

Informations

Durée : 4 jours (28h.)

Tarif* : Nous consulter

Réf : HADO

Niveau : Moyen

intra

Mise à jour le 09/09/25

*tarif valable jusqu'au 31/12/2025

Prochaines sessions

Contactez-nous pour connaître nos futures sessions.

Pré-requis

- Expérience avec un langage de programmation comme Java, Python ou Scala
- Compréhension des systèmes de fichiers et de la gestion des fichiers (en particulier des concepts de stockage distribué)
- Connaissance de base des systèmes Unix/Linux
- Notions sur les bases de données

Objectifs

Objectifs pédagogiques :

- Concevoir, exécuter et tester des programmes écrits avec Map/Reduce
- Entrer et sortir des données de formats variés pour les traiter avec Hadoop
- Utiliser Hive pour pouvoir interroger le système de fichiers HDFS avec un langage analogue à SQL
- Utiliser Pig pour produire facilement des programmes Map-Reduce en langage de haut niveau

Objectifs opérationnels :

- Développer des applications pour le Big Data

Programme

Introduction

Problème des systèmes traditionnels à grande échelle

Qu'est-ce qu'Hadoop ?

Quels problèmes peut-on résoudre avec Hadoop ?

Les concepts fondamentaux et HDFS

Le projet Hadoop et ses composants

HDFS, le système de fichiers distribué

MapReduce

L'utilisation de MapReduce

L'analyse de données avec les outils Unix

L'analyse de données avec Hadoop

Mappers

Reducers

Combiners

Clusters Hadoop et écosystème

Cluster Hadoop : concepts

Jobs et tasks

Systèmes de fichiers

Programmation distribuée : MapReduce, Pig et Spark

Bases NoSQL : HBase et Cassandra

Accès SQL à Hadoop : Hive

Ingestion de données : Flume, Kafka et Sqoop

Planification des workflows Hadoop : Oozie

Machine Learning : Mahout et Weka

HDFS

Motivations et design

Blocs et nœuds

Interface en ligne de commande

Interface Java

Flux de données

HBase

Mise en place de clusters Hadoop

- Spécification du cluster
- Configuration et Installation
- Configuration d'Hadoop
- Configuration d'HDFS
- Monitoring et logging
- Maintenance

Entrer et sortir des données d'Hadoop

- ingress et egress : éléments-clés
- Entrer des données de log avec Apache Flume
- Programmation des entrées de données avec Oozie
- Importer/Exporter des données depuis des SGBDR avec Sqoop
- MapReduce et XML
- MapReduce et JSON
- MapReduce et formats personnalisés

L'API Hadoop pour Java

- Tests unitaires avec Hadoop
- Pertinence des tests unitaires
- Tester les mappers et reducers : JUnit et MRUnit
- Execution des tests
- LocalJobRunner

Pig

- Faciliter l'écriture de programmes MapReduce avec Pig
- L'installation et l'exécution
- Le langage de script : Pig Latin
- Les fonctions Utilisateurs (UDF)
- Les opérateurs de traitement de données

Hive

- Interroger et gérer de larges volumes de données avec Hive
- L'installation
- L'exécution
- La comparaison avec les bases de données traditionnelles
- HiveQL
- Tables
- L'interrogation des données
- La fonction utilisateurs

Réalisation d'une application complète avec Hadoop, Pig et Hive