Développer des applications pour Spark avec Hadoop Cloudera avec Certification

INFORMATIONS GÉNÉRALES

Type de formation : Formation continue

Éligible au CPF : Non

Domaine : IA, Big Data et Bases de données

Action collective : Non

Filière : Big Data

Rubrique : NoSQL et Hadoop

Code de formation : BD019

PRÉSENTATION

Objectifs & compétences

- Identifier et utiliser les outils appropriés à chaque situation dans un écosystème hadoop
- Utiliser Apache Spark et l'intégrer dans l'écosystème hadoop
- Utiliser Sqoop, Kafka, Flume, Hive et Impala

Public visé

Développeur Analyste

Pré-requis

- Être à l'aise pour programmer dans l'un de ces langages : Scala et/ou Python
- Connaissance de base des lignes de commande Linux requise
- La connaissance de base du SQL est un plus

PROGRAMME

1.Introduction à Hadoop et à son écosystème
1.1. Introduction générale à hadoop
1.2. Traitement de données
1.3. Introduction aux exercices pratiques

2.HDFS : le système de fichiers Hadoop
2.1. Les composants d'un cluster hadoop
2.2. L'architecture d'HDFS
2.3. Utiliser HDFS

3.Le traitement distribué sur un cluster Hadoop
3.1. L'architecture de YARN
3.2. Travailler avec YARN
4.Les bases de Spark
4.1. Introduction à Spark
4.2. Démarrer et utiliser la console Spark
4.3. Introduction aux Datasets et DataFrames Spark
4.4. Les opérations sur les DataFrames

5.Manipulation des dataframes et des schemas
5.1. Créer des DataFrames depuis diverses sources de données
5.2. Sauvegarder des DataFrames
5.3. Les schémas des DataFrames
5.4. Exécution gloutonne et paresseuse de Spark

6.Analyser des données avec des requêtes sur dataframes
6.1. Requêter des DataFrames avec des expressions sur les colonnes nommées
6.2. Les requêtes de groupement et d'aggrégation

€ Tarifs

Prix public : 4000 €

Tarif & financement :
Nous vous accompagnons pour trouver la meilleure solution de financement parmi les suivantes :
Le plan de développement des compétences de votre entreprise : rapprochez-vous de votre service RH.
Le dispositif FNE-Formation.
L'OPCO (opérateurs de compétences) de votre entreprise.
France Travail: sous réserve de l'acceptation de votre dossier par votre conseiller Pôle Emploi.
CPF -MonCompteFormation
Contactez nous pour plus d'information : contact@aston-institut.com

Lieux & Horaires

Durée : 28 heures

Délai d'accès : Jusqu'a 8 jours avant le début de la formation, sous condition d'un dossier d'insciption complet

Prochaines sessions

Consultez-nous pour les prochaines sessions.

Informations non contractuelles - PDF généré le 7/11/2026

6.3. Les jointures

7.Les RDD - Structure fondamentale de Spark
7.1. Introduction aux RDD
7.2. Les sources de données de RDD
7.3. Créer et sauvegarder des RDD
7.4. Les opérations sur les RDD

8.Transformer les données avec des RDD
8.1. Écrire et passer des fonctions de transformation
8.2. Fonctionnement des transformations de Spark
8.3. Conversion entre RDD et DataFrames

9.Agrégation de données avec les RDD de paires
9.1. Les RDD clé-valeur
9.2. Map-Reduce : principe et usage dans Spark
9.3. Autres opérations sur les RDD de paires

10.Requêtage de tables et de vues avec Spark SQL
10.1. Requêter des tables en Spark en utilisant SQL
10.2. Requêter des fichiers et des vues
10.3. L'API catalogue de Spark

11.Travailler avec des Datasets Spark en Scala
11.1. Les différences entre Datasets et DataFrames
11.2. Créer des Datasets
11.3. Charger et sauvegarder des Datasets
11.4. Les opérations sur les Datasets

12.Écrire, configurer et lancer des applications Spark
12.1. Écrire une application Spark
12.2. Compiler et lancer une application
12.3. Le mode de déploiement d'une application
12.4. L'interface utilisateur web des applications Spark
12.5. Configurer les propriétés d'une application

13.Le traitement distribué avec Spark
13.1. Rappels sur le fonctionnement de Spark avec YARN
13.2. Le partitionnement des données dans les RDD
13.3. Exemple : le partitionnement dans les requêtes
13.4. Jobs, étapes et tâches
13.5. Exemple : le plan d'exécution de Catalyst

MODALITÉS

Modalités

Modalités : en présentiel, distanciel ou mixte . Toutes les formations sont en présentiel par défaut mais les salles sont équipées pour faire de l'hybride. – Horaires de 9H à 12H30 et de 14H à 17H30 soit 7H – Intra et Inter entreprise.
Pédagogie : essentiellement participative et ludique, centrée sur l'expérience, l'immersion et la mise en pratique. Alternance d'apports théoriques et d'outils pratiques.
Ressources techniques et pédagogiques : Support de formation au format PDF ou PPT Ordinateur, vidéoprojecteur, Tableau blanc, Visioconférence : Cisco Webex / Teams / Zoom.
Pendant la formation : mises en situation, autodiagnostics, travail individuel ou en sous-groupe sur des cas réels.

Méthode

Fin de formation : entretien individuel.
Satisfaction des participants : questionnaire de satisfaction réalisé en fin de formation.
Assiduité : certificat de réalisation.
Validations des acquis : grille d'evalution des acquis établie par le formateur en fin de formation.

Informations non contractuelles - PDF généré le 7/11/2026