

## Theory sheet 10

### Différentielle d'ordre deux

La dernière fois, nous avons vu comment approximer  $f(\mathbf{x} + \Delta\mathbf{x})$  pour un petit  $\Delta\mathbf{x}$  en utilisant la différentielle d'ordre un :

$$f(\mathbf{x} + \Delta\mathbf{x}) \approx f(\mathbf{x}) + df(\mathbf{x}, \Delta\mathbf{x}),$$

où

$$df(\mathbf{x}, \Delta\mathbf{x}) = \sum_{j=1}^n \frac{\partial f}{\partial x_j} \Delta x_j = (\text{grad } f(\mathbf{x}))^\top \Delta\mathbf{x}$$

Rappelons que si l'on fait un pas  $\mathbf{x} \rightsquigarrow \Delta\mathbf{x}$  dans la direction orthogonale à  $\text{grad } f(\mathbf{x})$ , l'approximation ci-dessus dégénère :

$$f(\mathbf{x} + \Delta\mathbf{x}) \approx f(\mathbf{x}),$$

ce qui est trivial. Si l'on souhaite tout de même capturer l'effet de ce déplacement sur  $f$ , il nous faut une information plus précise, fournie par l'objet suivant :

**Définition 1.** La différentielle d'ordre deux d'une fonction  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  est l'objet formel suivant :

$$d^2 f(\mathbf{x}) = \sum_{i,j=1}^n \frac{\partial^2 f}{\partial x_i \partial x_j} dx_i dx_j.$$

Comme pour la différentielle d'ordre un, il faut voir  $d^2 f$  comme une fonction de  $\mathbf{x}$  et des accroissements formels  $dx_j$ ,  $j = 1, \dots, n$ . On peut alors évaluer  $d^2 f(\mathbf{x})$  sur n'importe quel vecteur d'accroissements  $\Delta\mathbf{x}$  de la façon suivante :

$$d^2 f(\mathbf{x}, \Delta\mathbf{x}) = \sum_{i,j=1}^n \frac{\partial^2 f}{\partial x_i \partial x_j} \Delta x_i \Delta x_j.$$

Dans le cas  $n = 2$ , cela s'écrit :

$$d^2 f(\mathbf{x}, \Delta\mathbf{x}) = f''_{x_1 x_1}(\mathbf{x}) (\Delta x_1)^2 + 2 f''_{x_1 x_2}(\mathbf{x}) \Delta x_1 \Delta x_2 + f''_{x_2 x_2}(\mathbf{x}) (\Delta x_2)^2.$$

Si  $\Delta\mathbf{x}$  est petit, on a l'approximation suivante :

$$f(\mathbf{x} + \Delta\mathbf{x}) \approx f(\mathbf{x}) + df(\mathbf{x}, \Delta\mathbf{x}) + \frac{1}{2} d^2 f(\mathbf{x}, \Delta\mathbf{x})$$

Si  $n = 2$ , cela s'écrit :

