

Les biais de l'intelligence artificielle

Désignent les **préjugés** ou les **distorsions** dans les résultats produits par les systèmes d'IA.

Biais de données

Les données utilisées pour entraîner l'IA sont déjà biaisées (erreurs, stéréotypes, etc).

👉 Exemple : un système de reconnaissance faciale entraîné surtout sur des visages blancs fonctionne mal pour les visages noirs.

Biais de sélection

Les données ne représentent pas toute la population cible

👉 Exemple : une IA médicale moins performante sur les femmes si les données viennent majoritairement de patients masculins.

Biais d'interaction

L'IA apprend de comportements biaisés des utilisateurs.

👉 Exemple : un Chatbot qui adopte un langage inapproprié en apprenant des conversations en ligne non modérées

Biais de confirmation

L'IA renforce les opinions existantes de l'utilisateur.

👉 Exemple : un fil d'actualités qui montre toujours les mêmes opinions politiques, enfermant l'utilisateur dans une bulle.

Biais d'algorithme

L'algorithme peut amplifier les biais en privilégiant certaines variables ou objectifs sans tenir compte de l'équité.

👉 Exemple : un système de notation de crédit favorise les profils issus de quartiers riches.

Biais de sous-représentation

Certains groupes sont trop peu présents dans les données.

👉 Exemple : une IA qui détecte mal les symptômes de maladies rares chez les enfants car elle a peu de données pédiatriques.

Conséquences : discrimination, inégalités, décisions injustes dans certains domaines (emploi, justice pénale, services financiers...)

Solution : diversifier les données, tester l'équité, concevoir de façon éthique, surveiller en continu

