v.5, n.3, 2025

REVISTA CIENTÍFICA RECISATEC
ISSN 2763-8405

REVISÃO DO PAPEL DA INTELIGÊNCIA ARTIFICIAL NAS TÉCNICAS DE REPRODUÇÃO ASSISTIDA

REVIEW OF THE ROLE OF ARTIFICIAL INTELLIGENCE IN ASSISTED REPRODUCTION TECHNIQUES

REVISIÓN DEL PAPEL DE LA INTELIGENCIA ARTIFICIAL EN LAS TÉCNICAS DE REPRODUCCIÓN ASISTIDA

Oberdan Costa[1], Mariana Santos Costa[2], Marcel Frajblat[3]

e53384
https://doi.org/10.70187/recisatec.v5i3.384

PUBLICADO: 5/2025

RESUMO

Durante o processo de avaliação do potencial reprodutivo de um paciente, vários métodos baseados em inteligência artificial (IA) têm sido utilizados para manipular, processar e analisar grandes volumes de dados gerados ao longo das etapas das Técnicas de Reprodução Assistida (TRA) com objetivo de individualizar protocolos e otimizar as chances de gravidez. Eles surgiram como ferramentas objetivas, quantificáveis e não invasivos para análise rápida e precisa, aumentando as chances de sucesso nos tratamentos. O objetivo desta revisão é examinar de forma abrangente a literatura e explorar em ordem cronológica os últimos avanços de IA, especificamente das etapas de TRA, incluindo a estimulação ovariana controlada e as análises de oócitos e de sêmen. Resumimos 19 artigos publicados entre 2021 e 2025, extraídos de dois bancos de dados eletrônicos, usando os seguintes termos: “in vitro fertilization”, “ovarian stimulation”, “trigger”, “oocytes”, “sperm”, “Artificial Intelligence”, “Deep Learning” e “Machine Learning”. A revisão, além de ajudar os pesquisadores a terem uma compreensão mais abrangente de status e tendências futuras de trabalhos de IA nas TRA, permitirá que pesquisadores interdisciplinares proponham técnicas combinadas para conduzir abordagens individualizadas que reduzam impactos socioeconômicos e possivelmente ambientais.

PALAVRAS-CHAVE: Inteligência artificial. Técnicas de reprodução assistida. Estimulação ovariana. Oócitos. Sêmen.

ABSTRACT

During the process of assessing a patient's reproductive potential, several methods based on artificial intelligence (AI) have been used to manipulate, process and analyze large volumes of data generated throughout the stages of Assisted Reproductive Techniques (ART) with the aim of individualizing protocols and optimizing the chances of pregnancy. They have emerged as objective, quantifiable and non-invasive tools for rapid and accurate analysis, increasing the chances of success in treatments. The objective of this review is to comprehensively examine the literature and explore in chronological order the latest advances in AI, specifically in the ART stages, including controlled ovarian stimulation and oocyte and semen analysis. We summarized 19 articles published between 2021 and 2025, extracted from two electronic databases, using the following terms: “in vitro fertilization”, “ovarian stimulation”, “trigger”, “oocytes”, “sperm”, “Artificial Intelligence”, “Deep Learning”, and “Machine Learning”. The review, in addition to helping researchers gain a more comprehensive understanding of the status and future trends of AI work in TRA, will enable interdisciplinary researchers to propose

[1] Universidade Fernando Pessoa, Porto-Portugal.

[2] Biomédica especialista em Reprodução Humana Assistida pelo Instituto Sapientiae -SP, Mestra em Biologia Celular e Molecular pela Universidade Estadual Paulista Júlio de Mesquita Filho UNESP (Campus Rio Claro). Bolsista do programa de iniciação científica da Universidade Ceuma em Microbiologia Ambiental e Ecotoxicologia. Mestrado na área de biologia celular e molecular. Embriologista na área de andrologia e administrativo do laboratório. Doutoranda no Laboratório de Inovação em Reprodução Assistida da Universidade Federal do Rio de Janeiro.

[3] Professor e cientista da Universidade Federal do Rio de Janeiro nas áreas de biotecnologia reprodutiva animal e humana. Coordena o Laboratório de Inovação em Reprodução Assistida (LIRA), responsável pela execução de técnicas como fertilização in vitro, criopreservação de gametas e embriões, produção de modelos animais geneticamente modificados e controle de qualidade de materiais utilizados em reprodução humana assistida. Secretário-Geral do Conselho Internacional de Ciência de Animais de Laboratório (ICLAS). Segundo Secretário da Federação das Sociedades de Biologia Experimental (FeSBE).

combined techniques to conduct individualized approaches that reduce socioeconomic and possibly environmental impacts.

***KEYWORDS**: Artificial intelligence. Assisted reproductive techniques. Ovarian stimulation. Oocytes. Semen.*

RESUMEN
Durante el proceso de evaluación del potencial reproductivo de una paciente, se han utilizado diversos métodos basados en inteligencia artificial (IA) para manipular, procesar y analizar grandes volúmenes de datos generados a lo largo de las etapas de las Técnicas de Reproducción Asistida (TRA) con el objetivo de individualizar los protocolos y optimizar las posibilidades de embarazo. Surgieron como herramientas objetivas, cuantificables y no invasivas para un análisis rápido y preciso, aumentando las posibilidades de éxito de los tratamientos. El objetivo de esta revisión es examinar exhaustivamente la literatura y explorar en orden cronológico los últimos avances en IA, específicamente en las etapas de TRA, incluyendo la estimulación ovárica controlada y el análisis de ovocitos y semen. Se resumieron 19 artículos publicados entre 2021 y 2025, extraídos de dos bases de datos electrónicas, utilizando los siguientes términos: "fertilización in vitro", "estimulación ovárica", "desencadenante", "ovocitos", "espermatozoides", "Inteligencia Artificial", "Aprendizaje Profundo" y "Aprendizaje Automático". La revisión, además de ayudar a los investigadores a obtener una comprensión más completa del estado y las tendencias futuras del trabajo de IA en TRA, permitirá a los investigadores interdisciplinarios proponer técnicas combinadas para llevar a cabo enfoques individualizados que reduzcan los impactos socioeconómicos y posiblemente ambientales.

***PALABRAS CLAVE**: Inteligencia artificial. Técnicas de reproducción asistida. Estimulación ovárica. Ovocitos. Semen.*

INTRODUÇÃO

A crescente taxa de infertilidade entre casais se tornou uma preocupação global de saúde. da Organização Mundial da Saúde[1] apontam que uma em cada seis pessoas da população adulta global, sofre com problemas relacionados à infertilidade. No Brasil, 278 mil casais enfrentam infertilidade, o que equivale a 15% do total de casais em idade reprodutiva.

De acordo com a Resolução nº 2.294/2021, do Conselho Federal de Medicina (CFM)[2], a infertilidade é um problema de saúde com implicações médicas e psicológicas e, por isso, reconhece-se a legitimidade do anseio de superá-la. Essa condição dificulta o planejamento familiar, que é visto como parte integrante do direito à saúde, sendo a constituição da família com filhos, um instrumento de realização das pessoas humanas e da sociedade. As formas mais comuns de apoio às pacientes que procuram Técnicas de Reprodução Assistida (TRA) são a Fertilização *In Vitro* (FIV) e Injeção Intracitoplasmática de Espermatozóides (ICSI). A FIV é tem sido usada para muitos desafios de fertilidade, incluindo infertilidade masculina, endometriose ou infertilidade inexplicada. Em geral, o primeiro passo da FIV é a estimulação ovariana, durante a qual os ovários são estimulados com gonadotrofinas para promover o crescimento folicular com o objetivo de recuperar múltiplos oócitos maduros.

