

Éthique & IA au quotidien

Loyauté des Algorithmiques d'Apprentissage Automatique

PHILIPPE BESSE & CÉLINE CASTETS RENARD, AURÉLIEN GARIVIER, JEAN-MICHEL LOUBES

Université de Toulouse – INSA



Intelligence Artificielle (IA) au quotidien

- Pas de **Science Fiction** : transhumanisme, singularité technologique, lois d'Azimov
- Pas de **Sociologie** : destruction des emplois qualifiés, *big data big brother*
- **Algorithmes** de décision ou aide automatique à la décision
- **Sous-ensemble** de L'IA : apprentissage automatique (**machine learning**)
- **Entraînés** sur des bases de données : **apprentissage statistique** (*statistical learning*)
 - **Risque** de défaut de paiement, de comportement à risque, de rupture de contrat
 - **Risque** de récidive, de passage à l'acte
 - **Risque** de défaillance ou panne d'un système industriel
 - **Diagnostic** et bases d'images (*deep learning*)
 - **Profilage** professionnel (CV), publicitaire
 - ...
- Régression, *k*-ppv, Arbres, SVM, *random forest*, *boosting*, réseaux de neurones...

Battage médiatique de l'Intelligence Artificielle

- **Convergence** entre apprentissage automatique, données massives & Puissance de calcul, stockage
- **Succès** médiatisés de l'apprentissage profond (*deep learning*)
Reconnaissance d'images, véhicules autonomes, jeu de go...
- **Données confidentielles** et fort impact personnel
- **Enjeux** sociétaux & financiers considérables

Pourquoi se préoccuper d'Éthique en IA ?

- Rapport Villani (03-2018) : *L'IA au service de l'Humain*
- Vide entre Lois et Technologies : **responsabilité** des acteurs
- **Confiance** et acceptabilité des nouvelles technologies
- **Entreprises** philanthropiques et altruistes ?

THE WALL STREET JOURNAL. Subscribe Now | Sign In
SPECIAL OFFER: JOIN NOW

Home World U.S. Politics Economy Business Tech **Markets** Opinion Arts Life Real Estate Q

Oil at One-Year High on Falling Stockpiles **U.S. Stocks Rise on Oil Rally, Bank Earnings** **Platinum Partners' Flagship Hedge Fund Files for Bankruptcy**

MARKETS
U.S. Government Uses Race Test for \$80 Million in Payments
 Checks are ready for minority borrowers allegedly discriminated against on Ally Financial auto loans

By **ANNAMARIA ANDRIOTIS** and **RACHEL LOUISE ENSIGN**
 Updated Oct. 29, 2015 9:32 p.m. ET

Recommended Videos

c|net Rechercher sur CNET Q News Meilleurs Tests Culture

CNET France > News > Internet > Facebook plonge en bourse, Zuckerberg perd 16,8 milliards de dollars en deux heures

Facebook plonge en bourse, Zuckerberg perd 16,8 milliards de dollars en deux heures

Mark Zuckerberg a de nouveaux soucis, l'activité publicitaire de Facebook est en repli et l'action chute de 24% après la publication des résultats trimestriels en deçà des attentes. La fortune personnelle du patron aurait dégringolé de 16,8 milliards...

Cinq questions d'éthique

- 1 Propriété, **confidentialité** (*privacy*) des données personnelles et rôle de la CNIL (RGPD)
- 2 Entraves à la **concurrence** : moteurs de recherche, comparateurs
Pricing automatique et compétition virtuelle (Ezrachi A., Stucke M. 2016)
- 3 **Biais & Discrimination** de décision algorithmiques
- 4 **Explicabilité**, transparence des algorithmes
- 5 **Qualité** des prévisions donc des décisions

Loyauté des algorithmes

- **Trustworthiness** : Mériter la confiance : fiabilité, crédibilité, non discriminatoire
- **Accountability** : responsabilité, capacité à rendre compte

