

## DEVOIR SURVEILLÉ 6 (4H)

EXERCICE : CARACTÉRISATION DES FONCTIONS HOMOGÈNES DE DEGRÉ  $k$ 

Soient une fonction  $f : \mathbb{R}^n \setminus \{0\} \rightarrow \mathbb{R}$ , différentiable en tout point, et  $k$  une constante réelle.

a) On suppose que  $f$  est homogène de degré  $k$ , ce qui signifie par définition

$$\forall t > 0, \forall x \in \mathbb{R}^n \setminus \{0\}, \quad f(tx) = t^k f(x) \quad (\text{E1})$$

En dérivant la fonction  $t \mapsto t^{-k} f(tx)$  montrer que  $f$  vérifie la relation suivante due à Euler :

$$\forall x \in \mathbb{R}^n \setminus \{0\}, \quad \sum_{i=1}^n x_i \frac{\partial f}{\partial x_i}(x) = k f(x) \quad (\text{E2})$$

- b) Montrer que la réciproque du a) est vraie, en remarquant qu'on peut appliquer (E2) à des variables qu'on note  $tx$  à la place de  $x$ .
- c) Bonus, un peu de chimie. L'enthalpie libre  $G$  est une fonction homogène de degré 1 des différents  $n_i$  (nombre de moles des différents constituants). Quelle relation donne alors l'identité d'Euler (E2) ?

PROBLÈME :  $\varepsilon$ -ISOMÉTRIES ET PROBABILITÉS

## Notations :

- Dans tout le problème  $N, k$  et  $d$  désignent des entiers supérieurs ou égaux à deux.
- Pour tous entiers naturels non nuls  $p$  et  $q$ , on note  $\mathcal{M}_{p,q}(\mathbb{R})$  l'ensemble des matrices à  $p$  lignes et  $q$  colonnes à coefficients réels.
- On note  $A^\top$  la transposée d'une matrice  $A$ .
- Pour tous entiers naturels  $p$  et  $q$ , avec  $p \leq q$ , la notation  $\llbracket p, q \rrbracket$  désigne l'ensemble  $\{i \in \mathbb{N} \mid p \leq i \leq q\}$ .
- Dans tout le problème on note  $(\Omega, \mathcal{A}, \mathbb{P})$  un espace probabilisé **fini**. Toutes les variables aléatoires considérées sont définies sur  $\Omega$ .
- Pour tout événement  $A$  de probabilité non nulle, et pour tout événement  $B$ , on note  $\mathbb{P}_A(B)$  ou  $\mathbb{P}(B \mid A)$  la probabilité conditionnelle de  $B$  sachant  $A$ .
- Étant donnée une variable aléatoire  $Z$  à valeurs réelles, on note  $\mathbb{E}(Z)$  son espérance.
- On dit qu'une variable aléatoire  $Z$  est une variable de Rademacher lorsque  $Z(\Omega) = \{-1, 1\}$  et

$$\mathbb{P}(Z = -1) = \mathbb{P}(Z = 1) = \frac{1}{2}$$

- De façon générale, si  $E$  est un espace euclidien, son produit scalaire et sa norme seront respectivement notés  $\langle \cdot | \cdot \rangle$  et  $\|\cdot\|$ . Ces notations seront utilisées notamment pour  $\mathbb{R}^d$  et  $\mathbb{R}^k$ , munis de leurs structures euclidiennes canoniques.

## Problématique :

On s'intéresse à la question suivante : étant donnés  $N$  points dans un espace euclidien de grande dimension, est-il possible de les envoyer linéairement dans un espace de petite dimension sans trop modifier les distances entre ces points ? Pour préciser cette question, considérons  $N$  vecteurs distincts  $v_1, \dots, v_N$  dans  $\mathbb{R}^d$ . Pour tout réel  $\varepsilon$  tel que  $0 < \varepsilon < 1$ , on dit qu'une application linéaire  $f : \mathbb{R}^d \rightarrow \mathbb{R}^k$  est une  $\varepsilon$ -isométrie pour  $v_1, \dots, v_N$  lorsque :

$$\forall (i, j) \in \llbracket 1, N \rrbracket^2, \quad (1 - \varepsilon) \|v_i - v_j\| \leq \|f(v_i) - f(v_j)\| \leq (1 + \varepsilon) \|v_i - v_j\|$$

La question peut se reformuler ainsi : Pour quelles valeurs de  $k$  existe-t-il  $f : \mathbb{R}^d \rightarrow \mathbb{R}^k$  qui soit une  $\varepsilon$ -isométrie pour  $v_1, \dots, v_N$  ?

