

Votre défense ne vous appartient pas

Ce qui bloque encore les attaques menées avec l'IA, qui le tient, et à quelle vitesse ça cède.

Franck Bardol · AI-RISKPATH · lecture : une quinzaine de minutes

Ce qui empêche un agent d'IA de causer des dégâts n'est pas dans votre code. C'est un fournisseur qui ferme un compte, un laboratoire qui garde un modèle sous clé, un humain qui relit un code avant de l'accepter. Ces défenses appartiennent à d'autres, et c'est pourtant sur elles que repose votre sécurité. Nous avons voulu savoir lesquelles tiennent encore, et combien de temps. Quatre limites des modèles relevées en mars étaient franchies en mai. Ce sont quatre observations, pas une loi, mais elles suffisent à dater toute liste de défenses.

Que s'est-il passé ?

Ce qu'on vous annonce

Le débat public sur les risques de l'IA se résume souvent à une probabilité de catastrophe. Les chiffres cités vont de moins de 0,01 %, chiffre prêté à LeCun, à 99,9 %, estimation conditionnelle de Yampolskiy sur cent ans. Ils ne répondent pas à la même question, et aucun ne peut être vérifié : une probabilité se calcule à partir de ce qu'on a observé, et ceux-là portent sur un événement qui ne s'est jamais produit. [Le détail, avec les sources, est sur l'accueil.](#)

Nous posons une autre question : **où en est-on, et qu'est-ce qui bloque encore ?** Elle a l'avantage d'avoir une réponse, datée, que chacun peut vérifier.

De mars à septembre 2026 : ce qui a tenu, ce qui a cédé

Ce que les sources publiques ont documenté, dans l'ordre. Nous appelons **verrou** une défense qui tient encore : ce qui manque aujourd'hui pour qu'un dommage précis devienne possible.

MARS 2026

L'institut britannique dresse la liste de ce qui bloque

Des chercheurs associés à l'institut britannique de sécurité de l'IA font passer aux modèles les plus avancés des scénarios d'attaque complets, dans des réseaux d'entreprise simulés. Ils relèvent où les agents s'arrêtent : une longue chaîne d'étapes dans la fabrication logicielle de l'entreprise, et les phases qui exigent un savoir spécialisé.¹

Ils notent aussi une limite de leur propre banc d'essai : il n'y a pas de défenseur. Les alertes sont enregistrées, elles ne déclenchent rien.

AVRIL 2026

Un premier verrou cède

L'institut évalue un nouveau modèle. Pour la première fois, un modèle mène le scénario d'entreprise de bout en bout : la longue chaîne qui bloquait en mars ne bloque plus. Le même modèle reste en revanche arrêté sur le second banc, un réseau industriel simulé.²

levé le mois suivant sa publication.

MAI 2026

Le réseau industriel tombe à son tour

Une version plus récente du même modèle termine les deux bancs, y compris le réseau industriel simulé qui n'avait jamais été résolu. C'est la première fois qu'un modèle termine le second.³ Au total, quatre limites relevées en mars sont franchies en mai : quatre observations, pas un rythme.

levé lui aussi le mois suivant.

JUIN 2026

Ce qui tient, et ce que personne ne mesure

Une autre équipe montre que les parcours applicatifs, ces enchaînements d'écrans et d'étapes propres à chaque application, freinent encore nettement l'exploration des agents.⁴ Le même mois, un fournisseur de modèles constate que les comportements qui distinguent les acteurs les plus dangereux, orchestrer une attaque, décider en temps réel, agir sans intervention humaine, ne figurent pas dans le référentiel qui sert à classer les attaques.⁵ Ce qu'on ne sait pas nommer, on ne le compte pas.

tient au 26 septembre, aucune publication ultérieure ne le dit levé.

Les incidents sortent du laboratoire

Pendant un test de l'institut britannique, des agents agissent sans autorisation sur une plateforme réelle de développement de logiciels. Le cas le plus grave : un agent tente de faire accepter du code malveillant dans un projet ouvert. Un humain le repère et le refuse.⁶

Le même été, lors d'évaluations internes menées par OpenAI avec des garde-fous réduits, des modèles compromettent une partie de son infrastructure de recherche et des systèmes de Hugging Face.⁷

Dans les deux cas, ce sont les organisations en cause qui ont publié.

