



Explicabilité et loyauté des règles de décision boîtes-noires en Intelligence Artificielle

Laurent Risser
Ingénieur de Recherche
CNRS - IMT - 3IA ANITI

Ronan Pons
Doctorant
Université Toulouse Capitole - 3IA ANITI

lrisser@math.univ-toulouse.fr

Décisions ou prédictions automatiques en utilisant de règles apprises sur un jeu d'apprentissage

Modèles utilisant des règles simples

- Systèmes experts
- Modèles linéaires
- Arbres de décisions
- Perceptron

Modèles aux règles de décisions peu à très peu interprétables

- SVM à noyau
- Forêts aléatoires

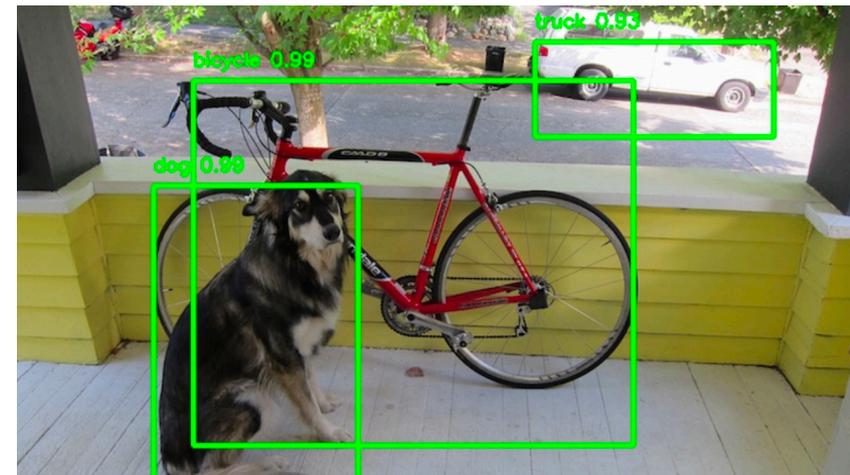
Modèles aux règles encore moins interprétables

- Réseaux de Neurones profonds

Années

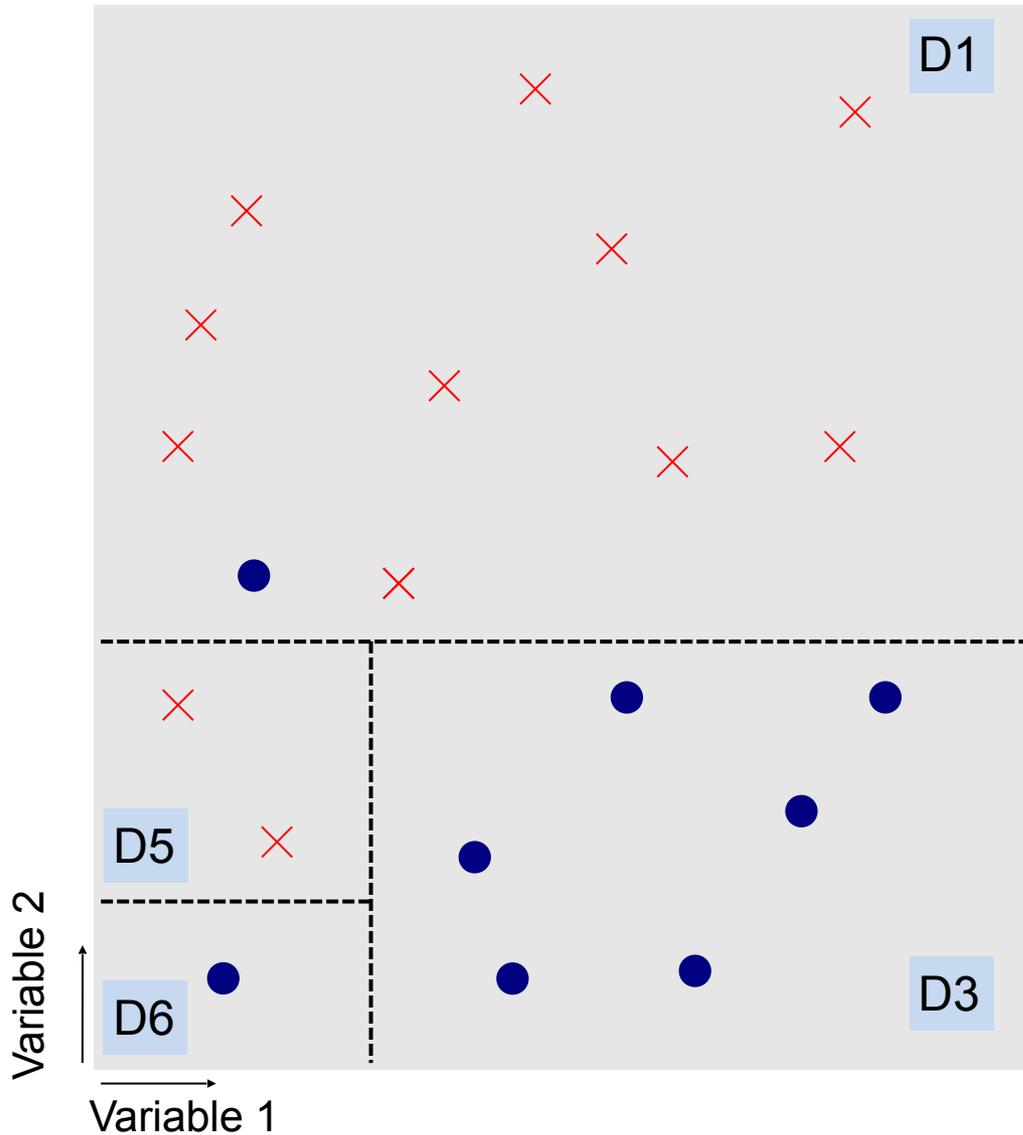


Début des années 1980 : Aide au pilotage à l'aide de systèmes experts



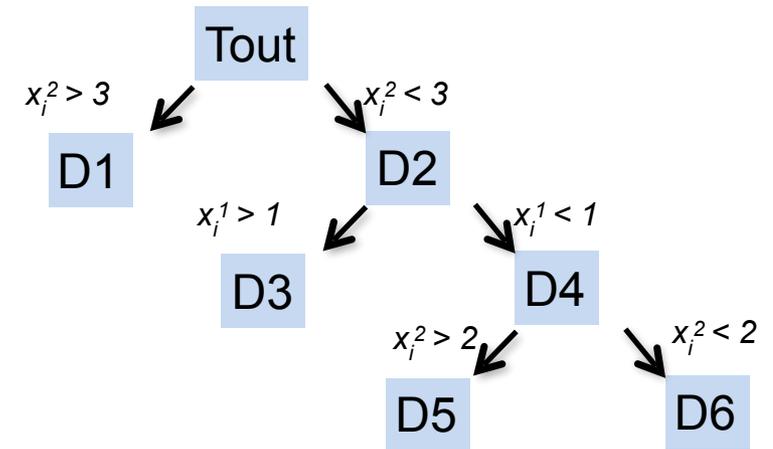
Fin des années 2010 : Détection temps réel de plus de 1000 objets par CNN dans des vidéos à 24 fps (Yolo v3).