Ce problème, adapté d'un sujet de Centrale conseillé par Ylan à cause de l'actualité, se propose d'établir le théorème suivant, démontré par William B. Johnson et Joram Lindenstrauss en 1984 :

Il existe une constante absolue  $c$  strictement positive telle que : quels que soient  $N$  et  $d$ , entier naturels supérieurs ou égaux à 2 et quels que soient  $v_1, \dots, v_N$  distincts dans  $\mathbb{R}^d$ , il suffit que

$$k \geq c \frac{\ln(N)}{\varepsilon^2}$$

pour qu'il existe une  $\varepsilon$ -isométrie  $f : \mathbb{R}^d \rightarrow \mathbb{R}^k$  pour  $v_1, \dots, v_N$ .

Les seules méthodes connues à ce jour pour démontrer ce théorème sont de nature probabiliste. Dans la partie I, on établit des résultats préliminaires portant sur la convexité et les probabilités. La partie II est consacrée à la démonstration (ici tronquée pour garder une taille de problème moins déraisonnable) d'une inégalité de concentration, due à Michel Talagrand, prix Abel 2024, qui est utilisée dans la partie III où le théorème de Johnson-Lindenstrauss est démontré.

## Partie I

### Projection sur un convexe fermé d'un espace euclidien :

Soit  $E$  un espace euclidien.

- Q1) Soient  $a$  et  $b$  dans  $E$ . Montrer la relation suivante et en donner une interprétation géométrique dans un parallélogramme :

$$\|a + b\|^2 + \|a - b\|^2 = 2(\|a\|^2 + \|b\|^2)$$

- Q2) En déduire que si  $u, v$  et  $v'$  dans  $E$  vérifient  $v \neq v'$  et  $\|u - v\| = \|u - v'\|$  alors  $\left\|u - \frac{v+v'}{2}\right\| < \|u - v\|$ .

- Q3) Soient  $F$  un fermé non vide de  $E$  et  $u$  dans  $E$ . Montrer qu'il existe  $v$  dans  $F$  tel que

$$\forall w \in F, \quad \|u - v\| \leq \|u - w\|$$

On pourra noter  $d = \inf\{\|u - w\|, w \in F\}$  et considérer une suite  $(w_n) \in F^{\mathbb{N}}$  telle que  $\|u - w_n\| \xrightarrow{n \rightarrow +\infty} d$ .

- Q4) En déduire que si  $C$  est un convexe fermé non vide de  $E$  et  $u$  est un vecteur de  $E$  alors il existe un unique  $v$  dans  $C$  tel que

$$\forall w \in C, \quad \|u - v\| \leq \|u - w\|$$

**Définition :** On dira que  $v$  est le projeté de  $u$  sur  $C$  et on notera  $d(u, C) = \|u - v\|$ . Autrement dit, on a défini une application  $p : E \rightarrow C$  appelée *projection* sur le convexe fermé  $C$ . Bien sûr dans le cas où  $C$  est un sous-espace vectoriel de  $E$ ,  $p$  est la projection orthogonale sur ce sous-espace.

### Inégalité de Hölder pour l'espérance

Soient  $p$  et  $q$  deux réels strictement positifs tels que  $\frac{1}{p} + \frac{1}{q} = 1$ .

- Q5) Montrer que, pour tous réels positifs  $a$  et  $b$ ,

$$ab \leq \frac{a^p}{p} + \frac{b^q}{q}$$

- Q6) En déduire que si  $X$  et  $Y$  sont deux variables aléatoires réelles sur un espace probabilisé **fini**  $(\Omega, \mathcal{A}, \mathbb{P})$  alors

$$\mathbb{E}(|XY|) \leq \mathbb{E}(|X|^p)^{1/p} \mathbb{E}(|Y|^q)^{1/q}$$

On pourra d'abord montrer ce résultat lorsque  $\mathbb{E}(|X|^p) = \mathbb{E}(|Y|^q) = 1$ .

### Espérance conditionnelle

Soit  $X : \Omega \rightarrow \mathbb{R}$  une variable aléatoire à valeurs réelles défini sur un univers **fini**  $\Omega$ . Pour tout événement  $A \subset \Omega$  de probabilité non nulle, l'espérance conditionnelle de  $X$  sachant  $A$ , notée  $\mathbb{E}(X | A)$ , est par définition le réel

$$\mathbb{E}(X | A) = \sum_{x \in X(\Omega)} \mathbb{P}_A(X = x) \cdot x$$

En d'autres termes,  $\mathbb{E}(X | A)$  est l'espérance de  $X$  dans l'espace  $(\Omega, \mathcal{A}, \mathbb{P}_A)$ . Les propriétés usuelles de linéarité et de positivité de l'espérance, qu'on ne demande pas de redémontrer, sont ainsi valables pour l'espérance conditionnelle sachant  $A$ .

