

Master 1<sup>ère</sup> année, MMA, 2022-2023  
OPTIMISATION

Examen du 09/01/2023

Durée 2h. Aucun document n'est autorisé. Les exercices sont indépendants.

**Total : 25.75 = 3.5 + 14.5 + 7.75, bonus : 0.5.**

**Exercice 1 (Cours) (3.5pt)**

1. Soit  $U \subset \mathbb{R}^n$  un ensemble convexe non vide et  $f : U \rightarrow \mathbb{R}$  une fonction convexe sur  $U$ . On suppose de plus que  $f$  admet en  $x \in U$  un minimum local.
  - a) Que peut-on alors dire de  $x$  pour  $f$  ?
  - b) Prouver le résultat.
2. Soit  $\Omega \subset \mathbb{R}^n$  un ouvert de  $\mathbb{R}^n$  et  $U \subset \Omega$  un sous-ensemble convexe non vide de  $\Omega$ . Soit  $f : \Omega \rightarrow \mathbb{R}$  une fonction différentiable sur  $\Omega$  et on suppose  $f$  convexe sur  $U$ . Soit  $x \in U$ .
  - a) Donner une condition nécessaire et suffisante pour que  $x$  soit un minimum global de  $f$  et faisant intervenir  $\nabla f(x)$ .
  - b) Prouver cette CNS.
  - c) Que devient la CNS si on a  $U = \Omega$  ? *On n'attend pas de justification.*

Correction.

Essentiellement voir Théorème 2.37.

1. a)  $x$  est un minimum global de  $f$  sur  $U$  (0.5pt).  
b) Voir la preuve de a) du théorème 2.37 (1pt).
2. a)  $x$  est un minimum global de  $f$  sur  $U$  si et seulement si pour tout  $y \in U$ ,  $\langle \nabla f(x), y - x \rangle \geq 0$  (0.5pt).  
b) Voir la preuve de c) du théorème 2.37 (1pt).  
c) La condition *pour tout*  $y \in U$ ,  $\langle \nabla f(x), y - x \rangle \geq 0$  est remplacée par  $\nabla f(x) = 0$  (0.5pt).

**Exercice 2 (14.5pt)**

Soit  $M, n \in \mathbb{N} \setminus \{0, 1\}$ . Dans la suite, on considère  $\mathbb{R}^M$  et  $\mathbb{R}^n$  munis de leurs produits scalaires canoniques respectifs que l'on note (par abus de langage)  $\langle \cdot, \cdot \rangle$  indépendamment de la dimension. Associés à ces produits scalaires, on utilise la notation unique (par abus de langage)  $\|\cdot\|$  pour les normes euclidiennes.

On suppose donnée une séquence de  $M$  points  $x_1, x_2, \dots, x_M$  de  $\mathbb{R}^n$ , et pour chacun d'entre eux est associé une classe  $y_i \in \{-1, 1\}$  pour  $i \in \{1, \dots, M\}$ . Voir la figure 1 pour une illustration. On dit que la famille des couples, éléments de  $\mathbb{R}^n \times \{-1, 1\}$ ,  $((x_i, y_i))_{1 \leq i \leq M}$  forment les *données d'entraînement*.

On souhaite trouver un hyperplan (ou une droite dans le cas  $n = 2$  comme sur la figure 1) passant par 0 et séparant, du mieux possible, ces points  $x_i$  entre ceux qui sont de la classe représentée par  $-1$  et ceux de la classe représentée par  $1$ .

Pour cela on considère la fonction suivante, pour  $\lambda > 0$

$$F : a \in \mathbb{R}^n \mapsto \frac{1}{2M} \sum_{i=1}^M (1 - y_i \langle x_i, a \rangle)^2 + \frac{\lambda}{2} \|a\|^2.$$

Et on s'intéresse au problème d'optimisation suivant

$$\inf_{a \in \mathbb{R}^n} F(a).$$




FIGURE 1. Exemple de points  $x_i \in \mathbb{R}^2$ . Ceux représentés par une croix, respectivement par un point, appartiennent à la classe  $-1$ , resp.  $1$ . La droite représentée, notée  $\mathcal{D}$ , est  $\{x \in \mathbb{R}^2 : \langle x, a \rangle = 0\}$ . Vu le sens de  $a$ , tous les  $x \in \mathbb{R}^2$  à gauche de  $\mathcal{D}$  satisfont  $\langle x, a \rangle > 0$ , et à droite de  $\mathcal{D}$ ,  $\langle x, a \rangle < 0$ . On associe à  $f_a : x \in \mathbb{R}^n \mapsto \langle x, a \rangle$  (définissant en particulier  $\mathcal{D}$ ), entièrement caractérisée par  $a \in \mathbb{R}^2$ , un coût  $F(a)$ . L'idée est de trouver un  $a$  de plus faible coût  $F(a)$ , en espérant que le  $F$  définie par le modèle permettent d'aboutir à un  $f_a$  effectuant une "bonne" classification.

