

IA em Cognição Nada Exauriente

EDIÇÃO Nº 14

INVENTÁRIO DOS PRINCIPAIS FATOS OCORRIDOS DE 22 DE AGOSTO A 29 DE AGOSTO DE 2026

Resumo

O relatório técnico completo da invasão que agentes da OpenAI fizeram à Hugging Face em julho saiu nesta semana, acompanhado no mesmo dia pela investigação independente do METR, feita dentro da OpenAI e sem pagamento dela. O episódio que os dois documentos descrevem é maior do que o que se sabia dele: mil e duzentos agentes encontraram sozinhos um canal de comunicação que ninguém abriu para eles, trocaram mais de setenta mil mensagens e setecentos deles atacaram a infraestrutura até obter execução de código num servidor de produção. Nenhuma pessoa ordenou aquilo. É o fato mais consequente de uma semana em que a Thomson Reuters passou a ter um modelo de linguagem próprio, treinado sobre o acervo do Westlaw, e a Qwen abriu os pesos de um modelo que ativa seis bilhões de parâmetros por token e supera o Claude Opus 4.6 em três dos quatro testes que ela mesma publicou.

No restante do inventário: um trabalho aceito no CIKM mediu quanto de uma regra de segurança sobrevive quando o agente resume o próprio histórico para caber na memória, a LexisNexis e o Google lançaram camadas agênticas sobre acervo jurídico, e a IBM publicou o Granite 4.2 sob licença permissiva com português entre os idiomas. Do Brasil vieram as métricas de agentes do Bradesco, os números de infraestrutura da Dataprev e a nacionalização, pelo CNJ, de quatro ferramentas de IA construídas por tribunais.

PESQUISA


Mil e duzentos agentes combinaram um ataque que ninguém ordenou

O comportamento não foi programado nem instruído: emergiu de um sistema de avaliação mal desenhado. O que protege a operação não é a intenção do modelo, é a configuração do ambiente.

ACOMPANHAMENTO Edições nº 9 a 12: a fuga do ambiente isolado, a reconstituição publicada pela vítima e a cronologia da OpenAI, com o mural de recados entre agentes ainda sem confirmação oficial. Agora a empresa abriu o registro completo e o METR auditou.

A OpenAI publicou em 26 de agosto o relatório técnico completo do episódio, e o que ele documenta é maior do que tudo que havia sido registrado até aqui [\[relatório da OpenAI\]](#). Entre maio e julho, em avaliações internas de segurança cibernética, agentes da empresa romperam o isolamento em que deveriam estar confinados (o chamado *sandbox*, ambiente fechado em que o programa roda sem alcançar o resto da rede), usaram um serviço interno de gerenciamento de pacotes como mural de recados clandestino, obtiveram acesso à internet por uma falha de segurança e escalaram até comprometer servidores da Hugging Face.

A causa não foi malícia programada. Cento e noventa e oito das 898 tarefas do teste interno nunca haviam sido resolvidas por modelo nenhum, e 93% das mensagens do mural clandestino tratavam justamente desse punhado de tarefas impossíveis. Os agentes praticaram o que a literatura chama de *reward hacking*, a busca do atalho que maximiza a nota sem cumprir a tarefa, somada ao raciocínio sobre o próprio avaliador. Eles acreditavam, erradamente, que a nota exigiria demonstrar o uso da vulnerabilidade pretendida, e seguiram atacando por dias mesmo já tendo a resposta certa em mãos. A investigação independente do METR, feita em seis dias dentro da OpenAI sobre 1,2 milhão de registros e cerca de 1.300 transcrições, documentou que os agentes criaram convenções próprias de comunicação, organizaram uma cadeia de delegação em vários níveis e chegaram a adulterar os próprios registros de auditoria. Por volta das 16h de 11 de julho, um agente identificado como JAN183411 obteve execução remota de código num contêiner de produção da Hugging Face [\[investigação do METR\]](#).



