

Stage pratique de 4 jour(s)
Réf : BDA

Participants

Responsables Infocentre
(Datamining, Marketing,
Qualité...), utilisateurs et
gestionnaires métiers de
bases de données.

Pré-requis

Connaissances de base en
statistiques ou avoir suivi le
stages "Statistiques, maîtriser
les fondamentaux" (Réf. STA).
Connaissances de base en
Python.

Prix 2020 : 2580€ HT

Dates des sessions

AIX

03 mar. 2020, 30 juin 2020
25 août. 2020, 01 déc. 2020

ANGERS

16 juin 2020, 25 août. 2020
17 nov. 2020

BORDEAUX

25 fév. 2020, 23 juin 2020
01 sep. 2020, 24 nov. 2020

BRUXELLES

14 avr. 2020, 20 oct. 2020
15 déc. 2020

DIJON

10 mar. 2020, 07 juil. 2020
15 sep. 2020, 17 nov. 2020

GENEVE

17 mar. 2020, 16 juin 2020
22 sep. 2020, 15 déc. 2020

GRENOBLE

16 juin 2020, 25 août. 2020
17 nov. 2020

LILLE

16 juin 2020, 25 août. 2020
17 nov. 2020

LIMOGES

25 fév. 2020, 23 juin 2020
01 sep. 2020, 24 nov. 2020

LUXEMBOURG

17 mar. 2020, 16 juin 2020
22 sep. 2020, 15 déc. 2020

LYON

10 mar. 2020, 07 juil. 2020
15 sep. 2020, 17 nov. 2020

MONTPELLIER

10 mar. 2020, 07 juil. 2020
15 sep. 2020, 17 nov. 2020

NANCY

25 fév. 2020, 23 juin 2020
01 sep. 2020, 24 nov. 2020

NANTES

16 juin 2020, 25 août. 2020
17 nov. 2020

NIORT

16 juin 2020, 25 août. 2020
17 nov. 2020

ORLEANS

16 juin 2020, 20 oct. 2020
15 déc. 2020

PARIS

Big Data Analytics avec Python

modélisation et représentation des données

Le Big Data Analytics repose sur la maîtrise des techniques d'exploration de données fondamentales : statistiques descriptives, prédictives ou exploratoires. Ce stage pratique vous présentera des méthodes telles que les régressions et les ACP et vous apprendra à les mettre en œuvre avec le logiciel Python.

OBJECTIFS PEDAGOGIQUES

Comprendre le principe de la modélisation statistique
Choisir entre la régression et la classification en fonction du type de données
Évaluer les performances prédictives d'un algorithme
Créer des sélections et des classements dans de grands volumes de données pour dégager des tendances

1) Introduction à la modélisation

2) Procédures d'évaluation de modèles

3) Les algorithmes supervisés

4) Les algorithmes non supervisés

5) Analyse en composantes

6) Analyse de données textuelles

Travaux pratiques

Développement/réalisation d'analyses sur le logiciel Python, avec les modules pandas, NumPy, SciPy, Matplotlib, seaborn, scikit-learn et statsmodels.

1) Introduction à la modélisation

- Introduction au langage Python.
- Introduction au logiciel Jupiter Notebook.
- Les étapes de construction d'un modèle.
- Les algorithmes supervisés et non supervisés.
- Le choix entre la régression et la classification.

Travaux pratiques

Installation de Python 3, d'Anaconda et de Jupiter Notebook.

2) Procédures d'évaluation de modèles

- Les techniques de ré-échantillonnage en jeu d'apprentissage, de validation et de test.
- Test de représentativité des données d'apprentissage.
- Mesures de performance des modèles prédictifs.
- Matrice de confusion, de coût et la courbe ROC et AUC.

Travaux pratiques

Mise en place d'échantillonnage de jeux de données. Effectuer des tests d'évaluations sur plusieurs modèles fournis.

3) Les algorithmes supervisés

- Le principe de régression linéaire univariée.
- La régression multivariée.
- La régression polynomiale.
- La régression régularisée.
- Le Naive Bayes.
- La régression logistique.

Travaux pratiques

Mise en œuvre des régressions et des classifications sur plusieurs types de données.

4) Les algorithmes non supervisés

- Le clustering hiérarchique.
- Le clustering non hiérarchique.
- Les approches mixtes.

Travaux pratiques

Traitements de clustering non supervisés sur plusieurs jeux de données.

5) Analyse en composantes

- Analyse en composantes principales.
- Analyse factorielle des correspondances.
- Analyse des correspondances multiples.
- Analyse factorielle pour données mixtes.
- Classification hiérarchique sur composantes principales.

Travaux pratiques

18 fév. 2020, 17 mar. 2020
14 avr. 2020, 12 mai 2020
16 juin 2020, 21 juil. 2020
25 août. 2020, 22 sep. 2020
20 oct. 2020, 17 nov. 2020
15 déc. 2020

REIMS

17 mar. 2020, 16 juin 2020
22 sep. 2020, 15 déc. 2020

RENNES

03 mar. 2020, 30 juin 2020
25 août. 2020, 01 déc. 2020

ROUEN

17 mar. 2020, 16 juin 2020
22 sep. 2020, 15 déc. 2020

SOPHIA-ANTIPOLIS

16 juin 2020, 25 août. 2020
17 nov. 2020

STRASBOURG

03 mar. 2020, 30 juin 2020
25 août. 2020, 01 déc. 2020

TOULON

03 mar. 2020, 30 juin 2020
25 août. 2020, 01 déc. 2020

TOULOUSE

25 fév. 2020, 23 juin 2020
01 sep. 2020, 24 nov. 2020

TOURS

25 fév. 2020, 23 juin 2020
01 sep. 2020, 24 nov. 2020

Mise en œuvre de la diminution du nombre des variables et identification des facteurs sous-jacents des dimensions associées à une variabilité importante.

6) Analyse de données textuelles

- Collecte et prétraitement des données textuelles.
- Extraction d'entités primaires, d'entités nommées et résolution référentielle.
- Étiquetage grammatical, analyse syntaxique, analyse sémantique.
- Lemmatisation.
- Représentation vectorielle des textes.
- Pondération TF-IDF.
- Word2Vec.

Travaux pratiques

Explorer le contenu d'une base de textes en utilisant l'analyse sémantique latente.

Modalités d'évaluation

L'évaluation des acquis se fait tout au long de la session au travers des multiples exercices à réaliser (50 à 70% du temps).

Compétences du formateur

Les experts qui animent la formation sont des spécialistes des matières abordées. Ils ont été validés par nos équipes pédagogiques tant sur le plan des connaissances métiers que sur celui de la pédagogie, et ce pour chaque cours qu'ils enseignent. Ils ont au minimum cinq à dix années d'expérience dans leur domaine et occupent ou ont occupé des postes à responsabilité en entreprise.

Moyens pédagogiques et techniques

- Les moyens pédagogiques et les méthodes d'enseignement utilisés sont principalement : aides audiovisuelles, documentation et support de cours, exercices pratiques d'application et corrigés des exercices pour les stages pratiques, études

de cas ou présentation de cas réels pour les séminaires de formation.

- A l'issue de chaque stage ou séminaire, ORSYS fournit aux participants un questionnaire d'évaluation du cours qui est ensuite analysé par nos équipes pédagogiques.

- Une feuille d'émargement par demi-journée de présence est fournie en fin de formation ainsi qu'une attestation de fin de formation si le stagiaire a bien assisté à la totalité de la session.