#### PARTIE I (5.75PT)

1. Soit  $a \in \mathbb{R}^n$  tel que la quantité  $\frac{1}{2M} \sum_{i=1}^M (1 - y_i \langle x_i, a \rangle)^2$  est "petite". Pourquoi peut-on alors avoir confiance que la fonction  $f_a : x \in \mathbb{R}^n \mapsto \langle x, a \rangle$  permette de séparer "correctement" les points  $x_i$  en fonction de leurs classes  $y_i$ ? Et comment cette séparation est-elle effectuée?
2. Justifier que  $F$  est  $C^\infty$  sur  $\mathbb{R}^n$ .
3. Montrer que  $F$  admet un minimum global sur  $\mathbb{R}^n$ , que l'on notera  $a_\lambda^* \in \mathbb{R}^n$ .
4. a) Montrer que pour tout  $a \in \mathbb{R}^n$ ,

$$\nabla F(a) = \frac{1}{M} \sum_{i=1}^M (y_i \langle x_i, a \rangle - 1) y_i x_i + \lambda a.$$

- b) Déterminer pour tout  $a \in \mathbb{R}^n$ ,  $\nabla^2 F(a)$ .
5. a) Montrer que  $F$  est strictement convexe.
- b) En déduire l'ensemble  $\arg \min_{a \in \mathbb{R}^n} F(a)$ .

#### PARTIE II (3.5PT)

On va maintenant revisiter les résultats précédents en adoptant un point de vue matriciel. On définit le vecteur  $\mathbf{1} = (1, \dots, 1) \in \mathbb{R}^M$  et  $Z \in \mathcal{M}_{n,M}(\mathbb{R})$  la matrice dont la  $i$ -ème colonne est donnée par le vecteur  $y_i x_i = (y_i x_{i,1}, \dots, y_i x_{i,n}) \in \mathbb{R}^n$ .

6. Rappeler la définition d'une fonctionnelle quadratique  $G : \mathbb{R}^n \rightarrow \mathbb{R}$ .
7. a) Montrer que pour tout  $a \in \mathbb{R}^n$ ,  $F(a) = \frac{1}{2M} \|\mathbf{1} - Z^T a\|^2 + \frac{\lambda}{2} \|a\|^2$ .
- b) En déduire que  $F$  est une fonctionnelle quadratique.
8. Donner alors, en utilisant les notations introduites dans cette partie, une expression de  $\nabla F(a)$  et  $\nabla^2 F(a)$ , pour tout  $a \in \mathbb{R}^n$ .
9. En déduire une expression de  $a_\lambda^*$ , puis  $\lim_{\lambda \rightarrow +\infty} a_\lambda^*$ . Pourquoi est-ce logique d'obtenir cette limite sachant la manière dont est construite la fonction objectif  $F$ ?

## PARTIE III (5.25PT)

10. Justifier pourquoi on peut appliquer l'algorithme de descente de gradient à pas optimal à  $F$ .
11. Montrer que les hypothèses du théorème de convergence de l'algorithme de descente de gradient à pas optimal appliqué à  $F$  sont bien satisfaites.
12. Écrire en Python une fonction codant cet algorithme, prenant en argument un point initial  $a_0 \in \mathbb{R}^n$ , une tolérance  $\varepsilon$  pour la condition d'arrêt et des arguments supplémentaires que vous jugerez nécessaires et que vous définirez avant la fonction. Enfin cette fonction renverra le dernier itéré correspondant à la variable  $a$ .
13. Dans cette question uniquement on suppose  $n = 2$ . La trajectoire visible sur la figure 2 peut-elle correspondre à celle produite par l'algorithme de descente de gradient à pas optimal appliquée à  $F$ ? En plus de la justification, on en donnera une rapide preuve.




FIGURE 2. Les points correspondent aux éléments d'une suite  $(a^{(k)})_{k \in \mathbb{N}}$ , convergent vers  $a_\lambda^*$  (représenté par l'étoile sur la figure), produite grâce à un algorithme itératif. Deux points reliés par un segment correspondent à deux itérés successifs de l'algorithme. Ainsi un segment donné a pour direction  $a^{(k+1)} - a^{(k)}$ , pour un certain  $k \in \mathbb{N}$ . En arrière plan sont représentées des lignes de niveau de  $F$ .

14. La figure 3 fournit une illustration de la convergence de l'algorithme de descente de gradient à pas optimal appliquée  $F$ . D'après le graphe, quelle type de convergence a-t-on pour la suite  $(F(a^{(k)}))_{k \in \mathbb{N}}$ , où  $(a^{(k)})_{n \in \mathbb{N}}$  est la suite des itérés produites par l'algorithme en démarrant  $a^{(0)} \in \mathbb{R}^n$ .

