



SINCLAIR



THÉORIE DES JEUX COOPÉRATIFS ET ANALYSE DE SENSIBILITÉ

MÉTHODES D'ESTIMATION DES EFFETS DE SHAPLEY

¹EDF Lab Chatou - Département PRISME

²Institut de Mathématiques de Toulouse

³SINCLAIR AI Lab

Journées thématiques MEXICO

Jeudi 4 Mai 2022

Les *éléments conditionnels* sont définis par :

$$V_A = S_A^{\text{clos}} = \frac{\mathbb{V}(\mathbb{E}[Y | X_A])}{\mathbb{V}(Y)} \quad \text{et} \quad E_A = \frac{\mathbb{E}[\mathbb{V}(Y|X_{\bar{A}})]}{\mathbb{V}(Y)}$$

L'estimation des effets de Shapley se fait en 2 temps :

1. **Estimation des éléments conditionnels** : estimer V_A ou E_A , pour tout $A \subseteq D$.
2. **W-Aggregation** : calculer les effets de Shapley en utilisant la formule (Song, Nelson, and Staum 2016)

$$\begin{aligned} Sh_j &= \frac{1}{d} \sum_{A \subseteq D \setminus \{j\}} \binom{d-1}{|A|}^{-1} (V_{\{A \cup \{j\}\}} - V_A) \\ &= \frac{1}{d} \sum_{A \subseteq D \setminus \{j\}} \binom{d-1}{|A|}^{-1} (E_{\{A \cup \{j\}\}} - E_A) \end{aligned}$$

1. Estimation par double Monte-Carlo (simulations)
2. Estimation par plus-proches voisins (data-driven)

1. Estimation par double Monte-Carlo (simulations)
2. Estimation par plus-proches voisins (data-driven)

Estimation Monte-Carlo

Il faut être en mesure de pouvoir :

- Simuler selon la loi jointe des entrées P_X ;
- Simuler selon toutes les lois marginales P_{X_A} , pour tout $A \subset D$;
- Simuler selon toutes les lois conditionnelles $P_{X|X_A}$, pour tout $A \subset D$.

On tire un échantillon X_A de taille N_o de la loi marginale P_{X_A} . Pour chaque observation $x_A^{(j)}$ de X_A , on tire un échantillon $\tilde{X}_{A,i} = (X | X_A = x_A^{(i)})$ de taille N_i de la loi $P_{X|X_A}$.

Avec un échantillon X de taille N_v de la loi jointe P_X , on estime empiriquement la variance de Y :

$$\widehat{\mathbb{V}(Y)} = \frac{1}{N_v - 1} \sum_{i=1}^{N_v} (y_i - \bar{y})^2$$

avec $y_i = G(x^{(i)})$ où $x^{(i)}$ est la i -ème observation de l'échantillon X , et $\bar{y} = \frac{1}{N_v} \sum_{i=1}^{N_v} y_i$.

Estimation Monte Carlo

On estime ensuite $V_A = \frac{\mathbb{V}(\mathbb{E}[Y|X_A])}{\mathbb{V}(Y)}$ par leur contrepartie empirique :

$$\mathbb{V}(\widehat{\mathbb{E}[Y|X_A]}) = \frac{1}{N_o - 1} \sum_{i=1}^{N_o} \left(\frac{1}{N_i} \sum_{j=1}^{N_i} G(\tilde{X}_{A,i}^{(j)}) - \bar{y} \right)^2.$$

Ainsi, on obtient un estimateur (consistant) de V_A :

$$\widehat{V}_A = \frac{\mathbb{V}(\widehat{\mathbb{E}[Y|X_A]})}{\widehat{\mathbb{V}(Y)}}.$$

Il reste qu'à estimer tous les \widehat{V}_A pour tout $A \subseteq D$. Cet algorithme est **très gourmand en nombre d'appel au code de calcul** : il nécessite $(N_v + d! \times (d - 1) \times N_o \times N_i)$ appels à G pour calculer **tous les effets de Shapley**.

