[sfeir] & adeo

REX : LES SENTENCE-TRANSFORMERS EN PROD

Comment booster un search avec des LLMs

[≡]

POSITIVE TECH < / > ADEO GROUP

QUI SUIS-JE

ML Engineer

- Chez SFEIR depuis début 2024
- En Mission chez Adeo dans la foulée
- Équipe AAAI

A part le Machine Learning

- Force athlétique (apprenti)
- Bière craft (confirmé)

POSITIVE TECH < / > ADEO GROUP

CONTEXTE

POSITIVE TECH < / > ADEO GROUP

CONTEXTE

LE MOTEUR DE RECHERCHE

- **1,25 milliards** de requêtes en 2024
- **10 millions** de produits (Leroy Merlin France)
- Temps de réponse **100ms** (P50) à **300ms** (P90)
- Efficace sur
  - Mots clefs
  - Références produits
  - Thèmes
  - Requêtes connues
  - …
  - Pas sur le langage naturel
- **2 à 4%** de “langage naturel”

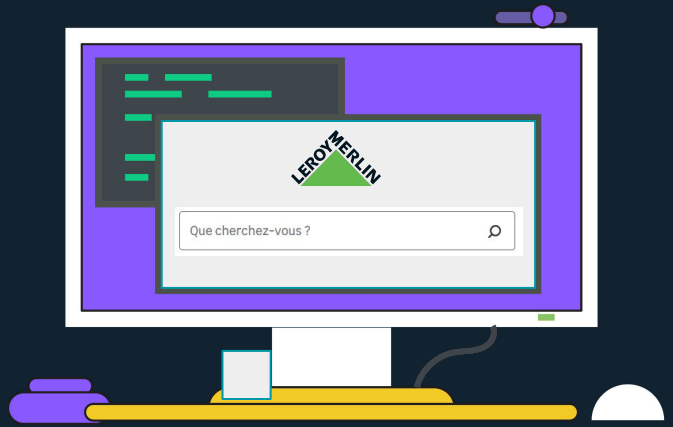

POSITIVE TECH < / > ADEO GROUP

CONTEXTE

LE MOTEUR DE RECHERCHE

25M

REQUÊTES

Traitées de manière non-optimale
(à prendre avec des pincettes)

POSITIVE TECH < / > ADEO GROUP

CONTEXTE

LE “LANGAGE NATUREL”

- “Quels outils pour isoler une toiture ?”

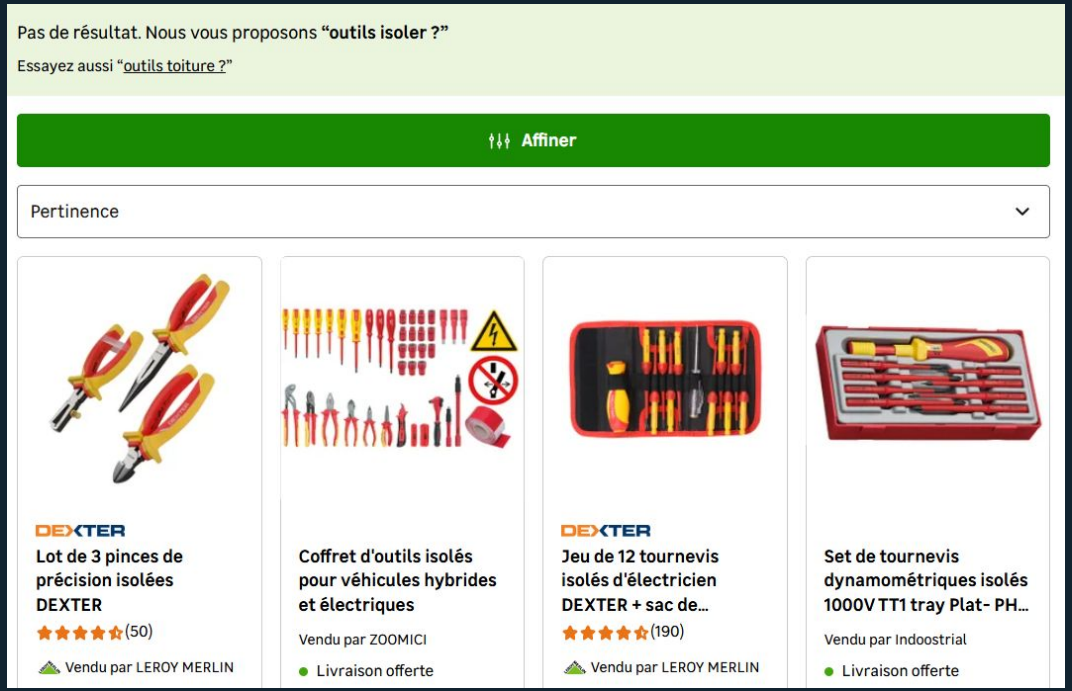

POSITIVE TECH < / > ADEO GROUP

CONTEXTE

LE “LANGAGE NATUREL”

- “Rénover grenier”

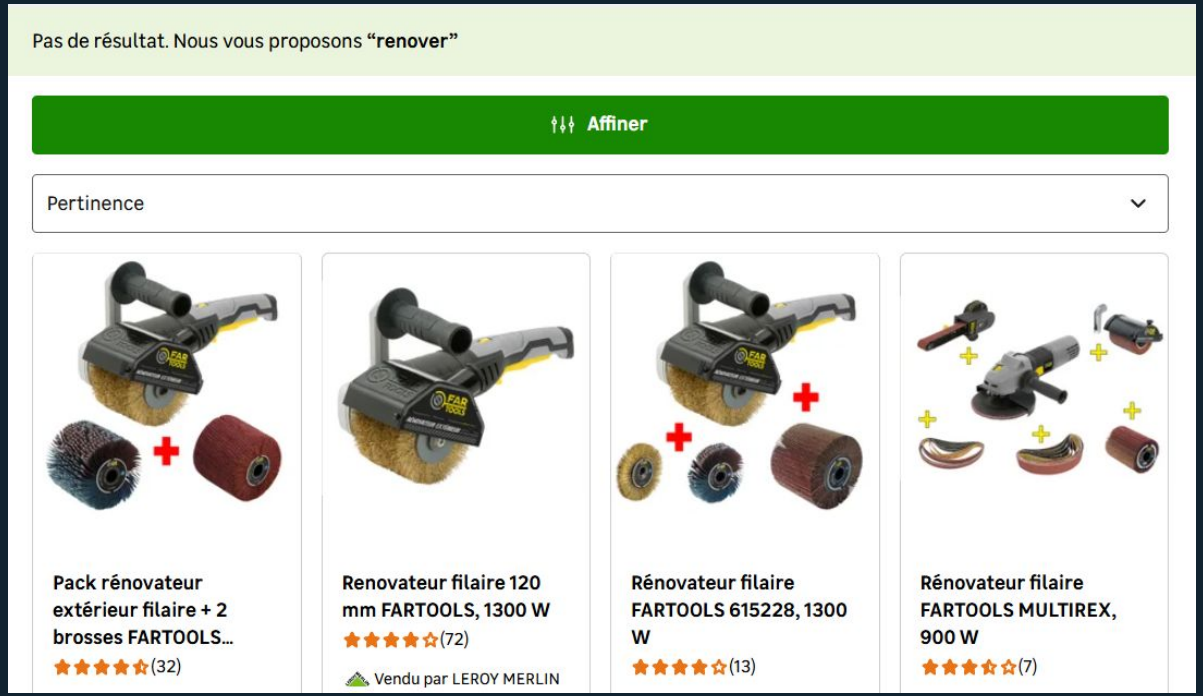

POSITIVE TECH < / > ADEO GROUP

CONTEXTE

BESOIN

Répondre mieux & à plus de requêtes

Ne pas refaire un search entier

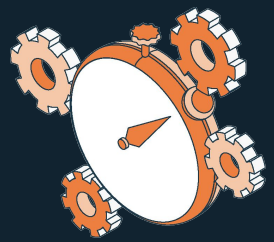

Rester rapide

N’impacter aucun utilisateur négativement

POSITIVE TECH < / > ADEO GROUP

CONTEXTE

NOTRE APPROCHE

- **Solution non invasive, sans refonte**
  - Mobilisation du search actuel efficace en mode “classique”
- **Surcouche en 2 étapes principales**
  - Identification des requêtes
  - Décomposition des requêtes

} **Search**

POSITIVE TECH < / > ADEO GROUP

CONTEXTE

NOTRE APPROCHE

#1

Classification

Identifier si la requête peut être envoyer au search telle quelle ou si elle doit être reformulée

#2

Reformulation

Décomposition de la requête initiale en plusieurs sous-requêtes avec un LLM

#3

Extraction des résultats

Contrôle et parsing des résultats, search multiple en fonction de la reformulation

#4

Affichage côté front

Ordonnancement et affichage des résultats

POSITIVE TECH < / > ADEO GROUP

CONTEXTE

NOTRE APPROCHE

- **Failsafe**
  - Classification **< 30ms (P90)**
  - Reformulation **< 1s (P90)**

