO). Resultados: A partir da análise comparativa dos modelos de algoritmos utilizados para prever o nascimento vivo nos tratamentos de reprodução humana assistida, é evidente que a escolha do modelo impacta diretamente o desempenho preditivo. Conclusão: Esses achados sugerem a importância de selecionar o modelo correto de algoritmo dependendo do contexto clínico. Além disso, apontam para a crescente relevância da IA no aprimoramento da personalização e predição de tratamentos de fertilização *in vitro*, impactando diretamente as práticas clínicas.

Palavras-chave: Inteligência artificial, fertilização *in vitro*, nascidos vivos.

ABSTRACT

Introduction: In recent years, artificial intelligence (AI) has emerged as a crucial tool to optimize in vitro fertilization (IVF) processes, offering new perspectives regarding the prediction of live births. **Objective:** To systematically review the role of AI in IVF, evaluating its impact on predicting live births. **Methods:** This study consists of a systematic review, analyzing scientific literature published in indexed journals within the databases of Latin American and Caribbean Literature in Health Sciences (Lilacs), Cochrane Library (COCHRANE), PubMed (United States National Library of Medicine), and Scientific Electronic Library Online (SciELO). **Results:** From the comparative analysis of algorithmic models used to predict live birth outcomes in human reproduction treatments, it is evident that model selection directly impacts predictive performance. **Conclusion:** These findings suggest the importance of selecting the appropriate algorithm model depending on the clinical context. Additionally, they highlight the growing relevance of AI in enhancing the personalization and predictive accuracy of IVF treatments, directly impacting clinical practices.

Keywords: Artificial intelligence, in vitro fertilization, live births.

RESUMEN

En los últimos años, la inteligencia artificial (IA) se ha convertido en una herramienta clave para optimizar los procesos de fertilización *in vitro* (FIV), ofreciendo nuevas perspectivas en cuanto a la predicción de nacidos vivos. **Objetivo:** Revisar sistemáticamente el papel de la IA en la FIV, evaluando su impacto en la predicción de nacidos vivos. **Métodos:** Este estudio consiste en una revisión sistemática, cuyo objeto de análisis es la literatura científica publicada en revistas indexadas en las bases de datos de Literatura Latinoamericana y del Caribe en Ciencias de la Salud (Lilacs), Biblioteca Cochrane (COCHRANE), PubMed (Biblioteca Nacional de Medicina de los Estados Unidos) y Scientific Electronic Library Online (SciELO). **Resultados:** A partir del análisis comparativo de los modelos de algoritmos utilizados para predecir el nacimiento vivo en tratamientos de reproducción humana, es evidente que la elección del modelo impacta directamente el rendimiento predictivo. **Conclusión:** Estos hallazgos sugieren la importancia de seleccionar el modelo adecuado de algoritmo según el contexto clínico. Además, destacan la creciente relevancia de la IA en el mejoramiento de la personalización y la predicción de tratamientos de fertilización *in vitro*, impactando directamente las prácticas clínicas.

Palabras clave: Inteligencia artificial, fertilización *in vitro*, nacidos vivos.

1 INTRODUÇÃO

A infertilidade é definida como uma dificuldade em conceber após 12 meses de tentativas regulares, uma condição que afeta milhões de casais, gerando um impacto tanto físico quanto emocional (Reisi et al., 2024). Existem várias causas de infertilidade que variam em relação aos fatores femininos, masculinos ou ambos, além dos casos de infertilidade sem causa conhecida (ISCA) (De et al., 2023). Nas mulheres, a infertilidade pode ser causada por disfunções ovulatórias, anomalias nas trompas de falópio, endometriose e idade. Nos homens, a influência da infertilidade pode estar na qualidade dos espermatozoides (De et al., 2023; Finotti et al., 2020).

Nas últimas décadas, a fertilização *in vitro* (FIV) se tornou uma das principais tecnologias de reprodução assistida, oferecendo esperança para casais e indivíduos que sofrem com essas dificuldades reprodutivas. Paralelamente, a inteligência artificial (IA) tem ganhado destaque em várias áreas da medicina, revolucionando diagnósticos e tratamentos. A combinação dessas duas áreas promete avanços significativos no sucesso dos tratamentos de fertilidade (Miloski, 2023).