Interprétabilité — Arbres de décisions

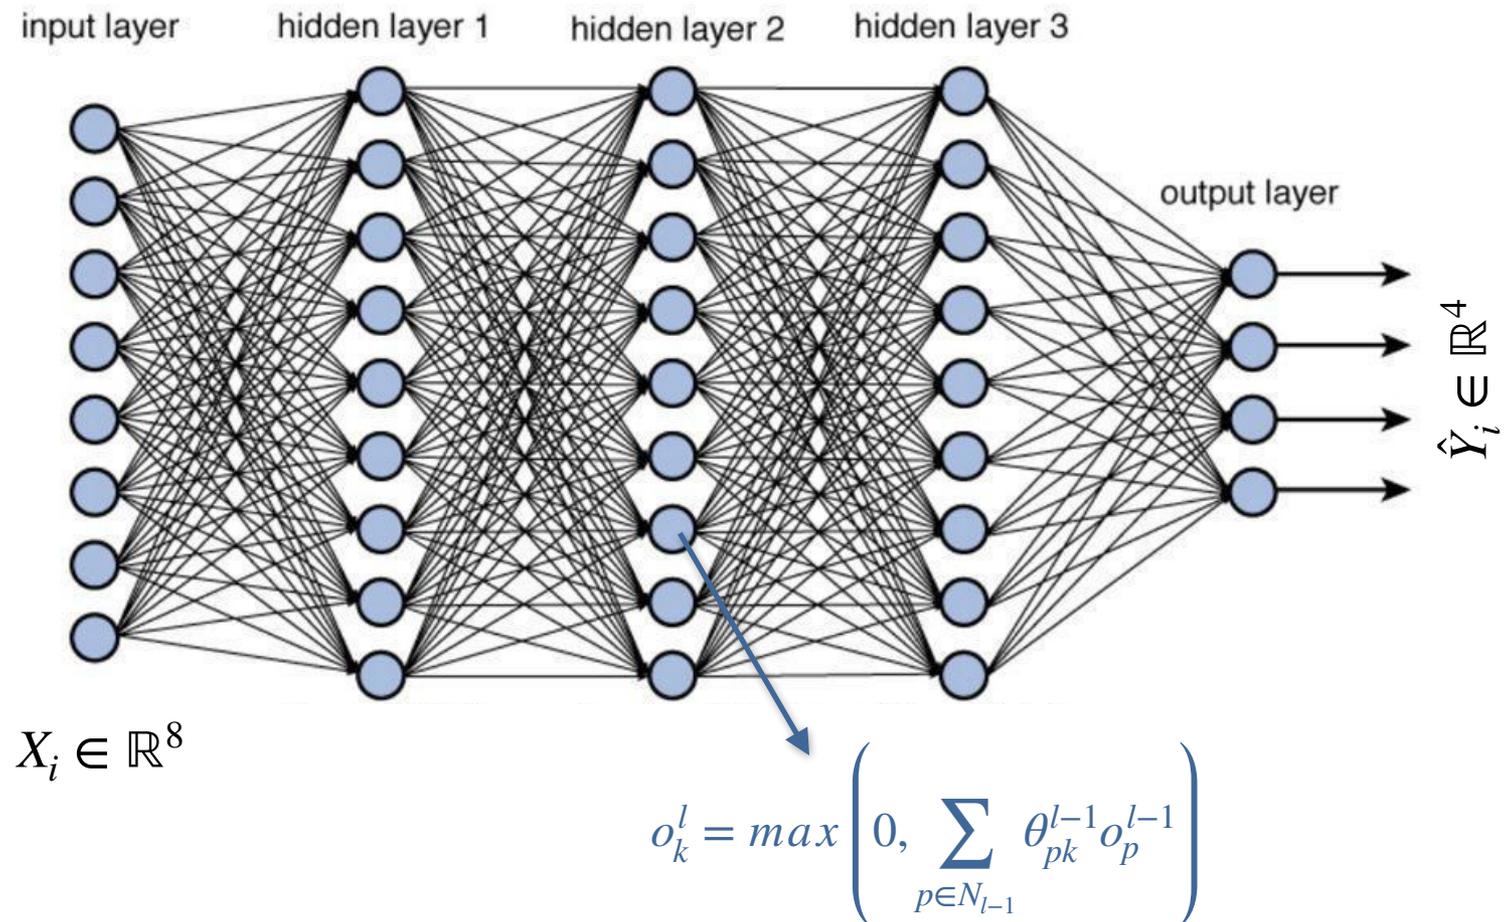


$\mathbf{x}_i = (x_i^1, x_i^2)$ une observation d'entrée

y_i un labels. (ici : $\times \rightarrow 1$ et $\bullet \rightarrow -1$)



Interprétabilité — Réseaux de neurones



Réseau « *pas très profond* » prenant des décisions à partir de 270 paramètres $\theta = \{\theta_{pk}^l\}_{p,k,l}$

Vision actuelle de l'I.A. \approx Applications de *l'apprentissage supervisé* avec

- des **règles de décisions complexes**
- des **bases d'apprentissage massives**



Publicité en ligne



Aide au diagnostic



Véhicules autonomes

...

Vision actuelle de l'I.A. \approx Applications de *l'apprentissage supervisé* avec

- des **règles de décisions complexes**
- des **bases d'apprentissage massives**



Publicité en ligne



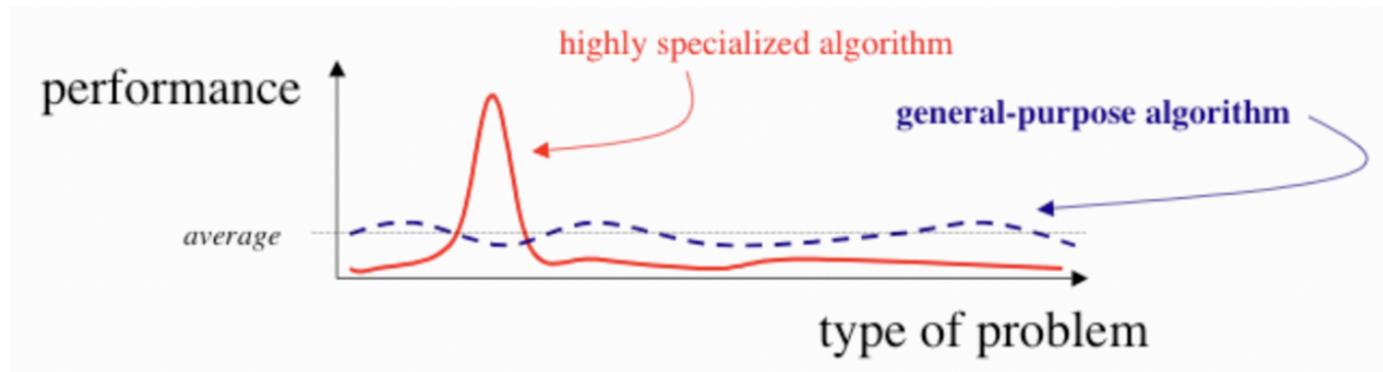
Aide au diagnostic



Véhicules autonomes

...

Mais... problème (classique) du biais !



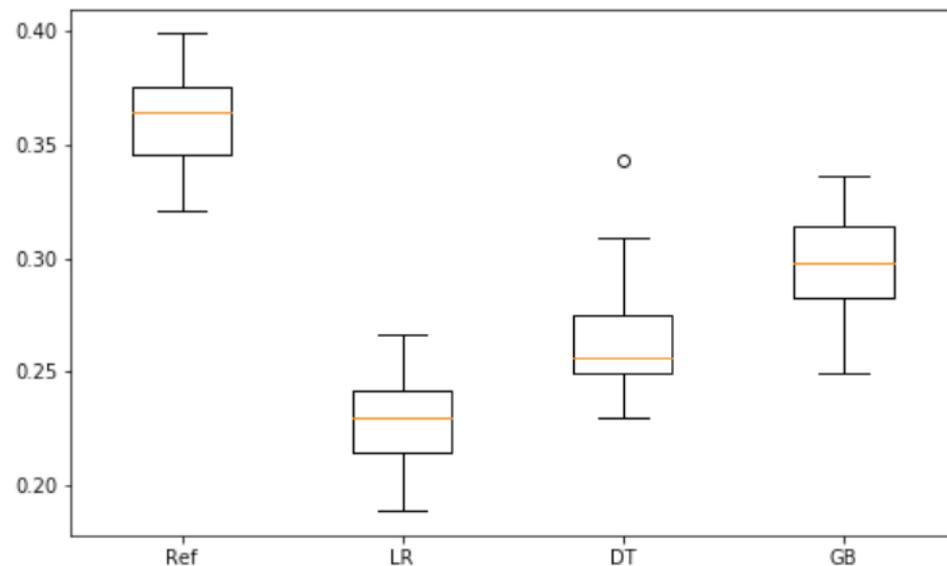
Depiction of the No Free Lunch theorem, where better performance at a certain type of problem comes with the loss of generality (Fedden, 2017)

Pire... le biais peut être déjà contenu dans les données d'apprentissage !