A ICSI tem sido considerado o padrão para o tratamento da infertilidade masculina grave. Essa técnica conjuntamente com IA tem gerado vários benefícios. De acordo com Chow *et al.*[3] destacam que o maior benefício da IA pode vir da seleção de espermatozoides para injeção intracitoplasmática de espermatozoides (ICSI), um processo atualmente realizado pelo embriologista. Nesse sentindo, Zaninovic e Rosenwaket[4] corroboram destacando que a aplicação de aprendizado

de máquina (ML) a imagens de oócitos antes da injeção intracitoplasmática de espermatozoides (ICSI), bem como a avaliação do comportamento do oócito durante a ICSI, pode se tornar crucial para a seleção de oócitos competentes.

TRA representam uma ampliação de possibilidades de tratamentos de casais que enfrentam a infertilidade e desejam ter filhos. Eles envolvem a estimulação ovariana, seleção e junção de oócitos e espermatozoides, bem como a fertilização e desenvolvimento embrionário, além da seleção dos melhores embriões para transferir para o útero da paciente, com o objetivo de alcançar a gravidez. Chen *et al.* e Rezaeiyeh *et al.*[5,6] destacam que esse procedimento é longo, financeiramente oneroso, emocionalmente desgastante e fisicamente exigente para o casal, tudo isso sem qualquer garantia de sucesso na gravidez.

Durante as etapas das TRA, os médicos e embriologistas tomam decisões cruciais para melhorar os resultados de um ciclo e aumentar as taxas de gravidez. Nesse processo de decisões, o tratamento de FIV é uma tarefa complexa, exigem precisão e experiência. Na FIV, a etapa inicial de um ciclo é a estimulação ovariana, onde em geral ocorre a escolha do protocolo e a dosagem e duração das gonadotrofinas usadas para estimular o crescimento de folículos com o objetivo de recuperar múltiplos oócitos maduros. O estudo de Fanton *et al* [7] apontam que a recuperação de um número maior de oócitos maduros aumenta as chances de obter blastocistos cromossomicamente normais (euplóides) de alta qualidade, aumentando a chance cumulativa de nascimento vivo de futuras transferências. No entanto, vale considerar que, além de sua eficácia, a estimulação excessiva também pode levar a complicações como a síndrome de hiperestimulação ovariana, uma condição potencialmente fatal. Por outro lado, a subestimulação pode resultar em um número insuficiente de oócitos em metáfase II (MII), reduzindo assim a taxa de sucesso da FIV[8]. Notavelmente, há um crescente corpo de evidências sugerindo que a estimulação ovariana pode ter impactos adversos na qualidade dos oócitos e embriões, afetando, em última análise, os resultados clínicos[9]. Embora essas experiências sejam valiosas, a abordagem pode ser subjetiva, levando a uma variabilidade nos resultados de clínica para clínica, por conseguinte, emerge uma necessidade urgente de abordagens consistentes e baseadas em dados para aumentar a precisão de decisões importantes nas etapas das TRA, de modo a otimizar as taxas de sucesso.

A integração da IA nas etapas das TRA, além de expandir significativamente a literatura sobre modelos de IA adaptados para os procedimentos, tem revolucionado os laboratórios de FIV ao automatizar processos e melhorar a tomada de decisões. Métodos baseados em IA são ideais para manipular, processar e analisar grandes volumes de dados de textos ou multimodais geradas ao longo de etapas das Técnicas de Reprodução Assistida (TRA), além de fornecer assistência valiosa aos embriologistas na análise e seleção de oócitos, espermatozoides etc., permitindo que pesquisadores interdisciplinares proponham técnicas para conduzir abordagens individualizadas. Abordagens de aprendizado de máquina (ML), incluindo redes neurais artificiais, máquinas de vetores de suporte (SVM), árvores de decisão e florestas aleatórias têm sido usadas para tomada de decisão e resultados clínicos no TRA. Uma ampla gama de tarefas é coberta por esses modelos, entre elas prever resultados de estimulação ovariana[10], otimização da dosagem hormonal[11], segmentação

semântica de imagens de oócitos[12], predição da qualidade do sêmen[13] e segmentação inicial de embriões[14].

Embora as etapas das TRA sejam abrangentes, nossa revisão visa resumir e explorar os últimos avanços de IA, especificamente das etapas de técnicas de reprodução assistida, incluindo estimulação ovariana controlada, análise de oócitos e sêmen. Nesse contexto, nosso estudo aborda questões de pesquisa como: (1) quais são as características dos modelos de IA atualmente usados em cada um dos trabalhos das três etapas-chaves do ciclo FIV? (2) Qual o desempenho dos modelos de IA em cada um dos trabalhos nas três etapas-chaves do ciclo FIV? (3) Quais são as características dos dados usados para treinar esses modelos de IA em cada um dos trabalhos nas três etapas-chaves do ciclo FIV?

METODOLOGIA

Para atingir o objetivo deste estudo investigamos a utilização de IA para a resposta do ovário à estimulação ovariana, análise de oócitos e sêmen. Uma busca abrangente na literatura foi conduzida nas fontes de dados da PubMed e do Google Acadêmico para identificar artigos relevantes. Os termos de busca incluíram *"in vitro fertilization", "ovarian stimulation", "trigger", "oocytes", "sperm", "Artificial Intelligence", "Deep Learning" e "Machine Learning"*. Limitamos nossa busca, incluindo estudos publicados a partir de 2021. A busca inicial rendeu um total de 1406 artigos. Após uma revisão completa dos resultados da busca, 19 artigos foram selecionados com base em sua relevância e aderência aos critérios de pesquisa.

Duas categorias principais de termo compõem os critérios de pesquisa - termos associados à fertilização in vitro (por exemplo, fertilização in vitro, estimulação ovariana, dosagem, gonadotrofina, gatilho de maturação, análise de oócitos e sêmen, qualidade de oócitos e espermatozoides) e termos relacionados à IA (por exemplo, inteligência artificial, rede neural, aprendizado de máquina e aprendizado profundo). Foram excluídos trabalhos que não implantaram métodos de IA ou ML, bem como, estudos que não forneceram detalhes suficientes sobre o método de IA usada ou seu papel específico nas etapas das TRA, incluindo estimulação ovariana controlada, análise de oócitos e sêmen.

Realizou-se a síntese dos dados extraídos dos estudos incluídos por meio de uma abordagem narrativa, com resumo e detalhamento das informações em texto e tabelas. Primeiro, delineamos os metadados dos estudos incluídos, características do estudo e desenho do estudo. Em seguida, resumimos os algoritmos de IA usados, identificando seu objetivo, validação e métricas de avaliação por etapa das TRA. Por fim, detalhamos as especificidades dos dados usados para o desenvolvimento do algoritmo de IA, que abrange aspectos como tamanho da amostra, tipos de dados e número de recursos por etapa das TRA.

RESULTADOS

A Figura 1 ilustra os resultados da busca nas fontes de dados pré-selecionadas, totalizando 1406 registros. Desse total, 58 foram identificados e eliminados como duplicatas. Uma revisão dos títulos e resumos dos 1348 trabalhos subsequentes levou à exclusão de 1278. Entre os 72 restantes,

os textos completos de 8 artigos não estavam disponíveis. Após a triagem do texto completo dos 64 textos completos elegíveis, 45 foram descartados por vários motivos, conforme mostrado na Figura 1. No total, 19 artigos foram selecionados para inclusão nesta revisão, incluindo onze estudos[15, 25] relacionados a estimulação ovariana controlada e termos correlacionados, três artigos[26, 28] que dizem respeito análise de oócitos e termos correlacionados e cinco estudos[13, 29, 32] relacionados a análise de sêmen e termos correlacionados.

