

# Optimisation

# Structure typique d'un problème d'apprentissage automatique

Optimisation

Entraînement (**procédure de recherche**)

Espace de recherche

Hypothèse/paramètre

Données d'entraînement

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4
5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6	6
7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7
8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8
9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9


Fonction de perte

Evaluation d'une hypothèse

Perte

???

Environnement de production



classifieur

classe prédite

Performance suffisante pour l'application considérée ?

# Optimisation

$$f : \mathcal{D} = \text{dom}(f) \subset \mathbf{R}^n \rightarrow \mathbf{R}$$

$$\min_x f(x) ?$$

- Minimisation d'une fonction sur un domaine
  - Domaine "ouvert" ou non ?
  - Domaine et fonction convexes ?
  - Fonction lisse ou non ?

# Optimisation

1. Optimisation lisse sans contraintes
2. Optimisation lisse avec contraintes
3. Algorithmes d'optimisation
4. Analyse convexe et dualité Lagrangienne
5. Ouverture vers l'optimisation non-lisse

# Définitions

$$f : \mathcal{D} = \text{dom}(f) \subset \mathbf{R}^n \rightarrow \mathbf{R}$$

$$\min_x f(x) ?$$

$x^*$  est un minimum global de  $f$  ssi pour tout  $x \in \text{dom}(f)$ ,  $f(x^*) \leq f(x)$

$x^*$  est un minimum local de  $f$  ssi il existe un ensemble ouvert  $U \subset \text{dom}(f)$  contenant  $x^*$  tel que pour tout  $x \in U$ ,  $f(x^*) \leq f(x)$

# Notions de base de topologie

Dans  $\mathbf{R}^n$ , La boule fermée  $B_f(x, \epsilon)$ , centrée sur  $x$  et de rayon  $\epsilon$  associée à la norme Euclidienne est l'ensemble des points  $y$  de  $\mathbf{R}^n$  tels que  $\|x - y\|_2 \leq \epsilon$

Dans  $\mathbf{R}^n$ , La boule ouverte  $B_o(x, \epsilon)$ , centrée sur  $x$  et de rayon  $\epsilon$  associée à la norme Euclidienne est l'ensemble des points  $y$  de  $\mathbf{R}^n$  tels que  $\|x - y\|_2 < \epsilon$

$U$  est un ouvert de  $\mathbf{R}^n$  ssi  $U \subset \mathbf{R}^n$  et pour tout  $x$  dans  $U$ , il existe  $\epsilon > 0$ , tel que  $B_f(x, \epsilon) \subset U$ .

$U$  est un fermé de  $\mathbf{R}^n$  ssi son complément dans  $\mathbf{R}^n$  est un ouvert de  $\mathbf{R}^n$

# Jacobienne, gradient

$$f : U \subset \mathbf{R}^n \rightarrow \mathbf{R}^m, \text{ de classe } C^1$$

**Dérivée partielle**  $f : x \mapsto (f_1(x), f_2(x), \dots, f_m(x))$

$$\frac{\partial f_i}{\partial x_j} : (a_1, \dots, a_n) \mapsto \lim_{h \rightarrow 0} \frac{f_i(a_1, \dots, a_{j-1}, a_j + h, a_{j+1}, \dots, a_n) - f_i(a_1, \dots, a_j, \dots, a_n)}{h}$$

**Matrice Jacobienne (transposée du gradient si  $m=1$ )**

$$\mathbf{J} = \begin{bmatrix} \frac{\partial \mathbf{f}}{\partial x_1} & \dots & \frac{\partial \mathbf{f}}{\partial x_n} \end{bmatrix} = \begin{bmatrix} \nabla^T f_1 \\ \vdots \\ \nabla^T f_m \end{bmatrix} = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \dots & \frac{\partial f_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial f_m}{\partial x_1} & \dots & \frac{\partial f_m}{\partial x_n} \end{bmatrix}$$

