



# VIII Workshop de Águas Subterrâneas dos Comitês PCJ

Inovações na Gestão de Recursos Hídricos Subterrâneos

Realização:

**CT-AS**  
Comitê Técnico de  
Águas Subterrâneas



Apoio:



**CT-Indústria**  
Comitê Técnico de Uso e  
Conservação de Água na Indústria

**CT-MH**  
Comitê Técnico de  
Monitoramento Hidrológico

**AgSolve**  
GeoAcqua

**edison da**  
Hídrica



**Unipar**  
Poder Hídrico



**Sigesp**





# Inteligência Artificial Aplicada ao Estudo e à Gestão das Águas Subterrâneas.

Clyvikh Camacho  
Pesquisador – Serviço Geológico do Brasil – SGB

# Roteiro

 **O Desafio:** O Contexto das Águas Subterrâneas nas Bacias PCJ.

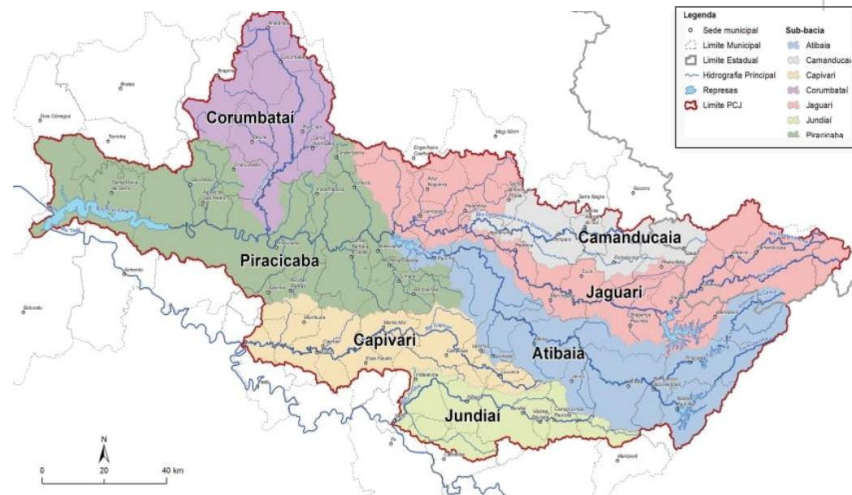
 **A Ferramenta:** O que é IA e Machine Learning neste contexto?

 **As Aplicações:** Como a IA está sendo usada na Hidrogeologia.


 **O Futuro:** Desafios e Oportunidades para o Comitê.

# O Desafio: Contexto das Bacias PCJ

- Região de alta densidade urbana e industrial, com grande demanda hídrica.
- A água subterrânea é um recurso estratégico, mas vulnerável (risco de superexploração e contaminação).
- Necessidade de gestão integrada (superficial + subterrânea) para garantir a segurança hídrica.
- O próprio Comitê PCJ (VIII Workshop) já identifica a IA e a inovação como chaves para a gestão.









Água doce congelada

Água doce não congelada



# A Caixa de Ferramentas: IA

# O que é IA?

## Segundo o ChatGPT.



**Inteligência Artificial (IA)** é um campo da ciência da computação que busca desenvolver sistemas capazes de realizar tarefas que normalmente exigiriam inteligência humana. Essas tarefas podem incluir aprendizado, reconhecimento de padrões, tomada de decisão, resolução de problemas, compreensão de linguagem natural, entre outras.



# O que é IA?

## Segundo o Copilot.

É uma tecnologia que simula processos de inteligência humana usando máquinas, especialmente sistemas computacionais. Ela abrange desde algoritmos simples até modelos complexos que aprendem e se adaptam com os dados. IA envolve aprendizado de máquina, processamento de linguagem natural, reconhecimento de imagem, e muito mais. Basicamente, é uma tentativa de criar máquinas que podem pensar e agir como humanos. Você acha isso fascinante ou assustador?



Mensagem para o Copilot




# O que é IA?

## Segundo o Gemini.



### Inteligência Artificial: Uma Definição Abrangente

**Inteligência Artificial (IA)** é um ramo da ciência da computação que se dedica a criar máquinas e sistemas capazes de simular comportamentos inteligentes, como aprendizado, raciocínio, resolução de problemas e percepção. Em outras palavras, a IA busca desenvolver sistemas que possam executar tarefas que, normalmente, requereriam inteligência humana. 

A IA, em sua base matemática, é fortemente fundamentada em transformações vetoriais e álgebra linear, onde dados são projetados em espaços multidimensionais e manipulados através de operações matriciais. No entanto, sistemas modernos combinam essas técnicas com otimização, estatística e não-linearidades para extrair padrões complexos.

# O que é IA?

## REVIEW

doi:10.1038/nature14539

### Deep learning


| NATURE | VOL 521 | 28 MAY 2015

Yann LeCun<sup>1,2</sup>, Yoshua Bengio<sup>3</sup> & Geoffrey Hinton<sup>4,5</sup>


Lecun et al. (2015) descrevem aprendizado profundo (inteligência artificial) como uma estrutura matemática para aprender representações a partir de dados.

