

# Analyse de sensibilité par HSIC pour codes stochastiques

Application à la gestion d'actifs hydrauliques

Julien Pelamatti & Jérôme Lonchamp

Projet AMPH2

EDF R&D

# Contexte : parc hydraulique français

## Quelques chiffres (2019)

- ▶ ~ 60 TWh de production
  - ▶ 11 % de la production du pays
- ▶ 2300 installations hydroélectriques différentes (433 exploitées par EDF)
  - ▶ Barrages
  - ▶ Stations de Transfert d'Énergie par Pompage (STEP)
  - ▶ Turbines *au fil de l'eau*
- ▶ Production concentrée en :
  - ▶ Auvergne Rhône-Alpes
  - ▶ Occitanie
  - ▶ Provence-Alpes-Côte d'Azur
  - ▶ Grand-Est




Figure: Source : RTE (2019)

## Contexte : maintenance du parc

- ▶ Optimisation et justification des stratégies de maintenance du parc hydraulique
- ▶ Analyse de la rentabilité technico-économique et planification des opérations de maintenance :
  - ▶ Inspection programmée ou déclenchée par des mesures/capteurs
  - ▶ Maintenance préventive
  - ▶ Maintenance corrective (suite à une défaillance)
  - ▶ Approvisionnement de pièces de rechange (préventif ou suite à des maintenances)
- ▶ On s'intéressera ici aux équipements suivants :
  - ▶ Alternateurs
  - ▶ Turbines
  - ▶ Transformateurs

## Contexte : maintenance du parc

- ▶ Difficultés
  - ▶ Un parc d'actifs large et varié, en termes de dimension, technologie et âge
    - ▶ Difficile de prédire l'usure des différents composants
    - ▶ Difficile de prédire les temps et les coûts de maintenance
  - ▶ Disponibilité et approvisionnement des pièces de rechange
    - ▶ Temps & coûts
  - ▶ Disponibilité de main d'œuvre
- ▶ Le phénomène est de nature aléatoire
  - ▶ Les dates de défaillance des composants ne sont pas connues d'avance
  - ▶ L'état des composants après inspection n'est pas connu d'avance
  - ▶ Possibilité d'avoir des faux positifs & négatifs sur les inspections

Il n'existe pas une stratégie de maintenance optimale à *priori*

**Le coût d'une stratégie de maintenance peut se voir comme une variable aléatoire**

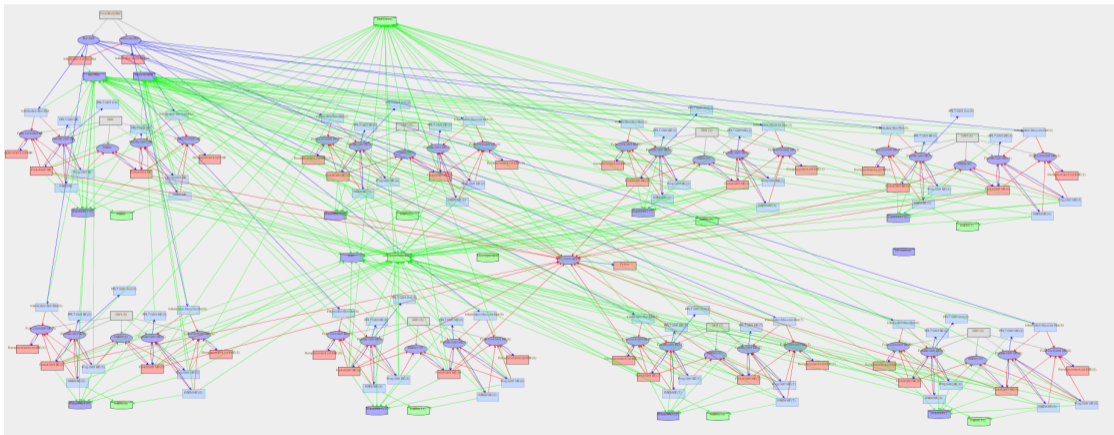
## Contexte : simulation de stratégies de maintenance

Simulation des stratégies de maintenance à l'aide du logiciel **VME** (EDF R&D)  
(Valorisation des Maintenances Exceptionnelles)

- ▶ Modélisation d'actifs ou de parcs d'actifs, et de leurs composants
- ▶ Modes de défaillances & stratégies de maintenance complexes (maintenance préventive, systématique, conditionnelle, ...)
- ▶ Logistique de pièces de rechange (temps et coûts d'approvisionnement), mise en commun de pièces pour des équipements du même type
- ▶ Variabilité saisonnière des coûts des pertes associées aux indisponibilités

