

UN POINT SUR L'EXPLICABILITÉ ET L'INTERPRÉTABILITÉ EN (DEEP ...) MACHINE LEARNING

M. Serrurier
IRIT, Toulouse, France

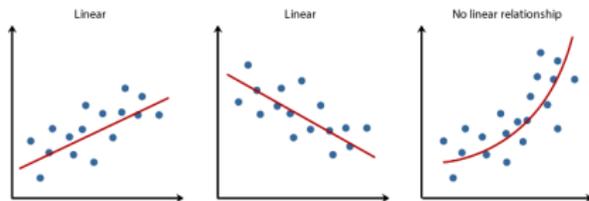
12 novembre 2018

INTRODUCTION

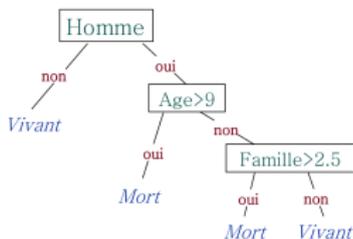
Acte de naissance : 1956, Dartmouth College

Chaque aspect de l'apprentissage, ou toute autre caractéristique de l'intelligence peut en principe être décrit si précisément qu'il est possible de construire une machine pour le simuler

- ▶ Approche logique (John McCarthy)
 - ▶ Inspirée des travaux de Turing
 - ▶ Modéliser le raisonnement par la logique
- ▶ Applications : systèmes experts, recherche opérationnelle
- ▶ Approche par schéma
 - ▶ Mc Culloch
 - ▶ Pitts
- ▶ Applications : Neurone artificiel
 - ▶ Perceptron
 - ▶ Perceptron multicouche
 - ▶ Deep learning



- ▶ **Mathématique : Modèle linéaire**
 - ▶ Pouvoir de représentation
 - ▶ Bornes de risque



- ▶ **Informatique : Arbres de décision**
 - ▶ Interprétable sous une forme logique
 - ▶ Lisible par un expert

Problème :

Sur des données complexes, les modèles d'apprentissage les plus efficaces sont aussi les moins explicables

- ▶ Cas pathologique : Deep learning
 - ▶ dépasse toutes les autres méthodes pour certains problèmes
 - ▶ Écosystème très développé et orienté vers les applications

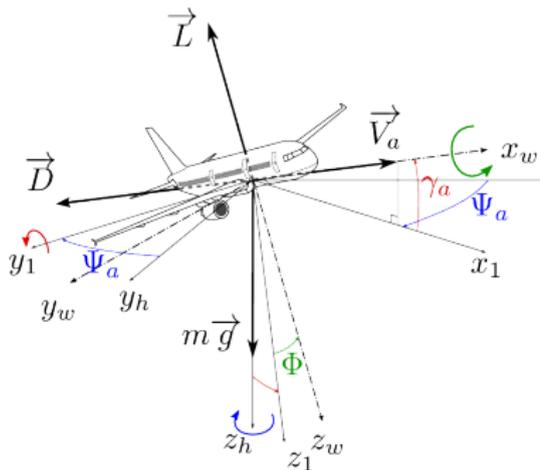


- ▶ Très peu de résultats sur l'explicabilité des réseaux profonds

- ▶ Explicabilité et interprétabilité des modèles
 - ▶ Garanties mathématiques
 - ▶ Modèles éthiques
 - ▶ Interprétation des CNN
 - ▶ Apprentissage de représentation
- ▶ Explicabilité et interprétabilité des prédictions
 - ▶ Cartes d'activation
 - ▶ Approximation locale de modèle
 - ▶ Deep learning et logique
- ▶ Aspects Neurosciences, philosophiques et juridiques

EXPLICABILITÉ ET INTERPRÉTABILITÉ DES MODÈLES

- ▶ Problème pour les applications critiques ex :
 - ▶ Prédiction de trajectoire d'avion
 - ▶ Détection d'intrusions dans un système
 - ▶ Véhicules autonomes



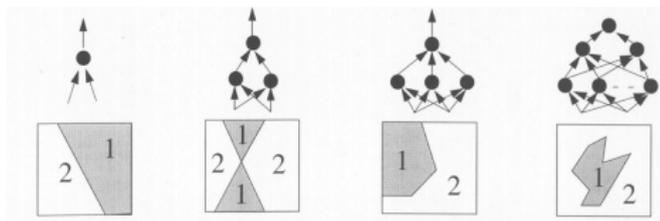
Problème :

Besoin de garantie sur les marges de sécurité des modèles

EXPLICABILITÉ DES MODÈLES

// QUELS TYPES DE GARANTIES?