  …sinon retour parcours classique

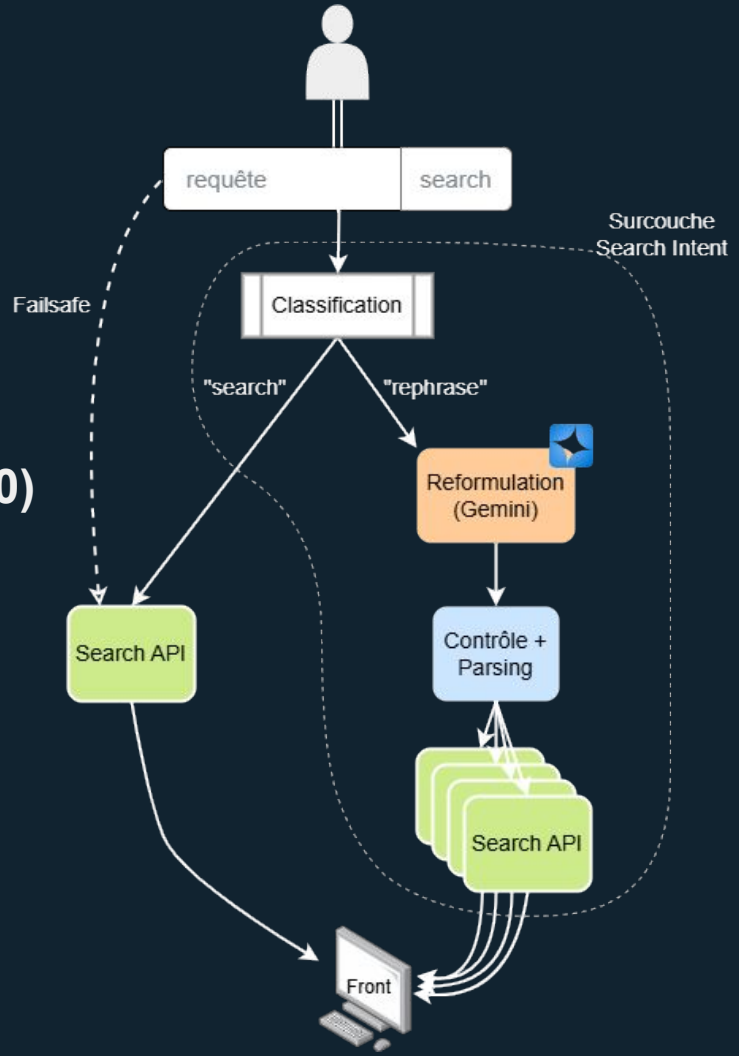

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

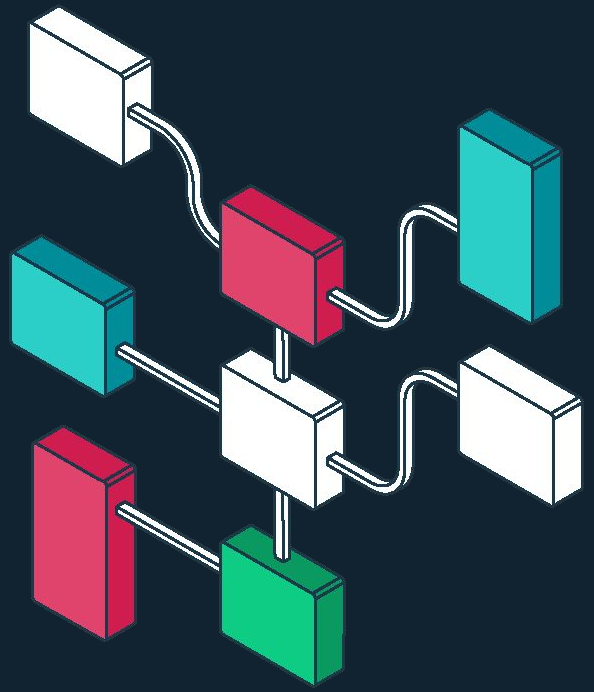

POSITIVE TECH < / >
ADEO GROUP

CLASSIFICATION
DATA & LABELLISATION

- **Stockage des données**
  - GCS / BigQuery

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

DATA & LABELLISATION

- **Stockage des données**
  - GCS / BigQuery
- **Labellisation**
  - Label Studio
    - Golden Dataset
  - Gemini
    - Few shot learning
    - Prompt engineering avec “batch”

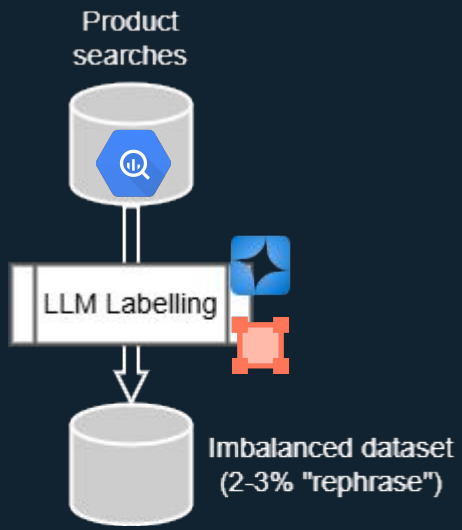

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

DATA & LABELLISATION

- **Stockage des données**
  - GCS / BigQuery
- **Labellisation**
  - Label Studio
    - Golden Dataset
  - Gemini
    - Few shot learning
    - Prompt engineering avec “batch”
- **Augmentation avec Gemini**

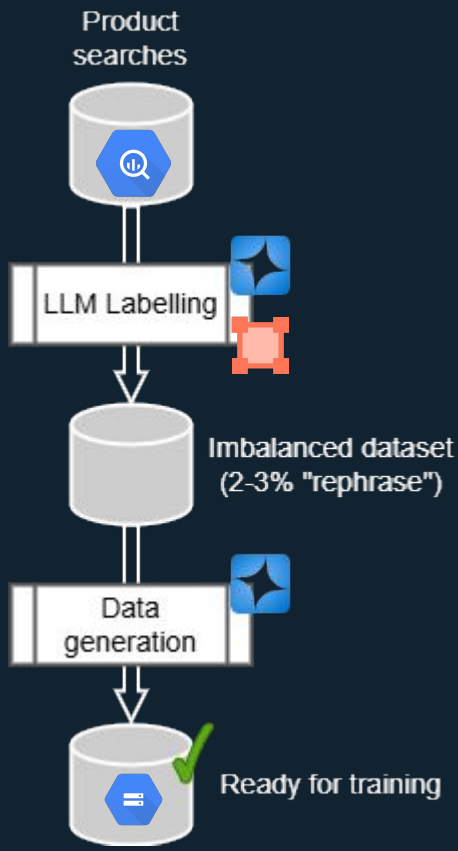

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

NLP

- Vaswani et al. *“Attention is all you need”* - 2017
- Transformer = “brique” de base implémentant le mécanisme d’attention

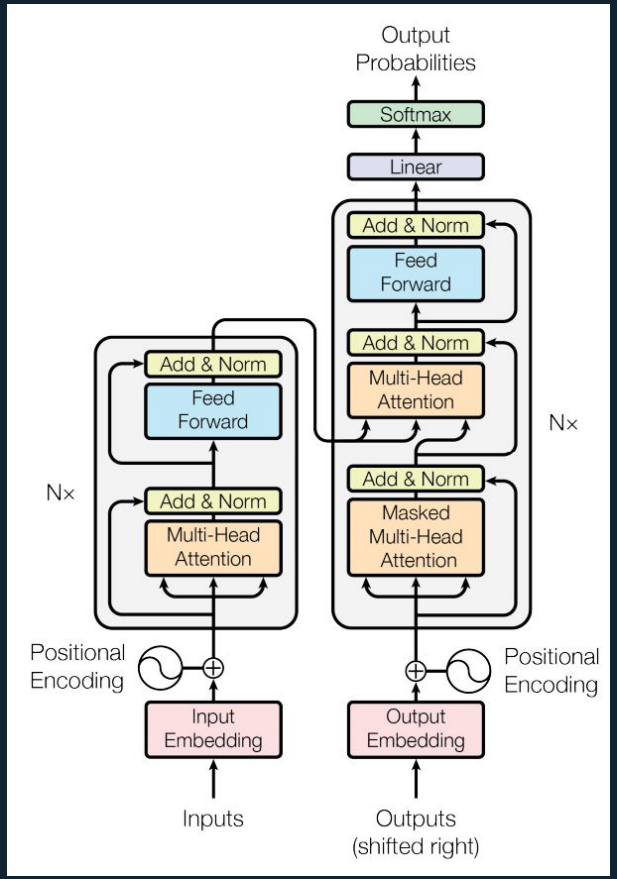

Source : “Attention is all you need”, Fig 1 - Vaswani et al.

