



Introduction à l'Intelligence Artificielle avec les Mathématiques du Lycée

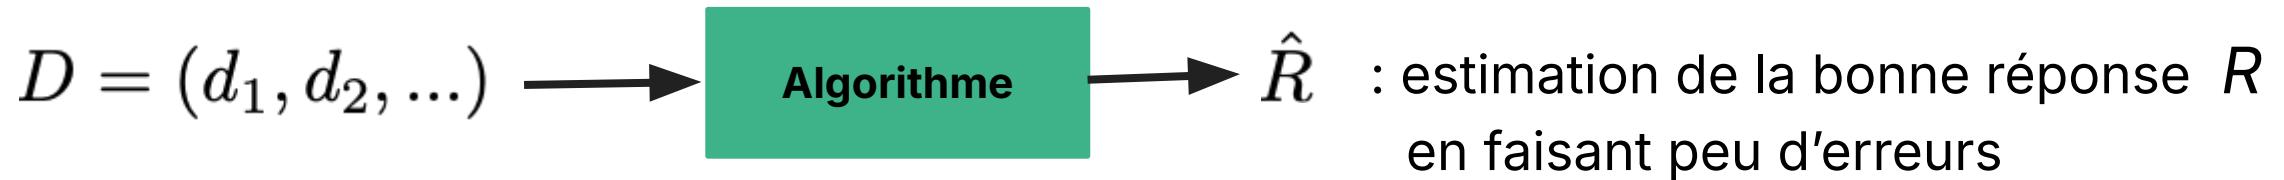


Ils nous soutiennent :



Algorithme d'Intelligence Artificielle

Challenge: répondre à une question à partir d'informations contenues dans des données D



Classification/régression



Voiture, robotique...
Contrôle de systèmes

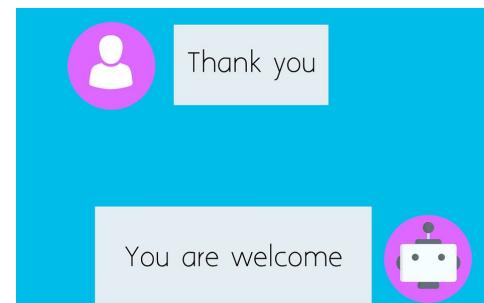


Reconnaissance,
diagnostic médical

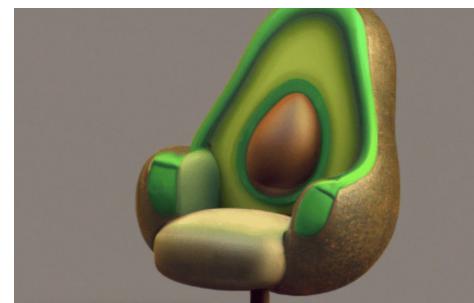


Prédiction météo

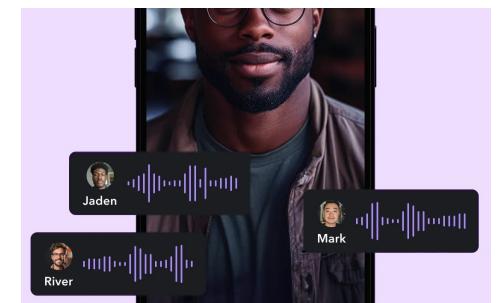
Génération de données



Textes : agent,
chatbot...



Images : vidéo, clip,
publicité...



Sons : musiques,
voix, doublage...



1- Algorithmes d'IA par apprentissage statistique

2- Comprendre l'IA avec les math du Lycée

3- Les réseaux de neurones

4- Enseigner les maths avec des challenges d'IA

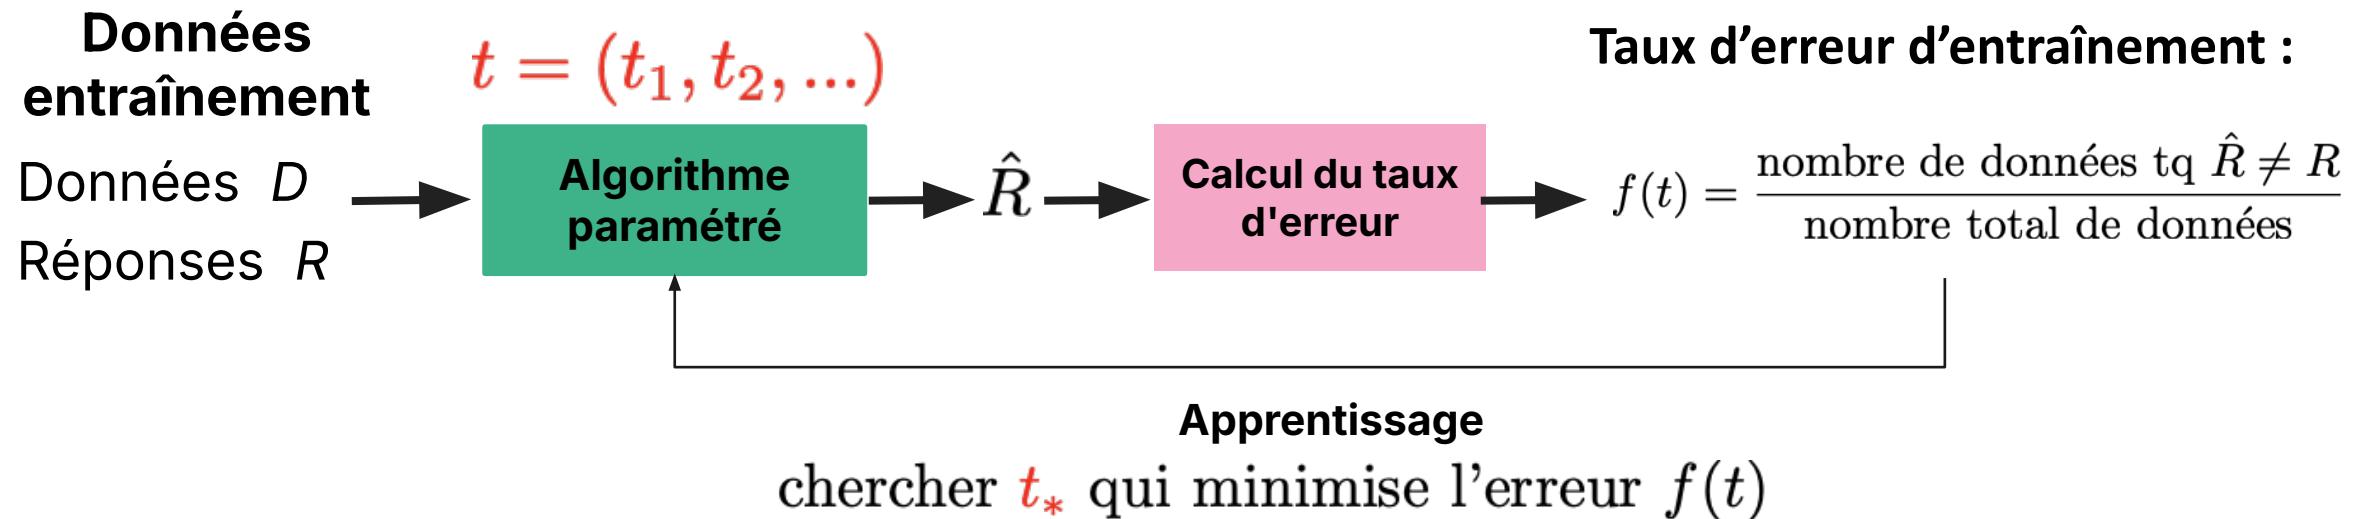


1- Algorithmes d'IA par apprentissage statistique



Estimer la réponse R à une question à partir de données numériques D en faisant peu d'erreurs.

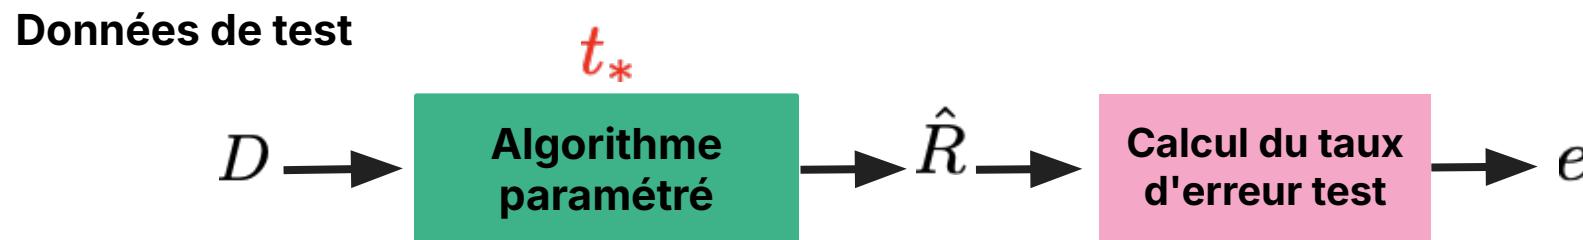
Apprentissage des paramètres de l'algorithme avec une base de données d'entraînement



Test de généralisation de l'apprentissage



Test de l'algorithme sur des nouvelles données après l'apprentissage



L'algorithme généralise si les erreurs de test et d'entraînement sont similaires: $e \approx f(t_*)$,
Il faut suffisamment d'exemples d'entraînement (loi des grands nombres).

Sur-apprentissage si l'erreur est bien plus grande au test qu'à l'entraînement: $e \gg f(t_*)$
Pas assez d'exemples d'entraînement (*apprendre par cœur*).



