



BRAZILIAN
INSTITUTE
OF DATA
SCIENCE

BIOS

LOVE DATA DAY

03 de junho 2025

Potência algorítmica, propósito humano

...o caminho para uma IA realmente
significativa na área da saúde

Rodolfo Pacagnella

*Professor Livre-docente do Departamento de Tocoginecologia da FCM Unicamp
Coordenador da trilha Saúde do BIOS – Brazilian Institute of Data Science*

naturemedicine

Review Article | [Published: 20 January 2022](#)


AI in health and medicine

[Pranav Rajpurkar](#), [Emma Chen](#), [Oishi Banerjee](#) & [Eric J. Topol](#) 

[Nature Medicine](#) **28**, 31–38 (2022) | [Cite this article](#)

Abstract:

Artificial intelligence (AI) is poised to broadly reshape medicine, potentially improving the experiences of both clinicians and patients....



nature.com/articles/s41591-021-01614-

naturemedicine

Review Article | [Published: 20 January 2022](#)


AI in health and medicine

[Pranav Rajpurkar](#), [Emma Chen](#), [Oishi Banerjee](#) & [Eric J. Topol](#) ✉

[Nature Medicine](#) **28**, 31–38 (2022) | [Cite this article](#)

Desafios:

- Interpretabilidade e implementação
- Justiça (Fairness)
- Regulação e responsabilidades



[nature.com/articles/s41591-021-01614-](https://www.nature.com/articles/s41591-021-01614-1)








ACESSO




**Falta de Acesso a
Serviços de Saúde**




APOIO NA ASSISTÊNCIA CLÍNICA




Mais de 50% das gestantes que têm um parto pré-termo não têm fatores de risco identificáveis¹



Aproximadamente 2/3 das gestantes com fatores de risco tradicionais **não** vão ter o parto antes de 37 semanas^{2,3}




70% de gestantes que apresentam sintomas de ameaça de parto pré-termo dão à luz no termo¹



95% das gestantes com sintomas de trabalho de parto prematuro **não** dão à luz dentro de 14 dias após os sintomas²

Variabilidade nos Padrões de Tratamento



APOIO NA
ASSISTÊNCIA
CLÍNICA



Lacunas no Monitoramento e Acompanhamento de Pacientes



**APOIO NA
ASSISTÊNCIA
CLÍNICA**



médicos gastam
cerca de 20% a
30% de seu tempo
em tarefas
administrativas,
como
preenchimento de
prontuários,
codificação de
diagnósticos e
procedimentos, e
cumprimento de
requisitos
regulatórios







GESTÃO

Falhas na Previsão de Demandas

“Em meio a série de mortes e falta de oxigênio em Manaus, pacientes internados fogem ou pedem para 'morrer em casa’”

Crescimento do volume de artigos científicos em Saúde (1950-2024) - estimativa





Prediction of spontaneous preterm delivery from maternal factors, obstetric history and placental perfusion and function at 11–13 weeks

Jarek Beta^{1,2}, Ranjit Akolekar¹, Walter Ventura¹, Argyro Syngelaki^{1,2} and Kypros H. Nicolaides^{1,2*}

¹Harris Birthright Research Centre for Fetal Medicine, King's College Hospital, London, UK
²Department of Fetal Medicine, University College Hospital, London, UK

Estudo prospectivo de triagem para resultados obstétricos adversos em mulheres que compareceram à primeira consulta hospitalar de rotina durante a gravidez

- 34 025 gestações.

Um modelo baseado em fatores maternos poderia detectar 38,2% dos partos prematuros em mulheres com gestações anteriores

Table 3—Logistic regression analysis for the prediction of spontaneous preterm delivery before 34 weeks based on maternal characteristics and obstetric history subdivided according to number of previous preterm deliveries