► Pouvoir de représentation



► optimisation

- convergence/optimalité
 - vitesse de convergence
- ## ► Statistiques bornes sur les erreurs

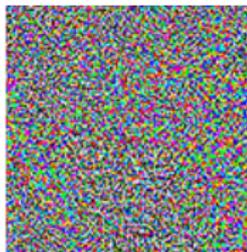
- ▶ Analyse de sensibilité
- ▶ Robustesse aux attaques



"panda"

57.7% confidence

+ ϵ



=



"gibbon"

99.3% confidence

- ▶ Image inverse

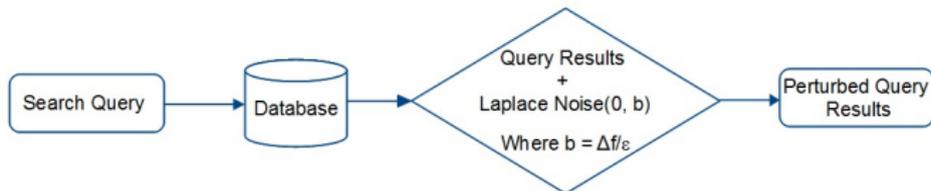
- ▶ Biais dans les bases
 - ▶ Prédiction criminalité
 - ▶ Sélection de CV

Intimité différentielle

Problème lié aux informations que l'on veut cacher, mais qui peuvent être trouvés à l'aide d'algorithmes d'apprentissage

- ▶ Machine learning et vie privée
 - ▶ Vie privée des utilisateurs
 - ▶ Secret industriel

- ▶ Fair learning : Prédire Y grâce à X mais sans être biaisé par une variable A . Possibilités :
 - ▶ Modifier X
 - ▶ Contraindre l'apprentissage
- ▶ Intimité différentielle
 - ▶ anonymisation
 - ▶ Partage de données et d'algorithme sans divulguer des données sensibles



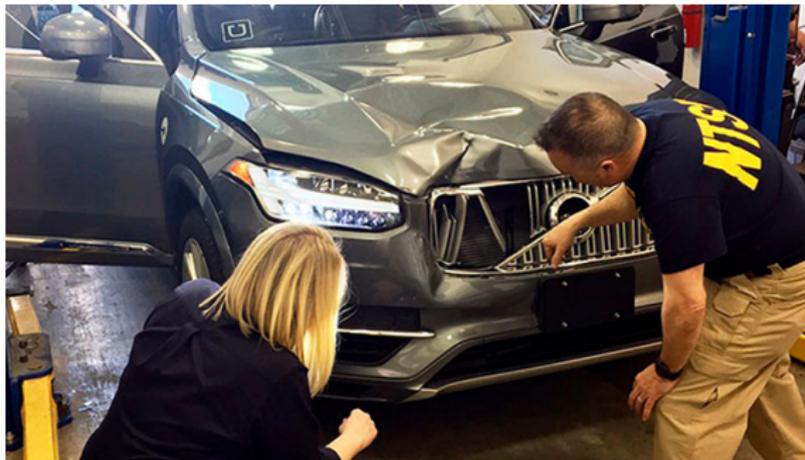
EXPLICABILITÉ ET INTERPRÉTABILITÉ DES PRÉDICTIONS

EXPLIQUER UNE PRÉDICTION

// ACCIDENT VOITURE AUTONOME

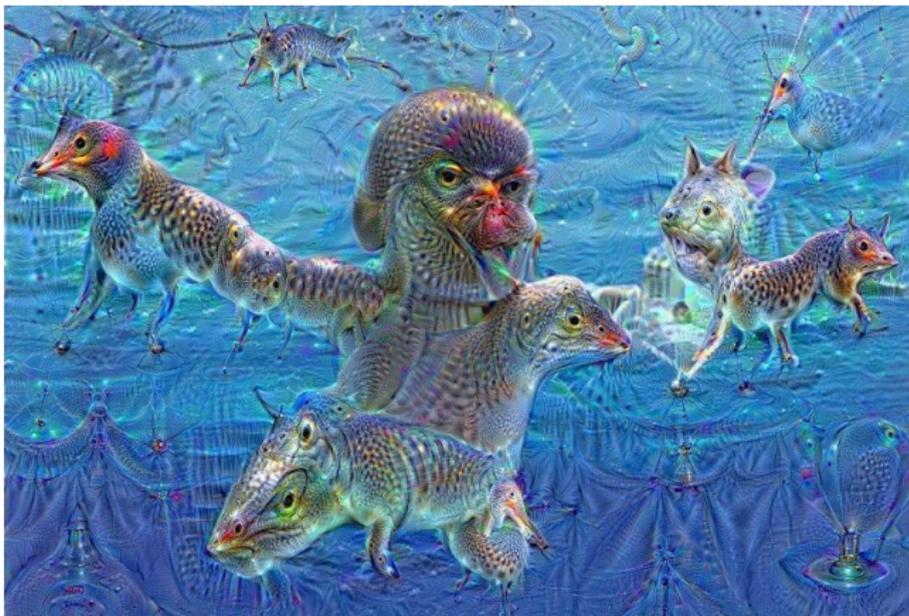
Question :