Aprender uma sequência de funções que transformam vetores mapeando-os de um espaço a outro até atingir o resultado desejado (Goodfellow et al., 2016).


1: Dados de entrada



2: Mudança de coordenadas



3: Melhor representação



É possível reproduzir o processo matemático.

# Como funciona uma LLM (*Large Language Models*) segundo o *DeepSeek*?

## Funcionamento Detalhado de um LLM

### 1. Entrada: Strings → Tokens → Vetores (Embeddings)

- **Tokenização:**

- O texto é dividido em unidades menores (*tokens*), que podem ser palavras, partes de palavras ou caracteres.
- Exemplo (com o tokenizer do GPT-3):
  - **String:** "Qual a vazão do poço?"
  - **Tokens:** ["Qual", " a", " vaz", "ão", " do", " poço", "?"]
- Cada token recebe um **ID numérico** (ex.: " poço" → 1521 no vocabulário do modelo).



- **Embeddings:**

- Cada token é mapeado para um **vetor de alta dimensão** (ex.: 1.536 dimensões no GPT-4).
- Esses vetores são aprendidos durante o treinamento e codificam:
  - Significado semântico ("poço" está próximo de "aquífero" no espaço vetorial).
  - Contexto posicional ("vazão" no início vs. no final da frase tem representações diferentes).



## 2. Processamento: Transformações Numéricas (Attention + Redes Neurais)

- **Multi-Head Self-Attention (o coração dos Transformers)**

- **Passo 1:** Cada token gera 3 vetores: **Query (Q), Key (K), Value (V)**.
  - Esses vetores são projeções lineares dos embeddings originais.
- **Passo 2:** O modelo calcula **atenção** entre todos os tokens:
  - A "importância" do token  $j$  para o token  $i$  é dada por:

$$\text{Attention}(Q_i, K_j) = \frac{Q_i \cdot K_j}{\sqrt{d_k}}$$

(onde  $d_k$  é a dimensão dos vetores).

- Exemplo: Na frase "A vazão do poço é alta", o modelo aprende que "vazão" e "poço" têm alta atenção mútua.
- **Passo 3:** Os vetores são recombinados usando pesos de atenção:

$$\text{Output}_i = \sum_j \text{softmax}(\text{Attention}(Q_i, K_j)) \cdot V_j$$

- **Feed-Forward Neural Network (FFNN)**

- Após a atenção, cada vetor passa por uma rede neural com não-linearidades (ex.: ReLU) para refinar ainda mais sua representação.

- **N Camadas de Transformers**

- O processo acima se repete em várias camadas (ex.: 12 camadas no BERT, 96 no GPT-4), permitindo que o modelo capture relações complexas.

### 3. Saída: Vetores → Tokens → Strings

- **Decodificação Autoregressiva (para modelos como GPT):**

1. O vetor do último token (ex.: [CLS] ou <EoS>) é usado para prever o próximo token.
2. A cada passo, o modelo gera uma **distribuição de probabilidade** sobre todos os tokens possíveis.
  - Exemplo: Após "A vazão do poço é", o modelo pode atribuir:
    - "alta": 70%
    - "baixa": 20%
    - "nula": 10%
3. O token mais provável é escolhido (ou amostrado, dependendo da temperatura).
4. O processo repete até gerar um token de parada (<EoS>).

- **Detokenização:**


- Os IDs numéricos dos tokens são convertidos de volta para strings.
- Exemplo de saída:

```
python
```

 Copy  Download

```
"A vazão do poço é alta, aproximadamente 10 m³/h."
```

Camadas ocultas – GhatGPT tem 96.




O ChatGPT não quis me contar quais são as funções de ativação que ele usa.


ReLU (Rectified Linear Unit) ou variantes dela, como a Leaky, Swish, ELU ou GELU (Gaussian Error Linear Unit).

SoftMax

$$\sigma(\mathbf{z})_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad \text{for } j = 1, \dots, K.$$



## Retropropagação de erro rede neural



$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n)$$

$$y_j(n) = \varphi_j(v_j(n))$$

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)}$$



$$e_j(n) = d_j(n) - y_j(n)$$



$$\frac{\partial E(n)}{\partial e_j(n)} = e_j(n)$$



$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n))$$



$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n)$$



$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n) \varphi'_j(v_j(n)) y_i(n)$$



$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)}$$



$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n)$$




$$\delta_j(n) = \frac{\partial E(n)}{\partial v_j(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n) \varphi'_j(v_j(n))$$

$$\delta_j(n) = \frac{\partial E(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = \frac{\partial E(n)}{\partial y_j(n)} \varphi'_j(v_j(n))$$

$$E(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n)$$

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)}$$





$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)}$$

$$e_k(n) = d_k(n) - y_k(n)$$

$$e_k(n) = d_k(n) - \phi_k(v_k(n))$$


$$\frac{\partial E(n)}{\partial y_j(n)} = - \sum_k e_k(n) \phi'_k(v_k(n)) w_{kj}(n)$$

