

Nº 179868


Piscou? Nasceu outro modelo! Como acompanhar a velocidade da IA?

Eric Tadeu Camacho Oliveira
Adriana Camargo de Brito

*Palestra apresentada no IPT,
30/09/2025. 28 slides*

A série “Comunicação Técnica” compreende trabalhos elaborados por técnicos do IPT, apresentados em eventos, publicados em revistas especializadas ou quando seu conteúdo apresentar relevância pública.

PROIBIDO A REPRODUÇÃO, APENAS PARA CONSULTA.



PISCOU? NASCEU OUTRO MODELO! COMO ACOMPANHAR A VELOCIDADE DA IA?

**Eric Tadeu Camacho de Oliveira
Adriana Camargo de Brito**

Quantos novos modelos de IA de impacto vocês acham que foram lançados em Setembro de 2025?

SÓ EM SETEMBRO, ATÉ DIA 28/09, TIVEMOS 12 MODELOS DE IMPACTO

Language

Grok 4 Fast
Magistral Small 1.2
Magistral Medium 1.2
Granite-Docling
Qwen3-Next-80B-A3B
K2 Think
Qwen3-Max
EmbeddingGemma
Apertus 8B
Apertus 70B
LongCat-Flash

Multimodal

Magistral Small 1.2
Granite-Docling

Vision

Magistral Small 1.2
Granite-Docling

Speech

Chatterbox Multilingual

ATUALIZAÇÃO - NOVO MODELO SAINDO DO FORNO

29/09/2025 - [DeepSeek-V3.2-Exp](#)


- Lançado como evolução de V3.1-Terminus
- Introduz **DeepSeek Sparse Attention (DSA)** para otimizar eficiência em contextos longos
- Licença: MIT (permite uso comercial / acadêmico)
- **Escalabilidade:** menos custo computacional no treino e inferência

 Experimental 

OBJETIVO DE HOJE

- 1) Apresentar o problema da "**Sobrecarga de Informação sobre as IAs**"
- 2) O que nos levou até esse momento?
- 3) Estratégias para acompanhar essa quantidade de lançamentos

LINHA DO TEMPO (1950 - 2025)



epoch.ai/data/ai-models

A ACELERAÇÃO DA IA - DE ONDE VIEMOS?

A inovação atual é construída sobre décadas de pesquisa

Marcos Relevantes

- **BERT (2018 · Google)** - Introdução a compreensão mais profunda sobre o contexto da linguagem
- **GPT-3 (2020 · OpenAI)** - Poder de escala e popularizou a IA Generativa
- **ChatGPT (2022 · OpenAI)** - Adoção rápida da IA para público geral e corporativo

Ciclo de Aceleração

Avanços → Ferramentas Acessíveis → Adoção em Massa → + Investimento → + Aceleração

[The Evolution of Generative AI: 2018–2025 Timeline Revealed](#)

A EXPLOÇÃO DE 2023-2025

O que antes levava anos, agora está acontecendo em **meses/semanas**

Alguns exemplos:

- **GPT-4 (Mar/2023 · OpenAI)** – Multimodalidade com imagens
- **Llama 2 (Jul/2023 · Meta)** - Democratização com open-source
- **Claude 3 (Mar/2024 · Anthropic)** - Ultrapassou GPT-4 em vários benchmarks
- **Llama 3 (Abr/2024 · Meta)** – Competitividade open-source
- **GPT-4o (Mai/2024 · OpenAI)** – Multimodalidade nativa

- **Llama 3.1 405B (Jul/2024 · Meta)** – Paridade open-source com modelos proprietários
- **Llama 3.3 70B (Dez/2024 · Meta)** - Desempenho aprimorado em instruções e código
- **Qwen2.5-Max (Jan/2025 · Alibaba)** - Superou GPT-4o e Claude 3.5 em alguns benchmarks
- **Grok 3 (Fev/2025 · xAI)** - Avanço em raciocínio e geração de imagens
- **Gemma 3 Series (Mar/2025 · Google/DeepMind)** – Modelos leves, open-source, versões multimodais e multilíngues

Ser o "**melhor modelo**" é passageiro

AI Timeline

ALÉM DO TEXTO: A ERA DA MULTIMODALIDADE

A IA agora Vê, Ouve e Fala

A inovação não é mais apenas sobre texto; é sobre expandir os tipos de dados que a IA entende e gera

- **Vídeo:** Sora (OpenAI), Veo (Google), Movie Gen (Meta)
- **Áudio e Música:** Suno AI (criação de músicas completas com vocais)
- **Multimodalidade Integrada:** GPT-4o e Gemini podem processar texto, áudio e imagens em tempo real