Correction.

$$0.75 + 0.5 + 0.75 + (1.25 + 1.25) + 0.75 + 0.5 \\ 0.5 + (0.5 + 0.75) + 0.5 + 1.25 \\ 0.25 + 1 + 2 + 1.25 + 0.75 + 0.5 \text{ bonus}$$

1. Soit  $a \in \mathbb{R}^n$  tel que la quantité  $\frac{1}{2M} \sum_{i=1}^M (1 - y_i \langle x_i, a \rangle)^2$  soit "petite". Alors pour tout  $i \in \{1, \dots, M\}$ , on a  $y_i \langle x_i, a \rangle \simeq 1$ , car on a une somme de termes positifs donc chacun doit être "petits". Ainsi  $\langle x_i, a \rangle \simeq y_i$ , puisque  $y_i \in \{-1, 1\}$ . Donc les valeurs (notamment leurs signes)  $f_a(x_i)$ , pour  $i \in \{1, \dots, M\}$ , sont des bons prédicteurs des classes  $y_i$  des  $x_i$  (0.75pt).




FIGURE 3. Illustration de la convergence de l'algorithme de descente de gradient à pas optimal appliquée à  $F$ .

2.  $F$  est  $\mathcal{C}^\infty$  par somme et composée de fonctions  $\mathcal{C}^\infty$  (0.5pt).

3. On a pour tout  $a \in \mathbb{R}^n$ ,  $F(a) \geq \frac{\lambda}{2} \|a\|^2$ , donc  $F$  est coercive sur  $\mathbb{R}^n$ . Comme  $F$  est continue, on déduit que  $F$  admet un minimum global sur  $\mathbb{R}^n$  (0.75pt).

4. a) Posons pour tout  $t \in \mathbb{R}$ ,  $\varphi(t) = (1-t)^2$  et tout  $i \in \{1, \dots, n\}$ ,  $g_i : a \in \mathbb{R}^n \mapsto y_i \langle x_i, a \rangle$ . Alors pour tout  $a \in \mathbb{R}^n$ ,  $F(a) = \frac{1}{2M} \sum_{i=1}^M \varphi(g_i(a)) + \frac{\lambda}{2} \|a\|^2$ . Comme  $\varphi$  et  $g_i$  sont  $\mathcal{C}^\infty$ , on a par la formule de la différentielle d'une composée, pour tous  $a, h \in \mathbb{R}^n$ ,  $i \in \{1, \dots, n\}$ ,  $d(\varphi \circ g_i)(a)(h) = \varphi'(g_i(a)) dg_i(a)(h) = -2(1 - y_i \langle x_i, a \rangle) y_i \langle x_i, h \rangle$ . Ainsi

$$dF(a)(h) = \left\langle -\frac{1}{M} \sum_{i=1}^M (1 - y_i \langle x_i, a \rangle) y_i x_i + \lambda a, h \right\rangle,$$

d'où par identification  $\nabla F(a) = \frac{1}{M} \sum_{i=1}^M (y_i \langle x_i, a \rangle - 1) y_i x_i + \lambda a$  (1.25pt).

b) On a pour  $a, h \in \mathbb{R}^n$ ,  $\nabla F(a+h) = \nabla F(a) + \frac{1}{M} \sum_{i=1}^M y_i^2 \langle x_i, h \rangle x_i + \lambda h$ , donc  $d(\nabla F)(a)(h) = \frac{1}{M} \sum_{i=1}^M y_i^2 \langle x_i, h \rangle x_i + \lambda h$ . Or pour tout  $i$ ,  $\langle x_i, h \rangle x_i = \underbrace{(x_i^T h)}_{\in \mathbb{R}} x_i = x_i (x_i^T h) = (x_i x_i^T) h$ . Comme

$y_i^2 = 1$ , on obtient ainsi  $d(\nabla F)(a)(h) = \left( \frac{1}{M} \sum_{i=1}^M x_i x_i^T + \lambda I_n \right) h$ . D'où par identification,  $\nabla^2 F(a) = \frac{1}{M} \sum_{i=1}^M x_i x_i^T + \lambda I_n$  (1.25pt).

