

**100% ACTUAIRES &
100% DATA SCIENCE**

INSTITUT DES
ACTUAIRES



29 / NOV / 2019

Hôtel Marriott Rive Gauche
Paris 14ème

Intervenants

- Marc Juillard
- Yolán Honoré –Rougé
- André Grondin
- Antoine Ly
- Frédéric Planchet

GT Transparence des algorithmes de machine learning

Constat

- ❑ Des actuaires de plus en plus confrontés aux algorithmes de *machine learning* (directement ou indirectement)
- ❑ Des modèles de plus en plus complexe que ce soit au niveau de l'algorithme (deep learning) ou au niveau de la donnée utilisée en entrée du modèle (image, texte, log applicatives, ...)
- ❑ Une réglementation qui encadre de plus en plus l'utilisation des données des modèles.

Partant de ces différents éléments, la Commission Innovation à lancer il y a un an un Groupe de Travail visant à faire un état des lieux des enjeux associés à la transparence des algorithmes de *machine learning* ainsi que les différentes techniques envisageables.

Il à noter que ce groupe de travail présente de fortes interactions avec les GT Etique des Algorithmes et Big Data.

- 1. Contexte et cadre théorique**
2. Application sur des données structurées
3. Application sur du texte
4. Application dans un cadre actuariel

Si certains modèles *machine learning* fournissent d'excellent résultats, ils commettent malgré tout des erreurs

Une bonne métrique de performance sur une base de test ne garantit pas un bon fonctionnement du modèle. En présence d'un jeu de données biaisé, le modèle de *machine learning* va reproduire puis propager ce biais.

Ce biais est difficile à détecter car :

- Il peut être de sources variées (biais d'endogénéité, biais de sélection, biais de variable omise, biais de données, biais cognitif,...)
- Le modèle s'appuie sur des règles « conceptuellement » différentes des humains pour prendre des décisions, les causes de biais peuvent être très différentes chez un humain et chez la machine.

Il faut donc comprendre le modèle pour s'assurer qu'il ne présente pas de biais.

Moteur de recrutement
AMAZON

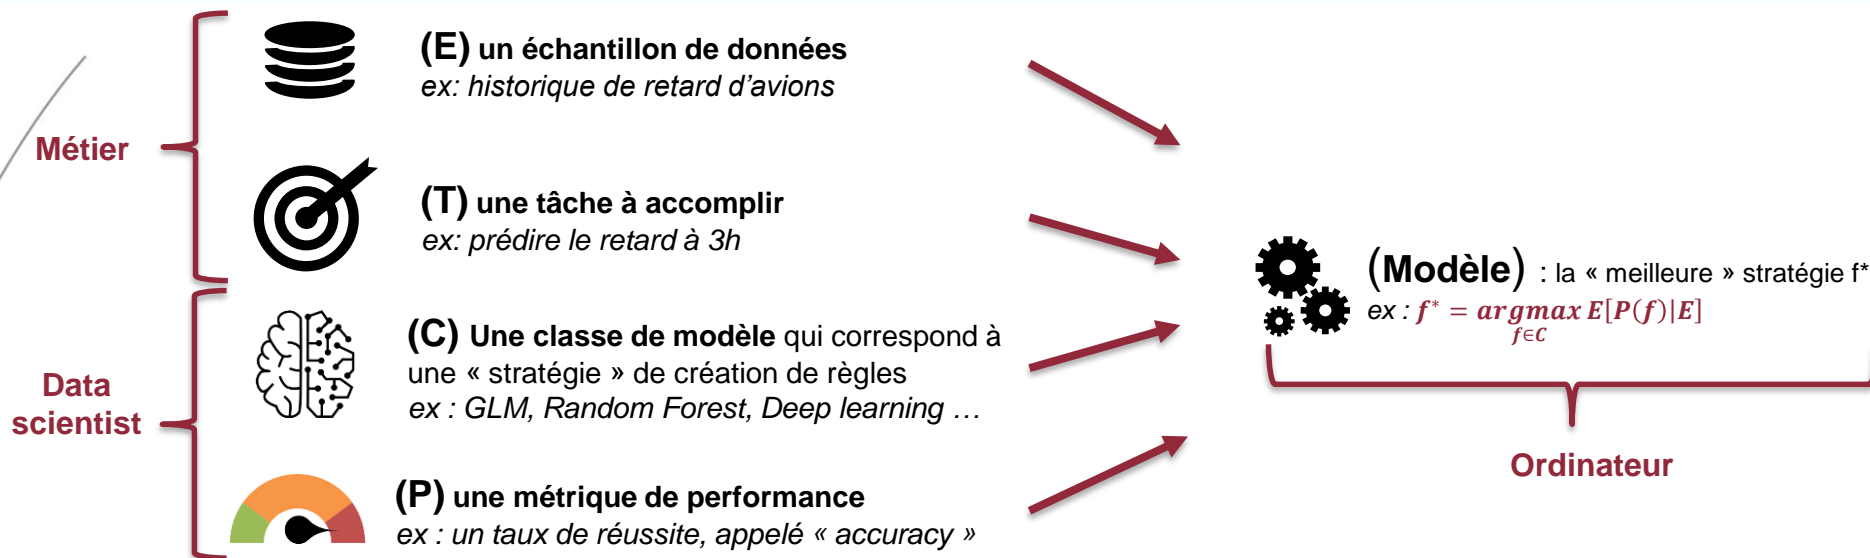
Model de prédiction récidive
COMPAS

Uber self-driving car kills
a pedestrian

Google photo confonds
skieurs et montagnes

Application de Watson
pour la recommandation
de traitement du cancer

RAPPEL : ENTRAINEMENT D'UN MODÈLE DE MACHINE LEARNING



A retenir :