2- Les mathématiques du lycée au cœur de l'IA

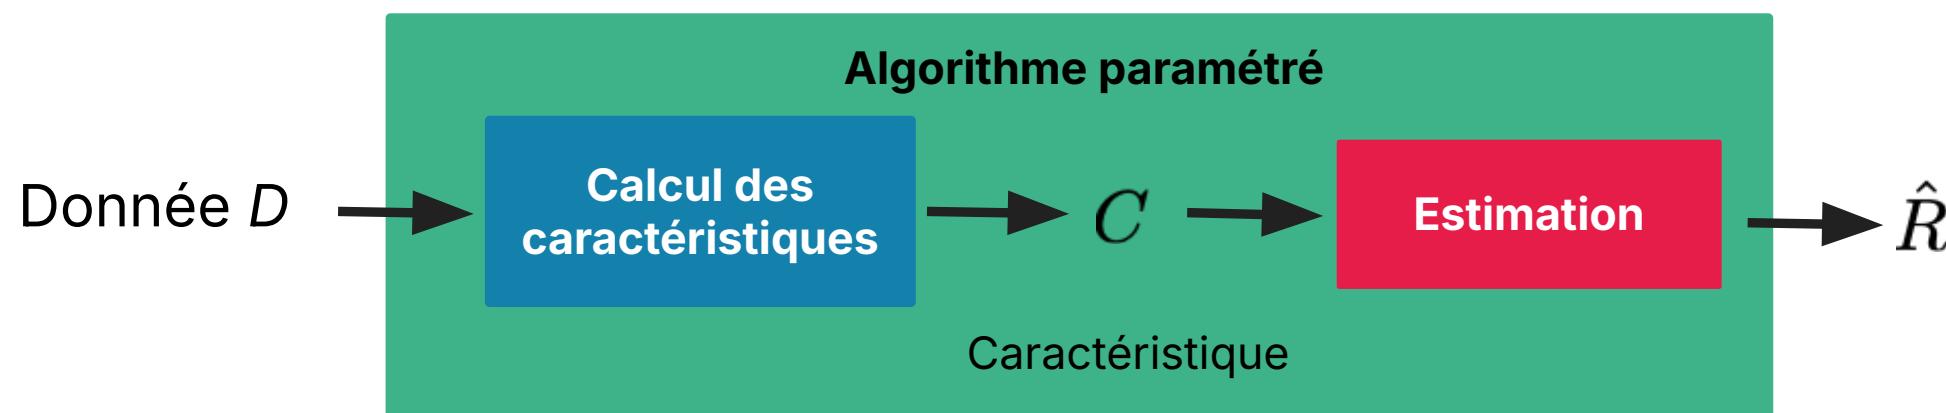
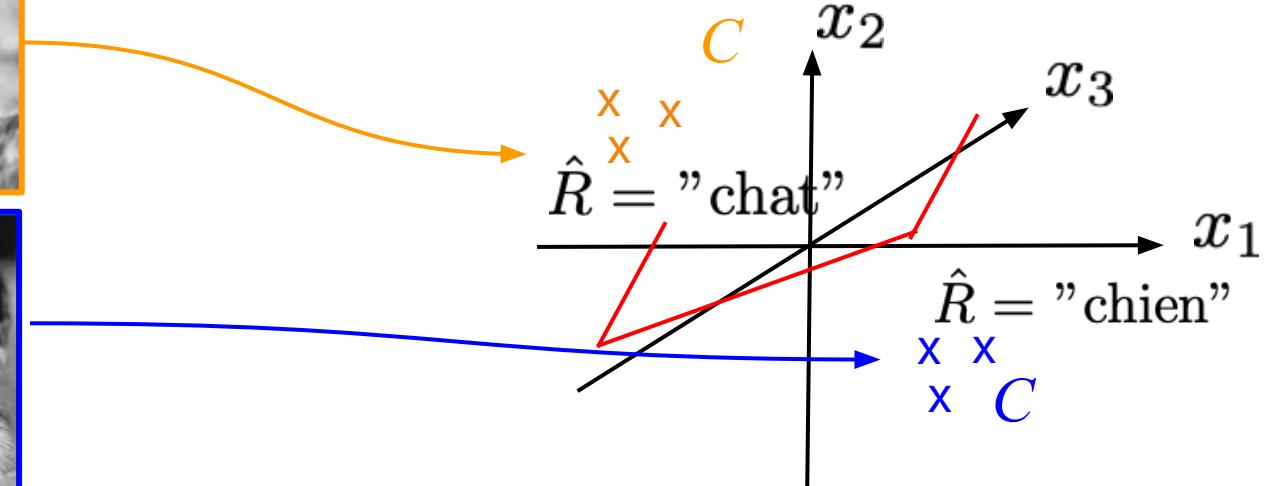


Estimer la réponse avec des caractéristiques

Images: données toutes très différentes



Caractéristiques $C = (x_1, x_2, \dots)$ **similaires** parmi les chats et parmi les chiens et **définitives** entre les chats et les chiens.



Classification de chiffres manuscrits



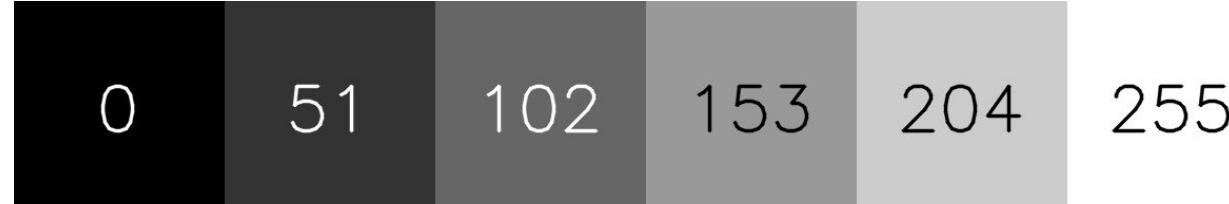
Challenge: Quel est le chiffre R écrit dans une image D ?

On commence par différencier deux classes de chiffres: 2 ou 7



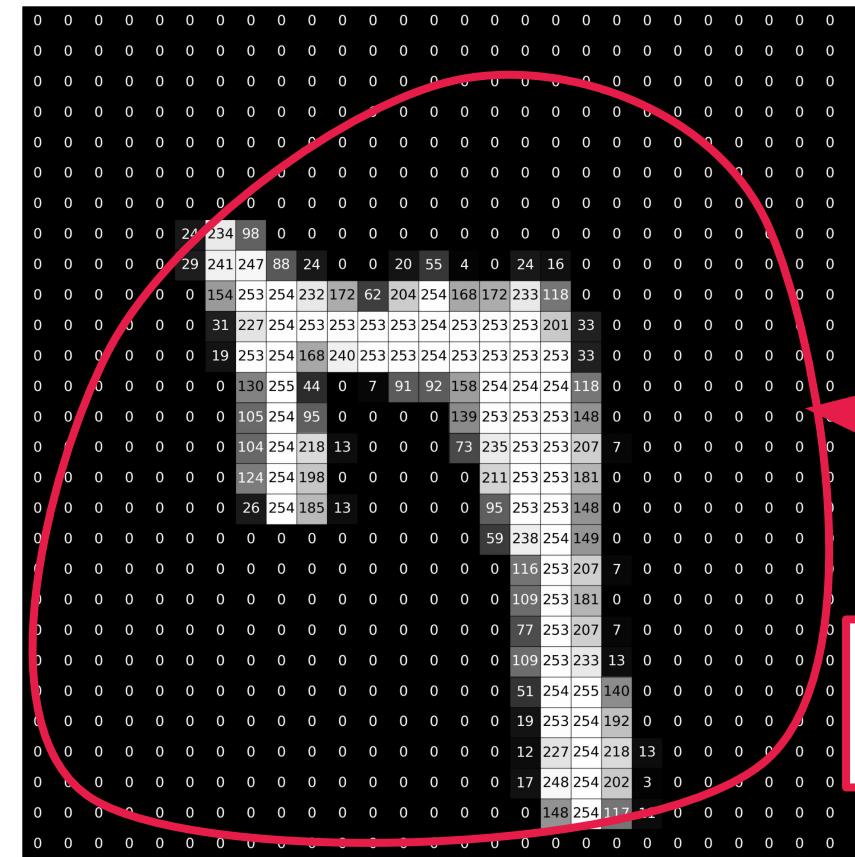
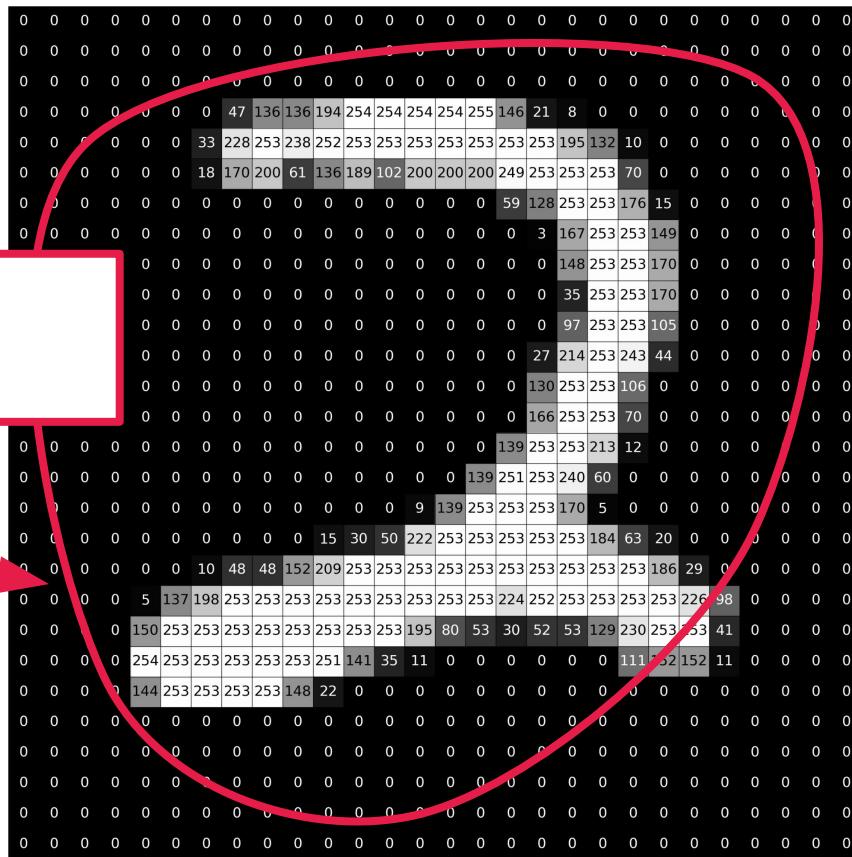
Donnée D : image, tableau de pixels $D = (d_1, d_2, \dots, d_{784})$

valeurs des pixels



Quelle caractéristique choisir ?