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n)$$

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\phi'_k(v_k(n))$$

$$= - \sum_k \delta_k(n) w_{kj}(n)$$

$$\delta_j(n) = \phi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n)$$




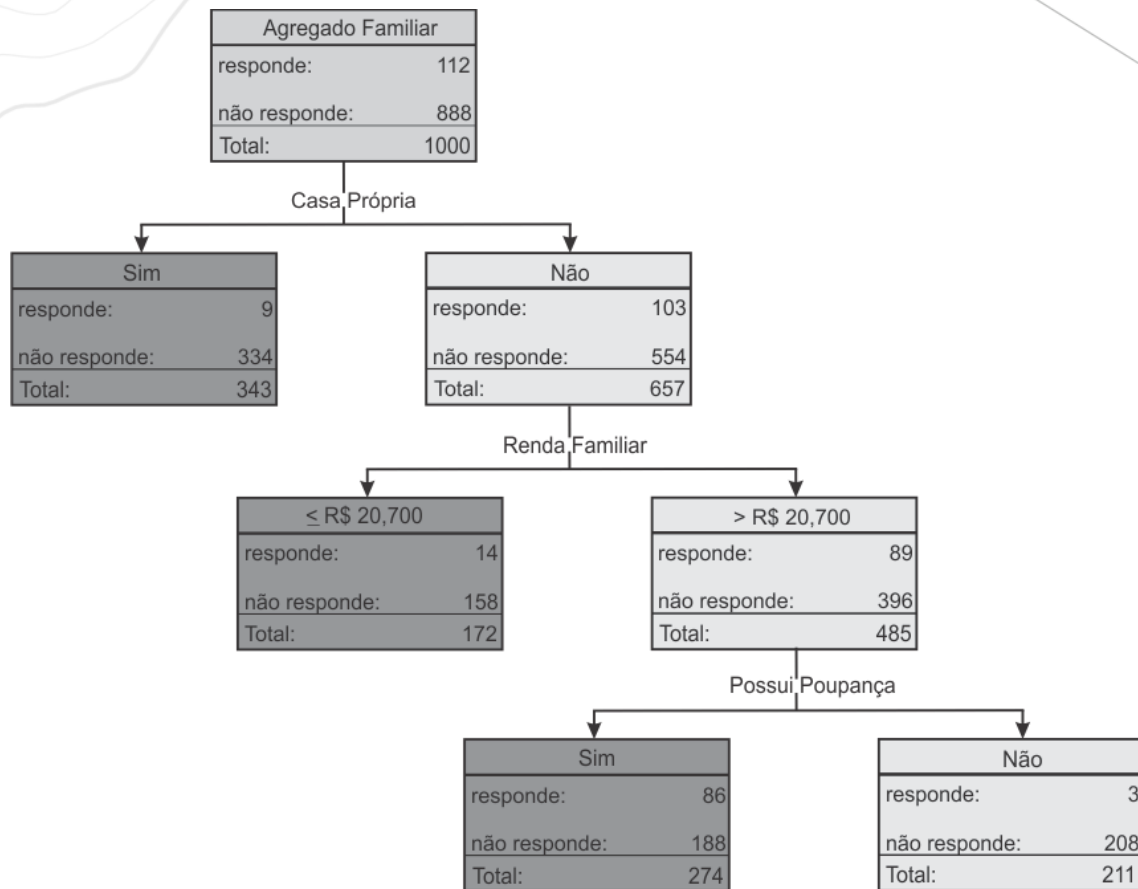
$$\begin{pmatrix} \text{Correção} \\ \text{dos} \\ \text{Pesos} \\ \Delta w_{ji}(n) \end{pmatrix} = \begin{pmatrix} \text{Parâmetro} \\ \text{de taxa de} \\ \text{aprendizado} \\ \eta \end{pmatrix} \times \begin{pmatrix} \text{Gradiente} \\ \text{local} \\ \delta_j(n) \end{pmatrix} \times \begin{pmatrix} \text{signal de} \\ \text{entrada} \\ \text{no} \\ \text{neurônio } j, \\ y_i(n) \end{pmatrix}$$



# Gradiente decrescente

$$\vartheta_{t+1} = \vartheta_t - \eta \cdot \nabla J(\vartheta_t; x_i, y_i)$$





$\hat{y}_i^{(2)}$ Estabelecimento  
de N árvoresExpansão  
dos pesos

Preditor 1

Preditor 2

Preditor N

Média dos  
Preditores

Dados de entrada

Inicialização

Dados de  
treinamentoDados de  
teste $= y_i$ 

i)

Níveis da IA: **Gemini.**

1 - IA Fraca: **Especializada** em uma tarefa específica, como assistentes virtuais e chatbots.


2 - IA Geral: Ainda uma teoria, mas seria uma máquina capaz de realizar **qualquer tarefa intelectual** que um humano pode fazer.