- l'algorithme de *machine learning* crée lui-même les règles qui permettent d'accomplir la tâche, **mais il ne fournit pas cette information de façon compréhensible par un humain en sortie de modèle**
- Il raisonne dans un monde où la machine parle à la machine. **La notion d'interprétabilité humaine n'est pas donc pas nativement prise en compte.**



L'utilisation standard d'un modèle de *machine learning* se fait de la façon suivante :



Les algorithmes de transparence cherchent à rajouter une **surcouche** au modèle entraîné afin d'analyser les prédictions et **fournir un « rapport » compréhensible par un humain** des causes de la prédiction

Deux propriétés principales sont souhaitables pour un modèle de transparence :

FIDÉLITÉ AU
MODÈLE INITIAL



SIMPLICITÉ DES
EXPLICATIONS

Ces deux propriétés sont souvent antinomiques : plus les explications sont simples, moins elles sont capables de représenter exactement les décisions réellement prises par le modèle. Il faut **choisir un compromis qui dépend** de ce que l'on veut faire.

La notion de transparence est relative :

- **A l'objectif** : Veut-on avoir une vue d'ensemble des décisions du modèle ou le détail pour un individu spécifique?
- **A l'interlocuteur** : Quelle est le niveau de connaissance de l'individu qui lit les explications? La notion de « simplicité » est très dépendante de cette information.

Des contraintes opérationnelles s'y ajoutent :

- **Rapidité d'exécution** : Si le temps d'exécution de l'explication est trop long, cela peut diminuer l'intérêt d'utiliser du modèle
- **Qualité des données** : le modèle de transparence dépend des données utilisées : valider leur qualité est essentiel

Les algorithmes de transparence peuvent se classer selon deux axes d'analyse principaux :

LOCAL

GLOBAL

Expliquer les causes d'une prédiction donnée

Expliquer les principales règles de décision du modèle

AGNOSTIQUE

Indépendant de la classe de modèle à expliquer

- LIME
- SHAP

- PDP
- ICE
- SHAP margins

+ permet d'expliquer un modèle sans y accéder
+ Toujours applicable

- Souvent lent
- Moins précis

SPÉCIFIQUE

Exploite la structure mathématique du modèle

- SHAP Tree
- Deelift

- Tree Interpreter
- SHAP margins

+ souvent rapide
+ parfois plus fidèle (garanties théoriques)

- Pas toujours applicable
- Nécessite d'accéder au modèle

- Régulateur
- Utilisateur final (agence...)
- Data scientist

- Management
- Métier
- Data scientist



2001



- On fixe une variable S.
- Les autres variables utilisées dans le modèle sont appelées C
- A S fixé, on calcule la valeur moyenne du prédicteur en faisant varier C sur les données.




- Intuitif
- facile à comprendre




- Suppose l'indépendance des variables
- Cache les effets croisés

$$\hat{f}_{x_S}(x_S) = \frac{1}{n} \sum_{i=1}^n \hat{f}(x_S, x_C^{(i)})$$



Crédit : <https://christophm.github.io>



- On trace les PDP pour toutes les valeurs de S.




- Plus intuitif
- Permet de découvrir des relations hétérogènes

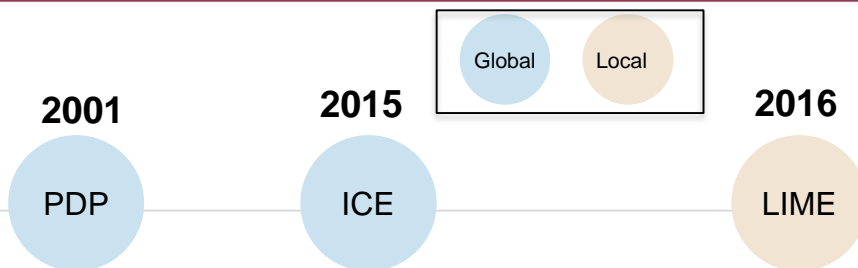


- Peu lisible
- Effet moyen difficile à capter

for each instance in $\{(x_S^{(i)}, x_C^{(i)})\}_{i=1}^N$ the curve $\hat{f}_S^{(i)}$ is plotted against $x_S^{(i)}$, while $x_C^{(i)}$ remains fixed.



Crédit : <https://christophm.github.io>



- Fixer un point à expliquer P
- Tirer des points aléatoirement (5000)
- Pondérer chaque point en fonction de sa distance à P
- Entraîner un modèle interprétable (arbre, régression L1) qui cherche à prédire la prédiction \hat{f}



$$\text{explanation}(x) = \arg \min_{g \in G} L(f, g, \pi_x) + \Omega(g)$$



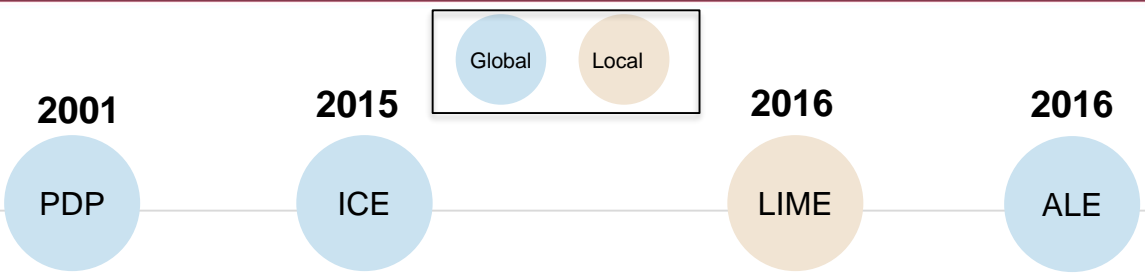
- Facile à interpréter
- Marche sur tout type de données (tabulaire, texte, image)