# Contexte : simulation de stratégies de maintenance

## Exemple de modèle VME : $n$ groupes identiques



## Contexte : simulation de stratégies de maintenance

- ▶ Les dates de défaillance, les erreurs d'inspections, et autres informations méconnues sont générées aléatoirement
- ▶ Deux évaluations d'une simulation avec les mêmes paramètres d'entrée pourront fournir des résultats différents
  - ▶ **Code stochastique**
- ▶ Comparaison avec une stratégie de référence, typiquement purement corrective
  - ▶ Est-il préférable d'effectuer des maintenances préventives, ou bien est-ce moins coûteux d'effectuer les réparations suite aux défaillances ?
  - ▶ Est-il convenient d'approvisionner une pièce de rechange avant épuisement du stock ?
- ▶ On s'intéresse à la Valeur Actuelle Nette (VAN) d'une stratégie de maintenance
  - ▶ Gains (ou pertes) économique par rapport à la stratégie de référence


## Contexte : simulation de stratégies de maintenance

- ▶ Évaluation des stratégies par échantillonnage Montecarlo
  - ▶ Chaque simulation est effectuée un large nombre de fois, afin de pouvoir estimer la distribution de la VAN
- ▶ Comment analyser les résultats?
  - ▶ Distribution entière
  - ▶ Moyenne / Médiane
  - ▶ Quantiles
  - ▶ Probabilité de VAN négative (probabilité de regret)
- ▶ Coût de calcul potentiellement élevé
  - ▶ Large nombre de simulations MC = meilleure estimation de la distribution de la VAN



## Contexte : simulation de stratégies de maintenance

Exemple de modèle VME :  $n$  groupes identiques (50 calculs, 1000 simulations par calcul)



## **Analyse de sensibilité pour codes stochastiques**

# Analyse de sensibilité

- ▶ L'évaluation d'une stratégie de maintenance dépend de plusieurs paramètres :
  - ▶ Types & paramètres de lois de défaillance des composants
  - ▶ Coûts des maintenances et des composants
  - ▶ Durées des maintenances & des approvisionnements
  - ▶ Pertes de production (indisponibilités)
  - ▶ État des composants suite aux maintenances
- ▶ Besoin d'une analyse de sensibilité de la distribution de la VAN par rapport aux différents paramètres caractérisant la simulation
  - ▶ Identification des paramètres de simulation influents sur la distribution de la VAN, afin de simplifier le modèle
  - ▶ Les paramètres les plus influents pourront faire l'objet d'une étude plus approfondie afin d'en valider les valeurs fournies

## Rappels : indices HSIC pour l'analyse de sensibilité

### Indices HSIC

- ▶ Quantification de la dépendance entre deux variables aléatoires  $X$  et  $Y$
- ▶ *Distance* dans un RKHS entre les *projections* de la loi jointe  $\mathcal{P}_{XY}$  et le produit des lois marginales  $\mathcal{P}_X\mathcal{P}_Y$

$$HSIC(X, Y) = MMD^2(\mathcal{P}_{XY}, \mathcal{P}_X\mathcal{P}_Y)$$

- ▶  $HSIC(X, Y) = 0 \iff$  indépendance entre  $X$  et  $Y$  (sous conditions)
- ▶ Estimation à l'aide de noyaux de covariance,  $k_x(\cdot, \cdot)$ ,  $k_y(\cdot, \cdot)$

$$\widehat{HSIC}(X, Y)_{Vstat} = \frac{1}{n^2} \text{Tr}(K_X H K_Y H)$$

- ▶  $K_x, K_y$  matrices de covariance,  $H$  matrice de centrage

# Rappels : indices HSIC pour l'analyse de sensibilité

## Indices HSIC

- ▶ On s'intéresse ici aux HSIC calculés indépendamment pour chaque paramètre d'entrée
  - ▶ pas de HSIC-ANOVA
  
- ▶ On utilisera un indice normalisé (entre 0 et 1) :

$$\widehat{R}^2_{HSIC(X,Y)} = \frac{\widehat{HSIC}(X, Y)}{\sqrt{\widehat{HSIC}(X, X) \widehat{HSIC}(Y, Y)}}.$$