3 - IA Superinteligente: **Superaria a inteligência humana** em todos os aspectos. Totalmente hipotética e alvo de muitas discussões éticas.

Mesmo uma IA fraca pode superar a inteligência humana em uma aplicação específica.

Modelos especialistas.

# IA modelos matemáticos – Sem acoplamento físico. Trabalhando com Vetores!



Segundo o Copilot.

# Limitações x Vantagens

## Limitações:

- 1 - Necessitam de grandes quantidades de dados para treinamento.
- 2 - A construção dos modelos necessitam conhecimento do processo, arquiteturas.
- 3 - Desafios éticos e operacionais na implementação de soluções baseadas em IA.
- 4 - Modelos de IA atuais não possuem acoplamento físico....

## Vantagens.

- 1 - Modelos de IA atuais não possuem acoplamento físico.
- 2 - Flexibilidade dos modelos a dados de entrada.
- 3 - Velocidade no processamento.
- 4 - Precisão nos resultados....

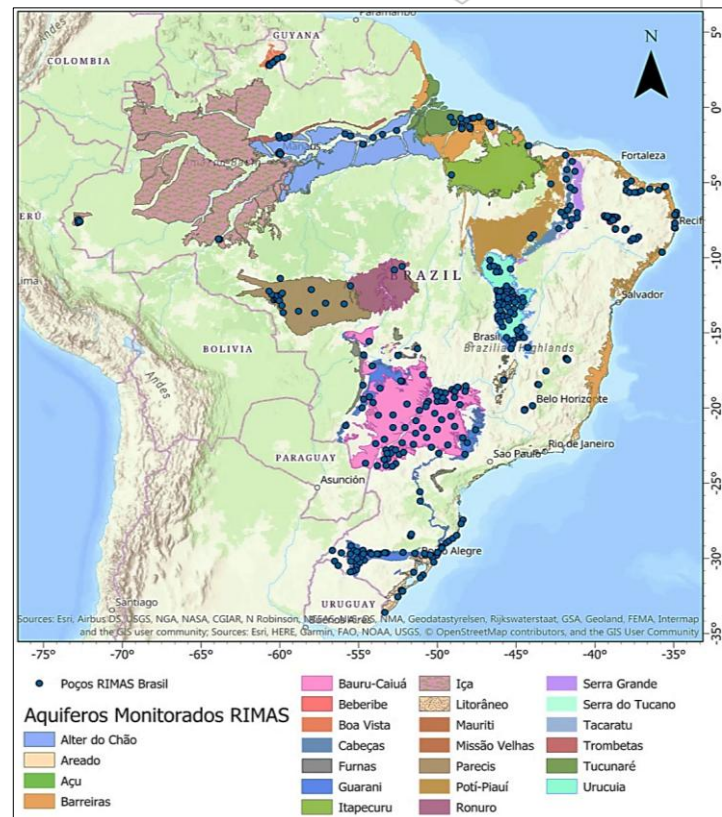


# Aplicações: Como a IA está sendo aplicada na hidrogeologia

## Exemplo – Monitoramento hidrogeológico

Um ser humano dificilmente conseguiria apresentar resultados quanto a variação do armazenamento das águas subterrâneas de todo o Brasil, de forma segura e rápida. Não apenas dos poços de monitoramento, mas de áreas não monitoradas.

Uma IA pode!



# Dados de entrada no modelo

**GRACE**

2002-04-01

**ET**

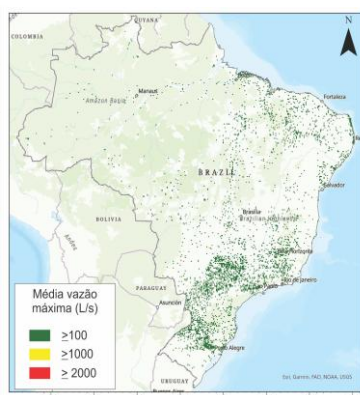
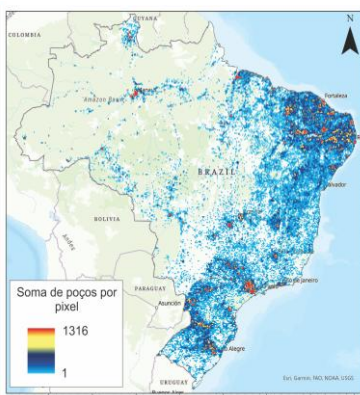


2002-04-01

**LAI**

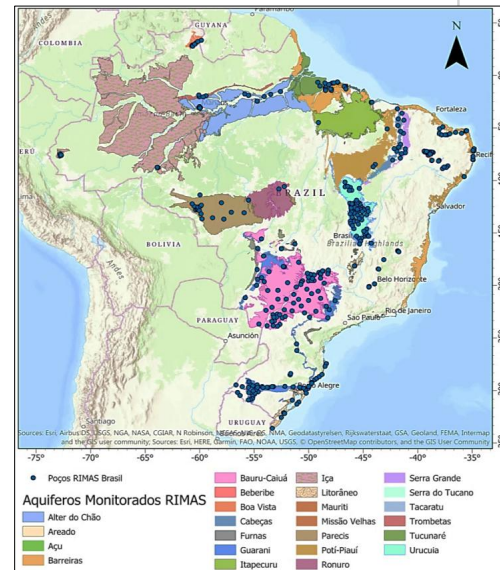
2002-04-01

**GPM**

2002-04-01



**Alvo = RIMAS**



Resultado: modelo baseado em IA supera os demais.

