

Cursus Data Scientist

Cursus Métier

 Présentiel ou en classe à distance



18 jours (126 h)

Prix inter : 11.990,00 € HT

Réf.: CM060

Les entreprises collectent aujourd'hui de tels volumes d'informations que leur exploitation avec des méthodes traditionnelles est devenue impossible. Pourtant, ces informations sont des mines d'or ! Mais encore faut-il savoir les traiter, les analyser et en tirer la substantifique moelle. C'est précisément la mission qui incombe au Data Scientist qui en imaginant de nouveaux modèles et en utilisant de nouveaux outils va donner du sens aux données et en extraire de la valeur pour aider l'entreprise à prendre des décisions. A la fois spécialiste des données, des chiffres, des statistiques, des outils informatiques et grand connaisseur du secteur pour lequel il analyse des données, le Data Scientist est aussi un créatif qui doit savoir utiliser les outils de restitution de données pour restituer de façon claire et convaincante le résultat de ses analyses.

A qui s'adresse cette formation ?



Pour qui

- Analystes
- Statisticiens
- Spécialistes BI
- Toute personne souhaitant évoluer vers une fonction de Data Scientist



Prérequis

- La connaissance du langage SQL est nécessaire pour suivre ce cursus. Il est conseillé d'avoir suivi la formation **"Interroger des bases de données avec le langage SQL" (LA300)** ou de disposer des connaissances équivalentes
- Disposer de connaissances en statistiques ou avoir suivi la formation **"Les fondamentaux de la statistique appliquée" (BI090)**
- **Disposez-vous des connaissances nécessaires pour suivre cette formation ? Testez-vous !**

Programme

Avant la session

- Un quiz de consolidation des prérequis

En présentiel / A distance

1 - Big Data - Les fondamentaux de l'analyse de données (3j)

- Objectif : Disposer des connaissances et compétences nécessaires pour identifier et collecter des données et s'assurer de leur qualité et de leur alignement sur les besoins et usages métiers de l'entreprise
- Les nouvelles frontières du Big Data (introduction) : immersion, l'approche des 4 Vs, cas d'usages du Big Data, technologies, architecture, master-slaves vs master-slaves, stockage, Machine Learning, Data Scientist et Big Data, compétences, la vision du Gartner, valeur ajoutée du Big Data
- La collecte des données : typologie des sources, les données non structurées, typologie 3V des sources, les données ouvertes (Open Data), nouveau

paradigme de l'ETL à l'ELT, le concept du Data Lake, les API de réseaux sociaux, ...

- Le calcul massivement parallèle : genèse et étapes clés, Hadoop, HDFS, MapReduce, Apache PIG et Apache HIVE, comparatif des 3 approches, limitations de MapReduce, moteur d'exécution Apache TEZ, la rupture Apache SPARK, Hive in Memory (LLAP), Big Deep Learning, ...
- Les nouvelles formes de stockage : enjeux, le "théorème" CAP, nouveaux standards : ACID => BASE, panorama des bases de données NoSQL, bases de données Clé-Valeur, bases de données Document, bases de données colonnes, bases de données Graphes, ...
- Le Big Data Analytics (fondamentaux) : analyse de cas concrets, que peuvent apprendre les machines ? , les différentes expériences (E), l'apprentissage, choisir un algorithme d'apprentissage machine, anatomie d'un modèle d'apprentissage automatique, les librairies de machine learning standards et Deep Learning, les plates-formes de Data Science
- Le Big Data Analytics (écosystème SPARK) : les différents modes de travail, les 3 systèmes de gestion de cluster, modes d'écriture des commandes Spark, machine learning avec Spark , travail sur les variables prédictives, la classification et la régression
- Traitement en flux du Big Data (streaming) : architectures types de traitement de Streams Big Data, Apache NIFI, Apache KAFKA, articulation NIFI et KAFKA, Apache STORM, articulation KAFKA et STORM, comparatif STORM/SPARK
- Déploiement d'un projet Big Data : Cloud Computing , 5 caractéristiques essentielles, 3 modèles de services, modes (SaaS , PaaS, IaaS), Cloud Privé virtuel (VPC), focus AWS, GCP et Azure
- Hadoop écosystème et distributions : écosystème, fonctions coeurs, HDFS, Map Reduce, infrastructure YARN, distributions Hadoop, focus Cloudera, Focus Hortonworks,...
- Architecture de traitement Big Data : traitement de données par lots, traitement de données en flux, modèles d'architecture de traitement de données Big Data, l'heure du choix
- La gouvernance des données Big Data : outils de gouvernance Big Data, les 3 piliers, le management de la qualité des données, le management des métadonnées Big Data, management de la sécurité, de la conformité et la confidentialité

2 - Les fondamentaux de l'analyse statistique avec R (3j)

