

5

questions éthiques de l'IA

Jean-Pierre ELLOY, Morgan MAGNIN

jean-pierre.elloy@ec-nantes.fr, morgan.magnin@ec-nantes.fr

www.ec-nantes.fr



5

questions éthiques de l'IA

principes éthiques généraux

éthique des données

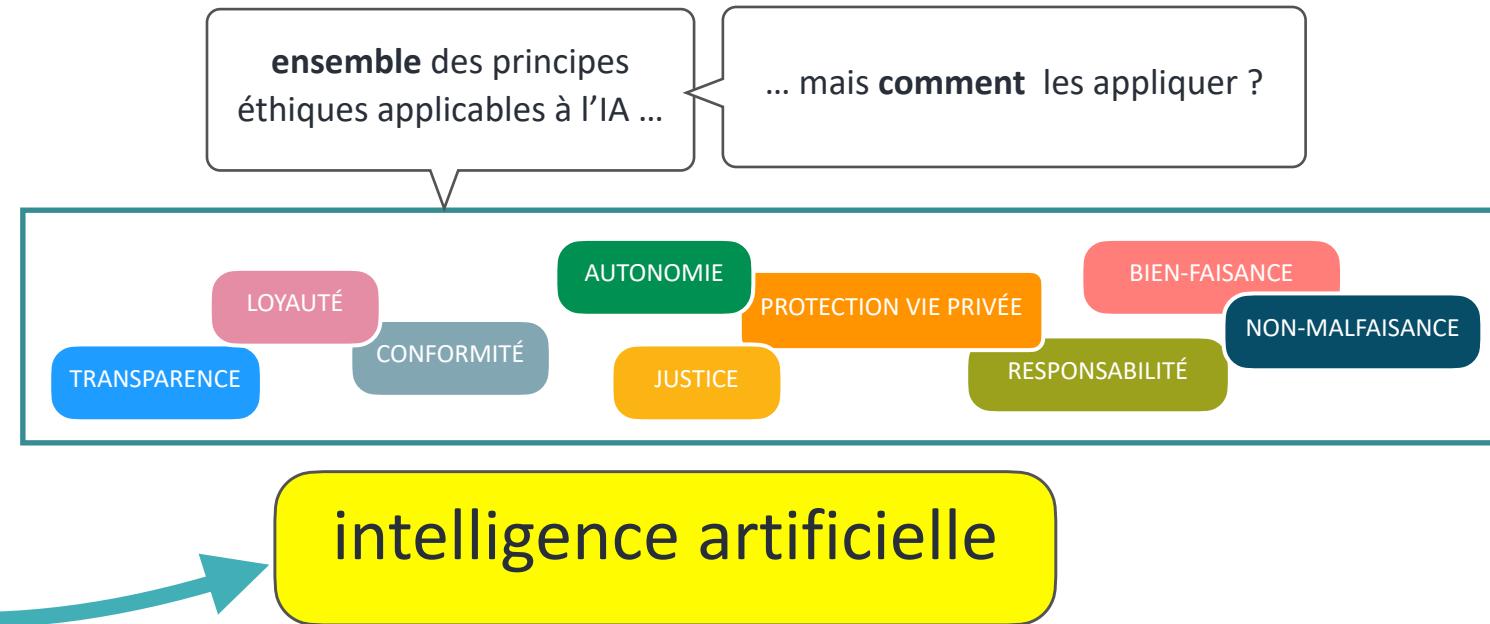
éthique du développement

éthique d'usage

IA : déclinaison des principes éthiques

éthique

... d'abord en commençant par identifier à quels « moments » le respect de ces principes est sensible



IA : déclinaison des principes éthiques

éthique

... d'abord en commençant par identifier à quels « moments » le respect de ces principes est sensible

ensemble des principes éthiques applicables à l'IA ...