## Water Resources Research

Research Article

### Large-Scale Groundwater Monitoring in Brazil Assisted With Satellite-Based Artificial Intelligence Techniques

Clyvihk Renna Camacho, Augusto Getirana ✉, Otto Corrêa Rotunno Filho, Maria Antonieta A. Mourão

First published: 20 August 2023 | <https://doi.org/10.1029/2022WR033588>

Avaliação do modelo:

Raiz quadrada do erro quadrático médio **RMSE = 1,32 cm**

Erro médio **MAE = 0,78 cm**

Eficiência de Nash-Sutcliffe **NSE = 0,90**

**R<sup>2</sup> = 0,90**

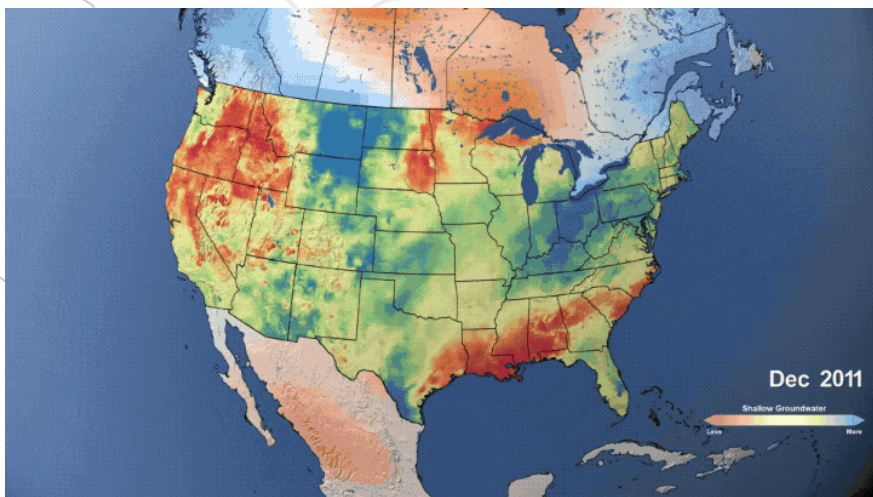
Eficiência de Kling-Gupta **KGE = 0,90**