Q7) Soit  $(A_1, \dots, A_m)$  un système complet d'événements de probabilités non nulles. Montrer que

$$\mathbb{E}(X) = \sum_{i=1}^m \mathbb{P}(A_i) \cdot \mathbb{E}(X | A_i)$$

### Variables aléatoires à queue sous-gaussienne

Soit  $X : \Omega \rightarrow \mathbb{R}$  une variable aléatoire réelle définie sur un univers fini  $\Omega$ . On suppose qu'il existe deux réels strictement positifs  $a$  et  $b$  tels que, pour tout réel positif  $t$ ,

$$\mathbb{P}(|X| \geq t) \leq a \exp(-bt^2)$$

Q8) Le but de cette question est de montrer que

$$\mathbb{E}(X^2) = 2 \int_0^{+\infty} t \mathbb{P}(|X| \geq t) dt$$

Pour cela, on note :  $X^2(\Omega) = \{y_1, \dots, y_n\}$  avec  $0 \leq y_1 < y_2 < \dots < y_n$ .

- Tracer le graphe de la fonction  $t \mapsto \mathbb{P}(X^2 \geq t)$  pour  $t \in \mathbb{R}^+$  en plaçant les points  $y_1, \dots, y_n$  en abscisse, et justifier qu'il s'agit d'une fonction continue par morceaux.
- En déduire que :

$$\int_0^{+\infty} P(X^2 \geq t) dt = y_1 + \sum_{i=1}^{n-1} P(X^2 \geq y_{i+1}) (y_{i+1} - y_i)$$

- En déduire que :

$$\int_0^{+\infty} P(X^2 \geq t) dt = \mathbb{E}(X^2)$$

- En déduire la formule annoncée en début de question.

Q9) Montrer que le moment d'ordre deux de  $X$  est inférieur ou égal à  $\frac{a}{b}$ .

Soit  $\delta$  un réel tel que  $0 \leq |\delta| \leq \sqrt{\frac{a}{b}}$ .

Q10) Justifier que, pour tout réel  $t$ ,

$$\mathbb{P}(|X + \delta| \geq t) \leq \mathbb{P}(|X| \geq t - |\delta|)$$

Q11) Montrer que, pour tout réel  $t$ ,

$$-b(t - |\delta|)^2 \leq a - \frac{1}{2}bt^2$$

Q12) En déduire que pour tout réel  $t$  tel que  $t \geq |\delta|$  on a

$$\mathbb{P}(|X + \delta| \geq t) \leq a \exp(a) \exp\left(-\frac{1}{2}bt^2\right)$$

**N.B** on admettra que l'inégalité précédente reste valable si  $0 \leq t < |\delta|$ .

## Partie II L'inégalité de concentration de Talagrand

Soit  $E$  un espace euclidien de dimension  $n \geq 1$  muni d'une base orthonormée  $(e_1, \dots, e_n)$ . Soient  $\varepsilon_1, \dots, \varepsilon_n : \Omega \rightarrow \{-1, 1\}$  des variables aléatoires de Rademacher indépendantes dans leur ensemble. On pose

$$X = \sum_{i=1}^n \varepsilon_i e_i.$$

L'objectif de cette partie est de montrer, pour tout convexe fermé non vide  $C$  de  $E$ ,

$$\mathbb{P}(X \in C) \cdot \mathbb{E} \left( \exp \left( \frac{1}{8} d(X, C)^2 \right) \right) \leq 1 \quad (\text{II.1})$$

### II A Étude de deux cas particuliers

Q13) Traiter le cas facile où  $C$  est un convexe fermé de  $E$  ne rencontrant pas  $X(\Omega)$ .

On suppose, dans la suite de cette sous-partie II.A uniquement, que  $C$  est un convexe fermé de  $E$  qui rencontre  $X(\Omega)$  en un seul vecteur  $u$ .

Q14) Montrer que la variable aléatoire  $\frac{1}{4} \|X - u\|^2$  suit une loi binomiale  $\mathcal{B}(n, 1/2)$ .

Q15) En déduire l'espérance de  $\exp \left( \frac{1}{8} \|X - u\|^2 \right)$  et montrer qu'elle est inférieure ou égale à  $2^n$ .