5. a) Pour tout  $i \in \{1, \dots, M\}$ , la matrice  $x_i x_i^T$  (de  $\mathcal{M}_n(\mathbb{R})$ ) est symétrique positive, car pour tout  $h \in \mathbb{R}^n$ ,  $\langle x_i x_i^T h, h \rangle = (x_i^T h)^2 \geq 0$ . Ainsi  $\frac{1}{M} \sum_{i=1}^M x_i x_i^T \succeq 0$ . Donc pour tout  $a \in \mathbb{R}^n$ ,  $\nabla^2 F(a) \succeq \lambda I_n \succ 0$  (0.5pt). Donc  $f$  est strictement convexe sur  $\mathbb{R}^n$  (0.25pt).

b) Comme  $f$  est strictement convexe,  $f$  admet donc au plus un minimum global, mais on sait qu'elle en admet au moins d'après la question 3.. On a donc  $\arg \min_{a \in \mathbb{R}^n} F(a) = \{a_\lambda^*\}$  (0.5pt).

6.  $G$  fonctionnelle quadratique si et seulement si pour tout  $x \in \mathbb{R}^n$ ,  $G(x) = \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle + c$ , avec  $A \in \mathcal{M}_n(\mathbb{R})$  symétrique,  $b \in \mathbb{R}^n$ ,  $c \in \mathbb{R}$  (0.5pt).

7. a) Vue la définition de  $Z$ , on a pour tout  $a \in \mathbb{R}^n$ ,  $Z^T a = (y_i \langle x_i, a \rangle)_{1 \leq i \leq M}$ , donc  $\|\mathbf{1} - Z^T a\|^2 = \sum_{i=1}^M (1 - y_i \langle x_i, a \rangle)^2$ . On a donc bien  $F(a) = \frac{1}{2M} \|\mathbf{1} - Z^T a\|^2 + \frac{\lambda}{2} \|a\|^2$  (0.5pt).

▮ Notez que la première norme euclidienne est sur  $\mathbb{R}^M$ , alors que la seconde sur  $\mathbb{R}^n$

b) On développe la norme euclidienne, pour tout  $a \in \mathbb{R}^n$ , on a

$$\begin{aligned} F(a) &= \frac{1}{2M} \langle \mathbb{1}, \mathbb{1} \rangle - \frac{1}{M} \langle \mathbb{1}, Z^T a \rangle + \frac{1}{2M} \langle Z^T a, Z^T a \rangle + \frac{\lambda}{2} \langle a, a \rangle, \\ &= \frac{1}{2} \left\langle \left( \frac{1}{M} Z Z^T + \lambda I_n \right) a, a \right\rangle - \left\langle \frac{1}{M} Z \mathbb{1}, a \right\rangle + \frac{1}{2}, \quad (0.5pt) \end{aligned}$$

où on a simplifié  $\langle \mathbb{1}, \mathbb{1} \rangle = M$ . On a donc bien  $F$  fonctionnelle quadratique comme  $\frac{1}{M} Z Z^T + \lambda I_n$  est symétrique (0.25pt).

▮ Notez que dans la première ligne du calcul les produits scalaires sont définies sur  $\mathbb{R}^M$ , mais dans la seconde sur  $\mathbb{R}^n$

8. On sait alors d'après le cours que pour tout  $a \in \mathbb{R}^n$ ,  $\nabla F(a) = \left( \frac{1}{M} Z Z^T + \lambda I_n \right) a - \frac{1}{M} Z \mathbb{1}$  et  $\nabla^2 F(a) = \frac{1}{M} Z Z^T + \lambda I_n$  (0.5pt).

▮ On peut vérifier facilement que ces expressions sont cohérentes avec les précédentes. Notez que  $\nabla F(a)$  est bien un vecteur de  $\mathbb{R}^n$  et  $\nabla^2 F(a)$  une matrice de taille  $n \times n$

9. On a vu que  $F$  admet un unique minimum global, noté  $a_\lambda^*$ . On a donc  $\nabla F(a_\lambda^*) = 0$ , i.e.  $a_\lambda^* = \frac{1}{M} \left( \frac{1}{M} Z Z^T + \lambda I_n \right)^{-1} Z \mathbb{1}$  (0.25pt)

▮ On sait même que  $a_\lambda^*$  est caractérisé<sup>a</sup> par l'équation  $\nabla F(a_\lambda^*) = 0$ , puisque  $F$  est strictement convexe

a. le minimum global de  $F$  est l'unique élément de  $\mathbb{R}^n$  qui annule  $\nabla F$ .

On a  $a_\lambda^* = \frac{1}{M} \frac{1}{\lambda} \left( \frac{1}{\lambda M} Z Z^T + I_n \right)^{-1} Z \mathbb{1}$ . Comme  $\frac{1}{\lambda M} Z Z^T + I_n \xrightarrow{\lambda \rightarrow +\infty} I_n$  (convergence dans  $\mathcal{M}_n(\mathbb{R})$ ), et comme l'application  $A \in \text{GL}_n(\mathbb{R}) \mapsto A^{-1}$  est continue (sur l'ouvert  $\text{GL}_n(\mathbb{R})$  de  $\mathcal{M}_n(\mathbb{R})$ ), on a  $\left( \frac{1}{\lambda M} Z Z^T + I_n \right)^{-1} \xrightarrow{\lambda \rightarrow +\infty} I_n$ . Par conséquent  $a_\lambda^* \xrightarrow{\lambda \rightarrow +\infty} 0$  (0.5pt).

