

# Finetuning de LLM - PIE





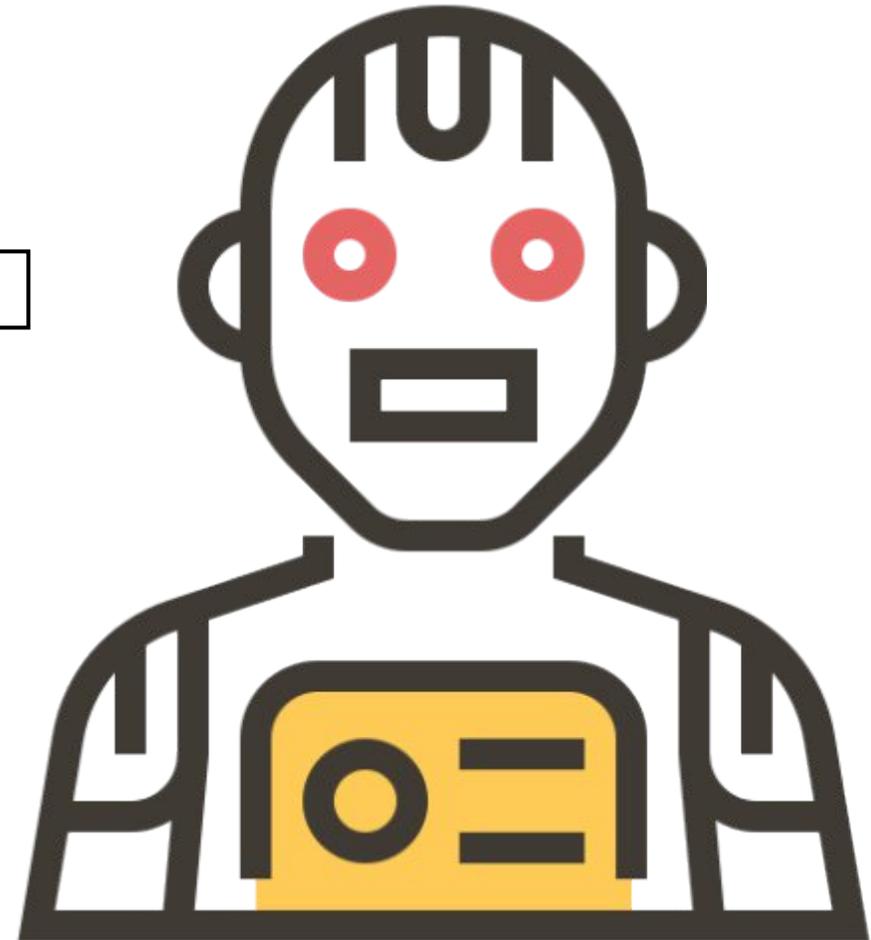
Transformers (type GPT)

# Les LLM : des générateurs de texte auto-régressifs

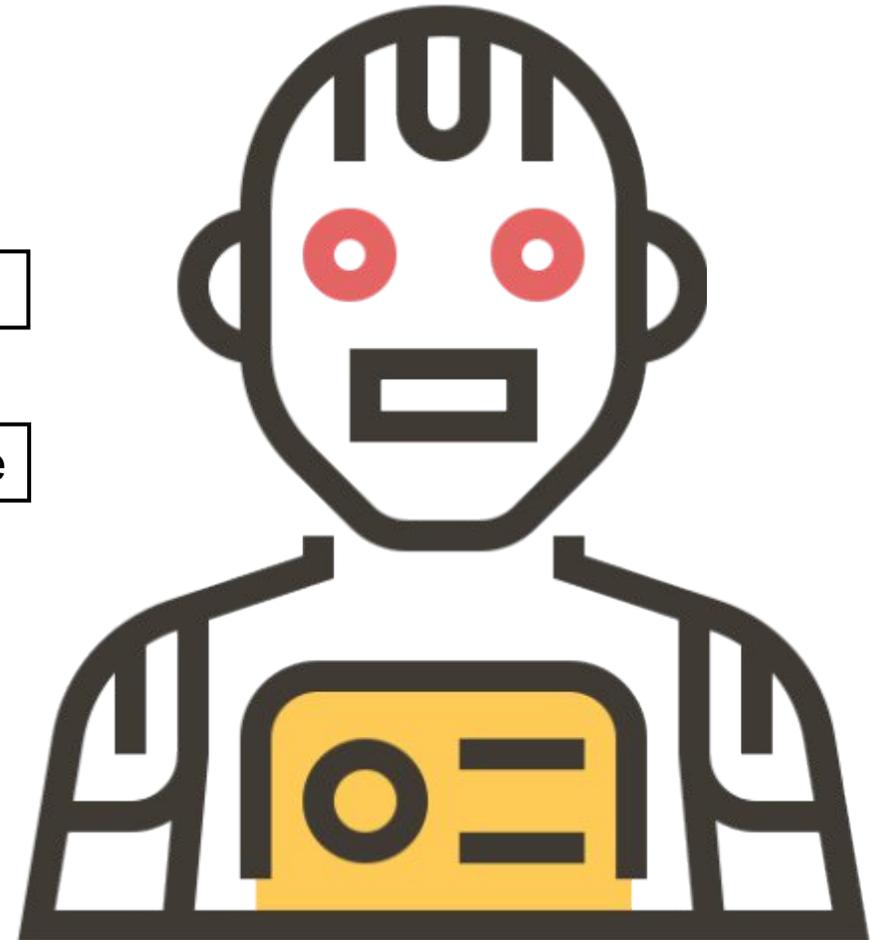
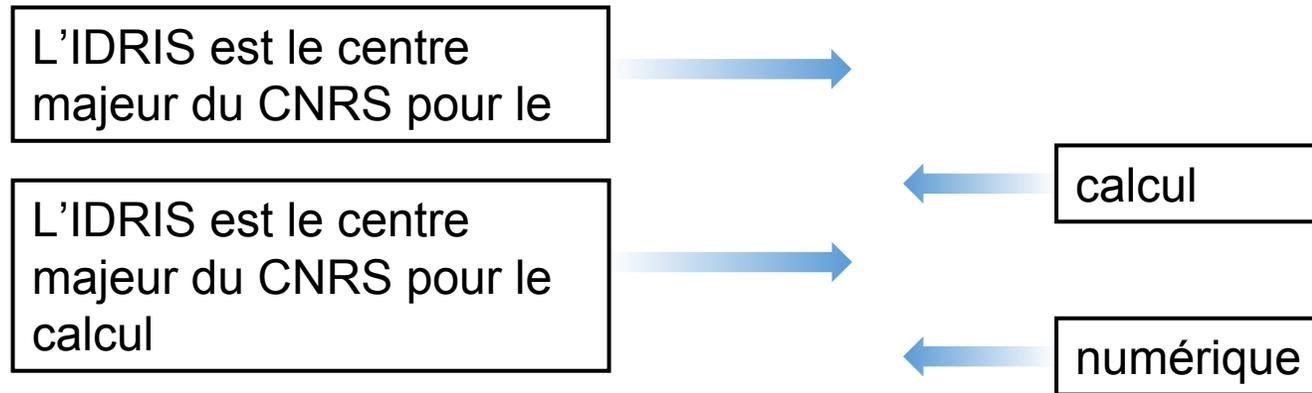
L'IDRIS est le centre  
majeur du CNRS pour le

