



RAG LLM & Tool Calling

Maximilien Andile
Séminaire Aristote
28 Nov 2025






Florin Pătan

What is it ?

Embeddings

-

Vectorisation



Embedding

Problème : Les ordinateurs ne peuvent pas comprendre directement le texte humain, nous avons besoin d'un format numérique

Solution : Transformer le texte en une liste de nombres qui


Capture la **Syntaxe**
(**sparse** vectors)

Capture **sens et contexte**
(Vecteurs denses)

I love golang


Embedding
Algo

[0.016312562 0.010191596
-0.045032285 -0.012354587
-0.01766443 -0.06242634
-0.0018334733 0.048577186
-0.012076703 ...
-0.062306173]



2013 : Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*.

Word2vec => Limitation: Only represented single words, not whole sentences.



Démo 1



Comment vectoriser un texte en utilisant
langchaingo

Modèles :

- Google - gemini-embedding-001
- OpenAI - text-embedding-3-small
- Mistral

Contexte



BOAMP.fr
Bulletin officiel des annonces des marchés publics


BOAMP.fr - Bulletin officiel des annonces des marchés publics - Accueil

Détail de l'avis 25-124767

Avis n° 25-124767 Publié le 9 novembre 2025
Date limite de réponse le 22/12/2025 à 17h00

 **Tierce Maintenance Applicative du Système d'Informations MEDOC et applications associées (lot 1) et des Applications bancaires (lot 2)**

DÉPARTEMENT : 93
ACHETEUR : Direction Générale Finances Publiques
TYPE D'AVIS : Avis de marché
PROCÉDURE : Procédure Ouverte




Démo 2

Vectorisation + l'indexation des appels d'offres



LangChainGo

OpenAI



Pinecone

What is it ?

RAG

=

Retrieval-Augmented Generation

-

Génération à enrichissement contextuel

Muhammad Arslan et al. / Procedia Computer Science 246 (2024) 3781–3790




Fig. 3. Evolution of Research Publications on RAG Applications

"Lorsqu'on leur pose des questions spécifiques à un domaine en dehors de leurs données d'entraînement, les LLM peuvent générer des informations incorrectes ou des 'hallucinations'.

Le RAG pallie cette limitation en récupérant des informations à partir d'une source de données externe, qui sont ensuite transmises comme informations contextuelles au modèle LLM pour la génération de la réponse."



Où les RAGs sont-ils utilisés et pourquoi ?

Discipline



Discipline: (Count of Publications)

Medical / Biomedical: (9)

Financial: (2)

Educational: (2)


Technology and Software Development: (9)

Social and Communication: (7)

Literature (3)

Other Categories: (8)

Tasks



Task: (Count of Publications)

Question Answering (QA): (20)

Text Generation and Summarization: (6)


Information Retrieval and Extraction: (6)

Text Analysis and Processing: (5)

Software Development and Maintenance: (4)

Decision Making and Applications: (5)

Other Categories: (6)



Démo 3


Construire une interface de discussion avec
mémoire



<https://llm-go-frontend.vercel.app/chat>

Test =>






Démo 4

Construire une interface de chat
avec DynamoDB pour la
mémoire + déployée sur AWS






Démo 5

Ajouter plus de contexte


(Le « RAG »)




What is it ?

Tool Calling

Outillage des LLM





Démo 6



Ajouter l'appel d'outil

- `search_offer`
- `send_email`



API Gateway



Lambda



- Inadéquation de la **Dimension** Vectorielle
 - Problème : Dimension du vecteur (ex. 1536) différente de celle de l'index (ex. 1024).
 - Solution : Réduire la dimension du vecteur de sortie du modèle d'intégration.
- Modèles de **vectorisation Incohérents**
 - Problème : Modèles différents pour l'indexation (A) et la recherche de requêtes (B).
 - Solution : Utiliser le même modèle pour l'intégration du texte et de la requête (cohérence de similarité).
- Sécurité et **Contrôle de l'Appel d'Outil** (Tool Calling)
 - Abus d'Outil/Vecteur d'Attaque
 - Problème : Lister les outils crée un vecteur d'attaque.
 - Solution : Obfuscuer les noms d'outils (ex. remboursement => courge24) + interdire l'invite système.
 - Manque de Contrôle
 - Problème : Le modèle accède aux outils sans confirmation.
 - Solution : Mettre en œuvre un contrôle (ex. révision par un LLM séparé) avant l'exécution.
- Difficulté de Découpage des Données (Data **Chunking**)
 - Problème : Découpage précis des données difficile.
 - Note : Pas de solution universelle simple ; dépend du contexte.
- Explosion **Budgétaire**
 - Causes : Coûts élevés des LLM et des bases de données vectorielles.
 - Atténuation : Surveiller les prix et explorer les LLM locaux.

Merci !



Golang Paris Meetup
practical-go-lessons.com