A Comissão Europeia define a IA como sistemas que exibem comportamento inteligente ao analisar o ambiente e tomar ações para alcançar objetivos específicos. O aprendizado da máquina, é um dos pilares da IA, que difere do aprendizado humano, pois a máquina aplica fórmulas a bancos de dados para gerar resultados desejados, repetindo o aprendizado apenas em casos semelhantes. O aprendizado profundo, por sua vez, é um subcampo do aprendizado da máquina que utiliza redes neurais artificiais com múltiplas camadas, atingindo alto desempenho em diversas tarefas (Briganti, 2023).

Sendo assim, diversos algoritmos desenvolvidos com IA, permitem que os computadores aprendam com a experiência, sem a necessidade de programação explícita (Blank et al., 2019). Na reprodução humana assistida as máquinas, são normalmente incubadoras *time lapse*, ou sistemas de imagens estáticas que alimentam os bancos de dados das clínicas e os algoritmos com IA podem ser aplicados nesses dados. Esses algoritmos treinados com dados de FIV podem prever a viabilidade dos óvulos, espermatozoides e embriões, e selecionar os embriões com maior probabilidade de levar a uma gravidez saudável e otimizar as condições do laboratório para o desenvolvimento embrionário (Hariton et al., 2021). Além da identificação dos momentos do desenvolvimento que são mais preditivos de nascimentos vivos, podendo levar a melhorias adicionais na avaliação da viabilidade, ou seja, na identificação das normalidades e potenciais na escolha de um embrião (Mapstone et al., 2024). Com isso,

aumentar as taxas de sucesso na FIV e, conseqüentemente, as chances de nascimentos vivos. Desse modo, este estudo tem como objetivo revisar sistematicamente o papel da IA na FIV e seu impacto na predição de nascidos vivos.

2 METODOLOGIA

O presente trabalho consiste em uma revisão sistemática, sobre o tema inteligência artificial na fertilização *in-vitro* e seu impacto na predição de nascidos vivos, cujo objeto de análise é a produção científica veiculada em periódicos indexados nos bancos de dados da Literatura Latino-americana e do Caribe em Ciências da Saúde (Lilacs), Biblioteca Cochrane (COCHRANE), PubMed (United States National Library of Medicine) e Scientific Eletronic Library Online (SciELO). Esta revisão sistemática foi elaborada seguindo o diagrama do *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) para trabalhos de revisão sistemática, conforme descrito por Moher et al., (2019).

A estratégia de busca bibliográfica foi delineada com base na pergunta investigativa: “A inteligência artificial causa impacto e demonstra eficácia nos procedimentos de fertilização *in vitro*?” que teve como suporte para a sua formulação a estratégia PICOS (*Population, Intervention, Comparison, Outcome and Study type*) (Methley et al., 2014).

A busca de documentos foi realizada nos meses de agosto e setembro de 2024 e, para isso, foram utilizados os seguintes descritores: nascido vivo, fertilização *in vitro*, inteligência artificial, reprodução assistida; e os seus correspondentes em inglês (live birth, *in vitro* fertilization, artificial intelligence, assisted reproduction); combinados por meio dos operadores booleanos “AND” e “OR”. Nas bases de dados Lilacs, COCHRANE e SciELO foram aplicados os filtros artigo e texto disponível. Já na base de dados PubMed foram aplicados os filtros free full text e clinical trial.

Como critérios de inclusão para a seleção dos artigos foram utilizados: publicações nos idiomas português e inglês, artigos publicados nos últimos 5 anos, pesquisas realizadas em humanos e artigos originais.

Os critérios de exclusão abrangem: artigos que não apresentem dados correlacionando a inteligência artificial e a fertilização *in-vitro*.