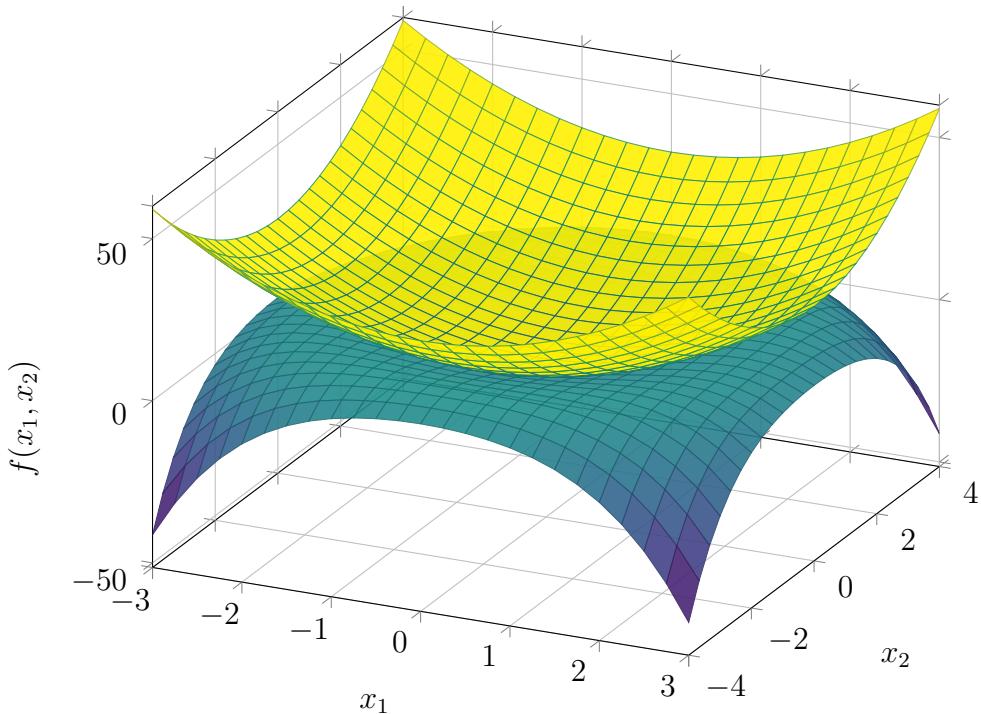
$$\begin{aligned} f(\mathbf{x} + \Delta\mathbf{x}) &\approx f(\mathbf{x}) + f'_{x_1}(\mathbf{x}) \Delta x_1 + f'_{x_2}(\mathbf{x}) \Delta x_2 \\ &\quad + \frac{1}{2} f''_{x_1}(\mathbf{x}) (\Delta x_1)^2 + f''_{x_1 x_2}(\mathbf{x}) \Delta x_1 \Delta x_2 + \frac{1}{2} f''_{x_2}(\mathbf{x}) (\Delta x_2)^2 \end{aligned}$$

Si  $n = 1$ , cela devient encore plus simple :

$$f(x + \Delta) \approx f(x) + f'(x) \Delta + \frac{1}{2} f''(x) \Delta^2.$$

Voici quelques remarques :

- Si  $\Delta\mathbf{x}$  est orthogonale à  $\text{grad } f(\mathbf{x})$ , on a  $f(\mathbf{x} + \Delta\mathbf{x}) \approx f(\mathbf{x}) + \frac{1}{2} d^2 f(\mathbf{x}, \Delta\mathbf{x})$ , donc la dépendance en  $\Delta\mathbf{x}$  ne disparaît plus !
- Pour d'autres  $\Delta\mathbf{x}$ , l'approximation est maintenant plus précise. On dit que la formule encadrée ci-dessus donne l'approximation d'ordre deux de  $f$  au voisinage de  $\mathbf{x}$ .
- À noter qu'en tant que fonction de  $\Delta\mathbf{x}$ , la différentielle d'ordre deux  $d^2 f(\mathbf{x}, \Delta\mathbf{x})$  est une forme quadratique.
- Interprétation géométrique : si l'approximation d'ordre un correspond à la recherche de la meilleure *droite* ou plan épousant le paysage de  $f$  en un point donné, l'approximation d'ordre deux donne la meilleure approximation par paraboloïde/hyperboloïde de  $f$  au voisinage d'un certain  $\mathbf{x}$ . Voici une illustration de cela :



La surface jaune sur ce graphique est donnée par  $z = 3x^2 + 2y^2$ . Il s'agit d'une approximation d'ordre deux de  $z = (3x^2 + 2y^2)(1 - x^2/10 - y^2/20)$ . Remarquez comment les deux surfaces se touchent en  $x = y = 0$ , comment elles restent proches lorsque  $(x, y) \approx (0, 0)$ , mais elles divergent rapidement l'une de l'autre si l'on s'éloigne trop de  $x = y = 0$ .

## Hessian

**Définition 2.** Le *Hessien* d'une fonction  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  en un point  $\mathbf{x} \in \mathbb{R}^n$  est la matrice  $H(\mathbf{x}) \in M_{n,n}$  des dérivées partielles secondes :

$$(H(\mathbf{x}))_{ij} = \frac{\partial^2 f}{\partial x_i \partial x_j}.$$

De la même manière que nous avons utilisé le gradient pour représenter la différentielle d'ordre un par

$$df(\mathbf{x}) = (\text{grad } f(\mathbf{x}))^\top d\mathbf{x},$$

on peut utiliser le Hessien pour représenter la différentielle d'ordre deux :

$$d^2f(\mathbf{x}) = (d\mathbf{x})^\top H(\mathbf{x}) d\mathbf{x}.$$

Cette formule met encore plus en évidence le fait que  $d^2f(\mathbf{x})$  est une forme quadratique en  $d\mathbf{x}$ , comme mentionné ci-dessus.

