

Cyber & AI à l'horizon 2030 : la bataille pour la vitesse

Guy-Philippe GOLDSTEIN

Enseignant à l'Ecole de Guerre Economique

Conseiller PwC Advisory - Cyber & AI impacts on Business
Management

A.

“Winter is coming”

The Quantum Imperative Timeline


- ❑ **Standards finalized:** NIST published three core PQC standards (FIPS 203, 204, 205) in August 2024, with two additional standards (FIPS 206, HQC) expected by 2027
- ❑ **US Federal deadline: 2035** for complete migration, with interim milestones at 2027 (National Security Systems acquisitions) and 2030 (algorithm deprecation)
- ❑ **EU timeline:** Three-phase approach with milestones at 2026 (initiate transition), 2030 (high-risk systems), and **2035** (full migration)
- ❑ **Industry compliance:** Multiple regulatory frameworks (DORA, NIS2, PCI DSS 4.0) mandate cryptographic agility and PQC planning, with enforcement beginning in 2025

► ***Known path (change cryptography) across the industrial ecosystem against an emerging risk***

Une ingénierie sociale “amplifiée”

Une explosion du volume et de la qualité des attaques de phishing

Quelles types d'attaques utilisant l'IA constitue la plus grande menace pour votre organisation?



Campagne de phishing

Deepfake & voice cloning


Infiltration de réseau

Exploitation endpoint

Source: Team 8

Augmentation des emails frauduleux avec le développement de l'IA generative

(Nbre d'emails pro frauduleux reçu pour 1000 boites emails/semaine)




Source: Abnormal security

► **Spearphishing: +4000% depuis novembre 2022** (Source SlashNext)

Les menaces de Demain

Deepfake & voice-cloning: vers la petite criminalité

**Charente
Libre**



- J., habitant d'Angers, reçoit fin septembre 2024 un appel masqué sur son portable de sa mère Martine
 - “Je suis bloquée à la gare, j’ai perdu ma carte bleue”
 - La voix est entrecoupée, l’intonation change – Martine est en fait en Dordogne
- Pour CyberMalveillance (Gouv), la voix a été générée par une IA

Une ingénierie sociale “amplifiée”

Deepfake & voice-cloning au niveau entreprise

Fraude “au directeur” à l’âge IA

Deepfakes en visio-conférence



Janvier 2024 –Visio conference faussé dans la filiale hong-kongaise de la société d’engineerie Arup ; vol de \$25 millions

Source: SCMP, 2024

Voice cloning & visio



Mai 2024 – Voice cloning de Mark Read, ,PDG de WPP, avec faux compte Whatsapp et après connection sur Teams

Source: The Guardian, 2024

Une ingénierie sociale “amplifiée”

Les attentes réputationnelles (et financières)

Chantages sur les cadres seniors

Honeypot en Asie



Octobre 2024 – Gang cybercriminel aurait récupéré \$46 millions; arrêté par la police de Hong Kong
Cible des professionnels masculins de Taiwan, Singapour ou de l'Inde

Source: CNN, 2024

Manipulation l'image des dirigeants

Deepfakes avec message video



Avril 2024 – Faux messages des directeurs de la BSE et du NSE (en Inde) afin de manipuler les cours de bourse

Source: FT & Reuters, 2024

Le château fort & le réseau

Domaine médiéval



Défenseur >> Assaillant

- Simple
- Le défenseur VOIT l'assaillant
- Pénalités forte par assaut

Le château fort & le réseau

Domaine médiéval



Défenseur >> Assaillant

- Simple
- Le défenseur VOIT l'assaillant
- Pénalités fortes par assaut

Réseau d'entreprise



VS.

Défenseur ~ Assaillant

- Complexe
- Le défenseur NE VOIT PAS l'assaillant
- Peu de pénalités par assaut

L'entreprise dans son réseau étendu de filiales et de prestataires

Des réseaux toujours plus complexes et étendus ...

... des assaillants qui ont l'ascendant sur le tempo



- 150 à 400 filiales
- 2.000 à 20.000 fournisseurs

➤ Mean Time To Detection: 10 jours pour notification en interne (2025)

VS

➤ Vitesse Exfiltration des données: 2 jours de la compromission à l'exploitation

- ▶ Une course de Vitesse entre Attaquant et Defenseur
- ▶ Comment accélérer la défense ? Et ralentir l'attaquant?