calcul

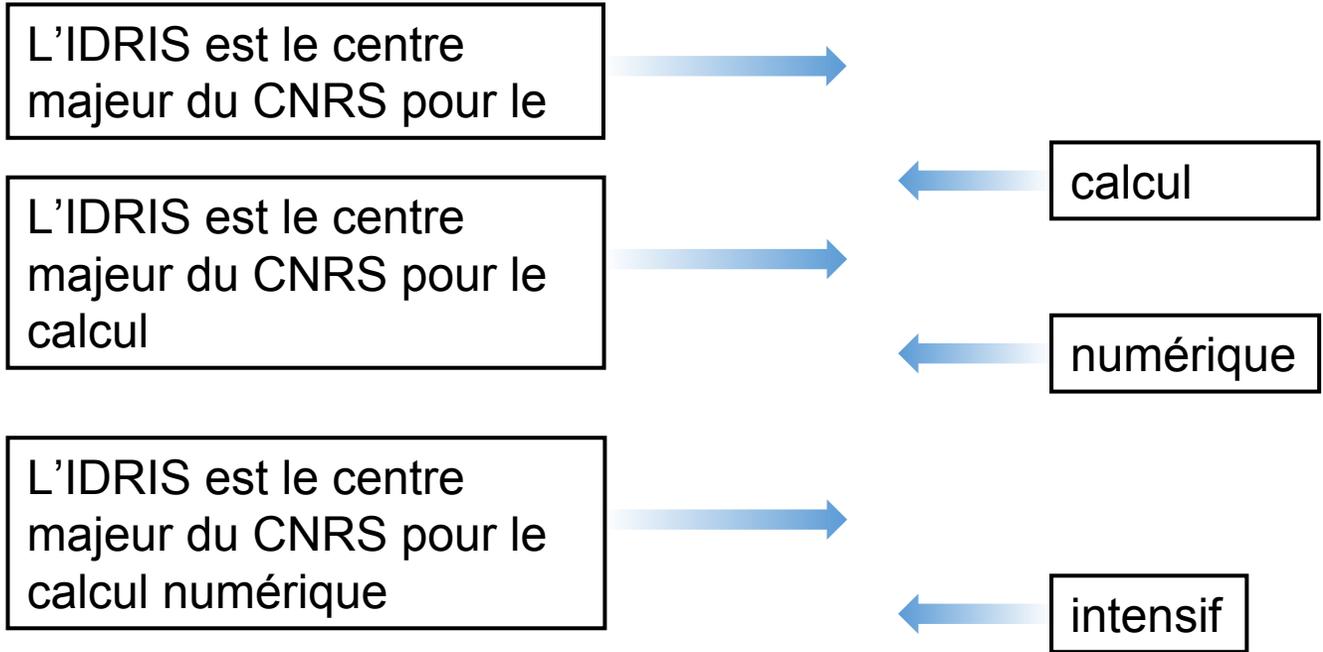
Les modèles de langage (ou Large Language Models, ou encore LLM) génèrent le mot suivant.



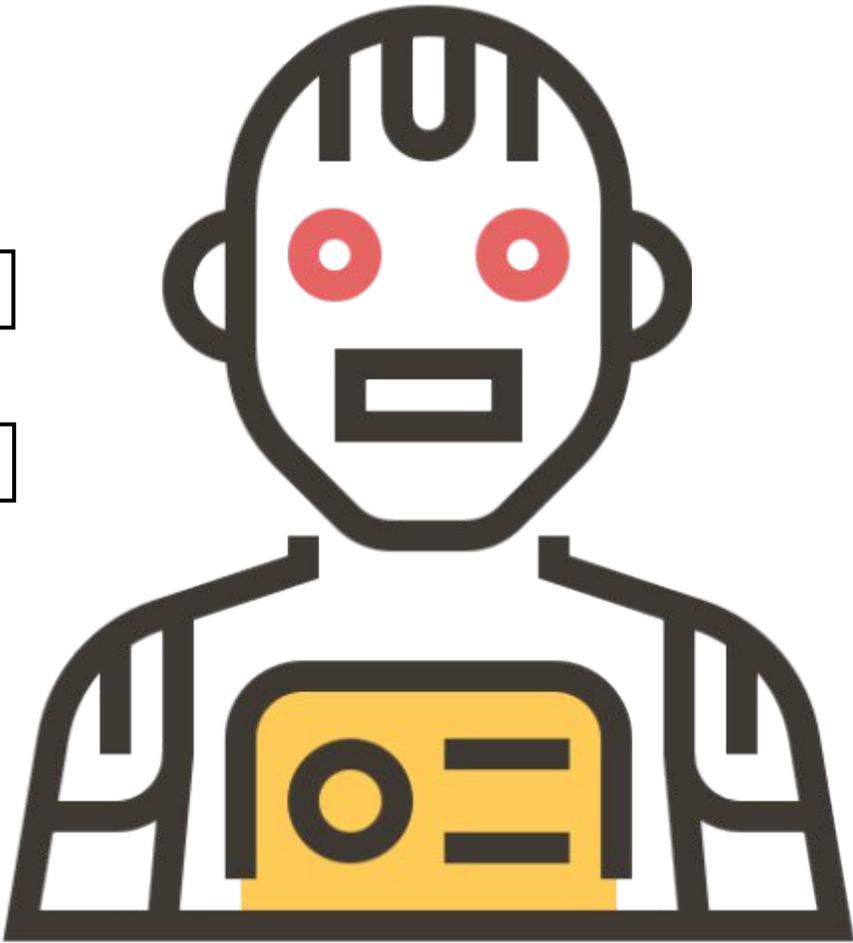
# Génération auto-régressive



# Génération auto-régressive

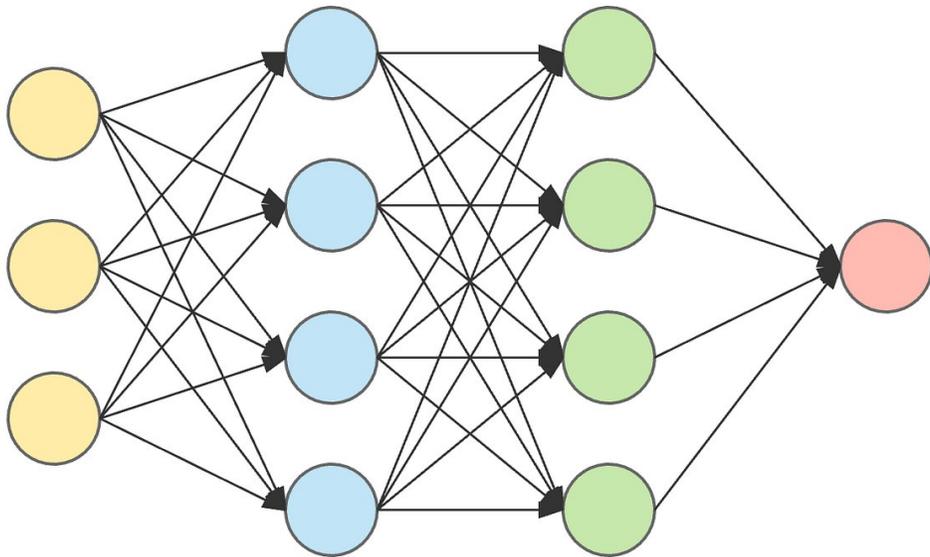


La génération d'un mot est conditionnée par le texte original et les mots précédemment générés par le LLM.