Notez que  $H(\mathbf{x})$  est symétrique, car les dérivées partielles commutent :

$$(H(\mathbf{x}))_{\mathbf{i}\mathbf{j}} = \frac{\partial^2 f}{\partial x_{\mathbf{i}} \partial x_{\mathbf{j}}} = \frac{\partial^2 f}{\partial x_{\mathbf{j}} \partial x_{\mathbf{i}}} = (H(\mathbf{x}))_{\mathbf{j}\mathbf{i}}.$$

En combinant la description de  $df(\mathbf{x})$  en termes de  $\text{grad } f(\mathbf{x})$  et celle de  $d^2f(\mathbf{x})$  en termes de  $H(\mathbf{x})$ , on obtient

$$f(\mathbf{x} + \Delta\mathbf{x}) \approx f(\mathbf{x}) + (\text{grad } f(\mathbf{x}))^\top \Delta\mathbf{x} + \frac{1}{2} (\Delta\mathbf{x})^\top H(\mathbf{x}) \Delta\mathbf{x}.$$

Cette formule n'est qu'une autre représentation de l'approximation d'ordre deux de  $f$ . De telles approximations sont appelées développements de Taylor (d'ordre un/deux). Il existe aussi des développements de Taylor d'ordre supérieur (utilisant des dérivées d'ordre plus élevé).

## Exemple

Prenons  $n = 2$ , considérons  $f(x, y) = x^y$  définie pour  $x, y > 0$ . Cherchons son développement de Taylor au voisinage de  $x = 1$  et  $y = 2$  :

$$\begin{aligned} f(1, 2) &= 1^2 = 1 \\ f'_x(1, 2) &= yx^{y-1} \Big|_{x=1, y=2} = 2 \\ f'_y(1, 2) &= x^y \ln x \Big|_{x=1, y=2} = 0 \\ f''_{xx}(1, 2) &= y(y-1)x^{y-2} \Big|_{x=1, y=2} = 2 \\ f''_{xy}(1, 2) &= 1 \cdot x^{y-1} + yx^{y-1} \ln x \Big|_{x=1, y=2} = 1 \\ f''_{yy}(1, 2) &= x^y (\ln x)^2 \Big|_{x=1, y=2} = 0. \end{aligned}$$

Donc,

$$\text{grad } f(1, 2) = \begin{pmatrix} 2 \\ 0 \end{pmatrix}, \quad H(1, 2) = \begin{pmatrix} 2 & 1 \\ 1 & 0 \end{pmatrix}.$$

On obtient donc la formule de Taylor d'ordre deux suivante :

$$f(1 + \Delta x, 2 + \Delta y) \approx 1 + 2 \cdot \Delta x + 0 \cdot \Delta y + \frac{1}{2} \cdot 2(\Delta x)^2 + 1 \cdot \Delta x \Delta y + \frac{1}{2} \cdot 0 \cdot (\Delta y)^2.$$

On peut aussi l'écrire ainsi :

$$f(x, y) = 1 + 2 \cdot (x - 1) + 0 \cdot (y - 2) + \frac{1}{2} \cdot 2(x - 1)^2 + 1 \cdot (x - 1)(y - 2) + \frac{1}{2} \cdot 0 \cdot (y - 2)^2,$$

où  $x = 1 + \Delta x \implies \Delta x = x - 1$  et  $y = 2 + \Delta y \implies \Delta y = y - 2$ .

Par exemple, notre approximation donne

$$f(1.01, 2.01) \approx 1.0202,$$

alors que la valeur exacte est

$$f(1.01, 2.01) = 1.020201508\dots$$

## Extrema libres (non contraints) : conditions du premier ordre

**Définition 3.** Un point  $\mathbf{x}_0 \in \mathbb{R}^n$  est un point de maximum local d'une fonction  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  si  $f(\mathbf{x}) \leq f(\mathbf{x}_0)$  pour tout  $\mathbf{x}$  suffisamment proche de  $\mathbf{x}_0$ .

C'est un point de minimum local si  $f(\mathbf{x}) \geq f(\mathbf{x}_0)$  pour tout  $\mathbf{x}$  suffisamment proche de  $\mathbf{x}_0$ .

