AYI NEDJIMI Consultants

Forensic Post-Hacking : Reconstruction et IA : Guide Complet

Catégorie : Intelligence Artificielle Lecture : 9 min Publié le : 17/02/2026 Auteur : Ayi NEDJIMI

Guide complet de la forensique numérique assistée par IA : collecte automatisée de preuves, reconstruction de timeline par LLM, analyse de malware.

L'analyse de malware est traditionnellement divisée en deux approches complémentaires : l'analyse statique (examen du code sans exécution — désassemblage, décompilation, analyse des chaînes de caractères, des imports, des entêtes PE) et l'analyse dynamique (exécution en sandbox pour observer le comportement réel). Les deux approches ont leurs limites : l'analyse statique est contournée par l'obfuscation, le packing et l'anti-reverse engineering ; l'analyse dynamique est contournée par les techniques anti-sandbox (détection d'environnement virtuel, déclencheurs temporels, triggers conditionnels). Les **LLM appliqués à l'analyse de malware** apportent une troisième dimension : la compréhension sémantique du code, capable de dépasser les obstacles de l'obfuscation pour extraire l'intention fonctionnelle. Pour approfondir, consultez Orchestration d'Agents IA : Patterns et Anti-Patterns. Guide complet de la forensique numérique assistée par IA : collecte automatisée de preuves, reconstruction de timeline par LLM, analyse de malware. Ce guide couvre les aspects essentiels de ia forensic post hacking reconstruction : méthodologie structurée, outils recommandés et retours d'expérience opérationnels. Les professionnels y trouveront des recommandations directement applicables.

Des outils comme **MalGPT**, **WormGPT Defender** (usage défensif), ou les intégrations LLM dans IDA Pro et Ghidra permettent de soumettre du code désassemblé ou décompilé (en C, pseudocode ou assembleur) à un LLM qui produit une explication en langage naturel : "Ce bloc de code énumère les processus en cours, vérifie si l'un d'eux correspond à une liste hardcodée de processus d'analyse (Process Monitor, Wireshark, x64dbg), et termine l'exécution si un tel processus est détecté — il s'agit d'une technique anti-analyse typique." Cette explication accélère considérablement la compréhension des analystes, en particulier pour du code fortement obfusqué ou pour des analystes moins expérimentés.

