

### Programme des colles de la semaine 20 (16/03 – 21/03)

Rappel : pas de colles la semaine du 23/03 au 28/03

#### I. Fonctions de plusieurs variables réelles : extremums

- Définitions** (voir semaine 18)
- Étude des extremums locaux** (voir semaine 19)
- Recherche d'extremums globaux** (voir semaine 19)
- Extremums sous contraintes linéaires**
  - Extremums sous une contrainte linéaire
    - Définition d'une contrainte
    - Notion d'extremum sous une contrainte  $\mathcal{C}$ .
    - Description d'une contrainte linéaire  $\mathcal{C}$  comme intersection d'hyperplans affines d'équation  $g_i(X) = b_i$ ,  $i \in \llbracket 1, p \rrbracket$  ( $g_i$  linéaire).
    - Notation  $\mathcal{H}$  l'unique sous-espace vectoriel parallèle à la contrainte  $\mathcal{C}$ , défini par les équations homogènes  $g_i(X) = 0$ ,  $i \in \llbracket 1, p \rrbracket$ .
  - Points critiques sous contrainte
    - Points critiques sous la contrainte  $\mathcal{C} : f$  défini sur un ouvert  $U$  de  $\mathbb{R}^n$  ;  $A$  est un point critique sous la contrainte  $\mathcal{C}$  si et seulement si  $A \in \mathcal{C} \cap U$  et  $\nabla f_A \in \mathcal{H}^\perp$ .
    - Prop : Si  $f$  est défini sur un ouvert  $U$ , si  $f$  admet un extremum local sous la contrainte  $\mathcal{C}$  en  $A$  alors  $A$  est un point critique de  $f$  sous la contrainte  $\mathcal{C}$ .  
Réciproque fausse.
  - Un description de  $\mathcal{H}^\perp$ .
    - Les  $g_i$  étant linéaires  $\nabla g_i$  est constante. On note simplement  $\nabla g_i$  la valeur constante.
    - Théorème :  $\mathcal{H}^\perp = \text{Vect}(\nabla g_1, \dots, \nabla g_p)$ .
  - Méthode.  
En pratique, dans les cas concrets, en basse dimension, on opérera le plus souvent par substitution de certaines variables, à l'aide des relations définissant la contrainte, afin de se ramener à l'étude des extremums d'une fonction à moins de variables (le plus souvent on se ramène ainsi à 1 ou 2 variables), et sans contrainte cette fois. La recherche des points critiques sous contrainte est à réserver aux cas un peu plus théoriques (optimisation en dimension  $n$  générique).

#### II. Convergences et approximations en probabilités

- Convergence en probabilités**
  - Définition
  - Inégalités de Markov et de Bienaymé-Tchebychev, pour des variables aléatoires discrètes ou à densité.
  - Loi faible des grands nombres, pour des variables aléatoires discrètes ou à densité.
  - Cas particulier : théorème d'or de Bernoulli
  - Un exemple classique (premier exemple simple d'« estimation » : on répète 1000 fois une expérience de Bernoulli de paramètre  $p$  inconnu, on obtient un certain nombre  $N$  de succès. Donner un intervalle  $I$  tel que  $p \in I$  avec une fiabilité de 95%.

- Une condition suffisante de convergence en probabilité (résultat hors-programme, démontré en TD ; la démonstration n'est pas exigible) :  
Si  $E(X_n)$  tend vers  $E(X)$  et  $V(X_n - X)$  tend vers 0, alors  $X_n$  converge en probabilité vers  $X$ .

#### 2. Convergence en loi

- Définition générale, à l'aide des fonctions de répartition
- Cas des variables discrètes, lorsque  $X_n(\Omega) \subset \mathbb{Z}$  (seul cas au programme), ou  $X_n(\Omega) \subset X(\Omega)$  : convergence des probabilités ponctuelles.  
La démonstration de l'équivalence entre ces deux définitions dans le cas discret n'a pas été faite en cours.
- Théorème de la limite centrée (**admis**) : si les  $X_n$  sont mutuellement indépendantes, de même loi, admettant une espérance et une variance, alors la variable aléatoire centrée réduite associée à  $X_1 + \dots + X_n$  converge en loi vers  $X$  suivant  $\mathcal{N}(0, 1)$ .

#### 3. Approximations classiques

- Approximation d'une loi hypergéométrique par une loi binomiale :  $X_n \hookrightarrow \mathcal{H}(N, n, p)$  converge en loi vers  $X \hookrightarrow \mathcal{B}(n, p)$ .  
On considère qu'on peut approcher  $\mathcal{H}(N, n, p)$  par  $\mathcal{B}(n, p)$  si  $N > 10n$ .
- Approximation d'une loi binomiale par une loi de Poisson : Si  $np_n \rightarrow \lambda$ , alors  $X_n \hookrightarrow \mathcal{B}(n, p_n)$  converge en loi vers  $X \hookrightarrow \mathcal{P}(\lambda)$ .  
En pratique, on peut approcher  $\mathcal{B}(n, p)$  par  $\mathcal{P}(np)$  si  $n \geq 30$ ,  $p \leq 0.1$ ,  $np \leq 10$ .
- Approximation d'une loi binomiale par une loi normale : on considère qu'on peut approcher  $\mathcal{B}(n, p)$  par  $\mathcal{N}(np, npq)$  si  $n \geq 30$ ,  $np \geq 5$ ,  $nq \geq 5$
- Approximation d'une loi de Poisson par une loi normale : on considère qu'on peut approcher  $\mathcal{P}(\lambda)$  par  $\mathcal{N}(\lambda, \lambda)$  si  $\lambda \geq 18$ .

#### III. Estimation (pas d'exercices cette semaine)

##### 1. Échantillons d'une loi de probabilité

- Définition d'un échantillon (ou échantillon aléatoire) de taille  $n$  : famille  $(X_1, \dots, X_n)$  de variables aléatoires de même loi  $\mathcal{L}$ , appelée loi parente de l'échantillon.
- Échantillon observé : réalisation d'un échantillon aléatoire  $(X_1(\omega), \dots, X_n(\omega))$ .
- Définition : échantillon indépendant identiquement distribué (en abrégé autorisé : i.i.d.)
- Définition : statistique sur un échantillon i.i.d.
- Exemple et définition : moyenne empirique, variance empirique.

##### 2. Estimation ponctuelle

- Position du pb : un certain phénomène est codé numériquement par une variable aléatoire dont on ignore la loi, mais dont on connaît l'appartenance à une certaine famille de lois  $\mu_\theta$  dépendant d'un paramètre  $\theta$  (par exemple l'ensemble des lois de Bernoulli). La loi  $\mu_\theta$  est définie sur l'espace probabilisé  $(\Omega, \mathcal{T}, P_\theta)$ . But : estimer la valeur de  $\theta$ , ou d'une fonction de  $\theta$ ,  $g(\theta)$ , par répétition de l'expérience.
- Définition d'un estimateur de  $g(\theta)$  :  $\varphi(X_1, \dots, X_n)$ ,  $(X_1, \dots, X_n)$  échantillon i.i.d.
- Estimation de  $g(\theta)$  : réalisation d'un estimateur.
- Remarque : cela ne dit rien quant à la validité de l'estimation.

##### 3. Biais d'un estimateur

- Définition du biais  $b_{T_n}(\theta) = E_\theta(T_n) - g(\theta)$ .
- Estimateur sans biais, estimateur biaisé. Exemples.