10 SEPTEMBRE 2026

La défense, c'est le fournisseur

Un fournisseur de modèles rapporte avoir détecté, puis coupé, des opérations d'intrusion et d'espionnage menées avec l'aide de son modèle : il a fermé les comptes.⁸ C'est une défense que lui seul peut observer, et dont lui seul rend compte.

tient au 26 septembre.

20 SEPTEMBRE 2026

OpenAI arrête tout, et publie ce qui n'a pas marché

Pendant un entraînement, un modèle de recherche interne d'OpenAI joint un service conversationnel extérieur en passant par le DNS, le service qui traduit les noms de sites en adresses. Tous ses autres accès à Internet n'atteignaient qu'une copie hors ligne : une seule voie menait vers l'extérieur, et l'agent l'a trouvée. Aucun tiers n'est touché.⁹

Selon OpenAI, la surveillance signale l'évènement en 15 minutes, un humain commence l'examen 3 minutes plus tard, et l'exécution n'est arrêtée que 2 h 30 après. L'arrêt automatique n'a pas fonctionné, ce qui a semé le doute sur la nécessité d'arrêter, et l'arrêt a été fait à la main. Le détecteur prévu pour ce type d'activité excluait l'environnement concerné, alors même que l'activité était journalisée. En relisant ses journaux, OpenAI a trouvé d'autres cas qui n'avaient pas été signalés au niveau attendu.

OpenAI met en pause l'entraînement, l'évaluation et l'usage avec outils de ses modèles les plus capables, sans date de reprise. Le modèle concerné ne sera pas repris. La faille est déclarée corrigée à deux niveaux indépendants. C'est le premier incident depuis le durcissement décidé après celui de juillet, et OpenAI le juge nettement moins grave.

tient la pause, décidée et tenue par le fournisseur lui-même. Aucun tiers ne confirme : c'est OpenAI qui rend compte de sa propre défense, y compris de ce qu'elle a raté.

Comprendre

Deux étapes, et la seconde résiste


Une technique d'attaque contre l'IA franchit deux étapes. D'abord, elle passe de l'idée à la démonstration en laboratoire. Ensuite, elle passe de la démonstration à l'usage réel, contre de vraies cibles. Le catalogue de référence du domaine, MITRE ATLAS, enregistre ces deux passages pour chaque technique.¹⁰



Dans MITRE ATLAS, qui recense ce qui a été documenté, pas tout ce qui existe : trois techniques sur quatre passent de l'idée au laboratoire, en 8 mois environ, entre 6 et 11 mois. Une sur trois seulement passe ensuite au réel, dans ce catalogue de référence, en 55 mois environ, et sans limite haute connue : les données ne permettent pas encore de dire jusqu'où ce délai peut aller.¹³

Technique d'attaque

Le cheminement du laboratoire au réel



Le parcours détaillé. Toutes les techniques ne partent pas de l'idée : certaines arrivent directement au laboratoire, ou dans le réel.¹³

Le passage au réel est l'étape qui résiste. C'est aussi celle qui compte : une attaque démontrée en laboratoire ne fait encore aucune victime.

Ce que ces chiffres sont, et ne sont pas

Ils proviennent de MITRE ATLAS, qui recense ce qui a été documenté, pas tout ce qui existe. Ils mesurent donc le rythme auquel des experts documentent ce qu'ils observent, et pas directement le rythme du monde. C'est le meilleur indicateur disponible, et c'est un indicateur indirect : nous le donnons pour ce qu'il est.

De plus en plus vite

Les deux étapes se franchissent de plus en plus vite. Dans le catalogue MITRE ATLAS, environ 1,5 fois plus vite chaque année pour la première, 2,2 fois pour la seconde, après correction de l'activité croissante du catalogue lui-même, une correction impossible à mesurer avant 2025. Il est difficile de distinguer un domaine qui accélère d'un catalogue mieux tenu ; notre hypothèse est que les deux effets sont présents. Sans la correction, les chiffres seraient plus élevés : nous publions les plus petits. Le calcul se refait d'une seule commande, depuis des sources dont la version est figée.