Independent variable	Univariate			Multivariate		
	OR	95% CI	p	OR	95% CI	p
Age (year)	1.009	0.991–1.028	0.320	1.027	1.008–1.047	0.006
Weight (kg)	1.004	0.997–1.011	0.260	—	—	—
Height (cm)	0.977	0.962–0.992	0.003	0.981	0.966–0.997	0.022
Race origin			<0.0001			<0.0001
Caucasian (reference)	1			1		
African	1.778	1.401–2.257	<0.0001	1.765	1.372–2.272	<0.0001
South Asian	1.757	1.139–2.709	0.011	1.741	1.112–2.726	0.015
East Asian	1.180	0.533–2.514	0.669	1.161	0.540–2.496	0.701
Mixed	0.688	0.305–1.553	0.369	0.679	0.300–1.539	0.354
Smoking	1.577	1.143–2.174	0.005	1.813	1.297–2.534	<0.0001
Assisted conception	1.722	1.114–2.661	0.014	1.713	1.095–2.679	0.018
History of alcohol abuse	—	0.140–2.268	0.419	—	—	—
History of substance abuse	—	0.347	0.824	—	—	—
Obstetric history			<0.0001			<0.0001
No pregnancy at or before 34 weeks (n = 16 103)	1			1		
Delivery at 16–34 weeks (n = 263)	5.848	3.524–9.704	<0.0001	5.848	3.524–9.704	<0.0001
Delivery at 16–34 weeks plus 31–36 weeks (n = 24)	18.725	6.789–51.748	<0.0001	18.725	6.789–51.748	<0.0001
Delivery at 16–34 weeks plus 31–36 weeks plus ≥37 weeks (n = 1)	7.327	2.536–21.167	<0.0001	7.327	2.536–21.167	<0.0001
Delivery at 16–34 weeks plus ≥37 weeks (n = 1)	1.548	0.715–3.349	0.267	1.548	0.715–3.349	0.267
Delivery at 16–34 weeks plus ≥37 weeks plus ≥37 weeks (n = 1)	9.749	3.316–28.662	<0.0001	9.749	3.316–28.662	<0.0001
Delivery at 31–36 weeks (n = 1)	2.331	1.361–3.993	0.002	2.331	1.361–3.993	0.002
Delivery at 31–36 weeks plus ≥37 weeks (n = 1)	1.872	0.971–3.609	0.061	1.872	0.971–3.609	0.061
Delivery at ≥37 weeks (n = 388)	0.583	0.456–0.747	<0.0001	0.583	0.456–0.747	<0.0001

OR, odds ratio; CI, confidence interval



Prediction of risk

- > Preeclampsia
 - > 11⁺⁰ to 14⁺¹ weeks
 - > 19⁺⁰ to 24⁺⁶ weeks
 - > 30⁺⁰ to 37⁺⁶ weeks
- > Small for Gestational Age
- > Trisomies
- > Gestational diabetes
- > Miscarriage
- > Stillbirth
- > Fetal macrosomia
- > Preterm birth - history
- > **Preterm birth - cervix**

Assessment / management

- > Management: SGA
- > Management: Fetal anemia
- > Pregnancy dating
- > Assessment: Fetal growth
- > Assessment: Birth weight
- > Assessment: Fetal Doppler
- > Assessment: Uterine PI
- > Assessment: Nuchal translucency

Performance audits

- > Mean arterial pressure
- > Uterine artery PI
- > Nuchal translucency
- > Ductus venosus PIV
- > Serum sFLT-1
- > Serum PLGF
- > Serum PAPP-A

Risk assessment

Risk for spontaneous birth at <28, <31, <34 or <37 weeks

This application allows estimation of risks for spontaneous preterm birth from a combination of previous obstetric history and measurement of cervical length at 20-26 weeks. 

Please record the following information and then press Calculate.

Maternal characteristics

Previous obstetric history

Cervical length

Measurement at 20-26 weeks

Calculate risk

Results

Risk of delivery before 28 weeks: **0.5 %**

Risk of delivery before 31 weeks: **1.3 %**

Risk of delivery before 34 weeks: **3.1 %**

Risk of delivery before 37 weeks: **8.8 %**

This software is based on research carried out by The Fetal Medicine Foundation. Neither the FMF nor any other party involved in the development of this software shall be held liable for results produced using data from unconfirmed sources. Clinical risk assessment requires that the ultrasound measurements are taken by accredited practitioners.