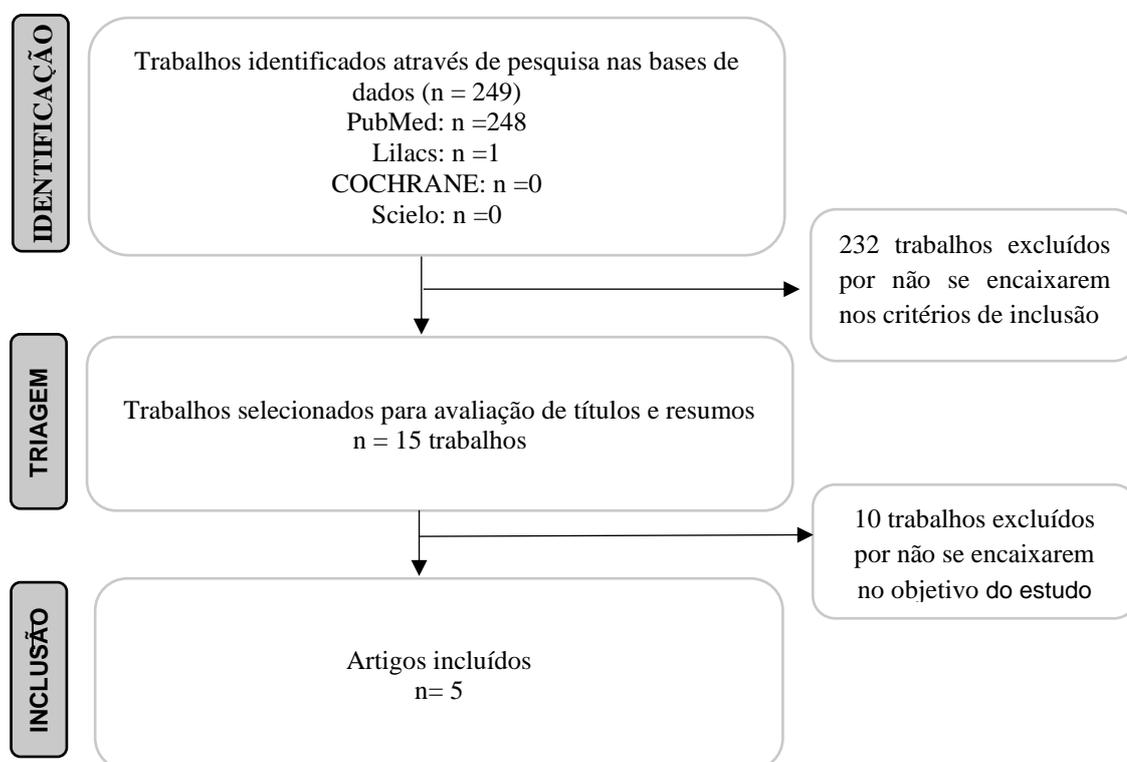
3 RESULTADOS E DISCUSSÃO

O processo de busca permitiu a identificação de 249 estudos, sendo 248

encontrados através da aplicação da estratégia de busca na plataforma de busca PubMed e 1 encontrado no LILACS. Dos 249 estudos identificados, 232 foram excluídos de acordo com os critérios de exclusão. Dessa forma, ficaram 15 artigos para a leitura do título e resumo, e desses, 10 foram excluídos pois não tratavam especificamente da predição de nascidos vivos, sendo assim, por fim, foram incluídos 5 artigos para a elaboração da revisão (Figura 1).

Esses artigos discutem e comparam a eficácia de diferentes modelos de IA e seus algoritmos, apresentando resultados variados em relação à predição de nascidos vivos após técnica de FIV.

Figura1 – Fluxograma de identificação e seleção das publicações de acordo com o PRISMA.



Fonte: Elaborado pelos autores.

Os estudos se baseiam em dados clínicos de pacientes submetidos a FIV. Incluindo informações sobre características demográficas, parâmetros hormonais, fatores relacionados à infertilidade e tratamentos anteriores. Também, os estudos consideram diversas variáveis preditoras, como idade materna, índice de Massa Corporal (IMC), qualidade dos embriões e níveis hormonais.

Foram utilizados diferentes modelos de algoritmos em bases de dados de

diferentes centros de fertilidade para prever nascimentos vivos em tratamentos de FIV. Os principais modelos foram Random Forest, LogitBoost, LightGBM (LGBM), XGBoost e MLCS2, que tiveram seus desempenhos avaliados por métricas como a área sob a curva (AUC) e pontuação F1.

O Random Forest usa várias árvores de decisão para fazer previsões. Ele gera várias amostras aleatórias dos dados e treina uma árvore de decisão para cada uma delas. A previsão final é estabelecida pela maioria das árvores (para classificação) ou pela média das previsões (para regressão). Este método é preciso e resistente a erros, mas pode ser lento e difícil de interpretar.

O LogitBoost aprimora modelos gradualmente, focando em erros anteriores para ajustar novos modelos. Ele é eficaz para classificação e oferece boa precisão em dados complexos. No entanto, pode se ajustar demais a dados ruidosos e é mais complexo de calcular. O LightGBM, criado pela Microsoft, é um algoritmo rápido e eficiente. Ele constrói árvores de decisão mais aprofundadas em áreas com mais falhas, melhorando a precisão. Ele também usa técnicas para reduzir a complexidade e acelerar o treinamento. Apesar de ser eficiente em termos de tempo e memória, pode ser sensível a configurações de parâmetros e precisa de cuidado para evitar ajustes excessivos.