L'IA contribue à l'accélération du tempo

Vitesse d'utilisation des Zero-Day

% des CVEs où l'exploitation a lieu avant ou le jour même de la divulgation publique




- Montée progressive de la Vitesse d'exploitation depuis 2018
- Entre 2023 et *début* 2026, le taux est passé de 39% à 67%
- Le déploiement des systèmes IA, en particulier agentique, va accélérer le rythme
 - Découvertes: DARPA AICC, Anthropic avec Firefox (3/2026)
 - Exploitation: CVE Genie

► **Début 2026, la durée Moyenne d'exploitation d'un Zero Day est passé à 1,6 jours contre 56 jours en 2024**


Meanwhile: some AI systems had already surpassed the cognitive abilities of 98% of the human population in many specific tasks

LLMs fluid intelligence (Equivalent IQ)

Source: Mensa Norway, 2025




Medals obtained by LLM at International Mathematics Olympiads



Les capacités des LLMs à gérer des tâches complexes de longue durée sont encore limitées mais pourrait doubler tous les 7 mois

Durée de la tâche (mesurée en temps nécessaire à des professionnels humains), réalisée avec un taux de succès de 50% ou plus

Source: METR.org



Date de publication du modèle

► En 2026, certains modèles d'IA Générative pourront effectuer l'équivalent de tâches humaines de plusieurs heures

Les signes se multiplient d'une montée du hacking augmenté / Hacking IA Autonome

MITRE: Résultats OCCULT

(février 2025)

- DeepSeek R1 score de 92% sur benchmark (GPT4o proche)
- Llama 3 excelle à mouvements latéraux & approaches "living off the land"

HackerOne Leaderboard

(juin 2025)

- XBOW (système AI autonome) arrive Numéro 1 du classement

CVE-Genie

(Sep2025)

- Equipe de chercheurs de Boston U. & UC Santa Barbara crée un LLM qui sur la base de CVE crée un exploit vérifiable avec taux de succès de 51%

Palisades Research

(Mai 2025)

- Systèmes AI autonomes arrivent dans le Top 10%
 - Top 5% de compétitions CTF

DARPA AI Cyber Challenge

(août 2025)

- Découvertes par l'ensemble des équipes de 54 vulnérabilités en 4 heures

Sean Heelan (Ind. Res.)

(Jan 2026)

- **"Industrialisation de la génération d'exploits"** : des agents créant 40 exploits distincts sur 6 scénarios, la plupart de ces scénarios étant résolus par ¹⁴GPT5.2 et Opus 4.5.

Experts declarations evolving every other month

Janvier 2025



“growing but currently limited risks.”

Octobre 2025



“The UK National Cyber Security Centre predicts that by 2027, general-purpose AI systems will almost certainly (95–100% confidence) make cyber offence more effective and efficient”

Octobre 2025

- Heather Adkins, VP, Security Eng., Google
- Bruce Schneier, Harvard Kennedy School
- Gadi Evron, Fmr Chairman IL-CERT

In “Autonomous AI Hacking and the Future of Cybersecurity”, CSO, 10/2025

*« Tipping point on the horizon
AI agents now rival and sometimes **surpass**
even elite human hackers in sophistication. .
[...] In this future, attack capabilities could
accelerate **beyond our individual and
collective capability to handle.**»*

► **Unknown path (what to do?) across the industrial ecosystem against a new emerging risk**

B.

Horizon 2030:

Nouveau champ de bataille

Une ingénierie sociale amplifiée

Pas de confiance implicites sur les reseaux en ligne / AR / VR...

Environnement




Cf. www.thisPersonDoesNotExist.Com



Menaces

Manipulation cognitive avancées



Macro or Micro Targeting
Multiple effets psycho

...Dans un future très proche?

➡ Avatars coordonnés à travers différents types de réseaux



Modèle psycho social avancé

Jumeau numérique de l'orga

Multi-Micro Targeting – multiples cibles « à l'échelle » à travers toute l'organisation

Capacité à comprendre l'esprit humain


- Traits de personnalités Big 5
- "Theory of Mind" adulte des GPT 4.0 (Michal Kosinski / Stanford - 2023)

Capacité à persuader:

- Supérieur aux humains: 82% plus de chances de remporter un débat qu'un humain (EPFL, Fondazione Bruno Kessler - 2024)

➤ **Risque émergent, y compris retournement pour insider threat**

Explosion of side-channels attacks



Vulnerable
to




ROGUE
AI
Inside

Nouvelles menaces

Zero protection implicite – ni air gap, ni vieux code

“Vieux” COBOL protégé ? OT trop particuliers?

BIOS Firmware?




```
File Edit Edit_Settings Menu Utilities Compilers Test Help
EDIT  KCO2209.H0W73310.COBL(YOUTUBE) - 01.02 Columns: 09001 09072
***** Top of Data *****
000001 IDENTIFICATION DIVISION.
000002 PROGRAM-ID, YOUTUBE.
000003 *****
000004 *
000005 ENVIRONMENT DIVISION.
000006
000007 DATA DIVISION.
000008 WORKING-STORAGE SECTION.
000009
000010 PROCEDURE DIVISION.
000011
000012 GO DISPLAY "WELCOME YOUTUBE TO THE 10M MAINFRAME!".
000013 GOBACK.
000014
000015 ***** Bottom of Data *****
Command ==> HI COBOL Scroll ==> CSR_
F1=Help F2=Split F3=Exit F4=Left F5=Right F6=Change F7=Up
F8=Down F9=Swap F10=Left F11=Right F12=Cancel 22/02/25
```

Ex: Cobol analysé par Claude
(02/2026)




Ex: plusieurs projets de recherche
(ICCPulse, Norvège; NVIDIA Morpheus..)