Medida de fase entre as simulações e as observações **KGE<sub>r</sub> = 0,95**


Razão entre as médias simuladas e as observadas **KGE<sub>alpha</sub> = 0,93**

Razão entre o desvio padrão simulado e o observado **KGE<sub>beta</sub> = 0,93**


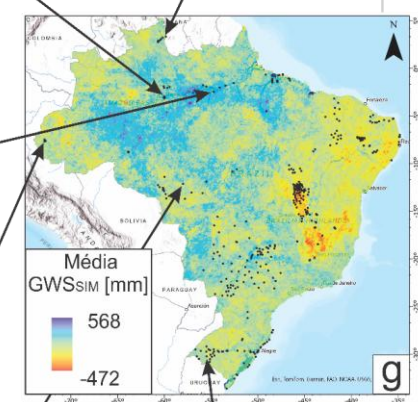






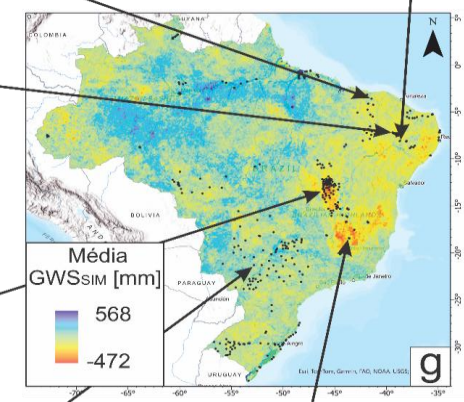







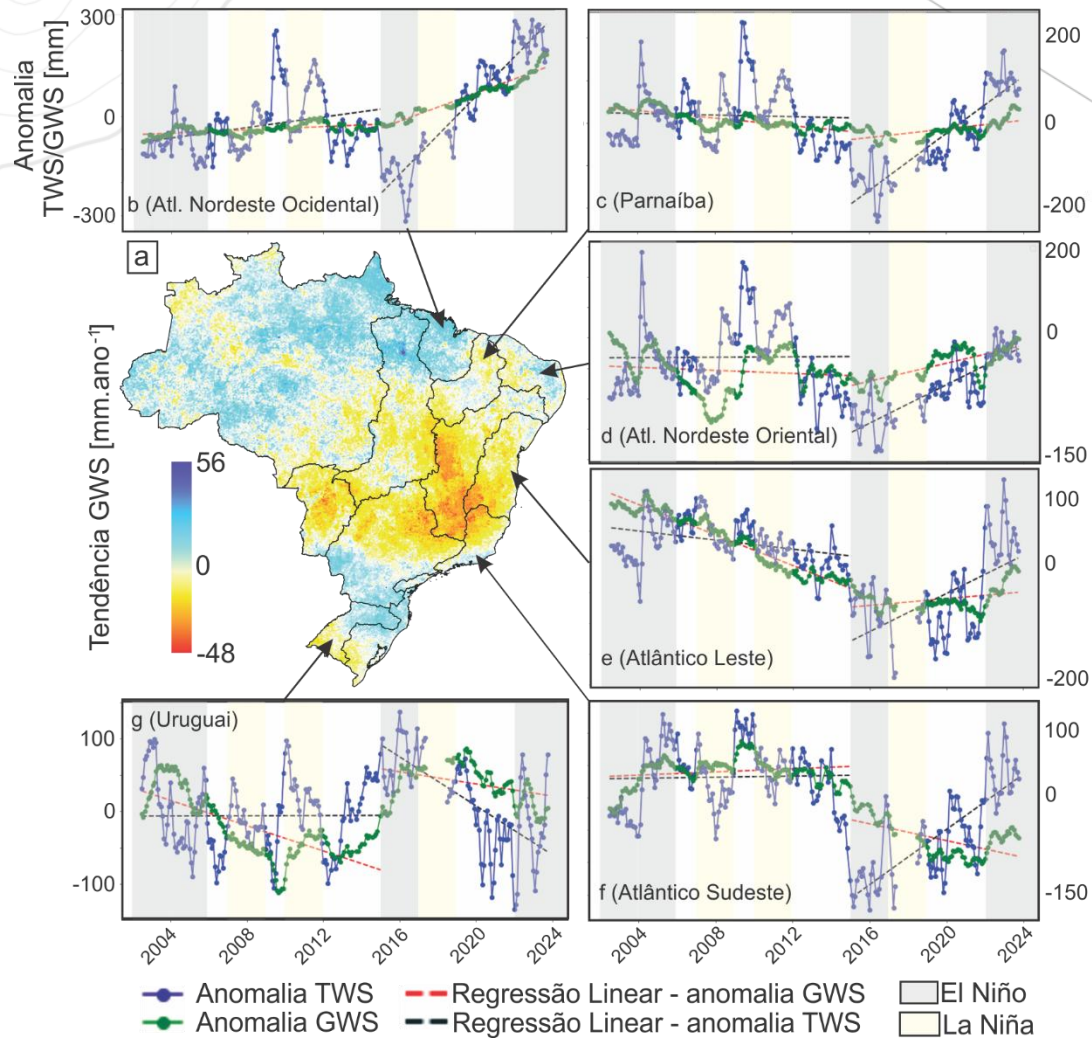


Fonte: <https://gracefo.jpl.nasa.gov/news/131/nasa-satellites-reveal-major-shifts-in-global-freshwater/>

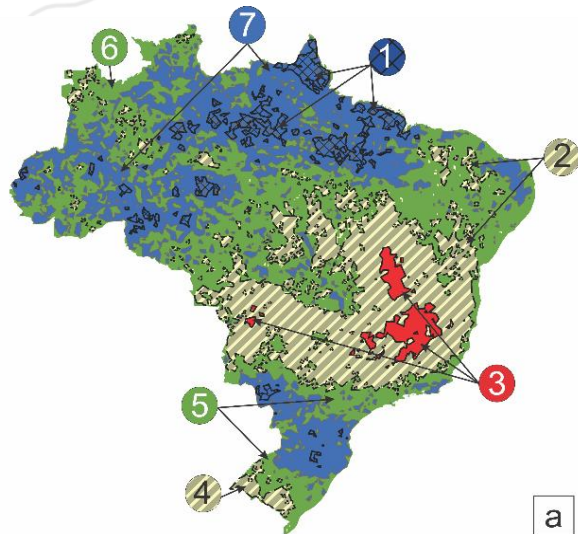









**A depleção de 524 km<sup>3</sup> em áreas críticas exige que a gestão do uso da água (mineração, irrigação) seja integrada ao planejamento de adaptação climática.**



Classificação e interpretação

- Alto ganho de armazenamento - Bacia Amazônica e pequenas áreas no Sul do Brasil - Variabilidade natural/mudanças na precipitação
- Ganho de armazenamento - Bacia Amazônica, Nordeste e áreas do Sul do Brasil - Variabilidade natural/mudanças na precipitação
- Perda de armazenamento - Nordeste/Sudeste e Centro-Oeste do Brasil - Uso de águas subterrâneas associado a mudanças na cobertura

- Perda intensa de armazenamento - Sudeste e Centro-Oeste - Uso intenso associado a mudanças na cobertura e secas
- Nenhuma tendência - Norte, Nordeste e Centro-Sul





Inclinação GWS [mm.ano<sup>-1</sup>]