La combinaison LLM + analyse de comportement sandbox produit les résultats les plus complets. Des plateformes comme **Any.run** avec assistance IA, **Joe Sandbox AI Report**, ou **Hybrid Analysis avec GPT** fournissent des rapports d'analyse qui intègrent les sorties de la sandbox (appels système, modifications de registre, communications réseau, fichiers créés) avec une analyse sémantique LLM qui relie ces comportements à des familles de malware connues, des groupes d'attaquants, et des techniques MITRE ATT&CK. L'analyste reçoit en quelques minutes un rapport structuré qui lui aurait demandé plusieurs heures, lui permettant de concentrer son expertise sur la validation des hypothèses et l'investigation des aspects les plus complexes.

```
# Assistant forensique IA pour analyse de malware et reconstruction d'incident
# Illustre l'utilisation d'un LLM pour la phase d'analyse forensique

import anthropic
import json
from pathlib import Path

class ForensicAIAssistant:
    """
    Assistant IA pour l'analyse forensique post-incident.
    Analyse les artefacts collectés et produit une timeline narrative.
    """

    FORENSIC_SYSTEM_PROMPT = """
    Tu es un expert forensique numérique senior. Analyse les artefacts fournis
    et produis:
    1. Une timeline chronologique des événements suspects
    2. Un mapping avec les techniques MITRE ATT&CK correspondantes
    3. Une évaluation de la criticité (données potentiellement exfiltrées,
       systèmes compromis)
    4. Des hypothèses d'attribution basées sur les TTPs observés
    5. Les IoC (hashes, IPs, domaines, chemins de fichiers) à bloquer immédiatement

    Sois factuel et précis. Indique clairement les certitudes vs les hypothèses.
    Format de sortie: JSON structuré + résumé narrative en français.
    """

    def __init__(self, api_key: str):
        self.client = anthropic.Anthropic(api_key=api_key)

    def analyze_artifact_batch(self, artifacts: dict) -> dict:
        """
        Analyse un batch d'artefacts forensiques et retourne une analyse structurée.

        Args:
            artifacts: dict contenant les artefacts (logs, hashes, registry keys, etc.)
        """
        # Formatage des artefacts pour le prompt
        artifact_text = json.dumps(artifacts, indent=2, ensure_ascii=False)

        prompt = f"""
        ARTEFACTS FORENSIQUES À ANALYSER:
        {artifact_text}

        Produis une analyse forensique complète selon le format demandé.
        Identifie les patterns d'attaque et mappe les techniques MITRE ATT&CK.
        """

        response = self.client.messages.create(
            model="claude-sonnet-4-5-20250929",
            max_tokens=4096,
            system=self.FORENSIC_SYSTEM_PROMPT,
            messages=[{"role": "user", "content": prompt}]
        )

        return {
            "raw_analysis": response.content[0].text,
            "token_usage": response.usage.input_tokens + response.usage.output_tokens,
            "artifacts_analyzed": len(artifacts)
        }

    def generate_incident_report(self, analysis_results: list, incident_id: str) -> str:
```

```
        """
        Génère un rapport d'incident structuré à partir des analyses.

        Args:
            analysis_results: Liste des analyses par batch d'artefacts
            incident_id: Identifiant de l'incident
        """
        combined_analysis = "\n\n---\n\n".join(
            [r["raw_analysis"] for r in analysis_results]
        )

        report_prompt = f"""
        INCIDENT ID: {incident_id}

        ANALYSES FORENSIQUES:
        {combined_analysis}

        Génère un rapport d'incident forensique complet incluant:
        - Résumé exécutif (max 300 mots, non-technique)
        - Chronologie détaillée de l'attaque
        - Systèmes et données affectés
        - Techniques ATT&CK utilisées (avec IDs)
        - IoC pour blocage immédiat
        - Recommandations de remédiation priorisées
        - Évaluation de l'attribution (avec niveau de confiance)

        Avertissement: chaque conclusion doit indiquer le niveau de confiance
        (HAUTE/MOYENNE/FAIBLE) et la source des preuves.
        """

        report_response = self.client.messages.create(
            model="claude-sonnet-4-5-20250929",
            max_tokens=8192,
            messages=[{"role": "user", "content": report_prompt}]
        )

        return report_response.content[0].text

# Utilisation:
# assistant = ForensicAIAssistant(api_key="...")
# artifacts = {
#     "suspicious_processes": ["powershell.exe -enc BASE64...", "cmd.exe /c whoami"],
#     "registry_modifications": ["HKLM\\Software\\Microsoft\\Windows\\CurrentVersion\
\Run"],
#     "network_connections": [{"dst": "185.220.101.45", "port": 4444, "protocol": "TCP"}],
#     "file_hashes": {"malware.exe": "sha256:a1b2c3..."},
# }
# analysis = assistant.analyze_artifact_batch(artifacts)
# print(analysis["raw_analysis"])
```

