# A CONTA DA IA CAI QUANDO A EMPRESA ESCOLHE, NÃO QUANDO O TOKEN BARATEIA

IA · LA AGÊNTICA · EFICIÊNCIA · GOVERNANÇA DE DADOS

**Arvind Jain**
Fundador e CEO da Glean, plataforma de IA corporativa que conecta buscas interna, assistente e agentes sobre os dados da empresa.

**Muhammad Lila**
Founder, Goodable

## EM 30 SEGUNDOS

**Arvind Jain, CEO da Glean, plataforma de IA corporativa, vê a IA disputando orçamento com gente pela primeira vez, e a conta nada mais a mais mesmo com o token mais barato.**

**Quase toda empresa com que a Glean conversa sente que gasta demais com IA sem retorno; para Jain, o retorno vem quando a empresa para de dar ferramentas a todos e escolhe onde usar.**

O OLHAR DA CURADORIA
**Natália Schifino**
Curadora da FFX

**DESTAQUE:** a economia de tokens que vem de investir na escolha do modelo certo para cada tarefa.

**APONTO:** que montar os agentes de cima para baixo aumenta a eficiência: pensar nos cinco que de fato mudam o negócio e trabalhar neles.

NÚMEROS DO PALCO

**95%**
Tarefas corporativas que modelos 10 a 20 vezes mais baratos resolvem.

**mais de 90%**
Corte de custo de IA em cenários onde as agente e modelo certo por tarefa

**90% a 95%**
Redução de custo feito com IA que não agrega valor, para Jain

PARA LEVAR

1. **Troque a ferramenta de IA para todos por uma lista curta de agentes, decidida pela diretoria.**
2. **Mande cada tarefa ao modelo mais barato que dê conta dela e deixe o mais caro para o que exige.**
3. **Entregue ao agente os documentos e dados da empresa já organizados, para ele não gastar tokens procurando.**

O ARTIGO · 2 MIN DE LEITURA

## Esperar que a IA faça mais barata não reduz a fatura de uma empresa: o uso cresce mais rápido que o preço cai.

O diagnóstico é de Arvind Jain, fundador e CEO da Glean, plataforma de IA corporativa, em entrevista no AI Summit do Web Summit Lisboa. **Natália Schifino, curadora da FFX, destacou duas saídas dele: o modelo certo para cada tarefa e os agentes escolhidos de cima para baixo.**

O preço por unidade de inteligência vai continuar caindo, admite Jain, inclusive com modelos abertos feitos para tarefas específicas. Mesmo assim, a IA chegou a um lugar inédito no orçamento: pela primeira vez que tratamos software e tecnologia no mesmo patamar das pessoas em termos de quanto custam." Foto do palco, uma simulação de. Acontece de julho de 2026 mostra o efeito se o token (a unidade em que os modelos cobram) ficasse 25% mais barato. 95% das organizações apresentariam a economia.

A primeira saída é gastar menos tokens escolhendo o modelo. Para Jain, quase todas as tarefas de uma empresa cabem em modelos que custam um décimo ou um vigésimo dos mais caros. A segunda é o contexto. Um assistente ligado aos sistemas da empresa gasta tokens só para achar documentos e dados antes de trabalhar; se recebe esse material pronto, organizado e mastigado de contexto, consome metade. **Somadas, as duas frentes cortam mais de 90% da conta, segundo Jain.** Vale lembrar que a camada de contexto é o que a Glean vende.

A economia com o modelo certo, porém, pode não chegar à fatura. A própria Accenture conta que sua plataforma interna manda cada tarefa ao modelo adequado por cerca de um sexto do custo dos modelos mais potentes. **Mesmo assim, quando o padrão era um modelo intermediário, grande parte dos funcionários ainda escolhia o mais potente.**

**Cinco passos para a fatura de IA encolher**

1. **Mapear** — Achar os processos internos que mais custam
2. **Priorizar** — Achar uma lista de onde agentes
3. **Modelo** — Usar o mais barato que dê conta da tarefa
4. **Contexto** — Entregar dados prontos e gastar metade dos tokens
5. **Resultado** — Conta mais de 90% menor, segundo Jain

Quando cada funcionário decide como usar a IA, o resultado é desperdício, Jain cuve com frequência que 80% do trabalho feito com IA não agrega valor e avalia que a fatia chega a 90% ou 95%: documentos de 50 a 100 páginas, agentes a habilidades de baixa qualidade. A saída que Natália apontou é definir os agentes de cima para baixo, concentrados nos cinco que de fato pesam no negócio.