FOTO: WELLIKA MATOS PMBV / SEMUC 2023

RESEARCH ARTICLE

Cervical length varies considering different populations and gestational outcomes: Results from a systematic review and meta-analysis

T. G. Bortoletto¹, T. V. Silva^{1,2}, A. Borovac-Pinheiro¹, C. M. Pereira¹, A. D. Silva¹, M. S. França³, A. R. Hatanaka³, J. P. Argenton¹, R. Passini, Jr.¹, B. W. Mol⁴, J. G. Cecatti¹, R. C. Pacagnella^{1*}

¹ School of Medical Sciences, University of Campinas (UNICAMP), Campinas, São Paulo, Brazil, ² University of Pernambuco (UPE), Recife, Pernambuco, Brazil, ³ Department of Obstetrics and Gynaecology, Federal University of São Paulo (UNIFESP), São Paulo, Brazil, ⁴ Department of Obstetrics and Gynaecology, Monash University, Clayton, Victoria, Australia

PLOS ONE



Cervical length measurements (mm) of 48 publications included in meta-analysis – 38,17 mm






Figure 4 – Comparison between low/medium income versus high income countries demonstrating a statistically significant difference (p value < 0.0001) in cervical length measurement




Algoritmo pega as **regras programadas** ou **determinadas por IA** e as aplica aos dados e as aplica aos dados clínicos do paciente para gerar uma saída ou ação, que é apresentada ao usuário por meio do mecanismo de comunicação

A decisão alavancada por inteligência artificial (IA).



Garbage in Garbage **OUT**



The background image features a dark blue, textured field of small, star-like particles. A bright, glowing light source is positioned in the upper center, casting a strong beam of light. A hand, rendered in a reddish-pink hue, enters from the right side, pointing its index finger towards the light source. The overall composition suggests a focus on data or a specific point of interest within a complex environment.

**Uma das principais vantagens
estratégicas do setor de saúde
ainda é sua capacidade
intrínseca de gerar grandes
volumes de dados reais e
contextualizados em escala.**

**Mas... o verdadeiro poder dos dados de saúde não está na
sua quantidade, mas nas suas características que exigem
curadoria, governança e uso ético.**

Técnico

- Fragmentação dos dados
- Padronização insuficiente
- Qualidade dos dados

Ético-social

- Viés e equidade
- Transparência e explicabilidade

Operacional / Humano

- Integração ao fluxo de trabalho
- Erro humano / hiperconfiança

Jurídico-regulatório

- Privacidade e segurança
- Consentimento e propriedade
- Conformidade normativa



Técnico

Desafio	Descrição	Implicação clínica
Fragmentação dos dados	Registros distribuídos em múltiplos provedores e EHRs sem padrão único	Dificulta treino, validação e atualização contínua dos modelos
Padronização insuficiente	Formatos e códigos divergentes para a mesma condição	Integração complexa, maior risco de erros de mapeamento
Qualidade dos dados	Erros, lacunas e inconsistências em notas humanas ou geradas por IA	Reduz confiabilidade das predições e amplifica erros

Jiang L, et al. Opportunities and challenges of artificial intelligence in the medical field: current application, emerging problems, and problem-solving strategies. **J Int Med Res**. 2021 Mar;49(3):3000605211000157.

LI, Yu-Hao et al. Innovation and challenges of artificial intelligence technology in personalized healthcare. **Scientific reports**, v. 14, n. 1, p. 18994, 2024.

Role of AI in Electronic Health Records (EHR)



Data Management
and Organization




Data Analysis and
Insights



Predictive
Analytics



Natural Language
Processing (NLP)



Virtual Medical
Assistants




Image and Signal
Analysis



Clinical Decision
Support



Personalized
Medicine




Prontuários Online (Intranet)



Datasets integrados



**Dados de
nascimento
OMOP + SQL**




**Brazilian Daily Weather Gridded
Data (BR-DWGD), CETESB,**

**Dados
Ambientais
NetCDF + SQL**

**Observational Medical
Outcomes Partnership**

<https://ohdsi.github.io/CommonDataModel/>





O Modelo Comum de Dados (CDM) - Observational Medical Outcomes Partnership (OMOP) é um padrão de dados comunitário aberto, projetado para padronizar a estrutura e o conteúdo de dados observacionais e permitir análises eficientes que podem produzir evidências confiáveis.

