

## Formation en STATISTIQUES « Méthodes statistiques pour les données massives – Big Data »

**Principaux aspects des Big Data abordés : le volume des données et leur variété.**

**Principaux thèmes travaillés : Données de grande dimension, Données de nature hétérogène, Classification, Régression, Clustering**

### Dates et Lieu

Les jeu-ven 7-8 sept  
ET le lun 18 sept 2023  
(3 jours en 2j+1j)

En distanciel

### Publics

Personnes souhaitant se mettre à jour sur les dernières méthodes statistiques pour les données massives (Big Data)

### Pré-requis

Avoir des notions avancées en statistique (inférence, clustering, régression, classification), ainsi que des notions de R. Réfléchir à des problématiques, jeux de données ou documents susceptibles d'être utilisés en support lors de la formation.

### Intervenant

Formateur de la Sté Arkesys

### Support logiciels

Cette formation n'est pas dédiée à la pratique d'un logiciel particulier mais nous proposons de nous appuyer sur le logiciel R pour les exercices et les illustrations

### OBJECTIFS :

- Réaliser une analyse de régression lorsque les données sont en grande dimension
- Réaliser un clustering en utilisant des modèles parcimonieux spécifiques à la grande dimension
- Réaliser une étude de classification sur des données de grande dimension
- Effectuer une sélection des variables pertinentes
- Effectuer ces analyses sous le logiciel R
- Extraire de l'information sur la problématique métier à partir des résultats de l'analyse

### PROGRAMME :

#### Introduction au Big Data

- > Les grandes évolutions de la statistique
- > Les 3 V : Volume, Variété, Vélocité
- > Les problèmes que cela engendre pour les techniques classiques

#### Big Data et Régressions

- > Illustration de la problématique de la grande dimension
- > Méthode de sélection de variables
- > Méthodes de projection
- > Méthodes de régularisation
- > Comparaison de méthodes
- > Régression sur données non quantitatives

#### Apprentissage non supervisé (clustering)

- > Illustration de la problématique de la grande dimension
- > Modèle de mélange parcimonieux
- > Algorithme EM
- > Sélection de modèles
- > Sélection de variables
- > Prise en compte de données hétérogènes

#### Apprentissage supervisé

- > Illustration de la problématique de la grande dimension
- > Sélection de variables
- > Méthodes de projection
- > Méthodes de régularisation
- > Comparaison de méthodes
- > Prise en compte de données hétérogènes

### METHODES :

Explications théoriques suivies de pratiques guidées puis mises en autonomie, sur des thématiques et jeux de données proches des problématiques des participants

### POUR Y PARTICIPER :

1/ S'inscrire sur SIRENE : <https://www.sirene.inserm.fr/>

(onglet « Agent formation », menu « Demander une formation », sous-menus « offre de formation continue & collective », domaine « TS4-Statistiques »)

2/ Compléter le questionnaire de pré-formation en ligne : [Questionnaire Big Data](#)

**1/ & 2/ A FAIRE pour le 21/06/2023 au plus tard**