Article 22 (RGPD) : Décision individuelle automatisée, y compris le profilage

- 1 La personne concernée a le droit de ne pas faire l'objet d'une décision fondée exclusivement sur un **traitement automatisé**, y compris le **profilage**, produisant des effets juridiques la concernant ou l'**affectant de manière significative** de façon similaire.
- 2 Le paragraphe 1 ne s'applique pas lorsque la décision :
 - a est nécessaire à la conclusion ou à l'exécution d'un **contrat** entre la personne concernée et un responsable du traitement ;
 - b est **autorisée par le droit** de l'Union ou le droit de l'État membre auquel le responsable du traitement est soumis et qui prévoit également des mesures appropriées pour la sauvegarde des droits et libertés et des intérêts légitimes de la personne concernée ; ou
 - c est fondée sur le **consentement** explicite de la personne concernée.
- 3 Dans les cas visés au paragraphe 2, points a) et c), le responsable du traitement met en œuvre des mesures appropriées pour la sauvegarde des droits et libertés et des intérêts légitimes de la personne concernée, au moins du droit de la personne concernée d'obtenir une intervention humaine de la part du responsable du traitement, d'exprimer son point de vue et de contester la décision.
- 4 Les décisions visées au paragraphe 2 ne peuvent être fondées sur les catégories particulières de **données à caractère personnel** (cf. article 9 : biométriques, génétiques, de santé, ethniques ; orientation politique, syndicale, sexuelle, religieuse, philosophique) **sous réserve** d'un intérêt public substantiel et que des mesures appropriées pour la sauvegarde des droits et libertés et des intérêts légitimes de la personne concernée ne soient en place.

Article 225-1 du code pénal

Constitue une **discrimination** toute distinction opérée entre les personnes physiques sur le fondement de leur **origine**, de leur sexe, de leur situation de famille, de leur grossesse, de leur apparence physique, de la particulière vulnérabilité résultant de leur situation économique, apparente ou connue de son auteur, de leur patronyme, de leur lieu de résidence, de leur état de santé, de leur perte d'autonomie, de leur handicap, de leurs caractéristiques génétiques, de leurs mœurs, de leur orientation sexuelle, de leur identité de genre, de leur âge, de leurs opinions politiques, de leurs activités syndicales, de leur capacité à s'exprimer dans une langue autre que le français, de leur appartenance ou de leur non-appartenance, vraie ou supposée, à une **ethnie**, une Nation, une **prétendue race** ou une religion déterminée

Article 225-2 du code pénal

La **discrimination** définie aux articles 225-1 à 225-1-2, commise à l'égard d'une **personne physique** ou morale, est punie de trois ans d'emprisonnement et de 45 000 euros d'amende lorsqu'elle consiste à :

- 1 refuser la fourniture d'un bien ou d'un service
- 2 entraver l'exercice normal d'une activité économique quelconque
- 3 refuser d'embaucher, à sanctionner ou à licencier une personne

Discrimination individuelle vs. de groupe

- **Loi française** et RGPD ont une approche individuelle de la discrimination
- *Quid* d'une forme **implicite** de discrimination :
 - **biais** structurel ou bases de données biaisées
 - variable sensible **absente** et prévisible
 - prévision **auto-réalisatrice**
- **Rapport Villani** & mesure de groupe de la discrimination :
Discrimination Impact Assessment (DIA)
- **Jurisprudence américaine** (*Title vii 1964 Civil Rights Act*) & *disparate impact* (DI)
Impact disproportionné pour un groupe $DI = \frac{P(Y=1|S=0)}{P(Y=1|S=1)}$
- **Question** : estimation du *DI* (cf. Besse et al. 2018 & **wikistat**)
- **Autres mesures** de discrimination
 - Taux d'erreur et représentativité de la base (e.g. reconnaissance faciale)
 - **Égalité d'opportunité** (Hardt et al. 2016 ; **What-if-tools**) ou
Conditional Procedure Accuracy Equality (Besse et al. 2018 ; **wikistat**)
 - ... cf. Zliobaité (2015)