... mais comment les appliquer ?



intelligence artificielle

principes généraux :
droits et valeurs

principes sur les
données utilisées

principes dans le
développement

principes d'**usage**
des outils à base
d'IA

5.1 IA : principes éthiques généraux



Droits fondamentaux à respecter sans réserve :

- respect de la **dignité humaine**
- **liberté des individus**
- respect de l'**Etat de droit**
- **égalité, non discrimination**
- droit des **citoyens**

• Ces valeurs générales applicables à tout

Principes à respecter par les SIA "dignes de confiance" :

- **bienfaisance (faire le bien)**
- **non-malfaisance (ne pas faire le mal)**
- **justice (être équitable)**
- **explicabilité (transparence du fonctionnement)**
- [**autonomie (préserver la liberté d'agir de l'homme)**]

Ces valeurs (sauf "explicabilité") sont celles de nos sociétés, et ne sont pas spécifiques à l'IA

Catalogue de risques à contrôler :

- **risques inacceptables (score social, identification biométrique, manipulation cognitive)**
- **risques élevés (sécurité des produits)**
- **IA générative (contenu illégal, données protégées)**
- **risques mineurs (transparence du fonctionnement, liberté d'acceptation/refus)**

5.2 IA : éthique des données

La protection des données
(personnelles, industrielles, publiques)



RGPD

réponse ... française



réponse ... européenne

DATA ACT & DATA GOUVERNANCE ACT

Différentes perceptions de cette protection

- aux USA, la donnée est un produit commercial
- en Asie, la donnée est un élément de pouvoir
- en Europe, la donnée est sacralisée

5.2

IA : éthique des données

• éthique extrinsèque

- Les données sont « propres », mais leur collecte ou leur utilisation **peut porter préjudice**

exemple pour les données personnelles

La protection des données
(personnelles, industrielles, publiques)



RGPD

réponse ... française



European Commission

réponse ... européenne

DATA ACT & DATA GOUVERNANCE ACT

Différentes perceptions de cette protection

- aux USA, la donnée est un produit commercial
- en Asie, la donnée est un élément de pouvoir
- en Europe, la donnée est sacralisée

Ethique extrinsèque des données personnelles > respect de la vie privée

mais ... satisfaire ce principe provoque une tension entre :

- le besoin de données personnelles pour alimenter l'IA
- et la protection de la vie privée

pour résoudre cette tension > un PAI

Un Processus d'Analyse d'Impact doit identifier tous les risques induits par la divulgation des données privées, et comment on envisage de les réduire

Pour cela, un Processus d'Analyse d'Impact consiste à répondre à :

- quelles sont les informations personnelles collectées ?
- pourquoi le sont-elles ?
- comment sont-elles utilisées ?
- avec qui sont-elles partagées ?
- quels dispositifs ont été mis en place pour en protéger la divulgation ?
- combien de temps seront-elles conservées ?
- comment seront-elles supprimées ?

IA : éthique des données

- éthique intrinsèque

Les données peuvent être « impropres »

Pour être « propres », les données manipulées par un SIA doivent répondre aux critères de : qualité (absence de **biais**), diversité et non-discrimination, et traçabilité