- Objectif : Disposer des connaissances nécessaires pour utiliser le logiciel libre de traitement des données "R" qui permet de réaliser des analyses statistiques et de les restituer sous forme graphique
- Introduction : présentation de R
- Installation de R ou Microsoft R Open sur MS Windows ou Scientific Linux
- Utilisation : console de commande, dossier de travail, espace de travail, historique des commandes, script
- Manipulation de packages : installation, désinstallation, mise à jour
- Types de données : manipulations de scalaires, de nombres complexes, de variables, de vecteurs, de matrices, de textes, de dates et de durées
- Import et export de données : données Excel, Access, csv, xml, json, MySQL, Oracle, fichiers SAS
- Manipulation de données : utilisation du SQL, data frames, tris, filtres, fusions, doublons
- Analyse de données : synthèses, valeurs absentes, variables pseudo-aléatoires, statistiques descriptives, intégration numérique et algébrique

3 - Analyse statistique avancée avec R (3j)

- Objectif : Être en mesure d'exploiter les fonctionnalités avancées de R et être ainsi à même d'analyser tous types de données dans un projet Big Data
- Introduction : analyses avancées avec R
- Travailler avec des échantillons
- Réaliser des tests d'ajustement : tests d'Anderson-Darling et de Shapiro-Wilk
- Estimation et intervalles de confiance
- Analyses statistiques avancées : test t-Student, test de Poisson, test binomial exact, proportions, transformations de Box-Cox et de Johnson
- Analyse de la variance et de la covariance : ANOVA à facteur(s) fixe(s), test de Student, test de Tukey HSD, test de Levene et Bartlett, ACP, AFE

4 - Les bases de l'apprentissage Machine (Machine Learning) (3j)

- Objectif : Maîtriser le Data Mining et le Machine Learning pour explorer de très importants volumes de données et construire des modèles répondant aux problèmes très variés des entreprises
- L'apprentissage machine : champs de compétences, focus : Data Science, Machine Learning, Big Data, Deep Learning, définition de l'apprentissage machine, les différents modes d'entraînement
- Les fondamentaux de l'apprentissage machine : préambule, jeux de données d'entraînement, fonctions hypothèses, fonctions de coûts, algorithmes d'optimisations
- La classification : introduction, la régression logistique, SVM, arbres de décision, K plus proches voisins (kNN), synthèse
- Les pratiques : prétraitement, ingénierie des variables prédictives (feature engineering), réglages des hyper-paramètres et évaluation des modèles, synthèse
- L'apprentissage d'ensembles (ensemble learning) : introduction, l'approche par vote, une variante, le bagging, les forêts aléatoires, le boosting, la variante Adaboost, gradient boosting, fiches synthèses
- La régression : régression linéaire simple et multi-variée, relations entre les variables, valeurs aberrantes, évaluation de la performance des modèles de régression, régularisation des modèles de régression linéaire, régression polynomiale, régression avec les forêts aléatoires, synthèse
- Le clustering : introduction, regroupement d'objets par similarité avec les k-moyens, k-means, l'inertie d'un cluster, variante k-means++, clustering flou, clustering hiérarchique, clustering par mesure de densité DBSCAN, autres approches du clustering, synthèse

5 - Big Data : mise en oeuvre pratique d'une solution complète d'analyse des données (4j)

- Objectif : Savoir mettre en oeuvre une solution complète de Big Data en environnement Hadoop et disposer des compétences nécessaires au traitement et à l'analyse des données
- Introduction : objectifs, schématisation du projet, écosystème et stack technologique, résultats attendus
- Ingestion de données massives : description, caractéristiques clés des outils d'ingestion, focus Apache NIFI et KAFKA, ingestion de données en streaming NIFI sur KAFKA, réalisation d'un workflow NIFI d'ingestion de donnée streaming dans HDFS
- Traitement de données Big Data en batch : diagramme de fonctionnement, solutions logicielles associées, Big Data Batch scripting, Data Warehousing Big Data, Big Data analytics
- Traitement avancé Big Data : l'apprentissage machine, l'écosystème Spark, création d'un modèle de ML, d'un modèle de clusterisation de données, d'un modèle d'analyse prédictive supervisé, application d'un modèle ML

- Stockage de données distribuées : principes des bases de données distribuées, solutions (NoSQL, NewSQL), création, ingestion de données et interrogation d'une base de données distribuées
- Automatisation de chaîne de traitement Batch : l'orchestrateur Oozie, ordonnancement de scripts HIVE, combinaison avec des scripts SPARK
- Traitement de données massives en flux (streaming) : principe de fonctionnement, solutions logicielles, l'inscription de streams à un Hub Streaming, le traitement avancé de données en flux (machine learning)
- Mise en oeuvre dans une architecture Big Data : approches standards, réalisation d'une solution complète de traitement de données de type Lambda ou Kappa

6 - Big Data - Analyse, Data Visualisation et introduction au Data StoryTelling pour la restitution de données (2j)

