

Hadoop, développer des applications pour le Big Data

Cours Pratique de 4 jours - 28h

Réf : APH - Prix 2025 : 2 920 HT

Le prix pour les dates de sessions 2026 pourra être révisé

Ce cours pratique vous apprendra à développer des applications vous permettant de traiter des données distribuées en mode batch. Vous collecterez, stockerez et traiterez des données de formats hétérogènes avec Apache Hadoop afin de mettre en place des chaînes de traitement intégrées à votre système d'information.

OBJECTIFS PÉDAGOGIQUES

À l'issue de la formation l'apprenant sera en mesure de :

Construire un programme à base de MapReduce

Intégrer Hadoop HBase dans un workflow d'entreprise

Travailler avec Apache Hive et Pig depuis Hadoop Distributed File System (HDFS)

Utiliser un graphe de tâches avec Hadoop

MÉTHODES PÉDAGOGIQUES

Cours 30%, travaux pratiques 70%.

TRAVAUX PRATIQUES

Développement d'applications pour le big data.

LE PROGRAMME

dernière mise à jour : 07/2025

1) Le big data

- Définition du périmètre du big data.
- Le rôle du projet Hadoop.
- Les concepts de base des projets big data.
- Présentation du cloud computing.
- Différence entre cloud computing privé et public.
- Les architectures big data à base du projet Hadoop.

Démonstration : Usage d'Hadoop et de GoogleApp.

2) Collecte de données et application de MapReduce

- Analyse des flux de données dans l'entreprise.
- Données structurées et non-structurées.
- Les principes de l'analyse sémantique des données d'entreprise.
- Graphe des tâches à base de MapReduce.
- La granularité de cohérence des données.
- Transfert de données depuis un système de persistance dans Hadoop.
- Transfert de données d'un Cloud dans Hadoop.

Travaux pratiques : Gérer la collecte d'informations clientèles par MapReduce. Configuration de l'implémentation Yarn. Développement d'une tâche basée sur Map Reduce.

3) Le stockage des données avec HBase

- Plusieurs types de base de données XML.
- Patterns d'usages et application au cloud.
- Application de Hadoop database au sein d'un workflow.
- Utilisation des projets Hive/Pig.

PARTICIPANTS

Concepteurs, développeurs.

PRÉREQUIS

Bonne expérience en développement Java. Des connaissances en architecture web constituent un plus.

COMPÉTENCES DU FORMATEUR

Les experts qui animent la formation sont des spécialistes des matières abordées. Ils ont été validés par nos équipes pédagogiques tant sur le plan des connaissances métiers que sur celui de la pédagogie, et ce pour chaque cours qu'ils enseignent. Ils ont au minimum cinq à dix années d'expérience dans leur domaine et occupent ou ont occupé des postes à responsabilité en entreprise.

MODALITÉS D'ÉVALUATION

Le formateur évalue la progression pédagogique du participant tout au long de la formation au moyen de QCM, mises en situation, travaux pratiques...

Le participant complète également un test de positionnement en amont et en aval pour valider les compétences acquises.

MOYENS PÉDAGOGIQUES ET TECHNIQUES

- Les moyens pédagogiques et les méthodes d'enseignement utilisés sont principalement : aides audiovisuelles, documentation et support de cours, exercices pratiques d'application et corrigés des exercices pour les stages pratiques, études de cas ou présentation de cas réels pour les séminaires de formation.
- À l'issue de chaque stage ou séminaire, ORSYS fournit aux participants un questionnaire d'évaluation du cours qui est ensuite analysé par nos équipes pédagogiques.
- Une feuille d'émargement par demi-journée de présence est fournie en fin de formation ainsi qu'une attestation de fin de formation si le stagiaire a bien assisté à la totalité de la session.

MODALITÉS ET DÉLAIS D'ACCÈS

L'inscription doit être finalisée 24 heures avant le début de la formation.

ACCESSIBILITÉ AUX PERSONNES HANDICAPÉES

Pour toute question ou besoin relatif à l'accessibilité, vous pouvez joindre notre équipe PSH par e-mail à l'adresse psh-accueil@orsys.fr.

- Utilisation du projet HCatalog.

- L'API Java HBase.

Travaux pratiques : Gérer les modifications d'un catalogue de données fournisseur.

4) Le stockage des données sur HDFS

- Patterns d'usages et application au cloud.
- Architecture et installation d'un système HDFS, journal, NameNode, DataNode.
- Opérations, commandes et gestion des commandes.
- L'API HDFS Java.
- Analyse de données avec Apache Pig.
- Le langage Pig Latin. Utiliser Apache Pig avec Java.
- Requête avec Apache Hive.
- Réplication de données. Partage de données sur une architecture HDFS.

Travaux pratiques : Administrer un référentiel client partagé sur Hadoop. Utilisation de la console de visualisation.

5) Spring Data Hadoop

- Introduction à Spring et Spring Data.
- Le namespace Hadoop pour Spring.
- Utiliser Spring pour simplifier la configuration Hadoop.
- Configuration du cache distribué.
- Définition des jobs et dépendance entre jobs.
- Intégration des outils (Pig, Hive...).

Travaux pratiques : Refondre la gestion du catalogue de données fournisseur via Spring Data.

LES DATES

CLASSE À DISTANCE

2025 : 18 nov.

PARIS

2025 : 04 nov.

2026 : 03 mars, 26 mai, 06 oct.

2026 : 03 mars, 26 mai, 06 oct.