O XGBoost é um algoritmo de boosting conhecido pela sua flexibilidade e eficiência. Ele melhora a precisão das previsões, minimizando erros através de iterações graduais. O XGBoost inclui termos que controlam a complexidade do modelo, prevenindo ajustes excessivos, e suporta treinamento paralelo, aumentando a velocidade. Embora seja preciso, ajustar seus parâmetros corretamente pode ser complicado.

O MLCS2 é específico para predições em contextos clínicos como a FIV. Ele combina vários modelos para melhorar a precisão e usa validação cruzada para garantir que as previsões funcionem bem em diferentes situações. No entanto, pode exigir muitos recursos computacionais e dados de alta qualidade para funcionar bem.

No trabalho de Goyal *et al.* (2020), foi demonstrado que o modelo Random Forest apresentou um melhor desempenho na predição de nascidos vivos em ciclos de FIV, com uma AUC de 84,6% e pontuação F1 de 76,49%, comparado com outros modelos que também foram avaliados, especialmente quando a seleção de características não foi aplicada. Os achados demonstram a eficácia do Random Forest em ciclos de FIV, sendo resistente ao overfitting, o que é importante para estudos com variáveis clínicas, dados que muitos estudos com IA podem enfrentar problemas com generalização ao lidar com dados de alta dimensionalidade (IBM, 2024; Kernbach; Staartjes, 2022).

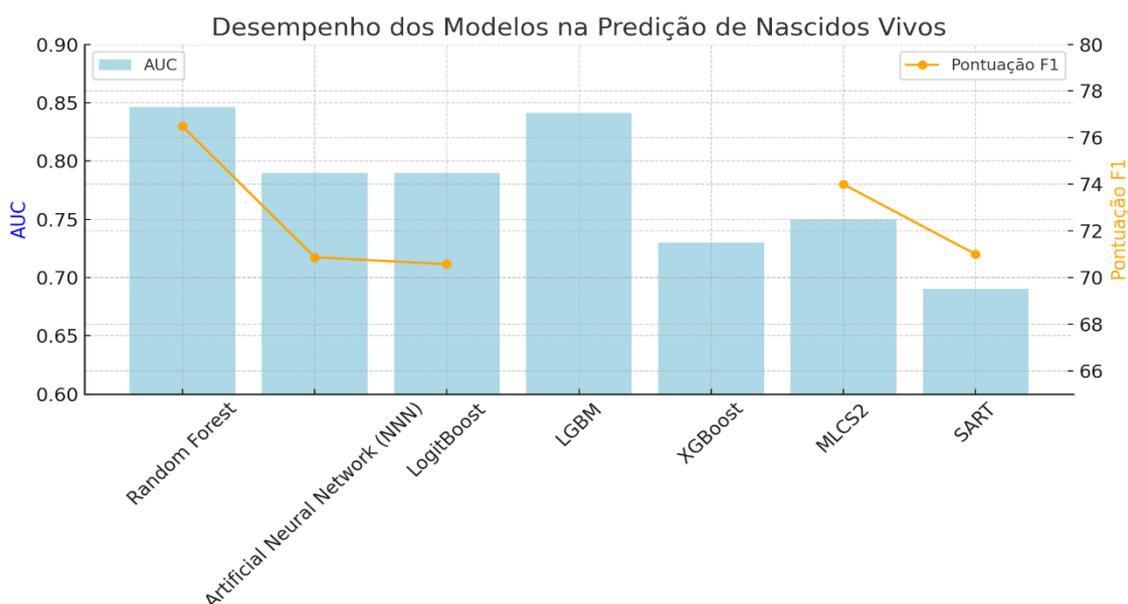
Zhang *et al.* (2022), comparou diferentes modelos de machine learning e ensemble learning no contexto da previsão de nascidos vivos em ciclos de FIV. Dentre os modelos de machine learning, o melhor desempenho foi do modelo Artificial Neural Network (ANN) com AUC de 0.79 e pontuação F1 de 70.87%, já entre os modelos de ensemble learning, o LogitBoost se destacou com uma AUC de 0.79 e pontuação F1 de 70.57%. Com o desempenho de ambos os modelos sendo similar, foi comparado o tempo de treinamento de cada. Com isso, o LogitBoost teve um menor tempo de treinamento, sendo reconhecido como mais adequado.