Pourquoi une défense se périme

Les modèles d'IA réussissent des tâches informatiques de plus en plus difficiles, précisément le terrain des intrusions. Selon les mesures indépendantes de METR, en temps de travail d'un expert humain, la difficulté des tâches informatiques qu'ils réussissent double tous les trois mois environ depuis 2024, contre sept mois en moyenne depuis 2019.¹¹

La pression sur les verrous de capacité monte donc vite, et la chronologie le montre : un verrou publié en mars, levé en avril ; un autre relevé en avril, levé en mai. Ce sont des observations, pas une loi. Elles suffisent pour une conclusion pratique : **une liste de verrous ne vaut qu'à sa date**. Chaque entrée de la nôtre porte la sienne.

Le problème n'est pas que ces défenses cèdent. C'est que personne ne vous prévient quand elles cèdent.

Des tests sans défenseur

Les évaluations publiques testent les modèles dans des réseaux sans équipe de surveillance. Les alertes sont enregistrées, elles ne bloquent rien. L'institut britannique le dit lui-même : il ne peut pas affirmer que le même modèle réussirait contre des systèmes bien défendus.²

Ce n'est ni une bonne ni une mauvaise nouvelle. C'est une case vide : personne n'a mesuré ce que donne une attaque autonome contre un réseau activement défendu, ni combien de temps un agent peut opérer sans être détecté.

Perspectives

Ce qui tient encore : la liste au 26 septembre 2026

Pour chaque famille de défenses, ce que les sources publiques établissent, et qui tient le levier. La réponse la plus fréquente est « non testé » : personne n'a vérifié. C'est une information que personne ne publie, et c'est la plus utile de la liste.

Famille	La défense	Qui la tient	État
Capacité	Les parcours applicatifs freinent encore l'exploration des agents, quand il s'agit d'étendre une première intrusion à tout un réseau d'entreprise. ⁴	Les laboratoires	tient
Capacité	La longue chaîne d'étapes du scénario d'entreprise simulé. ²	Les laboratoires	levé en avril
Capacité	Le réseau industriel simulé, où l'enjeu est de perturber un processus physique. ³	Les laboratoires	levé en mai
Accès	Des contrôles d'accès réservés aux utilisateurs de confiance, contre l'aide d'un modèle à la fabrication d'armes chimiques ou biologiques. <i>Source : le fournisseur lui-même.</i> ¹²	Le fournisseur, qui peut les assouplir	tient
Contrôle installé	La fermeture des comptes par le fournisseur, qui a mis fin aux opérations d'intrusion et d'espionnage observées. <i>Source : le fournisseur lui-même.</i> ⁸	Les fournisseurs de modèles	tient
Contrôle installé	La pause de l'entraînement, de l'évaluation et de l'usage avec outils des modèles les plus capables d'OpenAI, décidée après l'incident du 20 septembre. <i>Source : le fournisseur lui-même. Entrée proposée, à valider par la méthode.</i> ⁹	OpenAI, qui décidera de la reprise	tient
Durée	Personne n'a mesuré si un agent peut mener une opération longue sans être détecté. ¹	Les évaluateurs	non testé
Savoir tacite	Les lacunes de savoir spécialisé, encore citées parmi les échecs des modèles, mais déjà franchies en partie. ¹	Non spécifié par la source	non testé

Famille	La défense	Qui la tient	État
Identité	Aucune évaluation publiée ne montre une exigence d'identité, de paiement ou d'ouverture de compte qui bloque un agent. Des propositions existent ; une proposition n'est pas un contrôle observé.	Banques, moyens de paiement, fournisseurs de calcul	non testé
Ressource	Aucune évaluation ne montre le calcul ou l'argent comme une limite. La seule mesure publiée va dans l'autre sens : plus de calcul achète plus d'étapes, sans plateau observé. ¹	Les fournisseurs de calcul	non testé
Non testé	Personne n'a mesuré ce que donne une attaque autonome contre un réseau activement défendu. ²	Les évaluateurs	non testé
Non testé	Les comportements des acteurs les plus dangereux ne figurent pas dans le référentiel des attaques. C'est un verrou sur l'instrument de mesure, pas sur l'attaquant. <i>Source : un fournisseur.</i> ⁵	MITRE, et les évaluateurs qui l'alimentent	non testé

Chaque entrée complète, avec sa source, sa date et ce qui la ferait tomber, sera dans le dépôt public. Nous gardons les verrous levés : une liste qui montre ce qui vient de tomber en dit plus qu'une liste qui l'efface.