- Objectif : Être en mesure de concevoir des modèles de documents adaptés aux besoins métiers de l'entreprise et savoir mettre en oeuvre différentes techniques de visualisation graphique, de mise en récit et de présentation permettant de valoriser les données
- Data Visualisation ou la découverte de la grammaire graphique : des chiffres aux graphiques, les 3 dimensions, Tableau Software, de l'idée d'un graphique à sa formalisation dans un outil
- Data Storytelling : présentation, exemples, techniques et outils de la mise en récit des données, Storytelling des idées et des données
- Comment construire son histoire : pitch, scénario, schéma narratif, méthodologies
- Les outils : fonctions de Storytelling des outils de BI, le module Data Storytelling de Tableau Software, autres outils

Après la session

- Un vidéocast "L'écosystème Hadoop"
- Deux vidéos-tutos "Installation d'un environnement Hadoop de base" et "Développement d'un premier MapReduce"



Les objectifs de la formation

- Disposer d'une vision claire du Big Data, de ses enjeux, de son écosystème et des principales technologies et solutions qui y sont associées
- Maîtriser le cycle de vie de la donnée et savoir garantir la qualité des données
- Être en mesure d'aligner les usages métiers avec le cycle de vie de la donnée
- Savoir utiliser R pour analyser des données et restituer des résultats à l'aide de graphiques
- Comprendre comment utiliser des algorithmes d'auto-apprentissage adaptés à une solution d'analyse
- Disposer des compétences techniques nécessaires à réalisation d'analyses Big Data
- Maîtriser la boîte à outils technologique que constitue Hadoop et son écosystème et savoir comment PIG, HIVE, MapR...
- Savoir concevoir des modèles de documents et des graphiques répondant aux attentes de l'entreprise, en fonction du sujet analysé



Evaluation

- Pendant la formation, le formateur évalue la progression pédagogique des participants via des QCM, des mises en situation et des travaux pratiques. Les participants passent un test de positionnement avant et après la formation pour valider leurs compétences acquises.



Les points forts de la formation

- Chaque participant établit son propre planning de formation. En fonction de la date de début choisie parmi celles proposées ci-dessous, nos Conseillers Formation proposent différentes dates pour chacun des modules du cursus. Pour des raisons d'efficacité pédagogique, il est fortement recommandé de suivre les modules dans l'ordre présenté sur ce programme.
- L'alternance de formations et de périodes de mise en pratique en entreprise favorise l'acquisition rapide et durable de nouveaux savoirs.
- Animé par un expert spécialiste du sujet traité, chacun des 6 modules aborde un aspect spécifique de la thématique de formation.
- A travers de nombreuses mises en situation, les participants mettront en pratique les aspects théoriques abordés au cours des différentes étapes du cursus.





Dates et villes 2026 - Référence CM060



Dernières places disponibles



Session garantie

Lyon

du 5 janv. au 3 juil.
du 18 mai au 13 nov.

du 7 sept. au 5 mars
du 21 déc. au 18 juin

Rennes

du 5 janv. au 3 juil.
du 18 mai au 13 nov.

du 5 oct. au 2 avr.
du 21 déc. au 18 juin

Paris

du 5 janv. au 3 juil.
du 16 mars au 11 sept.
du 18 mai au 13 nov.

du 20 juil. au 15 janv.
du 7 sept. au 5 mars
du 5 oct. au 2 avr.

du 21 déc. au 18 juin

Strasbourg

du 5 janv. au 3 juil.
du 18 mai au 13 nov.

du 7 sept. au 5 mars
du 5 oct. au 2 avr.

A distance

du 5 janv. au 3 juil.
du 16 mars au 11 sept.
du 18 mai au 13 nov.

du 20 juil. au 15 janv.
du 7 sept. au 5 mars
du 5 oct. au 2 avr.

du 21 déc. au 18 juin

Nantes

du 5 janv. au 3 juil.
du 18 mai au 13 nov.

du 5 oct. au 2 avr.
du 21 déc. au 18 juin

Rouen

du 5 janv. au 3 juil.
du 18 mai au 13 nov.

du 7 sept. au 5 mars
du 5 oct. au 2 avr.

Toulouse

du 5 janv. au 3 juil.
du 16 mars au 11 sept.

du 20 juil. au 15 janv.
du 5 oct. au 2 avr.

Bordeaux

du 5 janv. au 3 juil.
du 18 mai au 13 nov.

du 7 sept. au 5 mars
du 21 déc. au 18 juin

Sophia Antipolis

du 5 janv. au 3 juil.
du 18 mai au 13 nov.

du 7 sept. au 5 mars
du 5 oct. au 2 avr.

Marseille

du 16 mars au 11 sept.
du 20 juil. au 15 janv.

du 7 sept. au 5 mars
du 21 déc. au 18 juin

Lille

du 16 mars au 11 sept.
du 20 juil. au 15 janv.

du 7 sept. au 5 mars
du 21 déc. au 18 juin

Aix-en-Provence

du 16 mars au 11 sept.
du 20 juil. au 15 janv.

du 7 sept. au 5 mars
du 21 déc. au 18 juin