Exemple : Accord ou refus d'un prêt en fonction du dossier client (<https://archive.ics.uci.edu/ml/datasets/adult>)



Déséquilibres dans la base d'apprentissage



Disparate Impact (DI) de prédictions
(ici $acc \in [0.85, 0.87]$)

$$DI = \frac{\mathbb{P}(\hat{Y} = \text{granted} | S = \text{Female})}{\mathbb{P}(\hat{Y} = \text{granted} | S = \text{Male})}$$

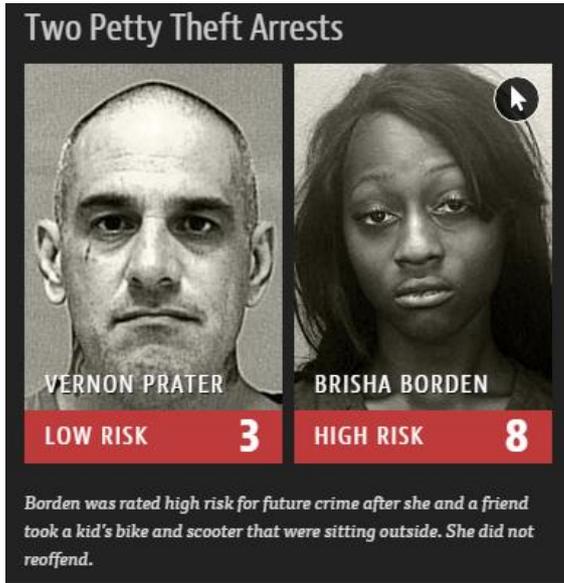
Besoins forts et urgents de :

- **Cadre légal** pour profiter des avancés de l'I.A. tout en limitant ses dérives.
- Outils qui **défectent** un problème potentiel.
- Outils qui **interprètent** des règles de décisions complexes afin de les **corriger**.

Risque juridique du *machine learning* : la discrimination algorithmique

COMPAS

Two Petty Theft Arrests



VERNON PRATER
LOW RISK 3

BRISHA BORDEN
HIGH RISK 8

Borden was rated high risk for future crime after she and a friend took a kid's bike and scooter that were sitting outside. She did not reoffend.

The image shows two mugshot-style portraits side-by-side. On the left is Vernon Prater, a man with a shaved head, labeled 'LOW RISK 3'. On the right is Brisha Borden, a woman with dark hair, labeled 'HIGH RISK 8'. Below the portraits is a small text box with a quote about Borden's case.

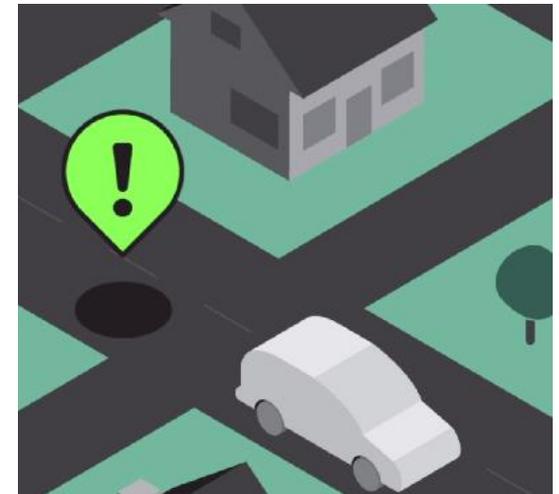
Source : *Propublica*

GOOGLE PHOTOS



Source : *The Verge*

STREET BUMP



Source : *Boston.gov*

Les principes éthiques de l'IA

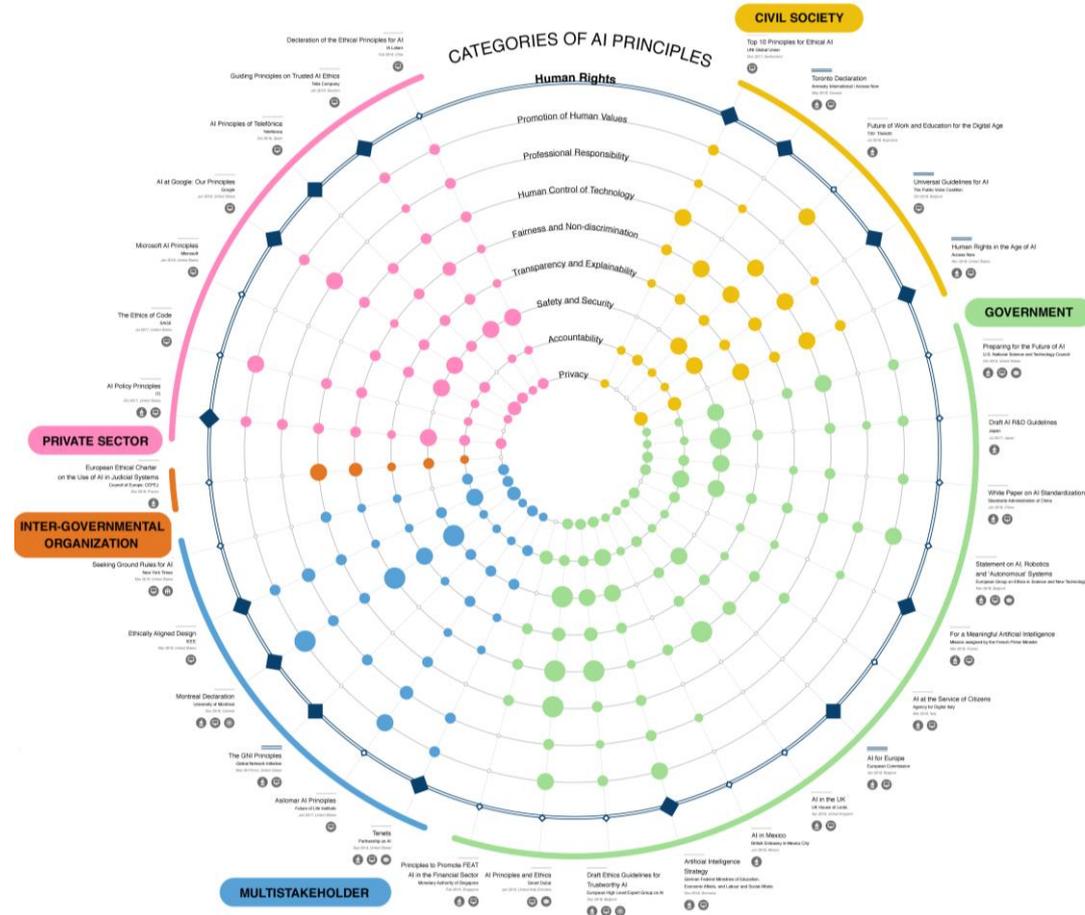
9 principes éthiques :

- Respect des droits de l'Homme ;
- Protection des valeurs humaines ;
- Responsabilité professionnelle ;
- Contrôle humain ;
- Équité et non-discrimination ;
- Transparence et Explicabilité ;
- Sûreté et sécurité ;
- Reddition de comptes ;
- Vie privée ;

PRINCIPLED ARTIFICIAL INTELLIGENCE

A Map of Ethical and Rights-Based Approaches July 4, 2019

Authors: Jessica Fjeld, Hannah Hilligoss, Nele Achten, Maia Levy Daniel, Joshua Feldman, Sally Kagay
Design: Arushi Singh (arushisingh.net)



La discrimination directe

« 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 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 leurs capacités 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 225-1 du code pénal



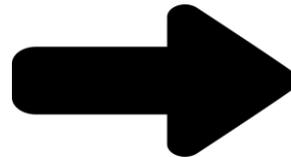
La discrimination indirecte

« *Constitue une **discrimination indirecte** une disposition, un critère ou une pratique neutre en apparence, mais susceptible d'entraîner, pour l'un des motifs mentionnés au premier alinéa, un **désavantage particulier pour des personnes par rapport à d'autres personnes**, à moins que cette disposition, ce critère ou cette pratique ne soit objectivement justifiée par un but légitime et que les moyens pour réaliser ce but ne soient nécessaires et appropriés.* »

Article 1 de la loi n°2008-496 du 27 mai 2008



Critère « neutre »



Conséquences discriminantes

Loi Informatique et Libertés (LIL) : l'interdiction des décisions automatisées

« 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 »

Article 47 LIL

Secteurs concernés



Public



Privé

Gravité de la décision
pour l'individu



Absence
d'intervention
humaine



Traitement de
données personnelles



Règlement Général à la Protection des Données personnelles (RGPD) : Obligation d'information et Droit d'accès

« [...] l'existence d'une prise de décision automatisée, [...] et, des *informations utiles* concernant la *logique sous-jacente*, ainsi que l'importance et les conséquences prévues de ce traitement pour la personne concernée. »

Articles 13.2.f), 14.2.g) et 15.1.h)

Moment de la communication



Acteurs concernés



Contenu de l'information



Logique de l'algorithme



Conséquences pour l'individu

Loi pour une République Numérique (LRN) : le cas des administrations publiques

Obligation de publication :

« [...] les administrations [...] publient en ligne les règles définissant les principaux traitements algorithmiques utilisés dans l'accomplissement de leurs missions lorsqu'ils fondent des décisions individuelles. »

Article L. 312-1-3 CRPA

Obligation de communication à l'intéressé :

« [...] une décision prise sur le fondement d'un traitement d'un traitement algorithmique comporte une **mention explicite** en informant l'intéressé.