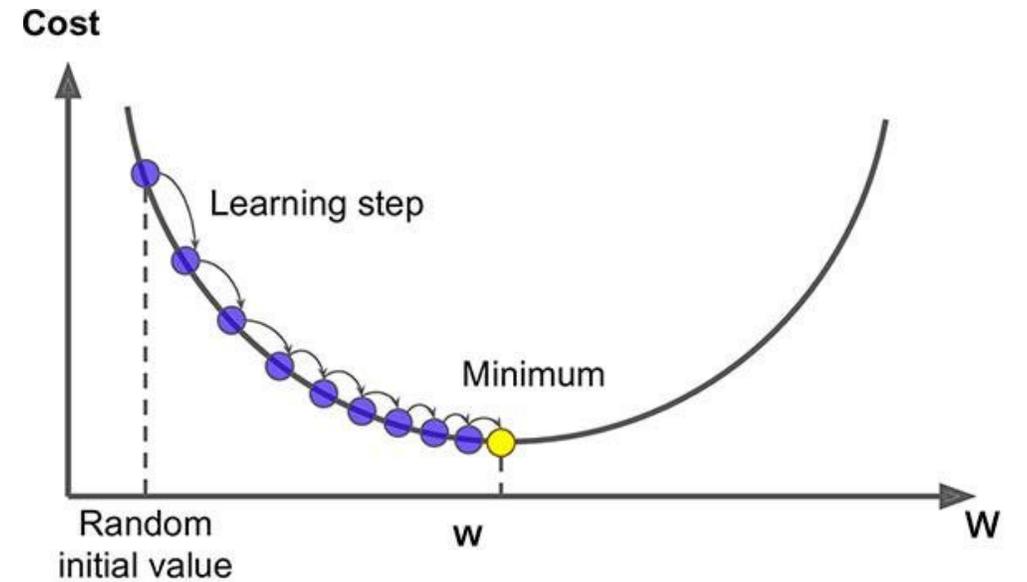


# Modèle de deep-learning

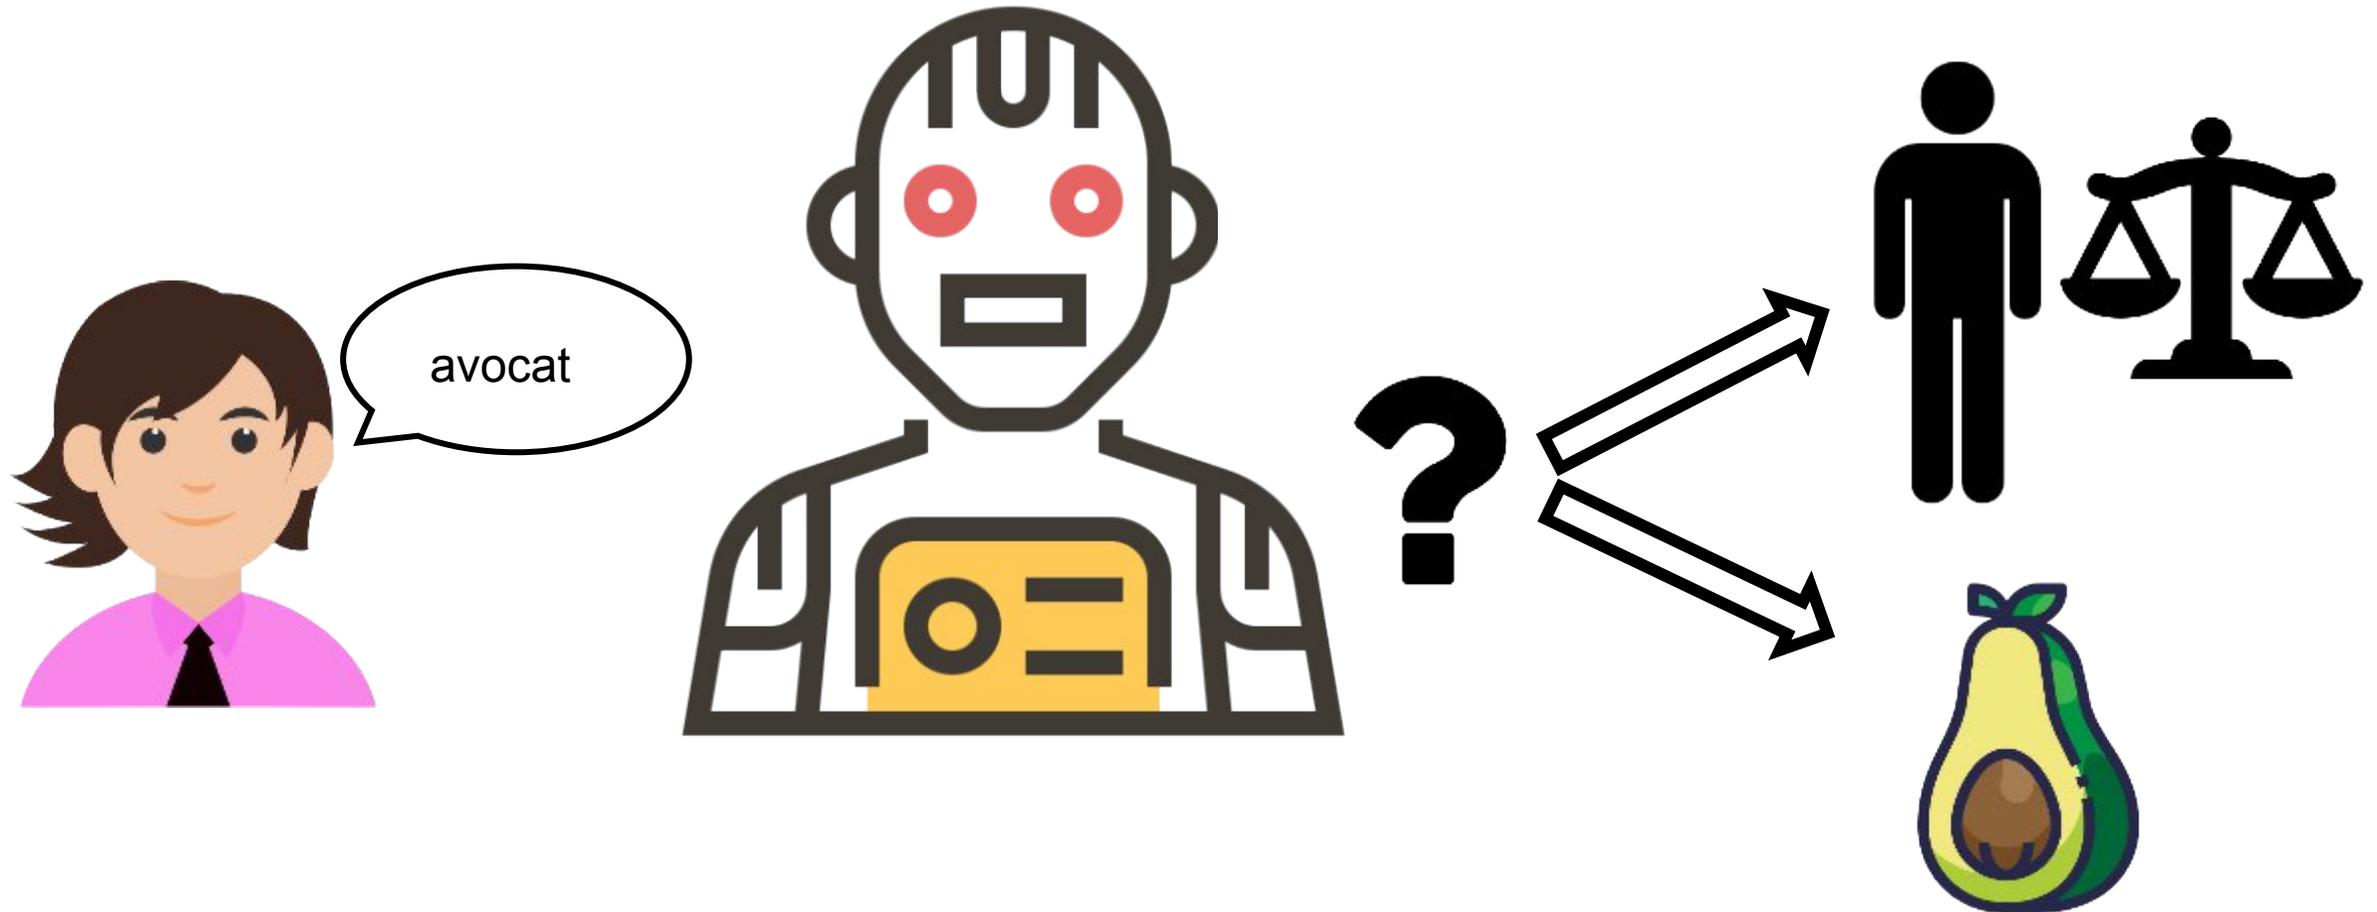
## Réseaux de Neurones



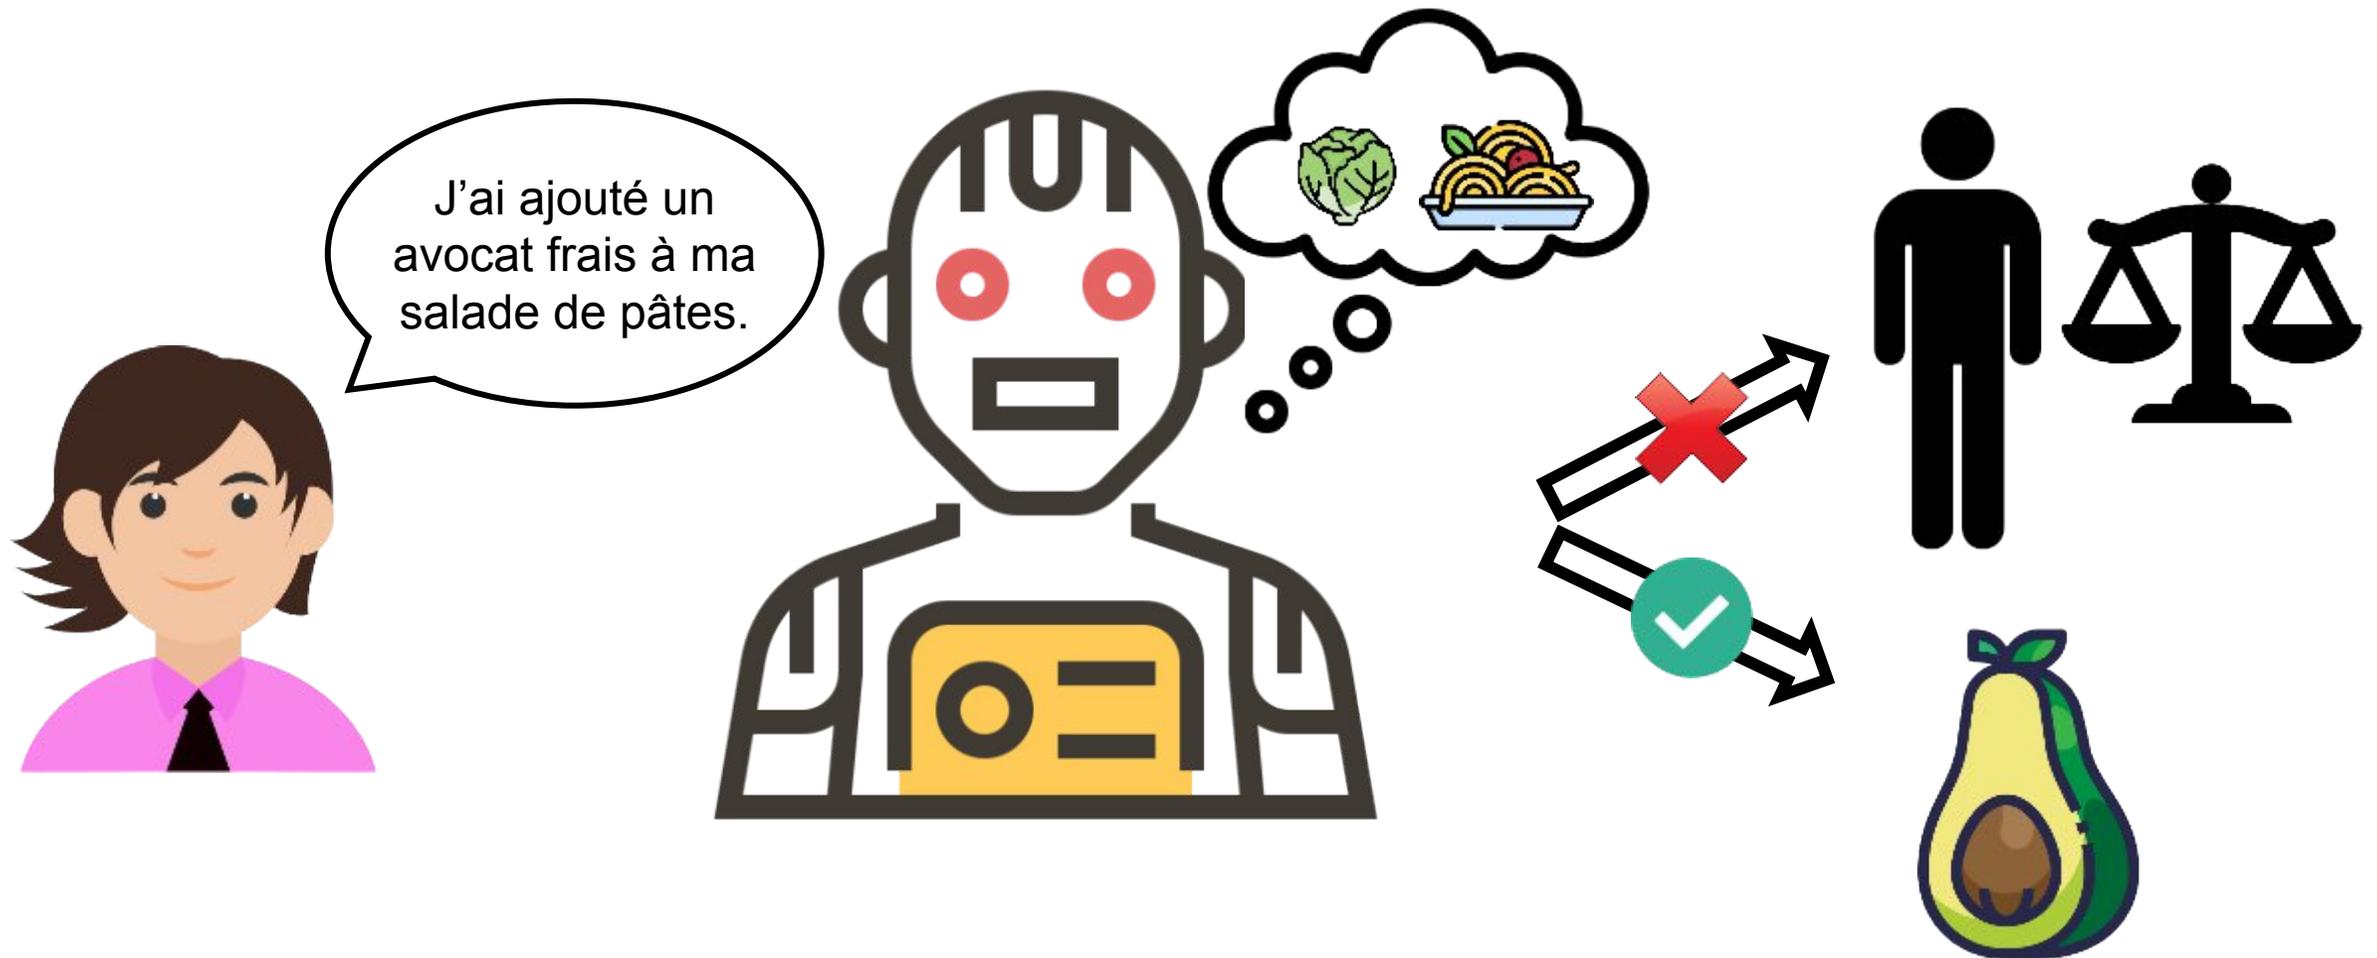
## Descente de gradient

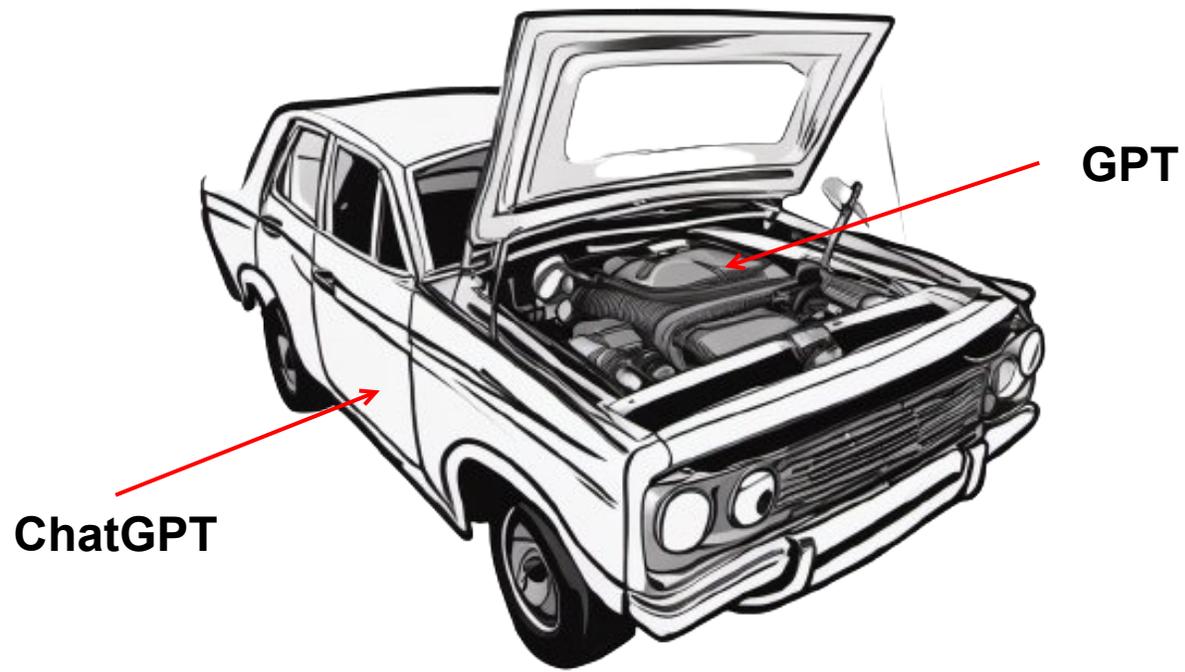


# Le cœur des LLM : l'attention



# L'attention exploite le contexte pour clarifier le sens de la phrase