AI FIRST DAY, DE DIOGO CUNHA E EDITH MORPURGO NA FOZ DE 2025 | © AI Summit. Foto: cedidos FFX no Web Summit 2025

## QUANDO VOCÊ MUDA SUA ESTRATÉGIA PARA SER MAIS INTENCIONAL, MAIS DE CIMA PARA BAIXO, É AÍ QUE COMEÇA A TER RETORNO REAL EM VALOR DE NEGÓCIO.

**Arvind Jain**, Founder & CEO da Glean

O método de Jain começa pelos processos internos mais caros e termina numa lista curta: apenas são os cinco que "vale a pena mesmo construir para automatizar estes cinco processos de negócio diferentes" **Jain reconhece o custo da escolha: o uso espalhado, mesmo cheio de lixo, ensina as equipes e muitas vezes as faz trabalhar mais rápido.**

**Quem decide o uso decide a conta**

| IA de cima para baixo | IA aberta a todos |
|---|---|
| **Decisão**<br>Quem paga escolhe processos, modelos e contexto | **Decisão**<br>Cada funcionário escolhe com ver a fatura |
| **Foco**<br>Cinco agentes ligados ao que gera no negócio | **Foco**<br>Até 95% do trabalho sem valor |
| **Retorno**<br>Valor de negócio mensurável | **Ganho**<br>Equipes aprendem a as vezes aceleram |

**Para a FFX, os dois pontos de Natália levam à mesma pergunta: quem decide o uso a IA é usada.** Na IA de cima para baixo, quem responde pelo custo escolhe os processos, o modelo e o contexto. Na ferramenta aberta a todos, escolhe quem não vê a conta. Enquanto for assim, cada queda no preço do token vira mais uso, e a fatura vista a subir.

LEITURA FFX

## O preço do token é do fornecedor; quantos tokens se gastam, e em que modelo, é decisão da empresa.

No Brasil, poucas ofram essa conta: só 45% das empresas acompanham o custo por token, embora 90% esperem consumir mais nos próximos 12 meses (pesquisa IDC para a Dell, Mobile Time, 2026).

O DS Bank montou uma estrutura própria que troca de modelo sem depender de um único fornecedor e reserva os modelos mais caros às tarefas complexas, porque usá-los em tudo seria desperdício (Mobile Time, 2026).

**Antes de liberar mais verba, faça como o DS: defina qual modelo cada caso de uso pode chamar e cobre cada área o custo por token do que ela consome.**

PROVOCAÇÃO FFX

## SE A SUA EMPRESA SÓ PUDESSE TER CINCO AGENTES DE IA, VOCÊ SABERIA DIZER QUAIS?

RETRATO DA EMPRESA — GLEAN

Plataforma de IA corporativa que conecta documentos, e-mail, CRM e tickets da empresa e oferece busca, assistente e agentes sobre vários modelos de linguagem.

**US$ 200** milhões de receita recorrente anual em 2025, o triplo de 15 meses antes (Latent Space, 2026)

**US$ 200** milhões de receita recorrente anual em dezembro de 2025 (Furtuna, 2026)

Avaliação de **US$ 7,2** bilhões na Série F de US$ 150 milhões, um jump de 2025 (Glean, 2025)

Leandro Lima, ex-Snowflake Brasil, contratado como VP para a América Latina em julho de 2026 (Exagone, 2026)

PONTOS

1. Accenture: IA Tokenomics para garração de valor empresarial (29 jul. 2025)
2. Mobile Time: Apenas 45% das empresas brasileiras usam IA, aponta pesquisa da Dell com IDC (5 nov. 2025)
3. Mobile Time: Empresas querem mais previsão para custos no uso da IA (24 jul. 2025)
4. Latent Space: Glean model routing (jun. 2026)
5. Furtuna: Glean hits $200 million ARR (9 dez. 2025)
6. Glean Press: Série F de US$ 150 milhões a US$ 7,2 bilhões (jun. 2025)
7. Exagone: Glean agora tem VP Latam (17 jul. 2026)
8. IDC, Cost of Cloud, Multicloud Report 2026, ricerca Brasil (Canaltech, 15 out. 2026)