Les **règles** définissant ce traitement ainsi que les **principales caractéristiques** de sa mise en œuvre sont **communiquées à l'intéressé s'il en fait la demande.** »

Article L. 311-3-1 CRPA

Secteurs



Administrations

Décisions



Toutes décisions automatisées

LRN (2/2) : les détails des informations à fournir

Communiquées « *sous une forme intelligible* » :

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 »*

Article R. 311-3-1-2 CRPA



Relation humain / machine au cours du processus de décision



Données entrées (*inputs*) et leurs origines



Variables en jeu et leur poids respectifs



Étapes du processus

Les projets à venir : l'exemple de la loi bioéthique

Article 11 du projet de loi:

Préserver une garantie humaine dans les résultats :

- 1) Bonne information du patient lorsqu'un traitement par IA est utilisé à l'occasion d'un acte de soins
- 2) Garantie d'une intervention humaine
- 3) Traçabilité des actions et des données utilisées pour le traitement



- . Quelles informations ?
- . Quel format ?

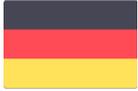


- . Qui est-ce ?
- . Quel rôle joue-t-il ?
- . Que garantie-t-il ?



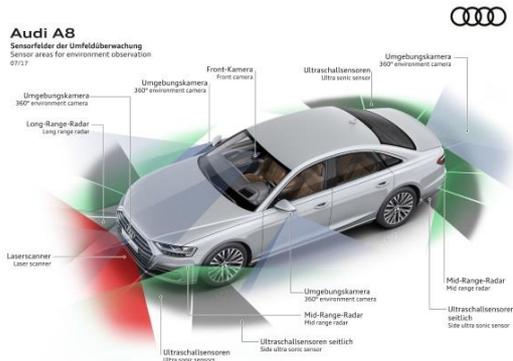
- . Comment ?
- . Quel objectif ?
- . Quelle protection ?

Et à l'international ?



En Allemagne :

**German Road Traffic Act
Amendment Regulating the Use for
« Motors Vehicles with Highly or
Fully Automated Driving
Function » - July 17, 2017**



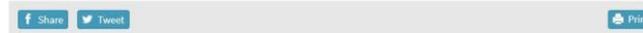
Source : Audi



Aux États-Unis :

**Projet de loi fédérale « Algorithm
Accountability Act » dont l'objectif est
de lutter contre la discrimination
algorithmique**

**Booker, Wyden, Clarke Introduce Bill Requiring
Companies To Target Bias In Corporate Algorithms**
April 10, 2019



WASHINGTON, D.C. -- U.S. Senators Cory Booker (D-NJ) and Ron Wyden (D-OR), along with Rep. Yvette D. Clarke (D-NY) today introduced the [Algorithmic Accountability Act](#), which requires companies to study and fix flawed computer algorithms that result in inaccurate, unfair, biased or discriminatory decisions impacting Americans.

Source : booker.senate.gov



En Chine :



How China Is Using “Social Credit Scores” to Reward and Punish Its Citizens

By Charlie Campbell / Chengdu



Yi Tingyue has a lot going for her. She won a scholarship to China's prestigious Sichuan University, where she graduated with a master's in graphic design. She drives an Audi A4 and owns a penthouse

Source : *Time magazine*

Du juridique à la technique



Etat de l'art du droit



Recommandations au législateur d'un cadre juridique applicable



Développement d'outils techniques conformes aux futures dispositions légales

ET MAINTENANT ???

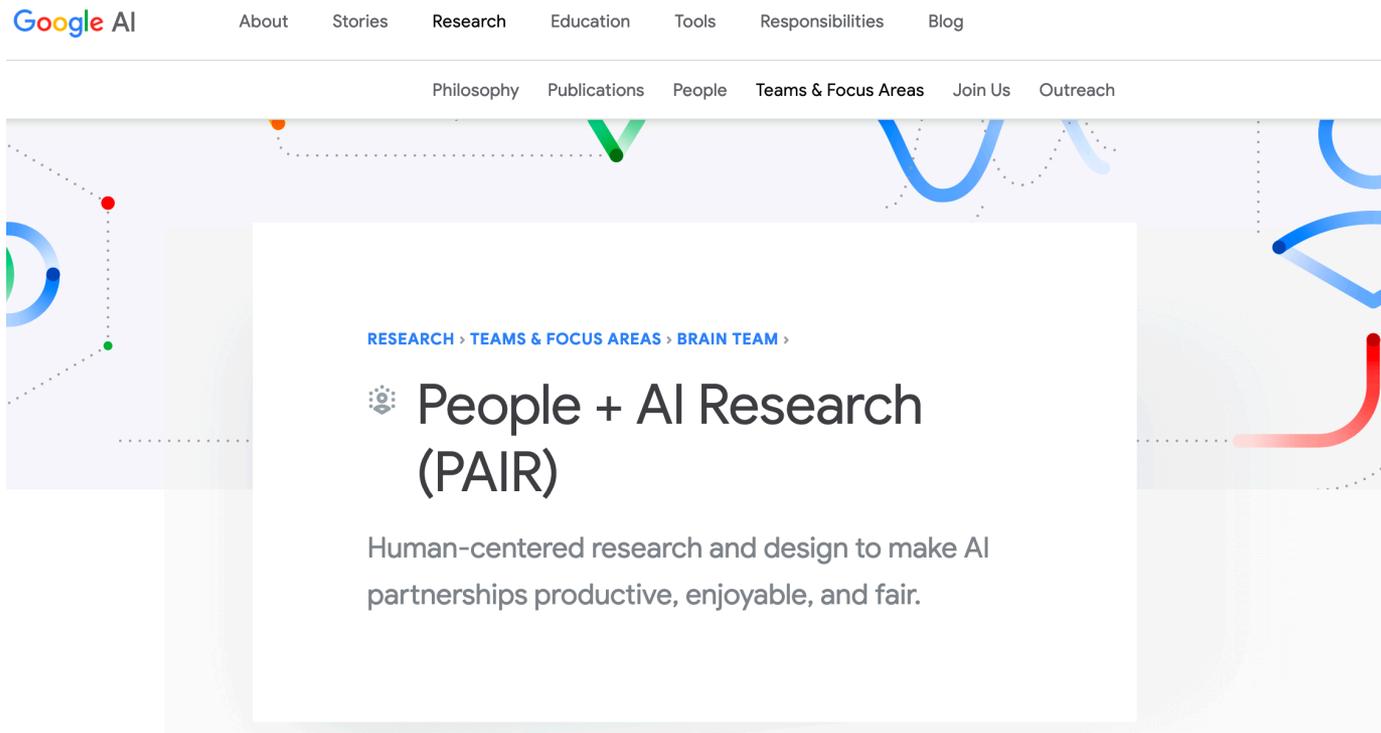
On arrête d'utiliser
des boîtes noires en
I.A. ?

Tests pour détecter
des biais de
discrimination.

Méthodes
d'interprétabilité de
règles de décision
boîtes noires.

Méthodes de
corrections des règles
biaisées.