biais méthodologique

données observées

biais statistique

données collectées

biais cognitif

SIA

biais éthique

données résultats

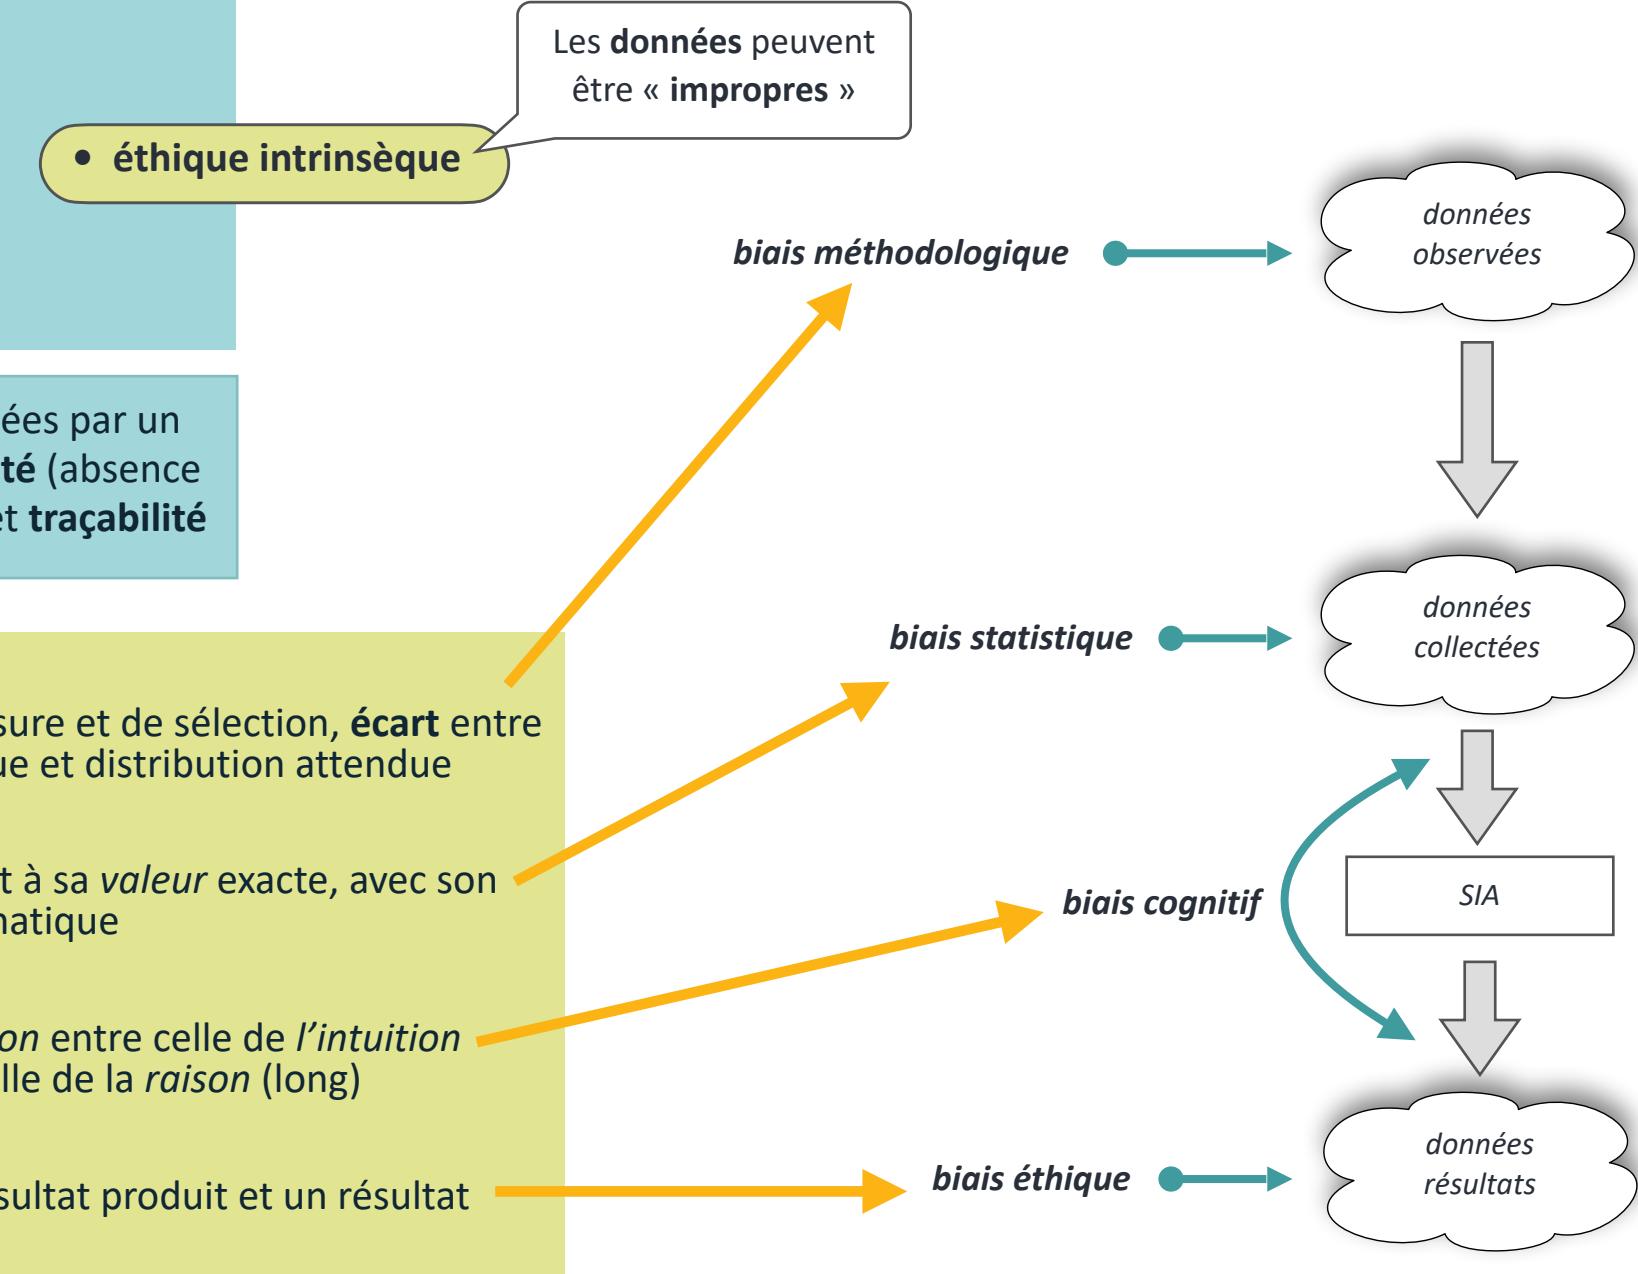
IA : éthique des données

- éthique intrinsèque

Les données peuvent être « impropre »

Pour être « propres », les données manipulées par un SIA doivent répondre aux critères de : qualité (absence de **biais**), diversité et non-discrimination, et traçabilité

- biais méthodologique
 - ... méthode de mesure et de sélection, **écart** entre *distribution* obtenue et distribution attendue
- biais statistique
 - ... **écart** par rapport à sa *valeur exacte*, avec son espérance mathématique
- biais cognitif
 - ... **écart de validation** entre celle de *l'intuition* (donc rapide) et celle de la *raison* (long)
- biais éthique
 - ... **écart** entre le résultat produit et un résultat socialement juste



5.3 IA : éthique du développement

Ces principes éthiques sont ceux du **numérique**, comme :

- l'**explicabilité**
- l'**interprétabilité** (*Interpretability*)
- la capacité (d'un système d'IA) à **rendre des comptes** (*Accountability*)
- la **transparence** (*Transparency*)
- la **fiabilité** (*Trustworthiness*)
- l'**équité** (*Fairness*)
- la **conformité** (respect des règles et de la législation)
- la **loyauté** (fidélité de la réalisation par rapport aux spécifications)