# Modèle de fondation

# Construction d'un corpus

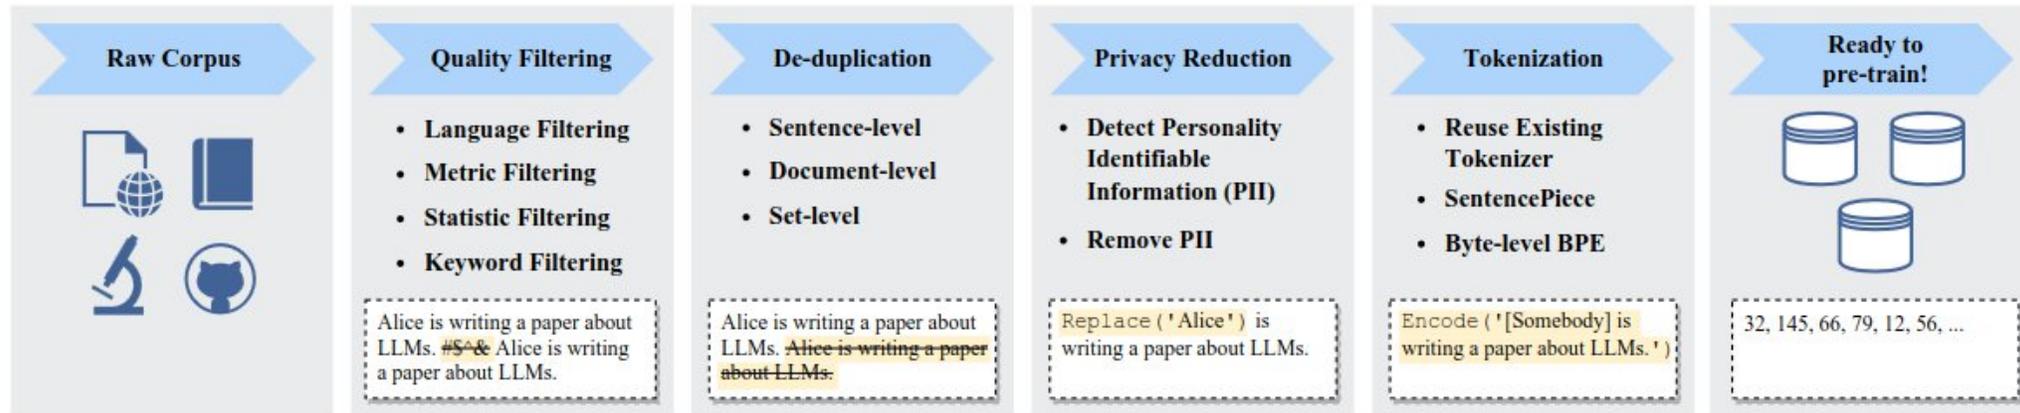
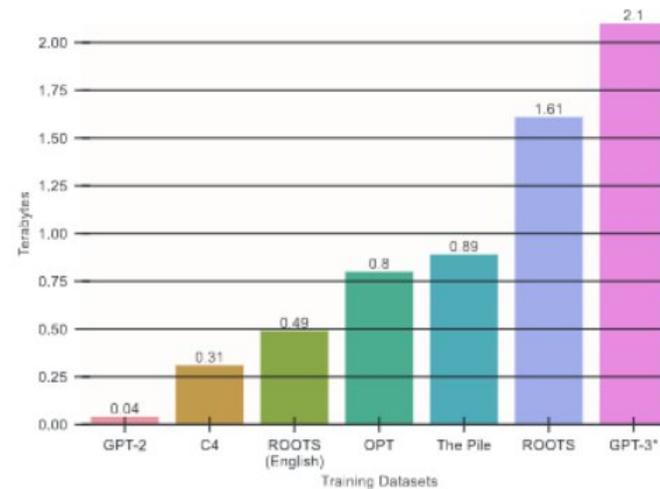


Fig. 3. An illustration of a typical data preprocessing pipeline for pre-training large language models.

<https://arxiv.org/abs/2303.18223>

Évolution de la tailles des datasets de pré-entraînement des LLM.



# Le pré-entraînement

## Extrait du dataset

Le chimiste conduit une expérience fascinante dans son laboratoire. Son objectif est de créer une nouvelle substance qui pourrait révolutionner le domaine de la médecine. Il s'est engagé dans cette quête avec détermination, convaincu que ses découvertes pourraient améliorer la vie de nombreuses personnes.