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

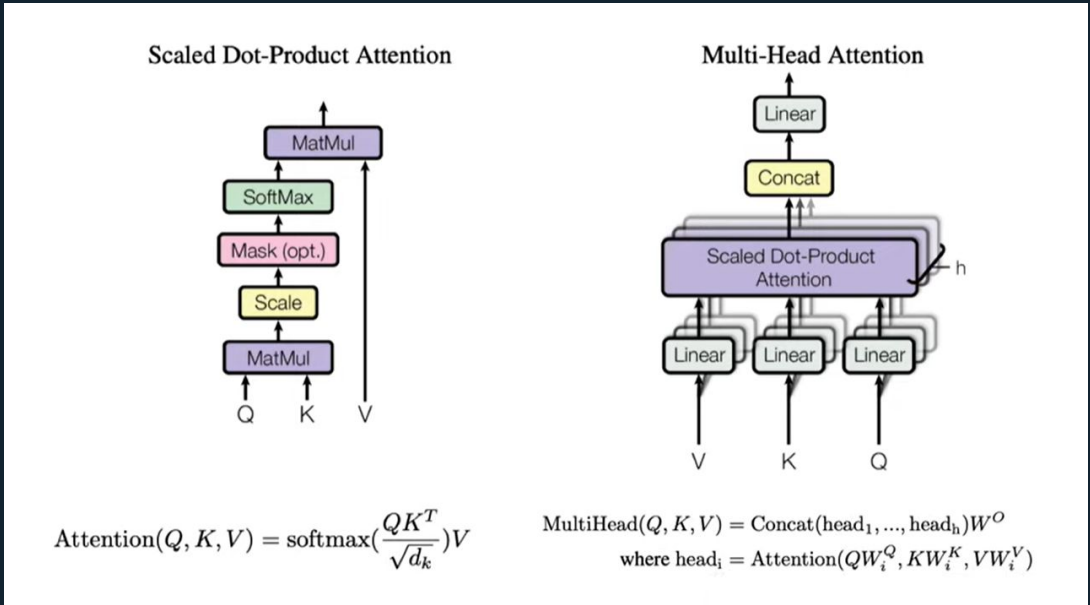

Source : "Attention is all you need", Fig 2 - Vaswani et al.

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

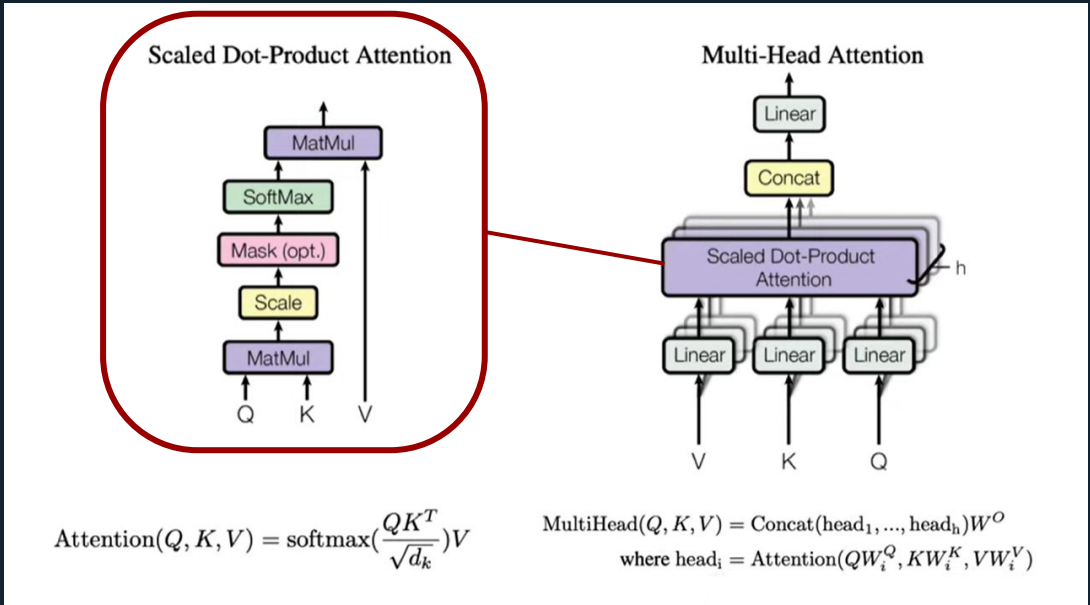

Source : "Attention is all you need", Fig 2 - Vaswani et al.

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION
SENTENCE TRANSFORMERS

TL;DR

Scaled Dot-Product Attention

- Aucun poids ou paramètre
- Ajuste les embeddings initiaux
  - Identification des similarités
  - Recontextualise

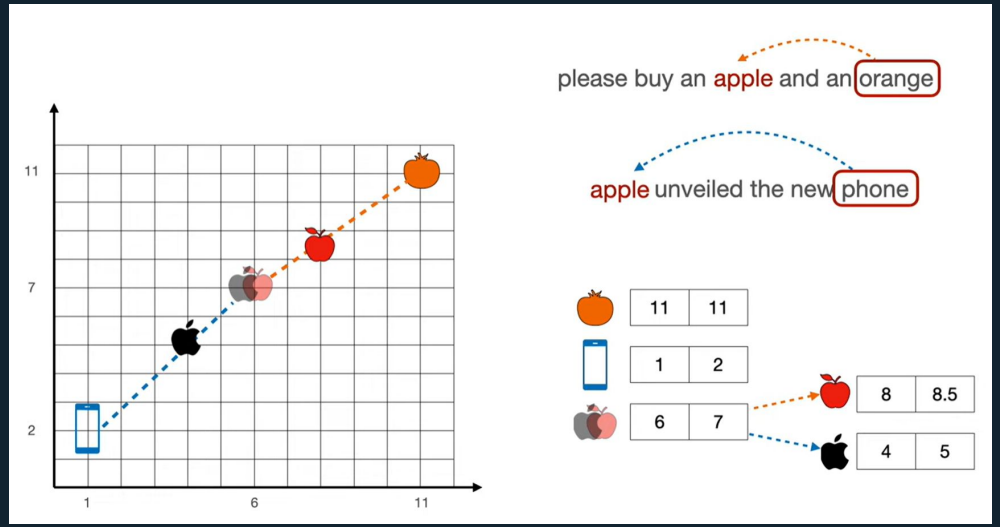

Inspiré de : "The Attention in Large Language Models", Serrano.Academy

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

TL;DR

Scaled Dot-Product Attention

- Aucun poids ou paramètre
- Ajuste les embeddings initiaux
  - Identification des similarités
  - Recontextualise

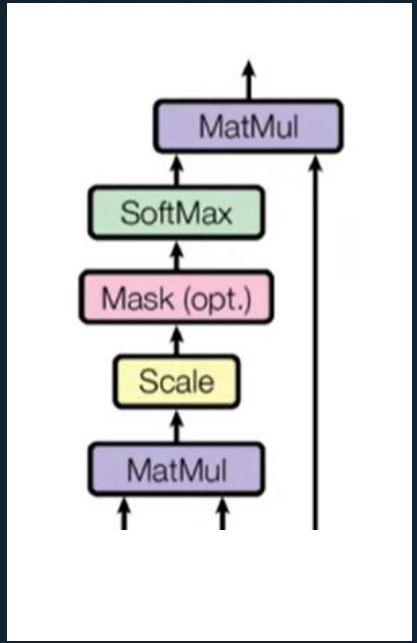

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

TL;DR

Scaled Dot-Product Attention

- Aucun poids ou paramètre
- Ajuste les embeddings initiaux
  - Identification des similarités
    - Chaque combinaison de 2 mots = 1 score
  - Recontextualise
    - Pondération par les scores

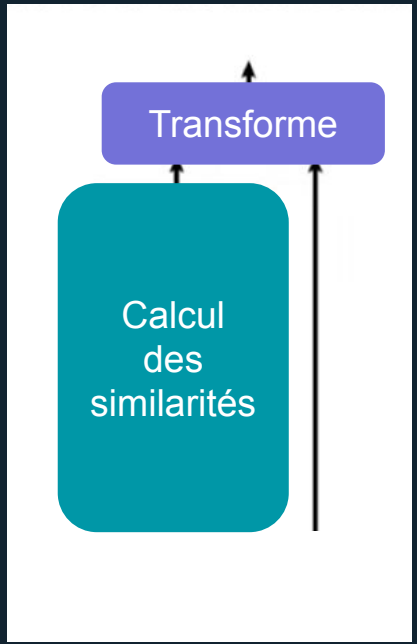

[≡]

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

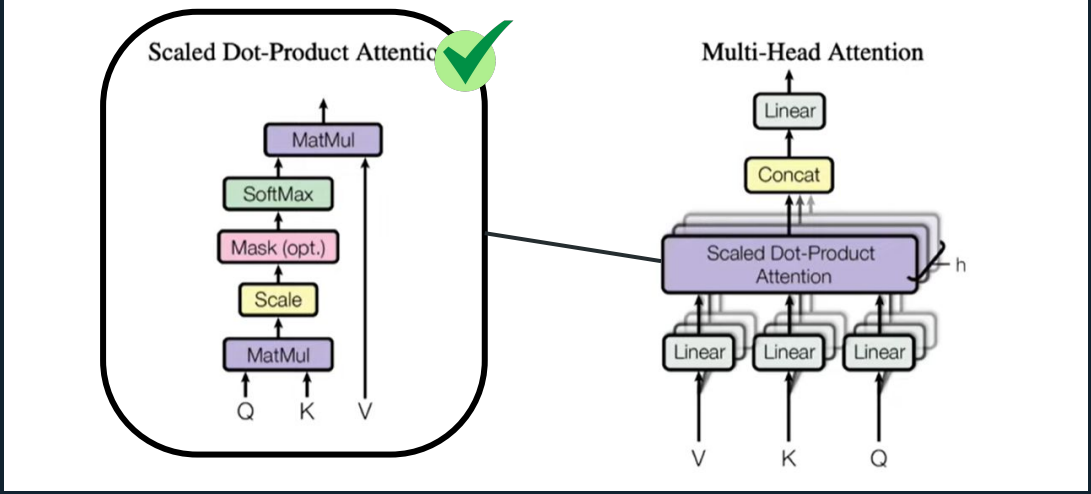

Source : "Attention is all you need", Fig 2 - Vaswani et al.