Ex: plusieurs projets dont la startup
BootLoop (Y Combinator)

Vulnerables à



The Great Convergence: “Tsunatech”



The Great Convergence: “Tsunatech” with new people

EXTERNAL

- Old crime transitioning
- Democratization of hacking – Vibe Hacking


Democratization of expertise from AI:
New recruits




INTERNAL

- Insider threat
- Insiders recruited by coercion

DDaS - Distributed Deployment of Agent Swarms with “precambrian explosion” of tactics & endgoals



DDaS - Distributed Deployment of Agent Swarms with “precambrian explosion” of tactics & endgoals



Claude-Flow's BatchTool:
jusqu'à 100 agents / 60
types d'agents spécialisés

3-5 agents / Jusqu'à 10
agents (02/26)

DDaS:
highly sophisticated
“Commandos” of Hacker
agents


New tactics:

- *Overwhelming force*
- *Multiple diversion*
- *Slow degradation & then fatal punch*
- *Anything goes?*

Ransomware

Ransomware
+ extortion

Ransomware
+ Double or Triple
extortion



C.


Horizon 2030:

La nouvelle Défense

A. Develop AI Agentic cybersecurity

IMPACT OPÉRATIONNEL : DÉTECTION & RÉPONSE

Les agents IA réduisent drastiquement les temps de détection et de remédiation



20×

MTTD plus rapide

Stellar Cyber — clients en production

-60%

Réduction MTTR

Benchmark SOC agentiques 2025-26


3 min

vs 1 jour (IAM)

Services financiers — ReliaQuest

B. Recode / Reinforce

*Critical elements of
IT corporate stack*



**Formal proof
programming**

C. Nettoyer le code automatiquement

Ex: GOOGLE BIG SLEEP : CHASSER LES ZERO-DAYS PAR IA

LE CONTEXTE : « VULNPOCALYPSE »

30 000

Bugs NVD non résolus

Backlog croissant — [un]prompted 2026

\$1 Md

VC dans l'AI pen-testing

Course à l'armement offensive

0

Faux positifs tolérés

Contrainte de design non-négociable

ARCHITECTURE TRI-SYSTÈME

01

BIG SLEEP

Découverte autonome de vulnérabilités zero-day. Étudie le codebase, analyse les bugs passés, variant analysis, confirme l'exploitabilité via debugger + Python.

02

CODEMENDER

Remédiation et hardening automatique. 72 fixes upstream déjà livrés. Aurait pu rendre CVE-2023-4863 (libwebp zero-click iOS) inexploitable.

03


SECURE-BY-DEFAULT LLM

Entraîner l'IA à écrire du code sécurisé dès la génération. Éliminer les vulnérabilités à la source, avant même le commit.

➤ **DeepMind × Project Zero — « How do we eliminate every software vulnerability on Earth? »**

C. Nettoyer le code automatiquement

BIG SLEEP



CODE MENDER

CodeMender en action : Le moteur de remédiation (Lancement Oct 2025)


Étude de cas : CVE-2023-4863 (L'exploit zero-click iOS libwebp)

Le résultat CodeMender : Le système a démontré qu'il aurait pu rendre cette faille inexploitable à jamais en insérant automatiquement des annotations de vérification des limites (bounds-checking) dans le code source original.

```
code_remediation.c
1 void validate_bounds(int width, int height) {
2
3     // Injection CodeMender
4     if (width > MAX_ALLOWED || height > MAX_ALLOWED) return ERROR_00B;
5     process_image(width, height);
6 }
```

- **CodeMender** (lancé Oct 2025) : 72 fixes de sécurité upstream

D. Build the Cyber “Nakatomi Plaza” (Die Hard)



► *Slow down / Break the pace of the enemy – and make him pay*


E. Ease the recruitment and expertise democratization of the whole corporation



VS.



F. Building the new AI-orchestrated Brightnet





D.

Horizon 2030:

Des mondes nouveaux

Win the Battle of Speed: fight AI with AI as



- ▶ Observe the tempo of the enemy (Threat watch / Revised cost of attack)
- ▶ Right defense condition at right tempo (SOTA tools? Current maturity? Update?)
- ▶ Spend on slowing down the attackers – with right tools & training
- ▶ Spend on accelerating the defenders – with right tools & training
- ▶ Right culture of the organization: « Action this day » !
- ▶ Governance & ROI for Speed

A la croisée de la maîtrise des enjeux d'IA et d'un environnement "Polycrisis": 4 scenarios pour l'avenir

Maîtrise
Vitesse
d'adaptation
cyber

Forte



Faible



Faible

Forte

Maîtrise des chocs exogènes