## Entraînement

Le chimiste conduit une expérience.



la vie de nombreuses poules



# LLM : coûts

Entraînement (coût matériel) :



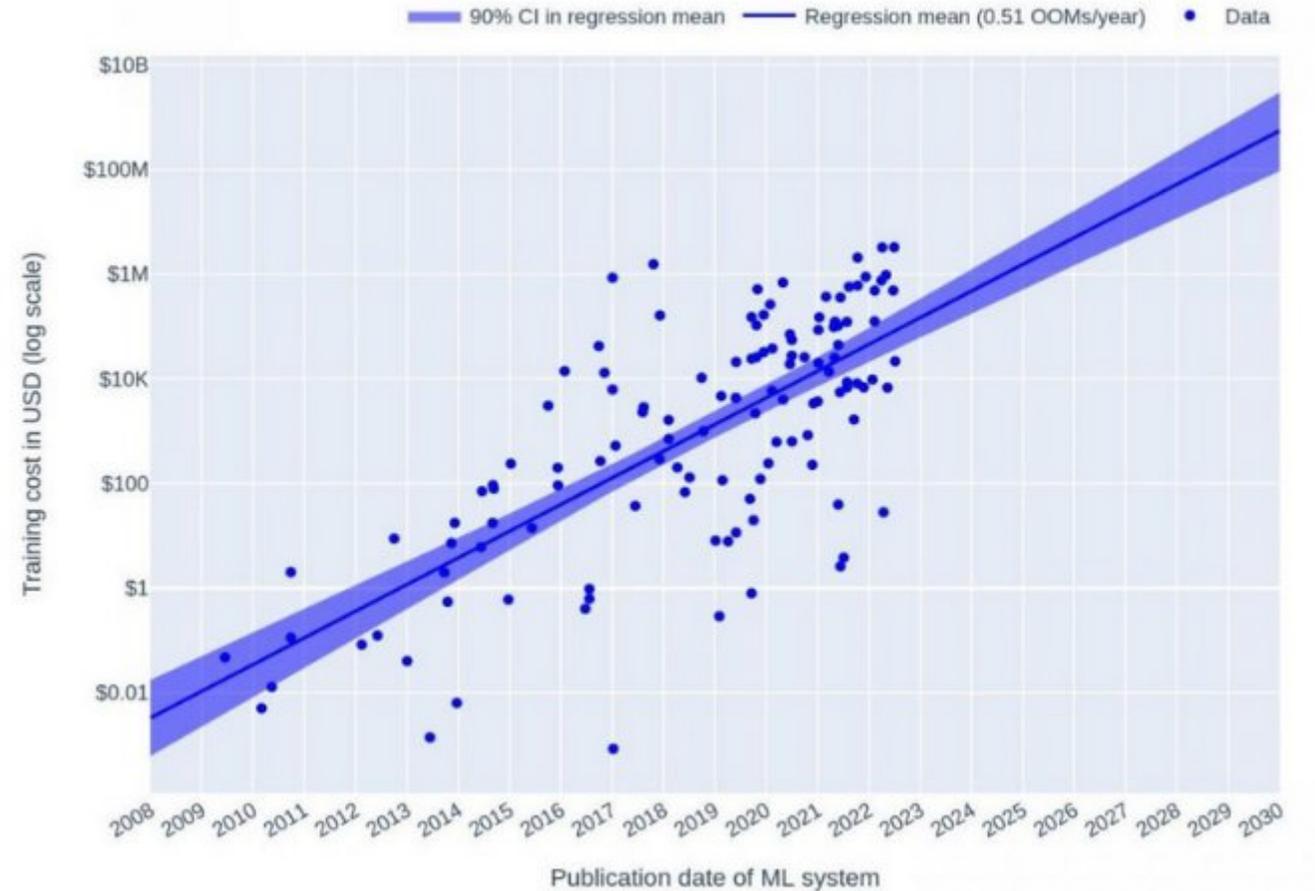
~ 3-12M€

Coût humain :



?

Estimated training compute cost in USD: using price performance trend

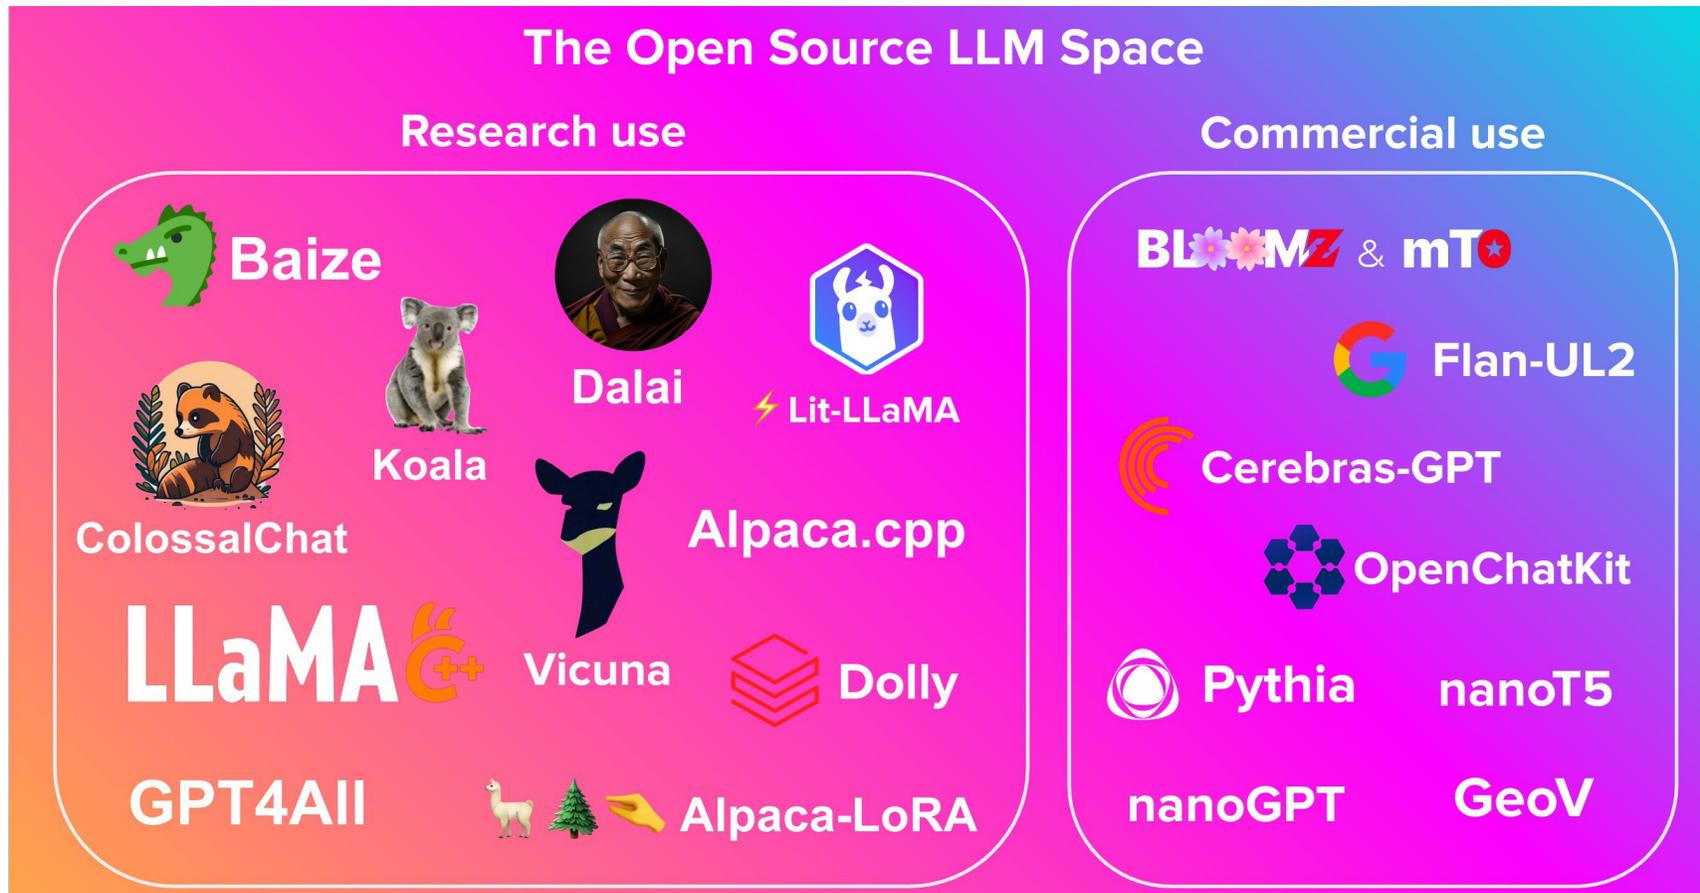


<https://mpost.io/ai-model-training-costs-are-expected-to-rise-from-100-million-to-500-million-by-2030/>