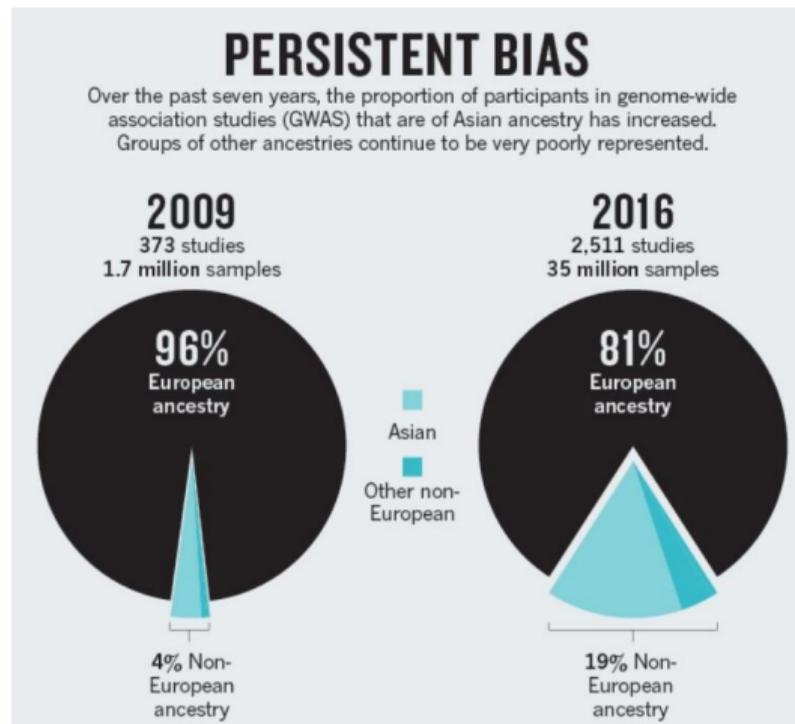
Testing et preuve d'une discrimination individuelle

- *SOS racisme* : pratique jugée déloyale mais reconnue
 - **Arrêt** de la Cours de Cassation (2012)
 - *article 225-3-1 code pénal* Les délits prévus par la présente section sont constitués... dès lors que la preuve de ce comportement est établie
- Discrimination à l'**embauche** :
 - **Observatoire** des Discriminations
 - **DARES** (Direction de l'Animation, des Études, de la Recherche et des Statistiques)
 - **ISM Corum**
- **Accès** à l'assurance, au crédit : L'Horty et al. (2017)

Biais en Santé

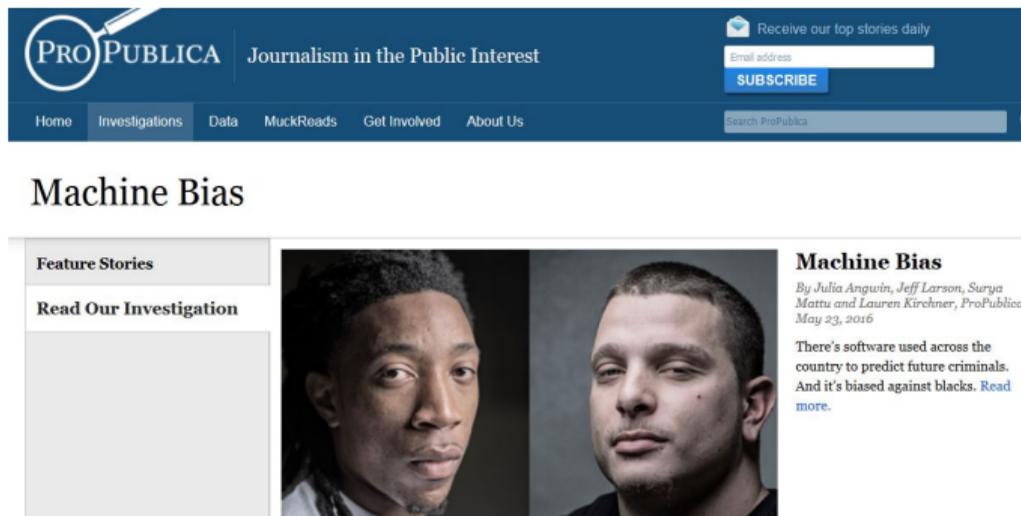
- Médecine de **précision** vs. de **population**
- **Traitement** personnalisé : sommes nous tous égaux ?
- **GWAS** *Genome Wide Association Studies*
Bases d'associations pangénomiques
- **Liaisons** entre variants génétiques (SNPs) et traits phénotypiques
- **Biais**
 - **Ethnique** : population d'ascendance blanche européenne *Genomics is failing on diversity* (Popejoy et Fullerton, 2016)
 - **Âge** et environnement : bases transversales et pas longitudinales
 - **Genre** : Chang et al. (2014), Pulit et al. (2017)

GWAS : Biais ethnique



Popejoy et Fullerton (2016)

Justice prédictive : ProPublica vs. equivant (NorthPointe Inc.)



The screenshot shows the ProPublica website header with the logo and tagline "Journalism in the Public Interest". Navigation links include Home, Investigations, Data, MuckReads, Get Involved, and About Us. A search bar and a "SUBSCRIBE" button are also visible.

