



LLM et reverse engineering — analyser le malware



16 mai 2026



Mis à jour le 17 mai 2026



18 min de lecture



Automatisez l'analyse malware avec les LLM : Ghidra + LLM API, classification d'IOC, analyse CFG. Guide technique pour analystes malware et reverse engineering

À RETENIR

A retenir -- LLM et reverse engineering malware

L'intégration des **LLM dans le reverse engineering de malware** accélère drastiquement l'analyse. La classification automatique des fonctions (benigne/malveillante/crypto/C2), l'annotation automatique du code désassemblé réduisent de 60 à 80% le temps d'analyse. L'approche **headless + LLM API** est la combinaison la plus déployée en 2026. Les hallucinations restent la limite principale : valider systématiquement les conclusions LLM aux points de décision et sur les fonctions critiques. L'analyse du ransomware BlackSuit et de Nitrogen en 2025 a validé ces pipelines.

Réponse sous 24h

Devis gratuit



Le **reverse engineering de malware assiste par LLM** représente l'une des avancées de code malveillant depuis l'introduction des debuggers interactifs. Face au volume de 500 000 nouvelles souches identifiées par jour selon Kaspersky Security Bulletin 2024, les analystes ne peuvent plus se permettre d'analyser chaque échantillon manuellement. L'intégration de Ghidra et IDA Pro permet de transformer des fonctions désassemblées en descriptions compréhensibles, d'extraire automatiquement les IOC (Indicators of Compromise) (crypto, network, persistance, C2), et de générer des rapports d'analyse en quelques heures. Cet article présente l'architecture technique complète d'un pipeline de reverse engineering en code Python pour l'intégration Ghidra/LLM, une analyse de cas réels (BlackSuit ransomware), des considérations pour le déploiement en production, et les limites importantes à connaître des hallucinations LLM sur du code désassemblé complexe.

Architecture du pipeline Ghidra + LLM

Le **pipeline de reverse engineering LLM** se compose de quatre étapes principales :

Decompilation Ghidra : utiliser Ghidra en mode headless pour décompiler le binaire et exporter les fonctions décompilées en pseudo-C ou en bytecode annoté

Preprocessing : normaliser le code décompilé (renommer les variables génériques, remplacer les données connues, résoudre les appels d'API Windows)

Analyse LLM : soumettre chaque fonction au LLM pour classification, description

Agrégation et rapport : consolider les analyses par fonction en un rapport d'analyse de malware, les IOC et les recommandations de détection

Réponse sous 24h

Devis
gratuit →