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

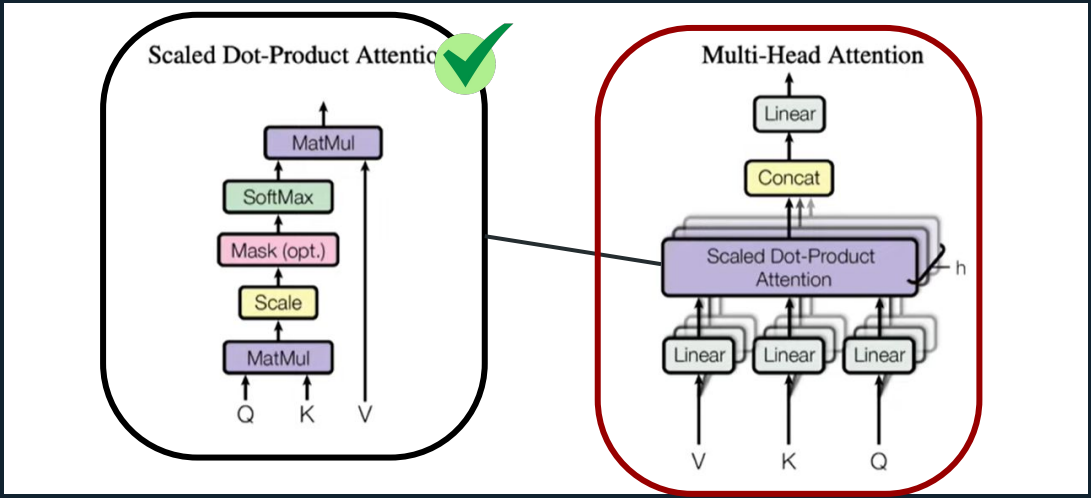

Source : "Attention is all you need", Fig 2 - Vaswani et al.

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

TL;DR

Multi-Head Attention

- Apprentissage de K, Q et V
  - Q - Query
  - K - Key
  - V - Value

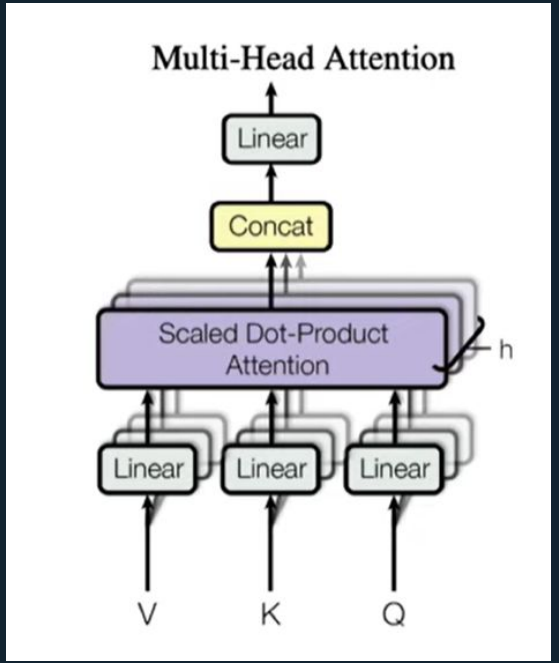

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

TL;DR

Multi-Head Attention

- Apprentissage de K, Q et V
  - Q - Query
  - K - Key
    - Quel concept ?
  - V - Value
    - Quels caractéristiques pertinentes pour le concept ?

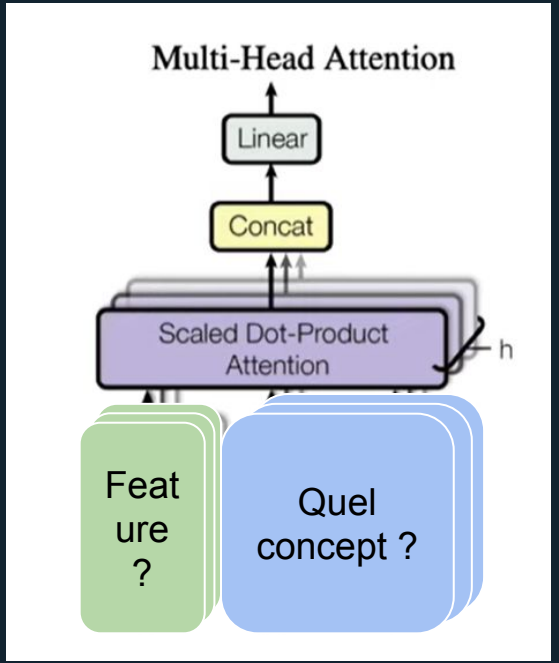

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

Exemple :

“I got some cash at the bank”

Comment réduire l'ambiguïté ?

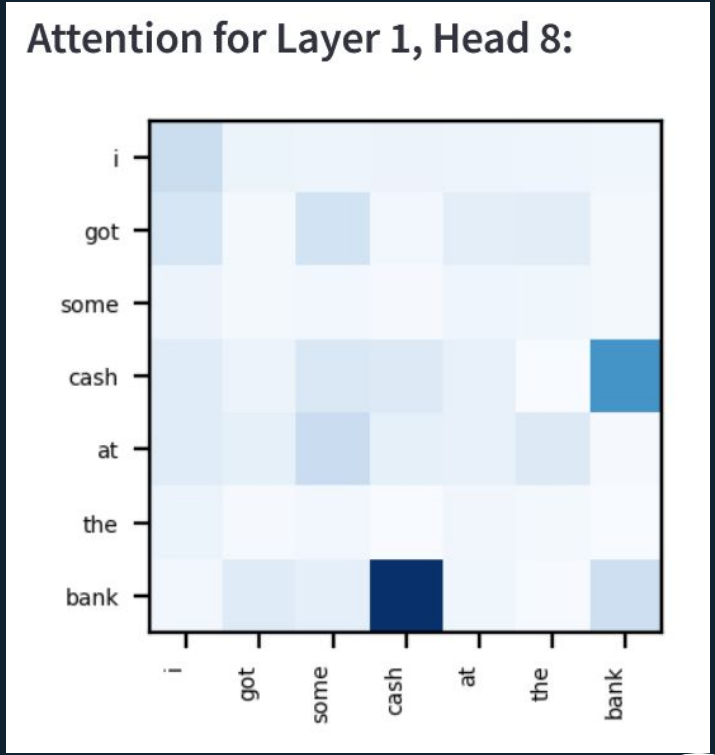

https://bertattentionviz.streamlit.app/

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

Exemple :

“I got some cash at the bank”

Comment augmenter le contexte spatial ?

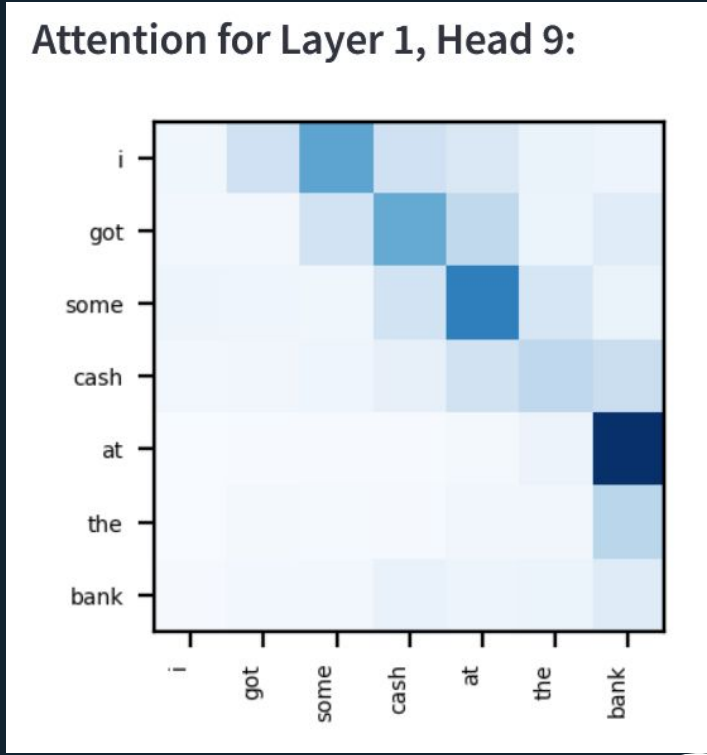

https://bertattentionviz.streamlit.app/

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

Exemple :

“We saw a boat from the bank”

Comment réduire l'ambiguïté ?

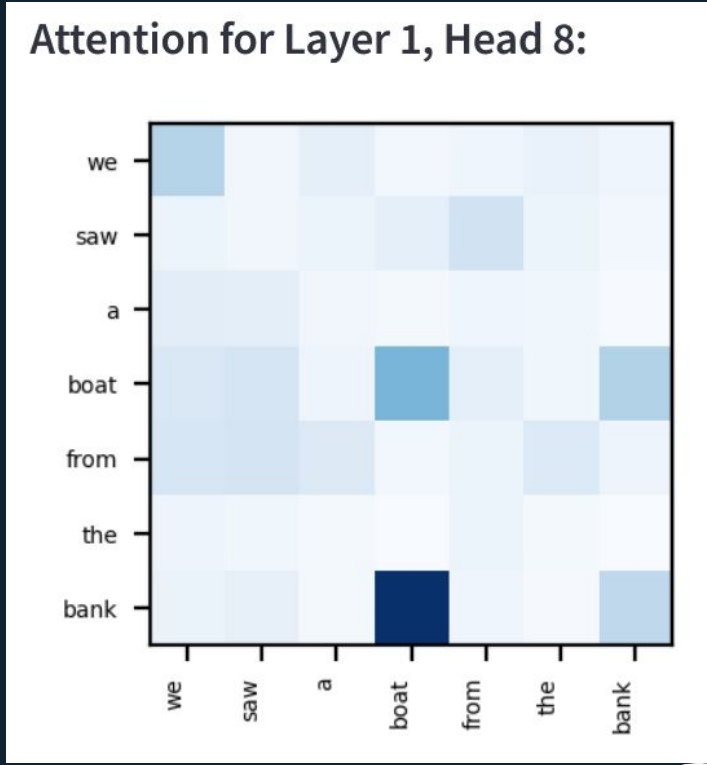

https://bertattentionviz.streamlit.app/

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

Exemple :

“We saw a boat from the bank”

Comment augmenter le contexte spatial ?