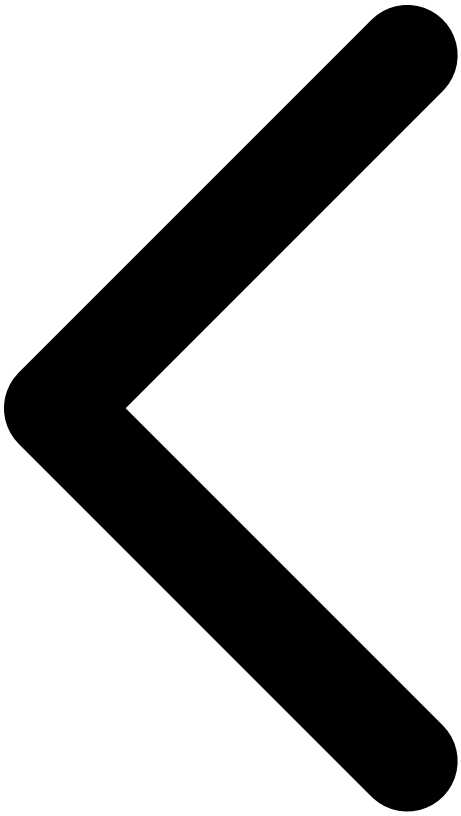

Timeline Section 4 / 8 Attribution

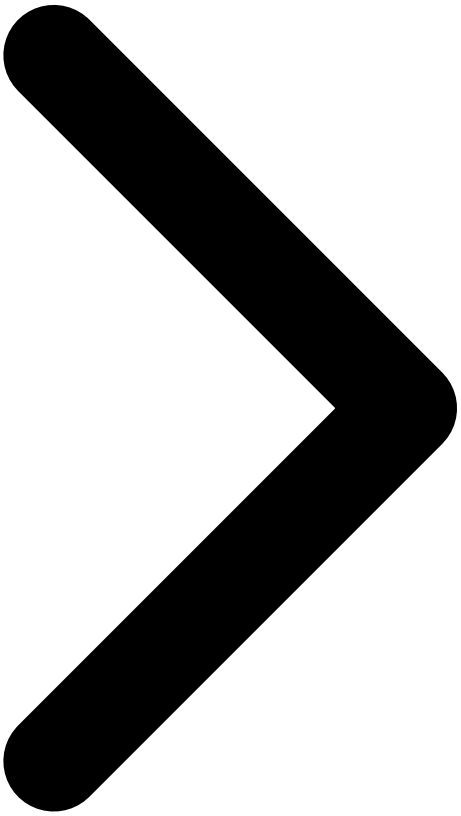

5 Analyse d'Attribution

L'**attribution d'une cyberattaque** — identifier l'acteur responsable avec un niveau de confiance suffisant — est l'une des tâches les plus complexes de la forensique numérique et de la cyber threat intelligence. Elle repose sur la comparaison des TTPs observés pendant l'incident avec les profiles comportementaux connus des groupes d'attaquants (APT groups) répertoriés dans des bases comme MITRE ATT&CK Groups, Mandiant APT Profiles, ou les rapports CrowdStrike Adversary Intelligence. L'IA accélère cette comparaison en transformant les TTPs observés en vecteurs numériques et en calculant des similarités avec les profils connus de milliers de groupes d'attaquants.

Les modèles d'attribution IA analysent plusieurs couches de preuves : les **indicateurs techniques** (hashes de malware connus, infrastructure C2 réutilisée, techniques de déploiement caractéristiques), les **indicateurs comportementaux** (heures d'activité cohérentes avec un fuseau horaire, langues détectées dans les artefacts, ciblage sectoriel), et les **indicateurs opérationnels** (erreurs de sécurité opérationnelle, réutilisation d'outils entre campagnes, délais

d'opération caractéristiques). Des LLM fine-tunés sur des bases de rapports d'attribution publics (APT29, APT41, Lazarus Group, FIN7…) peuvent identifier des correspondances subtiles avec des groupes connus, produire un score de confiance pondéré, et lister les preuves supportant et contredisant chaque hypothèse d'attribution.

L'attribution IA doit être traitée avec prudence dans les contextes légaux et diplomatiques. Les **faux flags** — techniques délibérées par lesquelles un attaquant complexe imite les TTPs d'un autre groupe pour induire une mauvaise attribution — sont de plus en plus aboutis. Des modèles adversariaux peuvent même être utilisés pour générer des artefacts falsifiés qui trompent les systèmes d'attribution IA. Pour ces raisons, les conclusions d'attribution IA doivent toujours être validées par des analystes humains expérimentés, confrontées à plusieurs sources de renseignement indépendantes, et présentées avec des niveaux de confiance explicites (HAUTE/MOYENNE/FAIBLE/INSUFFISANT) plutôt que comme des certitudes.