# Rappels : indices HSIC pour l'analyse de sensibilité

## Indices HSIC ciblés

- ▶ On peut exploiter les indices HSIC afin de faire de l'analyse de sensibilité **ciblée**
  - ▶ Quels sont les paramètres influents pour le franchissement dans un domaine critique  $\mathcal{C}$  de la sortie?
  - ▶ Exemple : on veut savoir quels sont les paramètres qui peuvent mener à des valeurs moyennes de VAN négatives
- ▶ On peut appliquer une transformation sur la variable de sortie, au plus simple :

$$\tilde{Y} = w(Y) = \begin{cases} 0 & \text{if } Y \notin \mathcal{C} \\ 1 & \text{if } Y \in \mathcal{C} \end{cases}$$

- ▶ Des fonctions de poids  $w(\cdot)$  plus pertinentes existent
- ▶ Nécessite l'utilisation d'un noyau  $k_Y(\cdot, \cdot)$  adapté
- ▶ On calcule ensuite  $HSIC(X, \tilde{Y})$  avec des estimateurs standards

# Rappels : indices HSIC pour l'analyse de sensibilité

## p-valeurs pour les indices HSIC

- ▶ On peut exploiter les indices HSIC afin de faire du *criblage*
  - ▶ Caractérisation qualitative des variables **influentes** / **non-influentes**
- ▶ On exploite des tests statistiques sur l'hypothèse d'indépendance  $\mathcal{H}_0$  entre  $X$  et  $Y$
- ▶ On s'intéresse à la statistique  $\widehat{S}_{\mathcal{T}} := n \times \widehat{HSIC}(X, Y)$
- ▶ On peut calculer la p-valeur associée

$$p_{\text{val}} = \mathbb{P} \left( \widehat{S}_{\mathcal{T}} > \widehat{S}_{\mathcal{T}, \text{obs}} \mid \mathcal{H}_0 \right)$$

- ▶ Faible valeur de  $p_{\text{val}}$   $\rightarrow$  on peut sereinement rejeter  $\mathcal{H}_0$
- ▶ On exploite une approximation asymptotique de la loi de  $\widehat{HSIC}(X, Y)$  (loi Gamma) pour calculer  $p_{\text{val}}$

## Analyse de sensibilité pour codes stochastiques

- ▶ On dispose d'un jeu de données contenant entrées et échantillons MC de la sortie

$$\left(\mathbf{x}^{(j)}, \mathbf{y}^{(j)}\right)_{(1 \leq j \leq n)} = \left(x_1^{(j)}, x_2^{(j)}, \dots, x_d^{(j)}; y_1^{(j)}, \dots, y_p^{(j)}\right)_{(1 \leq j \leq n)}$$

### Comment utiliser les indices HSIC dans ce contexte ?

- ▶ Sur la valeur moyenne de  $y$  ?
- ▶ Sur la variance de  $y$  ?
- ▶ HSIC *ciblés* sur des quantiles de  $y$  ?



# Analyse de sensibilité pour codes stochastiques

Exemple :

$$y(x_1, x_2) = x_1 \sin(x_1) + x_2 \mathcal{N}(0, 1)$$





Figure: Réalisation de  $y$

# Analyse de sensibilité pour codes stochastiques

Exemple (50 calculs, 300 simulations par calcul)



# Analyse de sensibilité pour codes stochastiques




Figure: Moyenne empirique


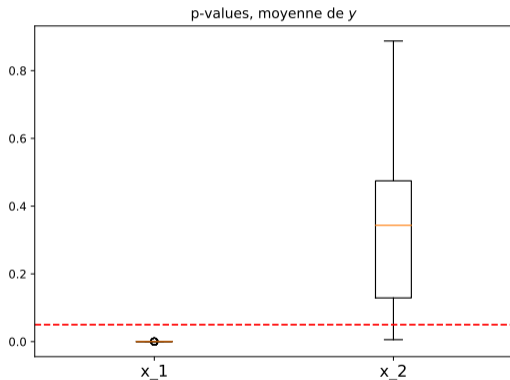
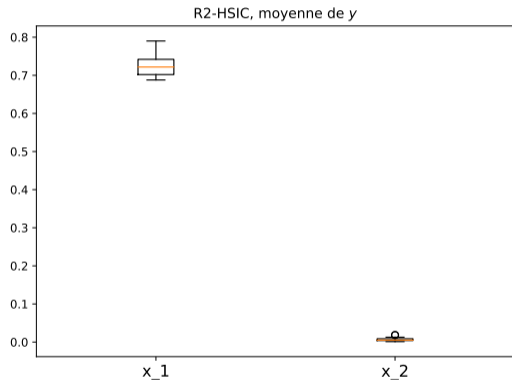


