

FORMATION TEXT MINNING

Comprendre les méthodes de la statistique textuelle

Machine Learning et Deep Learning pour les données textuelles s'inscrivent dans le cadre du traitement statistique et de la valorisation des données dans tout projet Big Data.

Ce cours pratique vous présentera toute la chaîne de conception appliquée au Machine Learning dans un contexte Big Data batch et streaming.

OBJECTIFS DE LA FORMATION

- Mettre en œuvre l'extraction des caractéristiques de données textuelles
- Créer des sélections et des classements dans de grands volumes de données textuelles
- Choisir un algorithme de classification
- Évaluer les performances prédictives d'un algorithme

DÉLAIS ET MODALITÉS D'ACCÈS

- Délais : 2 à 8 semaines selon le financement demandé
- Accessibilité PSH : DSI Group étudiera l'adaptation des moyens de la prestation pour les personnes en situation de handicap.



FORMATION

PUBLIC CONCERNÉ

Ingénieurs/chefs de projet IA, consultants IA
Toute personne souhaitant découvrir le Text Mining pour le Machine Learning et le Deep Learning

PRÉ-REQUIS

Bonnes connaissances en statistiques, du Machine Learning et du Deep Learning
Expérience requise

DURÉE

3 jours

FRAIS DE PARTICIPATION

1950 € HT

INTERVENANT

Albeiro ESPINAL
Doctorant Text Mining/NLP

INSCRIPTIONS

formation@group-dsi.com

DÉROULÉ

Jour 1

LES APPROCHES TRADITIONNELLES EN TEXT MINING

- Les API pour récupérer des données textuelles
- La préparation des données textuelles en fonction de la problématique
- La récupération et l'exploration du corpus de textes
- La suppression des caractères accentués et spéciaux
- Stemming, Lemmatization et suppression des mots de liaison
- Tout rassembler pour nettoyer et normaliser les données

Travaux pratiques : La recherche des documents, la préparation, la transformation et la vectorisation des données en DataFrame.

FEATURE ENGINEERING POUR LA REPRÉSENTATION DE TEXTE

- Comprendre la syntaxe et la structure du texte
- Le modèle Bag of Words et Bag of N-Grams
- Le modèle TF-IDF, Transformer et Vectorizer
- Le modèle Word2Vec et l'implémentation avec Gensim
- Le modèle GloVe
- Le modèle FastText

Travaux pratiques : Mise en place des opérations d'extraction des caractéristiques de données textuelles afin d'effectuer des classifications

www.group-dsi.com

Jour 2

LA SIMILARITÉ DES TEXTES ET CLASSIFICATION NON SUPERVISÉE

- Les concepts essentiels de similarité
- Analyse de la similarité des termes : distances Hamming, Manhattan, Euclidienne et Levenshtein
- Analyse de la similarité des documents
- Okapi BM25 et le palmarès de classement
- Les algorithmes de classification non supervisée

Travaux pratiques : Construire un système de recommandation des produits similaires sur la base de la description et du contenu des produits que vous avez choisi.

LA CLASSIFICATION SUPERVISÉE DU TEXTE

- Prétraitement et normalisation des données.
- Modèles de classification
- Multinomial Naïve Bayes
- Régression logistique. Support Vector Machines
- Random Forest. Gradient Boosting Machines
- Évaluation des modèles de classification

Travaux pratiques : Mise en œuvre des classifications supervisées sur plusieurs jeux de données.

Jour 3

NATURAL LANGUAGE PROCESSING ET DEEP LEARNING

- Les bibliothèques NLP : NLTK, TextBlob, SpaCy, Gensim, Pattern, Stanford CoreNLP
- Les bibliothèques Deep Learning : Theano, TensorFlow, Keras
- Natural Language Processing et Recurrent Neural Networks
- RNN et Long Short-Term Memory. Les modèles bidirectionnels RNN
- Les modèles Sequence-to-Sequence
- Questions et réponses avec les modèles RNN

Travaux pratiques : Construire un RNN pour générer un nouveau texte.