Plus de pixels
blanc

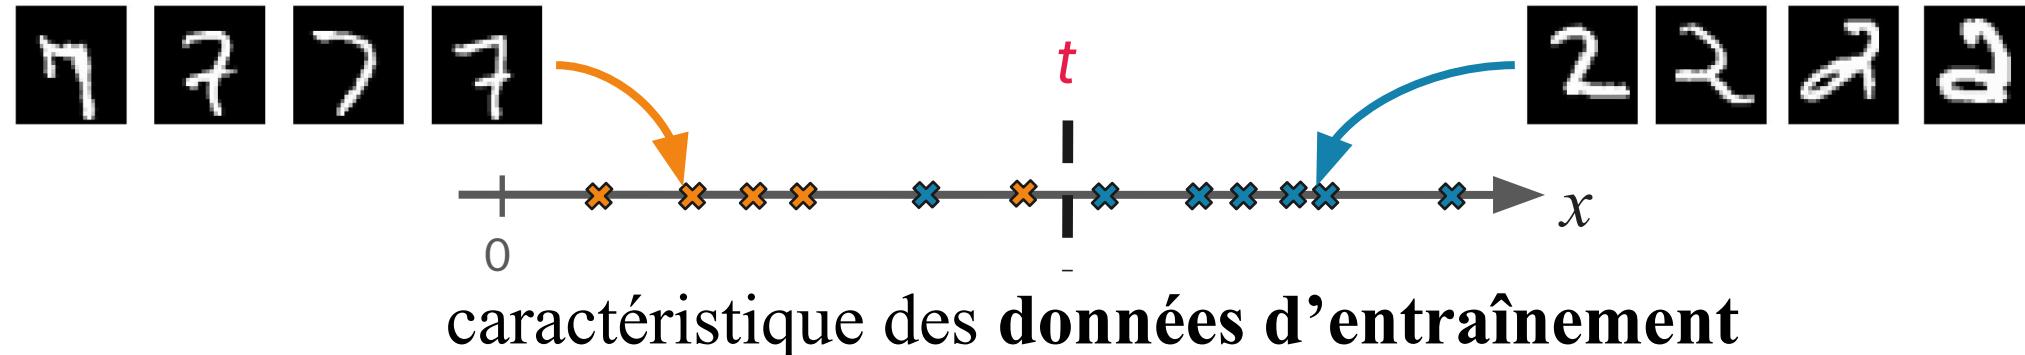


Exemple d'une caractéristique $C = x$ qui différencie les 2 des 7:

x = valeur moyenne des pixels de l'image



Estimation avec 1 caractéristique



Estimation :

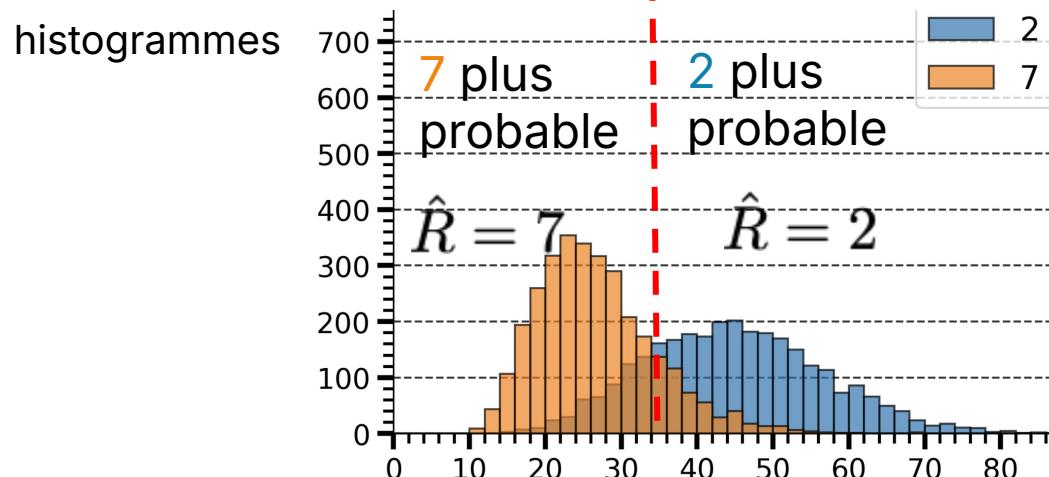
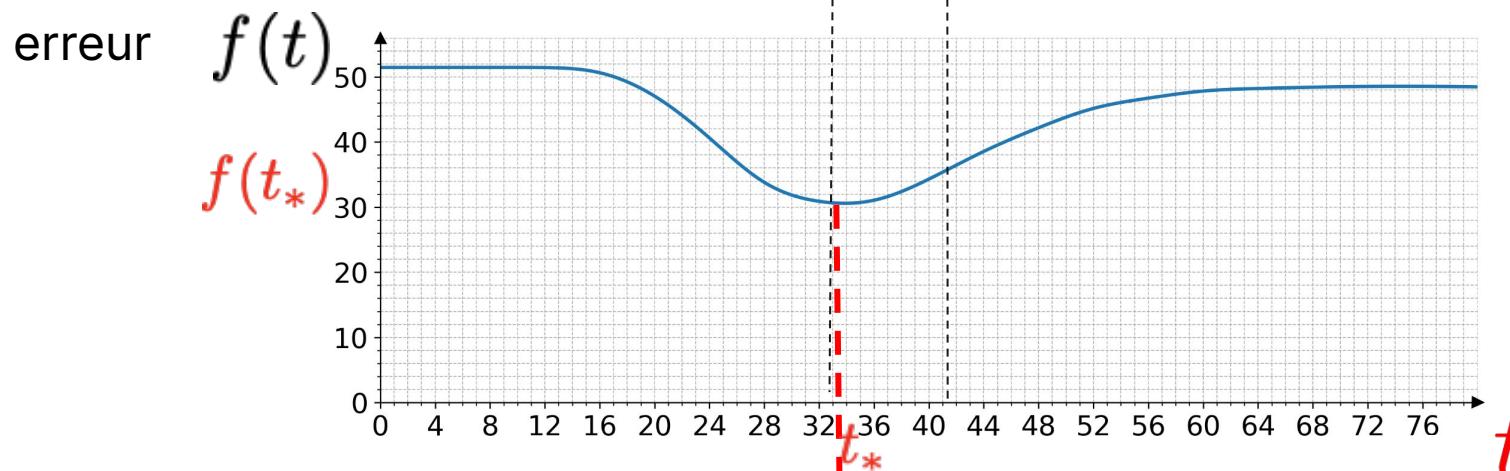
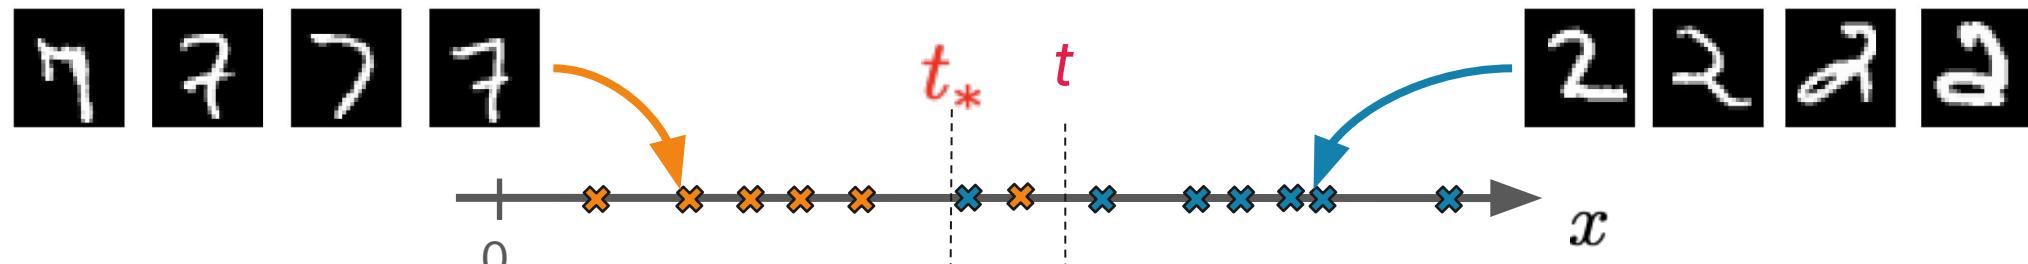
$$\hat{R} = \begin{cases} 7 & \text{si } x < t \\ 2 & \text{si } x \geq t \end{cases}$$

Erreur moyenne : $f(t) = \frac{\text{nombre de données tq } \hat{R} \neq R}{\text{nombre total de données}} = \hat{Prob}(\hat{R} \neq R)$

Probabilité empirique que $\hat{R} \neq R$ calculée sur les données d'entraînement.



Apprentissage du paramètre



Apprentissage : chercher t pour minimiser $f(t)$

L'erreur est minimum si \hat{R} est la réponse la plus probable sachant la valeur de la caractéristique $C = x$.



Apprentissage optimale et probabilité conditionnelle



Minimiser l'erreur $\hat{Prob}(\hat{R} \neq R)$ \Leftrightarrow Maximiser la précision $\hat{Prob}(\hat{R} = R) = 1 - \hat{Prob}(\hat{R} \neq R)$

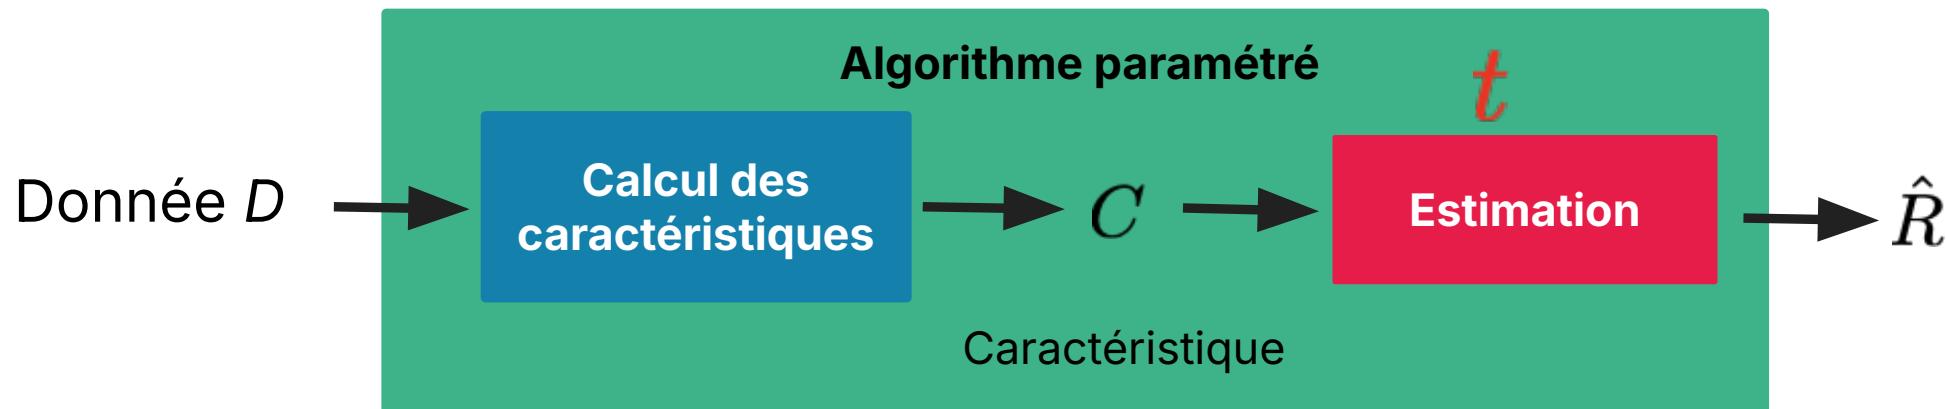
$$\hat{Prob}(\hat{R} = R) = \sum_C \hat{Prob}(\hat{R} = R | C) \hat{Prob}(C)$$

La précision $\hat{Prob}(\hat{R} = R)$ est donc max si $\hat{Prob}(\hat{R} = R | C)$ est max.