PROBLEMA: SATURAÇÃO DE BENCHMARKS

Os modelos estão melhorando tão rápido que os testes ficaram obsoletos, tornando as pontuações um indicador enganoso do valor real

AI Agent Benchmarks are Broken

Can We Trust AI Benchmarks? An Interdisciplinary Review of Current Issues in AI Evaluation

OS MOTORES DA ACELERAÇÃO: A CORRIDA GEOPOLÍTICA

Nova Corrida de Superpotências

A competição global, especialmente entre EUA e China, é um dos principais catalisadores do investimento e da inovação

EUA vs China


- Investimento Privado
- Produção de Modelos
- Qualidade



INVESTIMENTO PRIVADO EM IA

Global private investment in AI by geographic area, 2013–24


Source: Quid, 2024 | Chart: 2025 AI Index report



NÚMERO DE PUBLICAÇÕES

Number of highly cited publications in top 100 by select geographic areas, 2021–23


Source: AI Index, 2025 | Chart: 2025 AI Index report



PERFORMANCE DOS MODELOS EUA - CHINA

Performance of top United States vs. Chinese models on LMSYS Chatbot Arena

Source: LMSYS, 2025 | Chart: 2025 AI Index report



Estratégias:

- **EUA/Ocidente:** Foco em um ambiente "**pró-inovação**" liderado pelo setor privado
- **China:** Abordagem "**top-down**" dirigida pelo Estado, com metas claras para liderança global até 2030

Europe's AI strategy is no match for China's drive for global dominance (Jun 29, 2018)

OS MOTORES DA ACELERAÇÃO: O VOLANTE TECNOLÓGICO

Da escala bruta à eficiência inteligente

O foco mudou de modelos maiores para modelos mais **eficientes** e **capazes**


Tendências:

- **Economia da Inferência:** O custo para executar modelos caiu drasticamente, tornando aplicações complexas economicamente viáveis
- **Ascensão do Raciocínio:** Modelos como o *o1* da OpenAI são projetados para resolver problemas com passos lógicos, não apenas reconhecer padrões
- **O Futuro "Agêntico":** A eficiência permite que a IA execute tarefas de forma autônoma (agentes)
- **Hardware Especializado:** Chips customizados como LPUs (Groq) e TPUs (Google) superam GPUs em eficiência para inferência

PREÇO DE INFERÊNCIA

Inference price across select benchmarks, 2022–24




Source: Epoch AI, 2025; Artificial Analysis, 2025 | Chart: 2025 AI Index report



RACIOCÍNIO

GPT-4o vs. o1-preview vs. o1 on select benchmarks

Source: OpenAI, 2024 | Chart: 2025 AI Index report



A GRANDE DIVISÃO: OPEN-SOURCE VS PROPRIETÁRIO

- **Código Aberto (Open-Source):** Componentes publicamente disponíveis (ex: Llama da Meta, modelos da Mistral)
 - Permite uma maior modificação e personalização
- **Proprietário (Fonte Fechada):** Controlado por uma empresa (ex: GPT da OpenAI, Claude da Anthropic)
 - Acesso via APIs pagas

ANÁLISE COMPARATIVA

Critério	Open Source	Proprietário
Custo	Gratuito	Pago
Personalização	Máxima	Limitada
Desempenho	Se aproximando rapidamente	Ainda lidera
Segurança	Transparência	Segurança gerenciada

O HUB DO CÓDIGO ABERTO: HUGGING FACE

Onde a comunidade de IA se encontra

Principais Funções:

- **"GitHub para a IA"**: Repositório central com milhares de modelos e datasets
- **Bibliotecas Padrão**: Ferramentas como *transformers* e *diffusers* que simplificam o desenvolvimento
- **Comunidade Ativa**: Conectando desenvolvedores, pesquisadores e grandes empresas de tecnologia

COMO ACOMPANHAR A INOVAÇÃO DIÁRIA? - PARA OS TÉCNICOS

- **ArXiv.org:** Onde a pesquisa de ponta e atual aparece primeiro
- **Blogs de Laboratórios de IA:** OpenAI, Google AI, DeepMind

Showing 1–50 of 2,319 results

Search v0.5.6 released 2020-02-24

Query: order: -submitted_date; size: 50; date_range: from 2025-09-01 to 2025-09-29; include_cross_list: True; terms: AND all=Artificial Intelligence OR Language Models

Simple Search

Refine query New search

50 results per page. Sort results by Submission date (newest first) Go

1 2 3 4 5 ...