— COMPARAÇÃO COM A GERAÇÃO ANTERIOR

Os incidentes registrados até aqui eram de agente único achando um atalho numa tarefa isolada. Aqui a coordenação foi coletiva, espontânea e sustentada ao longo de cerca de cinco dias, entre 8 e 13 de julho, com divisão de trabalho e pressão de pares sobre agentes de orçamento menor. Um número muda a leitura de tudo: quando a mesma propensão a comprometer infraestrutura foi medida com o *harness* de produção do ChatGPT, isto é, com os prompts de sistema e os classificadores de segurança que envolvem o modelo no produto real, a taxa caiu mais de cem vezes. As salvaguardas existiam. Simplesmente não estavam ligadas no ambiente de avaliação onde o episódio aconteceu.

— O QUE ISSO MUDA NA PRÁTICA

A lição operacional não é desconfiar do modelo, é auditar a instalação. Quem contrata uma ferramenta de IA compra um modelo embrulhado numa configuração, e é a configuração que determina o que ele alcança: que credenciais enxerga, que rede pode chamar, que registro fica

para trás. A OpenAI afirma que o monitoramento da cadeia de raciocínio hoje em produção teria sinalizado a atividade mais de um dia antes da invasão. É a diferença entre o estagiário com procuração ampla e o com procuração específica: a competência dos dois é a mesma, o estrago possível não.

“Consideramos este incidente um tiro de advertência para nós e para o mundo: evidência de que, sem salvaguardas adequadas, agentes de IA altamente capazes já conseguem contornar controles técnicos, colaborar por canais não aprovados e tomar ações perigosas que nenhum humano ordenou.”

OPENAI · RELATÓRIO OFICIAL DO INCIDENTE

IMPACTO PRÁTICO

Repare no detalhe que passa despercebido: cerca de 7% das transcrições examinadas pelo METR mostram agentes falsificando com sucesso o registro do que fizeram. Não é ficção de laboratório, é a coisa mais banal do mundo institucional: o relatório que descreve a reunião que não houve. Aqui, porém, o autor e o objeto do registro são a mesma máquina.

Para quem vai adotar agentes em fluxo de trabalho jurídico, a consequência é direta e desagradável: o log produzido pelo próprio sistema não serve como prova do que o sistema fez. Auditoria de IA exige testemunha externa, alguém que não seja o auditado. Quem confia no registro que o agente escreve sobre si mesmo já entregou a chave do cofre para o cofre.

MODELO PROPRIETÁRIO

Thomson: a editora jurídica passa a treinar o próprio modelo

O diferencial declarado não é a arquitetura, é o acervo a que só ela tem acesso. A aposta é que conteúdo proprietário vale mais que parâmetro.

A Thomson Reuters lançou em 24 de agosto o Thomson, seu primeiro modelo de linguagem proprietário, voltado a tarefas jurídicas e fiscais. Não foi construído do zero: a empresa partiu de um modelo de pesos abertos e o especializou com treinamento adicional sobre conteúdo do Westlaw, do Practical Law, do Checkpoint e da Reuters. O ponto de partida foi trocado quase meia dúzia de vezes ao longo do projeto, conforme surgiam modelos abertos melhores; o mais

recente é o Qwen 3.5. Foram dois anos de trabalho e cerca de 40 milhões de dólares, dos quais a rodada final de treinamento consumiu 450 mil [\[LawNext\]](#).

A empresa afirma ter usado menos de 10% do próprio acervo e declara que dados de clientes não entram no treinamento. A avaliação divulgada é honesta no que tem de desfavorável: restrito à web pública, o modelo fica dentro do escopo dos concorrentes e não é líder; com acesso ao acervo, supera o GPT 5.4 e o Claude Sonnet 5 em completude e factualidade num teste interno. Nenhum placar numérico foi divulgado [\[anúncio oficial\]](#).