Figura 1 - Fluxograma do processo de seleção dos trabalhos. IA: inteligência artificial

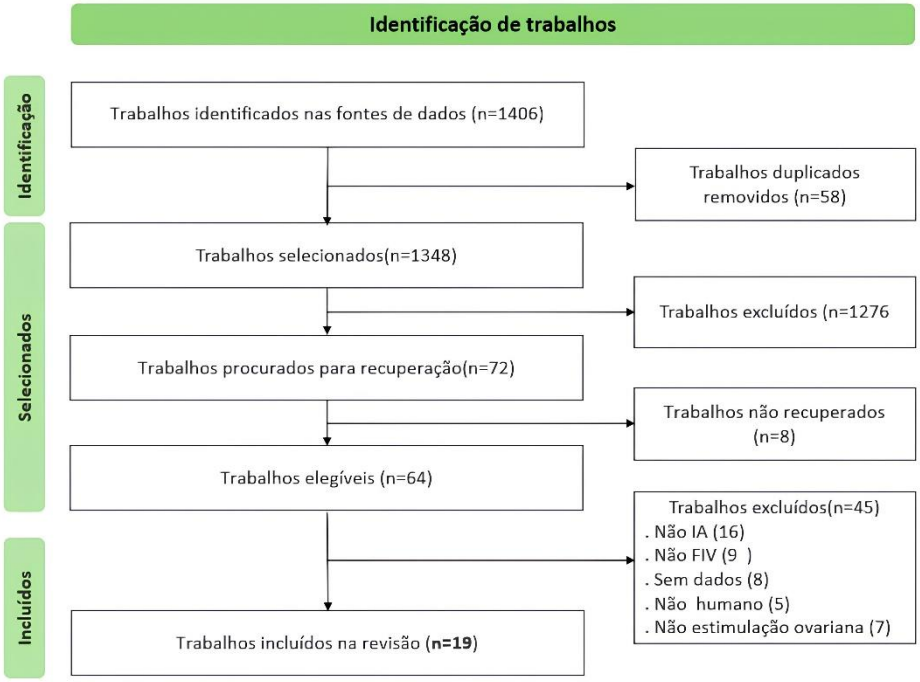

Fonte: Elaborada pelos Autores (2024)

Características dos Estudos Incluídos por Etapa das TRA

Os estudos incluídos foram publicados entre 2021 e 2025 (Tabela 1). Considerando as etapas das TRA, incluindo estimulação ovariana controlada, análise de oócitos e sêmen, o maior número de estudos foi publicado em 2024 (n=6) e 2023 (n=5). Os estudos incluídos são originários de 10 países diferentes (Tabela 1). A China foi o principal país de publicação com mais estudos (n=7), cinco delas com foco nas pesquisas para a Estimulação Ovariana Controlada (EOC). Em relação ao desenho da pesquisa (n=18) estudos foram retrospectivos e somente (n=1) foi prospectivo, com destaque para EOC, que relataram (n=10). Quanto aos locais de coleta de dados, os estudos de local único constituíram a maioria (n=14), a maior parte deles com foco na EOC, enquanto os estudos multissite foram responsáveis por (n=4) e não relatado ((n=1). O número de participantes EOC nos estudos variou de 181-11.286, com uma média de 3.452 (DP 3.504,46). Nos estudos da etapa das TRA análise de Oócitos (AO), somente dois apresentaram número de participantes, este variando de 100-909, com uma média de 504,5 (DP 404,50). Para os estudos da etapa da TRA análise de sêmen, o número de participantes variou de 60-1.272, com uma média de 617,8 (DP 418,14).

Tabela 1 - Características dos Estudos Incluídos por etapas das TRA

Recurso	Valores			Referências do autor		
	EOC[1]	AO[2]	AS[3]	EOC	AO	AS
Característica do estudo						
Ano de publicação, n (%)						
2025			1 (20)			[31]
2024	1 (9,10)	1 (33,34)	4 (80)	[15]	[26]	[13,29,30,32]
2023	4 (36,36)	1 (33,33)		[17,19,23,25]	[28]	
2022	4 (36,36)			[16,20,21,22]		
2021	2 (18,18)	1 (33,33)		[18,24]	[27]	
País de publicação, n (%)						
Japão	1 (9,09)			[15]		
Turquia			2 (40)			[13,31]
USA	2 (18,18)			[16,18]		
França	1 (9,09)			[17]		
Canadá		1 (33,34)			[26]	
China	5(45,46)		2 (40)	[20-24]		[29,32]
Israel	1 (9,09)			[19]		
República Checa		1 (33,33)			[27]	
Irã			1 (20)	[25]		[30]
Polônia	1 (9,09)	1 (33,33)			[28]	
Desenho do estudo						
Desenho da pesquisa, n (%)						
Retrospectivo	10 (90,90)	3 (100)	5 (100)	[15-20,22-25]	[26,27,28]	[13,29-32]
Prospectivo	1 (9,10)			[21]		
Coleta de dados, n (%)						
Site único	9 (81,81)	2 (66,66)	3 (60)	[15,17-24]	[27,28]	[13,31,32]
Multisite	2 (18,19)	1 (33,34)	1 (20)	[16,25]	[26]	[29]
Não relatado			1 (20)			[30]
Número de participantes						
Média (DP)	3.452 (3.504,46)	504,5 (404,50)	617,8 (418,14)	[15-25]	[26,27,28]	[13,29-32]
Faixa	181-11.286	100-909	60-1.272	[15-25]	[26,27,28]	[13,29-32]

EOC[1]: Estimulação Ovariana Controlada, AO[2]: Análise de Oócitos, AS[3]: Análise de Sêmen

Fonte: Elaborada pelos Autores (2025)

Algoritmos de IA e dados usados nos estudos por etapas das TRA

Aqui resumimos os algoritmos de IA e condensamos as características dos dados usados no desenvolvimento de algoritmos de IA por etapas da TRA, incluindo (1) Estimulação Ovariana Controlada (EOC), (2) Análise de Oócitos (AO) e (3) Análise de Sêmen (AS).

Etapa das TRA: Estimulação Ovariana Controlada

Nesta etapa, examinamos e exploramos em ordem cronológica os últimos avanços de IA relacionados a estimulação ovariana controlada e termos correlacionados, incluindo dosagem de gonadotrofina, gatilho de maturação e número de oócitos maduros. Para tal, primeiro, resumimos as características dos algoritmos de IA e em seguida, condensamos as características dos dados usados no desenvolvimento destes algoritmos.

Características dos Algoritmos de IA

Os algoritmos de IA nos estudos analisados concentraram-se principalmente em 6 objetivos principais (Tabela 2). O objetivo mais comum foi prever resposta ovariana (n=3, 27,28%). Isso foi seguido pelos estudos de previsão do número de oócitos recuperados usado em (n=2, 18,18%), otimizar o momento da injeção do gatilho (n=2, 18,18%) e predição da taxa de maturação ovocitária (n=2, 18,18%) %).