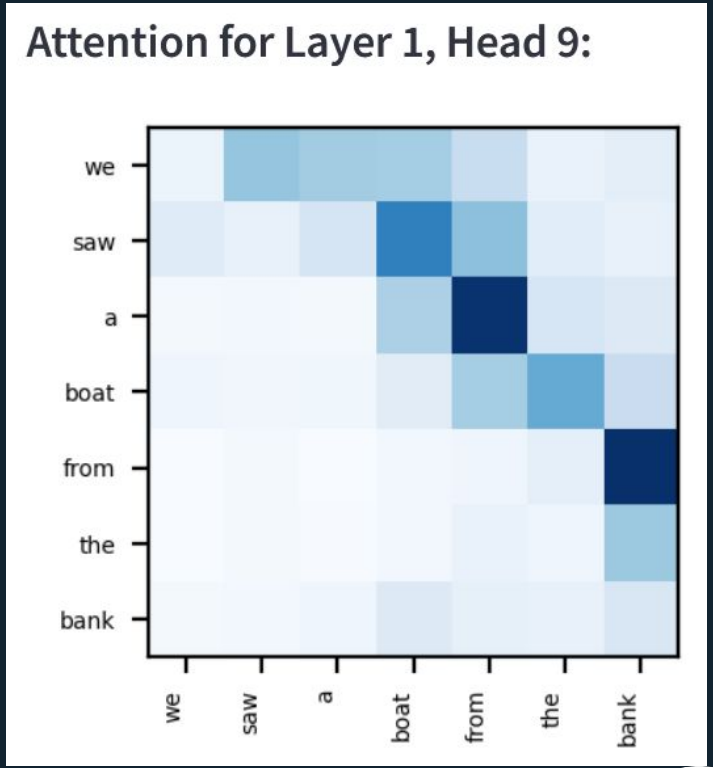

https://bertattentionviz.streamlit.app/

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION
SENTENCE TRANSFORMERS

TL;DR

Multi-Head Attention

- Orienter la transformation
  - Une tête = Un concept sémantique

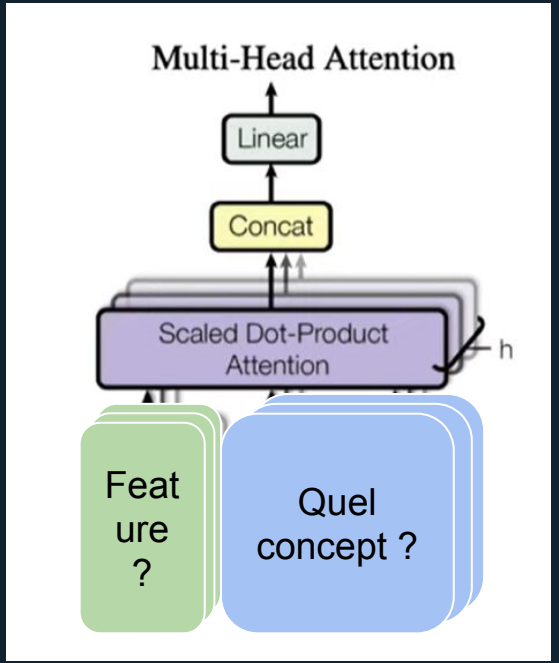

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

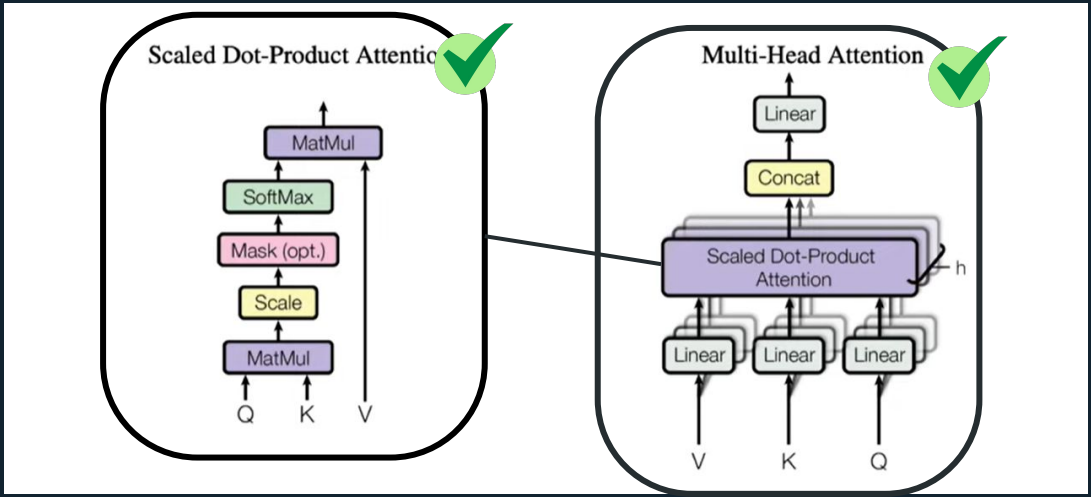

Source : "Attention is all you need", Fig 2 - Vaswani et al.

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

SENTENCE TRANSFORMERS

- Implémentation créée par UKP Lab et maintenue par Hugging Face 🤗
- Classifieur à entraîner
- Encodeur à choisir
    - TinyBert
    - DistilBert
    - Bert-large
    - …

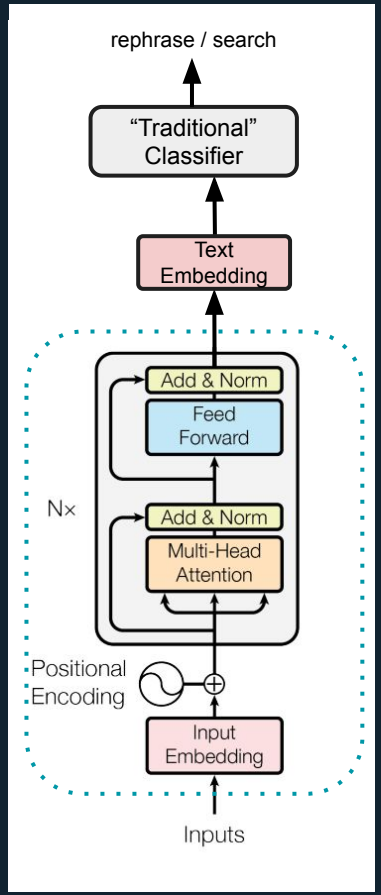

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

CHOIX DU MODÈLE

- **Taille & nombre de paramètres (têtes d'attentions, couches…)**
  - **60Mo**  **XXGo**
- **Performances**
- **Puissance de calcul requise**
- **…**

Meilleur compromis pour notre use case : **TinyBERT**

- Différence de performances
  - Plus que raisonnable
  - Compensable par l'augmentation du dataset
- CPU OK pour l'inférence
  - Permet de rester dans les standards Adeo

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

CHOIX DU MODÈLE

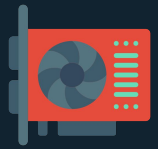

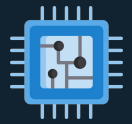

	GPU n1-standard-8 : 8vCPUs 30GB RAM + Tesla T4	CPU n1-standard-8 : 8vCPUs 30GB RAM	Avg weighted F1-score
Bert Uncased	26ms/prediction	65ms/prediction	0.973
TinyBert	2.8ms/prediction	12ms/prediction	0.971

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

CHOIX DU MODÈLE

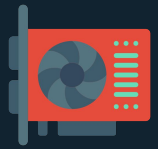

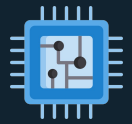

	GPU n1-standard-8 : 8vCPUs 30GB RAM + Tesla T4	CPU n1-standard-8 : 8vCPUs 30GB RAM	Avg weighted F1-score
Bert Uncased	26ms/prediction ✗	65ms/prediction ✗	0.973 ✓
TinyBert	2.8ms/prediction ✓	12ms/prediction ✓	0.971 ✓