- Instable
- Très sensible au sur-modèle et à son calibrage




Crédit : <https://christophm.github.io>






- On moyennise les variations de prédictions suite à une variation de C
- On pondère ces variations en fonction de la densité des observations

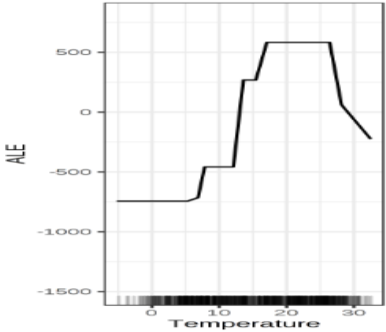


- Non biaisé
- Interprétation simple
- Mesure de l'interaction entre variables possibles

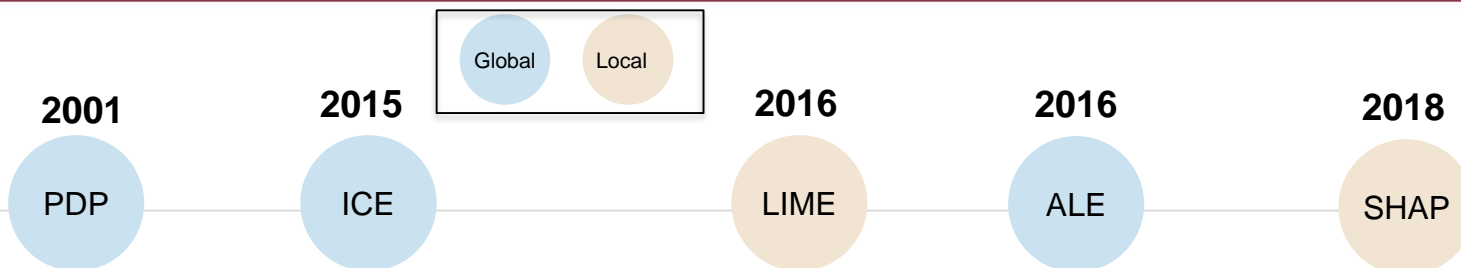


- Hétérogénéité invisible (contrairement à ICE)
- Difficile à implémenter, proxys informatiques

- $$\hat{f}_{j,ALE}(x) = \sum_{k=1}^{k_j(x)} \frac{1}{n_j(k)} \sum_{i: x_j^{(i)} \in N_j(k)} [f(z_{k,j}, x_j^{(i)}) - f(z_{k-1,j}, x_j^{(i)})]$$
- $$\hat{f}_{j,ALE}(x) = \hat{f}_{j,ALE}(x) - \frac{1}{n} \sum_{i=1}^n \hat{f}_{j,ALE}(x_j^{(i)})$$



Crédit : <https://christophm.github.io>



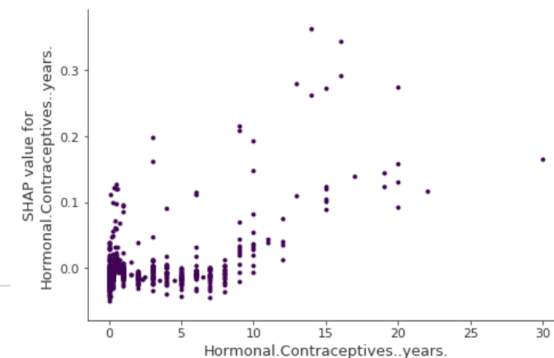

- On veut une fonction explicative qui vérifie des propriétés mathématiques : fidélité, monotonie, absence
- Il existe une seule solution additive qui vérifie ces propriétés
- Il s'agit dans l'idéal d'évaluer l'effet tous les combinaisons possibles d'occurrences des variables



- Garantie théorique
- Rapide pour les arbres
- Local et global




- Complexité informatique importante donc lent
- Kernel SHAP ignore les corrélations

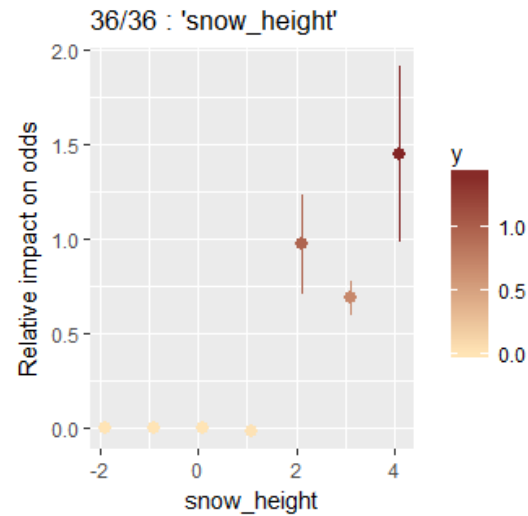


Crédit : <https://christophm.github.io>


Importance des variables



Marginales



Décomposition additive



Gestion du compromis simplicité versus fidélité

Exemple : mise en place d'un modèle visant à prédire le retard d'un avion au décollage.