Rappelons que pour trouver les extrema locaux d'une fonction lisse d'une variable  $f : \mathbb{R} \rightarrow \mathbb{R}$ , on commence par chercher les points candidats à l'extremum, c'est-à-dire les  $x$  tels que

$$f'(x) = 0.$$

Certains de ces points peuvent ne pas être extrémaux (il faut vérifier les conditions du second ordre), mais si  $x$  est un extremum local, alors  $f'(x) = 0$  (la condition est nécessaire).

Si  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  est une fonction de plusieurs variables et que  $\mathbf{x}$  est son minimum ou maximum, alors en particulier c'est un extremum d'une fonction d'une variable  $g(x_j) = f(\mathbf{x})$  (toutes les autres variables sont fixées sauf une ; assurez-vous de bien comprendre cet argument !). Donc  $g'(x_j) = 0$ , ou

$$g'(x_j) = \frac{\partial f}{\partial x_j} = 0.$$

Ainsi, toutes les dérivées partielles doivent être nulles en un point extrémal. On peut écrire cela de façon concise :

$$f'_{x_j}(\mathbf{x}) = 0 \quad \text{pour tout } j = 1, \dots, n,$$

ou en utilisant la notation du gradient :

$$\text{grad } f(\mathbf{x}) = \mathbf{0}.$$

Formulons cela comme un théorème :

**Théorème 1** (Conditions du premier ordre). Si  $\mathbf{x}$  est un point de minimum local ou de maximum local de  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ , alors

$$\text{grad } f(\mathbf{x}) = \mathbf{0}.$$

Comme dans le cas univarié, il s'agit d'une condition nécessaire pour que  $\mathbf{x}$  soit un extrémum, mais pas suffisante.

**Remarque 1.** Considérons  $f(x) = x^3$ . Clairement,  $f'(0) = 3x^2|_{x=0} = 0$ , mais  $x = 0$  n'est ni un minimum, ni un maximum de  $f$ .

## Type d'extremum : conditions du second ordre

Si on a trouvé  $\mathbf{x}_0$  tel que  $\text{grad } f(\mathbf{x}_0) = \mathbf{0}$ , alors on a l'approximation suivante de  $f$  au voisinage de ce point :

$$f(\mathbf{x}) \approx f(\mathbf{x}_0) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_0)^\top H(\mathbf{x}_0) (\mathbf{x} - \mathbf{x}_0).$$

Comment savoir si  $\mathbf{x}_0$  est un minimum ou un maximum ? Peut-il n'être ni l'un ni l'autre ?

Remarquons que  $f(\mathbf{x}) \geq f(\mathbf{x}_0)$  pour  $\mathbf{x} \approx \mathbf{x}_0$  si

$$(\mathbf{x} - \mathbf{x}_0)^\top H(\mathbf{x}_0) (\mathbf{x} - \mathbf{x}_0) \geq 0.$$

Si  $\mathbf{x}$  est un minimum local, cette condition doit être vérifiée pour tout  $\mathbf{x} \approx \mathbf{x}_0$ , ce qui par définition signifie que  $H(\mathbf{x}_0)$  est semi-définie positive.

De même, si  $\mathbf{x}$  est un point de maximum local, alors  $f(\mathbf{x}) \leq f(\mathbf{x}_0)$  pour tout  $\mathbf{x} \approx \mathbf{x}_0$ , ce qui est équivalent à  $H(\mathbf{x}_0)$  étant semi-définie négative.

Ce sont encore des conditions nécessaires, mais qu'en est-il des conditions suffisantes ? Plus précisément, si on a trouvé  $\mathbf{x}_0$  tel que  $\text{grad } f(\mathbf{x}_0) = \mathbf{0}$  et  $H(\mathbf{x}_0)$  est semi-définie positive, peut-on conclure que  $f$  admet un minimum en ce point ? La réponse est : oui, si  $H(\mathbf{x}_0)$  est définie positive (strictement).

**Théorème 2.** Si  $\mathbf{x}_0$  est un point tel que  $\text{grad } f(\mathbf{x}_0) = \mathbf{0}$  et  $H(\mathbf{x}_0)$  est définie positive, alors  $f$  admet un minimum local en ce point.

Si  $\mathbf{x}_0$  est un point tel que  $\text{grad } f(\mathbf{x}_0) = \mathbf{0}$  et  $H(\mathbf{x}_0)$  est définie négative, alors  $f$  admet un maximum local en ce point.