Quand  $\lambda$  devient très grand, le terme le plus pénalisant dans  $F$  (et qui va donc être "minimisé" en priorité) est  $\frac{\lambda}{2} \|a\|^2$ . Or le minimum global de  $a \in \mathbb{R}^n \mapsto \frac{\lambda}{2} \|a\|^2$  est 0. Il est donc logique que  $a_\lambda^* \xrightarrow{\lambda \rightarrow +\infty} 0$  (0.5pt).

10. Comme  $F$  est une fonctionnelle quadratique, on sait que l'algorithme de descente de gradient à pas optimal est bien définie : pour tout  $a \in \mathbb{R}^n$ , il existe un unique  $t^* > 0$  tel que  $t^* \in \arg \min_{t \in \mathbb{R}_+} F(a - t \nabla F(a))$  et on en a même une expression littérale (0.25pt).

11. On a  $F$  de classe  $\mathcal{C}^2$  sur  $\mathbb{R}^n$  et on a vu que pour tout  $a \in \mathbb{R}^n$ ,  $\nabla^2 F(a) \succeq \lambda I_n$  ( $F$  est  $\lambda$ -fortement convexe sur  $\mathbb{R}^n$ ) (0.5pt). De plus comme  $\nabla^2 F(a) = \frac{1}{M} Z Z^T + \lambda I_n$ , c'est donc une matrice symétrique réelle définie positive et indépendante de  $a$ . Notant  $M > 0$  sa plus grande valeur propre, on a donc pour tout  $a \in \mathbb{R}^n$ ,  $\nabla^2 F(a) \preceq M I_n$  (0.5pt). Ainsi  $F$  satisfait les hypothèses du théorème de convergence de l'algorithme de descente de gradient à pas optimal.

12. Voir cours.

0.5 : mise en forme globale du code Python,

0.25 : définition variables externes,

0.25 : initialisation de l'algorithme,

0.25 : condition d'arrêt,

0.25 : écriture itération nouveau  $a$ ,

0.5 : cohérence logique de l'algorithme (ordre...),

0.5 : **bonus (hors barème)** si écriture algorithme avec un seul produit matriciel, cf TP.

13. On remarque sur la figure que la trajectoire affine par morceaux ne se fait pas avec des changements de pentes à angle droit : dit plus précisément, on a pour tout  $k \in \mathbb{N}$ ,  $a^{(k+1)} - a^{(k)}$  n'est pas orthogonal à  $a^{(k+2)} - a^{(k+1)}$ , i.e.  $\langle \nabla F(a^{(k)}), \nabla F(a^{(k+1)}) \rangle \neq 0$ . Ce ne peut donc pas être une trajectoire produite par l'algorithme de descente de gradient à pas optimal qui satisfait nécessairement cette propriété d'orthogonalité (0.5pt).

En effet par définition du pas optimal, soit  $k \in \mathbb{N}$  et supposons  $\nabla F(a^{(k)}) \neq 0$  (sinon  $a^{(k)}$  est le minimum global de  $F$  et l'algorithme s'arrête), on a  $t^{(k)} \in \arg \min_{t > 0} F(a^{(k)} - t \nabla F(a^{(k)}))$ , i.e.  $t^{(k)}$  annule la dérivée de la fonction  $g_k : t \in \mathbb{R}_+^* \mapsto F(a^{(k)} - t \nabla F(a^{(k)}))$  (qui est bien dérivable sur  $\mathbb{R}_+^*$  par

composée de fonction différentiable). Or pour tout  $t > 0$ ,  $g'(t) = -\langle \nabla F(a^{(k)}) - t\nabla F(a^{(k)}), \nabla F(a^{(k)}) \rangle$ , d'où  $\left\langle \nabla F(\underbrace{a^{(k)} - t^{(k)}\nabla F(a^{(k)})}_{a^{(k+1)}}), \nabla F(a^{(k)}) \right\rangle = 0$  (0.75pt).

14. D'après la figure, on remarque que  $k \in \mathbb{N} \mapsto \log(|F(a^{(k)}) - F^*|)$  est une fonction affine de pente négative à partir d'un certain rang, où  $F^* = \min_{\mathbb{R}^n} F$ . Cela signifie que la convergence de  $(F(a^{(k)}))_{k \in \mathbb{N}}$  vers  $F^*$  est linéaire (0.5pt). En effet, il existe  $\sigma > 0$ ,  $\beta \in \mathbb{R}$  et  $k_0 \in \mathbb{N}$  tels que pour tout  $k \geq k_0$ ,  $\log(|F(a^{(k)}) - F^*|) = -\sigma k + \beta$ , ainsi  $|F(a^{(k)}) - F^*| = e^\beta (e^{-\sigma})^k$ , avec  $0 < e^{-\sigma} < 1$  puisque  $\sigma > 0$ , ce qui correspond bien à la définition de la convergence linéaire (0.25pt).