Q16) Justifier que  $d(X, C) \leq \|X - u\|$  et en déduire l'inégalité (II.1) dans ce cas.

### II.B - Initialisation

On suppose désormais que  $C$  est un convexe fermé de  $E$  tel que  $C \cap X(\Omega)$  contient au moins deux éléments. Quitte à permuter les vecteurs de la base, on peut supposer que ces deux vecteurs diffèrent par leur dernière coordonnée. On va montrer l'inégalité (II.1) par récurrence sur  $n = \dim(E)$ .

Q17) Montrer que dans le cas  $n = 1$ , l'inégalité (II.1) est une égalité.


### II.C - Propriétés de $C_{+1}$ et $C_{-1}$

Soit  $n$  un entier tel que  $n \geq 2$ . On suppose à présent que (II.1) est vérifiée au rang  $n - 1$ . On

note  $E' = \text{Vect}(e_1, \dots, e_{n-1})$  et  $\pi$  la projection orthogonale sur  $E'$ , i.e.  $\pi : \begin{cases} E \rightarrow E' \\ \sum_{i=1}^n x_i e_i \mapsto \sum_{i=1}^{n-1} x_i e_i \end{cases}$

On pose  $X' = \pi \circ X = \sum_{i=1}^{n-1} \varepsilon_i e_i$ . C'est une variable aléatoire à valeurs dans  $E'$ . Pour  $t$  dans  $\{-1, 1\}$  on note :

- $H_t$  l'hyperplan affine  $E' + t e_n$
- $C_t = \pi(C \cap H_t)$ .



Q18) Montrer, pour  $x' \in E'$  et  $t \in \{-1, 1\}$ , l'équivalence :  $x' \in C_t \iff x' + te_n \in C$ .

Q19) Montrer que  $C_{+1}$  et  $C_{-1}$  sont des convexes fermés non vides de  $E'$ .

Q20) Montrer que

$$\mathbb{P}(X \in C) = \frac{1}{2}\mathbb{P}(X' \in C_{+1}) + \frac{1}{2}\mathbb{P}(X' \in C_{-1})$$

## II.D - Suite de la démonstration de l'hérédité : admise ici, et application.

On admet qu'on a démontré la propriété donnée par (II.1), en fait il y a encore pas mal de travail!!

Q21) A l'aide de (II.1) montrer l'inégalité de Talagrand suivante :

Pour tout  $C$  convexe fermé non vide de  $E$  et pour tout réel  $t$  strictement positif

$$\mathbb{P}(X \in C) \cdot \mathbb{P}(d(X, C) \geq t) \leq \exp\left(-\frac{t^2}{8}\right)$$

## Partie III : démonstration du théorème de Johnson-Lindenstrauss

Dans cette partie on considère l'espace  $E = \mathcal{M}_{k,d}(\mathbb{R})$  muni du produit scalaire défini par

$$\forall (A, B) \in E^2, \quad \langle A | B \rangle = \text{tr}(A^\top \cdot B)$$

On notera  $\|\cdot\|_F$  la norme euclidienne associée. On rappelle que  $\mathbb{R}^d$  et  $\mathbb{R}^k$  sont munis de leurs normes euclidiennes canoniques, notées indistinctement  $\|\cdot\|$ . On identifie  $\mathbb{R}^d$  à  $\mathcal{M}_{d,1}(\mathbb{R})$ , de sorte qu'un vecteur quelconque  $x = (x_1, \dots, x_d)$  de  $\mathbb{R}^d$  peut être identifié à la matrice colonne  $(x_1 \dots x_d)^\top$ . On fixe un vecteur  $(u_1, \dots, u_d)$  dans  $\mathbb{R}^d$ , identifié comme ci-dessus à la matrice colonne  $(u_1 \dots u_d)^\top$  de  $\mathcal{M}_{d,1}(\mathbb{R})$ , et tel que  $\|u\| = 1$ . On définit l'application

$$g : \begin{cases} \mathcal{M}_{k,d}(\mathbb{R}) \rightarrow \mathbb{R} \\ M \mapsto \|M \cdot u\| \end{cases}$$

Soit  $X = (\varepsilon_{ij})_{1 \leq i \leq k, 1 \leq j \leq d}$  une variable aléatoire à valeurs dans  $\mathcal{M}_{k,d}(\mathbb{R})$ , dont les coefficients  $\varepsilon_{ij}$  sont des variables aléatoires de Rademacher indépendantes dans leur ensemble.