Figure: Variance empirique

## Analyse de sensibilité pour codes stochastiques


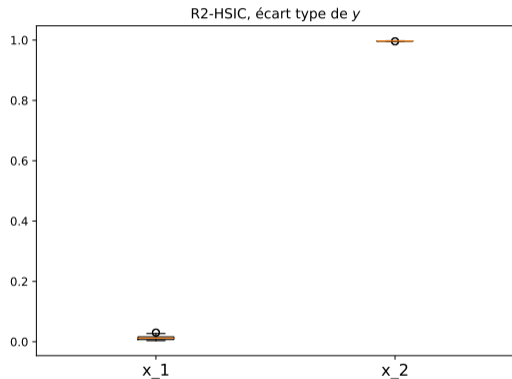
Calcul des indices HSIC entre  $x_1$ ,  $x_2$  et la moyenne (empirique) de  $y$



**On ne capte pas l'effet de  $x_2$  :(**

## Analyse de sensibilité pour codes stochastiques

Et si on regarde les HSIC entre  $x_1$ ,  $x_2$  et l'écart type (empirique) de  $y$  ?



**On ne capte pas l'effet de  $x_1$  :(**

## Analyse de sensibilité pour codes stochastiques

**On aimerait pouvoir analyser la distribution de  $y$  dans son entièreté**

- ▶ Peut-on adapter les indices HSIC au cadre stochastique ?
- ▶ Comment définir un noyau de façon à ce qu'il calcule une covariance entre deux échantillons de  $y$  ?

$$k(\mathbf{y}, \mathbf{y}') = k(y_1, \dots, y_p ; y'_1, \dots, y'_{p'})$$

- ▶ On peut remplacer  $\|y - y'\|_2^2$  (cas déterministe) par  $MMD^2(\mathbf{y}, \mathbf{y}')$ , e.g.,

$$k(\mathbf{y}, \mathbf{y}') = \exp\left(\frac{MMD^2(\mathbf{y}, \mathbf{y}')}{\sigma^2}\right)$$

## Quelques rappels sur la MMD

- ▶  $Y \sim \mathcal{P}_Y, Y' \sim \mathcal{P}_{Y'}$  deux variables aléatoires
- ▶ kernel embedding de  $Y, Y'$  dans un RKHS  $\mathcal{H}$  :

$$\mu_Y = \mathbb{E}_Y[k_{\mathcal{H}}(Y, \cdot)], \quad \mu_{Y'} = \mathbb{E}_{Y'}[k_{\mathcal{H}}(Y', \cdot)]$$

- ▶ La MMD entre  $Y$  et  $Y'$  est définie comme :

$$MMD(Y, Y') = \|\mu_Y - \mu_{Y'}\|_{\mathcal{H}}$$

- ▶ Estimation :

$$MMD^2(Y, Y') = \mathbb{E}[k_{\mathcal{H}}(Y, \tilde{Y})] + \mathbb{E}[k_{\mathcal{H}}(Y', \tilde{Y}')] - 2\mathbb{E}[k_{\mathcal{H}}(Y, Y')]$$

$$\widehat{MMD}^2(Y, Y') = \frac{1}{p(p-1)} \sum_{i=1}^p \sum_{j \neq i}^p k_{\mathcal{H}}(Y_i, Y_j) + \frac{1}{p'(p'-1)} \sum_{i=1}^{p'} \sum_{j \neq i}^{p'} k_{\mathcal{H}}(Y'_i, Y'_j) - \frac{2}{pp'} \sum_{i=1}^p \sum_{j=1}^{p'} k_{\mathcal{H}}(Y_i, Y'_j)$$

## Noyau de covariance *energy distance*

Afin de calculer la MMD entre deux échantillons de  $Y$  et  $Y'$ , on utilisera ici le noyau dit *energy distance* :

$$k(y, y') = |y| + |y'| - 2|y - y'|$$

A noter :

- ▶ Non-paramétré
- ▶ Non stationnaire
- ▶ Caractéristique

NB : on normalise les données entre 0 et 1



## Noyau de covariance *energy distance*




Figure: Noyau energy distance

## Analyse de sensibilité pour codes stochastiques

- ▶ Une fois défini le noyau entre échantillons de  $y$ , il est possible de calculer et exploiter les indices HSIC entre chaque paramètre et la sortie stochastique de façon standard
  - ▶ Estimateurs Vstat & Ustat
  - ▶ P-valeurs (estimateurs asymptotiques et par permutation)
- ▶ NB : il est possible de calculer la MMD entre deux échantillons de tailles  $p$  et  $p'$  différentes
- ▶ Coût de calcul considérablement plus large que pour les analyses sur des sorties déterministes