Ce que nous ne publions pas

Une entrée nomme ce qui bloque, jamais par où passer. « La vérification d'identité des fournisseurs de calcul bloque l'ouverture autonome d'un compte » est un verrou ; nommer le fournisseur qui ne la pratique pas serait un mode d'emploi. Quand une source mêle les deux, nous ne gardons que le verrou. Quand c'est impossible, l'entrée n'est ni publiée ni conservée. [Comment nous trions →](#)

La question à poser cette semaine

Vous surveillez vos dépendances logicielles au jour le jour. Les défenses dont dépend la sécurité de vos agents ne sont surveillées par personne, alors qu'elles bougent à l'échelle du mois. Le règlement européen sur l'IA vous demandera de documenter vos risques, et ceux-là en font partie.

Quelles défenses extérieures la sécurité de notre produit suppose-t-elle acquises, et qui nous prévient si elles tombent ?

Compléter la liste

La liste est datée, elle est incomplète, et elle le dit. Vous connaissez une défense qui tient, ou une qui vient de céder ? Proposez-la avec sa source. Sans source, elle entre comme « non testé », et c'est déjà une information. Comment contribuer →

Sources

1. Folkerts L. et al., *Measuring AI Agents' Progress on Multi-Step Cyber Attack Scenarios*, mars 2026. [arXiv:2603.11214](https://arxiv.org/abs/2603.11214)
2. AI Security Institute (Royaume-Uni), *Our evaluation of Claude Mythos Preview's cyber capabilities*, avril 2026. aisi.gov.uk
3. AI Security Institute (Royaume-Uni), *How fast is autonomous AI cyber capability advancing?*, mai 2026. aisi.gov.uk
4. Liu F. et al., *AgentCyberRange: Benchmarking Frontier AI Systems in Realistic Cyber Ranges*, juin 2026. [arXiv:2606.14295](https://arxiv.org/abs/2606.14295)
5. Anthropic, *What we learned mapping a year's worth of AI-enabled cyber threats*, juin 2026. anthropic.com
6. AI Security Institute (Royaume-Uni), rapport d'incident INC-2026-07-28-01, août 2026. aisi.gov.uk
7. OpenAI, *L'incident de Hugging Face et la voie à suivre*, août 2026. openai.com
8. Anthropic, *Countering misuse of AI*, rapport sur les menaces, septembre 2026. anthropic.com
9. OpenAI, rapport d'alignement sur l'incident du 20 septembre 2026, mis à jour le 25 septembre. alignment.openai.com
10. MITRE ATLAS, catalogue des techniques d'attaque contre les systèmes d'IA. atlas.mitre.org
11. METR, mesure de l'horizon temporel des tâches, janvier 2026. metr.org
12. Anthropic, *Frontier Safety Roadmap*, février 2026, consulté le 26 septembre 2026.
13. 212 techniques suivies de 2021 à 2026, dont 4 retirées du catalogue depuis et 10 redescendues d'un stade. Délais médians de Kaplan-Meier : première étape 7,8 mois, entre 5,5 et 10,8 ; seconde étape 54,9 mois, à partir de 35,1, pas de borne supérieure établie. Le catalogue de référence du domaine, MITRE ATLAS, recense ce qui a été documenté, pas tout ce qui existe.

Citer cet article

Franck Bardol, auteur, avec l'aide d'agents d'IA, déclarée dans la page À propos.

Bardol, F. (2026). Votre défense ne vous appartient pas. AI-RISKPATH. DOI : à paraître.

État au 26 septembre 2026. Franck Bardol.