### III.A - Une inégalité de concentration

Q22) Montrer que  $C = \{M \in \mathcal{M}_{k,d}(\mathbb{R}) \mid g(M) \leq r\}$  est une partie convexe et fermée de  $\mathcal{M}_{k,d}(\mathbb{R})$ .

Q23) Montrer que pour toute matrice  $M$  dans  $\mathcal{M}_{k,d}(\mathbb{R})$

$$\|M \cdot u\| \leq \|M\|_F$$

Soient  $r$  et  $t$  deux réels, avec  $t > 0$ .

Q24) Montrer que pour toute matrice  $M$  dans  $\mathcal{M}_{k,d}(\mathbb{R})$

$$d(M, C) < t \implies g(M) < r + t$$

Q25) En déduire que

$$\mathbb{P}(g(X) \leq r) \cdot \mathbb{P}(g(X) \geq r + t) \leq \exp\left(-\frac{1}{8}t^2\right)$$

### III.B - Médianes

On dit qu'un réel  $m$  est une médiane de la variable aléatoire  $g(X)$  lorsque

$$\mathbb{P}(g(X) \geq m) \geq \frac{1}{2} \quad \text{et} \quad \mathbb{P}(g(X) \leq m) \geq \frac{1}{2}$$

Q26) Justifier que  $g(X)$  admet au moins une médiane.

*On pourra considérer la fonction  $G$  de  $\mathbb{R}$  dans  $\mathbb{R}$  telle que, pour tout réel  $t$ ,  $G(t) = \mathbb{P}(g(X) \leq t)$ , et examiner l'ensemble  $G^{-1}([1/2, 1])$ . On se souviendra aussi que  $\Omega$  étant fini,  $g(X)$  prend un nombre fini de valeurs.*

Q27) Dédurre des deux questions précédentes que, pour tout réel strictement positif  $t$  :

$$\mathbb{P}(|g(X) - m| \geq t) \leq 4 \exp\left(-\frac{1}{8}t^2\right)$$

où  $m$  est une médiane de  $g(X)$ . Autrement dit que  $|g(X) - m|$  est une variable aléatoire sous-gaussienne.

Q28) En déduire, à l'aide de la partie I, que  $\mathbb{E}((g(X) - m)^2) \leq 32$ .

Q29) En écrivant

$$g(X)^2 = \|Xu\|^2 = \sum_{i=1}^k \left( \sum_{\ell=1}^d \varepsilon_{i,\ell} u_\ell \right)^2$$

montrer que  $\mathbb{E}(g(X)^2) = k$ , et en déduire que  $\mathbb{E}(g(X)) \leq \sqrt{k}$ .

Q30) En déduire que  $(\sqrt{k} - m)^2 \leq \mathbb{E}((g(X) - m)^2)$ .

### III. C - Un lemme-clé avec un petit calcul admis

Q31) A l'aide de ce qui précède et de la partie I, montrer que, pour tout réel  $t > 0$  :

$$\mathbb{P}(|g(X) - \sqrt{k}| \geq t) \leq 4 \exp(4) \exp\left(-\frac{1}{16}t^2\right)$$

On pose  $A_k = \frac{X}{\sqrt{k}}$ . Soient  $\varepsilon$  dans  $]0, 1[$  et  $\delta$  dans  $]0, 1/2[$ . On suppose que  $k \geq 160 \frac{\ln(1/\delta)}{\varepsilon^2}$ .

*On admettra que, pour tout vecteur unitaire  $u$  dans  $\mathbb{R}^d$ , on peut en déduire (par un calcul sans grâce) :*

$$\mathbb{P}(|\|A_k \cdot u\| - 1| > \varepsilon) < \delta$$

### III.D - Conclusion

On conserve les notations et les hypothèses précédentes. Soient  $v_1, \dots, v_N$  des vecteurs distincts dans  $\mathbb{R}^d$ . Pour tout  $(i, j) \in [1, N]^2$  tel que  $i < j$  on note  $E_{ij}$  l'événement

$$(1 - \varepsilon) \|v_i - v_j\| \leq \|A_k \cdot v_i - A_k \cdot v_j\| \leq (1 + \varepsilon) \|v_i - v_j\|$$

Q32) Montrer que  $\mathbb{P}(\overline{E_{ij}}) < \delta$ , où  $\overline{E_{ij}}$  désigne l'événement contraire de  $E_{ij}$ .

Q33) En déduire que  $\mathbb{P}(\bigcap_{1 \leq i < j \leq N} E_{ij}) \geq 1 - \frac{N(N-1)}{2} \delta$ .

Q34) En déduire le théorème de Johnson et Lindenstrauss.