UTILIZAÇÃO DE MODELOS BERT EM LÍNGUA PORTUGUESA PARA PREDIÇÃO DE CÓDIGOS CID EM CONTEXTO MATERNO E PERINATAL

Ricardo da Silva Santos (IFG/UNICAMP), Murilo Gazzola (MACKENZIE),
Renato Teixeira Souza (UNICAMP), Rodolfo Pacagnella (UNICAMP),
Cristiano Torezzan (Unicamp)



Prêmio - Melhor Trabalho em Andamento
Simpósio Brasileiro de Computação
Aplicada à Saúde

NEJM
AI

DATASETS, BENCHMARKS, AND PROTOCOLS

f X in ✉

Large Language Models Are Poor Medical Coders — Benchmarking of Medical Code Querying

Authors: Ali Soroush, M.D., M.S.  ✉, Benjamin S. Glicksberg, Ph.D. , Eyal Zimlichman, M.D., M.Sc. , Yiftach Barash, M.D., M.Sc. , Robert Freeman, R.N., M.S.N., N.E.-B.C. , Alexander W. Charney, M.D., Ph.D. , Girish N Nadkarni, M.D., M.P.H. , and Eyal Klang, M.D.  [Author Info & Affiliations](#)


Published April 19, 2024 | NEJM AI 2024;1(5) | DOI: 10.1056/AIdbp2300040
VOL. 1 NO. 5 | Copyright © 2024

Qual é o problema?

- Mais de 2.000 tipos diferentes de sistemas de prontuário eletrônico.
- Mais de 200 sistemas nacionais diferentes para entrada de dados e com pouca ou nenhuma interoperabilidade.
- Ausência de padronização da troca de informações.



Troca de Informação de Saúde Com a RNDS





Fluxo da Informação




Integrar x Interoperar

A RNDS padroniza a linguagem para a troca de informações em saúde em âmbito nacional.




Integração: Sistemas enviam e recebem diversas informações de forma distinta, não padronizadas



Interoperabilidade: Sistemas utilizam uma linguagem única e padronizada

Informações na RNDS – fase 1



Benefícios

Continuidade do cuidado

Cuidado centrado no paciente;

Redução de erros e redundâncias



Protagonismo na autogestão da saúde

Eficiência operacional

Melhor comunicação e engajamento


Aplicações

Transplantes

Hemovida

Peso Saudável

Saúde Brasil



SUS MINISTÉRIO DA SAÚDE

conectesus-paciente.saude.gov.br

GOV.BR/SAUDE
ConecteSUS minsau



Website




Play Store




iOS




Repositório de dados



Repositório de dados



Federated learning



Ético-social

Desafio	Descrição	Implicação clínica
Redução de Viés e busca de equidade	Sub-representação de populações específicas no conjunto de treino	Resultados menos precisos ou injustos para esses grupos
Transparência e explicabilidade	Modelos opacos (“black box”) dificultam compreensão	Erosão da confiança de pacientes e profissionais