- l'identification des **responsabilités**

... qui créent, ensemble, la **confiance** en l'outil développé

5.3 IA : éthique du développement

Ces principes éthiques sont ceux du **numérique**, comme :

- l'**explicabilité**
- l'**interprétabilité** (*Interpretability*)
- la capacité (d'un système d'IA) à **rendre des comptes** (*Accountability*)
- la **transparence** (*Transparency*)
- la **fiabilité** (*Trustworthiness*)
- l'**équité** (*Fairness*)
- la **conformité** (respect des règles et de la législation)
- la **loyauté** (fidélité de la réalisation par rapport aux spécifications)
- l'identification des **responsabilités**

... qui créent, ensemble, la **confiance** en l'outil développé

Mais **des difficultés natives, propres à l'IA**, peuvent empêcher, ou gêner, la vérification de certaines propriétés :

5.3 IA : éthique du développement

Ces principes éthiques sont ceux du **numérique**, comme :

- l'**explicabilité**
- l'**interprétabilité** (*Interpretability*)
- la capacité (d'un système d'IA) à **rendre des comptes** (*Accountability*)
- la **transparence** (*Transparency*)
- la **fiabilité** (*Trustworthiness*)
- l'**équité** (*Fairness*)
- la **conformité** (respect des règles et de la législation)
- la **loyauté** (fidélité de la réalisation par rapport aux spécifications)
- l'identification des **responsabilités**