Machine Bias

Feature Stories

Read Our Investigation



Machine Bias
By Julia Angwin, Jeff Larson, Surya Mattu and Lauren Kirchner, ProPublica, May 23, 2016

There's software used across the country to predict future criminals. And it's biased against blacks. [Read more.](#)

Angwin et al. (2016)

ProPublica vs. Equivant (NorthPointe Inc.)

- Absence de discrimination selon NorthPointe Inc.
 - Distributions des scores (m_1 et m_2) donc DI similaires
 - Taux d'erreur $(FN + FP)/n$ similaires
- Discrimination selon ProPublica : *Conditional Procedure Accuracy Equality*

Matrice de confusion

Observation Récidive	Score		
	Faible	Élevé	
Oui	FN	VP	q_1
Non	VN	FP	q_2
	m_1	m_2	n

- Taux de faux positifs = FP/q_2
afro-américain (45%) vs. caucasiens (25%)
- Taux de récidive afro-américain plus élevé (Chouldechova, 2016)
- Taux d'erreur très élevé (40%)

Rapport Villani (2018)

L'ouverture des boîtes noires" de l'IA est un "enjeu démocratique"

Article 22 (RGPD) : Décision individuelle automatisée, y compris le profilage

- 1 La personne concernée a le droit de ne pas faire l'objet d'une décision fondée exclusivement sur un **traitement automatisé**, y compris le **profilage**, produisant des effets juridiques la concernant ou l'**affectant de manière significative** de façon similaire.
- 2 Le paragraphe 1 ne s'applique pas lorsque la décision :
 - a est nécessaire à la conclusion ou à l'exécution d'un **contrat** entre la personne concernée et un responsable du traitement ;
 - b est **autorisée par le droit** de l'Union ou le droit de l'État membre auquel le responsable du traitement est soumis et qui prévoit également des mesures appropriées pour la sauvegarde des droits et libertés et des intérêts légitimes de la personne concernée ; ou
 - c est fondée sur le **consentement** explicite de la personne concernée.
- 3 Dans les cas visés au paragraphe 2, points a) et c), le responsable du traitement met en œuvre des mesures appropriées pour la sauvegarde des droits et libertés et des intérêts légitimes de la personne concernée, au moins du droit de la personne concernée d'obtenir une **intervention humaine** de la part du responsable du traitement, d'exprimer son point de vue et de **contester** la décision.
- 4 Les décisions visées au paragraphe 2 ne peuvent être fondées sur les catégories particulières de **données à caractère personnel** (cf. article 9 : biométriques, génétiques, de santé, ethniques, orientation politique, syndicale, sexuelle, religieuse, philosophique) **sous réserve** d'un intérêt public

Jongler entre RGPD et lois nationales

- **Loi** n° 78-17 du 6/01/1978 relative à l'informatique aux fichiers et aux libertés
- **Loi** n° 2015-912 du 24/07/2015 relative au renseignement
- **Loi** n°2016-1321 du 7/10/2016 pour une République Numérique (Lemaire)
- **Décrets** d'applications (2017)
- **RGPD** Règlement Général pour la Protection des Données 05-2018
- **Réforme** de la loi informatique et libertés LIL 3 : loi n° 2018-493 du 20 juin 2018
- **Code** des relations entre le public et les administrations
- **Conseil Constitutionnel** Décision n° 2018-765 DC du 12 juin 2018

Droit à l'explication en France (LIL3)

- Aucune **décision de justice** impliquant une appréciation sur le comportement d'une personne ne peut avoir pour fondement un traitement automatisé de données à caractère personnel destiné à évaluer certains aspects de la personnalité de cette personne
- Aucune décision produisant des **effets juridiques** à l'égard d'une personne ou l'affectant de manière significative ne peut être prise sur le seul fondement d'un traitement automatisé de données à caractère personnel, y compris le profilage
- **Exception** : à condition que les règles définissant le traitement ainsi que les principales caractéristiques de sa mise en œuvre soient communiquées par le responsable de traitement à l'intéressé s'il en fait la demande (sauf secret protégé par la loi)
- **Loi n° 2018-493 Le responsable de traitement** s'assure de la maîtrise du traitement algorithmique et de ses évolutions afin de pouvoir **expliquer**, en détail et sous une **forme intelligible**, à la personne concernée la **manière dont le traitement** a été mis en œuvre à son égard
- **En résumé** : identifier une **responsabilité humaine** plus qu'un droit à l'explication ou l'interprétation.