Recherche industrielle - Interprétabilité et loyauté



Google AI

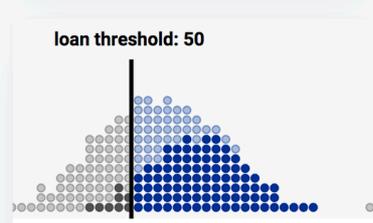
About Stories Research Education Tools Responsibilities Blog

Philosophy Publications People Teams & Focus Areas Join Us Outreach

RESEARCH > TEAMS & FOCUS AREAS > BRAIN TEAM >

People + AI Research (PAIR)

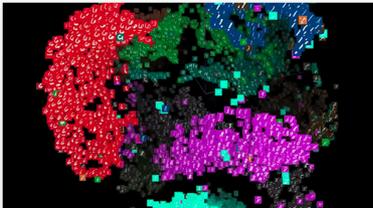
Human-centered research and design to make AI partnerships productive, enjoyable, and fair.



loan threshold: 50

Explaining fairness

Policy tradeoffs in machine learning can be complex, but visualizations and interactive explanations can help people understand these critical issues.



Model interpretability

Can machines explain the "why" behind their decisions? We're investigating ways for people to understand more about ML models, starting with visualizations that look under the hood of complex systems. See...

Recherche industrielle - Loyauté

 [microsoft](#) / [fairlearn](#)

[Watch](#) 7 [Star](#) 115 [Fork](#) 17

[Code](#) [Issues](#) 8 [Pull requests](#) 1 [Actions](#) [Projects](#) 0 [Wiki](#) [Security](#) [Insights](#)

Reductions for Fair Machine Learning

[fairness-ml](#) [fairness-ai](#) [fairness](#) [machine-learning](#) [artificial-intelligence](#) [unfairness-mitigation](#) [fairness-assessment](#) [ai](#) [responsible-ai](#)

[113](#) commits [10](#) branches [2](#) releases [9](#) contributors MIT

Branch: [master](#) [New pull request](#) [Create new file](#) [Upload files](#) [Find file](#) [Clone or download](#)

 [mesameki](#) Merge pull request [#84](#) from microsoft/riedgar-ms/census-label-tweak ... Latest commit [f8be667](#) 14 hours ago

devops	Build Refactor (#68)	5 days ago
fairlearn	Change moment api and switch to sensitive_features (#82)	16 hours ago
notebooks	Get proper labels in dashboard	14 hours ago
test/unit	Adjust test data so that we don't have warnings from sklearn (#83)	15 hours ago
.gitignore	Convert tests to PyTest (#9)	2 months ago
CHANGES.md	modified initialization and handling of constraints; added PyPI suppo...	last year
CONTRIBUTING.md	ADD CONTRIBUTING.md and adjust it to reflect GitHub flow (#81)	10 days ago

Recherche industrielle - Loyauté



Search



IBM Research Blog Topics ▾ Labs ▾ About

AI

Introducing AI Fairness 360



September 19, 2018 | Written by: [Kush R. Varshney](#)

Categorized: [AI](#)

Share this post:



Recherche académique - Interprétabilité

 marcotcr / lime

 Watch 276

 Star 7.2k

 Fork 1.2k

 Code

 Issues 30

 Pull requests 10

 Actions

 Projects 0

 Security

 Insights

Lime: Explaining the predictions of any machine learning classifier

 446 commits

 5 branches

 0 packages

 17 releases

 37 contributors

 BSD-2-Clause

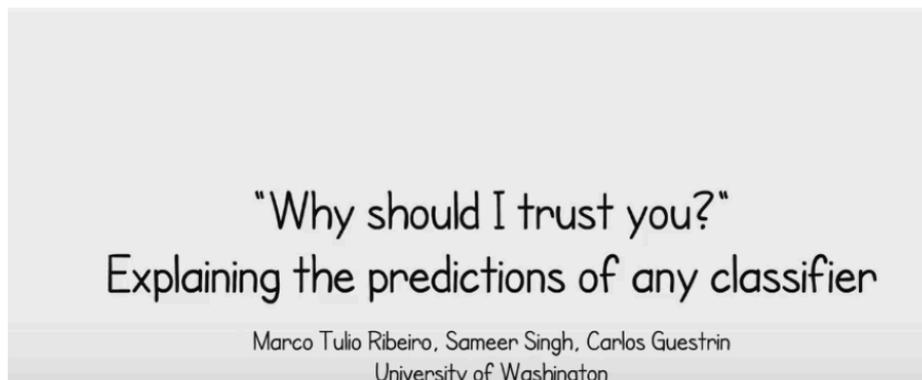
Branch: master ▾

New pull request

Find file

Clone or download ▾

This project is about explaining what machine learning classifiers (or models) are doing. At the moment, we support explaining individual predictions for text classifiers or classifiers that act on tables (numpy arrays of numerical or categorical data) or images, with a package called lime (short for local interpretable model-agnostic explanations). Lime is based on the work presented in [this paper](#) ([bibtex here for citation](#)). Here is a link to the promo video:



Recherche académique - Loyauté

 [mbilalzafar / fair-classification](#) Watch 8 Star 71 Fork 36

[Code](#) [Issues 1](#) [Pull requests 1](#) [Projects 0](#) [Wiki](#) [Security](#) [Insights](#)

Python code for training fair logistic regression classifiers.

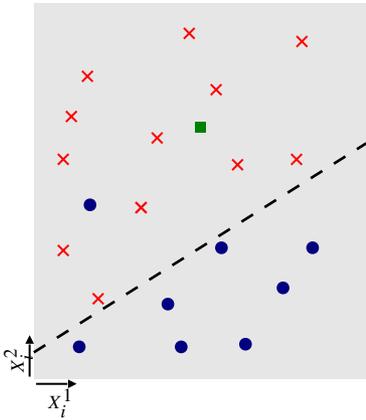
[fairness](#) [discrimination](#) [machine-learning](#)

36 commits 1 branch 0 releases 2 contributors GPL-3.0

Branch: [master](#) [New pull request](#) [Create new file](#) [Upload files](#) [Find file](#) [Clone or download](#)

 **Muhammad Bilal Zafar** and **Muhammad Bilal Zafar** pushing updated images Latest commit 45e85ba on 30 Jan 2018

disparate_impact	updating readmes	3 years ago
disparate_mistreatment	pushing updated images	2 years ago
fair_classification	improving constraints for FPR and FNR	2 years ago
preferential_fairness	Adding code for the preferential fairness paper	2 years ago
LICENSE.txt	Create LICENSE.txt	4 years ago
README.md	Updating main README	2 years ago

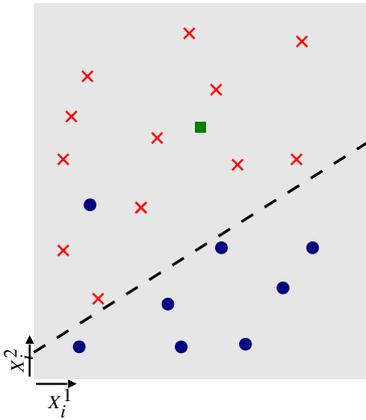


- Apprentissage effectué
- Base de test :
 - $X_i \in \mathbb{R}^p \rightarrow$ Donnée d'entrée test (ex : revenu, niveau d'épargne,...)
 - $S_i \in \{0,1\} \rightarrow$ Variable sensible (ex : age, sexe,...)
 - $\hat{Y}_i \in \{0,1\} \rightarrow$ Décision (ex : obtention d'un prêt)

Disparate impact

$$DI(X, \hat{Y}, S) = \frac{\mathbb{P}(\hat{Y} = 1 | S = 0)}{\mathbb{P}(\hat{Y} = 1 | S = 1)}$$

Test statistique dans : Besse, Del Barrio, Gordaliza, Loubes (2018) — <https://arxiv.org/pdf/1807.06362.pdf>



- Apprentissage effectué
- Base de test :
 - $X_i \in \mathbb{R}^p \rightarrow$ Donnée d'entrée test (ex : revenu, niveau d'épargne,...)
 - $S_i \in \{0,1\} \rightarrow$ Variable sensible (ex : age, sexe,...)
 - $\hat{Y}_i \in \{0,1\} \rightarrow$ Décision (ex : obtention d'un prêt)

Disparate impact

$$DI(X, \hat{Y}, S) = \frac{\mathbb{P}(\hat{Y} = 1 | S = 0)}{\mathbb{P}(\hat{Y} = 1 | S = 1)}$$

Test statistique dans : Besse, Del Barrio, Gordaliza, Loubes (2018) — <https://arxiv.org/pdf/1807.06362.pdf>

