

Formation Hadoop

Informations

Durée : 4 jours (28h.)

Tarif* : à partir de 1290 € HT

Réf : HADO

Niveau : Difficile

intra

*tarif valable jusqu'au 16/07/2024

Prochaines sessions

Contactez-nous pour connaître nos futures sessions.

Pré-requis

- Avoir des connaissances des principes de base Hadoop et des bases de données

Objectifs

- 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

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

Formation Hadoop

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