



Dask : mise en oeuvre, programmation

CB042

Durée: 3 jours

2 510 €

27 au 29 janvier
14 au 16 avril

7 au 9 juillet
3 au 5 novembre

Public :

Chefs de projet, Data Scientists, Développeurs, Architectes...

Objectifs :

Savoir mettre en oeuvre Dask pour paralléliser des calculs en Python

Connaissances préalables nécessaires :

Bases de la programmation python.

Objectifs pédagogiques :

Programme :

Introduction

Présentation de Dask, fonctionnalités, apports. Comparaison avec d'autres environnements : yarn, spark.
Calculs parallèles en environnements distribués, ou sur un seul serveur.
Les composants de Dask : scheduler, collections BigData.

Premiers pas avec Dask

Différentes méthodes d'installation : Anaconda, pip, depuis les sources

Atelier : installation, et création d'objets Dask,

choix des méthodes et tâches, visualisation des graphes d'exécution.
exécution par le scheduler



Elements de base

Array: cas d'usages, compatibilité NumPy, définition de chunks, exemples, bonnes pratiques

Atelier : création, stockage de Dask Array

Bag : définition, limites

Atelier : exemple de création, stockage, calcul sur des Dask Bags

Dask Dataframes : regroupement de dataframes pandas, stockage sur disque ou dans un cluster, critères de choix par rapport aux dataframes pandas, bonnes pratiques, compatibilité avec Parquet, intégration de tables SQL

Atelier : mise en oeuvre de dask.dataframes et comparaison avec pandas

Delayed ou Futures : une exécution stockée dans un graphe d'actions, ou en temps réel, critères de choix

Fonctionnement avancé

Gestion des performances
Configuration du scheduler
Les graphes d'exécution
Utilisation du dashboard
Outils de debugging

Atelier : tests de performances et debugging

Dask.distributed

Fonctionnalités : exécution dans un environnement distribué ou en local, outils de diagnostic et de suivi des performances, utilisation de l'API Futures pour des calculs en temps réel
Architecture : dask-scheduler et dask-worker

Atelier : mise en oeuvre de dask.distributed : installation, configuration, initialisation d'un client.

Présentation du dashboard
Analyse des performances
Limites de Dask.distributed
Bonnes pratiques

Dask-ML

Apports : utiliser les outils classiques de machine learning comme scikit-learn dans un environnement Dask
Exemples d'utilisation : modèles complexes, volumes de données importants
Présentation de Dask-ML et principe de fonctionnement
Intégration scikit-learn, PyTorch, Keras / Tensorflow

Atelier : Installation et exemples avec scikit-learn