

# STA211 - Entreposage et fouille de données

## Présentation

### Prérequis

être admis en M2 du master STIC, mention statistique ou être agrégé.

**La demande d'agrément est à faire uniquement pour les auditeurs qui souhaitent suivre STA211 en présentiel au semestre 1.** Pour obtenir l'agrément, les auditeurs adresseront, à partir du 25 Août, par courrier électronique à l'enseignant responsable : [ndeye.niang\\_keita@cnam.fr](mailto:ndeye.niang_keita@cnam.fr), un CV détaillé et une lettre de motivation indiquant les raisons de la demande et le projet pédagogique dans lequel elle s'inscrit. Une réponse sera donnée dans un délai d'une dizaine de jours.

Niveau requis : NFA008 (bases de données) et STA101 (analyse des données, méthodes descriptives). **Ces prérequis sont indispensables pour obtenir l'agrément. Vérifier avant d'envoyer une demande d'agrément.**

## Programme

### Contenu

#### Modèles prévisionnels et systèmes de gestion de l'entreprise

- structures spécifiques des bases de données de Data warehouse (star schema)
- OLAP

#### Méthodologies générales

- Méthodologies de Data Mining

#### Pré-traitement des données

- Analyses de la qualité des données,
- Techniques d'appréhension des valeurs manquantes ou aberrantes
- Techniques de construction de bases de travail (agrégations, etc. . . )

#### Données et techniques de fouille

##### Méthodes non supervisées :

- Cartes de Kohonen, Règles d'association

##### Méthodes supervisées :

- Rappels de théorie de l'apprentissage
- Arbres de décision, forêts aléatoires, Réseaux de neurones, deep learning
- Méta-algorithmes :
- boosting, bagging

##### Fouille dans de nouveaux types de données et méthodes associées :

- Données textuelles - Données multivues - Images et Multimedia

#### Outils :

- Environnements freeware : R, Python
- Outils spécifiques : SAS-EM, SPAD
- Data Mining et bases de données : OLAP Business Object

## Modalités de validation

- Projet(s)
- Mémoire
- Examen final

## Description des modalités de validation

L'évaluation s'effectuera à la fois :

- sous la forme d'un examen sur table pour la partie cours
- sous la forme d'un projet consistant en une fouille de données pour la partie pratique

Mis à jour le 18-02-2025



### Code : STA211

Unité d'enseignement de type cours

9 crédits

Volume horaire de référence (+/- 10%) : **70 heures**

#### Responsabilité nationale :

EPN06 - Mathématiques et statistique / 1

#### Contact national :

EPN06 Mathématiques et statistiques

2 rue conté

Accès 35 3 ème étage porte 19  
75003 Paris

Sabine Glodkowski

[sabine.glodkowski@lecnam.net](mailto:sabine.glodkowski@lecnam.net)

# Bibliographie

Titre	Auteur(s)
Analyse discriminante (Dunod, 2001)	M.BARDOS
Probabilités, analyse des données et statistique (Technip, 2006)	G.SAPORTA
Data mining et statistique décisionnelle (Technip, 2005)	S.TUFFERY
Etude de cas en statistique décisionnelle (Technip, 2009)	S.TUFFERY
The Elements of Statistical Learning (Springer, 2009). Téléchargeable ici : <a href="https://hastie.su.domains/ElemStatLearn/printings/ESLII_print12_toc.pdf.download.html">https://hastie.su.domains/ElemStatLearn/printings/ESLII_print12_toc.pdf.download.html</a>	T.HASTIE, J.FRIEDMAN, F.TIBSHIRANI
Analyse des données (Hermes,2003)	G.GOVAERT (ed)
Statistique exploratoire multidimensionnelle (1995)	L. LEBART, A. MORINEAU, M. PIRON
Statistique explicative appliquée (Technip, 2003)	J.P.NAKACHE, J.CONFAIS
An Introduction to Statistical Learning (2021) with Applications in R. Téléchargeable ici : <a href="https://hastie.su.domains/ISLR2/ISLRv2_corrected_June_2023.pdf.download.html">https://hastie.su.domains/ISLR2/ISLRv2_corrected_June_2023.pdf.download.html</a>	G. JAMES D. WITTEN, T. HASTIE, R. TIBSHIRANI
An Introduction to Statistical Learning (2023) with Applications in Python. Téléchargeable ici : <a href="https://hastie.su.domains/ISLP/ISLP_website.pdf.download.html">https://hastie.su.domains/ISLP/ISLP_website.pdf.download.html</a>	G. JAMES D. WITTEN, T. HASTIE, R. TIBSHIRANI and J. TAYLOR