Tabela 1 - Resultados

Autor e ano de publicação	Modelos com melhor desempenho	AUC	Pontuação F1	Principais variáveis
GOYAL <i>et al.</i> 2020	Random Forest	84.6	76.49	Idade da paciente; Ciclos anteriores; Tipo de infertilidade.
ZHANG <i>et al.</i> 2022	LogitBoost	0.79	70.57	Idade da paciente; Gravidez anterior; Tratamentos anteriores; Infertilidade; Ciclo fresco e congelado.
LIU; CHEN; JI, 2023	LGBM	0.841	NA	Idade da paciente; Índice de Massa Corporal (IMC); Infertilidade; Gravidez anterior; Tipos de embriões.
QIU <i>et al.</i> 2019	XGBoost	0.73	NA	Idade da paciente; Índice de Massa Corporal (IMC); Histórico de Gravidez; Tipo e causa da infertilidade; Nível hormonal.
NGUYEN <i>et al.</i> 2024	MLCS2	0.75	0.74	Idade da paciente; Índice de Massa Corporal (IMC); Infertilidade; Dados hormonais; Qualidade dos embriões.

No estudo de Liu, Chen e Ji (2023), entre as 1.857 mulheres, 851 mulheres acabaram com implantação embrionária e nascido vivo. Foram construídos 8 modelos de algoritmos para prever o nascimento vivo na primeira tentativa completa de fertilização *in vitro* usando fatores preditivos antes e depois do primeiro ciclo. O resultado mostrou que o modelo LGBM alcançou um desempenho melhor antes e após o primeiro ciclo, sendo consistente e preciso em diversas circunstâncias e conjuntos de dados quando comparado com diferentes modelos. Os índices de AUC variaram de 0,841 a 0,861 sinalizando uma alta precisão e estabilidade ao longo das fases de treinamento e validação.

Qiu *et al* (2019), incluíram 7.188 mulheres que passaram por ciclos completos de FIV. Destas, 2.797 (39%) tiveram nascimento vivo confirmado após o tratamento. Fatores preditivos de sucesso em termos de nascimentos vivos foram avaliados, confirmando que variáveis como idade, AMH, IMC, duração da fertilidade, histórico prévio de gravidez e tipo de infertilidade estão associadas com a chance de sucesso. Com isso, algoritmos de machine learning foram aplicados para prever a probabilidade de nascidos vivos, com base nas características pré-tratamento. O modelo XGBoost demonstrou uma melhor performance, com uma AUC de 0,73, em comparação com outros modelos que também foram avaliados.



Por fim, Nguyen *et al.* (2024) comparou a performance dos modelos de aprendizado de máquina MLCS1, MLCS2 em relação ao modelo SART na predição de nascidos vivos

em tratamentos de FIV. O MLCS2 apresentou desempenho superior em comparação ao modelo SART. A pontuação F1 para o MLCS2 foi de 0,74 em comparação a 0,71 para o SART. A AUC foi também significativamente superior para o MLCS2, com uma mediana de 0,75, enquanto o SART obteve 0,69, diferença considerada estatisticamente significativa. Com isso, o modelo MLCS2 teve uma capacidade significativamente maior de identificar pacientes com altas chances de nascimento vivo, os valores superiores reforçam que o modelo proporcionou melhores previsões, alinhadas a taxas de nascimento vivo, sugerindo um avanço em relação aos modelos tradicionais como o SART para a prática clínica de predição na FIV.

Os trabalhos apresentam uma variedade de idades entre as mulheres que buscam tratamento de fertilidade, destacando a complexidade do assunto. A maioria das pacientes são jovens, variando de 18 a 34 anos de idade. Apesar das idades médias oscilarem entre 31 e 33 anos, o número de mulheres com mais de 45 anos é bastante restrito. Além disso, a maior parte dos estudos não disponibiliza dados específicos sobre a quantidade de embriões transferidos, alguns consideram uma variável preditiva, porém não apresentam detalhes sobre a prática clínica.

A maioria dos artigos focou em variáveis demográficas e clínicas gerais, sem detalhar métodos de avaliação morfológica ou de tempo de incubação, tendo ênfase nos fatores clínicos que influenciam o sucesso da gravidez. A maioria dessas análises foi realizada antes do início do ciclo de FIV, o que justifica a ausência de informações sobre o número de embriões transferidos e sua qualidade. Isso ressalta a importância de realizar estudos futuros que integrem esses aspectos.