Ceci est cohérent avec le théorème de convergence de l'algorithme.

### Exercice 3 (7.75pt)

Soit  $n \in \mathbb{N}^*$ . Soit  $f$  une fonction  $\mathcal{C}^2$   $m$ -fortement convexe ( $m > 0$ ) sur  $\mathbb{R}^n$  muni de sa norme euclidienne notée  $\|\cdot\|$ . De plus, on suppose que  $\nabla f$  est  $L$ -Lipschitzienne ( $L > 0$ ), i.e. pour tous  $x, y \in \mathbb{R}^n$ ,

$$\|\nabla f(x) - \nabla f(y)\| \leq L \|x - y\|.$$

Soit  $x_0 \in \mathbb{R}^n$  et  $\tau > 0$  fixé. On considère la suite  $(x_k)_{k \in \mathbb{N}}$  définie par récurrence par

$$\forall k \in \mathbb{N}, \quad x_{k+1} = F(x_k),$$

où pour tout  $x \in \mathbb{R}^n$ ,  $F(x) = x - \tau \nabla f(x)$ . On veut trouver une condition sur  $\tau > 0$  de sorte que la suite  $(x_k)_{k \in \mathbb{N}}$  converge.

1. Comment nommeriez-vous cette méthode produisant la suite  $(x_k)_{k \in \mathbb{N}}$  ?
2. Étudier la convexité de  $f$  et montrer que  $f$  admet un unique minimum global, noté  $x^*$ , sur  $\mathbb{R}^n$ .
3. Montrer que pour tous  $x, y \in \mathbb{R}^n$ ,

$$\langle \nabla f(x) - \nabla f(y), x - y \rangle \geq m \|x - y\|^2.$$

4. a) En développant pour tous  $x, y \in \mathbb{R}^n$  la quantité  $\|F(x) - F(y)\|^2$ , en déduire que

$$\|F(x) - F(y)\|^2 \leq (1 + \tau^2 L^2 - 2m\tau) \|x - y\|^2.$$

- b) En déduire que si  $0 < \tau < \frac{2m}{L^2}$ , alors il existe  $0 < \alpha_\tau < 1$  tel que pour tout  $k \in \mathbb{N}^*$

$$\|x_{k+1} - x_k\| \leq \alpha_\tau \|x_k - x_{k-1}\|.$$

On suppose  $0 < \tau < \frac{2m}{L^2}$  dans la suite.

- c) En déduire que  $(x_k)_{k \in \mathbb{N}}$  converge. On notera  $\ell \in \mathbb{R}^n$  sa limite. *Indication : on cherchera à montrer que  $(x_k)_{k \in \mathbb{N}}$  est une suite de Cauchy. On pourra commencer par majorer pour tout  $k \in \mathbb{N}$ , tout  $p \in \mathbb{N}^*$ ,  $\|x_{k+p} - x_k\|$ .*
5. Montrer que la convergence de  $(x_k)_{k \in \mathbb{N}}$  vers  $\ell$  est linéaire.
6. Montrer que  $\ell = x^*$ .
7. a) Soit  $x, h \in \mathbb{R}^n$ . En considérant  $\psi : t \in \mathbb{R} \mapsto \langle \nabla f(x + th), h \rangle$  et en faisant deux développements de Taylor bien choisis, déduire que  $\langle \nabla^2 f(x)h, h \rangle \leq L \|h\|^2$ .
- b) On pose  $c = \frac{L}{m}$ . Que représente cette quantité ?
- c) Trouver la valeur optimale de  $\tau$ , que l'on exprimera en fonction de  $c$ , garantissant la convergence la plus rapide de  $(x_k)_{k \in \mathbb{N}}$  vers  $x^*$ . Commenter la vitesse de convergence de  $(x_k)_{k \in \mathbb{N}}$  lorsque  $c$  se trouve successivement dans ses deux régimes extrêmes.

Correction.

0.5+1+0.75+(0.5+0.5+0.75)+0.5+0.75+(1.25+0.5+0.75)

1. On remarque que c'est une méthode de descente de gradient (0.25pt), mais dont le pas valant  $\tau > 0$  est fixe. On peut donc l'appeler méthode de descente de gradient à pas fixe (0.25pt).