Tabela 2 - Características dos algoritmos de IA dos estudos da EOC

Recurso	Estudos n (%)	Referências
Objetivo do algoritmo de IA		
Prever o momento da recuperação do oócito e prescrições	1 (9,09)	[15]
Prever o número de oócitos recuperados	2 (18,18)	[17,25]
Otimizar o momento da injeção do gatilho	2 (18,18)	[16,18]
Predição da taxa de maturação ovocitária	2 (18,18)	[19,21]
Predição da dose inicial de gonadotrofina	1(9,09)	[20]
Prever resposta ovariana	3 (27,28)	[22,23,24]
Algoritmo de IA usado		
Light Gradient Boosting Machine (LGBM)	4 (36,37)	[15,17,18,25]
Regressão linear	1 (9,09)	[16]
eXtreme Gradient Boosting (XGBoost)	1 (9,09)	[19]
Artificial neural network (ANN)	2 (18,18)	[20,22]
Random Forest (RF)	2 (18,18)	(23,24]
Multilayer Perceptron Network (MLP)	1 (9,09)	[21]
Tipo de validação		
Validação cruzada K-fold	7 (63,63)	[15,17,18,21,22,23, 25]
Não	4 (36,37)	[16,19,20,24]
Métricas de avaliação		
Area Under the ROC Curve (AUC)	4(36,37)	[15,19,21,24]
Mean Absolute Error (MAE)	3 (27,27)	[16,17,25]
Não apresentou métrica	1 (9,09)	[18]
Root Mean Equare Error (RMSE)	1 (9,09)	[20]
Precisão (Coeficiente de regressão)	1 (9,09)	[22]
Erro quadrático médio (MSE)	1 (9,09)	[23]

Fonte: Elaborada pelos Autores (2025)

Diferentes algoritmos de IA foram usados nos estudos (Tabela 2). O LGBM foi usado em (n=4, 36,37%), enquanto ANN e RF foram aplicados em (n=2, 18,8%) e (n=2, 18,8%), respectivamente.

No ponto validação dos algoritmos de IA, a abordagem de validação cruzada K-fold dominou, sendo usada em (n=7, 63,63%) dos estudos.

Diferentes métricas de avaliação foram adotadas nos estudos (Tabela 2). A área sob a curva (AUC) e MAE foram as mais proeminentes, usada em (n=4, 36,37%) e (n=3, 27,27%) dos estudos,

respectivamente. Depois disso, todas as demais métricas apresentaram em (n=1, 9,09%) dos estudos.

Características dos dados usados no desenvolvimento de algoritmos de IA

Todos os estudos da etapa TRA EOC (n=11, 100%) especificaram o tamanho da amostra usada como entrada para algoritmos de IA (Tabela 3). Esses tamanhos variaram amplamente, variando entre 181 e 11.286 registros, abrangendo diversas categorias, como mulheres participantes, ciclos ou imagens. Em média, o tamanho da amostra foi de 3.452 (DP 3.504,46). Foi possível notar que, nenhum dos estudos usou conjuntos de dados públicos, todos optaram por conjuntos de dados fechados, ou seja, que não estão disponíveis ao público.

Tabela 3 - Características dos dados usados no desenvolvimento de algoritmos de IA da EOC

Recurso	Valores	Referências
Tamanho da amostra		
Média (DP)	3.452 (3.504,46)	[15-25]
Faixa	181 - 11.286	[15-25]
Fontes de dados, n (%)		
Fechados	11 (100)	[15-25]
Abertos	0 (0)	Nenhum
Tipos de dados, n (%)		
Demográficos	10 (28,57)	[15-18,20-25]
Clínicos	5 (14,28)	[18,22,23,24,25]
Laboratoriais	3 (8,58)	[15,17,21]
Medicamentos	8 (22,85)	[15,16,17,20,21,22,23,24]
Antropométricos	1 (2,86)	[16]
Medidas de imagens	2 (5,72)	[17,18]
Estilo de vida	1 (2,86)	[17]
Outros	5 (14,28)	[17,20,21,23,24]
Número de recursos		
Média (DP)	13,3 (7,48)	[15-18,20-25]
Faixa	4 - 29	[15-18,20-25]

Fonte: Elaborada pelos Autores (2025)

Dos estudos revisados, (n=10, 90,90%) especificaram o número de recursos usados tanto no desenvolvimento quanto na validação do modelo. O número de recursos nesses estudos variou de 4 a 29, com uma média de 13,3 (DP 7,48).

Os dados usados como entrada subjacente nesses algoritmos eram variados. Categorizamos esses dados em oito tipos distintos - demográficos, medicamentos, clínicos, outros, laboratoriais, medidas de imagens, antropométricos e estilo de vida.

Dados demográficos do paciente foram o tipo de dado mais usado, relatado em (n=10, 28,57%) dos estudos. Dados de medicamentos atuais do paciente foram considerados em (n=8, 23,68%), assim como os dados atuais do ciclo de FIV, incluindo detalhes de protocolos de estimulação e oócitos. Dados clínicos, abrangendo histórico cirúrgico, histórico reprodutivo e condições crônicas, foi usado em (n=5, 14,28%) dos estudos. Outros dados, abrangendo Gonadotrofina (Gn), Gn total (GnVol), GnDays (GnDays), dose inicial de Gn (GnVolIni), causa da infertilidade, duração da infertilidade, tipo de infertilidade, níveis hormonais básicos (E2, FSH e LH),

cirurgia pélvica e história de gravidez etc., foram usados em (n=5, 14,28%) dos estudos. Dados laboratoriais, incluindo níveis hormonais basais e dinâmicos, como hormônio folículo estimulante, hormônio luteinizante, estradiol, progesterona e hormônio antimulleriano, foram usados em (n=3, 8,58%) dos estudos. Dados das medidas de imagens de ultrassonografias e microscopias foram observadas em (n=2, 5,72%) dos estudos. Dados antropométricos foram usados (n=1, 2,86%) e dados do estilo de vida foram usados (n=1, 2,86%).

Esses dados fornecem insights valiosos sobre os recursos usados no desenvolvimento de algoritmos de IA em cada estudo correspondente.

Etapa das TRA: Análise de oócitos

Nesta etapa, identificamos e exploramos em ordem cronológica os últimos avanços de IA associados à análise de oócitos e termos correlacionados, incluindo classificação, seleção e segmentação de oócitos. Para tal, resumiremos as características dos algoritmos de IA e condensaremos as características dos dados usados no desenvolvimento de algoritmos de IA.

Características dos Algoritmos de IA dos estudos da Análise de oócitos

Os algoritmos de IA nos estudos analisados concentraram-se principalmente em 2 objetivos principais (Tabela 4). O objetivo mais comum foi Seleção de oócitos usado em 66,66% (n=2, 66,66%). Isso foi seguido pelo estudo Segmentação de oócitos (n=1, 33,34%).

Tabela 4 - Características dos algoritmos de IA dos estudos da análise de oócitos.

Recurso	Estudos n (%)	Referências
Objetivo do algoritmo de IA		
Seleção de oócitos	2 (66,66)	[27,28]
Segmentação de oócitos	1 (33,34)	[26]
Algoritmo de IA usado		
Light Gradient Boosting Machine (LGBM)	1 (33,34)	[26]
Support vector machines (SVM)	1 (33,33)	[27]
Deep Neural Network (DNN)	1 (33,33)	[28]
Tipo de validação		
Validação cruzada K-fold	1 (33,34)	[27]
Não	2 (66,66)	[26,28]
Métricas de avaliação		
Area Under the ROC Curve (AUC)	2(66,66)	[26,27]
Floating-Point Operations (FLOPs)	1 (33,34)	[28]

Fonte: Elaborada pelos Autores (2025)

Diferentes algoritmos de IA foram usados nos estudos (Tabela 4). LGBM, SVM e DNN foram usados totalizando (n=3, 100%) dos estudos. No ponto validação dos algoritmos de IA, a abordagem de 'não' dominou, sendo usada em (n=2, 66,66%) dos estudos.