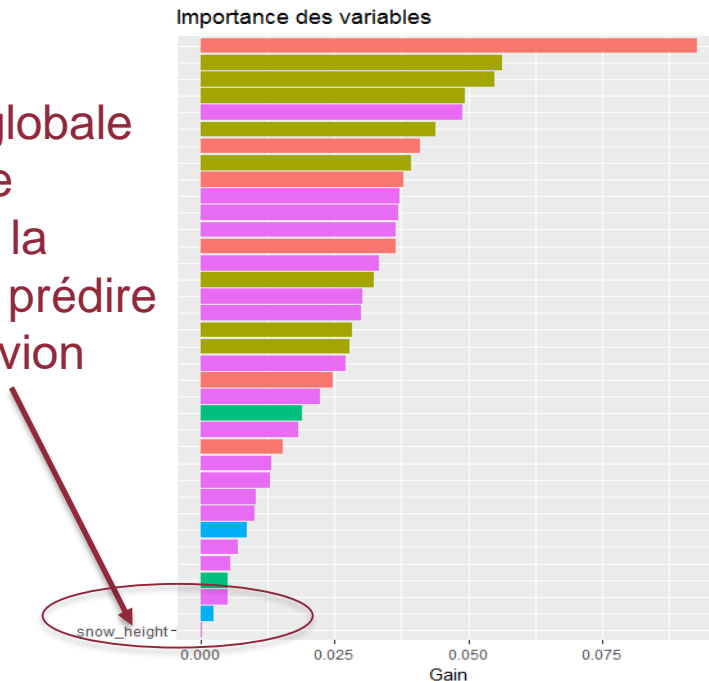
FIDÉLITÉ AU
MODÈLE INITIAL



SIMPLICITÉ DES
EXPLICATIONS



Exemple :
importance globale
de la variable
« hauteur de la
neige » pour prédire
un retard d'avion



Gestion du compromis simplicité versus fidélité


Exemple : mise en place d'un modèle visant à prédire le retard d'un avion au décollage.

FIDÉLITÉ AU
MODÈLE INITIAL

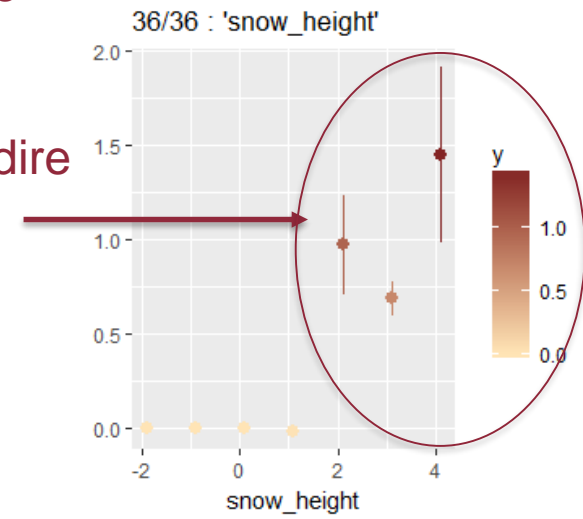


SIMPLICITÉ DES
EXPLICATIONS

Exemple :
importance globale
de la variable
« hauteur de la
neige » pour prédire
un retard d'avion



Exemple :
importance locale
de la variable
« hauteur de la
neige » pour prédire
un retard d'avion



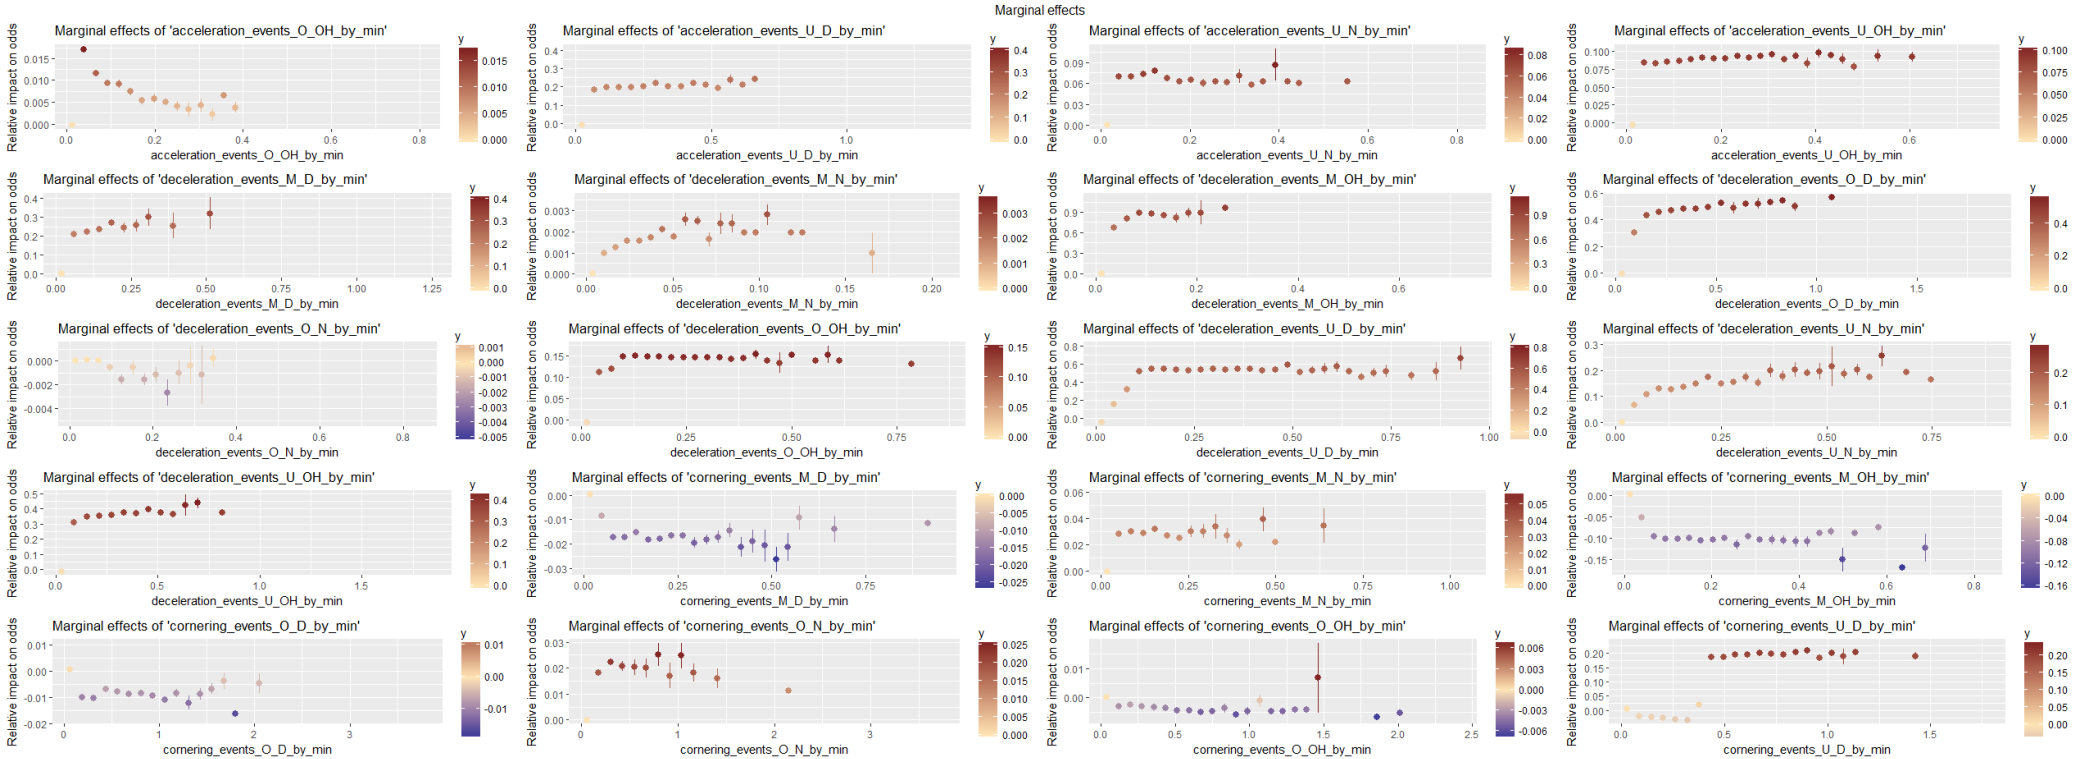
Gestion du compromis simplicité versus fidélité