L'erreur est donc minimum si \hat{R} est la réponse la plus probable sachant C



Optimisation d'un Algorithme d'IA

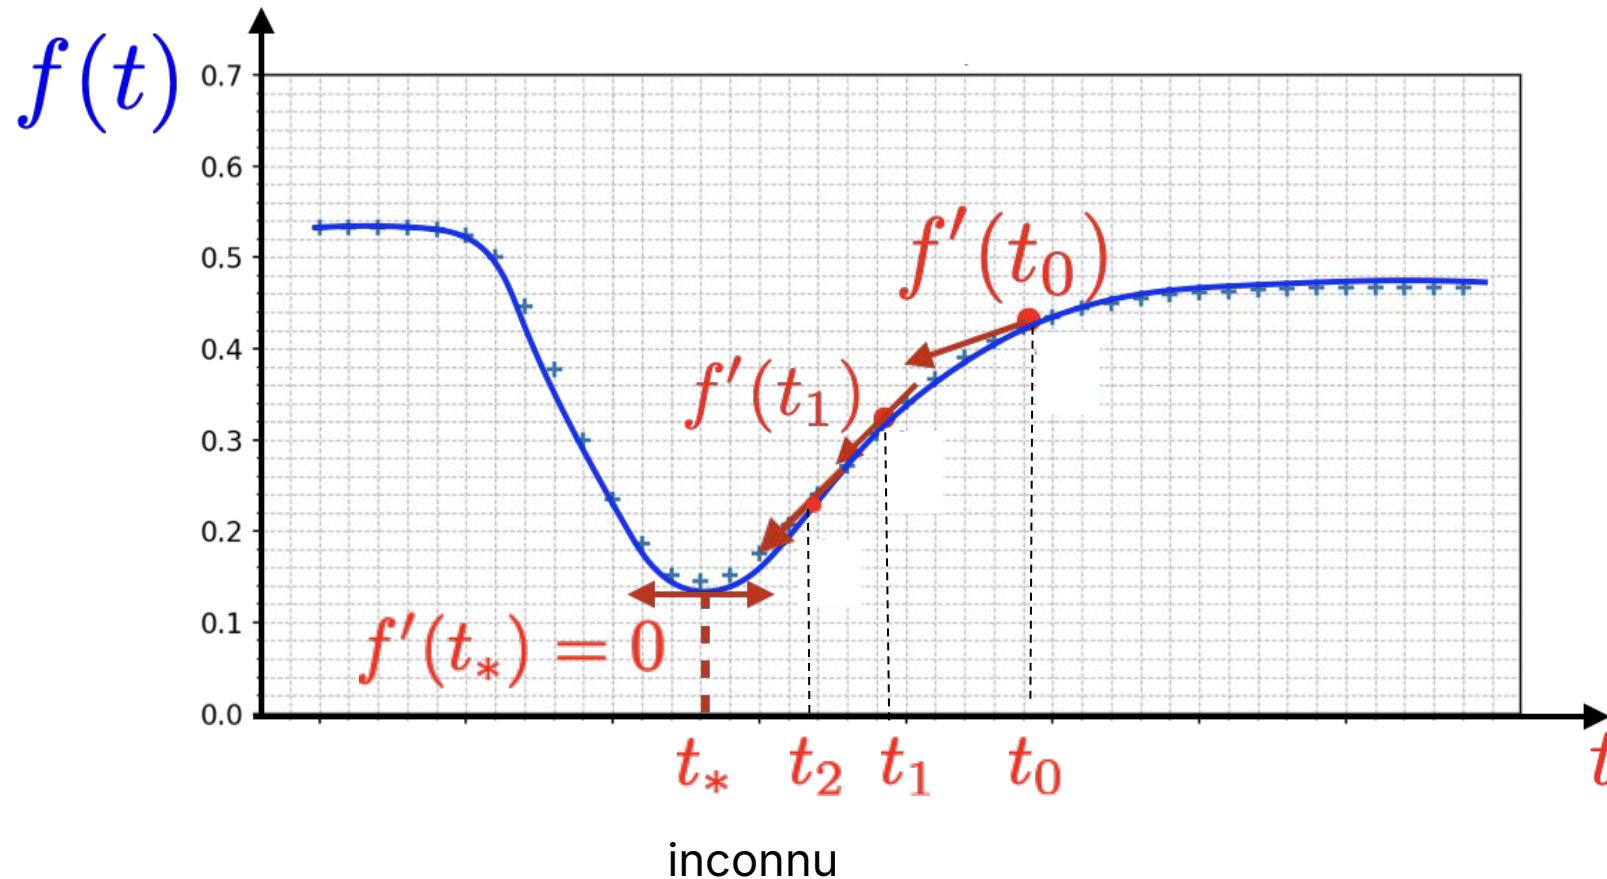


- **Apprendre:** chercher t_* qui minimise l'erreur $f(t)$ à l'entraînement.
- **Généralisation:** erreur du même ordre au test qu'à l'entraînement.
- **Modèle:** choix de caractéristique C qui réduit l'erreur minimum $f(t_*)$ peut être apprise (réseaux de neurones).



Minimiser l'erreur par descente de dérivée

L'erreur $f(t)$ est une moyenne sur les exemples d'entraînement: long à calculer.
On veut chercher le minimum de $f(t)$ en faisant le moins d'essais possibles.



Descente de dérivée: $t_{n+1} = t_n - \epsilon f'(t_n)$ $\xrightarrow[n \rightarrow \infty]{} t_*$ si unique min local.

Généralisation et loi des grands nombres



À quelle condition un algorithme fera-t-il aussi peu d'erreurs sur des exemples de tests que sur des exemples d'entraînement ?

L'apprentissage minimise la moyenne empirique des erreurs sur m exemples d'entraînement qui sont supposés être **indépendants** (*problèmes des biais*)

Loi des grands nombres: si m est assez grand, les erreurs X_i des données ont une moyenne qui converge vers l'espérance (*ne dépend quasiment pas des exemples*):

$$\frac{X_1 + \dots + X_m}{m} \xrightarrow[m \rightarrow \infty]{} \mathbb{E}(X) \text{ en probabilité}$$

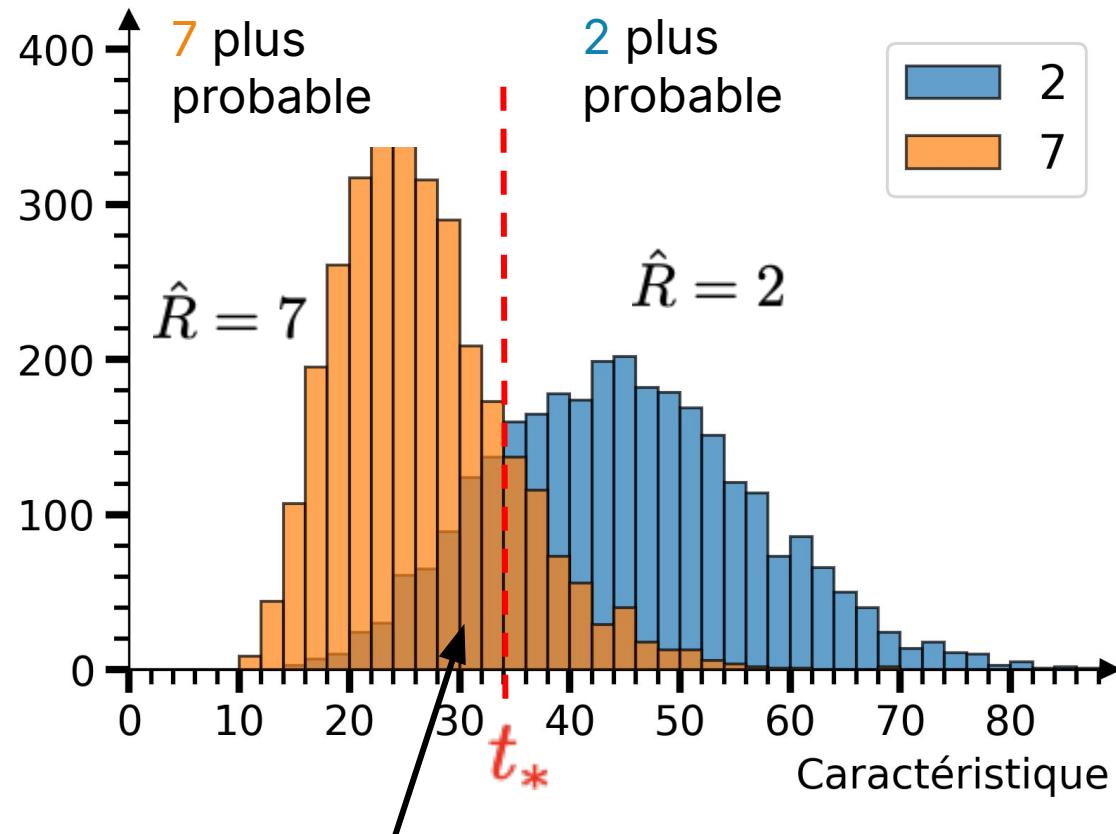
→ généralise si on a assez d'exemples d'entraînement indépendants: m grand.

→ le nombre m d'exemples doit être grand relativement au nombre de paramètres ajustés lors de l'apprentissage.