Diferentes métricas de avaliação foram adotadas nos estudos (Tabela 4). A área sob a curva (AUC) foi o mais proeminente, usada (n=2, 66,66%), seguido pelo FLOPS usada em (n=1, 33,34%) dos estudos.

Características dos dados usados no desenvolvimento de algoritmos de IA da análise de oócitos

Todos os estudos desta etapa-chave (n=3, 100%) especificou o tamanho da amostra usada como entrada para algoritmos de IA (Tabela 5). Esses tamanhos variaram amplamente, variando entre 103 e 11.757 registros, abrangendo a categoria imagens. Em média, o tamanho da amostra foi de 4.208,66 (DP 5.344,33). Foi possível notar que, nenhum dos estudos usou conjuntos de dados públicos, todos optaram por conjuntos de dados fechados, ou seja, que não estão disponíveis ao público.

Tabela 5 - Características dos dados usados no desenvolvimento de algoritmos de IA da análise de oócitos

Recurso	Valores	Referências
Tamanho da amostra		
Média (DP)	4.208,66(5.344,33)	[26,27,28]
Faixa	103 - 11.757	[26,27,28]
Fontes de dados, n (%)		
Fechados	3 (100)	[26,27,28]
Abertos	0 (0)	Nenhum
Tipos de dados, n (%)		
Demográficos	3 (50)	[26,27,28]
Medidas de imagens	3 (50)	[26,27,28]
Número de recursos		
Média (DP)	16,33 (4,49)	[26,27,28]
Faixa	14 - 24	[26,27,28]

Fonte: Elaborada pelos Autores (2025)

Os dados usados como entrada subjacente nesses algoritmos eram variados. Categorizamos esses dados em dois tipos distintos - demográficos e medidas de imagens.

Dados demográficos do paciente usado, relatado em (n=3, 50%) dos estudos. Dados das medidas de imagens de ultrassonografias e microscopias foram observadas em (n=3, 50%) dos estudos.

Dos estudos revisados, (n=3, 100%) especificaram o número de recursos usados tanto no desenvolvimento quanto na validação do modelo. O número de recursos nesses estudos variou de 14 a 24, com uma média de 16 (DP 4,49).

Etapa das TRA: Análise de Sêmen

Nesta etapa, identificamos e exploramos em ordem cronológica os últimos avanços de IA associados à análise de sêmen e termos correlacionados, incluindo prever a qualidade do sêmen, segmentação de espermatozoides e previsão de parâmetros de análise do sêmen. Para tal, resumiremos as características dos algoritmos de IA e condensaremos as características dos dados usados no desenvolvimento de algoritmos de IA.

Características dos Algoritmos de IA dos estudos da análise de sêmen

Os algoritmos de IA nos estudos analisados concentraram-se principalmente em 3 objetivos principais (Tabela 6). O objetivo mais comum foi prever a qualidade do sêmen usado em 60% (n=3). Isso foi seguido pelos estudos Segmentação de espermatozoides e previsão de parâmetros de análise do sêmen cada um com 20% (n=1), respectivamente.

Tabela 6 - Características dos algoritmos de IA dos estudos da análise de Sêmen

Recurso	Estudos n (%)	Referências
Objetivo do algoritmo de IA		
Prever a qualidade do sêmen	3 (60)	[13,30,32]
Segmentação de espermatozoides	1 (20)	[29]
Previsão de parâmetros de análise do sêmen	1 (20)	[31]
Algoritmo de IA usado		
Extra Trees Classifier (ETC)	1 (20)	[13]
BlendMask	1 (20)	[29]
Random Forest (RF)	1 (20)	[30]
VGG-16	1 (20)	[31]
YOLO v5	1 (20)	[32]
Tipo de validação		
Validação cruzada K-fold	1 (20)	[30]
Não	4 (80)	[13,29,31,32]
Métricas de avaliação		
Area Under the ROC Curve (AUC)	3(60)	[13,30,31]
Multi-object tracking accuracy (MOTA)	1 (20)	[29]
Não	1 (20)	[32]

Fonte: Elaborada pelos Autores (2025)

Diferentes algoritmos de IA foram usados nos estudos (Tabela 6). ETC, BlendMask, RF, VGG-16 e YOLO v5 foram usados cada um com (n=1, 20%) dos estudos, respectivamente. No ponto validação dos algoritmos de IA, a abordagem de 'não' dominou, sendo usada em (n=4, 80%) dos estudos.

Diferentes métricas de avaliação foram adotadas nos estudos (Tabela 6). A área sob a curva (AUC) foi o mais proeminente, usada (n=3, 60%), seguido pelo MOTA e 'Não' usados em (n=1, 20%) de cada um dos estudos, respectivamente.

Características dos dados usados no desenvolvimento de algoritmos de IA da análise de sêmen

Todos os estudos desta etapa da TRA (n=5, 100%) especificou o tamanho da amostra usada como entrada para algoritmos de IA (Tabela 7). Esses tamanhos variaram amplamente, variando entre 249 e 7.353 registros, abrangendo a categoria imagens. Em média, o tamanho da amostra foi de 2.041,40 (DP 2.676,10). Foi possível notar que, nenhum dos estudos usou conjuntos de dados públicos, todos optaram por conjuntos de dados fechados, ou seja, que não estão disponíveis ao público.

Tabela 7 - Características dos dados usados no desenvolvimento de algoritmos de IA da análise de sêmen

Recurso	Valores	Referências
Tamanho da amostra		
Média (DP)	2.041,40(2.676,10)	[13,29,30,31,32]
Faixa	249 - 7353	[13,29,30,31,32]
Fontes de dados, n (%)		
Fechados	5 (100)	[13,29,30,31,32]
Abertos	0 (0)	Nenhum
Tipos de dados, n (%)		
Demográficos	2 (18,18)	[30,31]
Estilo de vida	1 (9,10)	[13]
Medidas de imagens	2 (18,18)	[29, 32]
Outros	2 (18,18)	[13,31]
Medicamentos	2 (18,18)	[30,31]
Clínicos	2 (18,18)	[30,31]
Número de recursos		
Média (DP)	12 (2,94)	[13,29,31]
Faixa	9 - 16	[13,29,31]

Fonte: Elaborada pelos Autores (2025)

Os dados usados como entrada subjacente nesses algoritmos eram variados. Categorizamos esses dados em dois tipos distintos - demográficos, estilo de vida, medidas de imagens, outros, Medicamentos e Clínicos.

Dados demográficos do paciente, medidas de imagens, outros, medicamentos e clínicos usados, relatam em (n=2, 18,18%) em cada um dos estudos, respectivamente. Dados do estilo de vida foi observado em (n=1, 9,10%) dos estudos.

Dos estudos revisados (n=3, 60%) dos estudos especificaram o número de recursos usados tanto no desenvolvimento quanto na validação do modelo. O número de recursos nesses estudos variou de 9 a 16, com uma média de 12 (DP 2,94).

CONSIDERAÇÕES

Médicos e embriologistas enfrentam tarefas desafiadoras nas etapas das TRA. Algoritmos de IA vem sendo desenvolvidos para auxiliar à tomada de decisão clínica com o objetivo de melhorar os resultados dos pacientes e a eficiência da clínica, e por conseguinte aumento nas taxas de sucesso de nascidos vivos.