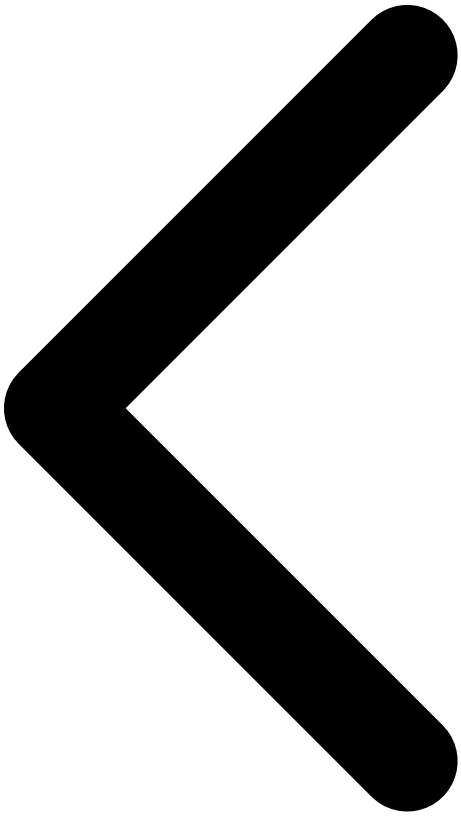

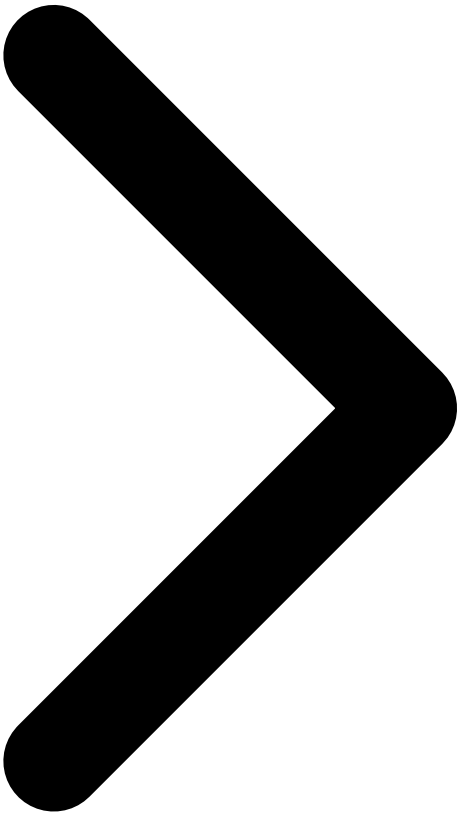

6 Génération Automatique de Rapports

La rédaction de rapports forensiques est une tâche chronophage qui peut représenter 30 à 40 % du temps d'une investigation. Un rapport forensique complet doit satisfaire plusieurs audiences simultanément : les équipes techniques (qui ont besoin des détails techniques exhaustifs pour la remédiation), le management (qui a besoin d'un executive summary compréhensible sans jargon technique), le service juridique (qui a besoin d'une documentation précise de la chaîne de preuves pour d'éventuelles poursuites), et les assureurs (qui ont besoin d'une évaluation des dommages et des lacunes de contrôle). Produire ces quatre versions manuellement pour chaque incident est un effort considérable. Pour approfondir, consultez Reinforcement Learning Appliqué à la Cybersécurité.

Les LLM transforment ce processus en **génération multi-format à partir d'une source unique** : l'analyste forensique fournit une structure de données enrichie (timeline d'événements, TTPs identifiés, systèmes affectés, IoC, hypothèses d'attribution) et le LLM génère automatiquement les différentes versions du rapport, calibrant le niveau technique et le

vocabulaire selon l'audience cible. La version technique inclut les hashes de tous les artefacts, les requêtes de corrélation, les résultats bruts de PLASO et de Volatility ; la version executive présente les faits essentiels (qui, quoi, quand, données exposées, impact business) en langage non-technique ; la version juridique suit les templates de documentation reconnus (ACPO Good Practice Guide, ISO/IEC 27037).

La **standardisation des rapports IA** via des formats comme STIX 2.1 (Structured Threat Information eXpression) et TAXII (Trusted Automated eXchange of Intelligence Information) facilite le partage de threat intelligence entre organisations. Un rapport généré par IA peut simultanément produire un fichier STIX 2.1 structuré contenant tous les IoC, TTPs, et relations entre entités, prêt à être importé dans les plateformes de threat intelligence comme MISP, OpenCTI ou Anomali. Ce partage automatisé accélère la dissémination des indicateurs de compromission au sein de la communauté de sécurité, permettant à d'autres organisations de se défendre contre des attaquants similaires.