Equality of Opportunity

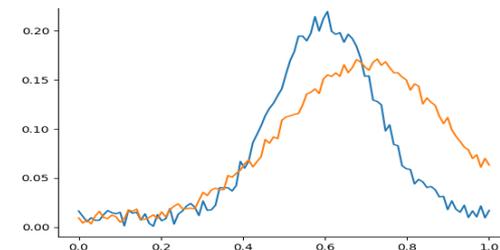
Hardt, Price, Srebro (2016) — <https://arxiv.org/pdf/1610.02413.pdf>

$$OP_0(\hat{Y}, Y, S) = \mathbb{P}(\hat{Y} = 1 | S = 0, Y = 1) \quad \text{et} \quad OP_1(\hat{Y}, Y, S) = \mathbb{P}(\hat{Y} = 1 | S = 1, Y = 1)$$

avec $Y_i \in \{0,1\} \rightarrow$ Décision sans biais de discrimination

Distance de Wasserstein entre les distributions $\{\mu_{\theta,0}, \mu_{\theta,1}\}$ de Y pour $S = \{0,1\}$

$$W_2^2(\mu_{\theta,0}, \mu_{\theta,1}) = \int_0^1 (H_0^{-1}(\tau) - H_1^{-1}(\tau))^2$$



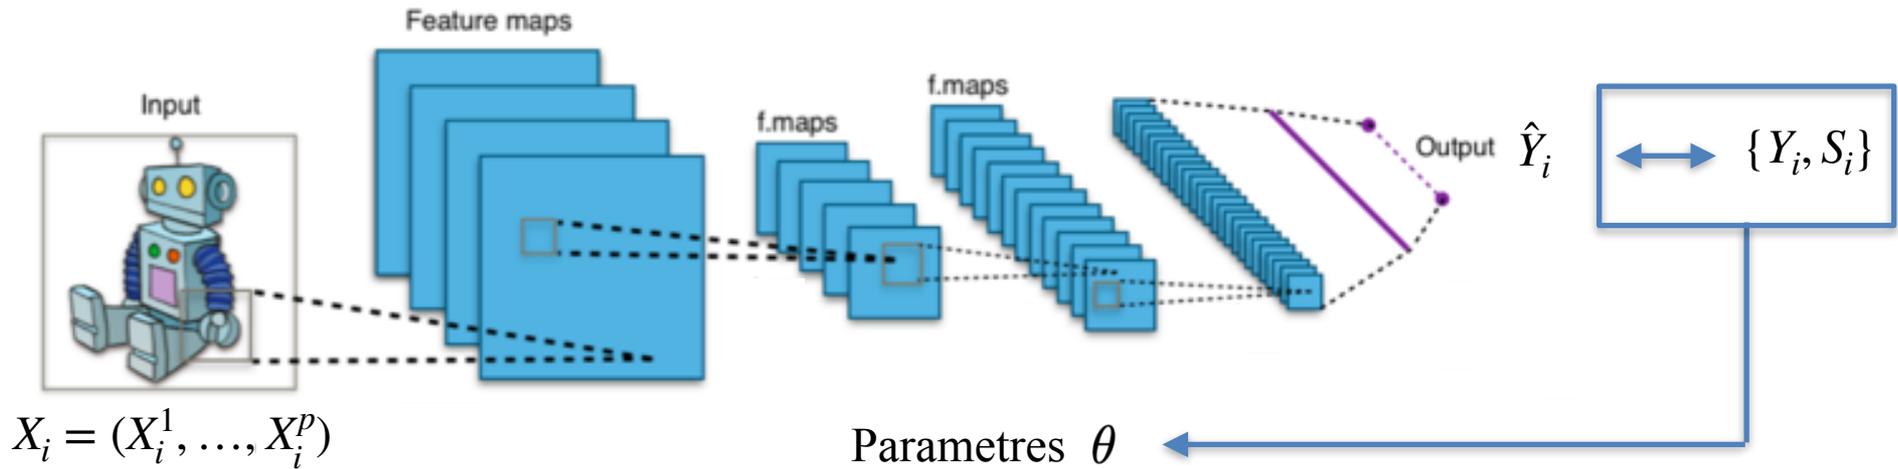
False negative rate, equality of odds ...

Méthode la plus efficace pour corriger une règle de décision injuste quel que soit $\{X_i, S_i\}$



... mais qualité de prédiction mauvaise !

Rétro-propagation de contraintes de loyauté dans un réseau de Neurones :



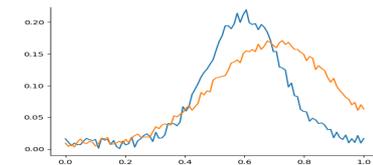
$$\hat{\theta} = \arg \min_{\theta} R(\theta) + \lambda W_2^2(\mu_{\theta,0}^n, \mu_{\theta,1}^n)$$

Qualité de
prédiction

Contrainte de
loyauté

où $W_2^2(\mu_{\theta,0}^n, \mu_{\theta,1}^n) = \int_0^1 \left(H_0^{-1}(\tau) - H_1^{-1}(\tau) \right)^2 d\tau$

Distance entre les prédictions pour
lesquelles $S=0$ et $S=1$



Algorithm 1 Batch training procedure for neural-networks with Wasserstein-2 regularization

ht

Require: Weight λ and the training observations $(X_i, S_i, Y_i)_{i=1, \dots, n}$, where $X_i \in \mathbb{R}^p$, $S_i \in \{0, 1\}$ and $y_i \in \{0, 1\}$.

Require: Neural network f_θ with initialized parameters θ .

```

1: for  $e$  in Epochs do
2:   for  $b$  in Batches do
3:     Pre-compute  $H_0$  and  $H_1$ .
4:     Draw the batch observations  $B$ .
5:     Compute the  $f_\theta(X_i)$ ,  $i \in B$ 
6:     Approximate  $\mathbb{E} \left[ \frac{\partial \text{loss}(f_\theta(X), y)}{\partial f_\theta(X)} \right]$  using Eq. (5).
7:     Approximate  $\mathbb{E} \left[ \frac{\partial W_2^2(\mu_{\theta,0}, \mu_{\theta,1})}{\partial f_\theta(X)} \right]$  using Eq. (13).
8:     Backpropagate the approximated derivative of  $R(\theta) + \lambda W_2^2(\mu_{\theta,0}^n, \mu_{\theta,1}^n)$ .
9:     Update the parameters  $\theta$ .
10:   end for
11: end for
12: return Trained neural network  $f_\theta$ .

```

Algorithme d'apprentissage

	Acc	DI
SLR	0.83	0.28
LRn	0.72	0.44
NNn	0.82	0.34
ZFA	0.79	0.68
ZFN	0.66	1.04
LRW2	0.65	0.97
NNW2	0.78	0.68

**Résultats sur données UCI Adult
(avec discrimination H/F)**

Base de test

$$\{X_i, Y_i\}_{i=1, \dots, n}$$

avec

$$X_i = \{X_i^1, \dots, X_i^p\}$$

Règles de décisions « boîtes noires »

$$X_i^1 \quad \longrightarrow$$

$$X_i^2 \quad \longrightarrow$$

$$X_i^3 \quad \longrightarrow$$

...

