



# Vector DB Poisoning 2026 : Pinecone, Weaviate



16 mai  
2026



Mis à jour le 17 mai  
2026



20 min de  
lecture



3630  
mots



Le vector DB poisoning injecte des embeddings adversariaux qui matchent la requête utilisateur, hijackant un RAG entier. ASR > 80%.

## À RETENIR

### A retenir — Vector Database Poisoning

**Vector DB poisoning** insère des embeddings adversariaux qui matchent la requête utilisateur, hijackant systématiquement le RAG.

**Embedding inversion** (Morris et al., 2023) : à partir d'un embedding text-embedding-3-small, la reconstruction du texte original a >90% de similarité.

Pinecone, Weaviate, Qdrant : sans authentification stricte, l'API d'insertion est exploitée. Cas réel Q1 2026 : 230 RAG entreprise compromis.

**Rogue ANN nodes** : embeddings forgés pour maximiser la similarité avec le cluster cible, devenant le top-1 retrieval pour ce cluster.

In projet cybersécurité  
Réponse sous 24h

Devis  
gratuit



Defenses : access control strict, anomaly detection sur embeddings (Mahalanobis distance), signing des inputs, periodic re-embedding.

Le **vector database poisoning** est l'attaque la moins médiatisée mais l'une des plus dangereuses sur les architectures RAG 2026. Contrairement à l'Indirect Prompt Injection RAG qui insère un texte adversarial dans le corpus, le poisoning attaque directement la couche vectorielle des embeddings stockés dans Pinecone, Weaviate, Qdrant, ChromaDB, Milvus. Un attaquant qui maîtrise la géométrie des embeddings peut créer un vecteur qui correspond statistiquement à la requête utilisateur d'un domaine, devenant le top-1 résultat à chaque retrieval. Cette branche de la recherche ingère alors systématiquement le contenu malveillant. Cet article explore la mécanique mathématique (rogue ANN nodes), le code Python d'attaque, les attaques d'embedding inversion (Morris et al., 2023), et les défenses 2026. Pour les architectes RAG et les CISO, le **vector database poisoning** représente le risque le moins audité mais le plus critique en 2026 — un seul rogue ANN node bien craft peut hijacker l'intégralité du retrieval d'une base de données corporate de millions de documents.

## 1. Genèse et état de l'art

Le concept de poisoning vectoriel émerge en 2024 avec deux papiers fondateurs :

**Zhong et al. (2023)** — *Poisoning Web-Scale Training Datasets*, démontre le poisoning de Common Crawl + RAG corpus.

**Morris et al. (2023)** — *Text Embeddings Reveal (Almost) As Much As Text*, montre comment inverser un embedding pour récupérer le texte original.

**Cheng et al. (2024)** — *PoisonedRAG: Knowledge Poisoning on RAG, A*

Réponse à la question : Comment protéger un RAG ?

Llama 2 RAG.

Devis  
gratuit



---

---

Réponse sous 24h

Devis  
gratuit →