

## Architecture des données : stockage et accès

*Appréhender et prendre en main les nouvelles architectures de données : Hadoop, NoSQL, Spark*

### DESCRIPTION

Si les algorithmes de Machine Learning ont connu des avancées majeures ces dernières années, c'est avant tout grâce à la quantité d'information disponible pour les entraîner. Accumuler toute cette donnée, la traiter, et la rendre disponible sont les enjeux principaux du mouvement Big Data.

Au cours de cette formation, nos consultants mettent à disposition les connaissances issues de leurs retours d'expériences auprès de nos clients, et vous font découvrir les bases des architectures permettant de répondre à ces enjeux de stockage et d'accès.

### OBJECTIFS PEDAGOGIQUES

- Découvrir les notions centrales de stockage de données
- Appréhender les enjeux des nouvelles architectures de données (Hadoop, NoSQL, Spark), et positionner leurs usages au sein de l'univers Big Data
- Savoir manipuler ces technologies et les bases de données de façon conjointe, pour mener à bien des analyses efficaces

### PUBLIC CIBLE

- Analyste
- Statisticien
- Développeur

### PRE-REQUIS

- Notions de programmation sur la base d'un langage quelconque
- Manipulation basique de la ligne de commande Linux

### METHODE PEDAGOGIQUE

Formation avec apports théoriques, échanges sur les contextes des participants et retours d'expérience pratique du formateur, complétés de travaux pratiques et de mises en situation.

### PROFIL DES INTERVENANTS

Cette formation est dispensée par un·e ou plusieurs consultant·es d'OCTO Technology ou de son réseau de partenaires, expert·es reconnus des sujets traités.

#### Stage pratique

Data Science

Code :

**DSARC**

Durée :

**3 jour(s) (21,00 heures)**

Exposés : **50 %**

Cas pratiques : **40 %**

Echanges d'expérience : **10 %**

#### Inter-entreprises :

Prochaines sessions disponibles [sur notre site web](#).

Tarif : 2 500,00 € HT / participant

#### Intra-entreprise :

Tarifs et dates sur demande.

Le processus de sélection de nos formateurs et formatrices est exigeant et repose sur une évaluation rigoureuse de leurs capacités techniques, de leur expérience professionnelle et de leurs compétences pédagogiques.

## **MODALITÉS D'ÉVALUATION ET FORMALISATION À L'ISSUE DE LA FORMATION**

L'évaluation des acquis se fait tout au long de la session au travers des ateliers et des mises en pratique.

Afin de valider les compétences acquises lors de la formation, un formulaire d'auto-positionnement est envoyé en amont et en aval de celle-ci.

En l'absence de réponse d'un ou plusieurs participants, un temps sera consacré en ouverture de session pour prendre connaissance du positionnement de chaque stagiaire sur les objectifs pédagogiques évalués.

Une évaluation à chaud est également effectuée en fin de session pour mesurer la satisfaction des stagiaires et un certificat de réalisation leur est adressé individuellement.

## **PROGRAMME PEDAGOGIQUE DETAILLE**

### **Jour 1**

#### **INTRODUCTION**

#### **ACCÈS AUX DONNÉES**

Les fichiers

- Arborescence
- Formats

Les bases de données

- Notion de Catalogue
- Le langage SQL
- Data Warehouses et Data Lake
- Bases d'analyse

API

- Définition
- Web Scraping

Traitements en mémoire

### **ARCHITECTE DE DONNÉES**

Limites des systèmes traditionnels

- Limites des fichiers
- Limites des SGBD

Les architectures distribuées

- Patterns d'accès
- 1OLTP
- 2OLAP
- Distribution vs Réplication

Concepts essentiels

- Disponibilités
- Cohérence
- Tolérance à la partition

Le théorème CAP

Quorums

### **BASES NOSQL**

Avantages et inconvénients

Modèles de données

- Key-Value
- Documents
- Column-Family
- Graph

Exemple : MongoDB

Les moteurs de recherche

## **JOUR 2**

## **HADOOP**

### Introduction à Hadoop

- Histoire
- Ecosystème

### HDFS

### Map-Reduce

- Les phases de Map-Reduce
- Notion de job
- Exemple

### YARN

### Les distributions

### La ligne de commande

### Administration d'un cluster

- Resource Manager
- History Server
- Hue

## **ÉTUDES DE CAS**

### Traitements de courbes de charge

- Contexte et hypothèses
- Raisonnements

### Analyse de logs

- Contexte et Hypothèses
- Raisonnements

## **CONCLUSION**

### Rappels des points abordés

Questions et réponses

Synthèse

### Jour 3

#### **DÉCOUVERTE DE SPARK**

Spark Core

- RDD
- Transformations
- Pair RDD

Spark SQL

Spark Streaming

Structured Streaming

---

#### **Accessibilité**

L'inclusion est sujet important pour OCTO Academy.

Nos référent-es sont à votre disposition pour faciliter l'adaptation de votre formation à vos besoins spécifiques.

Pour les contacter : [academy.accessibilite@octo.com](mailto:academy.accessibilite@octo.com)