Décret du 16/03/2017 Art. R. 311-3-1-2.

L'administration communique à la personne faisant l'objet d'une décision individuelle prise sur le fondement d'un traitement algorithmique, à la demande de celle-ci, sous une **forme intelligible** et sous réserve de ne pas porter atteinte à des secrets protégés par la loi, les informations suivantes :

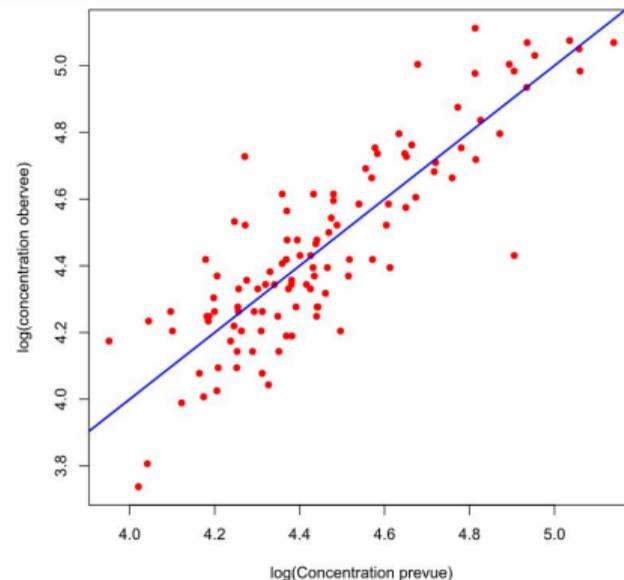
- 1 Le degré et le **mode de contribution** du traitement algorithmique à la prise de décision ;
- 2 Les **données traitées** et leurs sources ;
- 3 Les paramètres de traitement et, le cas échéant, leur **pondération**, appliqués à la situation de l'intéressé ;
- 4 Les **opérations** effectuées par le traitement.

Décision du Conseil Constitutionnel du n°2018-765 DC du 12 juin 2018, Pt 71

En dernier lieu, le **responsable du traitement** doit s'assurer de la maîtrise du traitement algorithmique et de ses évolutions afin de pouvoir expliquer, en détail et sous une forme intelligible, à la personne concernée la **manière** dont le traitement a été mis en œuvre à son égard. Il en résulte que ne peuvent être utilisés, comme fondement exclusif d'une décision administrative individuelle, des **algorithmes** susceptibles de **réviser eux-mêmes les règles qu'ils appliquent**, sans le contrôle et la validation du responsable du traitement

Explicabilité : interprétation d'un modèle linéaire du "siècle dernier"