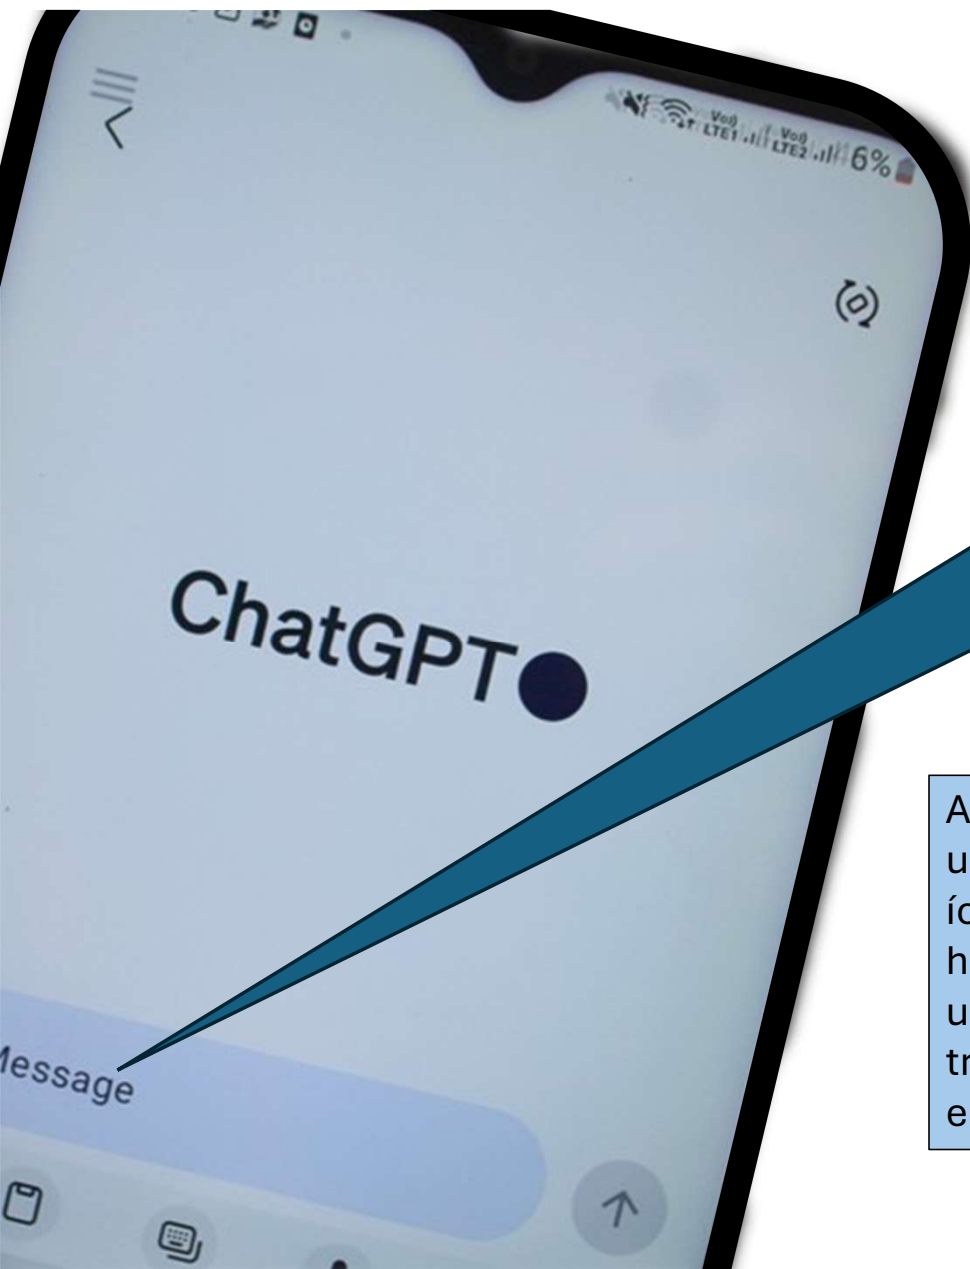
Jiang L, et al. Opportunities and challenges of artificial intelligence in the medical field: current application, emerging problems, and problem-solving strategies. **J Int Med Res.** 2021 Mar;49(3):3000605211000157.

LI, Yu-Hao et al. Innovation and challenges of artificial intelligence technology in personalized healthcare. **Scientific reports**, v. 14, n. 1, p. 18994, 2024.

Operários Tarsila do Amaral 85x118cm

Dados:
Geração e
curadoria

Não existe IA não
discriminatória sem dados
representativos



crie uma figurinha que tenha uma mulher grávida no meio com todos os serviços potencialmente necessários em volta, para que o gestor compreenda a noção de rede assistencial



Aqui está a ilustração representando uma gestante no centro de uma rede assistencial de saúde. Em volta dela, estão diversos ícones interconectados que simbolizam serviços essenciais, como hospital, ambulância, clínica de atenção primária, maternidade, unidade neonatal, farmácia, clínica de saúde mental e um trabalhador de saúde comunitário, todos ligados à figura central, enfatizando a rede de cuidados que envolve a gestante






refaça essa mesma imagem apenas mudando a gestante PARA UMA GESTANTE DE COR DE PELE PRETA



A ilustração foi atualizada conforme solicitado, com uma gestante negra no centro da rede assistencial de saúde, mantendo os mesmos ícones de serviços essenciais ao redor.






por que ela está descalça?



A representação da gestante descalça na ilustração não foi uma escolha intencional e pode ser vista como uma limitação na interpretação do pedido pela ferramenta de geração de imagens. Em um contexto ideal, especialmente para uso em materiais educativos ou informativos, seria preferível que a gestante fosse retratada de maneira mais realista e apropriada, incluindo o uso de calçados. Se desejar, posso tentar criar uma nova imagem com essa especificação.




Modelos algorítmicos de larga escala que **classificam pessoas**, reproduzem vieses humanos e **punem desproporcionalmente grupos pobres ou pouco representados**.



Dados gerados pelos próprios modelos reforçam as premissas originais, intensificando desigualdades.