56 0 -48


**Aproximadamente 1 mês de vazão do rio Amazonas.**






# Inteligência Artificial + SR = Águas Subterrâneas



# Inteligência Artificial + SR = Águas Subterrâneas






# Inteligência Artificial + SR = Águas Subterrâneas


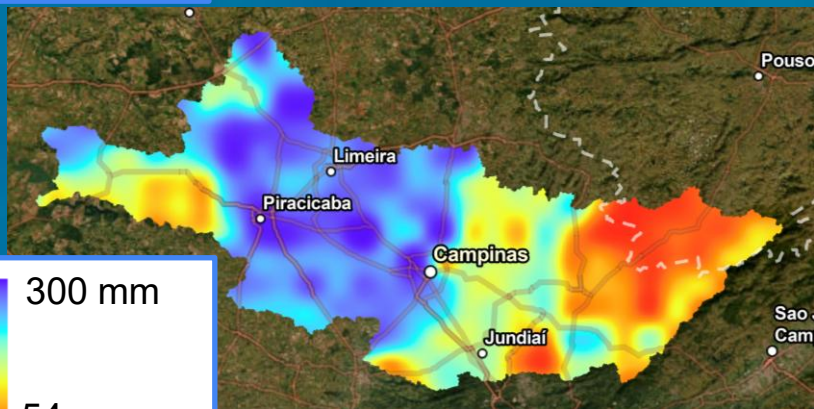
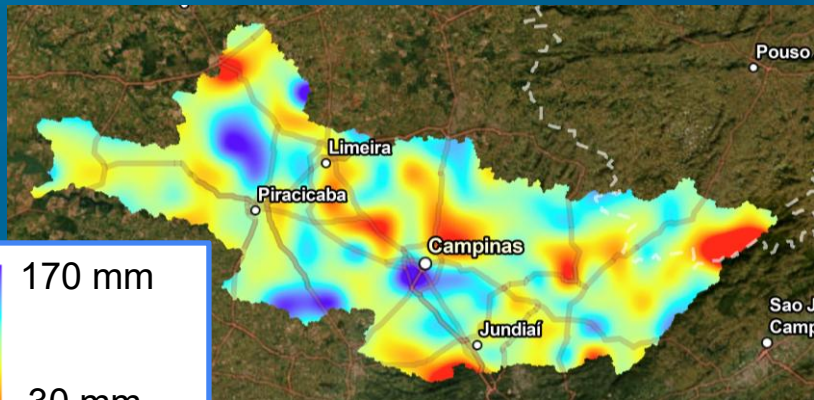


# O Futuro: Desafios e oportunidades para o PCJ

# Inteligência Artificial + SR = Águas Subterrâneas



# Inteligência Artificial + SR = Águas Subterrâneas



Alta porcentagem da água subterrânea na resposta do TWS.

Recarga: Embasamento 3-6%

Bauru - Cauia 10-12% 183 mm

Guarani 12-15% 190 mm

# O Futuro: Desafios e oportunidades para o PCJ

Qual o impacto do uso das águas subterrâneas na bacia?

O uso subterrâneo pode afetar os cursos superficiais?

O que é necessário para a compreensão das águas subterrâneas na PCJ?

Oportunidade: Monitoramento!

Cerca de 80% das empresas no Brasil investiram ou vão investir em IA nos próximos



## Governo Federal anuncia plano de investimentos em Inteligência Artificial



Publicado: 14/08/2024 11:03 Última Atualização: 14/08/2024 11:03



Será investido R\$ 1,76 bi em IA para melhorar serviços públicos e capacitar 115 mil

O que você procura?

### PESQUISA CIENTÍFICA

# Brasil produz 6,3 mil estudos sobre inteligência Artificial

Segundo relatório da Clarivate, País está entre as 20 nações com mais publicações sobre o tema entre 2019 e 2023

17/09/2024 19h11 • Atualizado 4 semanas atrás



30/07/2024 às 16:57

#### Economia

Microsoft vai investir quase R\$ 15 bi em inteligência artificial no Brasil

ESTADÃO conteúdo

São Paulo

27/09/2024 07h32



## Uso de Inteligência Artificial aumenta e alcança 72% das empresas, diz pesquisa

Avanço é significativo comparado aos 55% em 2023

Marién Ramos, da CNN

08/06/2024 às 12:29



# Aplicações:

Mapeamento,  
monitoramento,  
modelos regionais,  
qualidade,  
gestão...