Os cinco artigos analisados demonstram uma convergência importante na aplicação de algoritmos de aprendizado de máquina para a predição de nascidos vivos na FIV, mostrando que apesar das diferentes abordagens e variáveis incluídas, há uma tendência clara de melhoria nos resultados preditivos com o uso de técnicas avançadas de aprendizado de máquina.

Goyal *et al.* (2020) destaca o desempenho superior do Random Forest sem a necessidade de seleção de recursos, mostrando como um modelo de aprendizado de conjunto pode superar outros em precisão e AUC. Zhang *et al.* (2022) reforça essa visão ao indicar que o LogitBoost, como um modelo de aprendizado de conjunto, que oferece um excelente desempenho com tempo de treinamento significativamente menor, sendo preferido em cenários que exigem rapidez e eficiência.

Para Liu, Chen e Ji (2023), o LGBM se sobressaiu ao prever nascidos vivos tanto antes quanto depois do primeiro ciclo de FIV, sugerindo que a inclusão de fatores preditivos após o primeiro ciclo aumenta a precisão do modelo, algo que também foi observado no artigo de Qiu *et al* (2019) com o XGBoost. Este último, embora similar em eficácia ao Random Forest, teve melhor calibração, destacando sua robustez na discriminação e calibração dos resultados.

Finalmente, Nguyen *et al.* (2024) aponta para a superioridade do modelo MLCS2 sobre modelos tradicionais como o SART, ao mostrar melhores taxas de precisão e recall em múltiplos centros de FIV, reafirmando a relevância de algoritmos mais modernos em grandes bases de dados clínicos.

Essa correlação entre os estudos destaca que, embora diferentes modelos apresentem performances ligeiramente superiores em métricas específicas, o aprendizado de máquina, em suas várias formas, oferece uma alternativa viável e, muitas vezes, superior aos métodos estatísticos tradicionais na predição de nascidos vivos após tratamentos de FIV. Os avanços nesses modelos proporcionam maior precisão, personalização e, conseqüentemente, uma melhor assistência ao paciente, com impacto direto na prática clínica e na otimização de tratamentos de FIV (Pavlovic; Jiang; Hariton, 2024).

Ao longo do estudo, fica evidente que cada abordagem traz suas próprias vantagens e limitações. Modelos como o Random Forest e o XGBoost se destacaram pela sua precisão, sendo capazes de trabalhar com grandes quantidades de dados. No entanto, exigem uma maior capacidade computacional e uma interpretação mais cuidadosa, além disso, existe o risco de overfitting, que pode ocorrer caso não forem ajustados corretamente. Em contrapartida, estratégias como o LogitBoost são mais leves e apresentam desempenho equivalente a métodos mais complexos, contudo, a efetividade pode ser restringida em situações de alta disponibilidade de dados.

Já o LGBM e o MLCS2 se destacam por serem mais adaptáveis ao longo do processo da FIV, porém pedem um conhecimento técnico maior e mais infraestrutura. A combinação dos métodos pode ser uma boa ideia para melhorar a precisão e personalização das previsões, o que ajuda a adaptar os tratamentos para cada situação.

4 CONCLUSÃO

Por fim, esse estudo destacou a eficácia de diversos modelos de algoritmos na predição de nascidos vivos após a FIV, revelando o potencial dessas ferramentas para

aprimorar a tomada de decisão clínica. No entanto, a análise dos artigos demonstra que, embora as técnicas de uso da IA tenham apresentado resultados encorajadores, a variação nos contextos e nos dados utilizados indica que ainda há espaço para otimização e ajustes mais refinados.

Diante desse cenário, é crucial que mais estudos experimentais sejam conduzidos, especialmente aqueles que envolvam dados clínicos de múltiplos centros, com variáveis pré e pós-ciclo de FIV. Assim como descrever os padrões em laboratório que foram utilizados, se óvulos, sêmen e embriões ou apenas o desenvolvimento embrionário.

Esses estudos podem contribuir para a construção de modelos ainda mais robustos e precisos, adaptados a diferentes populações de pacientes e circunstâncias clínicas. É necessário a realização de mais pesquisas comparativas com diferentes algoritmos, como foi feito nos artigos analisados, para poder oferecer uma visão mais completa sobre a aplicação de cada modelo em cenários diversos. O crescimento da base experimental irá permitir validar as descobertas atuais e identificar melhorias que possam beneficiar o tratamento personalizado e o sucesso da FIV, aumentando assim as chances de nascidos vivos.