2. Comme  $f$  est  $m$ -fortement convexe et  $\mathcal{C}^2$  sur  $\mathbb{R}^n$ , on a donc pour tout  $x \in \mathbb{R}^n$ ,  $\nabla^2 f(x) \succeq mI_n \succ 0$ , i.e.  $f$  est strictement convexe sur  $\mathbb{R}^n$  (0.5pt). De plus on sait que la  $m$ -forte convexité de  $f$  implique sa coercivité, et comme  $f$  est continue sur  $\mathbb{R}^n$ , on déduit alors l'existence d'un minimum global sur  $\mathbb{R}^n$ , qui est donc unique par stricte convexité (0.5pt).

3. Comme  $g = f - \frac{m}{2} \|\cdot\|^2$  est convexe, on a donc pour tout  $x, y \in \mathbb{R}^n$

$$\begin{aligned} g(y) &\geq g(x) + \langle \nabla g(x), y - x \rangle, \\ g(x) &\geq g(y) + \langle \nabla g(y), x - y \rangle, \end{aligned}$$

avec  $\nabla g = \nabla f - m \text{id}_{\mathbb{R}^n}$ . Ainsi en multipliant par  $-1$  la première inégalité et en les sommant, on obtient

$$\langle \nabla g(x), x - y \rangle \geq \langle \nabla g(y), x - y \rangle,$$

i.e.  $\langle \nabla f(x) - \nabla f(y) - m(x - y), x - y \rangle \leq 0$ , d'où l'inégalité souhaitée (0.75pt).

4. a) Soit  $x, y \in \mathbb{R}^n$ , on a

$$\begin{aligned} \|F(x) - F(y)\|^2 &= \|x - y - \tau(\nabla f(x) - \nabla f(y))\|^2, \\ &= \|x - y\|^2 + \tau^2 \|\nabla f(x) - \nabla f(y)\|^2 - 2\tau \langle \nabla f(x) - \nabla f(y), x - y \rangle, \\ &\leq (1 + \tau^2 L^2 - 2\tau m) \|x - y\|^2. \quad (0.5pt) \end{aligned}$$

b) Posons  $\kappa : \tau \in \mathbb{R}_+ \mapsto 1 + \tau^2 L^2 - 2\tau m$ . C'est une fonction polynomiale de degré 2, positive, de coefficient dominant  $L^2 > 0$ , et qui vaut 1 en 0 et en  $\frac{2m}{L^2}$ . Ainsi pour tout  $\tau \in ]0, \frac{2m}{L^2}[$ , on a  $0 \leq \kappa(\tau) < 1$ , et en posant  $\alpha_\tau = \sqrt{\kappa(\tau)} \in [0, 1[$ , on a pour tout  $k \in \mathbb{N}^*$ ,  $\|x_{k+1} - x_k\| \leq \alpha_\tau \|x_k - x_{k-1}\|$  (0.5pt).

c) Soit  $k \in \mathbb{N}$  et  $p \in \mathbb{N}^*$ , alors

$$\|x_{k+p} - x_k\| \leq \sum_{j=0}^{p-1} \|x_{k+j+1} - x_{k+j}\| \leq \sum_{j=0}^{p-1} \alpha_\tau^{k+j} \|x_1 - x_0\| = \alpha_\tau^k \|x_1 - x_0\| \frac{1 - \alpha_\tau^p}{1 - \alpha_\tau} \leq C_\tau \alpha_\tau^k,$$

avec  $C_\tau = \frac{\|x_1 - x_0\|}{1 - \alpha_\tau} \geq 0$  (0.5pt). Soit  $\varepsilon > 0$ , comme  $\alpha_\tau \in [0, 1[$ , il existe  $k_0 \in \mathbb{N}$ , tel que pour tout  $k \geq k_0$  et  $p \in \mathbb{N}^*$ ,  $\|x_{k+p} - x_k\| \leq \varepsilon$ , i.e.  $(x_k)_{k \in \mathbb{N}}$  est une suite de Cauchy de  $\mathbb{R}^n$  (complet) donc converge vers  $\ell \in \mathbb{R}^n$  (0.25pt).

5. On a montré pour tout  $k \in \mathbb{N}$  et  $p \in \mathbb{N}^*$ ,  $\|x_k - x_{k+p}\| \leq C_\tau \alpha_\tau^k$ . En passant à la limite  $p \rightarrow +\infty$  dans cette inégalité, on obtient  $\|x_k - \ell\| \leq C_\tau \alpha_\tau^k$ , pour tout  $k \in \mathbb{N}$ , donc  $(x_k)_{k \in \mathbb{N}}$  converge linéairement vers  $\ell$  car  $\alpha_\tau \in [0, 1[$  (0.5pt).