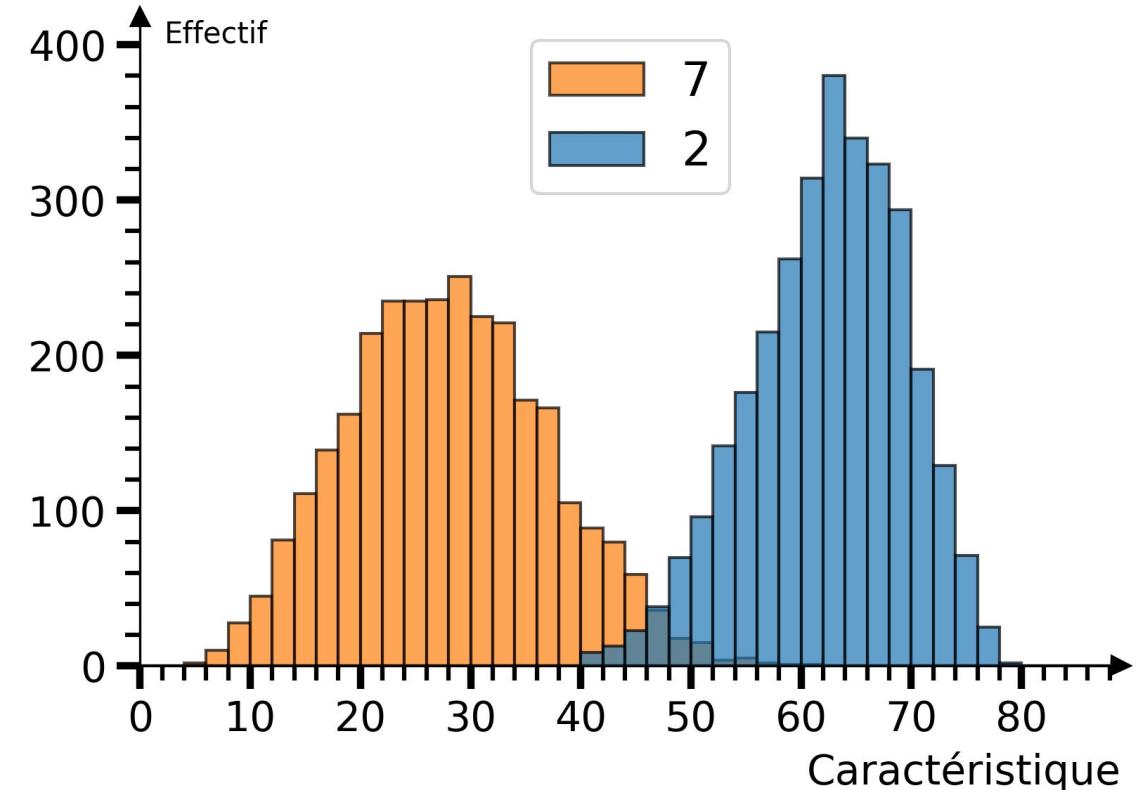


Choix de la caractéristique

On choisit la caractéristique qui sépare mieux les classes



Erreur minimum = surface de recouvrement
des histogrammes



Erreur plus faible: distributions mieux séparées



Moins d'erreur avec 2 caractéristiques

Mieux différencier les classes avec 2 caractéristiques complémentaires

Grandes valeurs partie basse

0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0

x_1

x_2

Grandes valeurs partie haute

0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0

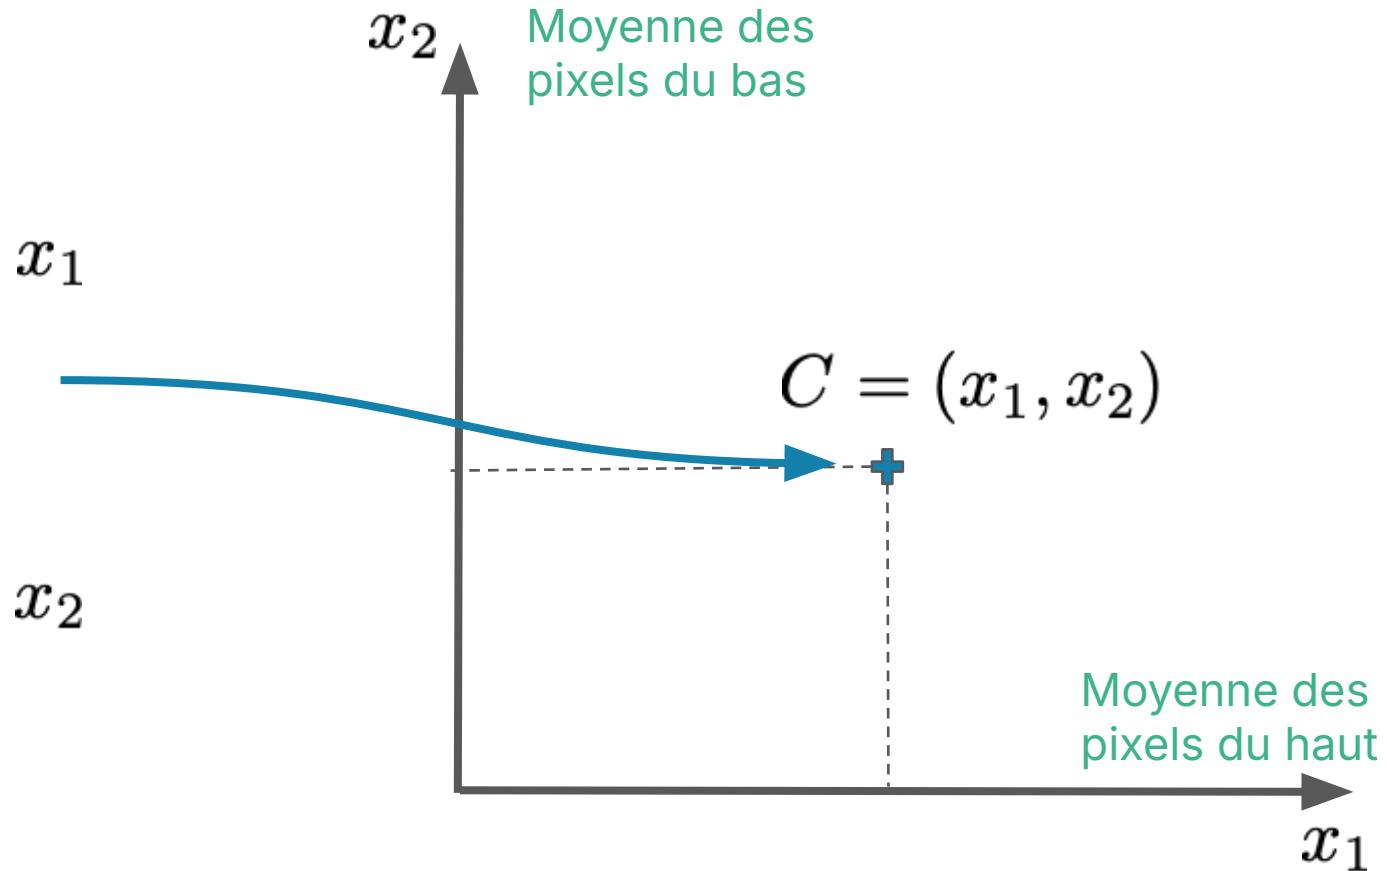
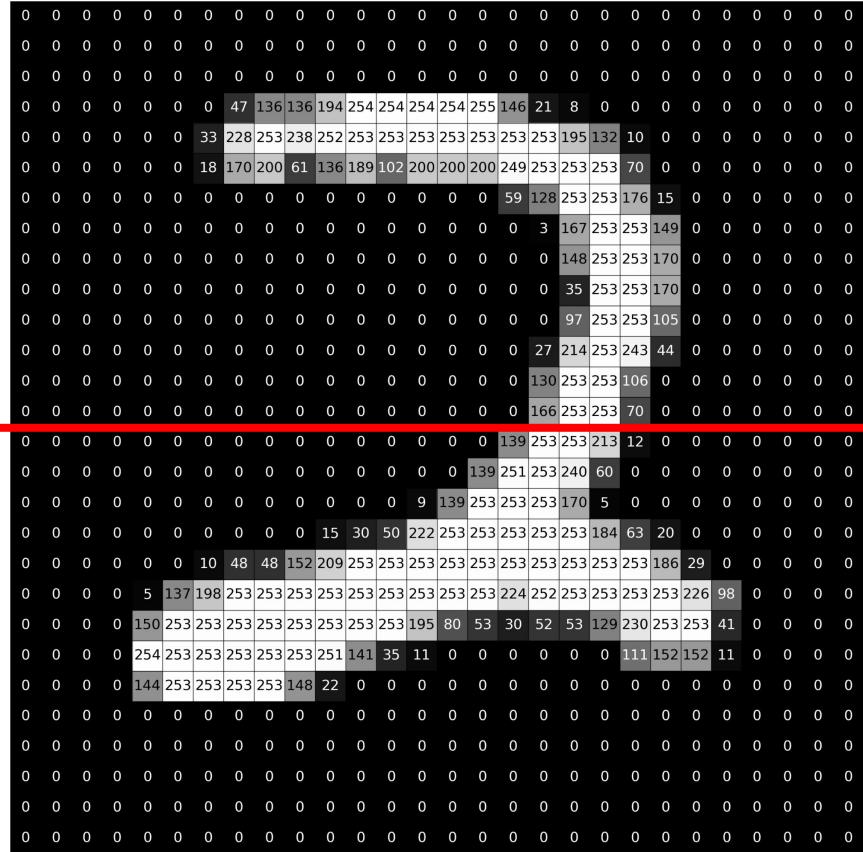
x_1

