

Data Scientist



Informatique

Référence formation : 4-IT-DAS - Durée : 5 jours

Objectifs

Savoir mettre en place un DataLake et un DataMart en SQL ou big data Savoir mettre en place une stratégie de Machine Learning en Python afin de créer le modèle le plus satisfaisant possible en le mesurant et en affichant les résultats, le tout, en utilisant des algorithmes performants

Pré-requis

Maîtriser l'algorithmique, avoir une appétence pour les mathématiques La connaissance de Python et des statistiques est un plus

Contenu pédagogique

Introduction aux Data Sciences

- Qu'est que la data science ?
- Qu'est-ce que Python ?
- Qu'est que le Machine Learning ?
- Apprentissage supervisé vs non supervisé
- Les statistiques
- La randomisation
- La loi normale

Introduction à Python pour les Data Science

- Les bases de Python
- Les listes
- Les tuples
- Les dictionnaires
- Les modules et packages
- L'orienté objet
- Le module math
- Les expressions lambda
- Map, reduce et filter



XXL Formation

34 rue Raymond Aron
76130 Mont Saint Aignan

Tél : 02 35 12 25 55 – Fax : 02 35 12 25 56

N° siret : 485 050 611 00014 – N° d'agrément : 23.76.03752.76

- Le module CSV
- Les modules DB-API 2 Anaconda

Introduction aux DataLake, DataMart et DataWharehouse

- Qu'est-ce qu'un DataLake ?
- Les différents types de DataLake
- Le Big Data
- Qu'est-ce qu'un DataWharehouse ?
- Qu'est qu'un DataMart ?
- Mise en place d'un DataMart
- Les fichiers
- Les bases de données SQL
- Les bases de données No-SQL

Python Package Installer

- Utilisation de PIP
- Installation de package PIP PyPi

MathPlotLib

- Utilisation de la bibliothèque scientifique de graphes MathPlotLib
- Affichage de données dans un graphique 2D
- Affichages de sous-graphes
- Affichage de polynômes et de sinusoïdales

Machine Learning

- Mise en place d'une machine learning supervisé
- Qu'est qu'un modèle et un dataset
- Qu'est qu'une régression
- Les différents types de régression
- La régression linéaire
- Gestion du risque et des erreurs
- Quarter d'Ascombe
- Trouver le bon modèle
- La classification
- Loi normale, variance et écart type
- Apprentissage
- Mesure de la performance No Fee Lunch

La régression linéaire en Python



XXL Formation

34 rue Raymond Aron
76130 Mont Saint Aignan

Tél : 02 35 12 25 55 – Fax : 02 35 12 25 56

N° siret : 485 050 611 00014 – N° d'agrément : 23.76.03752.76

- Programmer une régression linéaire en Python
- Utilisation des expressions lambda et des listes en intention
- Afficher la régression avec Mathplotlib
- L'erreur quadratique
- La variance
- Le risque

Le Big Data

- Qu'est-ce que Apache Hadoop ?
- Qu'est-ce que l'informatique distribué ?
- Installation et configuration de Hadoop
- HDFS
- Création d'un datanode
- Création d'un namenode distribué
- Manipulation de HDFS
- Hadoop comme DataLake
- Map Reduce
- Hive
- Hadoop comme DataMart
- Python HDFS

Les bases de données NoSql

- Les bases de données structurées
- SQL avec SQLite et Postgresql
- Les bases de données non ACID
- JSON
- MongoDB
- Cassandra, Redis, CouchDb
- MongoDB sur HDFS
- MongoDB comme DataMart PyMongo

Numpy et SciPy

- Les tableaux et les matrices
- L'algèbre linéaire avec Numpy
- La régression linéaire SciPy
- Le produit et la transposée
- L'inversion de matrice
- Les nombres complexes
- L'algèbre complexe
- Les transformées de Fourier Numpy et Mathplotlib



XXL Formation

34 rue Raymond Aron
76130 Mont Saint Aignan

Tél : 02 35 12 25 55 – Fax : 02 35 12 25 56

N° siret : 485 050 611 00014 – N° d'agrément : 23.76.03752.76

ScikitLearn

- Régressions polynomiales
- La régression linéaire
- La création du modèle
- L'échantillonnage
- La randomisation
- L'apprentissage avec fit
- La prédiction du modèle
- Les metrics
- Choix du modèle
- PreProcessing et Pipeline
- Régressions non polynomiales

Nearest Neighbors

- Algorithme des k plus proches voisins (k-NN)
- Modèle de classification
- K-NN avec SciKitLearn
- Choix du meilleur k
- Sérialisation du modèle
- Variance vs Erreurs
- Autres modèles : SVN, Random Forest