**“Você confiaria
seu tratamento a
um algoritmo?”**



Perspective

Thinking about Trust: People, Process, and Place

Stephen Marsh,^{1,*} Tosan Atele-Williams,¹ Anirban Basu,² Natasha Dwyer,³ Peter R. Lewis,⁴ Hector Miller-Bakewell,⁵ and Jeremy Pitt⁶

Sistema de Confiança e Abordagens

Duas Abordagens para Confiança:

- **Imposição de Confiança:**
Confiança imposta via algoritmos e estatísticas.
- **Empoderamento de Confiança:**
Usuário toma decisões baseadas em evidências.




**confiança é crucial para o
a utilização de IA**

Confiabilidade


An overview of clinical decision support systems: benefits, risks, and strategies for success

Reed T. Sutton¹, David Pincock², Daniel C. Baumgart¹, Daniel C. Sadowski¹, Richard N. Fedorak¹ and Karen I. Kroeker¹

npj Digital Medicine (2020) 3:17 ; <https://doi.org/10.1038/s41746-020-0221-y>



Non-knowledge based single system CDSS




An Open Science Approach to Artificial Intelligence in Healthcare

A Contribution from the International Medical Informatics Association Open Source Working Group

Chris Paton^{1,3}, Shinji Kobayashi^{2,3}

Explicabilidade



Relação entre "Caixa-Preta" e Confiança em IA

- Confiança envolve precisão, eficácia e transparência.
- **Processos tipo "Caixa-Preta"** - Erosão da confiança devido à falta de transparência.
- **Equilíbrio Necessário** entre complexidade do algoritmo e transparência para ganhar confiança.
- Confiança como fator crítico para adoção responsável de IA em saúde.

Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead

Cynthia Rudin 

Nature Machine Intelligence 1, 206–215 (2019) | [Cite this article](#)



Transparência

Cynthia Rudin sugere uma alternativa: o desenvolvimento e uso de modelos que são inerentemente interpretáveis:

“o caminho a seguir é focar no **desenvolvimento de modelos de aprendizado de máquina que sejam inerentemente interpretáveis**, pois isso não apenas tornaria os modelos mais transparentes, mas também poderia evitar práticas ruins e potenciais danos à sociedade”

Operacional / Humano

Desafio	Descrição	Implicação clínica
Integração ao fluxo de trabalho	Necessidade de adaptar rotinas, sistemas e treinamento	Atrasos na adoção, atrito entre equipes de TI e clínicos
Erro humano / hiperconfiança	Dependência excessiva de recomendações algorítmicas	Risco de diagnósticos ou tratamentos inadequados

Jiang L, et al. Opportunities and challenges of artificial intelligence in the medical field: current application, emerging problems, and problem-solving strategies. **J Int Med Res.** 2021 Mar;49(3):3000605211000157.

LI, Yu-Hao et al. Innovation and challenges of artificial intelligence technology in personalized healthcare. **Scientific reports**, v. 14, n. 1, p. 18994, 2024.

The “inconvenient truth” about AI in healthcare

Trishan Panch, Heather Mattie & Leo Anthony Celi ✉

- 1) Ferramentas de IA, per se, **não reestruturam a forma como os serviços** são oferecidos.
- 2) As unidades de saúde carecem de infraestrutura necessária **para coletar dados da população local** para ‘ajustar’ algoritmos pré-treinados e evitar viés, preconceitos e problemas de generalização.



“algoritmos que se destacam na literatura **não são, de fato, executáveis nas linhas de frente da prática clínica**”

Ishii et al. *Journal of Intensive Care* (2020) 8:35
<https://doi.org/10.1186/s40560-020-00452-5>

Journal of Intensive Care

REVIEW

Open Access

The advent of medical artificial intelligence: lessons from the Japanese approach



Euma Ishii^{1,2,3*}, Daniel K. Ebner⁴, Satoshi Kimura⁵, Louis Agha-Mir-Salim⁶, Ryo Uchimido^{2,7} and Leo A. Celi^{3,7}


AI models demonstrated high internal validity (AUC = 0.82, Accuracy = 0.89) but exhibited reduced performance in external validation (AUC = 0.80, Accuracy = 0.87), particularly in sensitivity. Significant heterogeneity ($I^2 > 99\%$) was observed across studies, limiting generalizability.



These findings underscore the urgent need for more diverse, **well-validated AI models** to improve maternal and neonatal outcomes globally

From Promise to Practice: Artificial Intelligence for Maternal and Neonatal Outcome Prediction—A Systematic Review


OLUWAFUNMILOLA DEBORAH AWE





**Validação
humana
sistemática**
(*human-in-the-
loop*) é mandatória
em ciclos de
desenvolvimento e
uso de IA





**A ferramenta foi desenvolvida na nossa
população?**

Validada na nossa população?