Research Paper/

## Groundwater Potential Mapping Using GIS-Based Hybrid Artificial Intelligence Methods

Tran Van Phong ✉, Binh Thai Pham ✉, Phan Trong Trinh ✉, Hai-Bang Ly ✉, Quoc Hung Vu ✉, Lanh Si Ho ✉, Hiep Van Le, Lai Hop Phong ✉, Mohammadtaghi Avand ✉, Indra Prakash ✉

First published: 21 March 2021 | <https://doi.org/10.1111/gwat.13094> | Citations: 27

### scientific reports

[Explore content](#) ▾ [About the journal](#) ▾ [Publish with us](#) ▾

[nature](#) > [scientific reports](#) > [articles](#) > [article](#)

Article | [Open access](#) | Published: 26 June 2023

## Data driven of underground water level using artificial intelligence hybrid algorithms

[Mohammadtaghi Rahimi](#) & [Hossein Ebrahimi](#) ✉

[Scientific Reports](#) **13**, Article number: 10359 (2023) | [Cite this article](#)

[nature](#) > [scientific reports](#) > [articles](#) > [article](#)

Article | [Open access](#) | Published: 18 July 2024

## Groundwater contamination modelling in Ayad River Basin, Udaipur

[Kuldeep Pareta](#) ✉

[Scientific Reports](#) **14**, Article number: 16624 (2024) | [Cite this article](#)

## Water Resources Research

Research Article

## Large-Scale Groundwater Monitoring in Brazil Assisted With Satellite-Based Artificial Intelligence Techniques

Clyvihk Renna Camacho, Augusto Getirana ✉, Otto Corrêa Rotunno Filho, Maria Antonieta A. Mourão

First published: 20 August 2023 | <https://doi.org/10.1029/2022WR033588>

Research Article

## Groundwater quality parameters prediction based on data-driven models

[Mohammed Falah Allawi](#) ✉, [Yasir Al-Ani](#), [Arkan Dhari Jalal](#), [Zainab Malik Ismael](#), [Mohsen Sherif & Ahmed El-Shafie](#)

Article: 2364749 | Received 18 Mar 2024, Accepted 31 May 2024, Published online: 13 Jun 2024

✉ Cite this article | <https://doi.org/10.1080/19942060.2024.2364749> | [Check for updates](#)

[Open Access](#) [Review](#)

## Revolutionizing Groundwater Management with Hybrid AI Models: A Practical Review

by [Mojtaba Zaresefat](#) <sup>1,\*</sup> ✉ and [Reza Derakhshani](#) <sup>2,3</sup> ✉

<sup>1</sup> Copernicus Institute of Sustainable Development, Utrecht University, 3584 CB Utrecht, The Netherlands

<sup>2</sup> Department of Geology, Shahid Bahonar University of Kerman, Kerman 76169-13439, Iran

<sup>3</sup> Department of Earth Sciences, Utrecht University, 3584 CB Utrecht, The Netherlands

\* Author to whom correspondence should be addressed.

*Water* **2023**, *15*(9), 1750; <https://doi.org/10.3390/w15091750>

Camacho, C.R. et al. (2023) “Large-Scale Groundwater Monitoring in Brazil Assisted With Satellite-Based Artificial Intelligence Techniques”, *Water Resources Research*, 59(9), p. e2022WR033588. Available at: <https://doi.org/10.1029/2022WR033588>.

Razavi, S., Tolson, B. A., & Burn, D. H. (2012). Review of surrogate modeling in water resources. *Water Resources Research*, 48(7). <https://doi.org/10.1029/2011WR011527>

Rajaei, T., Ebrahimi, H., & Nourani, V. (2019). A review of the artificial intelligence methods in groundwater level modeling. *Journal of Hydrology*, 572(December 2018), 336–351. <https://doi.org/10.1016/j.jhydrol.2018.12.037>

Tao, H., Hameed, M. M., Marhoon, H. A., Zounemat-Kermani, M., Heddad, S., Kim, S., et al. (2022). Groundwater level prediction using machine learning models: A comprehensive review. *Neurocomputing*, 489, 271–308. <https://doi.org/10.1016/j.neucom.2022.03.014>

Nourani, V., Jabbarian Paknezhad, N., Ng, A., Wen, Z., Dabrowska, D., & Üzelaltınbulat, S. (2024). Application of the machine learning methods for GRACE data based groundwater modeling, a systematic review. *Groundwater for Sustainable Development*, 25(February), 101113. <https://doi.org/10.1016/j.gsd.2024.101113>

**CT-AS**  
Câmara Técnica de  
Águas Subterrâneas



**CT-Indústria**  
Câmara Técnica de Uso e  
Conservação de Água na Indústria

**CT-MH**  
Câmara Técnica de  
Monitoramento Hidrológico

**AgSolve**  
**GeoAcqua**

**edisonda**  
soluções em tecnologia



**UNIPER**  
AGORA TUBARÃO



**Sigesp**



**Hidrostudio**  
engenharia



**SGBX**  
**SERVIÇO GEOLÓGICO**  
**DO BRASIL - CPRM**



UNIVERSIDADE FEDERAL  
DO RIO DE JANEIRO



**COPPE**  
UFRJ


Instituto Alberto Luiz Coimbra de  
Pós-Graduação e Pesquisa de Engenharia



**Programa de Engenharia Civil**

COPPE - Universidade Federal do Rio de Janeiro





OBRIGADO.  
[clyvihk.camacho@sgb.gov.br](mailto:clyvihk.camacho@sgb.gov.br)