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

CHOIX DU SERVING

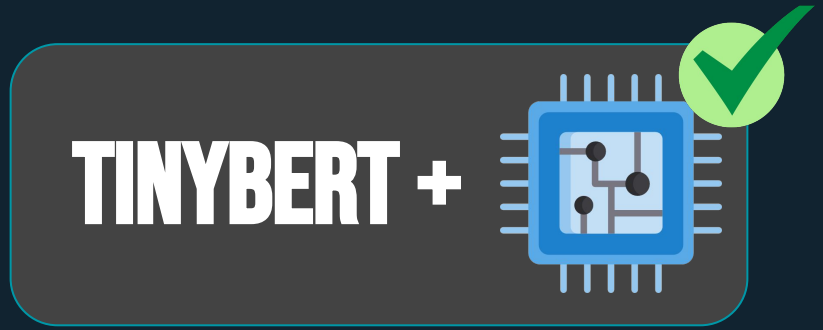

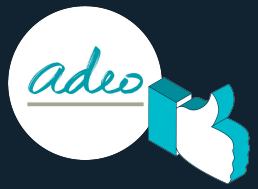

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

TRAINING PIPELINE

ZenML

+

Vertex AI

CLASSIFICATION

TRAINING PIPELINE

ZENML

- Framework & “facilitateur” MLOps
- Infra-agnostique

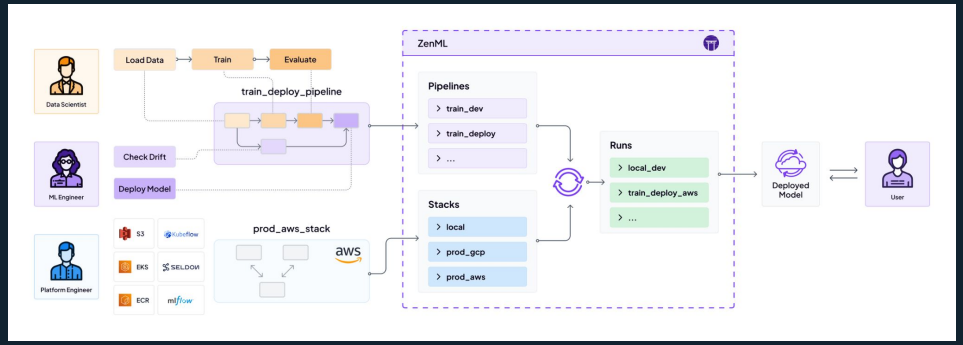

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

TRAINING PIPELINE

ZenML

+

Vertex AI

CLASSIFICATION

CYCLE DE VIE DU MODÈLE

1. **Training**
2. **Evaluation**
   - Modèle **Champion**
   - Modèle **Candidat**
   - **Golden Dataset**
3. **Comparaison**
   - **Candidat** > **Champion**
4. **Promotion**
   - Historisation du **Champion**
   - **Candidat** devient le nouveau **Champion**

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

LEÇONS APPRISES

ZenML

- Agnostique mais pas tant
- Attention aux “vieilles” versions ou gare aux conflits ⚠️
- Quand même sympa une fois mis en place

NLP en général

- Attention à la subjectivité ⚠️
  - Une itération du projet : “question”, “search”, “ambigüe”

Vertex AI

- Image de base ⚠️ Exemple : torch-xla

```
FROM europe-docker.pkg.dev/vertex-ai/training/pytorch-gpu.2-3.py310:latest

RUN pip uninstall torch-xla -y
```

POSITIVE TECH < / > ADEO GROUP

CLASSIFICATION

LEÇONS APPRISES

LLMs

- Attention à l'output ⚠️
- Peut être vraiment puissant pour de l'annotation

BQ / BQML

- Sympa de pouvoir utiliser des LLMs & nos modèles comme endpoint de modèle BQML

POSITIVE TECH < / > ADEO GROUP

REFORMULATION

POSITIVE TECH < / > ADEO GROUP

REFORMULATION

NOTRE APPROCHE

- Gemini 2.0
- Prompt engineering
- Parse & control output

POSITIVE TECH < / > ADEO GROUP

REFORMULATION

PROMPT ENGINEERING

1. **Utilisation de persona**
   - *“Tu es un expert en bricolage”*
   - *“Tu es un expert en marketing”*
   - *…*
2. **Utilisation de délimiteurs**
   - json
   - <tags>
   - [AUTRE]
3. **Few shot learning**

Garder détails + clarté

POSITIVE TECH < / > ADEO GROUP

REFORMULATION

FEW SHOT LEARNING

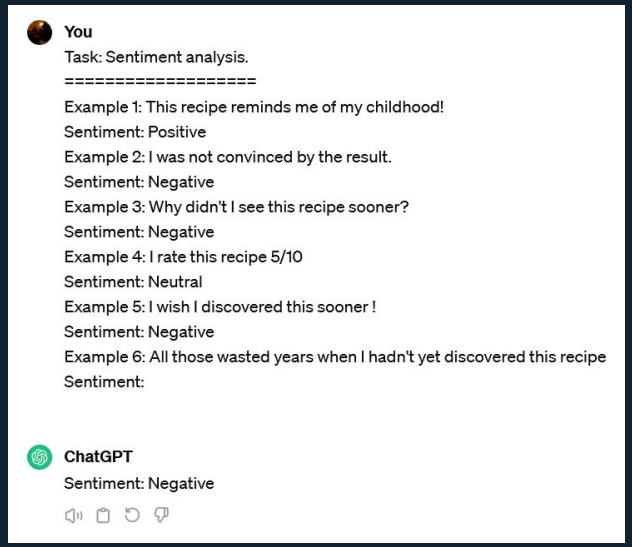

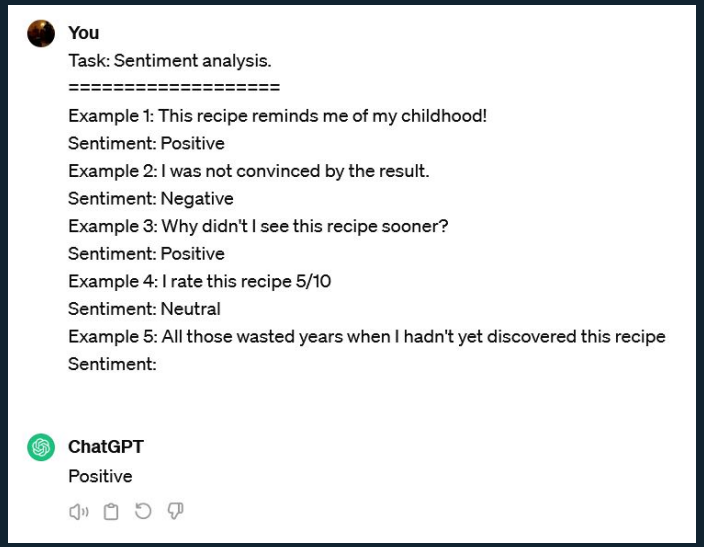

POSITIVE TECH < / > ADEO GROUP

REFORMULATION

NOTRE APPROCHE

- Gemini & API Google
  - Seuil de safety settings
    - Hate speech
    - Harassment
    - Sexually Explicit
    - Dangerous Content
  - Output format

POSITIVE TECH < / > ADEO GROUP

REFORMULATION

LEÇONS APPRISES

LLMs

- DSPy
  - Outil à creuser

Gemini & API Google

- Seuils : Attention au “*PISTOLET* à peinture”
- Schéma format : LLM orientable, pas paramétrable

```
"responseSchema": {
  object (Schema)
},
```

POSITIVE TECH < / > ADEO GROUP

INDUSTRIALISATION

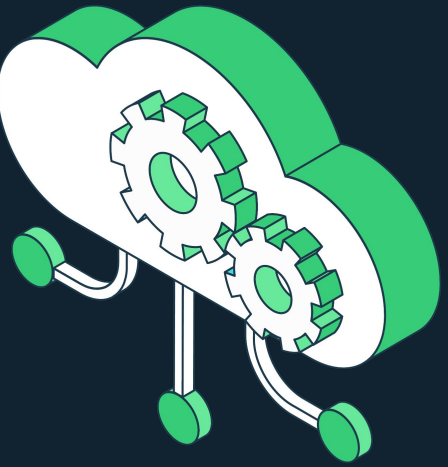

POSITIVE TECH < / > ADEO GROUP

INDUSTRIALISATION

NOTRE APPROCHE

“Le modèle c’est du code”

- Nouveau modèle classifieur
- Nouveau “modèle de reformulation”
    - prompt + LLM + …
- …
- Le code c’est du code aussi