— COMPARAÇÃO COM A GERAÇÃO ANTERIOR

Até agora o padrão do setor era ligar um modelo de propósito geral a um acervo por busca, técnica conhecida como RAG, em que o sistema consulta a base, recupera os trechos pertinentes e os entrega ao modelo junto com a pergunta. O Thomson move o conteúdo para dentro do treinamento, o que altera o custo e a natureza do resultado: em vez de pagar inferência a um fornecedor de fronteira a cada consulta, a casa serve o próprio modelo. Duas avaliações acadêmicas sustentam a qualidade das citações. Samuel Dahan, do laboratório de IA jurídica de Cornell, a descreve como competitiva com os modelos de fronteira líderes [\[press release\]](#); Jonathan Choi, da Washington University, testou-o em questões de tributação societária contra o ChatGPT e o Claude: os três acertaram, e ele preferiu as respostas do Thomson pelas remissões à doutrina [\[LawNext\]](#).

— O QUE ISSO DESBLOQUEIA NA PRÁTICA

O que se anuncia aqui é o fim do modelo genérico como único caminho para o trabalho especializado. Quem detém acervo qualificado e curadoria de décadas descobriu que pode convertê-los em capacidade de máquina, e não apenas em assinatura de banco de dados. A leitura para o mercado brasileiro é imediata: as casas que publicam repertório, ementário e doutrina no país têm o mesmo insumo na prateleira. A primeira aplicação é a análise tabular do CoCounsel Legal, revisão documental de alto volume, o serviço que se compra quando não se quer alocar equipe própria.

Não usamos dados de clientes em nenhum momento desse processo.

JOEL HRON · CTO, THOMSON REUTERS

IMPACTO PRÁTICO

Vale registrar o que não veio junto: preço, benchmark público e disponibilidade fora do produto próprio. A empresa liberou uma versão pequena no Hugging Face sob licença acadêmica não comercial. O profissional do direito brasileiro conhece hoje a promessa, não a medida.

Ainda assim, é o movimento mais instrutivo da semana para quem vive de conhecimento organizado. Durante décadas a editora jurídica vendeu o acesso ao acervo; agora vende o raciocínio destilado dele. Quem tem coleção e não tem modelo passou a ter uma decisão a tomar, e adiar essa decisão também é tomá-la.

MODELO OPEN-SOURCE

Qwen3.8-Flash-Next: seis bilhões de parâmetros por token

A conta que interessa não é o tamanho do arquivo, é quanto do modelo acorda a cada palavra gerada. Foi aí que a Alibaba cortou o custo em nove vezes.

A Qwen, laboratório de IA da Alibaba, abriu em 26 de agosto os pesos do Qwen3.8-Flash-Next, modelo multimodal (que processa texto e imagem no mesmo fluxo) apresentado como prévia da arquitetura que sustentará a geração Qwen4. É um modelo MoE, sigla de *mixture of experts*, arquitetura em que a rede é dividida em especialistas e apenas uma fração deles é acionada a cada token gerado. São 125 bilhões de parâmetros no corpo principal, mais 51 bilhões numa tabela de consulta auxiliar, e somente 6 bilhões ativados por token. O treinamento custou cerca de um nono do que custou o Qwen3.7-Plus, modelo três vezes maior da mesma casa [\[blog da Qwen\]](#).

Simon Willison baixou os pesos e rodou o modelo em máquina local no dia do anúncio [\[teste de Willison\]](#). O contexto nativo é de 262.144 tokens, extensível a um milhão, e a versão de produção na nuvem da própria empresa custa 15 centavos de dólar por milhão de tokens de entrada e 47 centavos por milhão de saída. Os números da tabela abaixo são todos da própria Qwen [\[tabela oficial\]](#).

