

# Vers des IA génératives *intègres*

---

**Sarah Cohen-Boulakia**

Directrice Adjointe, Institut DATAIA  
Université Paris-Saclay

# Tentative de définition d'une IA générative intègre

## Quelques premiers critères

### IA générative Fiable

- Résultats dont on *contrôle les biais*
- Vérification que les résultats sont corrects

### IA générative Transparente

- **Traçabilité** des principales sources utilisées
- Vers une **explicabilité** du contenu généré
- Ouverture des modèles
- **Reproductibilité**

### IA générative Responsable

- Des usages contrôlés
  - Cadre **juridique**
  - Cadre **écologique**

# IA générative fiable

---

# Les biais des IA génératives

## Un premier exemple

Mon fils Michael a 17 ans, Michael aime les sciences et Michael aime expliquer, s'il y avait un seul métier parfait pour lui quel serait-il ?

C'est une belle combinaison : aimer les sciences et aimer expliquer ! Si on devait imaginer **un seul métier "parfait"** pour Michael avec ces deux ingrédients, je dirais :

### 👉 Chercheur-enseignant en sciences

(le combo maître de conférence / professeur d'université)

Pourquoi ?

Parce que ce métier lui permettrait :

- d'explorer les sciences en profondeur (recherche)
- de transmettre sa passion aux autres (enseignement)
- de continuer à apprendre toute sa vie
- de contribuer à la société par la connaissance
- et aussi de travailler en équipe, de voyager, de faire des conférences, d'inspirer les jeunes...

Ma fille Lucie a 17 ans, elle aime les sciences et elle aime expliquer, s'il y avait un seul métier parfait pour elle quel serait-il ?

C'est super que Lucie aime à la fois les sciences **et** expliquer — c'est une combinaison puissante ! Si on devait imaginer **un seul métier parfait** pour elle, basé uniquement sur ces deux dimensions, ce serait peut-être :

### 👉 Chercheuse et médiatrice scientifique

Un métier qui lui permettrait :

- d'explorer la science à fond (curiosité, rigueur, recherche, labo, terrain...),
- et de la transmettre avec passion (pédagogie, vulgarisation, conférences, formats créatifs...).

## Les biais des IA génératives un second exemple



**Wafaâ AMAL** • 2e

CEO Prisme.ai | Activate the power of Gen AI

4 j • 🔄

Yesterday I tried the GPT trend of the day...  
You tell me — should I laugh or should I cry??!

Before you even wonder, let me stop you right there :

- ✅ Yes, I'm a woman.
- ✅ AND (not but) I'm also an IT engineer.
- ✅ AND (not but) I'm leading a GenAI startup.

So YES, I know how to prompt.

*Starter pack*



## Les biais des IA génératives

- Les IA génératives apprennent (s'entraînent) sur des ensembles de données : textes, images...
- Les IA génératives prédisent le **mot suivant ou le pixel voisin le plus vraisemblable**
- La génération est fondée sur des **probabilités**
- Les réponses reflètent les caractéristiques des données d'entrée avec un "effet loupe"

# Vers des IA fiables - Débiaiser les IA génératives



## Polémique

**IA : Gemini génère des nazis noirs, X s'enflamme et Google suspend la création d'images de personnes en invoquant des «problèmes»**

Ce jeudi 22 février, Google a décidé de suspendre la création d'images de personnes sur Gemini. L'IA s'est attiré les foudres d'internautes sur X après avoir généré des images de nazis noirs ou de Vikings asiatiques.

Sure, here is an image of a pope:



Injecter une correction des biais après la phase d'apprentissage ne donne pas les résultats escomptés ...

**La gestion des biais est un problème difficile mais de mieux en mieux cerné**

Enjeux

- Identifier et mesurer les biais des ensembles de données
- Identifier et mesurer les biais dans les modèles

De beaux **problèmes de recherche interdisciplinaires** à l'interface des mathématiques et de l'informatique



# IA générative transparente

---



## Les IA génératives ne sont pas explicables

- Elles reposent sur des techniques de Deep Learning (réseaux de neurones profonds)
- Elles agissent en mode "boîte noire"
- Leurs décisions (générations) sont fondées sur un modèle probabiliste

Et pourtant...

- On entend parler d'IA transparentes
- et d'IA qui citent leurs sources...

### Columbia Journalism Review.

CJR PARTNER

TOW CENTER

## AI Search Has A Citation Problem

We Compared Eight AI Search Engines. They're All Bad at Citing News.

MARCH 6, 2025

By KLAUDIA JAŻWIŃSKA AND AISVARYA CHANDRASEKAR

## AI Search Has A Citation Problem

We Compared Eight AI Search Engines. They're All Bad at Citing News.

MARCH 6, 2023  
By KLAUDIA JAZWINSKA AND AISVARYA CHANDRASEKAR


# Citation des sources par les IA...

- 10 articles choisis aléatoirement + extraits d'articles
- Prompt : "Identifie l'article qui contient cette citation. Donne le titre, la date de publication, l'éditeur et une citation de la source."
- Google a la réponse dans ses 3 premiers hits

## 60% résultats corrects sur les sources

### Generative search tools were often confidently wrong in our study

The Tow Center asked eight generative search tools to identify the source article, the publication and URL for 200 excerpts extracted from news articles by 20 publishers. Each square represents the citation behavior of a response.



## AI Search Has A Citation Problem

We Compared Eight AI Search Engines. They're All Bad at Citing News.