Foi testada na prática clínica?

Em ensaio clínico?

Funciona?

?

Jurídico-regulatório

Desafio	Descrição	Implicação clínica
Privacidade e segurança	Risco de violação ou re-identificação de dados sensíveis	Danos à confidencialidade e possíveis sanções legais
Consentimento e propriedade	Pacientes não compreendem ou não controlam o uso de seus dados	Questionamentos éticos e legais sobre legitimidade do processamento
Conformidade normativa	Legislação desatualizada frente ao ritmo da IA	Incerteza jurídica, barreiras à adoção escalonada

Jiang L, et al. Opportunities and challenges of artificial intelligence in the medical field: current application, emerging problems, and problem-solving strategies. **J Int Med Res.** 2021 Mar;49(3):3000605211000157.

LI, Yu-Hao et al. Innovation and challenges of artificial intelligence technology in personalized healthcare. **Scientific reports**, v. 14, n. 1, p. 18994, 2024.

Responsabilização

Questão da "**Responsabilidade pelo Uso do Sistema**" é um tópico complexo que cruza várias disciplinas, incluindo ética, direito e gestão.

O dilema é complicado porque várias partes estão envolvidas na implementação e uso da IA em um ambiente médico:

1. **Desenvolvedores de Sistema:** defeito no algoritmo
2. **Administradores Hospitalares:** decidem adquirir e implementar o sistema de IA
3. **Equipe de Saúde:** usuários finais do sistema de IA - uso inadequado do sistema.
4. **Consultores em tecnologia:** aconselhamento da administração hospitalar na aquisição e implementação do sistema



Article

Application of Artificial Intelligence-Based Technologies in the Healthcare Industry: Opportunities and Challenges

DonHee Lee ¹ and Seong No Yoon ^{2,*}

¹ College of Business Administration, Inha University, Incheon 22212, Korea; dhlee04@inha.ac.kr

² Department of Business Edward Waters College, Jacksonville, FL 32209, USA

* Correspondence: Seong.yoon@ewc.edu

Principais Pontos de Interesse

- Centralidade da Pessoa Humana
- Proteção de Direitos Fundamentais
 - (Art. 2º e Art. 3º)
- Promoção da Pesquisa e Desenvolvimento (P&D)
 - (Art. 2º, inciso IX)
- Governança e Transparência
 - (Art. 19 a Art. 25)
- Responsabilidade Civil e Proteção dos Vulneráveis
 - (Art. 27 e Art. 12)



SENADO FEDERAL

PROJETO DE LEI
Nº 2338, DE 2023

Dispõe sobre o uso da Inteligência Artificial.

Iniciativa: Senador Rodrigo Pacheco (PSD/MG)

EM TRAMITAÇÃO

3/mai 2023

Casa Iniciadora (Senado) Fase concluída ✓

PL 2338/2023

Situação: REMETIDA À CÂMARA DOS DEPUTADOS

Tramitação

17/mar 2025

Casa Revisora (Câmara) Em tramitação ⚠

PL 2338/2023

Situação: Aguardando Parecer do(a) Relator(a) na Comissão Especial destinada a proferir parecer ao Projeto de Lei nº 2338, de 2023, do Senado Federal, que "dispõe sobre o desenvolvimento, o fomento e o uso ético e responsável da inteligência artificial com base na centralidade da pessoa humana" (PL2338/23)


Tramitação

Sanção (Presidência da República) Fase prevista

Situação: Previsto

Potenciais problemas

- Muito defensiva, regulação muito rigorosa
 - Mais rigorosa que outras regulamentações como a europeia
- Conflito entre inovação e proteção
- Exigências demasiadas
 - Explicabilidade e Transparência
 - Avaliação de Impacto Algorítmico (AIA)
- Retira capacidade competitiva
- Pouca clareza na definição das categorias de risco
- Excessiva responsabilização independentemente do grau de autonomia do sistema



The screenshot displays the official page for the **SENADO FEDERAL** (Brazilian Senate) regarding **PROJETO DE LEI Nº 2338, DE 2023**. The title of the bill is **Dispõe sobre o uso da Inteligência Artificial**. The initiative is attributed to **Senador Rodrigo Pacheco (PSD/MG)**.

