

Cybersécurité et IA générative

L'objectif de cette formation est de donner aux professionnels de la cybersécurité les outils pour anticiper, détecter et mitiger les vulnérabilités liées aux LLMs, à l'orchestration multi-agents, à l'usage de plugins tools et API dans les systèmes d'IA générative, et pour poser un cadre de sécurité opérationnel.

Pré-requis : Bonnes bases en cybersécurité, connaissances générales en IA ou architectures logicielles modernes, lecture de code Python ou YAML utile (non indispensable).



- Modalité :**
- Distanciel en classe virtuelle
 - E-learning : à venir
 - Présentiel

Communauté: community.reconvert.net

Durée totale : 21 H (3 jours)

Sécurisation des outils, agents et chaînes

Confinement des tools: sandboxing, whitelisting, quota
 Logs, audit, replay des agents
 Limiter les agents autonomes : contrôle par supervision, critic agents, throttle
 Safe tool composition : gestion des dépendances entre agents

Détection et monitoring en environnement LLM

Outils d'observabilité: LangSmith, TruLens, PromptLayer, Helicone
 Journaux de prompt + outils utilisés + outputs générés
 Détection d'anomalies dans les réponses:
 + exfiltration
 + non-conformité
 + hallucinations malicieuses

PLAN DETAILLE

Comprendre les LLMs et les architectures agentiques

Rappels : LLMs, prompts, embeddings, context window
 Architectures LangChain, CrewAI, AutoGen, Hugging Face Transformers
 Chaînes, agents, tools, mémoire, exécution multi-agent

Cartographie des surfaces d'attaque dans un système LLM

Attaques sur l'entrée: prompt injection, jailbreak
 Manipulation du contexte: prompt pollution, data poisoning
 Tool misuse - usage malicieux d'outils exposés:
 + API non filtrée
 + exécution de code
 + accès web
 Hijack d'agent ou de mémoire: state leakage, replay attack

Panorama des menaces réelles

Exemples concrets :
 + vol de données via prompt
 + désactivation de sécurité par agent
 + exfiltration d'informations
 Études de cas :
 + ChatGPT
 + Plugins malveillants
 + Hallucinations exploitées
 Risques directs: injection, fuite, contournement
 Risques indirects: manipulation, désinformation

Sécuriser les entrées et les prompts

Techniques de sanitation et validation de prompt
 Prompt templating sécurisé
 Détection de patterns malveillants:
 + regex
 + scoring LLM
 + agents critiques)

Cybersécurité et IA générative

L'objectif de cette formation est de donner aux professionnels de la cybersécurité les outils pour anticiper, détecter et mitiger les vulnérabilités liées aux LLMs, à l'orchestration multi-agents, à l'usage de plugins tools et API dans les systèmes d'IA générative, et pour poser un cadre de sécurité opérationnel.

Pré-requis : Bonnes bases en cybersécurité, connaissances générales en IA ou architectures logicielles modernes, lecture de code Python ou YAML utile (non indispensable).



- Modalité :**
- Distanciel en classe virtuelle
 - E-learning : à venir
 - Présentiel

Communauté: community.reconvert.net

Durée totale : 21 H (3 jours)

PLAN DETAILLE

Atelier 1 : Risques d'un système GenAI multi-agent

Étude d'un cas concret: chatbot ou agent multi-outils
 Identification des points de vulnérabilité
 Proposition de sécurisation:
 + pare-feu applicatif
 + journalisation
 + isolation

Gouvernance sécurité d'un système LLM/agent

Politiques de droits, rôles et audit
 Cycle de vie sécurisé d'un prompt / modèle / outil
 Revue de sécurité en phase design:
 + menace, DPIA
 + logs, validation

Sécurité dans le cycle DevSecOps IA

Intégration de la sécurité dans la CI/CD de modèles ou d'agents
 Testing des prompts, scoring automatique
 Méthodologie de revue de chaîne (prompt → outil → réponse)
 Outils de test de vulnérabilités spécifiques aux LLMs

Cadre réglementaire et souveraineté

RGPD appliqué aux systèmes LLM (traces, personnalisation, exécution)
 IA Act : contraintes sur la sécurité et la robustesse des systèmes
 Hébergement sécurisé:
 + cloud souverain
 + LLM self-hosted
 + vector stores chiffrés

Atelier final : Audit d'un système LLM/Agent

Analyse complète d'un prototype avec LangChain ou AutoGen
 Identification de vulnérabilités potentielles
 Élaboration d'un plan de sécurisation