Nesta revisão, 19 estudos foram avaliados e (n=18, 94,73%) deles tiveram indicadores de desempenhos na avaliação. Os resultados dos estudos apresentados nas Tabelas 2, 4 e 6 mostram avanços significativos no uso de algoritmos de inteligência artificial (IA) no auxílio à tomada de decisão clínica e laboratorial em três etapas das TRA, incluindo estimulação ovariana controlada e análise de oócitos e de sêmen. Apesar dos avanços tecnológicos com uso de IA nas TRA, ainda há uma prática em basear as decisões predominantemente na experiência clínica e laboratorial individual.

Recursos dos modelos de IA que usam características da etapa TRA - estimulação ovariana controlada para prever resultados em ciclos de fertilização in vitro foram examinados na literatura. Notavelmente, o objetivo mais comum foi prever resposta ovariana (n=3, 27,28%). Isso foi seguido pelos estudos de previsão do número de oócitos recuperados usado em (n=2, 18,18%), otimizar o momento da injeção do gatilho (n=2, 18,18%) e predição da taxa de maturação ovocitária (n=2, 18,18%) %).

Diferentes algoritmos de IA foram usados nos estudos (Tabela 2). O LGBM foi usado em (n=4, 36,37%), enquanto ANN e RF foram aplicados em (n=2, 18,18%) e (n=2, 18,18%), respectivamente. No ponto validação dos algoritmos de IA, a abordagem de validação cruzada K-fold dominou, sendo usada em (n=7, 63,63%) dos estudos. Diferentes métricas de avaliação foram adotadas nos estudos (Tabela 2). A área sob a curva (AUC) e MAE foram as mais proeminentes, usada em (n=4, 36,37%) e (n=3, 27,27%) dos estudos, respectivamente. Como exemplo de estudo desta etapa das TRA destacamos o trabalho [23]. Eles previram com sucesso as respostas ovarianas à estimulação ovariana controlada com base em modelos de regressão aleatória da floresta. O modelo de regressão foi capaz de atingir coeficientes de correlação entre os valores observados e previstos variaram de 0,86 ± 0,02 a 0,72 ± 0,05 nos conjuntos de dados de teste.

Em se tratando da análise do oócito, essa, é vital como um precursor para melhorar os resultados do desempenho da reprodução assistida. A qualidade do oócito, por exemplo, pode ser definida como a saúde geral, enquanto a competência se refere à capacidade de ser fertilizado e se desenvolver em um embrião saudável. Nesse sentido, modelos de análises de dados orientados por IA, têm sido fundamentais na aplicação dos métodos de avaliação que sejam mais objetivos, precisos, quantificáveis na prática clínica. Alguns recursos dos modelos de IA que usam características de etapa das TRA para avaliação da qualidade de oócitos têm sido promissores, conforme resultados examinados na literatura. Especificamente, o objetivo do algoritmo de IA mais comum foi a seleção de oócitos usado em (n=2, 66,66%). Isso foi seguido pelo estudo Segmentação de oócitos 33,34% (n=1). Diferentes algoritmos de IA foram usados nos estudos (Tabela 4). LGBM, SVM e DNN foram usados totalizando (n=3, 100%) dos estudos. No ponto validação dos algoritmos de IA, a abordagem de 'não' dominou, sendo usada em 66,66% (n=2) dos estudos. Diferentes métricas de avaliação foram adotadas nos estudos (Tabela 4). A área sob a curva (AUC) foi o mais proeminente, usada 66,66% (n=2), seguido pelo FLOPS usada em 33,34% (n=1) dos estudos. Como exemplo de estudo na etapa das TRA análise de oócitos destacamos o trabalho [28], que para fins de determinação da classe ocitária, aplicaram duas estruturas baseadas em redes neurais profundas. O DeepLabV3Plus foi responsável pela análise das imagens de oócitos para extrair regiões específicas das imagens de oócitos. Como resultado, A*cc* ao nível de 0,964 foi obtido ao nível do conjunto de validação e 0,957 ao nível do conjunto de teste. Isso indica um bom resultado do modelo.

No tocante a etapa das TRA análise de sêmen, detectar e analisar diferentes partes dos espermatozoides humanos, avaliando parâmetros como concentração, motilidade e morfologia são tarefas desafiadoras para os andrologistas e embriologistas. Vários modelos baseados em IA e ML estão sendo continuamente treinados usando características morfológicas de acordo com as diretrizes da OMS para classificar os espermatozoides como normais ou anormais. Características

encontradas em modelos de IA na análise de sêmen em imagens têm sido promissoras, conforme resultados examinados na literatura. Os algoritmos de IA nos estudos analisados concentraram-se principalmente em 3 objetivos principais (Tabela 6). O objetivo mais comum foi prever a qualidade do sêmen usado em (n=3, 60%). Isso foi seguido pelos estudos Segmentação de espermatozoides e previsão de parâmetros de análise do sêmen cada um com (n=1, 20%), respectivamente.

Diferentes algoritmos de IA foram usados nos estudos (Tabela 6). ETC, BlendMask, RF, VGG-16 e YOLO v5 foram usados cada um com (n=1, 20%) dos estudos, respectivamente. No ponto validação dos algoritmos de IA, a abordagem de 'não' dominou, sendo usada em (n=4, 80%) dos estudos. Diferentes métricas de avaliação foram adotadas nos estudos (Tabela 6). A área sob a curva (AUC) foi o mais proeminente, usada (n=3, 60%), seguido pelo Mota e 'Não' usados em (n=1, 20%) de cada um dos estudos, respectivamente. Como exemplo de pesquisa destacamos o trabalho [31]. Eles avaliaram a eficácia dos algoritmos de aprendizado profundo orientados por inteligência artificial (IA) na previsão de parâmetros de análise de sêmen com base em imagens de ultrassonografia testicular. Com base nos resultados da análise do sêmen, eles categorizaram os pacientes em grupos de acordo com a concentração espermática, motilidade progressiva e morfologia. Os resultados apontam que valores da área sob a curva (AUC) para a classificação da concentração espermática (oligospermia versus normal), motilidade progressiva (astenozoospermia versus normal) e morfologia (teratozoospermia versus normal) foram 0,76, 0,89 e 0,86, respectivamente. Eles previram com sucesso os parâmetros de análise de sêmen usando dados derivados de imagens de ultrassonografia testicular por meio de algoritmos de aprendizado profundo, o que representa uma aplicação inovadora de inteligência artificial.

A IA tem o potencial chave para aumentar as chances de sucesso dos resultados de tratamentos na reprodução humana assistida, ampliando possibilidades de tratamentos para os casais inférteis. Os resultados desde estudo sugerem que a IA pode auxiliar com segurança etapas das TRA, especificamente nas etapas da estimulação ovariana controlada, análise de oócitos e sêmen, melhorando os resultados da paciente e as taxas de sucesso da clínica. Esta revisão, além de ajudar os pesquisadores a terem uma compreensão mais abrangente do estado da arte da IA no campo da reprodução assistida e tendências, permitirá que projetos interdisciplinares proponham técnicas combinadas para conduzir abordagens individualizadas que otimizem os resultados clínicos e ampliem o acesso a tratamentos de reprodução assistida de forma mais eficiente e personalizada.

Embora diante de todos esses avanços na reprodução assistida, há necessidade de estudos futuros, que envolvam a aplicabilidade da combinação IA e Time-Lapse na avaliação embrionária com o objetivo reduzir controvérsias em torno do uso de incubadoras de monitoramento contínuo de embriões.

Financiamento

Esta pesquisa não recebeu nenhuma bolsa específica de agências de financiamento dos setores público, comercial ou sem fins lucrativos.

Conflitos de interesse

Os autores declaram não haver conflito de interesses.