The page features a vertical timeline of the bill's progress:

- 3/mai 2023**: **Casa Iniciadora (Senado)**. Status: **Fase concluída** (checked). Situation: **REMETIDA À CÂMARA DOS DEPUTADOS**. A dropdown menu shows **Tramitação**.
- 17/mar 2025**: **Casa Revisora (Câmara)**. Status: **Em tramitação** (clock icon). Situation: **Aguardando Parecer do(a) Relator(a) na Comissão Especial destinada a proferir parecer ao Projeto de Lei nº 2338, de 2023, do Senado Federal, que "dispõe sobre o desenvolvimento, o fomento e o uso ético e responsável da inteligência artificial com base na centralidade da pessoa humana" (PL2338/23)**. A dropdown menu shows **Tramitação**.
- Sanção (Presidência da República)**. Status: **Fase prevista** (minus icon). Situation: **Previsto**.

- Não há amplo posicionamento institucional de Institutos de Pesquisa
- Não há posicionamento aberto e assertivo das Universidades
- Não há discussão aberta nem mesmo nesta Universidade

Projeto de Lei nº 2338, de 2023



Iniciativa Assunto Senador Economista Jurídico
 UNICAMP
 ESCRITÓRIO DE PRIVACIDADE
 Open Knowledge Brasil
 SB
 GEDAI UFPR

PRIVACIDADE DOCUMENTOS LEGISLAÇÕES CURSOS E GUIAS PROGRAMAS E PROJETOS

Início >
 ANPD
Análise preliminar da proposta de regulação da IA no Brasil
 ANPD apresenta estudo preliminar sobre o Projeto de Lei nº 2338/2023
 18 JUL 2023

Texto inicial
 Nossas Causas
 Imprimir
 ACERVO DIGITAL
 AÇÕES EV
 .446
 NÃO



Regulação da Inteligência Artificial: Garantindo um Futuro Ético e Inclusivo no Brasil.

O Projeto de Lei Nº 2338 de 2023, de autoria do Senador Rodrigo Pacheco (PSD/MG), dispõe sobre a regulação da inteligência artificial e o futuro ético e inclusivo no Brasil.

Publicado em 06/07/2023 17h56 | Atualizado em 07/07/2023 17h03

Inteligência Artificial no Brasil e no

suas
 a de
 lição
 s de
 1) a passos largos, assim deve seguir a regulamentação
 esta sexta-feira, nosso olhar se volta para o cenário
 sendo incorporados pelo capital; 2) seu possível
 nceituosos de infratores ou criminosos, assim

Compartilhe: [f](#) [x](#) [in](#) [u](#) [e](#)



Protect autonomy



Promote human well-being, human safety and the public interest



Ensure transparency, explainability and intelligibility



Foster responsibility and accountability



Ensure inclusiveness and equity



Promote AI that is responsive and sustainable



Os 3 “T” para uma IA Clinicamente Viável

A IA clinicamente viável exige

- **Transparência**
sustentada por metadados ricos, padrões interoperáveis e documentação pública;
- **Testes** contínuos
que ligam métricas de machine learning a desfechos clínicos reais, suportados por pipelines de *continuous validation*; e
- **Trabalho** colaborativo
entre especialistas de dados, ética e assistência que mantêm a supervisão humana prescrita pelo AI Act.

1 | Transparência — modelos e dados auditáveis

Metadados e rastreabilidade (“data lineage”)

- A rastreabilidade é pré-requisito dos 40 requisitos de transparência do guia da OMS para LMMs em saúde.

Documentação Padronizada

Interoperabilidade

2 | Testes — validação prospectiva e monitoramento contínuo

Desenho de validação



Validação contínua

3 | Trabalho Colaborativo — equipes multidisciplinares orientadas por dados



**CURADORIA E
LIDERANÇA
CLÍNICA**



**ENGENHARIA
DE DADOS EM
SAÚDE**



**CIÊNCIA DE
DADOS
VOLTADA PARA
A CLÍNICA**



**ESPECIALISTA
EM ÉTICA**





**LEGISLAÇÃO
ROBUSTA**

**Potência
algorítmica,
propósito humano**



BRAZILIAN
INSTITUTE
OF DATA
SCIENCE



UNICAMP

Obrigado

rodolfop@unicamp.br