# Analyse de sensibilité pour codes stochastiques

On reprend l'exemple précédent :






Figure: Réalisation de  $y$

# Analyse de sensibilité pour codes stochastiques

Et calcule les HSIC entre  $x_1$ ,  $x_2$  et les échantillons des  $y$  correspondants



**On capte les effets des deux variables :)**

## **Analyse de sensibilité, application aux modèles VME**

# Utilisation des indices HSIC dans le cadre de VME

On compare ici trois types d'analyses différentes :

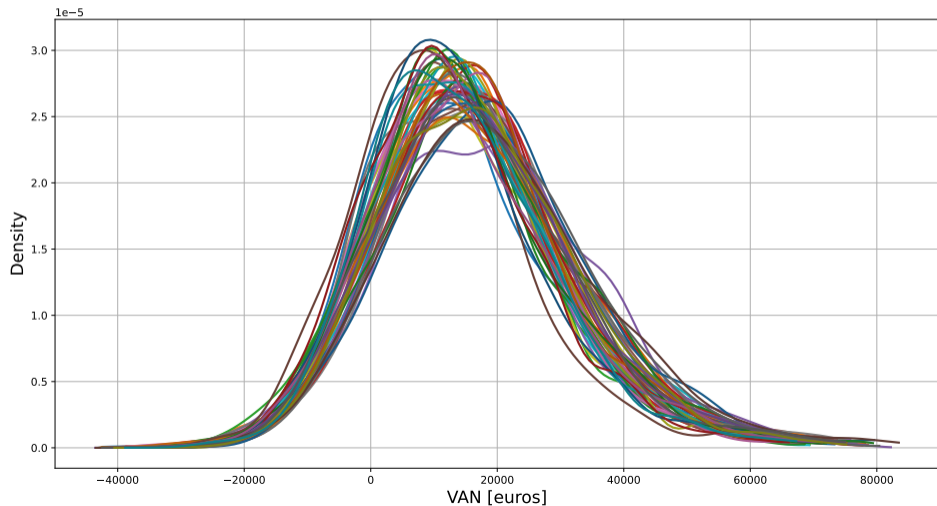
1. Analyse de sensibilité globale sur un scalaire représentatif
  - ▶ VAN moyenne
2. Analyse de sensibilité ciblée sur un seuil critique
  - ▶ e.g., VAN moyenne inférieure à 0 (investissement à perte)
3. Analyse de sensibilité globale sur la distribution de la VAN
  - ▶ Utilisation du noyau basé sur l'utilisation de la MMD entre échantillons

## Cas d'application : $n$ groupes identiques

- ▶ On considère  $n$  groupes identiques
- ▶ 4 co-variables, distributions uniformes
  - ▶ Paramètres  $\lambda$  et  $\beta$  de la loi de Weibull de défaillance des groupes
  - ▶ Incertitude sur les coûts de maintenance
  - ▶ Incertitude sur les temps de maintenance
- ▶ 3 analyses de sensibilité :
  - ▶ Analyse de sensibilité globale sur la VAN moyenne
  - ▶ Analyse de sensibilité ciblée sur la probabilité d'une VAN négative :  
 $P(VAN < 0.) < 0.15$
  - ▶ Analyse de sensibilité sur la distribution de la VAN
- ▶ 1000 simulations Montecarlo par jeu de paramètres
- ▶ 500 jeux de paramètres considérés
- ▶ Intervalle de confiance calculé sur 50 re-échantillonnages bootstrap

## Contexte : simulation de stratégies de maintenance

Cas d'application :  $n$  groupes identiques (50 calculs, 1000 simulations par calcul)





# Cas d'application : $n$ groupes identiques

## Indices R2-HSIC




Figure: Global




Figure: Target




Figure: MMD

# Cas d'application : $n$ groupes identiques

## P-valeurs




Figure: Global




Figure: Target


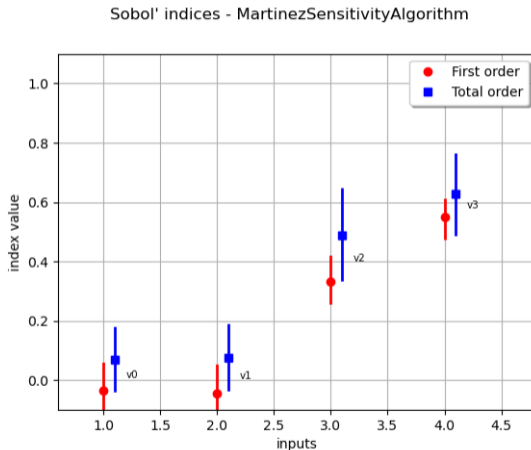


Figure: MMD

# Cas d'application : $n$ groupes identiques

## Indices de Sobol' (1er ordre et total) sur la VAN moyenne





- Nécessite considérablement plus de données ( $\sim 10\times$ )



# Cas d'application : $n$ groupes identiques

Quelle est l'influence de la distribution associée à chaque paramètre ?