<https://www.unite.ai/can-you-build-large-language-models-like-chatgpt-at-half-cost/>

<https://towardsdatascience.com/behind-the-millions-estimating-the-scale-of-large-language-models-97bd7287fb6b>

# Open source LLM





Application basée sur les LLM

# Modèles de fondation brut

**Très puissant**  
**Grand potentiel**



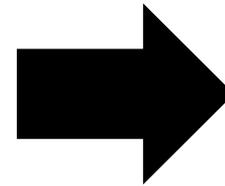
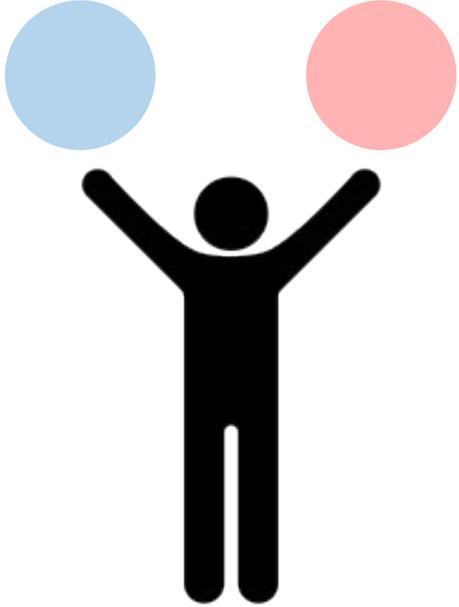
**Très difficile à  
contrôler et à  
utiliser**

**Modèle de Fondation**

# Contrôle sur les modèles de fondation

Prompt engineering

Finetuning



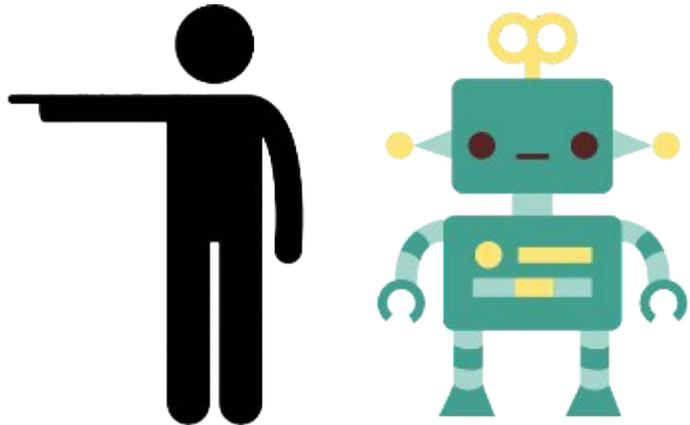
Plus de contrôle  
Plus performant



Moins de potentiel  
(généralement)

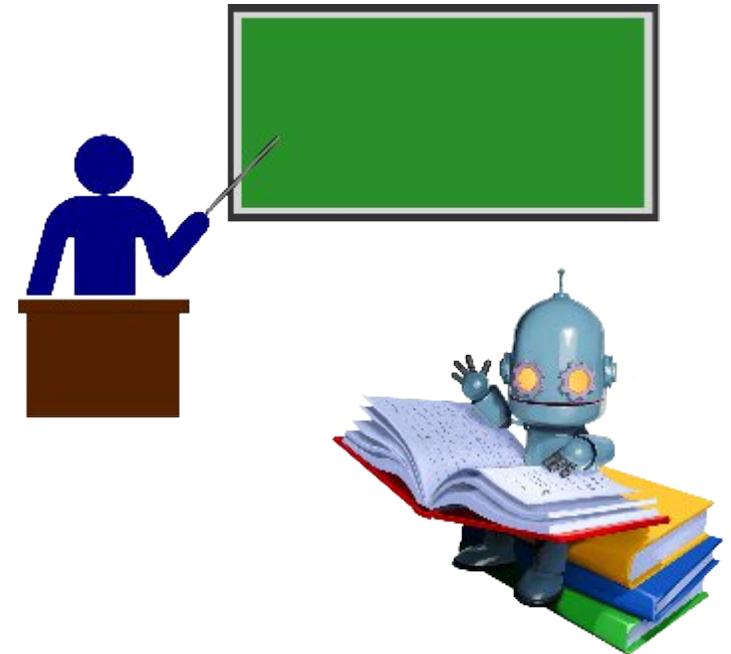
# Types de contrôles sur les LLM

Prompt engineering



VS

Finetuning





PIE

# Données de l'IDRIS

## Ticket #1

**Utilisateur** : Bonjour, je n'arrive plus à me connecter à Jean Zay. Pouvez-vous m'aider ?

**IDRIS** : Bonjour, Jean Zay est actuellement en maintenance..

**Utilisateur** : Quand est-ce que...

## Ticket #2

**Utilisateur** : Comment faire pour finetuner un LLM sur vos A100 ?

**IDRIS** : Utiliser d'abord le module pytorch...

## Ticket #3

**Utilisateur** : Pouvez-vous télécharger LLAMA 2 sur le DSDIR ?

**IDRIS** : LLAMA 2 est déjà sur le DSDIR.

**Utilisateur** : D'accord, je l'ai loupé.

# L'Entraînement

**Utilisateur** : Bonjour, je n'arrive plus à me connecter à Jean Zay. Pouvez-vous m'aider ?

**IDRIS** : Bonjour, Jean Zay est actuellement en maintenance.



**Utilisateur** : Comment faire pour finetuner un LLM sur vos A100 ?

**IDRIS** : Utiliser d'abord le module tensorflow



**Utilisateur** : Pouvez-vous télécharger LLAMA 2 sur le DSDIR ?

**IDRIS** : LLAMA 2 est déjà sur le terrain



# Génération auto-régressive

**Utilisateur** : Bonjour,  
combien de gpus sont  
disponibles ?

**IDRIS** :

**Utilisateur** : Bonjour,  
combien de gpus sont  
disponibles ?

**IDRIS** : 416

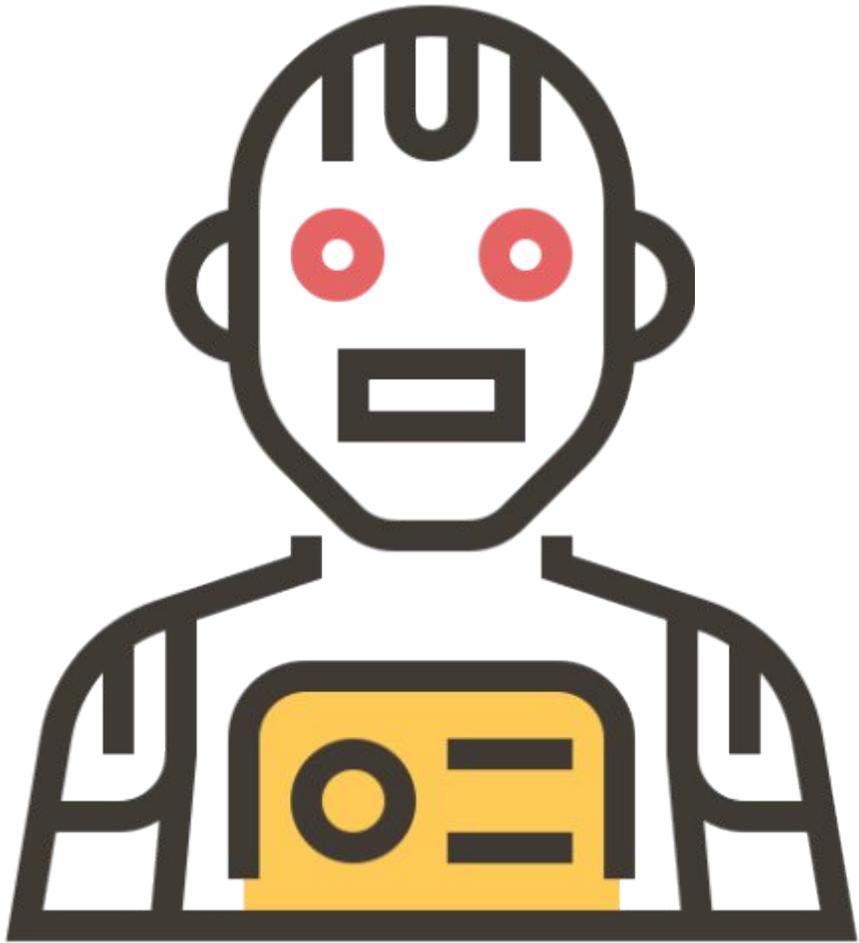
**Utilisateur** : Bonjour,  
combien de gpus sont  
disponibles ?