... qui créent, ensemble, la **confiance** en l'outil développé

Mais **des difficultés natives, propres à l'IA**, peuvent empêcher, ou gêner, la vérification de certaines propriétés :

« **apprendre sans comprendre** » est à la base des mécanismes d'apprentissage. C'est un apprentissage qui peut même être sans but (énoncé ou spécifié d'avance)

comment **expliquer les résultats** (transparence) d'un algorithme d'apprentissage qui évolue sans cesse pendant son utilisation

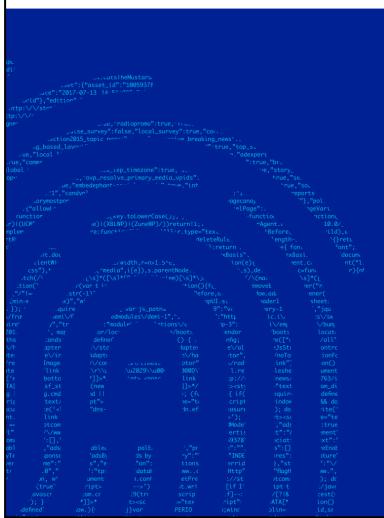
comment **vérifier la conformité (et la loyauté)** des résultats produits par un algorithme d'apprentissage... alors que la spécification des résultats attendus n'existe pas

en cas de faute, 3 acteurs sont impliqués : — le concepteur de l'algorithme, — l'utilisateur des résultats produits... — et le mécanisme d'apprentissage qui continue d'apprendre au cours de son usage

5.4 IA : éthique de son usage



LA DÉCLARATION
DE MONTRÉAL POUR
UN DÉVELOPPEMENT
RESPONSABLE
DE L'INTELLIGENCE
ARTIFICIELLE
2018



1 - Principe de bien-être

- améliorer les conditions de vie, santé et conditions de travail
- permettre d'exercer ses capacités physiques et intellectuelles
- ne doit pas augmenter le stress, l'anxiété, le harcèlement

2 - Principe du respect de l'autonomie

- permettre à chacun de réaliser sa propre conception de la vie
- éviter les dépendances par une confusion entre IA et humains
- ne doit pas mettre en œuvre des mécanismes de surveillance, d'évaluation ou d'incitation contraignants

3 - Principe de protection de l'intimité et la vie privée

- protéger des espaces d'intimité non surveillés
- protéger l'intimité de la pensée et des émotions
- pas de profil personnalisé pour influencer le comportement
- avoir un contrôle étendu sur ses données personnelles

4 - Principe de solidarité

- favoriser les relations humaines et réduire l'isolement
- favoriser le travail collaboratif
- ne pas simuler des comportements cruels par des robots

5 - Principe de participation démocratique

- une IA qui peut affecter la qualité de vie des personnes doit être intelligible et justifiable
- le code des algorithmes doit être accessible aux autorités
- la découverte d'effets non prévus doit être signalée

6 - Principe d'équité

- ne pas créer de discriminations sociales, religieuses, ethniques..
- éliminer les relations de domination fondées sur la richesse, le pouvoir, la connaissance
- bénéficier économiquement à tous

7 - Principe d'inclusion de la diversité

- ne pas induire l'uniformisation ou la normalisation
- respecter les multiples expressions de toutes les diversités
- pour chaque catégorie de service, une offre d'IA diversifiée

8 - Principe de prudence

- restreindre la diffusion d'IA pouvant présenter un danger
- satisfaire des critères de fiabilité, sécurité intégrité... testés
- prévenir des risques d'usage néfaste des données et de l'IA

9 - Principe de responsabilité

- seuls des êtres humains peuvent être tenus pour responsables
- une décision qui affecte la vie doit être prise par une personne

10 - Principe de développement soutenable

- efficacité énergétique des infrastructures des IA
- filière de maintenance, réparation et recyclage
- lutter contre le gaspillage des ressources naturelles