**“Chain rule”**

$$J_{f \circ g}(\mathbf{a}) = J_f(g(\mathbf{a}))J_g(\mathbf{a})$$

# Conditions d'optimalité

Conditions nécessaires, premier ordre

Si  $x^*$  est un minimum local et  $f$  est de classe  $\mathcal{C}^1$  sur un ouvert  $U \subset \mathbf{R}^n$  contenant  $x$ , alors  $\nabla f(x^*) = 0$

# Hessienne


$$f : U \subset \mathbf{R}^n \mapsto \mathbf{R}$$

$$\nabla^2 f = H(f) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix}$$

# Conditions d'optimalité

## Conditions nécessaires, premier ordre

Si  $x^*$  est un minimum local et  $f$  est de classe  $\mathcal{C}^1$  sur un ouvert  $U \subset \mathbf{R}^n$  contenant  $x$ , alors  $\nabla f(x^*) = 0$



## Conditions nécessaires, second ordre

Si  $x^*$  est un minimum local et  $f$  est de classe  $\mathcal{C}^2$  sur un ouvert  $U \subset \mathbf{R}^n$  contenant  $x$ , alors  $\nabla f(x^*) = 0$  et  $\nabla^2 f(x^*)$  est semi-définie positive

## Conditions suffisantes, second ordre

Si  $f$  est de classe  $\mathcal{C}^2$  sur un ouvert  $U \subset \mathbf{R}^n$  contenant  $x$ , si  $\nabla f(x^*) = 0$  et si  $\nabla^2 f(x^*)$  est définie positive, alors  $x^*$  est un minimum local.

# Existence de minimum

## **Théorème de Weierstrass**

Si  $f$  est définie et continue sur un sous-ensemble fermé et borné de  $\mathbf{R}^n$ , alors  $f$  admet un minimum global.

## **Théorème**

Si  $f$  est définie et continue sur  $\mathbf{R}^n$  et *coercive* (i.e.  $f(x) \rightarrow +\infty$  when  $\|x\| \rightarrow +\infty$ ), alors  $f$  admet un minimum global sur tout sous-ensemble fermé de  $\mathbf{R}^n$ .

## **Théorème**

Si  $f$  est convexe et minorée, alors  $f$  admet un minimum global.

# Optimisation

1. Optimisation lisse sans contraintes
2. Optimisation lisse avec contraintes
3. Analyse convexe et dualité Lagrangienne
4. Ouverture vers l'optimisation non-lisse
5. Algorithmes d'optimisation

# Optimisation sous contraintes

$$\min_{x \in \mathbf{R}^n} f(x) \text{ subject to } \begin{cases} c_i(x) = 0, & i \in \mathcal{E} \\ c_i(x) \leq 0, & i \in \mathcal{I} \end{cases}$$

$$\Omega = \{x \in \mathbf{R}^n \mid \text{pour tout } i \in \mathcal{E}, c_i(x) = 0, \text{ pour tout } j \in \mathcal{I}, c_j(x) \leq 0\}$$

$x^*$  est une solution locale du problème ssi  $x^* \in \Omega$  et il existe un ensemble ouvert  $U \subset \mathbf{R}^n$  contenant  $x^*$  tel que pour tout  $x \in U \cap \Omega$ ,  $f(x^*) \leq f(x)$

# Condition nécessaire d'optimalité: intuition


$$f : x_1, x_2 \mapsto x_1 + x_2$$

**Cas d'une seule  
contrainte d'égalité**

$$x_1^2 + x_2^2 = 2$$

**Condition nécessaire  
d'optimalité**

$$\nabla f(x^*) = \lambda_1^* \nabla c_1(x^*).$$



# Condition nécessaire d'optimalité: intuition

$$f : x_1, x_2 \mapsto x_1 + x_2$$

**Cas d'une seule  
contrainte d'inégalité**


$$x_1^2 + x_2^2 \leq 2$$

**Condition nécessaire  
d'optimalité**

$$\nabla f(x^*) = -\lambda_1^* \nabla c_1(x^*)$$

$$\lambda_1^* \geq 0$$

$$\lambda_1^* c_1(x^*) = 0.$$



# Cas général : KKT conditions

Soit  $f$ ,  $(e_i)_{i=1}^{n_E}$  et  $(c_i)_{i=1}^{n_I}$  des fonctions de  $\mathbf{R}^d$  vers  $\mathbf{R}$  de classe  $\mathcal{C}^1$ .