Si  $\mathbf{x}_0$  est un point tel que  $\text{grad } f(\mathbf{x}_0) = \mathbf{0}$  et  $H(\mathbf{x}_0)$  est indéfinie, alors  $f$  n'admet ni maximum local, ni minimum local en ce point.

Si  $\mathbf{x}_0$  est un point tel que  $\text{grad } f(\mathbf{x}_0) = \mathbf{0}$  et  $H(\mathbf{x}_0)$  est semi-définie (positive ou négative), une analyse supplémentaire est nécessaire pour conclure s'il s'agit d'un maximum, d'un minimum ou d'aucun des deux.

**Remarque 2.** Si  $H(\mathbf{x}_0)$  est seulement semi-définie, vérifier si  $\mathbf{x}_0$  est un extremum local demande une analyse plus poussée. Reprenons la remarque précédente : si  $f(x) = x^3$ , son Hessien est une matrice  $1 \times 1$  identifiée à sa dérivée seconde :  $H(x) = f''(x) = 6x$ . En zéro, ce Hessien est nul :  $H(0) = 0$ , donc à la fois  $\geq 0$  et  $\leq 0$ . Cependant,  $x_0 = 0$  n'est clairement pas un extremum local de  $f$ .

Considérons un autre exemple :  $f(x) = x^4$ . Dans ce cas  $H(0) = 0$ , mais on a bien un minimum local en  $x_0 = 0$ . Ces exemples montrent qu'il faut des développements plus précis pour vérifier l'existence d'un extremum en un point où le Hessien est semi-défini.

**Remarque 3.** Rappelons que dire que  $H(\mathbf{x}_0)$  est d'un certain type (définie positive (semi-)/définie négative (semi-)/indéfinie) revient à dire que la forme quadratique correspondante  $d^2f(\mathbf{x}_0)$  est de ce type. C'est pourquoi on parle souvent de  $d^2f(\mathbf{x}_0)$  comme étant d'un certain type.

**Remarque 4.** Géométriquement, un Hessien définie positive (négative) signifie que la fonction  $f$  ressemble à un paraboloïde ouvert vers le haut (bas) au voisinage de  $\mathbf{x}_0$ . Si  $H(\mathbf{x}_0)$  est indéfinie,  $f$  ressemble à un hyperboloid près de  $\mathbf{x}_0$ . Dans ce cas, on dit que  $f$  admet un point selle en  $\mathbf{x}_0$ .

## Example

Soit  $f(x, y) = xe^{-x^2-y^2}$ . Alors

$$f'_x = 0 \implies e^{-x^2-y^2} - 2x^2e^{-x^2-y^2} = 0 \implies x = \pm \frac{1}{\sqrt{2}}$$

et de même

$$f'_y = 0 \implies -2ye^{-x^2-y^2} = 0 \implies y = 0.$$

On a donc deux points candidats à l'extremum :  $(\frac{1}{\sqrt{2}}, 0)$  et  $(-\frac{1}{\sqrt{2}}, 0)$ . Vérifions leur nature :

$$H(\mathbf{x}) = \begin{pmatrix} f''_{xx} & f''_{xy} \\ f''_{xy} & f''_{yy} \end{pmatrix} = e^{-x^2-y^2} \begin{pmatrix} 2x(2x^2-3) & 2y(2x^2-1) \\ 2y(2x^2-1) & 2x(2y^2-1) \end{pmatrix}.$$

Au point  $(\frac{1}{\sqrt{2}}, 0)$  on a

$$H\left(\frac{1}{\sqrt{2}}, 0\right) = e^{-\frac{1}{2}} \begin{pmatrix} \frac{-4}{\sqrt{2}} & 0 \\ 0 & -\frac{2}{\sqrt{2}} \end{pmatrix}.$$

Cette matrice est définie négative, donc  $(\frac{1}{\sqrt{2}}, 0)$  est un maximum local. Ensuite, au point  $(-\frac{1}{\sqrt{2}}, 0)$  on a

$$H\left(-\frac{1}{\sqrt{2}}, 0\right) = e^{-\frac{1}{2}} \begin{pmatrix} \frac{4}{\sqrt{2}} & 0 \\ 0 & \frac{2}{\sqrt{2}} \end{pmatrix}.$$

Comme cette matrice est définie positive,  $(-\frac{1}{\sqrt{2}}, 0)$  est un minimum local de  $f$ .