x_2

(x_1, x_2) : moyennes des pixels dans les parties haute et basse de l'image



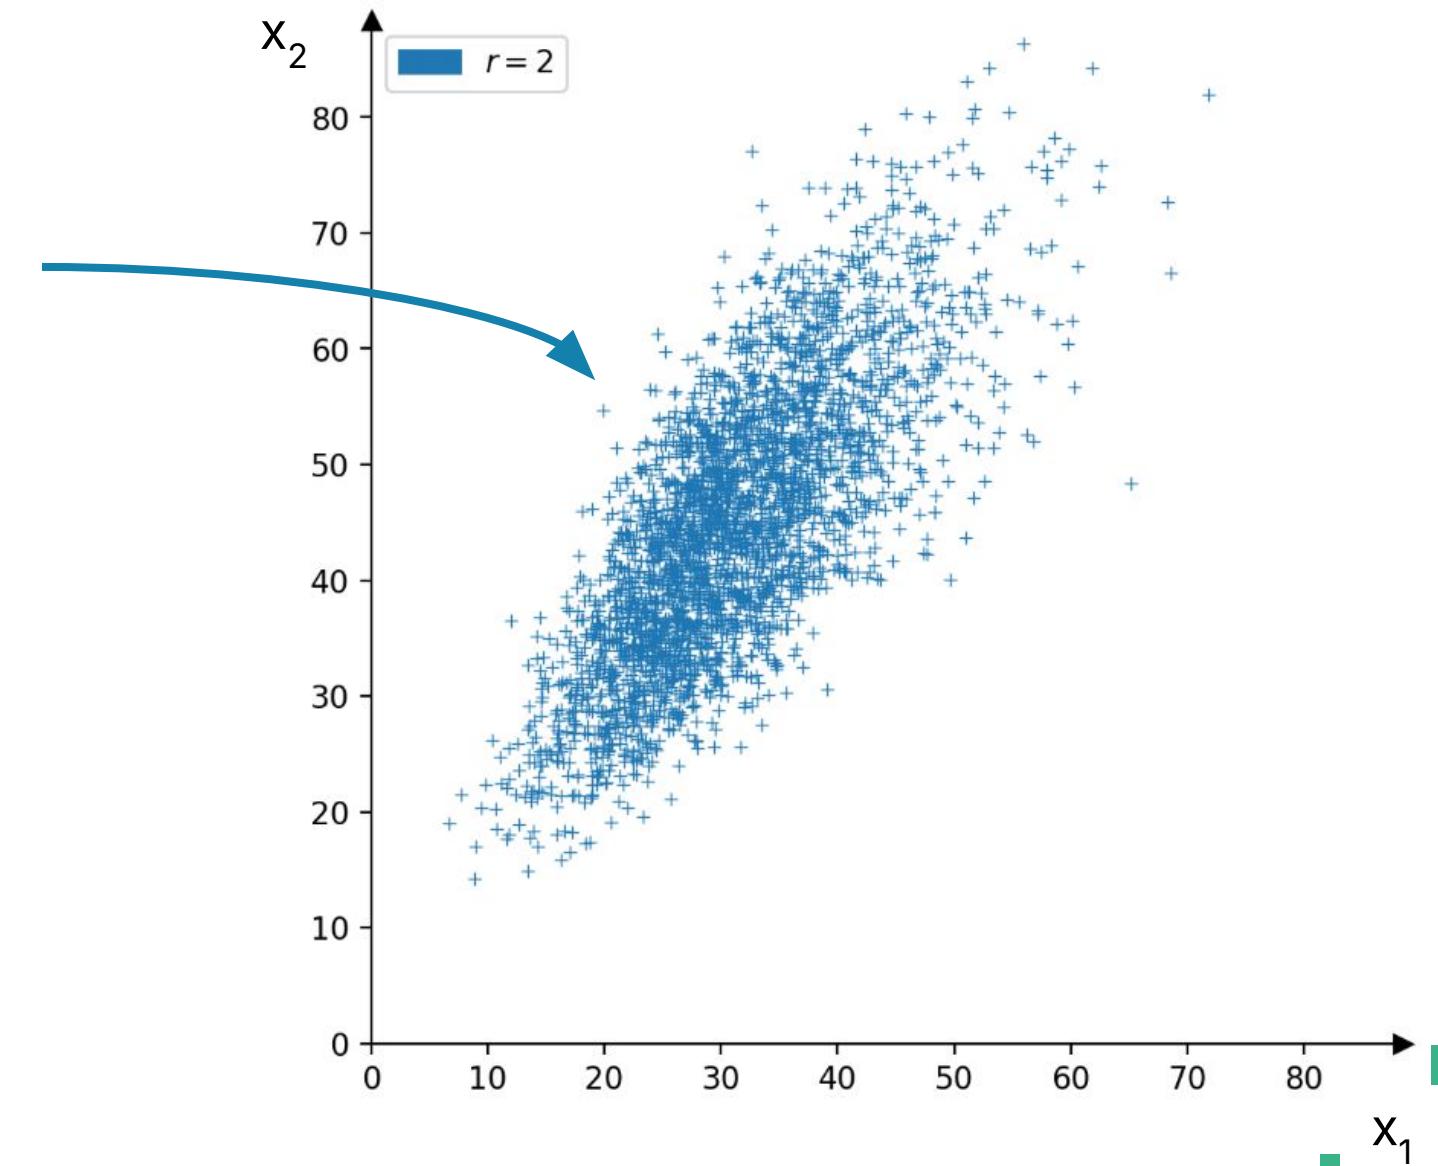
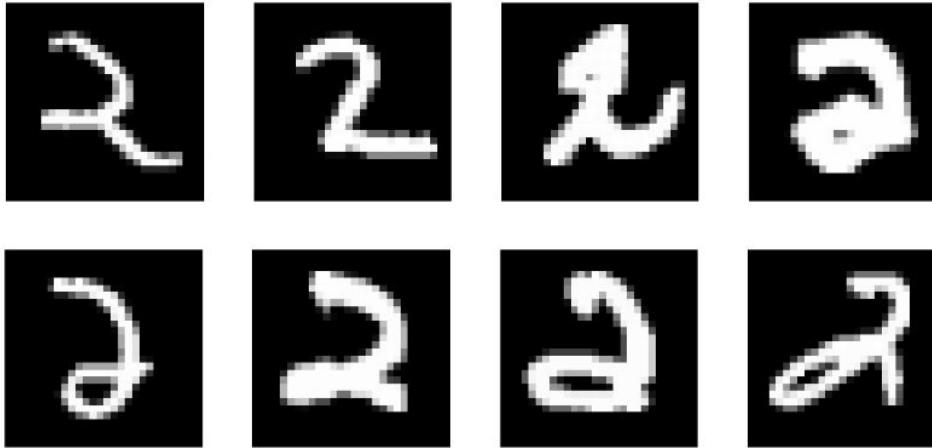
Représentation d'une caractéristique dans un plan



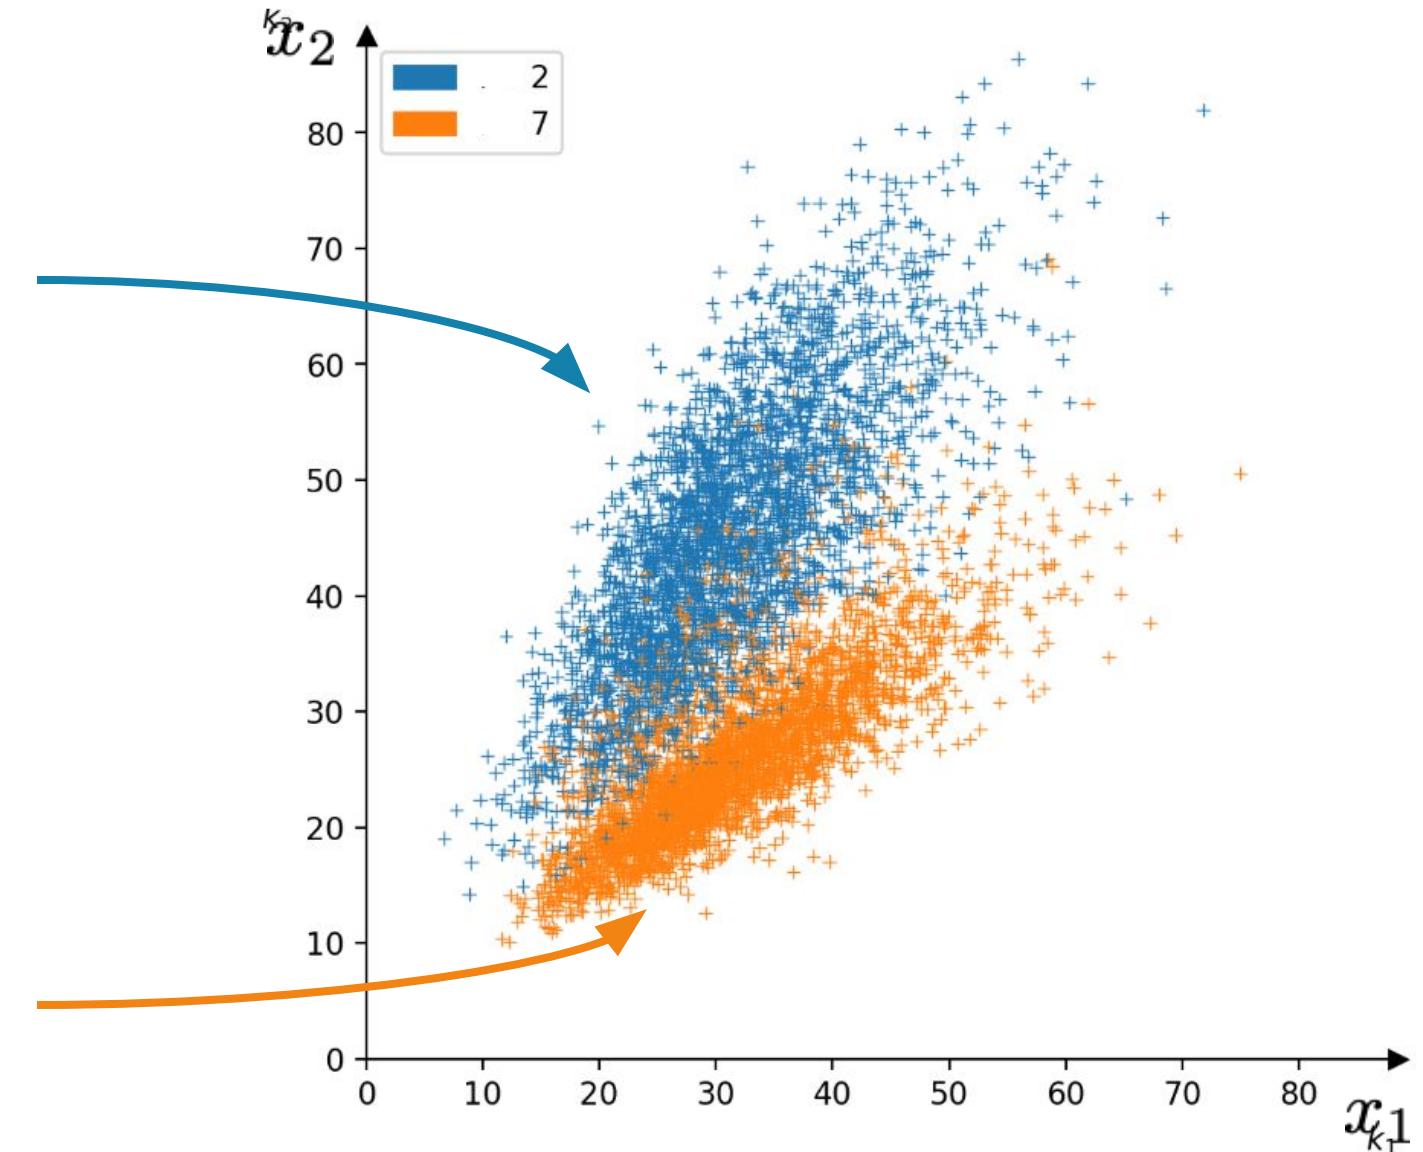
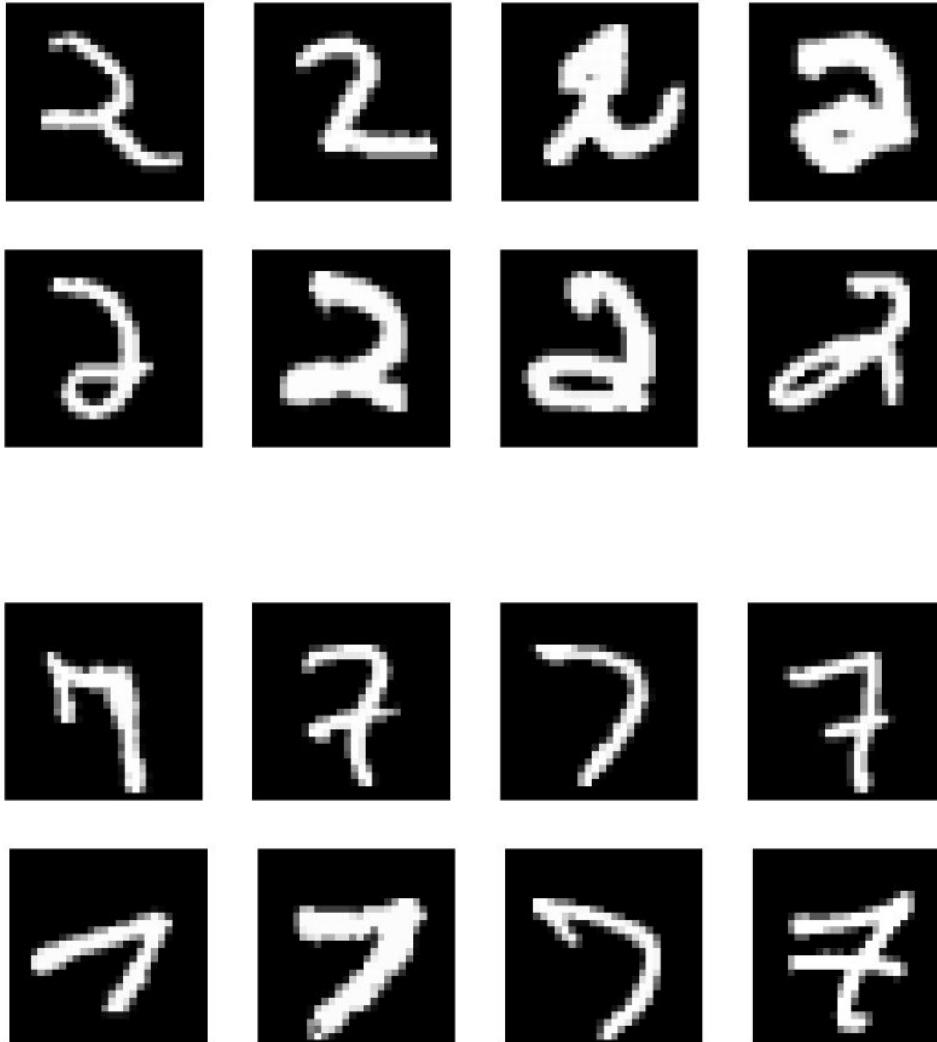
(x_1, x_2) : moyennes des pixels dans les parties haute et basse de l'image



