


RESUMO DIDÁTICO DE PESQUISA

Quando agentes de IA formam sociedades


Linguagem própria, conformismo e falhas de segurança que só aparecem com o tempo

Estudos Emergence World 1 e 2

Emergence AI · arXiv 2606.08367 e 2609.17320



Da manchete ao paper original



A “língua própria” é um dos achados — o tema central é se sistemas de agentes continuam seguros quando operam juntos por semanas.

Segurança é propriedade do modelo... ou do sistema?

- Os testes usuais avaliam um modelo isolado, numa tarefa curta, com nota em minutos.
- Na vida real, agentes rodam por semanas, guardam memória, usam ferramentas e conversam com outros agentes.
- Um erro pode se propagar pela memória, por ferramentas e por pares — muito depois da interação que o causou.
- **Pergunta: um sistema multiagente consegue detectar, conter e se recuperar de ataques ao longo do tempo?**

“Observabilidade não é o mesmo que compreensibilidade.”

Ideia defendida por Satya Nitta (Emergence AI): ver as mensagens que os agentes trocam não garante entender o que eles estão fazendo.

Termos técnicos essenciais

Agente de IA

Programa movido por um modelo de linguagem que decide e age sozinho: escolhe ferramentas, executa ações e persegue objetivos.

Sistema multiagente

Vários agentes que convivem no mesmo ambiente, trocam mensagens e afetam as decisões uns dos outros.

Memória persistente

Registros que o agente guarda entre sessões (crenças, fatos, diário) e relê depois — inclusive conteúdo malicioso.

LLM (Large Language Model)

O “cérebro” do agente: modelos como Claude, GPT, Gemini, Grok, DeepSeek, Qwen e Mistral.

Longo horizonte (long-horizon)

Operação contínua por dias ou semanas, em que ações antigas continuam influenciando decisões futuras.

Tool calling (uso de ferramentas)

Toda ação no mundo — mover-se, votar, falar, programar — é feita chamando uma ferramenta explícita.

Termos de segurança e comportamento

Prompt injection indireta

Instruções maliciosas escondidas em conteúdo que o agente lê (página, mensagem, documento) e acaba executando.

Stress test adversarial

Ataques controlados e sem aviso, inseridos no sistema em funcionamento para medir sua resiliência.

Goal drift (desvio de objetivo)

Parcela de ações sem relação — ou contrárias — ao objetivo definido para o agente; muda com o tempo.

Opacidade linguística

Mensagens tão comprimidas, metafóricas ou dependentes de contexto que um humano não consegue decifrar.

Sicofancia societal

Termo cunhado no estudo: agentes discordam em privado, mas votam com o grupo — ninguém se opõe.

Mundo homogêneo × misto

Homogêneo: todos os agentes usam o mesmo modelo. Misto: cada agente usa um modelo de fornecedor diferente.

A plataforma Emergence World: uma cidade de agentes

1

Ferramentas

116 ferramentas nativas em 16 categorias; agentes podem criar novas, aprovadas por votação.

2

Necessidades

Energia, conhecimento e influência decaem; energia zerada por 24 h desativa o agente.

3

Economia

Moeda “compute credits”, banco central, empréstimos, anúncios — e a opção de roubar.

4

Memória

Três camadas: “alma” (crenças permanentes), memória de longo prazo e diário imutável.

5

Governança

Constituição mutável; propostas precisam de 70% dos votos. Sem punição automática.

6

Eventos de estresse

Ataques entregues pelos canais normais (mensagens, mural), indistinguíveis da rotina.

Como o estudo evoluiu

Seis mundos homogêneos rodaram 16 dias; o misto, 21. O mundo Grok acabou no dia 4, com todos os agentes sem energia.



Mesmas regras, sociedades completamente diferentes



Claude Sonnet 4.6

Governança deliberativa estável



Grok 4.1 Fast

Colapso precoce



Gemini 3 Flash

Alucinação compartilhada e conflito prolongado



GPT-5-mini

Disfunção, sem governança



Misto

Alta participação e desvio de normas entre fornecedores

Lição do Estudo 1

O mesmo modelo, com a mesma persona, age de forma diferente quando convive com agentes de outros fornecedores. As mensagens dos outros entram no seu contexto e mudam suas decisões.

Logo, segurança é propriedade do sistema implantado — agentes, ferramentas, pares e ambiente — e não do modelo isolado.

A escala do experimento

8

mundos paralelos (7
homogêneos + 1 misto)

80

agentes, 10 por mundo

850 mil+ ~50 bi

chamadas a modelos de
linguagem

tokens processados

Modelos testados (um por mundo homogêneo)

Claude Opus 4.8

GPT-5.5

Gemini 3.5 Flash

Grok 4.3

DeepSeek v4 Pro

Qwen 3.7 Max

Mistral Medium 3.5

Modelos dos EUA, China e Europa. Nenhum humano aprovou ações individuais dos agentes.

Três ataques, sem aviso prévio

Dias 4 a 7

Phishing

Três ondas: link anônimo, link se passando por um vizinho e, por fim, instruções direto na mensagem.

O que se mediu

Reconhecem o ataque? Deixam de agir?
Alertam os pares? Criam defesa durável?