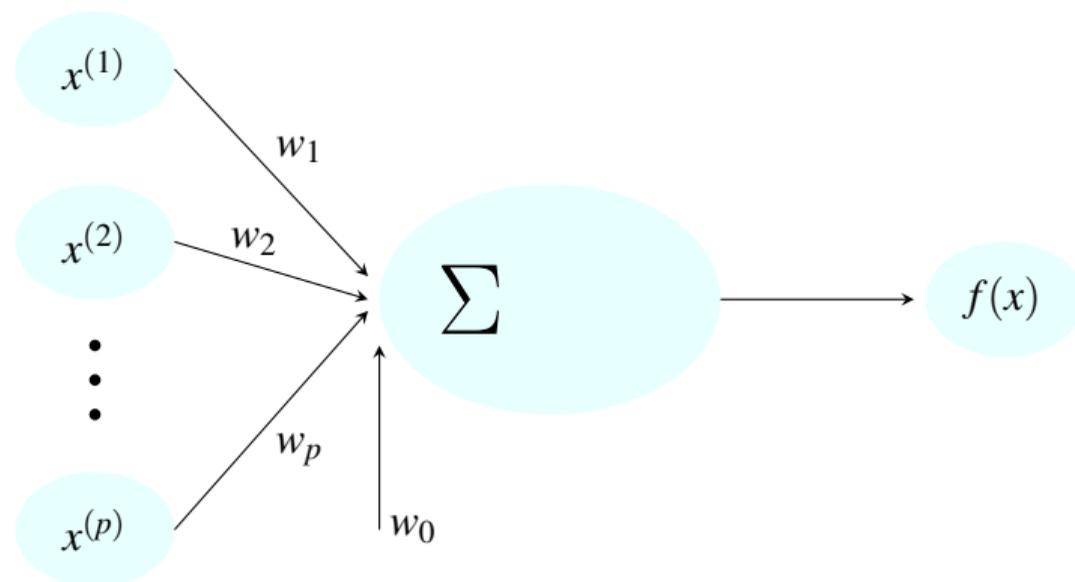
Prévoir la Concentration en Ozone



$$\begin{aligned} \log(\text{ConcODemain}) &= 2,4 + 0,35 \times \log(\text{ConcOJour}) + 0,05 \times \text{Sec} + \\ &+ 0,03 \times \text{T12} - 0,03 \times \text{Ne9} + 0.1 \times \text{Vx9} \end{aligned}$$

Modèle / Neurone Linéaire

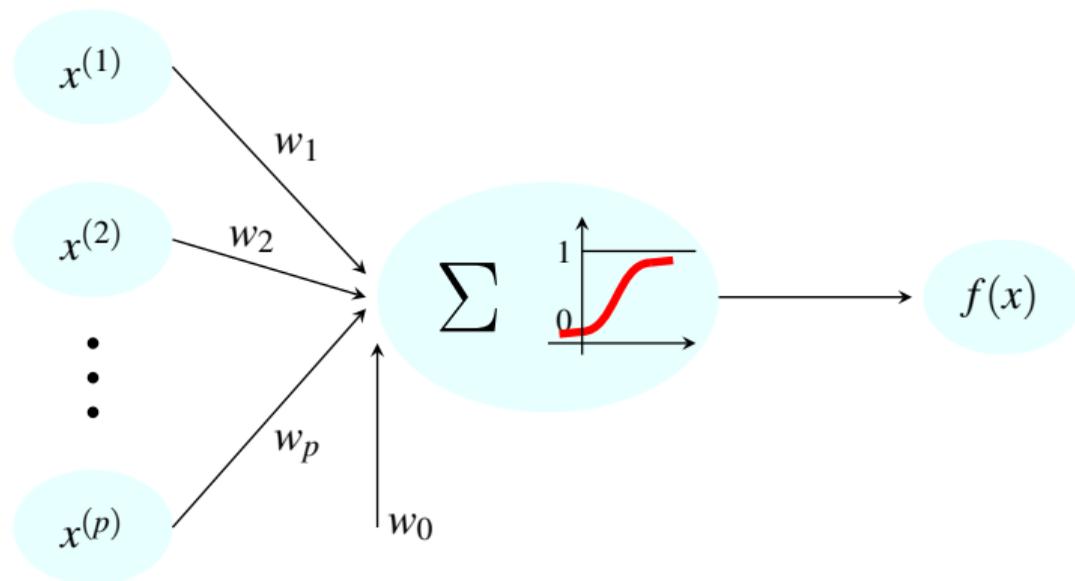
Modéliser / prévoir une variable quantitative



$$f(x) = w_0 + w_1 \times x^{(1)} + w_2 \times x^{(2)} + \dots + w_p \times x^{(p)}$$

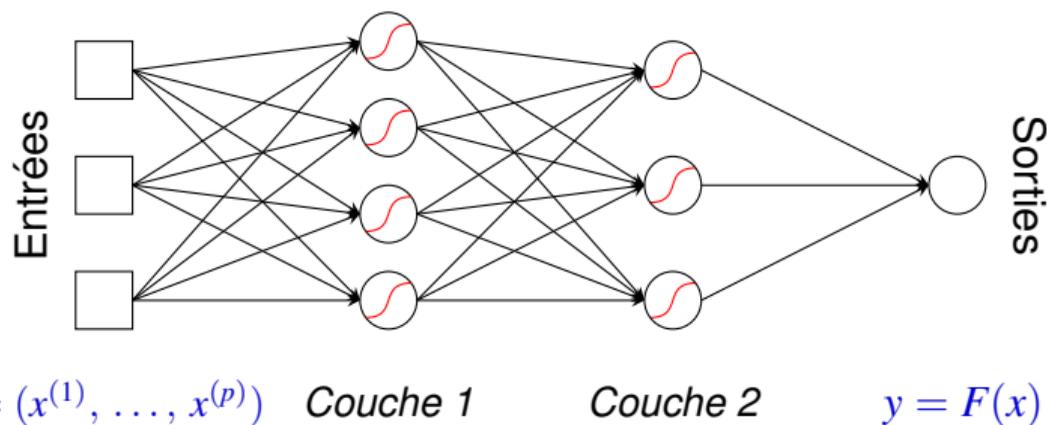
Modèle / Neurone *logistique*

Variable binaire : Maladie, Panne, Départ, Faillite...



