

Modèles statistiques pour l'apprentissage automatique (Semestre 9)

Enseignants :
Frédéric Pennerath (Cours, TD,TP) et Mohammed Fellaji (TP)

Le cours "Modèles statistiques pour l'apprentissage automatique" aborde le problème de l'apprentissage automatique sous l'angle des modèles probabilistes et de l'estimation statistique. Si le cours présente les modèles et les méthodes les plus utiles dans ce contexte, il ne se veut pas être un catalogue exhaustif. L'objectif du cours est davantage de présenter au sein d'une théorie cohérente les concepts et outils des statistiques, communs à l'ensemble de ces modèles et méthodes et de montrer comment à partir d'hypothèses de modélisation propres à chaque type de problème traité, ces concepts sont assemblés logiquement avant d'aboutir à une méthode opérationnelle. Ainsi une part importante du cours est consacrée à la mise en application de ces concepts, en TD (exercices de modélisation) et en TP (mise en oeuvre de modèles).

Contenu du cours

- Introduction. Rappels de théorie des probabilités, statistiques et théorie de l'information (3h).
- Inférence Bayésienne (3h)
- Introduction aux réseaux bayésiens : modèle général, propriétés, Naive Bayes (3h)
- Modèles gaussiens pour la classification : QDA, LDA, etc (1,5h)
- Famille exponentielle et modèles linéaires généralisés (3h)
- Processus gaussiens (1,5h)
- Modèles à variables cachées et algorithme EM (3h)
- Modèles de mélange. Exemple des mélanges de gaussiennes (GMM) (1,5h)
- Processus Markoviens
 - Processus et chaînes de Markov, modèles de Markov cachés (3h)
 - Filtre de Kalman, EKF, UKF et filtres particuliers (3h)

Le cours comporte au total 52 HPE, dont :

- 17 cours de 1,5h
- 5 TD de 1,5h
- 5 TP de 3h
- 2 examens (1h + 3h)

Modalités d'évaluation

- Examen écrit à mi-parcours de 1h (coef. 1/4)
- Examen écrit final de 3h (coef. 3/4)

Prérequis

Notions en théorie des probabilités, statistiques, algèbre linéaire et programmation Python.

Bibliographie / Support

- Support de cours (transparentes du cours)
- "Machine Learning – A Probabilistic Perspective", K. Murphy (MIT Press, 2012)
- "Bayesian Reasoning and Machine Learning", D. Barber (Cambridge University Press, 2012)
- "All of Statistics : A Concise Course in Statistical Inference", L. Wasserman (Springer-Verlag, 2004)

Apprentissage par renforcement (Semestre 10)

Enseignants :

Alain Dutech (cours, TP), Hervé Frezza-Buet (TP) et Jérémy Fix (TP)

Le cours présente les bases théoriques de l'apprentissage par renforcement ainsi que les principes des algorithmes les plus courants. Par le biais de travaux pratiques, ces éléments seront étendus à des situations plus complexes, permettant d'introduire les algorithmes les plus récents ayant, par exemple, permis à l'ordinateur de maîtriser le jeu de Go.

Contenu du cours

- Introduction sur l'apprentissage par renforcement
- Processus Décisionnels de Markov (MDP)
- Propriétés d'existence et d'unicité de la fonction de valeur.
- Algorithmes d'inférence de la fonction de valeur.
- Résolution approchée
 - Approximation linéaire
 - Estimation de Monte Carlo
 - Théorie des bandits manchots
 - Apprentissage profond

Modalités d'évaluation

Examen écrit de 2h.

Prérequis

Notions en algèbre linéaire, théorie des probabilités et programmation Python.

Bibliographie / Support

- Support de cours (Présentation du cours, polycopié)
- "Reinforcement Learning : An Introduction, 2nd edition", R. Sutton, A. Barto (Bradford Book, 2018)
- "Processus décisionnels de Markov en intelligence artificielle, vol. 1", O. Buffet, O. Sigaud (Hermès Science, 2008)

Théorie de l'apprentissage statistique (Semestre 10)

Enseignant : Michel Barret (cours, TD)

L'apprentissage supervisé a pour objectif de proposer des méthodes qui, à partir d'une base d'exemples, permettent de prendre une décision portant sur un paramètre à partir d'observations, la décision devant être la meilleure possible en moyenne. Par exemple, classifier des images suivant leur contenu, c'est-à-dire décider si une image représente un chat, un chien, ou autre chose. Nous présenterons formellement le problème et étudierons les garanties de généralisation des algorithmes d'apprentissage supervisé, c'est-à-dire la qualité de prédiction de la sortie associée à une entrée non présente dans la base d'entraînement. Pour atteindre cet objectif, nous introduirons les concepts d'espace d'hypothèses ayant la capacité d'apprentissage PAC (probablement approximativement correcte), de dimension Vapnik-Chervonenkis d'un espace d'hypothèses. Enfin, en fonction du temps disponible, nous présenterons le point de vue d'Olivier Catoni sur les bornes bayésiennes PAC pour les déviations entre risque empirique et risque réel.

Contenu du cours

- Formalisation du problème de l'apprentissage supervisé
- Capacité d'apprentissage PAC et convergence uniforme
- Le dilemme biais-complexité
- La dimension VC (Vapnik-Chervonenkis) d'un espace d'hypothèse
- Deux théorèmes fondamentaux de l'apprentissage supervisé
- Bornes bayésiennes PAC pour les déviations des moyennes empiriques par rapport à leurs espérances

Modalités d'évaluation

Examen écrit de 2h.

Prérequis

Notions en théorie des probabilités, statistiques et apprentissage automatique (machine learning).

Bibliographie / Support

- "L'apprentissage face à la malédiction de la grande dimension, S. Mallat, (Cours du Collège de France, 2018).
- "Understanding Machine Learning, from theory to algorithms", S. Shalev-Shwartz et S. Ben-David (Cambridge University Press, 2014).
- "Comment : Transductive PAC-Bayes Bounds Seen as a Generalization of Vapnik-Chervonenkis Bounds", O. Catoni (Measures of Complexity, chap 10, Springer, 2015).