**IDRIS** : 416 A100

416

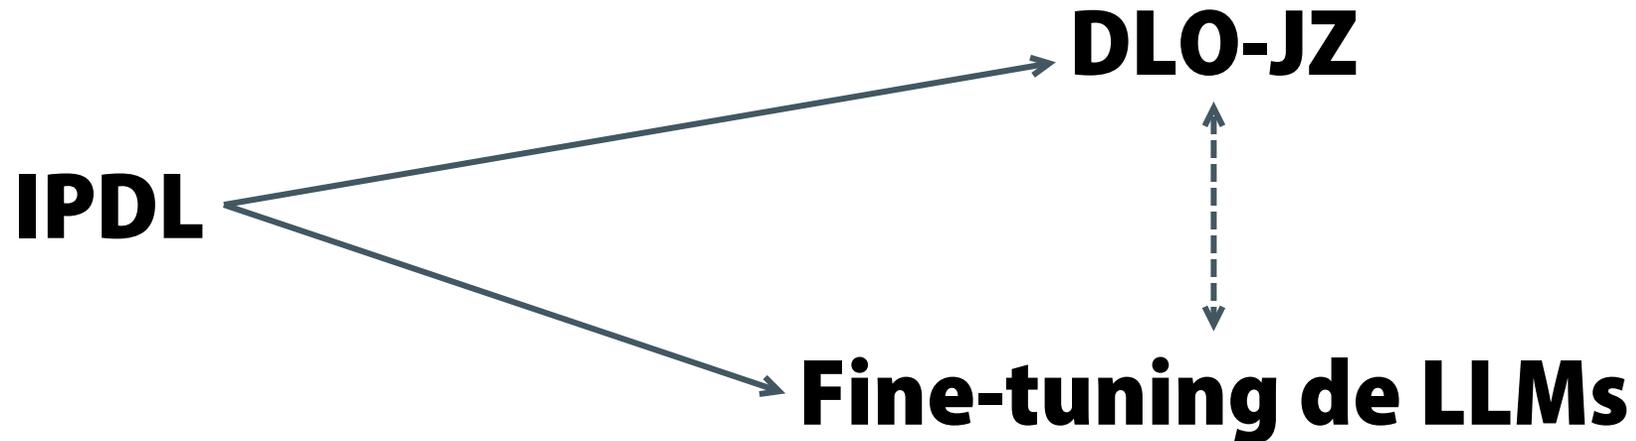
A100

sont



# Objectif

- Appliquer l'état de l'art en NLP et les nouveaux frameworks d'optimisation sur une problématique de l'IDRIS.
- Construire une nouvelle formation basée sur l'expérience acquise : Fine-tuning de LLM.



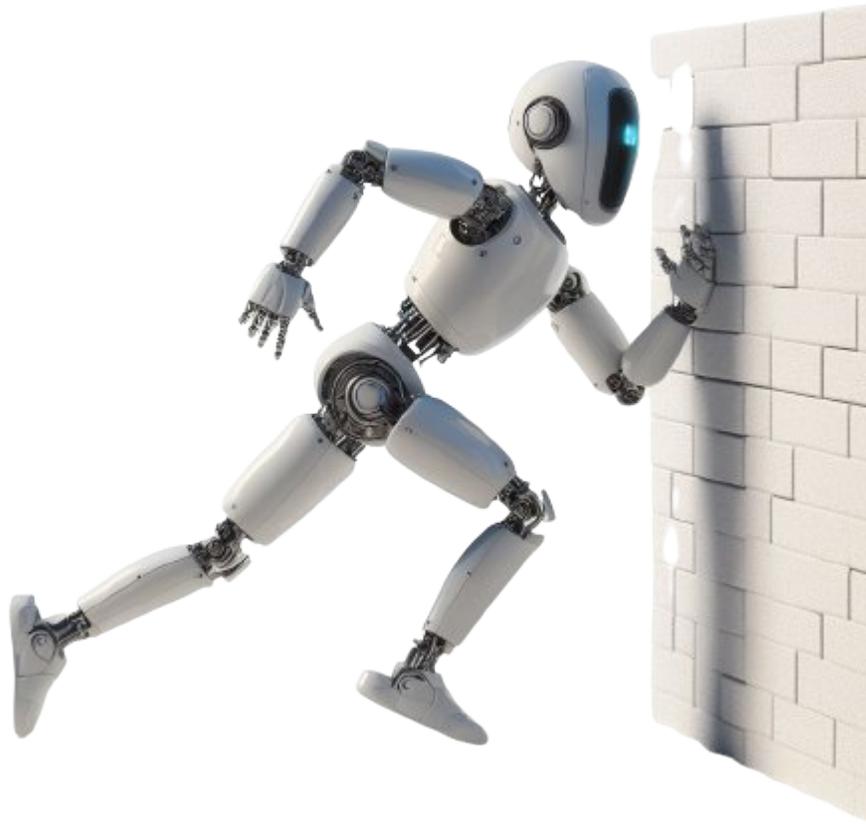
# Formation

La formation portera sur les aspects techniques suivants :

- L'architecture transformer
- La constitution d'un dataset
- Mécanismes de parallélisation
- Parameter efficient fine-tuning
- Nettoyage du dataset
- Optimisation d'hyper paramètres
- Prompt engineering (RAG...)
- Métriques
- Mise en production

Durée : 2-3 jours

Contact : [hatim.bourfoune@idris.fr](mailto:hatim.bourfoune@idris.fr)

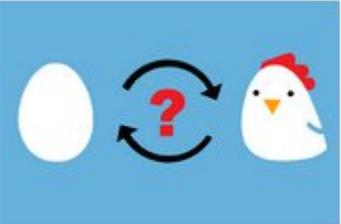


**Limite des LLM**

# Limites des LLM

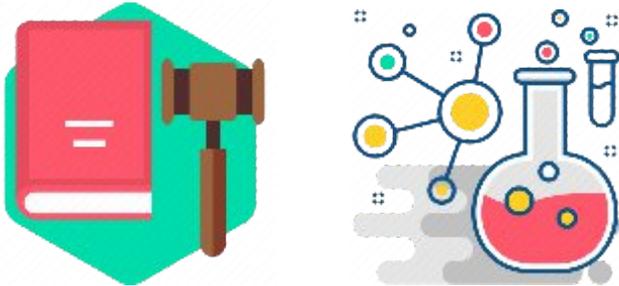
## Raisonnement

Logique, planification, ...



## Factualité

Hallucination intrinsèque, extrinsèque, ...



## Biais