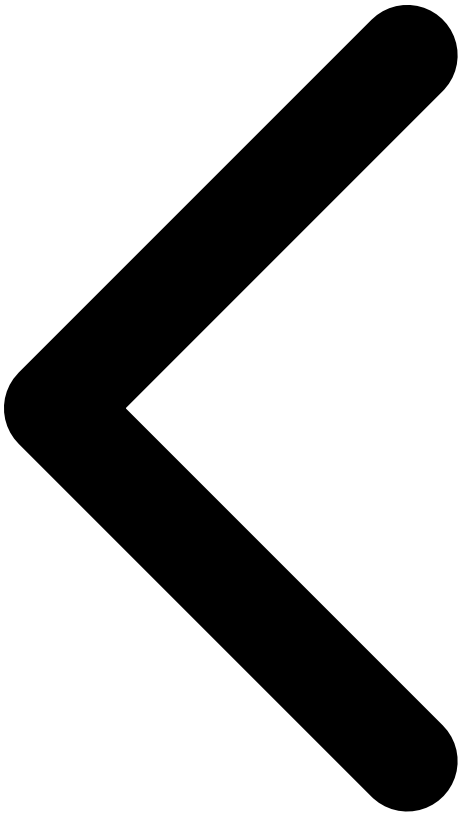

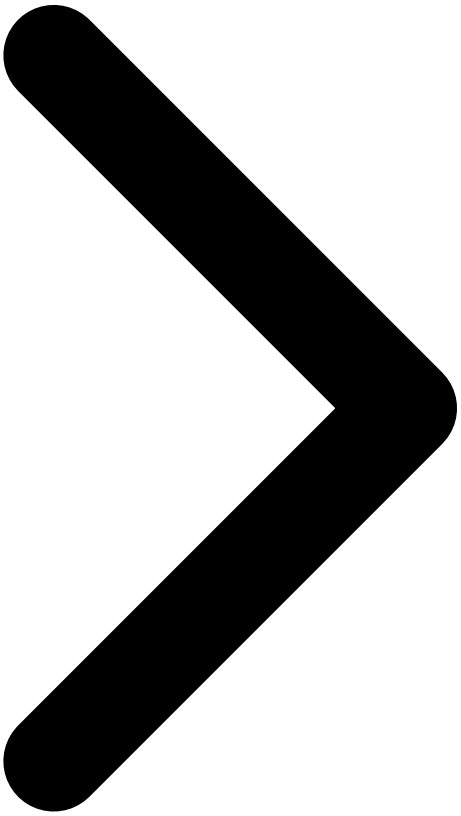

7 Outils (Autopsy, PLASO, Volatility + IA)

Autopsy (The Sleuth Kit) est l'une des plateformes forensiques open-source les plus utilisées, récemment enrichie de modules IA. Son module **ML Classifier** utilise des modèles entraînés pour identifier automatiquement le contenu des fichiers suspects (malware, données sensibles, fichiers cachés), scorer les artefacts par pertinence forensique, et suggérer des pistes d'investigation. L'intégration LLM récente (via plugin) permet de décrire en langage naturel ce que l'on cherche ("afficher tous les fichiers créés dans le profil utilisateur dans les 48h avant l'incident") et de convertir ces requêtes en filtres forensiques précis. Autopsy intègre également des connecteurs vers VirusTotal, MalShare et d'autres sources de threat intelligence pour enrichir automatiquement les hash lookups.

PLASO (log2timeline), développé par Kristinn Gudjonsson, est le standard de facto pour la création de super-timelines forensiques. Il analyse plus de 200 formats de sources (Windows Event Log, NTFS, macOS unified logging, Linux syslog, browser databases, mobile device databases) et produit un fichier CSV ou une base de données Elasticsearch avec tous les

événements horodatés. L'intégration IA avec PLASO passe par **Timesketch**, la plateforme d'analyse collaborative qui inclut désormais des fonctionnalités ML : détection de clusters d'événements anormaux, clustering de sessions utilisateurs, et intégration avec des LLM pour la requête en langage naturel et la narration automatique des séquences d'événements.

Volatility Framework, l'outil de référence pour l'analyse de dumps mémoire, intègre depuis la version 3 des capacités IA via des plugins communautaires et des intégrations LLM. L'analyse d'un dump mémoire de 16 Go peut maintenant être orchestrée par un pipeline IA : exécution automatique d'une suite de plugins (pslist, dlllist, netscan, malfind, cmdline, pstree), extraction des artefacts suspects, hash lookup automatique, et soumission au LLM pour une interprétation contextuelle. Le plugin **Volatelligence** (community) connecte Volatility à des LLM pour produire une narration automatique des processus suspects, des connexions réseau anormales et des injections de code détectées dans la mémoire.