REFERÊNCIAS

BLANK, C. et al. Prediction of implantation after blastocyst transfer in in vitro fertilization: a machine-learning perspective. **Fertility and sterility**, v. 111, n. 2, p. 318–326, 1 fev. 2019.

BRIGANTI, G. **Intelligence artificielle : une introduction pour les cliniciens. Revue des Maladies Respiratoires**, v. 40, n. 4, p. 308–313, 7 mar. 2023.

DE, L. et al. Revisão integrativa: causas de infertilidade e tratamentos de fertilização. **Brazilian Journal of Health Review**, v. 6, n. 5, p. 25242–25253, 19 out. 2023.

DIMITRIADIS, I. et al. Artificial intelligence in the embryology laboratory: a review. **Reproductive biomedicine online**, v. 44, n. 3, p. 435–448, 1 mar. 2022.

FINOTTI, M. et al. **DIRETORIA DA FEBRASGO**. [s.l: s.n.]. Disponível em: <<https://www.febasgo.org.br/images/pec/anticoncepcao/n84---G---Propedeutica-bsica-da-infertilidade-conjugal.pdf>>.

GALVÃO, TAÍS FREIRE; PEREIRA, M. G. Revisões sistemáticas da literatura: passos para sua elaboração. **Epidemiologia e Serviços de Saúde**, v. 23, n. 1, p. 183–184, 2014.

GOLDBERG, J. M.; FALCONE, T.; MARJAN ATTARAN. In vitro fertilization update. **Cleveland Clinic journal of medicine**, v. 74, n. 5, p. 329–338, 1 maio 2007.

GOYAL, A.; MAHESHWAR KUCHANA; RAO, P. Machine learning predicts live-birth occurrence before in-vitro fertilization treatment. **Scientific reports**, v. 10, n. 1, 1 dez. 2020.

HARITON, E. et al. A machine learning algorithm can optimize the day of trigger to improve in vitro fertilization outcomes. **Fertility and sterility**, v. 116, n. 5, p. 1227–1235, 1 nov. 2021.

IBM. **What is Overfitting?** | IBM. Disponível em: <<https://www.ibm.com/topics/overfitting>>.

INHORN, M. C.; PATRIZIO, P. Infertility around the globe: new thinking on gender, reproductive technologies and global movements in the 21st century. **Human reproduction update**, v. 21, n. 4, p. 411–426, 22 mar. 2015.

KERNBACH, J. M.; STAARTJES, V. E. Foundations of Machine Learning-Based Clinical Prediction Modeling: Part II—Generalization and Overfitting. **Acta neurochirurgica**, p. 15–21, 1 jan. 2022.

LIU, X.; CHEN, Z.; JI, Y. Construction of the machine learning-based live birth prediction models for the first in vitro fertilization pregnant women. **BMC pregnancy and childbirth**, v. 23, n. 1, 27 jun. 2023.

MANSOUR, H. Infertility diagnosis and management. **Beni-Suef University Journal of Basic and Applied Sciences**, v. 12, n. 1, 8 set. 2023.

MAPSTONE, C. et al. Deep learning pipeline reveals key moments in human embryonic development predictive of live birth after in vitro fertilization. **Biology Methods and Protocols**, v. 9, n. 1, 2024.

METHLEY, A. M. et al. PICO, PICOS and SPIDER: a comparison study of specificity and sensitivity in three search tools for qualitative systematic reviews. **BMC health services research**, v. 14, n. 1, 21 nov. 2014.

MILOSKI, B. Opportunities for artificial intelligence in healthcare and in vitro fertilization. **Fertility and sterility**, v. 120, n. 1, p. 3–7, 1 jul. 2023.

MOHER, D. et al. Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. **PLoS medicine**, v. 6, n. 7, p. e1000097–e1000097, 21 jul. 2009.

NGUYEN, E. T. et al. Predicting IVF live birth probabilities using machine learning, center-specific and national registry-based models. **medRxiv (Cold Spring Harbor Laboratory)**, 21 jun. 2024.

PAVLOVIC, Z. J.; JIANG, V. S.; HARITON, E. Current applications of artificial intelligence in assisted reproductive technologies through the perspective of a patient's journey. **Current Opinion in Obstetrics & Gynecology**, v. 36, n. 4, p. 211–217, 1 abr. 2024.