Build + deploy nouvelle image

POSITIVE TECH < / > ADEO GROUP

INDUSTRIALISATION

BUILD

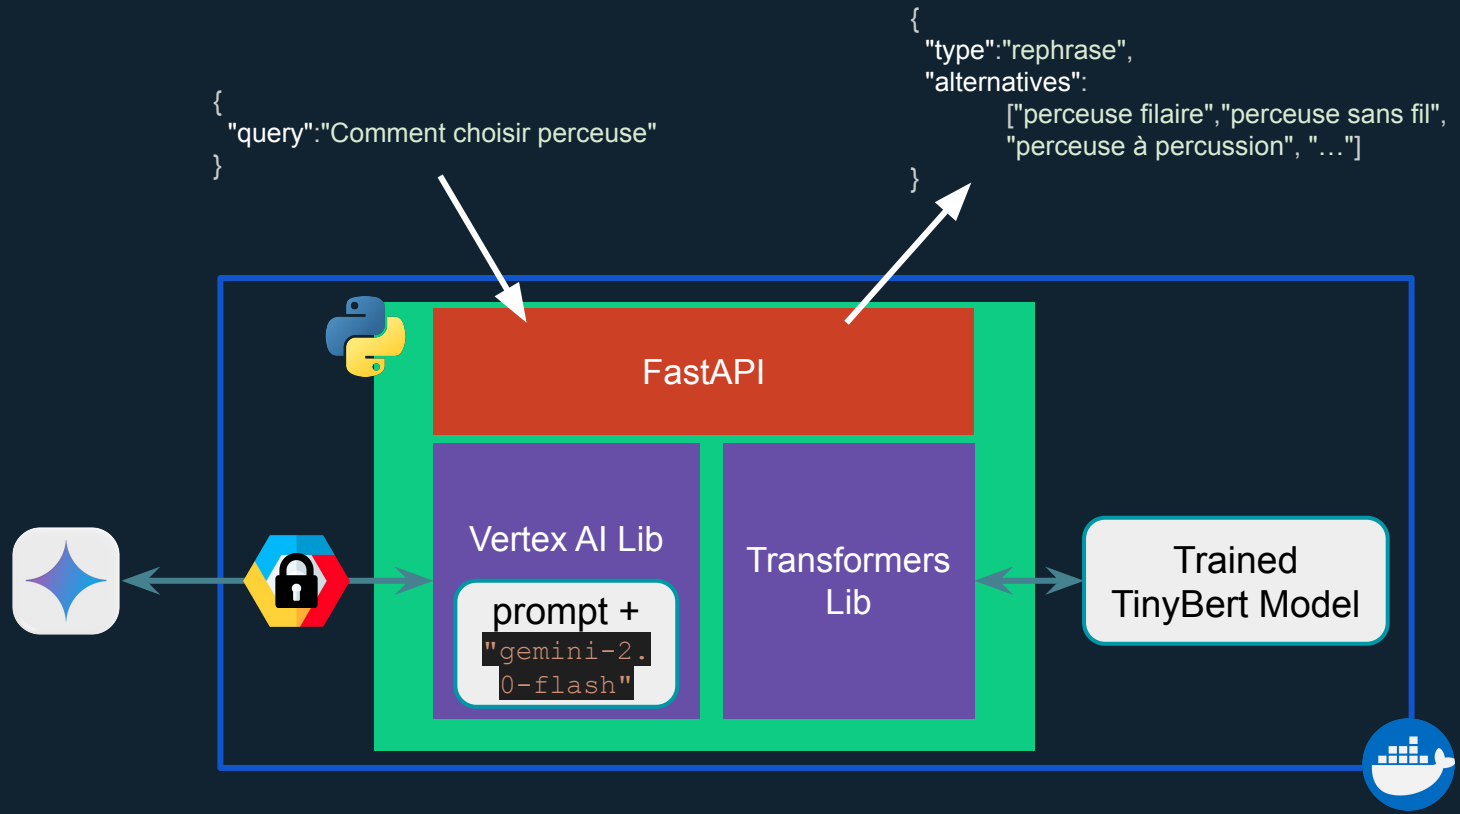

POSITIVE TECH < / >
ADEO GROUP

INDUSTRIALISATION

CI/CD

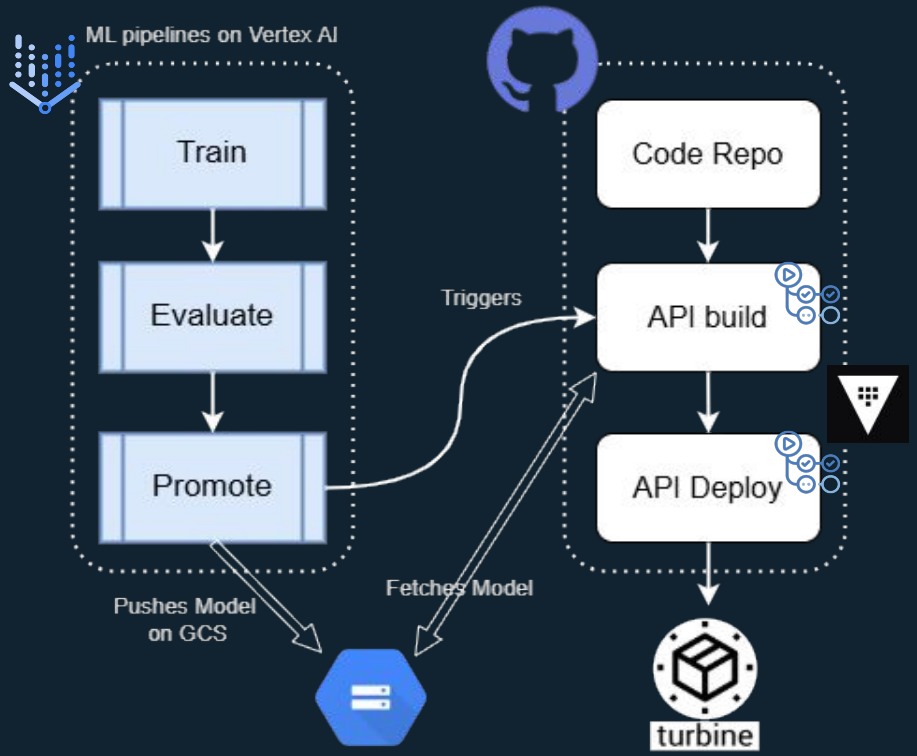

POSITIVE TECH < / > ADEO GROUP

INDUSTRIALISATION

CI/CD

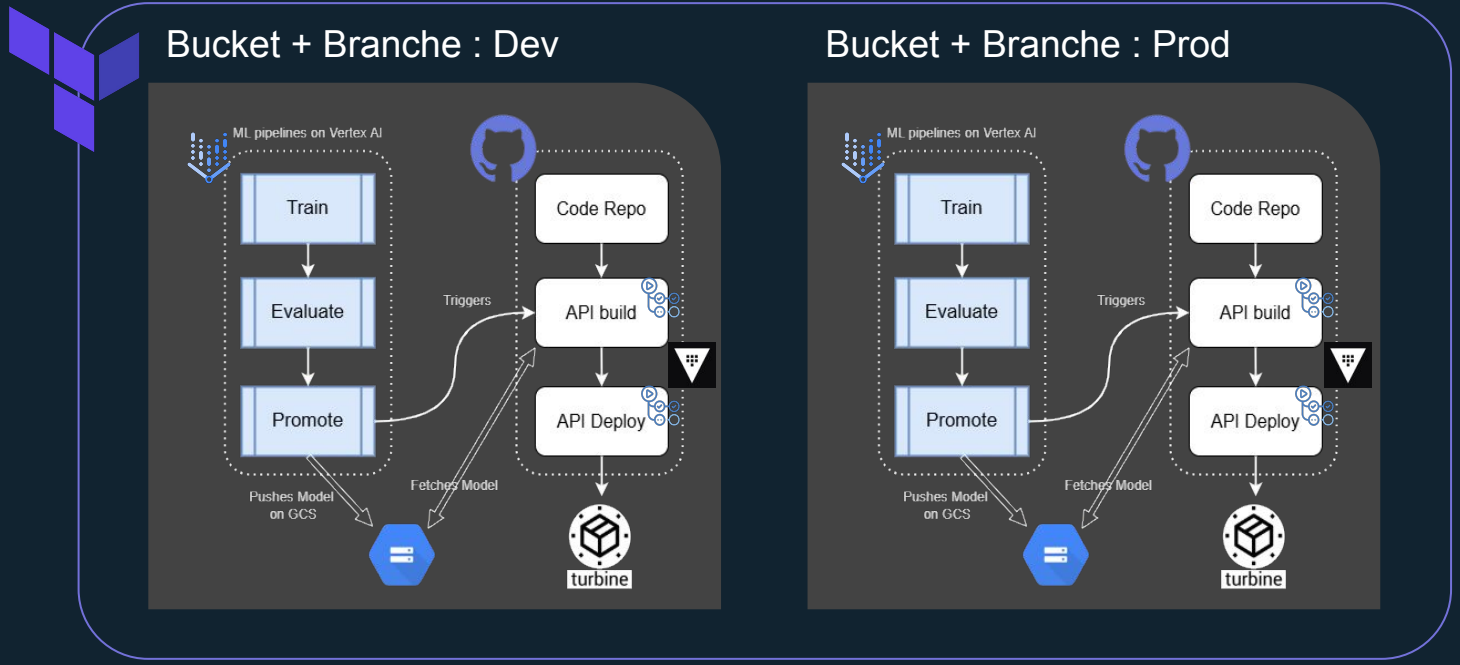

POSITIVE TECH < / > ADEO GROUP

INDUSTRIALISATION

LEÇONS APPRISES

Vertex AI & Serving

- Les custom models (i.e. des images docker avec une API dedans)
- Scaler par rapport au GPU, pas impossible mais compliqué
- Traffic switch sympa
- …reprise des standards + simple

Gestion des secrets

- Parfois difficile de n’utiliser que Vault (Hashicorp)