Exemple : mise en place d'un modèle visant à prédire le retard d'un avion au décollage.

**FIDÉLITÉ AU
MODÈLE INITIAL**



**SIMPLICITÉ DES
EXPLICATIONS**



Exemple : Objectif classer des images d'avions et de moto (2000 photos Caltech 101 dataset).



0419.png



0498.png



0507.png



0535.png



0554.png



0571.png



0759.png



0768.png



0779.png



0780.png



0787.png



0794.png



0795.png



0802.png



0812.png



0827.png



0841.png



0856.png



0908.png



0975.png



1033.png



1060.png



1061.png



1070.png

Gestion du compromis simplicité versus fidélité

Exemple : reconnaissance image

FIDÉLITÉ AU
MODÈLE INITIAL




SIMPLICITÉ DES
EXPLICATIONS

Entraînement d'un premier CNN avec 29 millions de neurones. Performance sur base de test : 94%

Moto à 95%



Pixel d'importance
pour avion



Pixel d'importance
pour moto



Avion à 95%



1. Contexte et cadre théorique
- 2. Application sur des données structurées**
3. Application sur du texte
4. Application dans un cadre actuariel



Le use case


Comprendre et maîtriser le taux d'incidence en incapacité
Revue potentielle de la segmentation

Données à disposition



Maîtrise actuarielle

pandas
 $y_i = \beta' x_{it} + \mu_i + \epsilon_{it}$



shap
lime
pdpbox



Meilleure maîtrise du risque

Data engineering
Hyperparamétrage
Cross validation



GLM

RANDOM FOREST

GBM

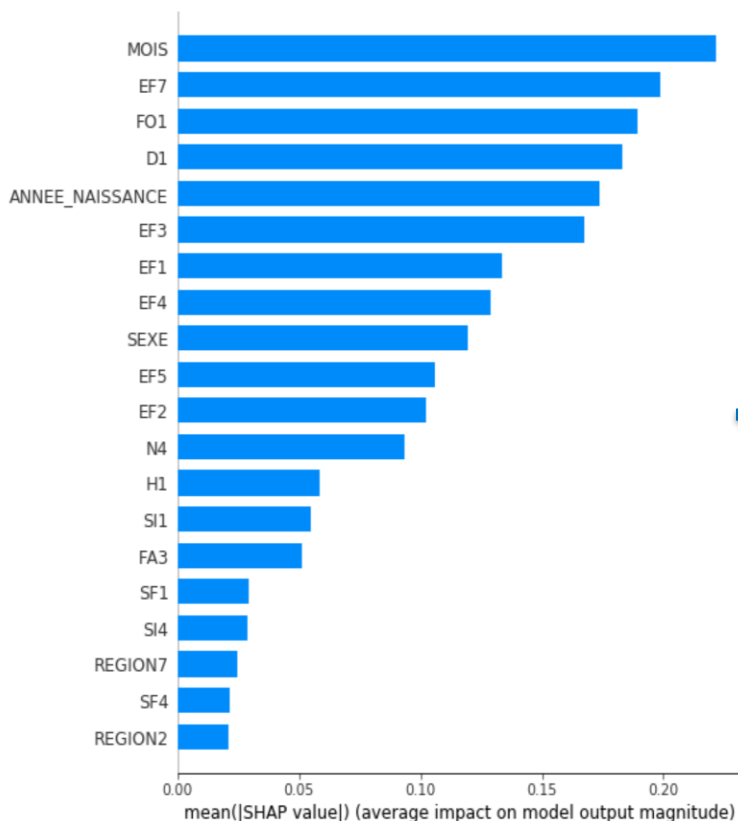


CLASSE	PART	TAUX_INCIDENCE	AUC	RECALL
PORTEFEUILLE	100%	3,9%	0,81	0,77




CLASSE	PART	TAUX_INCIDENCE	AUC	RECALL	
CONVENTION_1_JEUNES	20%	4,6%	72%	92%	
CONVENTION_1_ADULTES	21%	4,5%	78%	79%	
CONVENTION_1_SENIORS	15%	3,3%	85%	65%	
CONVENTION_2_JEUNES	10%	3,9%	80%	87%	
CONVENTION_2_ADULTES	25%	3,2%	86%	70%	
CONVENTION_2_SENIORS	9%	3,4%	87%	64%	

Importance des variables



Contribution de chaque variable




- Mettre en avant pour chaque classe les variables et leurs effets sur la prédiction par une approche locale via shap

Individu type de la classe 2

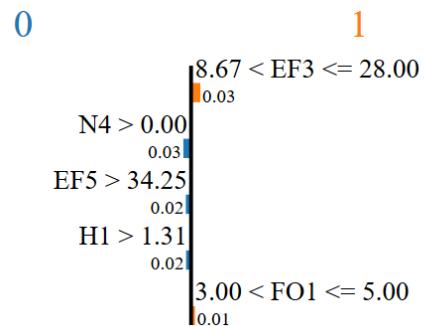



Individu type de la classe 4



- Utilisation du package lime



Prediction probabilities



Feature Value

Feature	Value
EF3	10.00
N4	1.00
EF5	59.33
H1	2.50
FO1	5.00

Prediction probabilities



Feature Value

Feature	Value
FO1	10.00
N4	1.00
EF3	0.00
FA3	1.00
SEXE	1.00

- Par segment du portefeuille, il s'agit de confronter les prédictions de début de période aux valeurs réalisées en fin de période
