

Formation Python - Calcul parallèle

Objectifs : Développer des compétences avancées pour exploiter efficacement les architectures de calcul parallèle en Python, en maîtrisant les techniques de multithreading, multiprocessing, calcul distribué et traitement GPU afin d'optimiser les performances des applications et workflows de traitement de données.

Compétences visées : - Appréhender le paysage de calcul parallèle avec Python

- Maîtriser les concepts et terminologies de la programmation parallèle
- Identifier les goulots d'étranglement et les parties parallélisables de votre programme
- Utiliser efficacement les bibliothèques de calcul parallèle en Python
- Savoir développer des applications parallélisées (multithreading, multiprocessing, calcul distribué, cloud computing)
- Exécuter des calculs sur GPU (cartes graphiques)
- Créer des workflows de traitement de données

Durée : 5 jour(s) (35 heures)

Public : Développeurs, chefs de projets, data scientists développant des applications scientifiques requérant d'importantes capacités de calculs

Pré-requis : Pour suivre ce stage dans de bonnes conditions, il est recommandé d'avoir suivi en amont la formation [Python - Bases et introduction aux bibliothèques scientifiques](#)

Méthode pédagogique : Cette formation est majoritairement pratique. L'ensemble des TP sera réalisé sur des machines louées dans le cloud et dotées de cartes graphiques NVIDIA ainsi que sur les postes des participants. Les concepts présentés font l'objet de TP d'illustration afin de permettre leur assimilation. Environ 70% du temps est consacré à la pratique des bibliothèques présentées. L'interactivité est garantie au travers de TP réalisés en majeure partie sur les notebooks Jupyter/Lab.

Pédagogie active mêlant exposés, exercices et applications pratiques dans le logiciel Python.

Modalités d'évaluation : Un formulaire d'auto-évaluation proposé en amont de la formation nous permettra d'évaluer votre niveau et de recueillir vos attentes. Ce même formulaire soumis en aval de la formation fournira une appréciation de votre progression.

Des exercices pratiques seront proposés à la fin de chaque séquence pédagogique pour l'évaluation des acquis.

En fin de formation, vous serez amené(e) à renseigner un questionnaire d'évaluation à chaud.

Une attestation de formation vous sera adressée à l'issue de la session.

Trois mois après votre formation, vous recevrez par email un formulaire d'évaluation à froid sur l'utilisation des acquis de la formation.

Accessibilité : Vous souhaitez suivre notre formation Formation par ville et êtes en situation de handicap ? Merci de nous contacter afin que nous puissions envisager les adaptations nécessaires et vous garantir de bonnes conditions d'apprentissage

Tarifs :

- Présentiel : 3250 € HT

- Distantiel : 3000 € HT
(-10% pour 2 inscrits, -20% dès 3 inscrits)

Option(s) :

- Forfait déjeuners : 100 € HT

Nos prochaines sessions

Distance

du 25 au 29 novembre 2024

du 1 au 5 avril 2025

du 24 au 28 novembre 2025

Lyon

du 12 au 16 mai 2025

du 3 au 7 novembre 2025

Paris

du 9 au 13 décembre 2024

du 23 au 27 juin 2025

du 8 au 12 décembre 2025

Toulouse

du 14 au 18 avril 2025

du 13 au 17 octobre 2025

Programme :

- Etat de l'art de la discipline et concepts de base

- Historique des supercalculateurs
- Comprendre les différentes architectures disponibles pour le calcul parallèle (CPU, GPU, TPU, ASIC, FPGA, NUMA...)
- Tout n'est pas parallélisable : comprendre les limites de la programmation parallèle
- Présentation du paysage de calcul parallèle avec Python

Travaux pratiques

Identifier les capacités matérielles de votre ordinateur. Mesurer les performances/limites de votre configuration (disques, mémoire, processeurs, ...).

Configurer son environnement de calcul parallèle.

Administrer une ferme de serveurs avec ansible

- Les concepts de la programmation parallèle

- Comprendre la terminologie: programmation asynchrone, concurrente, distribuée, multithreading, multiprocessing, ...
- Multithreading : paralléliser le code de votre programme - mise en oeuvre des concepts de base
- Comprendre les limites du multithreading en Python
- Multiprocessing : paralléliser votre programme sur plusieurs processeurs et mécanismes de synchronisation (verrous, sémaphores, barrières, pools de process...)

Travaux pratiques

Application des concepts de base aux travers d'exercices pratiques.

Mesurer les différences de performances entre les bibliothèques multithreading et multiprocessing.

Premier cluster de calcul distribué avec les Managers et Proxy.

- Le calcul sur GPU

Un GPU ne se programme pas comme un CPU.

- Comprendre les architectures GPU : kernels, mémoire, threads, ...
- Travailler avec des cartes graphiques externes (eGPU)
- Mise en œuvre des principales bibliothèques Python pour GPU: Cupy, PyCUDA, Numba et RapidsAI

Travaux pratiques

Identifier quand un GPU devient plus intéressant qu'un CPU.

Traitement d'images, calcul matriciel, tester la fiabilité d'un mot de passe, ...

- Calcul distribué

- Les principales bibliothèques : Celery, Dask et PySpark
- Déployer et superviser un cluster de calcul parallèle avec chacune des bibliothèques
- Exécuter des calculs sur un cluster

Travaux pratiques

Batch de tâches avec Celery.

Calcul numérique et analyse de données avec Dask (array et dataframe)

Analyse de données avec les DataFrames Spark et la bibliothèque Koalas.

- Créer un pipeline de traitement de données

- Présentation des bibliothèques Luigi et Airflow
- Concevoir et superviser son workflow

Travaux pratiques

Réaliser un workflow sur un ensemble de fichiers volumineux et le superviser avec Airflow.

- Tour d'horizon des autres bibliothèques Python pour le calcul parallèle

- La compilation Just In Time avec Numba
- Greenlets : vers un meilleur multithreading
- MPI4Py : Message Passing Interface
- Pythran : Le transpileur qui convertit votre code Python en C++

Travaux pratiques

Exercices de base illustrant les principes de chacune des bibliothèques

Date de dernière modification : 5 novembre 2024