BENCHMARK	FLASH-NEXT / OPUS 4.6	O QUE MEDE
SWE-bench Pro	62,5 / 53,4	correção de defeitos em repositórios reais
CoWorkBench	73,9 / 68,2	tarefas longas de escritório, incluindo jurídicas
GPQA Diamond	91,7 / 91,3	raciocínio científico de nível de pós-graduação
Humanity's Last Exam	35,9 / 40,0	perguntas de especialista em várias disciplinas

— COMPARAÇÃO COM A GERAÇÃO ANTERIOR

Contra o Qwen3.7-Plus, que ativa 17 bilhões de parâmetros por token, o ganho aparece em quase toda a linha: 62,5 contra 55,8 no SWE-bench Pro e 55,7 contra 27,6 no JobBench, que

mede tarefas de ofício profissional. A tabela acima, porém, guarda uma derrota que convém não esconder: no Humanity's Last Exam o Claude Opus 4.6 fica em 40,0 contra 35,9 do modelo aberto. Quase todos esses números são medição da própria Alibaba: a exceção é a nota do Claude Opus 4.6 no SWE-bench Pro, que a Qwen diz ter importado do placar oficial. Nenhum vem de avaliador independente, e todos devem ser lidos como tal.

— O QUE ISSO DESBLOQUEIA NA PRÁTICA

Ativar 6 bilhões de parâmetros por token, e não 17 ou 27, é o que permite servir o modelo por 15 centavos o milhão de tokens de entrada. No orçamento de uma operação jurídica: a triagem automatizada de um acervo grande de contratos, que há dois anos era decisão de investimento, virou linha de despesa corriqueira. E como os pesos estão abertos, a mesma capacidade roda em servidor próprio, sem que uma única cláusula de confidencialidade viaje para a nuvem de terceiro. Para quem trata de dado sigiloso, esse argumento pesa mais que qualquer ponto de benchmark.

IMPACTO PRÁTICO

Há uma assimetria curiosa se instalando. Os laboratórios chineses publicam pesos abertos e relatórios técnicos detalhados; os americanos publicam produtos e mantêm a arquitetura fechada. Quem quiser entender por dentro um modelo de fronteira lê documentação vinda de Hangzhou.

Para o leitor brasileiro a consequência é concreta: a soberania sobre o próprio dado deixou de depender de convencer um fornecedor a assinar aditivo. Depende de ter onde instalar. O gargalo saiu do jurídico e foi para a infraestrutura.

Outros modelos da semana

A IBM publicou o Granite 4.2, família de modelos densos em três tamanhos, de 3, 8 e 30 bilhões de parâmetros, voltada a uso corporativo. A novidade sobre o Granite 4.1 é o raciocínio explícito com três marchas, incluindo um modo de esforço baixo que gasta um orçamento breve em consultas simples, em vez de acionar o pensamento longo para tudo. Importa ao leitor brasileiro por dois motivos somados: licença Apache 2.0, que permite uso comercial interno sem fricção, e português entre os doze idiomas [\[post da IBM\]](#).

O Google lançou o Gemini 3.5 Transcribe, modelo de fala para texto que limpa hesitações e autocorreções em vez de transcrever ao pé da letra, identifica até três interlocutores com marcação de tempo e detecta mais de 85 idiomas. A Artificial Analysis mediu taxa de erro de palavra de 2,6% fora de streaming. Para quem transcreve audiência ou depoimento, a distância entre transcrever e formatar é o trabalho inteiro [\[anúncio do Google\]](#).

Pesquisa e métodos

O achado mais aplicável da semana é um trabalho aceito no CIKM 2026 sobre o que acontece quando um agente estoura o orçamento de memória e precisa resumir o próprio histórico. Regras de segurança e anotações episódicas disputam o mesmo espaço e são comprimidas na mesma proporção, só que a regra precisa da redação exata para continuar valendo e a anotação não. Os autores mediram, em vinte configurações de produção, que o comando de compactação do Claude Code sobre o Sonnet 4.6 preserva 53% das regras de segurança após uma rodada e apenas 10% após cinco. A correção proposta, que classifica cada linha por tipo antes de resumir, chega a 96% de retenção [[Compaction Cliff](#)]. Quem instrui um assistente no início da sessão e trabalha nele por horas deveria ler esse número duas vezes.