REFERÊNCIAS

1. Organização Mundial Da Saúde. Infertily prevalence estimates: 1990-1921 [Internet]. Geneva: WHO; 2023. [cited 2025 Feb 15]. Available from: https://www.who.int/publications/i/item/978920068315.

2. Conselho Federal De Medicina (CFM). Resolução CFM nº 2.294, de 15 de junho de 2021. Adota as normas éticas para a utilização das técnicas de reprodução assistida – sempre em defesa do aperfeiçoamento das práticas e da observância aos princípios éticos e bioéticos que ajudam a trazer maior segurança e eficácia a tratamentos e procedimentos médicos, tornando-se o dispositivo deontológico a ser seguido pelos médicos brasileiros e revogando a Resolução CFM nº 2.168, publicada no D.O.U. de 10 de novembro de 2017, Seção I, p. 73. Diário Oficial da União [Internet]. Brasília, p. 60, 15 jun 2021. [cited 2025 Feb 16]. Available from: https://bit.ly/3XHKyf1.

3. Chow DJX, Wijesinghe P, Dholakia K, Dunning KR. Does artificial intelligence have a role in the IVF clinic? Reproduction and Fertility [Internet]. 2021 Sep 15;2(3):C29-34. [cited 2025 Feb 16]. Available from: https://raf.bioscientifica.com/view/journals/raf/2/3/RAF-21-0043.xml?main%20body=pdf-62708. doi: 10.1530/RAF-21-0043. PMID: 35118395; PMCID: PMC8801019.

4. Zaninovic N, Rosenwaks Z. Artificial intelligence in human in vitro fertilization and embryology. Fertility and Sterility [Internet]. 2020 Nov 1;114(5):914-20. doi: 10.1016/j.fertnstert.2020.09.157. PMID: 33160513.

5. Chen H, Li J, Cai S, Zeng S, Yin C, Kuang W, et al. Impact of body mass index (BMI) on the success rate of fresh embryo transfer in women undergoing first in vitro fertilization/intracytoplasmic sperm injection (IVF/ICSI) treatment. International Journal of Obesity [Internet]. 2021 Oct 9;46(1):202-10. [cited 2025 Feb 16]. Available from: https://www.nature.com/articles/s41366-021-00978-0. doi: 10.1038/s41366-021-00978-0.

6. Rezaeiyeh RD, Mehrara A, Ali M, Fallahi J, Sedighe F. Impact of Various Parameters as Predictors of The Success Rate of In Vitro Fertilization. DOAJ (DOAJ: Directory of Open Access Journals). 2022 Apr 1;16(2):76-84. [cited 2025 Feb 16]. Available from: https://doi.org/10.22074/ijfs.2021.531672.1134.

7. Fanton M, Nutting V, Solano F, Maeder-York P, Hariton E, Barash O, et al. An interpretable machine learning model for predicting the optimal day of trigger during ovarian stimulation. Fertility and Sterility [Internet]. 2022 Jul 1;118(1):101-8. [cited 2025 Feb 16]. Available from: https://www.fertstert.org/article/S0015-0282(22)00244-8/fulltext. doi:10.1016/j.fertnstert.2022.04.003.

8. Datta AK. Maheshwari A, Felix N, Campbell S, Nargund G. Mild versus conventional ovarian stimulation for IVF in poor, normal and hyper-responders: a systematic review and meta-analysis. Hum Reprod Update [Internet]. 2021 Feb 19;27(2):229-253. [cited 2025 Feb 16]. Available from: https://academic.oup.com/humupd/article/27/2/229/5955862. doi: 10.1093/humupd/dmaa035. PMID: 33146690; PMCID: PMC7902993.

9. Bosch E, Labarta E, Kolibianakis E, Rosen M, Meldrum D. Regimen of ovarian stimulation affects oocyte and therefore embryo quality. Fertility and Sterility. 2016 Mar;105(3):560-70. [cited 2025 Feb 20]. Available from: https://www.fertstert.org/article/S0015-0282(16)00063-7/fulltext. doi: 10.1016/j.fertnstert.2016.01.022. PMID: 26826273.

10. Rawan AlSaad, Alaa Abd-alrazaq, Fadi Choucair, Ahmed A, Aziz S, Sheikh J. Harnessing Artificial Intelligence to Predict Ovarian Stimulation Outcomes in In Vitro Fertilization: Scoping Review. Journal of Medical Internet Research [Internet]. 2024 Jul 5;26:e53396-6. [cited 2025 Feb 20]. Available from: https://www.jmir.org/2024/1/e53396. doi: 10.2196/53396.

11.Choo CW, Kim JH. A prospective cohort study to develop a treatment algorithm for controlled ovarian stimulation to select a starting dose of recombinant follicle stimulating hormone based on patient characteristics and ovarian response (fame study). Fertil Steril [Internet]. 2021 116(3):e196-e197, 2021. [cited 2025 Feb 20]. Available from: https://www.fertstert.org/article/S0015-0282(21)01137-7/fulltext. doi: 10.1016/j.fertnstert.2021.07.538.

12.Targosz A, Przystałka P, Wiaderkiewicz R, Mrugacz G. Semantic segmentation of human oocyte images using deep neural networks. BioMedical Engineering OnLine [Internet]. 2021 Apr 23;20(1). [cited 2025 Feb 20]. Available from: https://biomedical-engineering-online.biomedcentral.com/articles/10.1186/s12938-021-00864-w. doi: 10.1186/s12938-021-00864-w PMID: 33892725; PMCID: PMC8066497.

13.Aykaç A, Kaya C, Çelik Ö., Aydin ME, Sungur M. A predição da qualidade do sêmen com base em comportamentos de estilo de vida por modelos baseados em aprendizado de máquina. Reproductive Biology and Endocrinology. [Internet]. 2024 2024 Aug 29;22(1). [cited 2025 Feb 20]. Available from: https://rbej.biomedcentral.com/articles/10.1186/s12958-024-01268-w. doi: 10.1186/s12958-024-01268-w.

14.Zhao M, Xu M, Li H, Alqawasmeh O, Chung JPW, Li TC, et al. Application of convolutional neural network on early human embryo segmentation during in vitro fertilization. Journal of Cellular and Molecular Medicine [Internet]. 2021 Mar 1;25(5):2633-44. [cited 2025 Feb 20]. Available from: https://pubmed.ncbi.nlm.nih.gov/33486848/. doi: 10.1111/jcmm.16288. Epub 2021 Jan 24. PMID: 33486848; PMCID: PMC7933952.

15.Asada Y, Shinohara T, Yonezawa S, Kinugawa T, Asano E, Kojima M, et al. Development of an AI-based support system for controlled ovarian stimulation. Reproductive Medicine and Biology [Internet]. 2024 Jan;23(1). [cited 2025 Feb 20]. Available from: https://pmc.ncbi.nlm.nih.gov/articles/PMC11366684/. doi: 10.1002/rmb2.12603. PMID: 39224211; PMCID: PMC11366684.

16.Fanton M, Nutting V, Solano F, Maeder-York P, Hariton E, Barash O, Weckstein L, Sakkas D, Copperman AB, Loewke K. An interpretable machine learning model to predict optimal trigger day during ovarian stimulation. Fertil Steril [Internet]. 2022;118(1):101-108. [cited 2025 Feb 20]. Available from: https://linkinghub.elsevier.com/retrieve/pii/S0015-0282(22)00244-8.S0015-0282(22)00244-8. doi: 10.1016/j.fertnstert.2022.04.003.