Exemple en épidémiologie : interpréter, évaluer les facteurs de risque

Explicabilité : réseau de neurones : (Perceptron)



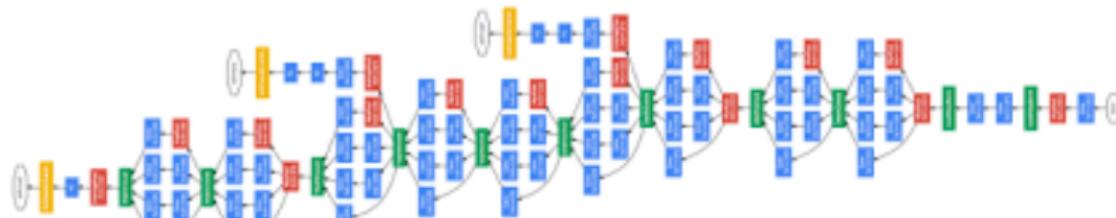
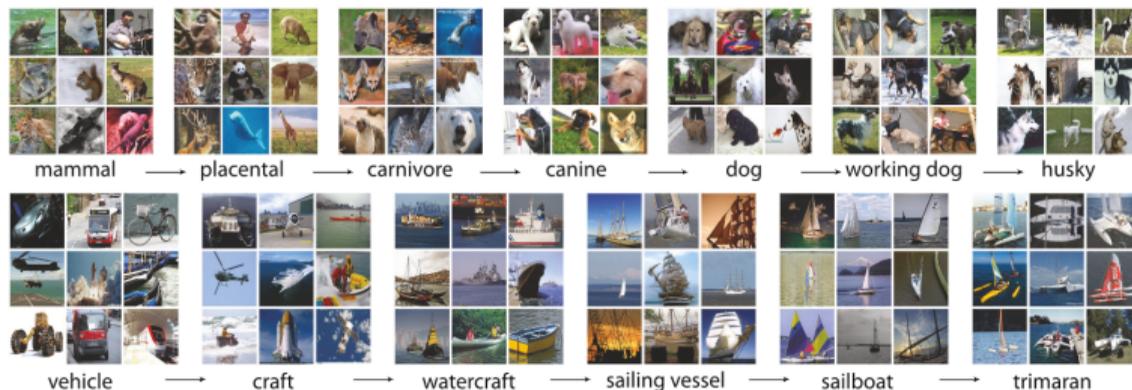
- **Interprétation** impossible : *Boîte Noire*
- **Idem** pour *k*-p.p.v., SVM, *boosting*, *random forest*...
- Quelle **explication** ?

Explicabilité : Deep Learning

Exemple : base de données ImageNet :

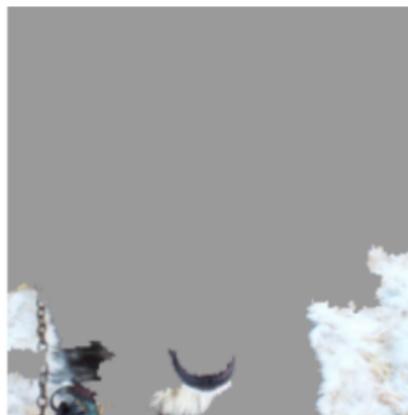
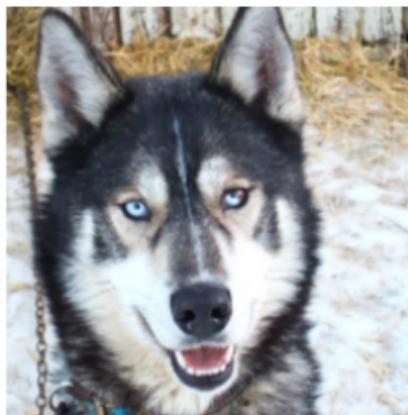
15 millions d'images, 22000 catégories

2016 : 152 couches et mieux que l'expert humain



Ouvrir les boîtes noires pour l'acceptabilité (robustesse)

- **Enjeux** majeurs sociétaux et industriels (projet franco-canadien DEEL)
- **Recherche** très active
- **Interprétation** impossible, quelle explication ?
- Explication fonctionnelle, détection d'artefact *vs.* explication individuelle
- **Approximation** locale linéaire : package LIME de R, **What-if-tools** & TensorFlow



Éthique "industrielle"

Amazon, Google, Facebook, IBM, Microsoft, Apple...