- Le backtesting doit permettre de remettre en cause et/ou de renforcer la performance d'un modèle, de maîtriser les risques inhérents à ce dernier et d'identifier les actions à mettre en place

Classe	Taux historique	Erreur moyenne du modèle	Prédiction Nouvelle période	Réel Nouvelle période	Erreur sur la nouvelle période	Commentaire
Classe 1	4,6%	7%	4,%	4%	7%	Changement de tendance
Classe 2	4,5%	10%	4,1%	2%	10%	Prédiction stable
Classe 3	3,3%	5%	3,4%	11%	40%	KO

Qualité de la variable Xi à un instant t de production	Contribution de la variable explicative Xi pour un modèle donné		
	FAIBLE	MOYENNE	FORTE
Variable non renseignée	Alerte	Alerte	Alerte
Valeur atypique	Proxy	Alerte/Proxy	Alerte
Valeur connue	Good	Good	Good

1. Contexte et cadre théorique
2. Application sur des données structurées
- 3. Application sur du texte**
4. Application dans un cadre actuariel

Une présence de plus en plus importante dans l'assurance

• Cas d'usage :

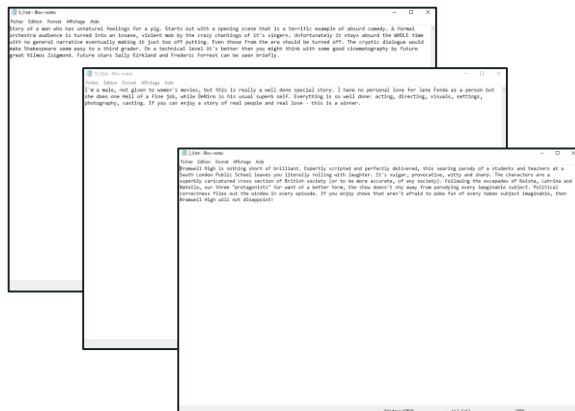
- Analyse automatique de mails
- Extraction d'information pertinente dans des documents volumineux (CG, régulation, prescriptions, etc.)
- Labellisation automatique des claims
- Analyse des rapports d'expertise de sinistre
- Net Promoter Score (NPS)
- Analyse de sentiments pour l'aide à la stratégie d'investissement
- Etc.



Données non structurées



Décision quantifiable



Modèle



- une catégorie
- un score de sentiment,
- etc.

Quelques rappels sur les méthodes

- **Le traitement du texte :**

- Afin d'être exploitable, l'information textuelle doit être transformée en un vecteur numérique
- Le traitement peut comporter plusieurs étapes (lemmatisation, correction orthographique, suppression de certains mots ou caractères, etc.)
- La transformation dépend du type de représentation (fréquentielle, contextuelle, etc.)



La préparation de la donnée

"Bromwell High is nothing short of brilliant. Expertly scripted and perfectly delivered, this searing parody of a students and teachers at a South London Public School leaves you literally rolling with laughter..."



[Bromwell, High, nothing, short, brilliant, expertly, scripted, perfectly, delivered, this, searing, parody, students, teachers, South, London, Public, School, leaves, you, literally, rolling, with, laughter]



Exemple de représentation: Bag of Words

On crée D variables (une pour chaque mot du dictionnaire).