on dit que le point  $x^* \in \mathbf{R}^d$  vérifie les conditions de Karush-Kuhn-Tucker (KKT) pour le problème :

$$\min_{x \in \mathbf{R}^d} f(x) \text{ tel que } \begin{cases} e_i(x) = 0, & i \in \mathcal{E} \\ c_i(x) \leq 0, & i \in \mathcal{I} \end{cases}$$

si et seulement si il existe  $\lambda_E^* \in \mathbf{R}^{n_E}$  et  $\lambda_I^* \in \mathbf{R}^{n_I}$ , tels que :

1.  $\nabla_x \mathcal{L}(x^*, \lambda_E^*, \lambda_I^*) = 0$ , où  $\mathcal{L}(x, \lambda_E, \lambda_I) = f(x) + \sum_{i=1}^{n_E} \lambda_{E,i} e_i(x) + \sum_{i=1}^{n_I} \lambda_{I,i} c_i(x)$
2.  $e_i(x^*) = 0$  pour tout  $i$  dans  $\{1, 2, \dots, n_E\}$
3.  $c_i(x^*) \leq 0$  pour tout  $i$  dans  $\{1, 2, \dots, n_I\}$
4.  $\lambda_{I,i} \geq 0$  pour tout  $i$  dans  $\{1, 2, \dots, n_I\}$
5.  $\lambda_{I,i} c_i(x^*) = 0$  pour tout  $i$  dans  $\{1, 2, \dots, n_I\}$

# Condition nécessaire d'optimalité: cas général

## Mangasarian-Fromovitz Constraint Qualification (MFCQ)

**(Plus d'exemples de qualifications des contraintes sur la feuille d'exercice numéro 1)**

Les gradients des contraintes d'égalité sont linéairement indépendants au point  $x^*$  et il existe un vecteur  $d \in \mathbf{R}^n$  tel que  $\nabla c_i(x^*)^T d < 0$  pour toutes les contraintes d'inégalité **actives** en  $x^*$  et tel que  $\nabla e_j(x^*)^T d = 0$  pour toutes les contraintes d'égalité.

**Théorème :** Si  $x^*$  est une solution locale et que la qualification des contraintes de Mangasarian-Fromovitz est respectée en  $x^*$  alors les conditions KKT sont vérifiées en  $x^*$ .

# Autres exemples de qualifications des contraintes

**Theorem 1** *Conditions nécessaires de solution locale pour des contraintes linéaires. Si les fonctions  $e_i$  et  $c_j$  sont affines pour  $i = 1 \dots n_E$  et  $j = 1 \dots n_I$  alors les conditions KKT sont des conditions nécessaires de solution locale pour le problème considéré.*

**Theorem 2** *Conditions nécessaires de solution locale pour des contraintes linéairement indépendantes.*

*Si au point  $x \in \mathbf{R}^d$  la matrice formée par les gradients des contraintes d'égalité et des contraintes d'inégalité **actives** est de rang plein (c'est à dire que les  $n_E$  vecteurs gradients pour les contraintes d'égalité—qui doivent toujours toutes être actives—et les vecteurs gradients pour les contraintes d'inégalité actives en  $x$ —c'est à dire telles que  $c_i(x) = 0$ —sont linéairement indépendants), alors les conditions KKT sont des conditions nécessaires de solution locale en  $x$  pour le problème considéré.*

**Theorem 3** *Conditions nécessaires de solution locale pour un problème convexe.*

*Si  $f$  est convexe,  $c_i$  est convexe pour tout  $i$  in  $1 \dots n_I$  et  $e_j$  est affine pour tout  $j$  in  $1 \dots n_E$  et si la condition de Slater est vérifiée, c'est à dire s'il existe  $x \in \mathbf{R}^d$  tel que  $e_j(x) = 0$  pour tout  $j$  in  $1 \dots n_E$  et  $c_i(x) < 0$  pour tout  $i$  in  $1 \dots n_I$ , alors les conditions KKT sont des conditions nécessaires de solution locale pour le problème considéré.*