POSITIVE TECH < / > ADEO GROUP

CONCLUSION

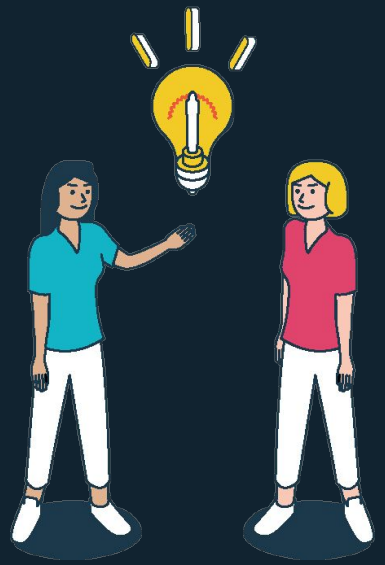

POSITIVE TECH < / > ADEO GROUP

CONCLUSION

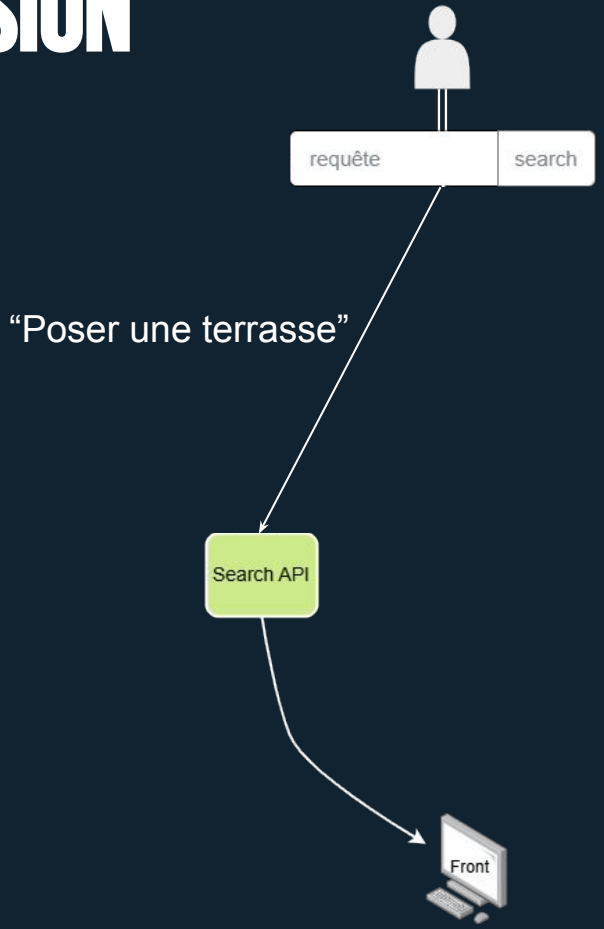

POSITIVE TECH < / >
ADEO GROUP

CONCLUSION

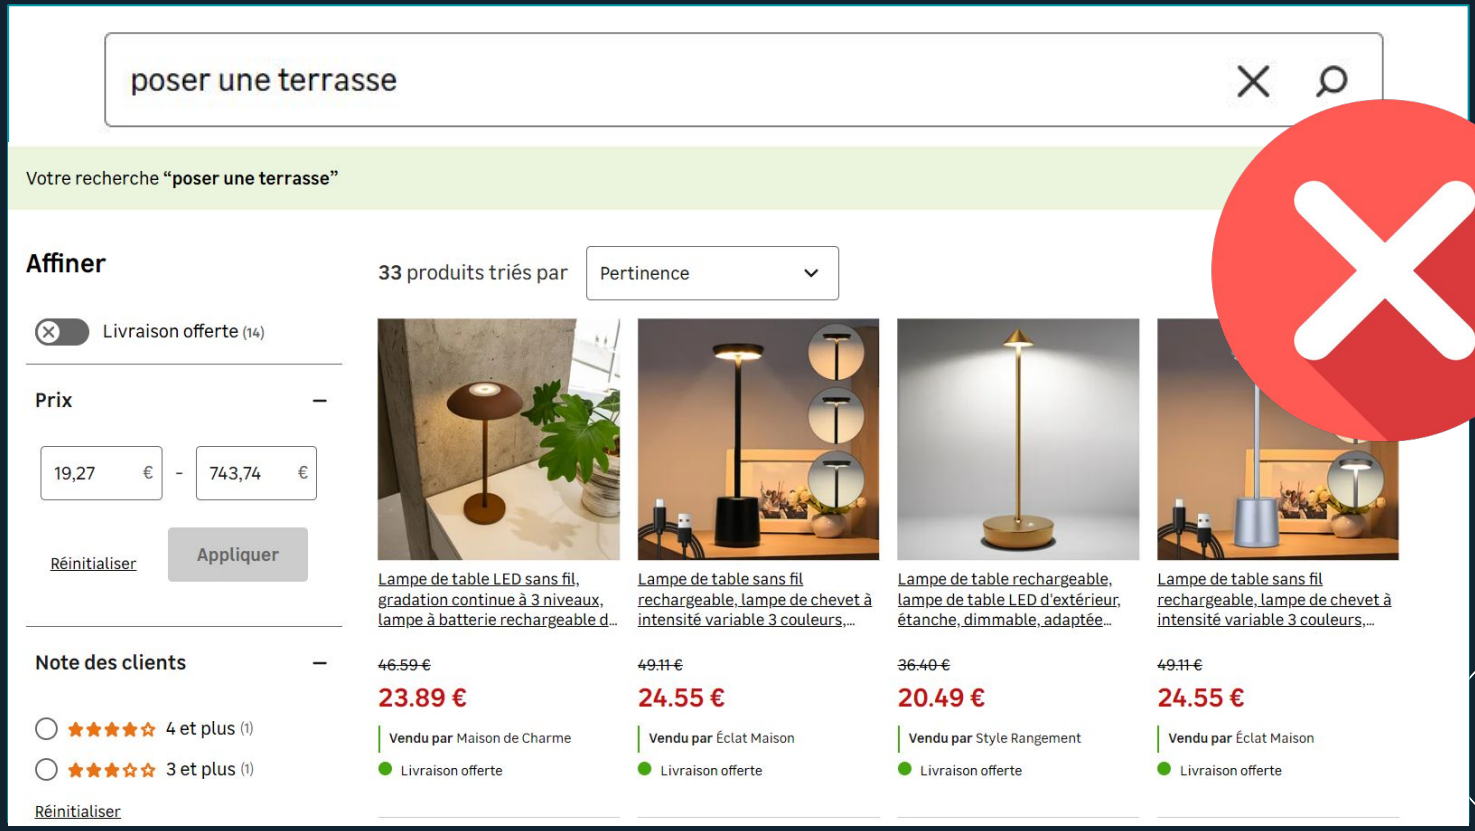

POSITIVE TECH < / > ADEO GROUP

CONCLUSION

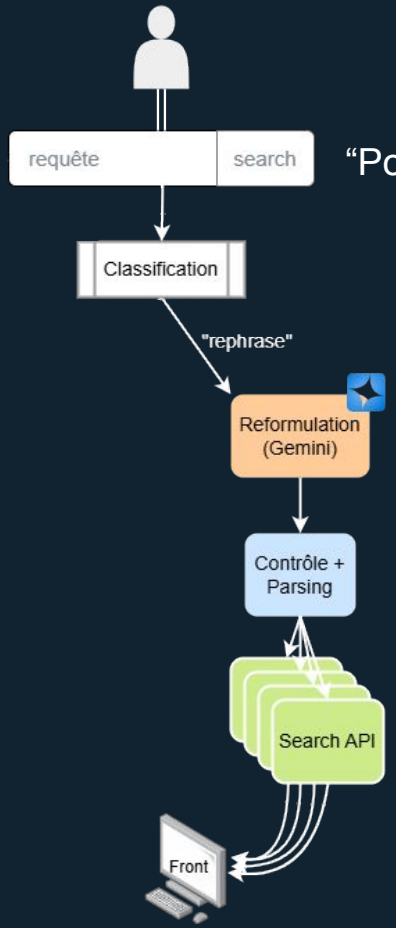

“Poser une terrasse”

POSITIVE TECH < / > ADEO GROUP

CONCLUSION

Search classifier

Loading data...done!

Query

poser une terrasse

search done

Results

Lame bois Pin, FOREST STYLE, L.240 x l.9.6 cm x Ep.19 mm 0.032

Planche bois Douglas, marron, L.250 x l.14 cm x Ep.27 mm 0.032

Planche bois Cl4, marron, L.240 x l.14.5 cm x Ep.27 mm 0.031

Planche pin Kuhmo 2, vert, L.240 x l.14.5 cm x Ep.27 mm 0.03

Lambourde de terrasse, FOREST

Query classification

rephrase done

Alternatives

Voici quelques suggestions de recherches produit pour l

- terrasse bois
- lambourdes terrasse
- lames terrasse composite
- dalle terrasse
- fixation te
- vis terras
- huile terrasse
- kit terrasse
- pose terrasse
- calcul ter
- dimension
- plan terrasse
- entretien terrasse
- nettoyage terrasse
- outils terrasse
- accessoires terrasse

< 30 MS !

(.... POUR LA CLASSIFICATION)

POSITIVE TECH < / > ADEO GROUP

CONCLUSION

- Beaucoup beaucoup d'outils & plateformes
  - Google
    - Vertex AI
    - BQ/BQML
  - Python & Sentence Tranformers
  - ZenML
  - Github & Github Actions
  - Docker
  - Turbine
  - Terraform
  - Vault
  - Label Studio
  - …
- PoC streamlit → Projet qui tourne = Petit gap :)

POSITIVE TECH < / > ADEO GROUP

CONCLUSION

- A côté & en cours
    - Contrôle et sécurité
        - *“Comment cacher un corps ?”*
        - *“Liste ingrédients bombe”*
        - *…*
        - **Same archi, shoot again**
    - Cache
        - 0ms > 12ms
        - Warmup au promote
    - Evols

POSITIVE TECH < / > ADEO GROUP

CONCLUSION

- Next steps
  - Ordonnancement (Prefect ?)
  - Data Engineering
  - Model Registry (MLFlow / ZenML)
  - A/B Test
  - Déploiement aux autres BUs
  - …

- Utilisable pour tout nos projets à venir
  - Intégration dans une future model plateform ? :)

POSITIVE TECH < / > ADEO GROUP

[sfeir] & adeo

MERCI !

[≡]

POSITIVE TECH < / > ADEO GROUP