Chaque document est alors représenté par le simple comptage des mots présents


hello good you morning left mining with thus brilliant
 $X = [0, 0, 1, 0, \dots, 0, 0, 1, 0, 1]$

Vecteur de taille D

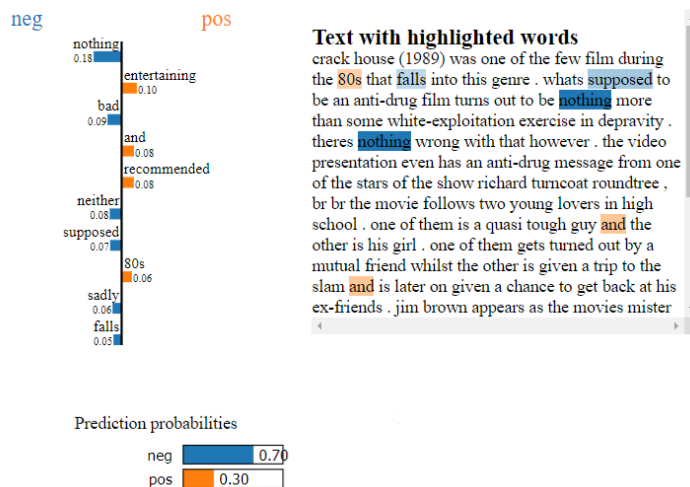
De manière générale

- **Les analyses qu'il est toujours possible d'appliquer :**
 - **Globale** : Etude des sensibilités de chaque mot sur la sortie (par exemple on crée autant de documents que de mots existant dans le dictionnaire et on analyse la sortie du modèle)
 - **Locale** : les méthodes introduites comme LIME ou SHAP peuvent aider à l'interprétation dans le cas où un modèle plus complexe est utilisé (deeplearning, Xgboost) avec certaines limites...
- **Exemple avec la base Imdb :**


Analyse des sensibilités



Application de LIME



Application de SHAP




L'interprétabilité se transcrit également dans la représentation du texte

- **L'utilisation des embeddings :**

- Les documents (ou les mots) sont représentés par des vecteurs de sorte à représenter un contexte
- Les modèles permettant de transformer les documents/mots en vecteurs numériques les plus connus : Word2Vec (2013) BERT (2019)

Illustration de l'embedding Word2Vec



[Bromwell, High, nothing, short, brilliant, expertly, scripted, perfectly, delivered, this, searing, parody, students, teachers, South, London, Public, School, leaves, you, literally, rolling, with, laughter]

$X = [-0.76, 1.57, 0.006, \dots, 3.548, -1.686, -2.4, 0.05, 1.1]$

Vecteur de taille $k \ll D$

- **Les limites de l'interprétation :**

- **Globale** : l'analyse est toujours possible mais est uniquement univariée (ne tient pas compte des co-occurrence des mots: exemple « not bad » vs « bad »)
- **Locale** : Les dimensions sont difficilement interprétables (**on ne peut plus associer une variable à un mot!**)

- **L'interprétation passe également au travers de la maîtrise des données !**

1. Contexte et cadre théorique
2. Application sur des données structurées
3. Application sur du texte
- 4. Application dans un cadre actuariel**

Impact d'une variable binaire sur une réponse quantitative (PLANCHET F., WABO A. [2019]
« Mesure d'impact d'une variable binaire sur une réponse quantitative dans un cadre non paramétrique », ISFA, document de travail.)

Contexte de l'étude

- La présente étude s'inscrit dans le contexte suivant, aisément transposable à de nombreuses autres situations : on cherche à mesurer l'influence de deux réseaux d'experts, A et B, sur les coûts de sinistres matériels automobile, pour ainsi déterminer le réseau conduisant, toutes choses égales par ailleurs, au coût le plus faible, que l'on qualifiera de « plus performant ». Dans la suite, on privilégiera arbitrairement l'écart de coût de A par rapport à B.
- On ne dispose pas d'une base de sinistres où les deux réseaux sont intervenus, un sinistre étant expertisé par A ou B mais jamais par A et B. on doit donc estimer le montant du coût manquant
- Le modèle GLM fournit une réponse simple à cette question


$$\begin{aligned}\mathbb{E}[Y|X] \\ = \exp(\beta_0) \times (\exp(\beta_1))^{X_1} \times \dots \times (\exp(\beta_m))^{X_m}\end{aligned}$$

- La validité de cette mesure est toutefois conditionnée par la validité de l'hypothèse de proportionnalité ; dans le cas où cette hypothèse n'est pas valide, on peut se tourner vers des modélisations non paramétrique de la variable réponse, mais la mesure d'influence devient plus délicate.

Impact d'une variable binaire sur une réponse quantitative

Trois propositions de mesures

- L'approche la plus intuitive est de reconstituer les valeurs manquantes sur un échantillon de comparaison à l'aide, par exemple, d'un GBM : le calcul des écarts de coûts est alors immédiat ;
- Il est également possible de décomposer la valeur de la réponse en fonction des contributions de chaque variables en s'appuyant sur les valeurs SHAP



- La mesure d'impact sur une catégorie de sinistres est alors obtenue par

$$\frac{\bar{y}_A - \bar{y}_B}{\bar{y}}$$

$$= \frac{\frac{1}{n_{test}^A} \sum_{i=1}^{n_{test}^A} \sum_{j=0}^m \hat{\phi}_{ij}^A - \frac{1}{n_{test}^B} \sum_{i=1}^{n_{test}^B} \sum_{j=0}^m \hat{\phi}_{ij}^B}{\frac{1}{n_{test}} \sum_{i=1}^{n_{test}} \sum_{j=0}^m \hat{\phi}_{ij}}$$

Impact d'une variable binaire sur une réponse quantitative

Trois propositions de mesures

- Les mesures unitaires d'impact sont déterminées avec le Kernel SHAP. Le Kernel SHAP est une technique qui permet d'expliquer une prédiction d'un modèle d'apprentissage automatique, en construisant localement un modèle linéaire autour de cette prédiction (cf. RIBEIRO et al. [2016]). Son principe est de trouver le meilleur modèle linéaire qui traduit le comportement du modèle prédictif pour une prédiction donnée (cf. LUNDBERG et LEE [2017]) :

$$g(x') = \underset{\varepsilon \in G_L}{\operatorname{argmin}} L(f, \varepsilon, \pi_{x'})$$