Distribution uniforme





Distribution triangulaire





# Cas d'application : $n$ groupes identiques

Quelle est l'influence de la distribution associée à chaque paramètre ?

Distribution uniforme



Distribution uniforme avec support élargi ( $\times 2$ )




## Cas d'application : installation hydroélectrique

- ▶ 6 co-variables
- ▶ 3 analyses de sensibilité :
  - ▶ Analyse de sensibilité globale sur la VAN moyenne
  - ▶ Analyse de sensibilité ciblée sur la probabilité d'une VAN négative :  
 $P(VAN < 0.) < 0.15$
  - ▶ Analyse de sensibilité sur la distribution de la VAN
- ▶ 500 simulations Montecarlo par par évaluation de distribution
- ▶ 500 évaluations de distribution de la VAN
- ▶ Intervalle de confiance calculé sur 50 re-échantillonnages avec remise

## Contexte : simulation de stratégies de maintenance



Cas d'application : Installation hydroélectrique (50 calculs, 1000 simulations par calcul)

---




# Cas d'application : installation hydroélectrique

## R2-HSIC





1. Dispo TRSN
2. Pb Defaillance Cables
3. Proba Avarie new T7
4. Proba Avarie old T7
5. Facteur fiab
6. Facteur coût






# Cas d'application : installation hydroélectrique

## p-valeurs



1. Disponibilité TRSN
2. Probabilité defaillance cables
3. Probabilité Avarie new T7
4. Probabilité Avarie old T7
5. Facteur fiabilité
6. Facteur coût



## Conclusions

- ▶ Méthodologie d'analyse de sensibilité sur les distributions de valorisation d'investissements
- ▶ 3 types d'analyse de sensibilité basées sur les indices HSIC (et p-valeurs associées) sont mises en place
  - ▶ Analyse globale d'une valeur scalaire représentative
  - ▶ Analyse ciblée sur un domaine critique
  - ▶ Analyse sur la distribution de la sortie
- ▶ Interprétabilité potentiellement difficile
- ▶ Les 3 méthodes fournissent des résultats semblables concernant l'importance relative entre co-variables et l'identification de variables non-influentes
  - ▶ Modèles relativement simples
- ▶ Variabilité des résultats considérablement plus faible pour les analyses de la distribution entière mais coûts de calcul additionnels considérables
  - ▶ **Analyse du compromis nécessaire**

## Perspectives & travaux futurs

- ▶ Identification de cas d'applications caractérisés par des distributions en sortie plus complexes
  - ▶ Multi-modales
  - ▶ Queues de distribution importantes
- ▶ Prise en considération de co-variables non continues (e.g., loi de défaillance)
- ▶ Analyse de l'influence des choix de noyaux
- ▶ Extension aux HSIC-ANOVA (meilleure gestion des co-variables dépendantes)
- ▶ Optimisation des temps de calcul (parallélisation et exploitation de GPU)
- ▶ Applications aux parcs éoliens



*“That’s all Folks!”*

## Quelques références

- ▶ Da Veiga, Sébastien. "Kernel-based ANOVA decomposition and Shapley effects—Application to global sensitivity analysis." arXiv preprint arXiv:2101.05487 (2021).
- ▶ Gretton, Arthur, et al. "A kernel statistical test of independence." Advances in neural information processing systems 20 (2007).
- ▶ Gretton, Arthur, et al. "A kernel two-sample test." The Journal of Machine Learning Research 13.1 (2012): 723-773.
- ▶ Marrel, Amandine, and Vincent Chabridon. "Statistical developments for target and conditional sensitivity analysis: application on safety studies for nuclear reactor." Reliability Engineering & System Safety 214 (2021): 107711.
- ▶ Székely, Gábor J., and Maria L. Rizzo. "Energy statistics: A class of statistics based on distances." Journal of statistical planning and inference 143.8 (2013): 1249-1272.