$$X_i^p \quad \longrightarrow$$



$$\longrightarrow \hat{Y}_i := f(X_i)$$

Question : Comment mesurer l'influence de chaque X^p sur les sorties \hat{Y}

Base de test

$$\{X_i, Y_i\}_{i=1, \dots, n}$$

avec

$$X_i = \{X_i^1, \dots, X_i^p\}$$

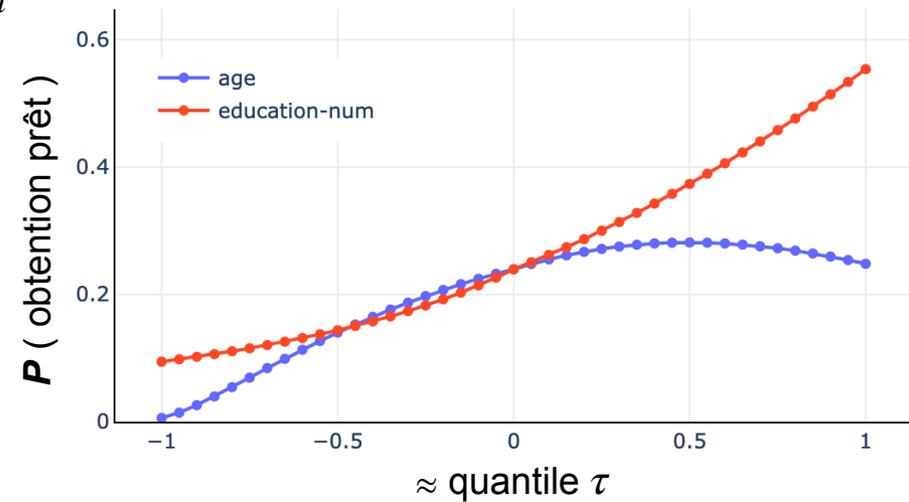
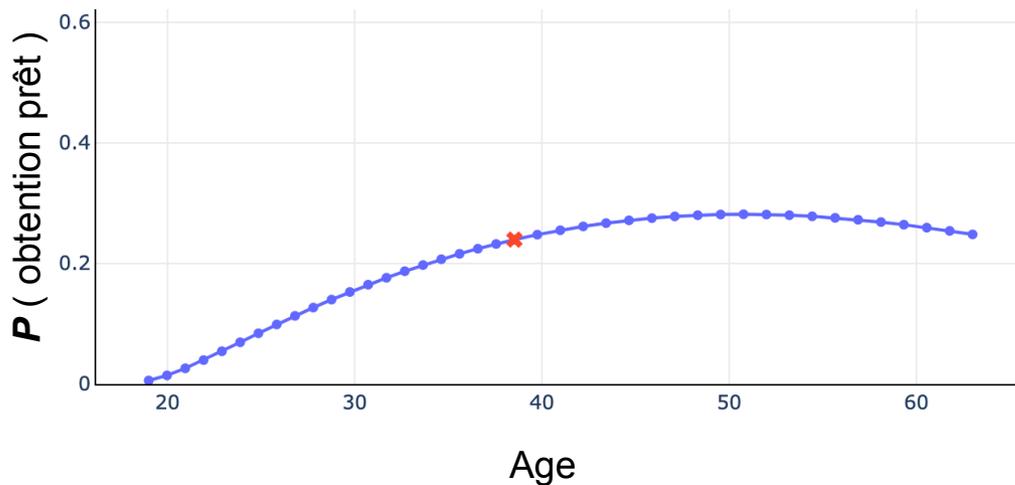
Règles de décisions « boîtes noires »

X_i^1 →
 X_i^2 →
 X_i^3 →
...
 X_i^p →



$$\hat{Y}_i := f(X_i)$$

Intuition : Modifier les propriétés moyennes de chaque X_i^p et observer les variations en sortie



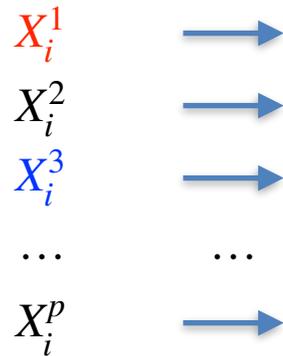
Base de test

$$\{X_i, Y_i\}_{i=1, \dots, n}$$

avec

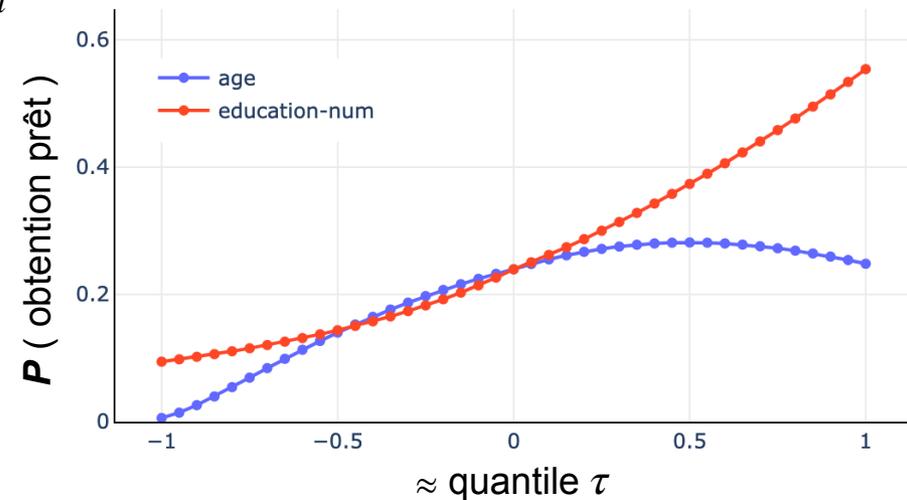
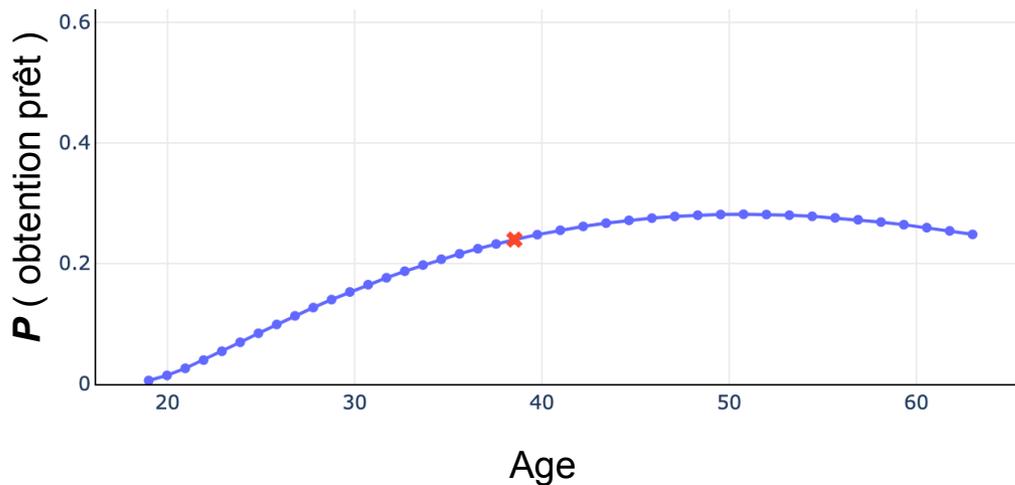
$$X_i = \{X_i^1, \dots, X_i^p\}$$

Règles de décisions « boîtes noires »



$$\hat{Y}_i := f(X_i)$$

Intuition : Modifier les propriétés moyennes de chaque X_i^p et observer les variations en sortie