- Où f et g sont respectivement le modèle à expliquer et le modèle explicatif, G_L est la classe des modèles linéaires, x^{\wedge} est le vecteur correspondant à l'absence/présence des variables explicatives de l'instance d'intérêt x dans la prédiction obtenue, et les paramètres $\pi_{x^{\wedge}}$ (mesure de proximité) et L (fonction de perte) sont donnés ci-dessous

$$\begin{cases} L(f, \varepsilon, \pi_{x'}) = \sum_{z' \in Z} \pi_{x'}(z') \left(f(h_x(z')) - \varepsilon(z') \right)^2, \\ \pi_{x'}(z') = \frac{m-1}{|z'| (m - |z'|)} \binom{m}{|z'|}^{-1}. \end{cases}$$

Impact d'une variable binaire sur une réponse quantitative

Trois propositions de mesures

- On peut décomposer plus finement la mesure globale

$$\frac{\bar{y}_A - \bar{y}_B}{\bar{y}} = \frac{\frac{1/n_{test}^A \sum_{i=1}^{n_{test}^A} \sum_{j=0}^m \hat{\phi}_{ij}^A - 1/n_{test}^B \sum_{i=1}^{n_{test}^B} \sum_{j=0}^m \hat{\phi}_{ij}^B}{1/n_{test} \sum_{i=1}^{n_{test}} \sum_{j=0}^m \hat{\phi}_{ij}}}$$

$$= \frac{\frac{1/n_{test}^A \sum_{i=1}^{n_{test}^A} \hat{\phi}_{i1}^A - 1/n_{test}^B \sum_{i=1}^{n_{test}^B} \hat{\phi}_{i1}^B}{1/n_{test} \sum_{i=1}^{n_{test}} \sum_{j=0}^m \hat{\phi}_{ij}} + \dots + \frac{\frac{1/n_{test}^A \sum_{i=1}^{n_{test}^A} \hat{\phi}_{ip}^A - 1/n_{test}^B \sum_{i=1}^{n_{test}^B} \hat{\phi}_{ip}^B}{1/n_{test} \sum_{i=1}^{n_{test}} \sum_{j=0}^m \hat{\phi}_{ij}} + \dots + \frac{1/n_{test}^A \sum_{i=1}^{n_{test}^A} \hat{\phi}_{im}^A - 1/n_{test}^B \sum_{i=1}^{n_{test}^B} \hat{\phi}_{im}^B}{1/n_{test} \sum_{i=1}^{n_{test}} \sum_{j=0}^m \hat{\phi}_{ij}}}$$


Effet de la variable « cible »

$$\dots + \frac{1/n_{test}^A \sum_{i=1}^{n_{test}^A} \hat{\phi}_{im}^A - 1/n_{test}^B \sum_{i=1}^{n_{test}^B} \hat{\phi}_{im}^B}{1/n_{test} \sum_{i=1}^{n_{test}} \sum_{j=0}^m \hat{\phi}_{ij}}$$

Impact d'une variable binaire sur une réponse quantitative

Trois propositions de mesures

- La mise en œuvre dans un contexte dynamique, avec des évaluations trimestrielles,



Impact d'une variable binaire sur une réponse quantitative

Conclusion

- Au terme de cette étude qui avait pour objectif de mesurer l'influence du réseau d'experts retenu sur les coûts de sinistres matériels automobile, deux approches ont été développées. La première consiste à comparer les deux réseaux sur une base de sinistres identiques et la seconde consiste à mesurer (à l'aide du Kernel SHAP) la contribution marginale d'un réseau dans les coûts prédits. Ces deux approches ont été mises en œuvre avec un modèle d'apprentissage automatique : le Stochastic Gradient Boosting Model. Les résultats sont confrontés à ceux obtenus par DE LUSSAC [2018] avec un modèle GLM multiplicatif.
- Toutes ces approches conduisent qualitativement au même résultat, tant en vision instantanée (surperformance de A par rapport à B) que dynamique (dégradation de la performance au fil des trimestres de l'historique de deux ans considéré).
- Le GLM, malgré ses hypothèses limitées ou encore sa qualité de prédiction moindre comparée à celle d'un modèle d'apprentissage automatique, demeure un modèle suffisamment pertinent pour se faire une idée sur la comparaison entre deux réseaux. D'autant plus que sa modélisation est relativement simple et son interprétation compréhensible et facile.

Merci à l'ensemble des participants du groupe de travail !

BERAUD-SUDREAU	Guillaume
BERREBI	Mickaël
BILLIAU	Pierre
BLANCHET	Aymeric
BOURAS	Amina
CASOTTO	Mattia
CHAPELON	Rémi
CHIU	Florence
DAMA	Maryse
DUBUS	Brigitte
ELIE	Romuald
GEISSLER	Christophe
GERONDEAU	Estelle
GOUYEN	Yoann
GRONDIN	André
GROSCOT	Herbert
HONORÉ-ROUGÉ	Yolan
ITTAH	Mickaël
JUILLARD	Marc
LY	Antoine
MAILLART	Arthur
MESSOUSI	Adel
MOURENS	Amélie
OLYMPIO	Anani
PICARD	Florence
PLANCHET	Frédéric
PONS	Florian
RAMOS	Nathalie
RANDUINEAU	Raphaël
VERMET	Franck
WESNER	Nicolas
YANKOL	Meryem