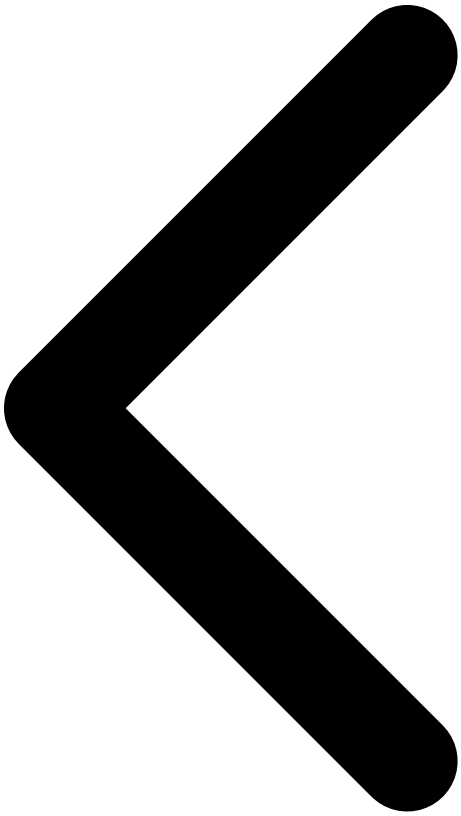

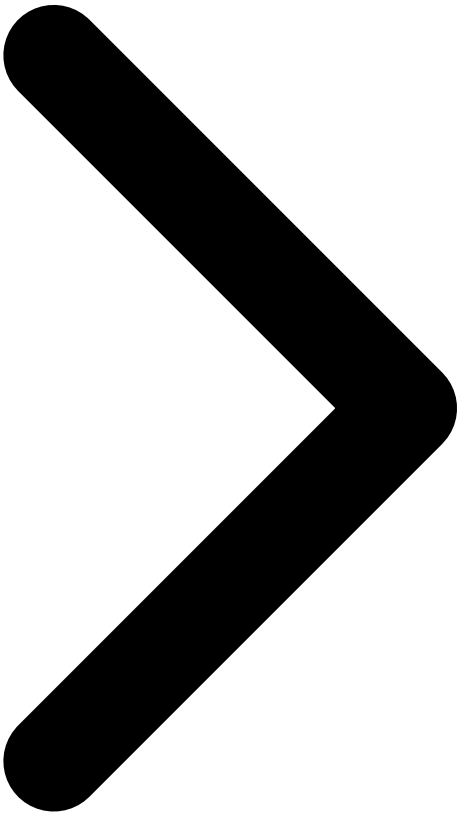

8 Considérations sur la Chaîne de Custody

La **chaîne de custody (chain of custody)** est le registre documentaire ininterrompu qui prouve que des preuves numériques n'ont pas été altérées depuis leur collecte jusqu'à leur présentation en justice. Dans le contexte de la forensique assistée par IA, maintenir cette chaîne impose des exigences supplémentaires par rapport à la forensique traditionnelle. Toute action effectuée par un système IA sur des preuves numériques doit être journalisée avec une granularité suffisante pour être auditée : quel modèle a analysé quelles données, avec quels paramètres, à quel moment, et avec quels résultats. Cette traçabilité de l'IA est d'autant plus importante que les LLM sont des "boîtes noires" dont les décisions peuvent être difficiles à expliquer en contexte judiciaire. Pour approfondir, consultez Sécurité des Agents IA en Production : Sandboxing et Contrôles.

Des mécanismes technologiques renforcent la chaîne de custody dans les systèmes forensiques IA. La **blockchain d'evidence** (registre distribué immuable) enregistre le hash de chaque artefact collecté et de chaque rapport produit avec un horodatage certifié (RFC 3161), créant une

preuve cryptographique d'intégrité impossible à falsifier. Les **signatures numériques des rapports IA** (via certificats qualifiés eIDAS) lient chaque rapport à son auteur humain (l'analyste validant le rapport généré par IA) et à la version du modèle IA utilisée. Ces mécanismes permettent de répondre aux objections défensives lors de procédures judiciaires : "prouvez que les preuves n'ont pas été altérées" et "prouvez que le rapport reflète fidèlement les artefacts collectés".

La **validation humaine obligatoire** reste le principe central de toute forensique IA admissible en justice. Les LLM peuvent produire des hallucinations — des informations plausibles mais fausses — qui, si elles sont intégrées sans vérification dans un rapport forensique présenté en justice, pourraient compromettre une procédure entière. Les bonnes pratiques exigent que chaque conclusion IA soit vérifiée par un analyste humain certifié (GIAC GCFE, EnCE, CFCE) avant d'être incluse dans un rapport officiel, que les niveaux de confiance IA soient explicitement mentionnés, et que les sources primaires (artefacts bruts) soient toujours accessibles pour contre-expertise. L'IA est un assistant puissant de la forensique, mais la responsabilité légale et professionnelle reste entièrement celle de l'analyste humain.