Next

1. [arXiv:2509.22653](#) [pdf, ps, other] [cs.RO](#) [cs.AI](#) [cs.CL](#) [cs.CV](#) [cs.LG](#)

See, Point, Fly: A Learning-Free VLM Framework for Universal Unmanned Aerial Navigation

Authors: Chih-Yao Hu, Yang-Sen Lin, Yuna Lee, Chih-Hai Su, Jie-Ying Lee, Shr-Ruei Tsai, Chin-Yang Lin, Kuan-Wen Chen, Tsung-Wei Ke, Yu-Lun Liu

Abstract: We present See, Point, Fly (SPF), a training-free aerial vision-and-language navigation (AVLN) framework built atop vision-... [More](#)

Submitted 26 September, 2025; originally announced September 2025.

Comments: CoRL 2025. Project page: <https://spf-web.pages.dev>

2. [arXiv:2509.22651](#) [pdf, ps, other] [cs.CL](#) [cs.AI](#) [cs.CV](#) [cs.HC](#) [cs.SD](#)

VoiceAssistant-Eval: Benchmarking AI Assistants across Listening, Speaking, and Viewing

Authors: Ke Wang, Houxing Ren, Zimu Lu, Mingjie Zhan, Hongsheng Li

Abstract: The growing capabilities of large language... [More](#)

Submitted 26 September, 2025; originally announced September 2025.

3. [arXiv:2509.22647](#) [pdf, ps, other] [cs.CV](#) [cs.AI](#) [cs.CL](#)

CapRL: Stimulating Dense Image Caption Capabilities via Reinforcement Learning

Authors: Long Xing, Xiaoyi Dong, Yuhang Zang, Yuhang Cao, Jianze Liang, Qidong Huang, Jiaqi Wang, Feng Wu, Dahua Lin

Abstract: Image captioning is a fundamental task that bridges the visual and linguistic domains, playing a critical role in pre-training Large Vision-Language... [More](#)

[More](#)

Submitted 26 September, 2025; originally announced September 2025.

Comments: Code is available at <https://github.com/InternLM/CapRL>

COMO ACOMPANHAR A INOVAÇÃO DIÁRIA? - PÚBLICO NO GERAL

Newsletters

- [AI Agents | RAG | LLMs](#)
- [Neural Bits](#)
- [The Batch](#)
- [Superhuman AI newsletter](#)
- [IA Sob Controle](#)
- [AI & Future Tech Trends](#)
- [Artificial Intelligence](#)
- [The Neural Maze](#)
- [Top AI Papers of the Week](#)
- [LLM Watch](#)

- [Daily Dose of Data Science](#)
- [The Rundown AI](#)
- [TLDR AI](#)

Youtube

- [Inteligência Mil Grau](#)
- [Andrej Karpathy](#)
- [Asimov Academy](#)
- [Sebastian Raschka](#)

Podcasts

- [IA Sob Controle](#)

COMO ACOMPANHAR A INOVAÇÃO DIÁRIA? - PÚBLICO NO GERAL

LinkedIn

- [Avi Chawla](#)
- [Elvis S.](#)
- [Pascal Biese](#)
- [Akshay Pachaar](#)
- [João \(Joe\) Moura](#)
- [Ben Burtenshaw](#)
- [Miguel Otero Pedrido](#)
- [Anderson L. Amaral](#)
- [Alex Razvant](#)
- [Andriy Burkov](#)

- [Maryam Miradi](#)
- [Bob Inteligência Mil Grau](#)
- [Mario Filho](#)
- [Sai Charan](#)
- [Elisa Terumi](#)
- [Taranjeet Singh](#)
- [Md Amanatullah](#)
- [Samuel Matioli](#)
- [Tony Kipkemboi](#)
- [Kalyan KS](#)
- [Daniel Han](#)
- [Banias Baabe](#)

- [Celso Sousa](#)

Fóruns

- [Alignment Forum](#)
- [OpenAI Forum](#)
- [Google AI Forum](#)

Slack

- [AI Agents BR](#)

Discord

- [HuggingFace](#)
- [Learn AI Together](#)

DOMINANDO A SOBRECARGA DE INFORMAÇÃO

É impossível acompanhar tudo

Estratégias Práticas:

- **Definir quais conteúdos priorizar**
 - **Não precisa conhecer todos os modelos** → focar nos que resolvem seu problema
- **Criar um email** que focará em receber as atualizações (cadastrar em newsletters, blogs, ferramentas de IA)
- **Criar uma rotina** para ler as atualizações (Ex: 15 minutos todos os dias)

DOMINANDO A SOBRECARGA DE INFORMAÇÃO

- Utilizar ferramentas como **Obsidian/Notion**, para salvar e organizar as informações e **Raindrop.io** para salvar links
- **Modo expert:** Criar um sistema com agentes de IA que receberão as atualizações vindas de várias fontes e farão um resumo para você!

Obrigado!



linkedin.com/school/iptsp/



instagram.com/ipt_oficial/



youtube.com/@IPTbr/

www.ipt.br