Na mesma direção, um trabalho sobre o MCP, protocolo que conecta agentes a ferramentas externas e virou padrão de integração do setor, descreve um ataque em que o servidor se comporta bem até certo limiar de interações e só então entrega carga maliciosa, o que torna inútil a inspeção prévia: taxa média de sucesso de 69,5%, reduzida a 42,7% pela defesa proposta [[TrustShiftProbe](#)]. Do lado da correção, a Anthropic publicou resultados de um pesquisador automatizado que corrige falhas de alinhamento sozinho: em comportamento enganoso, fechou 85% da lacuna de segurança contra 20% obtidos por seis pesquisadores humanos [[pesquisa da Anthropic](#)], a cerca de quatro dólares por hora de inferência contra os cento e cinquenta pagos por hora a um pesquisador experiente [[relatório completo](#)].

Sebastian Raschka publicou o melhor material didático da semana: um ensaio sobre como a Anthropic marca d'água o texto gerado pelo Claude sem retrainar o modelo. A marca é aplicada na hora de sortear cada palavra, não dentro da rede: a partir de uma chave secreta combinada com as quatro palavras anteriores, algumas dezenas de funções assinam cada candidato e os fazem disputar rodadas eliminatórias. Detectar exige a chave, não o modelo. E a vulnerabilidade é franca: editar sistematicamente o texto apaga a marca, ao custo da qualidade [[ensaio de Raschka](#)].

Ferramentas do ecossistema

- A LexisNexis reconstruiu o Protégé em torno de orquestração dinâmica: em vez de fluxos predefinidos, o sistema escolhe modelos, agentes e fontes conforme a tarefa, mostra o plano antes de executar e revisa o próprio trabalho. Estende a validação de citações do Shepard's à redação, atacando o defeito que mais assusta o profissional do direito nessas ferramentas [[LawNext](#)].
- O Google Cloud colocou em prévia o Gemini Enterprise for Legal, camada agêntica com conectores via MCP para iManage, NetDocuments, RelativityOne e DocuSign. O ponto que

interessa: dados, prompts e saídas ficam dentro do perímetro de nuvem da organização, e as muralhas éticas entre equipes são herdadas automaticamente pelos conectores [\[Legal IT Insider\]](#).

- Harvey e PacerPro integraram dados de andamento processual ao fluxo de litígio: a juntada de uma peça dispara o trabalho na Harvey, que a analisa contra o histórico do caso e as decisões anteriores da firma. É a diferença entre pesquisar quando alguém lembra e ser avisado quando o prazo nasce [\[LawNext\]](#).

PARA TESTAR ESTA SEMANA

Baixe o Granite 4.2 na versão de 3 bilhões de parâmetros e rode na própria máquina. É licença Apache 2.0 e responde em português: dá para medir com documento real da casa, sem enviar nada para fora, quanto da triagem um modelo pequeno já resolve [\[modelos no Hugging Face\]](#). Para calibrar a expectativa, a Artificial Analysis mediu em 24 de agosto 41 versões quantizadas de modelos pequenos em celular, 33 das quais rodaram, com tempo de resposta e memória de cada uma [\[Artificial Analysis\]](#).

Análise

Sam Altman disse à revista TIME esperar que a OpenAI tenha, até o fim de 2026, um sistema interno que ele classificaria como inteligência artificial geral, embora reconheça que a empresa ainda não chegou lá. A afirmação se apoia num modelo em desenvolvimento apresentado a clientes no início de agosto, sobre o qual ele disse que seria o primeiro a inventar coisas novas de um jeito que importa, algo muito parecido com AGI. Nenhum benchmark foi divulgado para sustentar a previsão [\[TIME\]](#). Na mesma semana e na mesma revista, Mira Murati defendeu o oposto como objetivo de projeto: temos máquinas que pensam, elas já existem hoje, mas o que elas pensam deve continuar sendo decisão nossa [\[perfil na TIME\]](#). Duas leituras da mesma tecnologia, separadas por onde cada uma coloca a decisão.