Conclusion : La forensique numérique assistée par IA réduit le MTTU de 75-83 % tout en améliorant la couverture d'analyse. La combinaison PLASO + LLM pour la timeline, Volatility + IA pour l'analyse mémoire, Autopsy + ML pour le triage, et les LLM pour la génération de rapports multi-formats constitue l'état de l'art en 2026. La chaîne de custody et la validation humaine systématique garantissent l'admissibilité judiciaire dans ce contexte d'automatisation croissante.

Considerations pratiques avancees

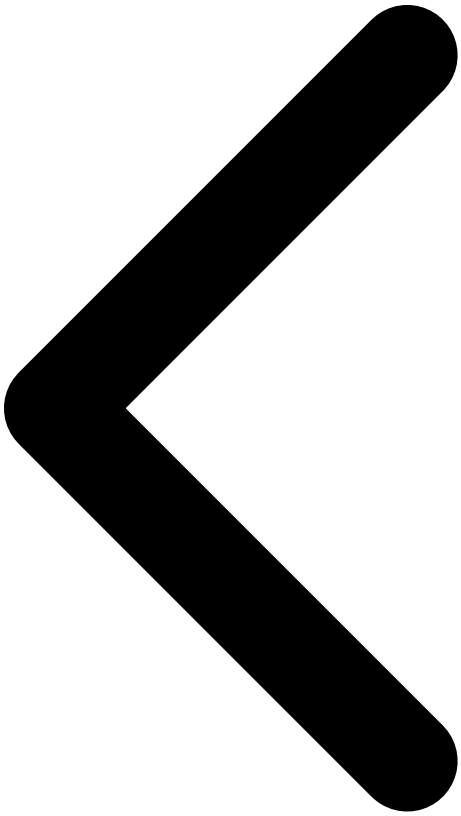

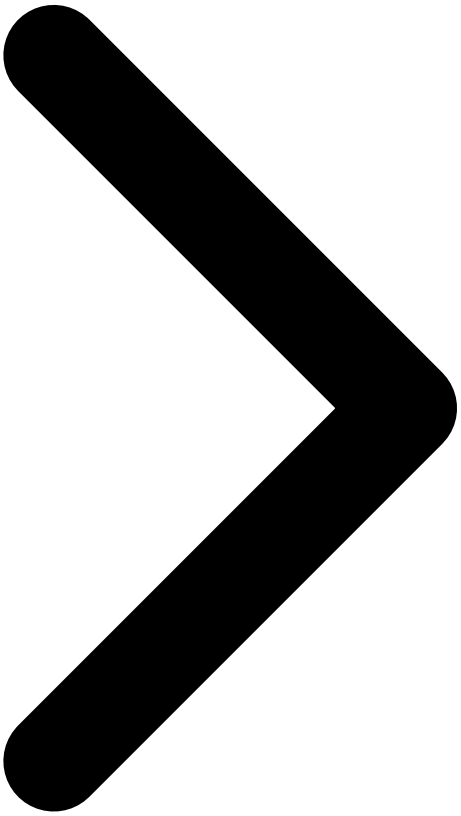

Besoin d'une investigation forensique post-incident ?

Nos experts forensiques interviennent sous 2 heures sur tout incident cyber. Rapport complet avec timeline, attribution et recommandations sous 48h.

Références et ressources externes

- OWASP LLM Top 10 — Les 10 risques majeurs pour les applications LLM
- MITRE ATLAS — Framework de menaces pour les systèmes d'intelligence artificielle
- NIST AI RMF — AI Risk Management Framework du NIST
- arXiv — Archive ouverte de publications scientifiques en IA
- HuggingFace Docs — Documentation de référence pour les modèles de ML