Comment expliquer l'erreur d'une voiture autonome



EXPLICABILITÉ DES PRÉDICTIONS

// COMMENT VOIT UN RÉSEAU DE NEURONES



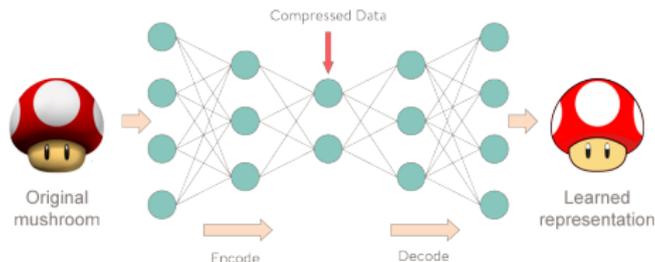
- ▶ déterminer quels sont les pixels d'une image qui impactent le plus la classification :
 - ▶ analyse locale de sensibilité
 - ▶ carte d'activation basée sur le gradient



Principe :

Apprendre une représentation de faible dimension des données

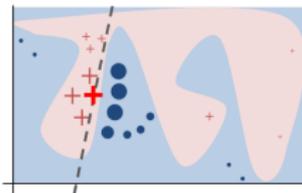
- ▶ Auto-encoder
- ▶ Variational Auto-encoder
- ▶ Apprentissage adverse
 - ▶ Generative Adversarial Networks (GAN)
 - ▶ Bi-GAN
 - ▶ Info-GAN



Principe :

Approximer localement un réseau avec un modèle linéaire

- ▶ LIME - Local Interpretable Model-Agnostic Explanations
 - ▶ Perturbation autour de l'exemple à prédire
 - ▶ Calcul d'un séparateur linéaire pour ces exemples perturbés
 - ▶ Interprétation à partir du modèle linéaire
- ▶ Approche agnostique : ne dépends pas du modèle que l'on veut approximer



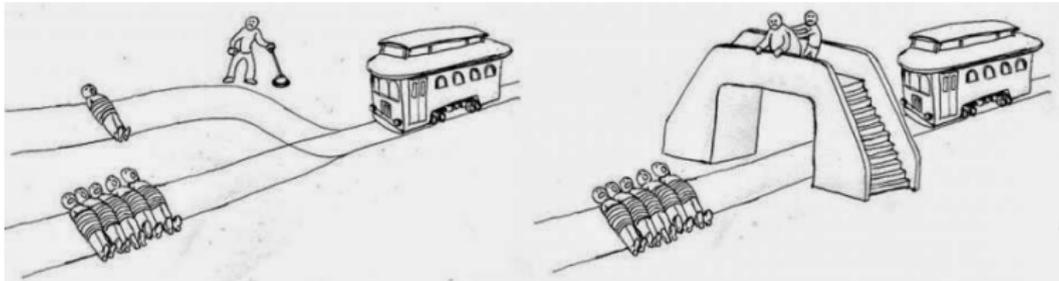
Principe :

Utiliser un réseau de neurones pour apprendre des règles en logique du premier ordre

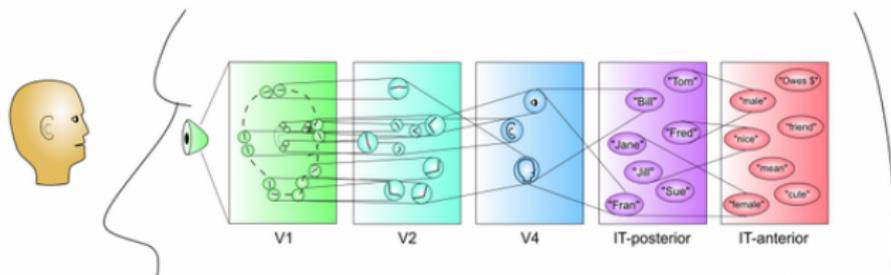
- ▶ TensorLog
 - ▶ Codage des données logique sous forme matricielle
 - ▶ Inférence par calcul de gradient
- ▶ Permet de considérer de l'information a priori
- ▶ Ne marche que sur des problèmes simples

NEUROSCIENCE, PHILOSOPHIE ET JURIDIQUE

- ▶ Comment définir l'interprétabilité
- ▶ Qu'est qu'un algorithme éthique
- ▶ Acceptabilité des décisions algorithmiques



- ▶ Les réseaux de neurones ont-ils une interprétation biologique
- ▶ Les réseaux de neurones peuvent-ils aider à la compréhension du cerveau



- ▶ Droits des algorithmes
 - ▶ Libéralisation des données publiques
 - ▶ Droit à l'explicabilité
- ▶ problèmes :
 - ▶ Comment définir l'explicabilité en droit
 - ▶ comment définir les responsabilités pour des décisions prises par des algorithmes

Exemple :

Facebook et le divorce



CONCLUSIONS

- ▶ Apprentissage artificiel capable de répondre à des problèmes difficiles
- ▶ L'aspect boîtes noires des algorithmes d'apprentissage limite leur applicabilité à des applications critiques
- ▶ Besoin important
 - ▶ De garantie formelle
 - ▶ De faire le lien avec les outils formels d'intelligence artificielle
- ▶ Déborde sur d'autres domaines
 - ▶ philosophie
 - ▶ droit
 - ▶ neurosciences