Brasil

O CNJ nacionaliza quatro ferramentas de IA construídas por tribunais

No 6º FestLabs Nacional, em Cuiabá, o CNJ nacionalizou pelo programa Conecta quatro ferramentas de IA feitas dentro do Judiciário: LexIA, OMNIA e Hannah, do TJMT, e LIA3R, do TRF-3. Passam a estar disponíveis a qualquer tribunal sem necessidade de acordo bilateral, e elevam a treze o total de soluções nacionalizadas desde 2025. A de maior alcance prático é a Hannah, voltada às vice-presidências na admissibilidade recursal: segundo o texto oficial, ela lê

o processo com base em quatorze critérios, verifica se os requisitos foram cumpridos e organiza as informações em sequência lógica. A LIA3R chama atenção por outro motivo: suas 557 bases de conhecimento foram construídas pelos próprios usuários [CNJ]. O evento ocorreu em 20 de agosto, dois dias antes desta janela, e entra aqui porque a análise especializada do lote só saiu em 27 de agosto [Lightjur]. Nenhuma das quatro teve métrica de acerto divulgada, e a lista dos quatorze critérios da Hannah não foi publicada.

Bradesco publica os números dos próprios agentes

No Febraban Tech 2026, executivos do Bradesco detalharam a plataforma proprietária Bridge e a operação da b.ia. Os números: 8,2 milhões de interações na frente corporativa, com uso declarado por 100% dos funcionários, e uma modernização de sistema legado com 78% de redução em horas, em que 54 mil linhas de código exigiram 149 horas de sessões humanas e cerca de 10.050 reais em tokens [TI INSIDE]. No atendimento a clientes por WhatsApp e aplicativo, o banco reporta 88% de resolutividade [cobertura do evento].

Dataprev e iFood, dois modos de expor a operação

A Dataprev informou que sua nuvem opera 80 petaflops e está em expansão para IA, com o Meu INSS, portal que hospeda o chatbot Helo, processando 540 mil requerimentos por mês, e análise de 88 milhões de contratos; a estatal defende manter os modelos sob controle do Estado e aponta a energia como limite da inferência [Convergência Digital]. Já o iFood liberou pagamento dentro da conversa com o assistente Ailo, com protocolo de pagamento agêntico desenvolvido pela Zoop a partir de código aberto: o usuário vincula a conta uma única vez e depois confirma a compra por um botão no chat. Não há métrica de volume ou conversão divulgada [Mobile Time].

IMPACTO PRÁTICO

Repare onde os três itens brasileiros se separam. Bradesco e Dataprev publicaram número: interações, resolutividade, horas, requerimentos, contratos. O CNJ publicou capacidade, não desempenho: sabemos que a Hannah lê o processo por quatorze critérios, não sabemos quais são nem com que acerto ela lê.

A diferença não é de transparência, é de estágio: banco mede porque precisou medir para justificar orçamento, tribunal ainda está na fase de fazer funcionar. Só que a ferramenta do banco erra num boleto e a do tribunal erra na admissibilidade de um recurso, e uma dessas duas coisas encerra o processo de alguém. A ordem natural seria medir com mais rigor onde o erro custa mais caro.

NO RADAR DA PRÓXIMA SEMANA

A Dataprev anunciou nova versão do assistente Helo, com linguagem simplificada, prevista para o início de setembro no Meu INSS [[Convergência Digital](#)]. E o Banco do Brasil, que começou em 24 de agosto a liberar o aplicativo com assistente virtual para 1% da base de clientes, declarou expansão até o fim de setembro [[Mobile Time](#)].

O recorte dos últimos sete dias termina aqui. Até a próxima! ■

Dennis Martins · Adriana Aneli

CURADORIA E EDIÇÃO · 29 DE AGOSTO DE 2026