(Fonction `shapleyPermEx` du package [sensitivity](#), voir le TP2)

Une **heuristique** pour optimiser le compromis coût/précision de l'estimateur : fixer $N_i = 3$.

Au-delà du coût d'estimation, la nécessité de **connaître** et **pouvoir simuler** selon les lois conditionnelles peut être compliqué, **surtout en situation de dépendance entre les variables**.

Une **heuristique** pour optimiser le compromis coût/précision de l'estimateur : fixer $N_i = 3$.

Au-delà du coût d'estimation, la nécessité de **connaître** et **pouvoir simuler** selon les lois conditionnelles peut être compliqué, **surtout en situation de dépendance entre les variables**.

Est-il possible d'estimer les effets de Shapley avec un échantillon i.i.d. des entrées/sorties du modèle ?

1. Estimation par double Monte-Carlo (simulations)
2. Estimation par plus-proches voisins (data-driven)

Estimation KNN

Démarche proposée par (Broto, Bachoc, and Depecker 2020) : dans une approche Double Monte-Carlo, **ne pas simuler selon les lois conditionnelles**, mais plutôt **approcher un échantillon des lois conditionnelles** par procédure **KNN**.

Intuition : Au tableau.

Estimation KNN

Démarche proposée par (Broto, Bachoc, and Depecker 2020) : dans une approche Double Monte-Carlo, **ne pas simuler selon les lois conditionnelles**, mais plutôt **approcher un échantillon des lois conditionnelles** par procédure KNN.

Intuition : Au tableau.

Soit $(X^{(1)}, \dots, X^{(N)})$ un N -échantillon i.i.d de X , et notons $k_N^A(l, n)$ l'indice tel que $X_A^{(k_N^A(l, n))}$ soit le n -ième plus proche voisin de $X_A^{(l)}$ dans $(X_A^{(1)}, \dots, X_A^{(N)})$.

$$\widehat{E}_{A, \text{KNN}} = \frac{1}{N} \sum_{l=1}^N \left(\frac{1}{N_s - 1} \sum_{i=1}^{N_s} \left[G \left(X^{(k_N^{\bar{A}}(l, i))} \right) - \frac{1}{N_s} \sum_{h=1}^{N_s} G \left(X^{(k_N^{\bar{A}}(l, h))} \right) \right]^2 \right)$$

où N_s est l'hyper-paramètre relatif au nombre de voisin à sélectionner. De plus, $\widehat{E}_{A, \text{KNN}}$ converge vers E_A en probabilité lorsque N tends vers $+\infty$

(Fonctions `shapleySubsetMC`, `sobolshap_knn` et `shapleysobol_knn` du package [sensitivity](#), voir le TP2)

Points positifs :

- Approche *data-driven*.
- Estimateur convergent sous certaines hypothèses peu contraignantes.
- Estimation peu coûteuse.

Points négatifs :

- Le choix du nombre de voisins N_s est un paramètre à choisir, et peut **beaucoup influencer** les résultats (manque de stabilité).

- Broto, B, F Bachoc, and M Depecker. 2020. "Variance Reduction for Estimation of Shapley Effects and Adaptation to Unknown Input Distribution" [in en]. *SIAM/ASA Journal on Uncertainty Quantification* 8, no. 2 (January): 693–716. issn: 2166-2525, accessed December 2, 2020. <https://doi.org/10.1137/18M1234631>. <https://epubs.siam.org/doi/10.1137/18M1234631>.
- Song, E., B. L. Nelson, and J. Staum. 2016. "Shapley Effects for Global Sensitivity Analysis: Theory and Computation" [In English]. *SIAM/ASA Journal on Uncertainty Quantification* 4, no. 1 (January): 1060–1083. issn: 2166-2525. <https://doi.org/10.1137/15M1048070>. <http://epubs.siam.org/doi/10.1137/15M1048070>.