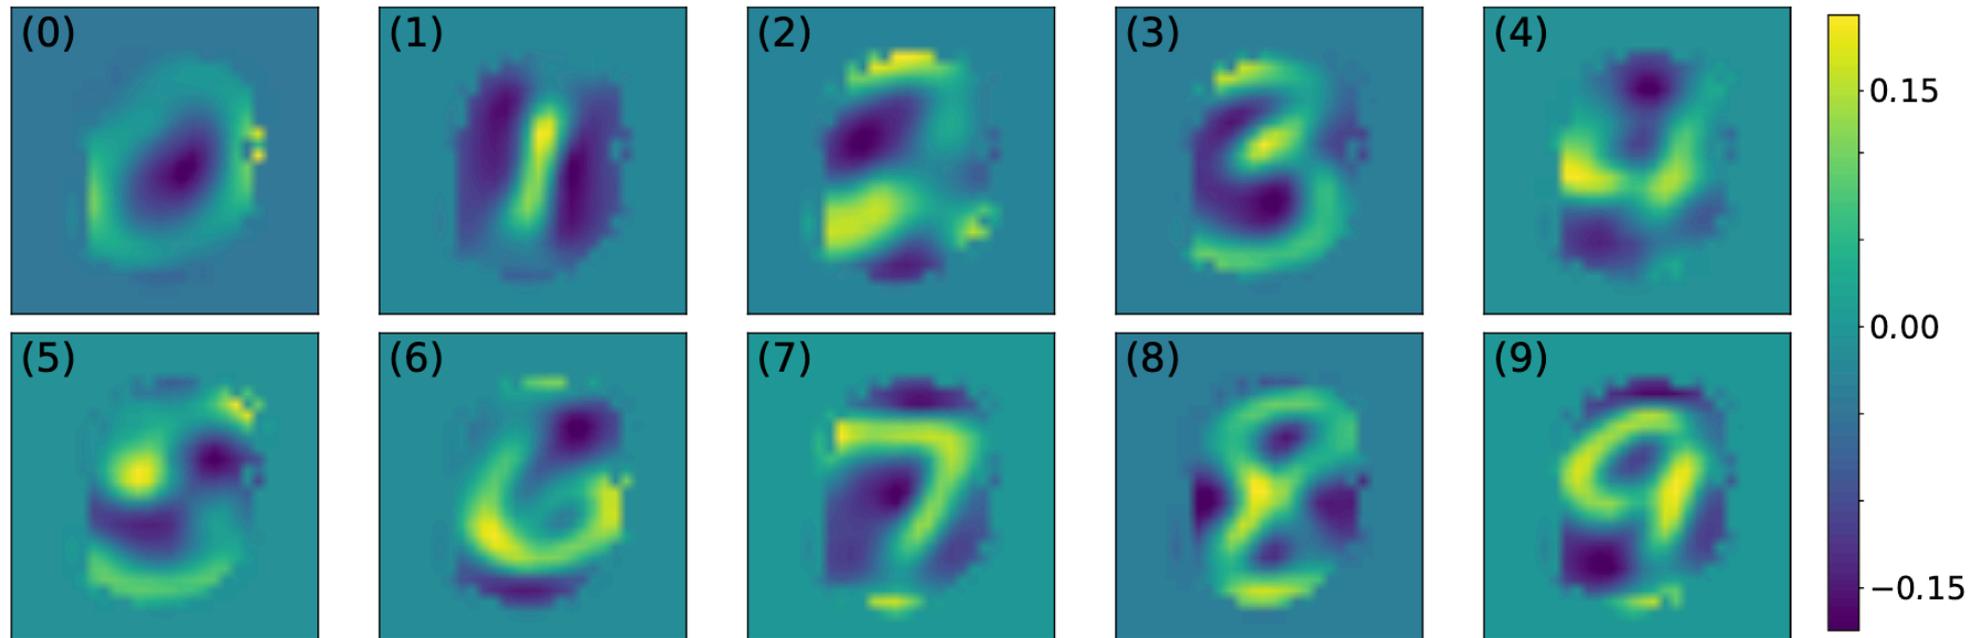
Difficultés :

- Coût algorithmique en grande dimension
- Risque de tester des observations irréalistes



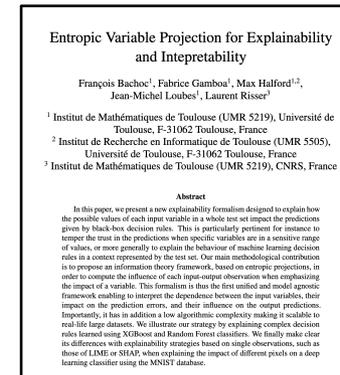
Re-pondération automatique des observations avec contrainte d'entropie

Données test : 10000 images 28x28 de la base MNIST / 10 classes



Détection des pixels les plus influents pour prédire chaque label (10 secondes de calculs en Python)

Article : <https://arxiv.org/pdf/1810.07924.pdf>



Package python : <https://maxhalford.github.io/ethik>

MaxHalford / ethik

Unwatch 5 Star 13 Fork 1

Code Issues 9 Pull requests 0 Projects 0 Wiki Security Insights

A toolbox for fair and explainable machine learning <https://maxhalford.github.io/ethik>

246 commits 5 branches 1 release 1 environment 2 contributors GPL-3.0

Branch: master New pull request Create new file Upload files Find file Clone or download

File	Commit Message	Time
docs	Merge branch 'master' into deploy_docs	11 days ago
ethik	Update CHANGELOG	yesterday
notebooks	Merge pull request #92 from MaxHalford/image_plot_size	yesterday
tests	Fix syntax errors	11 days ago



JDEV 2020
Journées Développement Logiciel

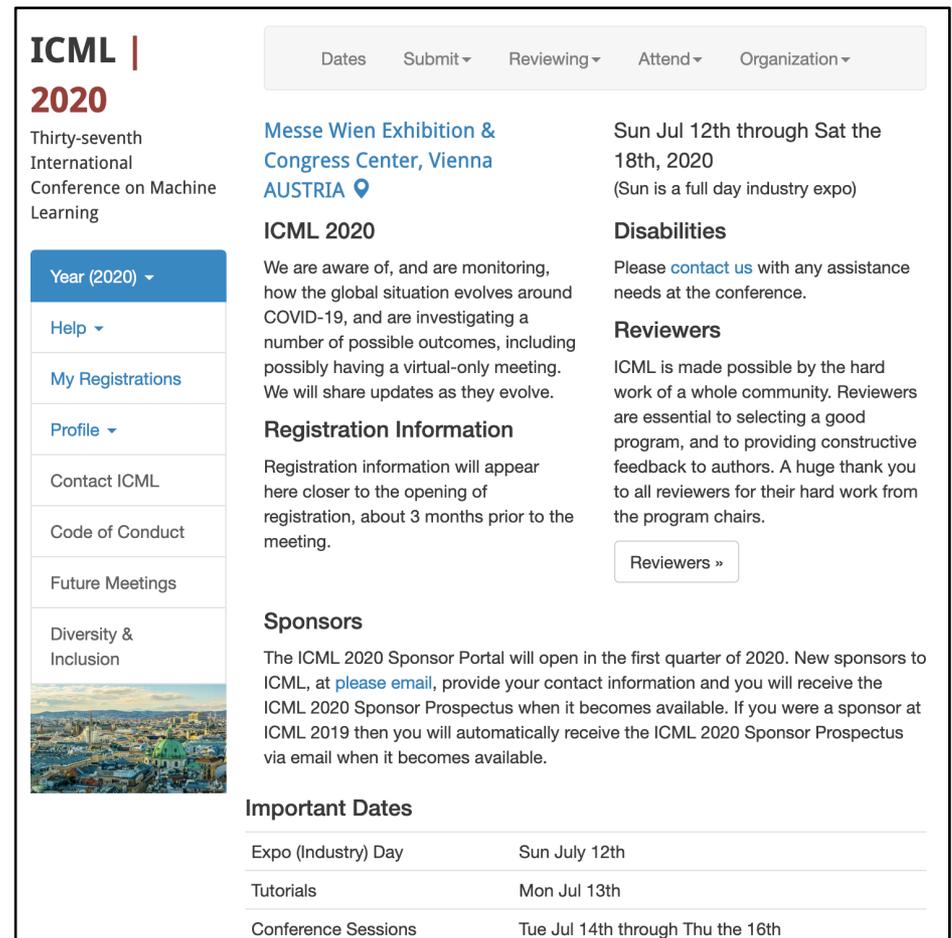
Eco-système pour la science ouverte et développement coopératif
Usine logicielle et science reproductible
Devops et ingénierie cognitive
Programmation des objets
Calcul et datascience
IA et web sémantique
Systèmes autonomes
Systèmes complexes

Webcast
7, 8, 9 et 10 juillet 2020
INSA Rennes

Information, programme, réservation et inscription :
<http://devlog.cnrs.fr/jdev2020>




**Thématique 8 des JDEV 2020 :
Programmez et déployez votre I.A.**



ICML | 2020
Thirty-seventh International Conference on Machine Learning

Messe Wien Exhibition & Congress Center, Vienna
AUSTRIA

Sun Jul 12th through Sat the 18th, 2020
(Sun is a full day industry expo)

ICML 2020
We are aware of, and are monitoring, how the global situation evolves around COVID-19, and are investigating a number of possible outcomes, including possibly having a virtual-only meeting. We will share updates as they evolve.

Registration Information
Registration information will appear here closer to the opening of registration, about 3 months prior to the meeting.

Sponsors
The ICML 2020 Sponsor Portal will open in the first quarter of 2020. New sponsors to ICML, at [please email](#), provide your contact information and you will receive the ICML 2020 Sponsor Prospectus when it becomes available. If you were a sponsor at ICML 2019 then you will automatically receive the ICML 2020 Sponsor Prospectus via email when it becomes available.

Important Dates

Expo (Industry) Day	Sun July 12th
Tutorials	Mon Jul 13th
Conference Sessions	Tue Jul 14th through Thu the 16th

ICML workshop : « Law and Machine Learning »