Pandas

- L'analyse des données avec Pandas
- Les Series
- Les DataFrames
- La théorie ensembliste avec Pandas
- L'importation des données CSV
- L'importation de données SQL
- L'importation de données MongoDB Pandas et SKLearn

Le Clustering

- Regroupement des données par clusterisation
- Les clusters SKLearn avec k-means
- Autres modèles de clusterisation : AffinityPropagation, MeanShift, ...
- L'apprentissage semi-supervisé

Jupyter

- Présentation de Jupyter et lpython



XXL Formation

34 rue Raymond Aron
76130 Mont Saint Aignan

Tél : 02 35 12 25 55 – Fax : 02 35 12 25 56

N° siret : 485 050 611 00014 – N° d'agrément : 23.76.03752.76

- Installation
- Utilisation de Jupyter avec Mathplotlib et Sklearn

Python Yield

- La programmation efficace en Python
- Le générateurs et itérateurs
- Le Yield return
- Le Yield avec Db-API 2, Pandas et Sklearn

Les réseaux neuronaux

- Le perceptron
- Les réseaux neuronaux
- Les réseaux neuronaux supervisés
- Les réseaux neuronaux semi-supervisés
- Les réseaux neuronaux par Hadoop Yarn
- Les heuristiques
- Le deep learning

Organisation	Les sessions de formation ont lieu de 9h00 à 12h30 et de 13h30 à 17h00
Profil formateur	<ul style="list-style-type: none">• Nos formateurs sont des experts dans leurs domaines d'intervention• Leur expérience de terrain et leurs qualités pédagogiques constituent un gage de qualité
Moyens pédagogiques	<ul style="list-style-type: none">• Réflexion de groupe et apports théoriques du formateur.• Travail d'échange avec les apprenants sous forme de réunion - discussion.• Utilisation de cas concrets issus de l'expérience professionnelle.• Validation des acquis par des questionnaires, des tests d'évaluation, des mises en situation et des jeux pédagogiques.• Alternance entre apports théoriques et exercices pratiques (en moyenne sur 30 à 50% du temps)
Moyens techniques en formation <u>présentielle</u>	Accueil des apprenants dans une salle dédiée à la formation et équipée avec : <ul style="list-style-type: none">• Ordinateurs• Vidéo projecteur ou Écran TV interactif• Tableau blanc ou Paper-Board
Moyens techniques en formation <u>distancielle</u>	A l'aide d'un logiciel comme © Microsoft Teams ou Zoom, un micro et une caméra pour l'apprenant. <ul style="list-style-type: none">• Suivez une formation en temps réel et entièrement à distance. Lors de la session en ligne, les apprenants interagissent et communiquent



XXL Formation

34 rue Raymond Aron
76130 Mont Saint Aignan

Tél : 02 35 12 25 55 – Fax : 02 35 12 25 56

N° siret : 485 050 611 00014 – N° d'agrément : 23.76.03752.76

	<p>entre eux et avec le formateur.</p> <ul style="list-style-type: none">• Les formations en distanciel sont organisées en Inter-Entreprise comme en Intra-Entreprise.• L'accès à l'environnement d'apprentissage (support de cours, ressources formateur, fichiers d'exercices ...) ainsi qu'aux preuves de suivi et d'assiduité (émargement, évaluation) est assuré.• Les participants recevront une convocation avec le lien de connexion à la session de formation.• Pour toute question avant et pendant le parcours, une assistance technique et pédagogique est à disposition par téléphone au 02 35 12 25 55 ou par email à commercial@xxlformation.com
Modalités d'évaluation	<ul style="list-style-type: none">• Positionnement préalable oral ou écrit.• Feuille de présence signée en demi-journée.• Evaluation des acquis tout au long de la formation.• Questionnaire de satisfaction• Attestation de stage à chaque apprenant• Evaluation formative tout au long de la formation.• Evaluation sommative faite par le formateur ou à l'aide de la certification NULL : https://www.francecompetences.fr/recherche/NULL
Public concerné	Salariés - Demandeur d'emploi - Reconversion professionnelle
Adaptation pédagogique et matérielle	Si vous avez besoin d'adaptation matérielle ou pédagogique, merci de prendre contact avec notre référent Handicap par téléphone au 02 35 12 25 55 ou par email à handicap@xxlformation.com

**XXL Formation**

34 rue Raymond Aron
76130 Mont Saint Aignan

Tél : 02 35 12 25 55 – Fax : 02 35 12 25 56

N° siret : 485 050 611 00014 – N° d'agrément : 23.76.03752.76