1. We believe that *artificial intelligence* technologies hold great promise for raising the *quality* of people's *lives* and can be leveraged to *help humanity* address important global challenges such as climate change, food, inequality, health, and education.

...

7. We believe that it is important for the operation of *AI systems* to be *understandable* and *interpretable* by people, for purposes of explaining the technology.

Loi et qualité des décisions

- **Qualité** et confiance envers une décision
- Apprentissage statistique : qualité de décision = qualité de prévision
- RGPD et lois françaises **muettes**
- Loi sur la publication des **sondages d'opinion**
- *L'efficacité prédictive sera d'autant plus grande qu'elle sera le fruit de l'agrégation de données massives in La Gouvernamentalité Algorithmique (Rouvroy et Berns, 2013)*
- **Vrai** et **Faux**
- **Taux d'erreur** de 3% en image vs. 30 à 40% pour le risque de récidive
- **Ne pas confondre** estimation / prévision d'une **moyenne** (*loi des grands nombres*) et celle d'un processus physique, d'un **comportement individuel** humain
- **Domaine d'application** : pertinence et représentativité de la base d'apprentissage (*Google flue trend 2008-2015*)
- **Obligation** de moyen mais pas de résultat

IA au quotidien et éthique

- **Biais et discrimination** : *DIA* ou définition statistique de la discrimination de groupe
- Le droit à l'**Explication** oblige à une responsabilité humaine, pas à une interprétation / explication indispensable mais spécifique à chaque domaine d'application
- **Qualité** de décision / prévision : vide juridique sur l'obligation d'informer (cf. sondages)

Recherche très active

- **Corriger** un biais (*fair learning*) et discrimination positive
- **Explicabilité** industrielle ou individuelle
- **Qualité** et meilleur compromis

Éthique individuelle

- *Hippocratic oath*
- Code of ethics
- Serments d'Hippocrate du *data scientist*
- Charte européenne et américaine du statisticien
- Consentement libre et éclairé !

Éthique collective

- CNIL, Autorité de la concurrence
- Contre pouvoir citoyens
- Audit des algorithmes (Rapport Villani)
- Proposition de labels

Références

- Angwin J., Larson J., Mattu S., Kirchner L. (2016). **How we analyzed the compas recidivism algorithm**. ProPublica, en ligne consulté le 28/04/2017.
- Besse P. del Barrio E., Gordaliza P., Loubes J.-M. (2018). Confidence Intervals for testing Disparate Impact in Fair Learning, arXiv preprint arXiv :1807.06362.
- Chang D., Gao F., Slavney A., Ma L., Waldman Y., Sams A., Billing-Ross P., Madar A., Spritz R., Keinan A. (2014). Accounting for eXentricities : Analysis of the X Chromosome in GWAS Reveals X-Linked Genes Implicated in Autoimmune Diseases, *PLoS One*, 9(12).
- Chouldechova A. (2016). **Fair prediction with disparate impact: A study of bias in recidivism prediction instruments**, arXiv pre-print.
- Hardt M., Price E., Srebro N. (2016). Equality of Opportunity in Supervised Learning, *30th Conference on Neural Information Processing System (NIPS)*.
- L'Horty Y., Bunel M., Mbaye S., Petit P., du Parquet L. (2017). Discriminations dans l'accès à la banque et à l'assurance : Les enseignements de trois testings, *TEPP Research Report 2017-08*, TEPP.
- Popejoy A., Fullerton S. (2016). Genomics is failing on diversity, *Nature*, 538, 161-164.
- Pulit S., Karaderi T., Lindgren C. (2017). Sexual dimorphisms in genetic loci linked to body fat distribution, *Bioscience Report*, 37(1).
- Rouvroy A., Berns T. (2013). **Gouvernementalité algorithmique et perspectives d'émancipation**, *Réseaux*, 177, 163-196.
- Zliobaitė I. (2015). **A survey on measuring indirect discrimination in machine learning**. arXiv pre-print.