17.Ferrand T, Boulant J, He C, Jérôme Chambost, Jacques C, Pena CA, et al. Predicting the number of oocytes retrieved from controlled ovarian hyperstimulation with machine learning. Human Reproduction [Internet]. 2023 Aug 15;38(10):1918-26. [cited 2025 Feb 20]. Available from: https://pmc.ncbi.nlm.nih.gov/articles/PMC10546073/. doi: 10.1093/humrep/dead163. PMID: 37581894; PMCID: PMC10546073.

18.Hariton E, Chi EA, Chi G, Morris JR, Braatz J, Rajpurkar P, et al. A machine learning algorithm can optimize the day of trigger to improve in vitro fertilization outcomes. Fertility and Sterility [Internet]. 2021 Nov;116(5):1227-35. [cited 2025 Feb 20]. Available from: https://pubmed.ncbi.nlm.nih.gov/34256948/. doi: 10.1016/j.fertnstert.2021.06.018.

19.Houri O, Gil Y, Danieli-Gruber S, Shufaro Y, Sapir O, Hochberg A, et al. Prediction of oocyte maturation rate in the GnRH antagonist flexible IVF protocol using a novel machine learning algorithm - A retrospective study. European journal of obstetrics, gynecology, and reproductive biology [Internet]. 2023 May;284:100-4. [cited 2025 Feb 20]. Available from: https://pubmed.ncbi.nlm.nih.gov/36965213/. doi: 10.1016/j.ejogrb.2023.03.022. Epub 2023 Mar 21. PMID: 36965213.

20.Hua L, Zhe Y, Jing Y, Shen Fujin, Jiao C, Liu L. Prediction model of gonadotropin starting dose and its clinical application in controlled ovarian stimulation. BMC Pregnancy and Childbirth [Internet]. 2022 Nov 4;22(1). [cited 2025 Feb 20]. Available from: https://pubmed.ncbi.nlm.nih.gov/36333671/. doi: 10.1186/s12884-022-05152-6. PMID: 36333671; PMCID: PMC9635211.

21.Liang X, Liang J, Zeng F, Yang L, Li Y, Cai K, et al. Evaluation of oocyte maturity using artificial intelligence quantification of follicle volume biomarker by three-dimensional ultrasound. Reproductive Biomedicine Online [Internet]. 2022 Dec 1;45(6):1197-206. [cited 2025 Feb 20]. Available from: https://pubmed.ncbi.nlm.nih.gov/36075848/. doi: 10.1016/j.rbmo.2022.07.012. Epub 2022 Jul 28. PMID: 36075848.

22.Liu L, Shen F, Liang H, Yang Z, Yang J, Chen J. Machine Learning-Based Modeling of Ovarian Response and the Quantitative Evaluation of Comprehensive Impact Features. Diagnostics [Internet]. 2022 Feb 14;12(2):492. [cited 2025 Feb 21]. Available from: https://pubmed.ncbi.nlm.nih.gov/35204580/. doi: 10.3390/diagnostics12020492. PMID: 35204580; PMCID: PMC8871024.

23.Wei J, Xiong D, Zhang Y, Zeng J, Liu W, Ye F. Predicting ovarian responses to the controlled ovarian hyperstimulation in elderly infertile women using clinical measurements and random forest regression. European journal of obstetrics, gynecology, and reproductive biology [Internet]. 2023 Sep;288:153-9. [cited 2025 Feb 21]. Available from: https://pubmed.ncbi.nlm.nih.gov/37544248/. doi: 10.1016/j.ejogrb.2023.07.012. Epub 2023 Jul 24. PMID: 37544248.

24.Yan S, Jin W, Ding J, Yin T, Zhang Y, Yang J. Machine-intelligence for developing a potent signature to predict ovarian response to tailor assisted reproduction technology. Aging [Internet]. 2021;13(13):17137–54. [cited 2025 Feb 21]. Available from: https://pubmed.ncbi.nlm.nih.gov/33999860/. doi: 10.18632/aging.203032. Epub 2021 May 17. PMID: 33999860; PMCID: PMC831246.

25.Krystian Zieliński, Pukszta S, Mickiewicz M, Kotlarz M, Piotr Wygocki, Marcin Zieleń, et al. Personalized prediction of the secondary oocytes number after ovarian stimulation: A machine learning model based on clinical and genetic data. PLoS Computational Biology [Internet]. 2023 Apr 27;19(4):e1011020–0. [cited 2025 Feb 20]. Available from: https://journals.plos.org/ploscompbiol/article?id=10.1371/journal.pcbi.1011020. doi: 10.1371/journal.pcbi.1011020. PMID: 37104276; PMCID: PMC10138216.

26.Fjeldstad J, Qi W, Siddique N, Mercuri N, Nayot D, Krivoi A. Segmentation of mature human oocytes provides interpretable and improved blastocyst outcome predictions by a machine learning model. Scientific Reports [Internet]. 2024 May 8;14(1):10569. [cited 2025 Feb 20]. Available from: https://www.nature.com/articles/s41598-024-60901-1#Abs1. doi: 10.1038/s41598-024-60901-1. PMID: 38719918; PMCID: PMC11078996.

27.Baručić D, Kybic J, Teplá O, Topurko Z, Kratochvílová I. Automatic evaluation of human oocyte developmental potential from microscopy images. In: Proceedings of the 17th international symposium on medical information processing and analysis. 2021;12088:403-9.

28.Targosz A, Myszor D, Mrugacz G. Human oocytes image classification method based on deep neural networks. BioMedical Engineering OnLine [Internet]. 2023 Sep 21;22:92. [cited 2025 Feb 20]. Available from: https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10512614/. doi: 10.1186/s12938-023-01153-4. PMID: 37735409; PMCID: PMC10512614.

29.Yang H, Ma M, Chen X, Chen G, Shen Y, Zhao L, et al. Multidimensional Morphological Analysis of Live Sperm Based on Multiple-target Tracking. Computational and Structural Biotechnology Journal [Internet]. 2024 Mar 1:176-184. ISSN 2001 0370. [cited 2025 Feb 20]. Available from: https://www.sciencedirect.com/science/article/pii/S2001037024000497. doi: 10.1016/j.csbj.2024.02.025.

30.Mehrjerd A, Dehghani T, Jajroudi M, Eslami S, Rezaei H, Ghaebi NK. Ensemble machine learning models for sperm quality evaluation concerning success rate of clinical pregnancy in assisted reproductive techniques. Scientific Reports [Internet]. 2024 Oct 16;14(1). [cited 2025 Feb 21]. Available from: https://pubmed.ncbi.nlm.nih.gov/39414869/. doi: 10.1038/s41598-024-73326-7. PMID: 39414869; PMCID: PMC11484743.

31.Lutfullah Sagir, Kaba E, Merve Huner Yigit, Filiz Tasci, Uzun H. Predicting Semen Analysis Parameters from Testicular Ultrasonography Images Using Deep Learning Algorithms: An Innovative Approach to Male Infertility Diagnosis. Journal of Clinical Medicine [Internet]. 2025 Jan 15;14(2):516-6. [cited 2025 Feb 21]. Available from: https://pmc.ncbi.nlm.nih.gov/articles/PMC11766078/. doi: 10.3390/jcm14020516.

32.Wang J, Jin Y, Jiang A, Chen W, Shan G, Gu Y, et al. Testing the generalizability and effectiveness of deep learning models among clinics: sperm detection as a pilot study. Reproductive Biology and Endocrinology [Internet]. 2024 May 22;22(1). [cited 2025 Feb 20]. Available from: https://rbej.biomedcentral.com/articles/10.1186/s12958-024-01232-8. doi: 10.1186/s12958-024-01232-8. PMID: 38778327; PMCID: PMC11110326.