6. Comme pour tout  $k \in \mathbb{N}$ ,  $x_{k+1} = F(x_k)$ , par continuité de  $F$  (puisque  $f$  est  $\mathcal{C}^2$ ), on obtient  $\ell = F(\ell)$  en passant à la limite, d'où  $\nabla f(\ell) = 0$ . Or  $f$  admet un unique minimum global, qui est donc l'unique  $x \in \mathbb{R}^n$  satisfaisant  $\nabla f(x) = 0$  comme  $f$  est (strictement) convexe. D'où  $\ell = x^*$  (0.75pt).

Nous venons donc de montrer que la suite  $(x_k)_{k \in \mathbb{N}}$ , définie via la méthode de descente de gradient à pas fixe, converge vers l'unique minimum global de  $f$ , pourvu que le pas de descente est suffisamment petit (appartient à  $]0, \frac{2m}{L^2}[$ )

7. a) La fonction  $\psi$  est  $\mathcal{C}^1$  sur  $\mathbb{R}$  par composée de fonctions  $\mathcal{C}^1$ . Soit  $t \in \mathbb{R}$ , alors par la formule de Taylor-Young à l'ordre 2, on a  $\psi(t) = \psi(0) + t\psi'(0) + o_{t \rightarrow 0}(t)$  et  $\psi(-t) = \psi(0) - t\psi'(0) + o_{t \rightarrow 0}(t)$ . Ainsi en faisant la différence de ces deux équations, on obtient  $\langle \nabla f(x+th) - \nabla f(x-th), h \rangle = 2t\psi'(0) + o_{t \rightarrow 0}(t)$  (0.25pt). Or  $\psi'(t) = \langle \nabla^2 f(x+th)h, h \rangle$  (0.5pt) et par hypothèse sur  $f$  et l'inégalité de Cauchy-Schwarz, on a  $\langle \nabla f(x+th) - \nabla f(x-th), h \rangle \leq \|\nabla f(x+th) - \nabla f(x-th)\| \|h\| \leq 2|t| \|h\|^2$ . Ainsi on obtient

$$2t \langle \nabla^2 f(x)h, h \rangle + o_{t \rightarrow 0}(t) \leq 2|t| \|h\|^2. \quad (0.25pt)$$

Par conséquent en supposant  $t > 0$ , en divisant par  $t$  et en faisant  $t \rightarrow 0$ , on obtient bien l'inégalité souhaitée (0.25pt).

Détails du calcul de  $\psi'$ . Posons  $\eta : u \in \mathbb{R}^n \mapsto \langle u, h \rangle$  et  $\varphi : t \in \mathbb{R} \mapsto \nabla f(x + th)$ . Ce sont des fonctions  $\mathcal{C}^1$  sur leurs ensembles de définition et pour tout  $u, v \in \mathbb{R}^n$ ,  $d\eta(u)(v) = \langle v, h \rangle$ , pour tout  $t \in \mathbb{R}$ ,  $\varphi'(t) = d(\nabla f)(x + th)(h) = \nabla^2 f(x + th)h$ . Ainsi par la formule de la différentielle d'une composée, comme  $\psi = \eta \circ \varphi$ , on a pour tout  $t \in \mathbb{R}$ ,  $\psi'(t) = d\eta(\nabla f(x + th))(\varphi'(t)) = \langle \nabla^2 f(x + th)h, h \rangle$ .

b) D'après la précédente question, on déduit que  $L$  est un majorant de l'ensemble des valeurs propres des  $\nabla^2 f(x)$ , pour  $x \in \mathbb{R}^n$ . Donc  $c$  s'apparente à un conditionnement et on a nécessairement  $c \geq 1$  (0.5pt).

c) La fonction  $\kappa$  définie en 4.b) est minimale en  $\tau = \frac{m}{L^2}$  et  $\kappa\left(\frac{m}{L^2}\right) = 1 - \left(\frac{m}{L}\right)^2 = 1 - \frac{1}{c^2}$ . Ainsi pour ce pas de descente, la convergence est la plus rapide (0.25pt).

Lorsque  $c \rightarrow 1$ , c'est-à-dire les valeurs propres des  $\nabla^2 f(x)$  pour  $x \in \mathbb{R}^n$  sont environ toutes égales, alors le taux de convergence linéaire  $\sqrt{1 - \frac{1}{c^2}}$ , de la méthode, tend vers 0. La convergence devient superlinéaire. Lorsque  $c \rightarrow +\infty$ , i.e. le rapport entre  $\sup\{\lambda : \exists x \in \mathbb{R}^n, \lambda \text{ vp de } \nabla^2 f(x)\} \leq L$  et  $\inf\{\lambda : \exists x \in \mathbb{R}^n, \lambda \text{ vp de } \nabla^2 f(x)\} \geq m$  devient de plus en plus grand, alors le taux de convergence linéaire tend vers 1 : la convergence linéaire est de plus en plus lente (0.5pt).