

## Data Science : Natural Language Processing (NLP) & Speech Recognition

*Devenir un expert du langage écrit et parlé avec python*

### DESCRIPTION

Les données non structurées issues du langage sont omniprésentes en entreprise (mails, appels téléphoniques, visio, réunions, avis, commentaires, etc.) mais ne sont que rarement utilisées. Les progrès en deep learning, ont permis de rendre plus accessible l'exploitation des données voix et texte.

Cette formation prépare les datascientists à maîtriser les données texte et voix, au sein d'un contexte technologique innovant et en particulier au cours d'un projet d'Intelligence Artificielle.

A travers des exercices, vous apprendrez à structurer et créer des modèles de machine learning sur ces données du langage. A la fin de la session, vous disposerez d'une compréhension solide du potentiel et de l'état de l'art en Natural Language Processing (NLP) et en Speech Processing. Les mises en pratique vous permettront d'être indépendant pour déployer et créer de la valeur sur ces données, et devenir un expert du traitement automatique du langage écrit et parlé.

### OBJECTIFS PEDAGOGIQUES

- Savoir structurer les données texte et voix
- Savoir analyser un volume conséquent de données texte et/ou voix et appliquer des modèles de machine learning
- Savoir traiter de la voix et/ou du texte en temps réel
- Savoir mettre en place une recherche intelligente dans des documents et/ou enregistrements audio
- Savoir créer des modèles de détection d'intention, d'entités

### PUBLIC CIBLE

- Analyste
- Statisticien
- Architecte

### Stage pratique

Data Science

Code :  
**NLPSR**

Durée :  
**3 jour(s) (21,00 heures)**

Exposés : **50 %**  
Cas pratiques : **40 %**  
Echanges d'expérience : **10 %**

### Inter-entreprises :

Prochaines sessions disponibles [sur notre site web](#).  
Tarif : 2 450,00 € HT / participant

### Intra-entreprise :

Tarifs et dates sur demande.

- Développeur
- Data scientist
- Machine Learning Engineer

#### PRE-REQUIS

- Connaissances générales sur le Machine Learning ainsi qu'en statistiques
- Notions de base en Python.
- Avoir suivi la formation "[Fondamentaux de la Data Science](#)" (DSFDX)

#### METHODE PEDAGOGIQUE

Formation avec apports théoriques, échanges sur les contextes des participants et retours d'expérience pratique des formateurs, complétés de travaux pratiques et de mises en situation.

#### PROFIL DES INTERVENANTS

Toutes nos formations sont animées par des consultants-formateurs expérimentés et reconnus par leurs pairs.

#### MODALITÉS D'ÉVALUATION ET FORMALISATION À L'ISSUE DE LA FORMATION

L'évaluation des acquis se fait tout au long de la session au travers des ateliers et des mises en pratique. Une évaluation à chaud sur la satisfaction des stagiaires est réalisée systématiquement en fin de session et une attestation de formation est délivrée aux participants mentionnant les objectifs de la formation, la nature, le programme et la durée de l'action de formation ainsi que la formalisation des acquis.

#### PROGRAMME PEDAGOGIQUE DETAILLE

##### Jour 1

## INTRODUCTION AU DOMAINE DE L'ANALYSE DU TEXTE ET DE LA VOIX

NLP, NLU, Speech processing et understanding

### NATURAL LANGUAGE PROCESSING (NLP)

Les bases du NLP : encoding, regex, tokenisation(n-grams) bag of words

NLP : la réduction de dimensions

Nettoyer le texte : stemming, lemmatisation

- Topic modeling : SVD, NMF, LDA
- Word embedding : Word2vec, FastText, etc.

### INFORMATION RETRIEVAL (IR) : CRÉER UN MOTEUR DE RECHERCHE

- Indexation de contenu, moteur recherche simple
- Réaliser un moteur de recherche intelligent

## Jour 2

### NATURAL LANGUAGE UNDERSTANDING (NLU)

Les cas d'usages au travers de mises en pratique :

- Créer un modèle simple d'analyse de sentiments
- Créer un modèle simple de détection d'intention
- Créer un modèle simple de détection d'entités NER

Méthodologie avancée :

- Mettre en place un modèle de machine learning sur du texte (analyse de sentiment, etc.)
- Modélisation deep learning : Sequence, Bert, HuggingFace

Consommer une API de NLP :

- Utiliser une API externe

### Jour 3

#### SPEECH PROCESSING

Introduction à la donnée audio: signal numérique, encodage

Speech recognition

- Entraîner un modèle de speech to text (trigger word detection)
- Utiliser un modèle de speech to text complet (API Cloud, modèle pré-entraîné)

#### SPEECH UNDERSTANDING

Les cas d'usages

- Détection intention
- Analyse de sentiments

Speech analysis

- Représentation : transformée de Fourier, spectrogramme mel MFCC, (librosa, pyaudio)
- Les particularité du langage parlé : syntaxe, gestion du débit de parole, erreur de transcription
- Speaker Embedding : caractériser le timbre, l'intonation de la voix