QIU, J. et al. Personalized prediction of live birth prior to the first in vitro fertilization treatment: a machine learning method. **Journal of Translational Medicine**, v. 17, n. 1, 23 set. 2019.

REISI, M. et al. **Relationships between couple collaboration, well-being, and psychological health of infertile couples undergoing assisted reproductive treatment.** *Reproductive Health*, v. 21, n. 1, 16 ago. 2024.

RIEGLER, M. A. et al. Artificial intelligence in the fertility clinic: status, pitfalls and possibilities. **Human reproduction**, v. 36, n. 9, p. 2429–2442, 29 jul. 2021.

SOUZA, K. K. P. C. S. P.; ALVES, O. DE F. A. DE F. AS PRINCIPAIS TÉCNICAS DE REPRODUÇÃO HUMANA ASSISTIDA. **SAÚDE & CIÊNCIA EM AÇÃO**, v. 2, n. 1, p. 26–37, 17 out. 2016.

VERMILYEA, M. et al. Development of an artificial intelligence-based assessment model for prediction of embryo viability using static images captured by optical light microscopy during IVF. **Human Reproduction**, v. 35, n. 4, p. 770–784, abr. 2020.

ZANINOVIC, N.; ELEMENTO, O.; ROSENWAKS, Z. Artificial intelligence: its applications in reproductive medicine and the assisted reproductive technologies. **Fertility and Sterility**, v. 112, n. 1, p. 28–30, jul. 2019.

ZHANG, Y. et al. Live-Birth Prediction of Natural-Cycle In Vitro Fertilization Using 57,558 Linked Cycle Records: A Machine Learning Perspective. **Frontiers in Endocrinology**, v. 13, 22 abr. 2022.

2. PROPOSTA DE SUBMISSÃO

2.1. REVISTA:

Brazilian Journal of Health Review

2.2. REGRAS DE SUBMISSÃO

A abrangência temática da BJHR, em sua essência, abrange todas as áreas do conhecimento descritas pelo CNPq, desde que a pesquisa apresente contribuição para a área da saúde.

A BJHR aceita contribuições escritas em português, inglês ou espanhol.

Seguem as principais diretrizes:

- **1. Condições para Submissão**
 - **Originalidade:** O artigo submetido deve ser original e inédito, não podendo estar em avaliação para publicação em outra revista. Caso o artigo esteja sendo avaliado por outro periódico, essa condição deve ser justificada nos "Comentários ao editor".
 - **Formato de Arquivo:** O arquivo de submissão deve estar em um dos seguintes formatos: Microsoft Word, OpenOffice ou RTF.
 - **Referências:** Quando possível, as URLs das referências citadas devem ser incluídas.
 - **Formatação do Texto:**
 - O texto deve ser escrito com espaçamento de 1,5 linhas, utilizando fonte de 12 pontos.
 - O uso de itálico é preferido em vez de sublinhado, exceto para URLs.
 - Figuras e tabelas devem estar inseridas no corpo do texto, e não no final do documento como anexos.
 - **Estilo e Normas Bibliográficas:** O texto deve seguir os padrões de estilo e os requisitos bibliográficos estabelecidos nas Diretrizes para Autores, disponíveis na página "Sobre a Revista".

- **Avaliação por Pares:** Para submissão em seções que envolvem avaliação pelos pares (ex.: artigos científicos), as diretrizes para assegurar a avaliação cega devem ser seguidas.
- **2. Diretrizes para Autores**
 - **Exclusividade:** A revista aceita apenas artigos originais que não tenham sido publicados em outros periódicos. Artigos apresentados em eventos podem ser submetidos, desde que essa informação seja devidamente informada pelos autores.
 - **Limite de Páginas:** Os artigos devem ter no máximo 20 páginas.
 - **Número de Autores:** O número máximo de autores permitidos por artigo é 8.
 - **Formatação:**
 - Fonte: Times New Roman, tamanho 12, espaçamento entre linhas de 1,5.
 - Figuras e Tabelas: Devem estar no corpo do texto e ser editáveis, com fonte de 10 pontos tanto no conteúdo quanto no título (posicionado acima) e na legenda (posicionada abaixo).
 - **Título:** O título do artigo deve ser apresentado em três idiomas (português, inglês e espanhol) no início do arquivo, com fonte de tamanho 14.
 - **Resumo e Palavras-Chave:** Devem ser incluídos logo abaixo do título, com espaçamento simples.
 - **Anonimato:** O arquivo submetido não deve conter identificação dos autores, assegurando a avaliação cega.