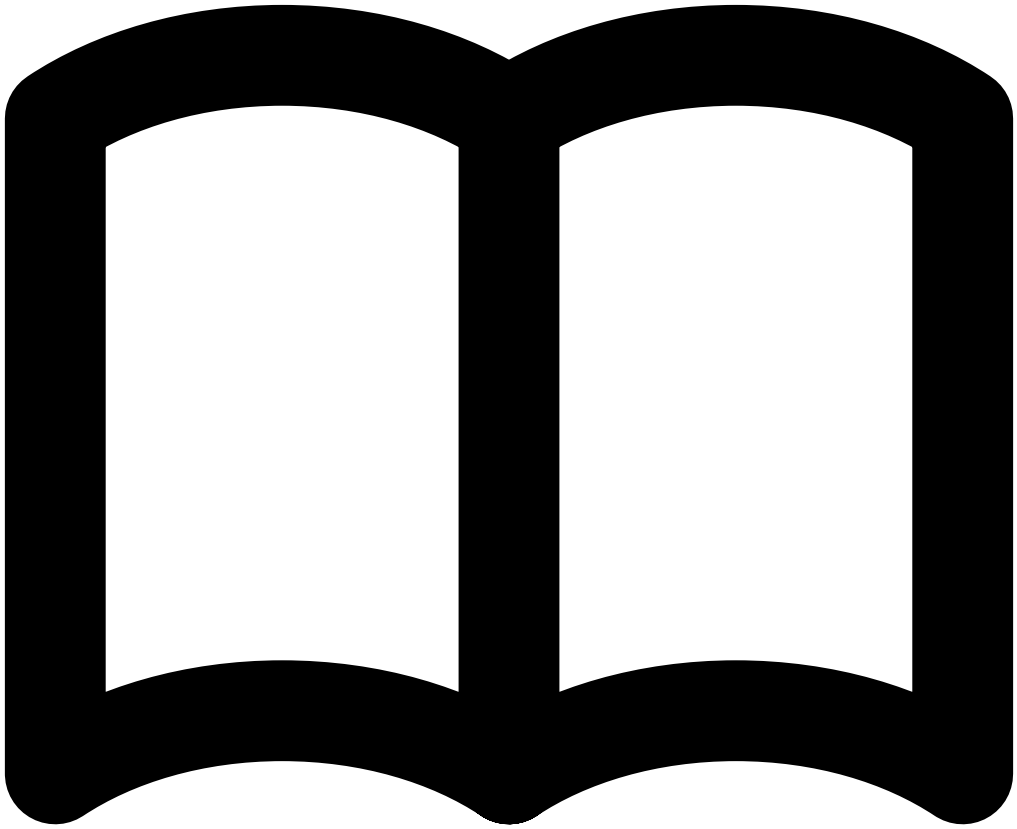

Articles Connexes

Red Teaming Cyber-Défense Agentique
Méthodologie de red teaming pour agents IA.

Détection Multimodale Réseau
CNN, LSTM, GNN pour la cyberdéfense réseau.

Forensique Mémoire
Analyse RAM et artefacts volatiles.

Forensique Windows Server 2025
Nouveaux artefacts et sources de preuves.

Registry Forensics Avancé
Artefacts registre et techniques d'analyse.

Hacking Assisté par IA
Génération de payloads et contre-mesures.

Pour approfondir ce sujet, consultez notre outil open-source ai-prompt-injection-detector qui facilite la détection des injections de prompt.

Sources et références : ArXiv IA · Hugging Face Papers

> Points clés à retenir
>
> - 5 Analyse d'Attribution
> - 6 Génération Automatique de Rapports
> - 7 Outils (Autopsy, PLASO, Volatility + IA)
> - 8 Considérations sur la Chaîne de Custody
> - Considerations pratiques avancees
> - Conclusion

FAQ

Qu'est-ce que Forensic Post-Hacking ?

Le concept de Forensic Post-Hacking est détaillé dans les premières sections de cet article, qui couvrent les fondamentaux, les enjeux et le contexte opérationnel. Pour un accompagnement sur ce sujet, contactez nos experts.

Pourquoi Forensic Post-Hacking est-il important en cybersécurité ?

La compréhension de Forensic Post-Hacking permet aux équipes de sécurité d'améliorer leur posture défensive. Les sections « 5 Analyse d'Attribution » et « 6 Génération Automatique de Rapports » détaillent les raisons de cette importance. Pour un accompagnement sur ce sujet, contactez nos experts.

Comment mettre en œuvre les recommandations de cet article ?

Les recommandations pratiques sont détaillées tout au long de l'article, avec des commandes, des outils et des méthodologies éprouvées. La section « Conclusion » fournit une synthèse actionnable. Pour un accompagnement sur ce sujet, contactez nos experts.

Conclusion

Cet article a couvert les aspects essentiels de Table des Matières, 1 Introduction à la Forensique Numérique Assistée par IA, 2 Collecte Automatisée et Préservation des Preuves. La mise en pratique de ces recommandations permet de renforcer significativement la posture de securite de votre organisation.

Ayi NEDJIMI Consultants — Expert cybersécurité offensive & intelligence artificielle

ayinedjimi-consultants.fr · ayi@ayinedjimi-consultants.fr