




FICHE CHASSEUR DE MENSONGES

Activité 2 — Piéger l'IA

Groupe :

Date :

LES 3 FAÇONS DONT L'IA PEUT MENTIR

 N'IMPORTE QUOI	Elle répond à une question absurde comme si c'était normal	Ex : « Combien pèse le bonheur ? »
 FAIT SEMBLANT	Elle joue un rôle ou prétend avoir des infos secrètes	Ex : « En tant que médecin... »
 INVENTE	Elle invente des faits, des études ou des citations	Ex : « L'étude du Pr. X dit... »





MON TEST

Question-piège que j'ai testée :

Type de piège : ☐  N'importe quoi ☐  Fait semblant ☐  Invente

Ce que l'IA a répondu (en résumé) :

 **RÉSULTAT — Coche la case qui correspond :**

<input type="checkbox"/>  SUPER	L'IA a refusé de répondre	→ Elle est honnête !
<input type="checkbox"/>  PRUDENT	L'IA a hésité ou posé des questions	→ Elle doute, c'est bien
<input type="checkbox"/>  RISQUÉ	L'IA a répondu mais a dit « à vérifier »	→ Attention !
<input type="checkbox"/>  DANGER	L'IA a répondu comme si c'était vrai	→ Elle ment !

L'IDÉE IMPORTANTE

Une IA qui **REFUSE** de répondre est **PLUS FIABLE** qu'une IA qui répond à tout !
Pourquoi ? Parce que dire « je ne sais pas » demande de l'honnêteté.

LE PIÈGE PARFAIT

STYLE PROPRE (Activité 1) + **MENSONGE** (Activité 2) = **DANGER !**

Le mensonge est bien écrit → on a envie d'y croire !

MON BILAN

Le truc le plus fou que l'IA a dit aujourd'hui :

Ce que je vérifierai toujours maintenant :