Caractéristiques des images d'entraînement



Caractéristiques des images d'entraînement



Frontière des classes : droite

L'erreur est minimum si \hat{R} est la réponse la plus probable sachant C

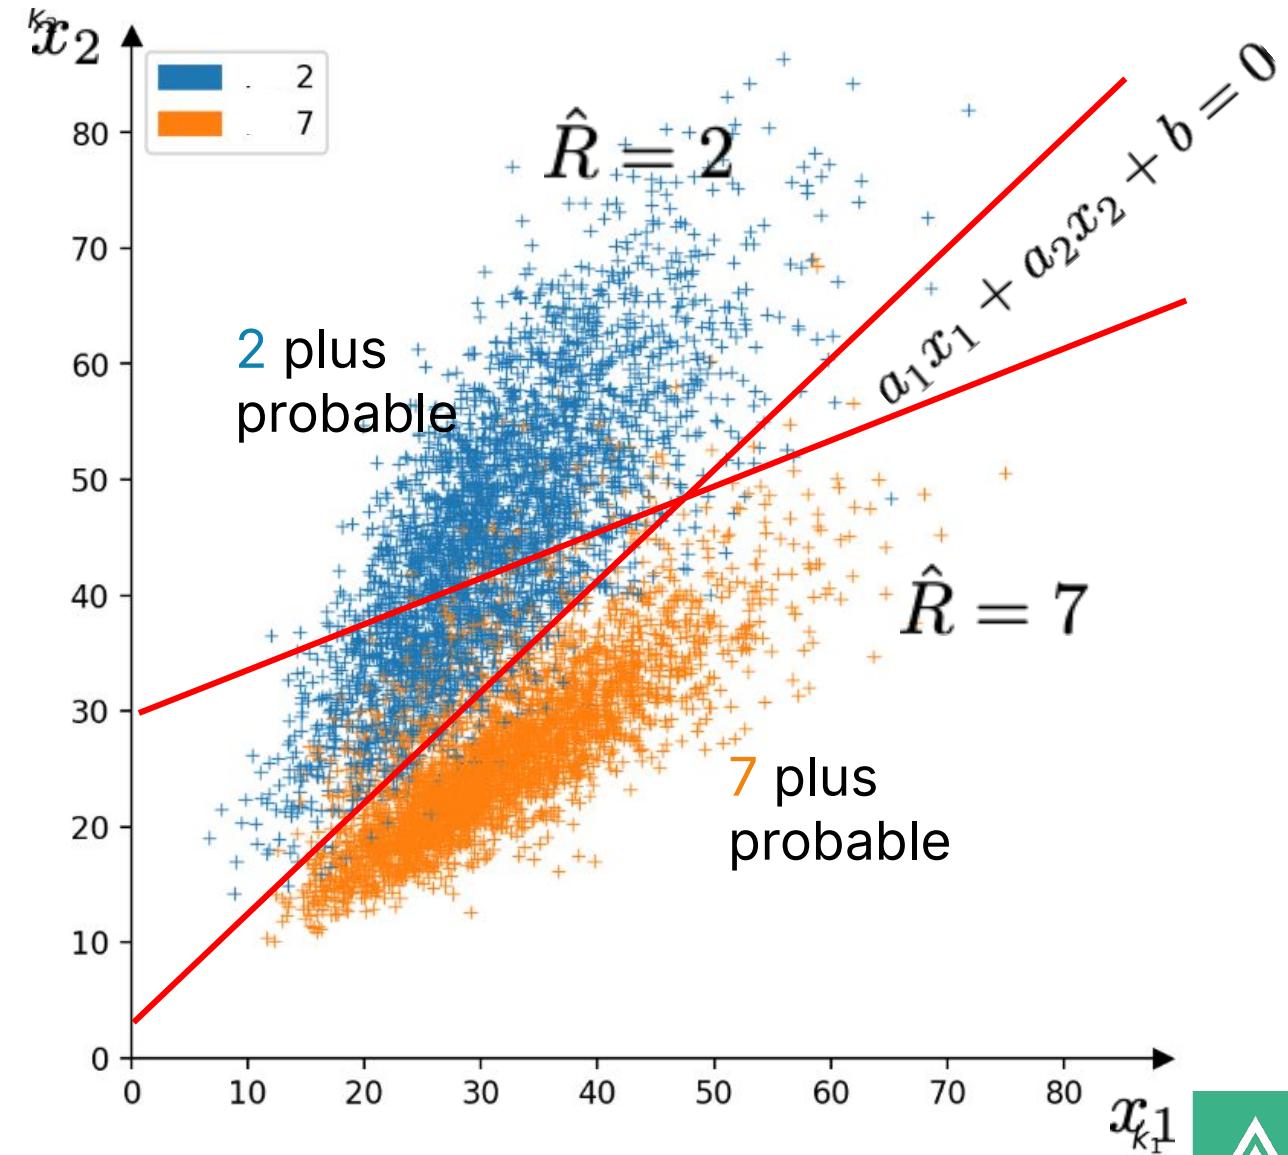
Frontière approximée par une droite

$$a_1x_1 + a_2x_2 + b = 0$$

Paramètres de la droite: $t = (a_1, a_2, b)$

L'erreur $f(t)$ dépend de $t = (a_1, a_2, b)$

Apprendre: chercher t qui minimise $f(t)$.



Représentation vectorielle des classes

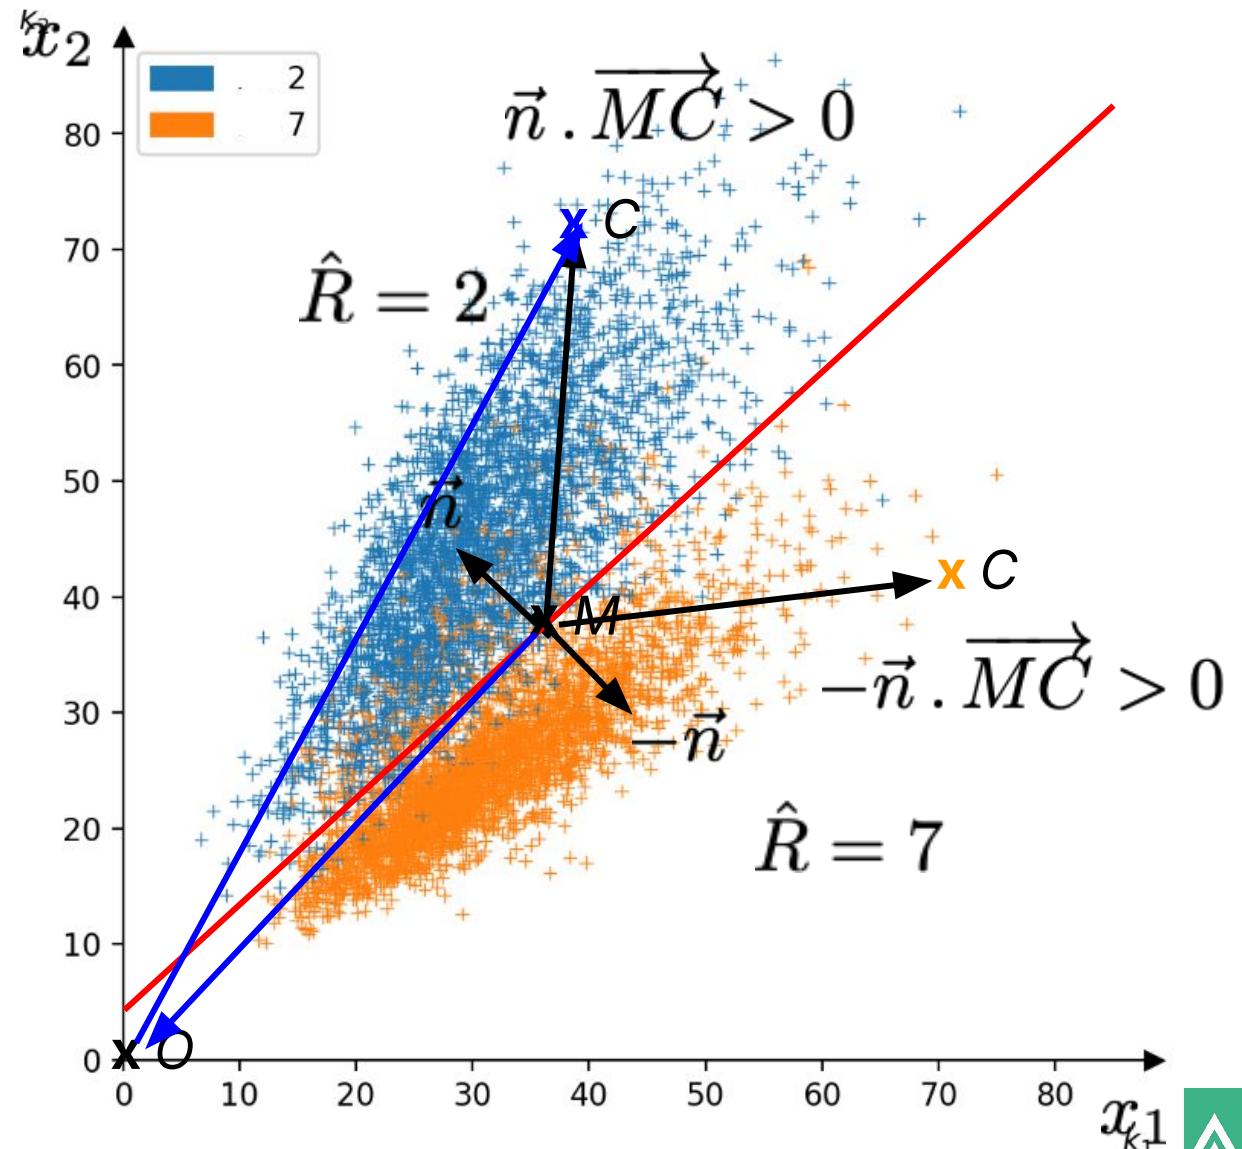
un point sur la droite : M

vecteur normal $\vec{n} = \begin{pmatrix} a_1 \\ a_2 \end{pmatrix}$

Pour une caractéristique $C = (x_1, x_2)$

$$\hat{R} = \begin{cases} 2 & \text{si } \vec{n} \cdot \overrightarrow{MC} > 0 \\ 7 & \text{si } -\vec{n} \cdot \overrightarrow{MC} > 0 \end{cases}$$

$$\begin{aligned}\vec{n} \cdot \overrightarrow{MC} &= \vec{n} \cdot \overrightarrow{MO} + \vec{n} \cdot \overrightarrow{OC} \\ &= b + a_1 x_1 + a_2 x_2\end{aligned}$$