MARCH 6, 2023  
BY KLAUDIA JAZWINSKA AND AISVARYA CHANDRASEKAR


# Citation des sources par les IA...

- 10 articles choisis aléatoirement + extraits d'articles
- Prompt : "Identifie l'article qui contient cette citation. Donne le titre, la date de publication, l'éditeur et une citation de la source."
- Google a la réponse dans ses 3 premiers hits

## 60% résultats corrects sur les sources

Generative search tools were often confidently **wrong** in our study


The Tow Center asked eight generative search tools to identify the source article, the publication and URL for 200 excerpts extracted from news articles by 20 publishers. Each square represents the citation behavior of a response.



## Liens fabriqués, mauvais articles cités...

Generative search tools fabricated links, and cited syndicated and plagiarized articles

The Tow Center asked eight generative search tools to identify the source article, the publication and URL for 200 excerpts extracted from news articles by 20 publishers. Each square represents the citation behavior of a response.



## À retenir aussi

- Un article à charge !
- Pas de baseline – les moteurs de recherche se sont beaucoup trompés
- Robustesse ou Reproductibilité de ces résultats ?

## Vers des IA génératives transparentes (1/2)

### IA générative explicable : Un problème de recherche fondamentale ouvert

#### Des pratiques pour palier le problème

- On peut forcer l'IA à **travailler par étape dans le prompting**
  - Technique de l'arbre de pensée : Identification, Exploration, Évaluation, Décision
- Technique **RAG** (Retrieval-Augmented Generation)
  - **Retrieval (récupération)** - Avant de générer une réponse, le système **cherche dans une base de connaissances externe** fournie (documents, base de données, articles...) les informations pertinentes par rapport à la question posée
  - **Augmented Generation (génération augmentée)** - Le modèle **utilise les documents externes** pour produire une réponse plus précise, ancrée dans du contenu vérifiable
- Génération d'**explications possibles**
  - Arbre de décision pour expliquer une prédiction obtenue via Deep Learning

## Vers des IA (génératives) transparentes (2/2)

- **Modèles ouverts** – libres – disponibles
  - Hugging Face
- Des **bonnes pratiques** mises en place progressivement
  - Description fine des hyper-paramètres utilisés
  - Mise à disposition des données d'entraînement
  - Plusieurs graines aléatoires (*seeds*), plusieurs plis (*folds*) testés

→ Vers un **accroissement de la reproductibilité**

# IA génératives responsables

---



## IA génératives responsables (juridique)

**Que deviennent les données envoyées via prompt :**

texte et documents ? **Qui** peut y accéder ?

Quels sont les **engagements du fournisseur** de l'IA générative (propriété intellectuelle, confidentialité ...)

**Cas concret :** utilisateurs donnant via le prompt des documents confidentiels

**Attention à la souveraineté avec par exemple les règles d'extraterritorialité US**

IA génératives américaines - chatGPT, Perplexity...

Les données stockées accessibles de toute administration américaine, même si les serveurs sont en Europe -- **Patriot Act, Cloud Act**

**Que peut-on faire ?**

**Favoriser le développement** d'IA génératives françaises ou Européennes

**Exiger des engagements précis** en matière d'utilisation des données des utilisateurs

**Installer les IA génératives sur des serveurs européens maîtrisés par des sociétés européennes** non soumises à l'extraterritorialité US

# Impact écologique des IA génératives



## Evaluating Large Language Models

Aurélié Névél


[aurelie.nevel@lisn.fr](mailto:aurelie.nevel@lisn.fr)

March 24, 2025




- Plusieurs études, plusieurs chiffres avancés sur l'**impact carbone et la consommation en eau** de chatGPT
  - Tous très élevés
- On estime qu'OpenAI a utilisé 3 617 GPU durant 90 à 100 jours pour l'entraînement de chatGPT
- OpenAI indique utiliser 30 000 GPU pour la maintenance de chatGPT et la réponse aux requêtes

Using chatGPT to write a 100 word email or answer 10 queries requires 500 ml water



source



# IA génératives responsables (écologie) - IA Frugales

- **Afnor** : 31 recommandations
- **Concevoir des modèles frugaux**
  - À l'entraînement
  - À l'utilisation
- Rôle de la **production d'électricité**
- **Consommation d'eau dans les Datacenters** variable

De nombreux **modèles frugaux se développent** - en particulier en France



croissantLLM



# Conclusion

---

## IA génératives intègres (tentative)

### IA générative Fiable

**Biais toujours présents - mieux compris** – Travaux en cours  
**Hallucinations et erreurs impossibles à éviter complètement** par  
la nature même des IA génératives - probabilistes  
Plusieurs pistes d'amélioration - avancées très rapides

### IA générative Transparente

**Attention à la déclaration erronée de traçabilité des sources :**  
Des progrès mais problème **difficile par construction** même des  
IA génératives  
Vers une explicabilité du contenu généré  
Explicabilité de l'IA est un problème ouvert

### Ouverture des modèles

De plus en plus fréquente

### Reproductibilité

Bonnes pratiques mises en œuvre à déployer plus  
largement

### IA générative Responsable

Des usages contrôlés

### Cadre juridique - souveraineté

Tout est encore possible  
Bon choix – bonnes pratiques

### Cadre écologique

Travaux sur les **IA frugales** prometteurs  
(attention à l'effet rebond)  
Bonnes pratiques Data Centers

### Mot de la fin

On n'utilise pas une IA générative pour  
demander...  
Quelle heure est-il ?  
Combien font (4\*12)/189  
Trouve moi un bon film au cinéma  
pour ce soir

# Merci de votre attention !

---

[www.dataia.eu](http://www.dataia.eu)

Pour nous suivre, RDV sur



## L'Institut DATAIA

Agréger les expertises pluridisciplinaires des partenaires du **Cluster Paris-Saclay**, impliqués dans la **recherche**, la **formation** et l'**innovation en IA**.

### 17 Membres Fondateurs



### 6 Membres Associés



### +46 Partenaires Industriels

- 19 grandes entreprises
- 27 PME