

Formation Pig, Hive et Impala

■ Durée :	4 jours (28 heures)
■ Tarifs inter-entreprise :	2 760,00 € HT (standard) 2 208,00 € HT (remisé)
■ Public :	techniciens et spécialistes des bases de données, responsables, analystes métier et professionnels BI, souhaitant utiliser les technologies Big Data dans leur entreprise
■ Pré-requis :	Connaissances fondamentales des bases de données et de SQL sont un atout majeur
■ Objectifs :	- Manipuler des ensembles de données complexes stockés dans Hadoop sans avoir à écrire de code complexe avec Java - Automatiser le transfert des données dans le stockage Hadoop avec Flume et Sqoop - Filtrer les données avec les opérations Extract-Transform-Load (ETL) avec Pig - Interroger plusieurs ensembles de données pour une analyse avec Pig et Hive
■ Modalités pédagogiques, techniques et d'encadrement :	• Formation synchrone en présentiel et distanciel. • Méthodologie basée sur l'Active Learning : 75 % de pratique minimum. • Un PC par participant en présentiel, possibilité de mettre à disposition en bureau à distance un PC et l'environnement adéquat. • Un formateur expert.
■ Modalités d'évaluation :	• Définition des besoins et attentes des apprenants en amont de la formation. • Auto-positionnement à l'entrée et la sortie de la formation. • Suivi continu par les formateurs durant les ateliers pratiques. • Évaluation à chaud de l'adéquation au besoin professionnel des apprenants le dernier jour de formation.
■ Sanction :	Attestation de fin de formation mentionnant le résultat des acquis
■ Référence :	BUS100295-F

■ Note de satisfaction des participants:	Pas de données disponibles
■ Contacts :	commercial@dawan.fr - 09 72 37 73 73
■ Modalités d'accès :	Possibilité de faire un devis en ligne (www.dawan.fr , moncompteformation.gouv.fr , maformation.fr , etc.) ou en appelant au standard.
■ Délais d'accès :	Variable selon le type de financement.
■ Accessibilité :	Si vous êtes en situation de handicap, nous sommes en mesure de vous accueillir, n'hésitez pas à nous contacter à referenthandicap@dawan.fr , nous étudierons ensemble vos besoins

Introduction

Vue d'ensemble de Hadoop
 Analyser les composants Hadoop
 Définir l'architecture Hadoop

Stocker les données dans HDFS

Réaliser un stockage fiable et sécurisé
 Surveiller les mesures du stockage
 Contrôler HDFS à partir de la ligne de commande

Traitement parallèle avec MapReduce

Détailler l'approche MapReduce
 Transférer les algorithmes et non les données
 Décomposer les étapes clés d'une tâche MapReduce

Automatiser le transfert des données

Faciliter l'entrée et la sortie des données
 Agréger les données avec Flume
 Configurer le fan in et le fan out des données
 Déplacer les données relationnelles avec Sqoop

Décrire les caractéristiques d'Apache Pig

Exposer les différences entre Pig et MapReduce
 Identifier les cas d'utilisation de Pig

Identifier les configurations clés de Pig

Structurer les données non structurées

Représenter les données dans le modèle de données de Pig

Exécuter les commandes Pig Latin au Grunt Shell

Exprimer les transformations dans la syntaxe Pig Latin

Appeler les fonctions de chargement et de stockage

Transformer les données avec les opérateurs relationnels

Créer des nouvelles relations avec des jointures

Réduire la taille des données par échantillonnage

Exploiter Pig et les fonctions définies par l'utilisateur

Filtrer les données avec Pig

Consolider les ensembles de données avec les unions

Partitionner les ensembles de données avec les splits

Ajouter des paramètres dans des scripts Pig

Exploiter les avantages métier de Hive

Factoriser Hive en composants

Imposer la structure sur les données avec Hive

Organiser les données dans Hive

Créer des bases de données et des tables Hive

Exposer les différences entre les types de données dans Hive

Charger et stocker les données efficacement avec SerDes

Concevoir la disposition des données pour la performance

Remplir les tables à partir de requêtes

Partitionner les tables de Hive pour des requêtes optimales

Composer des requêtes HiveQL

Réaliser des jointures sur des données non structurées

Distinguer les jointures disponibles dans Hive

Optimiser la structure des jointures pour les performances

Repousser les limites de HiveQL

Trier, répartir et regrouper des données

Réduire la complexité des requêtes avec les vues

Améliorer la performance des requêtes avec les index

Déployer Hive en production

Concevoir les schémas de Hive

Établir la compression des données

Déboguer les scripts de Hive

Rationaliser la gestion du stockage avec HCatalog

Unifier la vue des données avec HCatalog

Exploiter HCatalog pour accéder au metastore Hive

Communiquer via les interfaces HCatalog

Remplir une table Hive à partir de Pig

Traitement parallèle avec Impala

Décomposer les composants fondamentaux d'Impala

Soumettre des requêtes à Impala

Accéder aux données Hive à partir d'Impala

Lancer le framework Spark

Réduire le temps d'accès aux données avec Spark-SQL

Interroger les données Hive avec Spark-SQL