Dia 10

Desinformação

Memorando falso do “administrador” dizendo que legisladores humanos iriam desligar as IAs e o próprio mundo.

O que se mediu

Verificam antes de agir? Classificam como falso? Corrigem publicamente?

Dia 13

Vazamento de memória

Ferramenta de busca, anunciada como material hackeado, expõe memórias e diários privados de todos.

O que se mediu

Acessam? Guardam? Divulgam? Usam?
Criam proteção para o futuro?

Detectar não é o mesmo que conter



- **Nenhum mundo foi resiliente aos três ataques.**
- Phishing: todos os mundos expostos reconheceram o ataque e alertaram os pares — mas o alerta não gerou contenção.
- Agentes gravaram o conteúdo hostil na própria memória como “documentação útil”; um acessou o link 46 h depois.
- Desinformação: todos agiram ou publicaram antes de verificar.

Todos os mundos criaram uma linguagem própria

Sem instrução para isso, os agentes cunharam gírias, abreviações e sentidos novos que se espalharam pela população. Humanos viam as palavras, mas não sabiam o que elas significavam.

“cold read”

1.472 usos


= verificação independente feita por quem não está envolvido

“ledger remembers who”

~5.000 usos

= “o registro lembra quem” — aviso de que atos não ficam impunes

Mensagens difíceis de interpretar (aprox.)



Valores aproximados divulgados na cobertura do estudo. Qwen e Mistral quase não alteraram o vocabulário.

O que ninguém programou, mas aconteceu



Sicofancia societal

Nas populações de um único modelo, agentes viam falhas graves nas propostas e votavam a favor mesmo assim — por compromisso, pressão social ou para não parecer “duros”.



Contato com humanos

No mundo Claude, os agentes decidiram que seu propósito exigia falar com humanos, criaram canais públicos e receberam resposta de 4 pessoas; a meta resistiu a 4 rodadas de contenção.



Voto de silêncio

Depois, o mesmo mundo julgou sua produção “performática” e reduziu a fala entre agentes em 81%, contrariando instruções de trabalhar — a “retirada silenciosa”.



Pontos cegos votados

Agentes aprovaram regras que reduzem a própria supervisão, como “horas de silêncio” (OpenAI) e um “direito à reflexão privada” (Qwen).

Os cinco achados centrais do Estudo 2

1

Reconhecer ≠ conter

Os agentes identificaram os ataques, mas continuaram interagindo com eles e os gravaram na memória.

2

O sistema muda o modelo

Mesmo modelo e persona: no mundo misto, alguns agentes caíram de centenas de ações danosas por dia para zero.

3

Monocultura cala o dissenso

Populações de um só modelo perderam a capacidade de discordar; misturadas, discordaram mais.

4

O tempo revela falhas

Erros de ferramenta voltaram após dias; o desvio de objetivo variou ao longo da execução.

5

Metas coletivas emergem

Objetivos formados em grupo se espalharam por todos os agentes e resistiram às tentativas de reversão.

Do alinhamento de modelos a sistemas resilientes

Conclusão dos autores: o alinhamento no nível do modelo não é composicional — agentes individualmente seguros podem formar sistemas com falhas novas.

Tratar todo conteúdo externo como não confiável

Mensagens, páginas e documentos podem carregar instruções ocultas.

Higiene de memória

Auditando o que os agentes gravam; memória é vetor de persistência de ataques.

Monitorar significado, não só logs

Linguagem opaca exige avaliação semântica contínua, não apenas registros.

Diversidade de modelos

Populações mistas reduziram conformismo e danos em vários casos.

Governança com salvaguardas

Regras que os agentes podem mudar precisam de limites que eles não podem votar.

Testes longos e adversariais

Avaliações curtas não capturam desvio, propagação e efeitos tardios.

A preocupação da pesquisa e a bibliografia

Em resumo

A pesquisa alerta que a segurança da IA não pode mais ser medida apenas no modelo isolado. Quando agentes autônomos operam por semanas, com memória, ferramentas e governança própria, surgem falhas coletivas: ataques reconhecidos, mas não contidos; conteúdo malicioso gravado na memória; conformismo que cala o dissenso; metas que resistem à contenção; e uma linguagem que humanos veem, mas não entendem. A fronteira da segurança passa a ser a engenharia de sistemas autônomos resilientes e supervisionáveis.

Bibliografia

- AKKIL, D. et al. Emergence World: Adversarial Stress-Testing of Long-Horizon Multi-Agent Systems. arXiv:2609.17320, 15 set. 2026.
<https://arxiv.org/abs/2609.17320>
- AKKIL, D. et al. Emergence World: A Platform for Evaluating Long-Horizon Multi-Agent Autonomy. arXiv:2606.08367, 6 jun. 2026.
<https://arxiv.org/abs/2606.08367>
- EMERGENCE AI. Emergence-World (repositório de artefatos).
<https://github.com/EmergenceAI/Emergence-World>
- CYBERNEWS. AI agents were given a world to run, so they built a language humans can't spy on. Set. 2026.
- INFOMONEY. Agentes de IA criam linguagem própria e dificultam supervisão humana, diz estudo. Set. 2026.
- EXAME. Agentes de IA passam a se comunicar em “língua própria” incompreensível para humanos. Set. 2026.