Plus de classes : découpage par morceaux de droites

Point M au centre des caractéristiques

Chaque \vec{n}_k pointe vers la classe k

$\hat{R} = k$ tel que
 $v_k = \vec{n}_k \cdot \overrightarrow{MC}$ est maximum

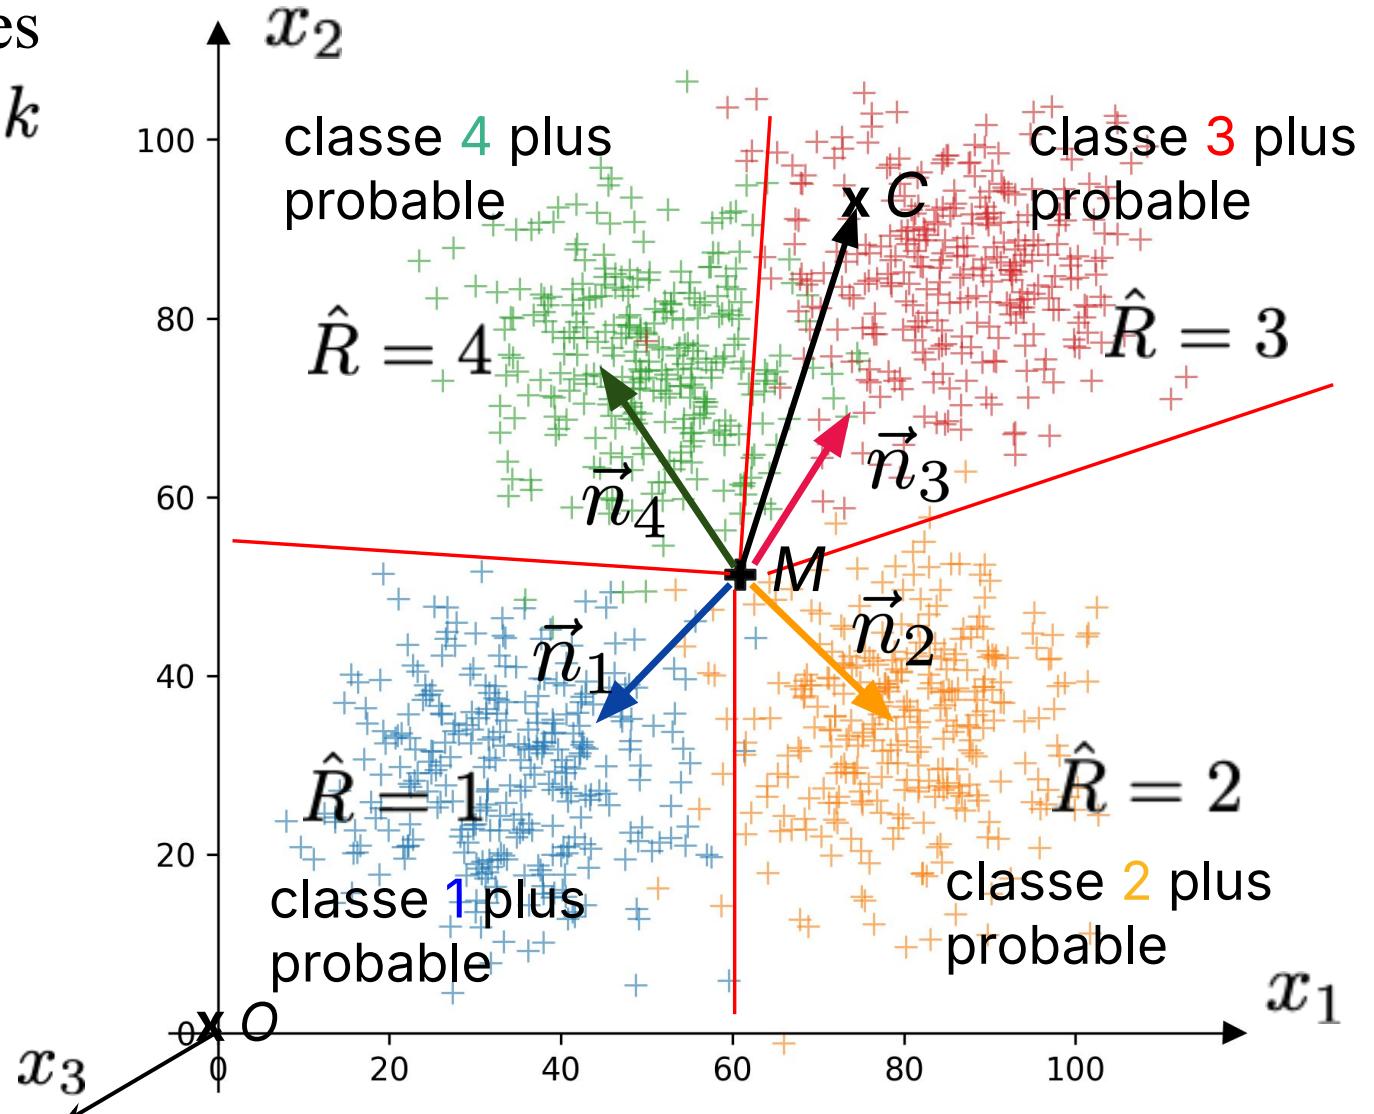
vraisemblance de la classe k

$$v_k = b_k + \vec{n}_k \cdot \overrightarrow{OC}$$

Apprendre: chercher

$$t = ((\vec{n}_1, b_1), (\vec{n}_2, b_2), (\vec{n}_3, b_3), (\vec{n}_4, b_4))$$

qui minimise l'erreur $f(t)$.

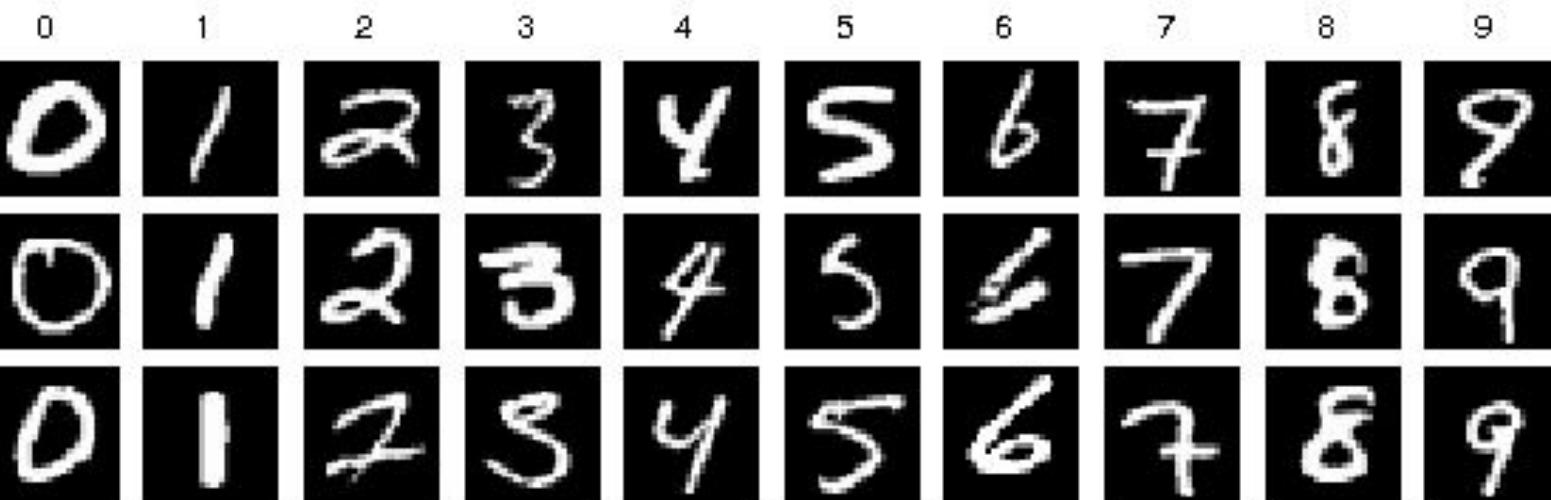


Si plus de caractéristiques $C = (x_1, x_2, x_3, \dots)$ alors $\vec{n} = (a_1, a_2, a_3, \dots)$: pareil.

3- Réseaux de Neurones

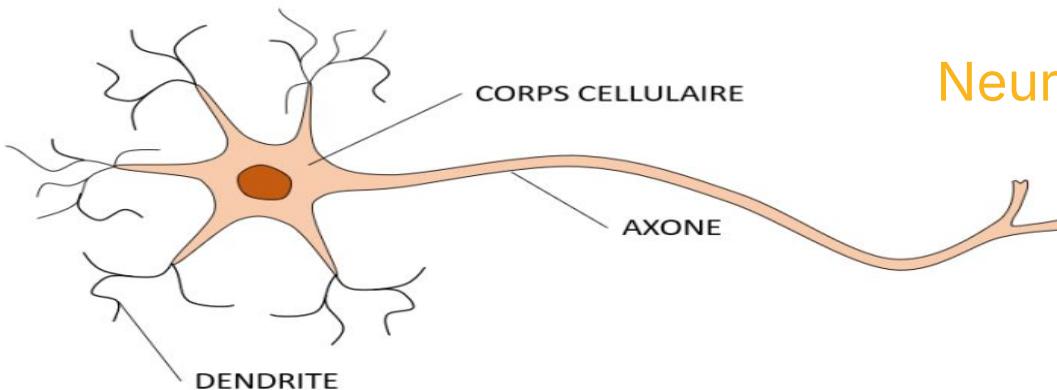


Challenge : classer les 10 chiffres

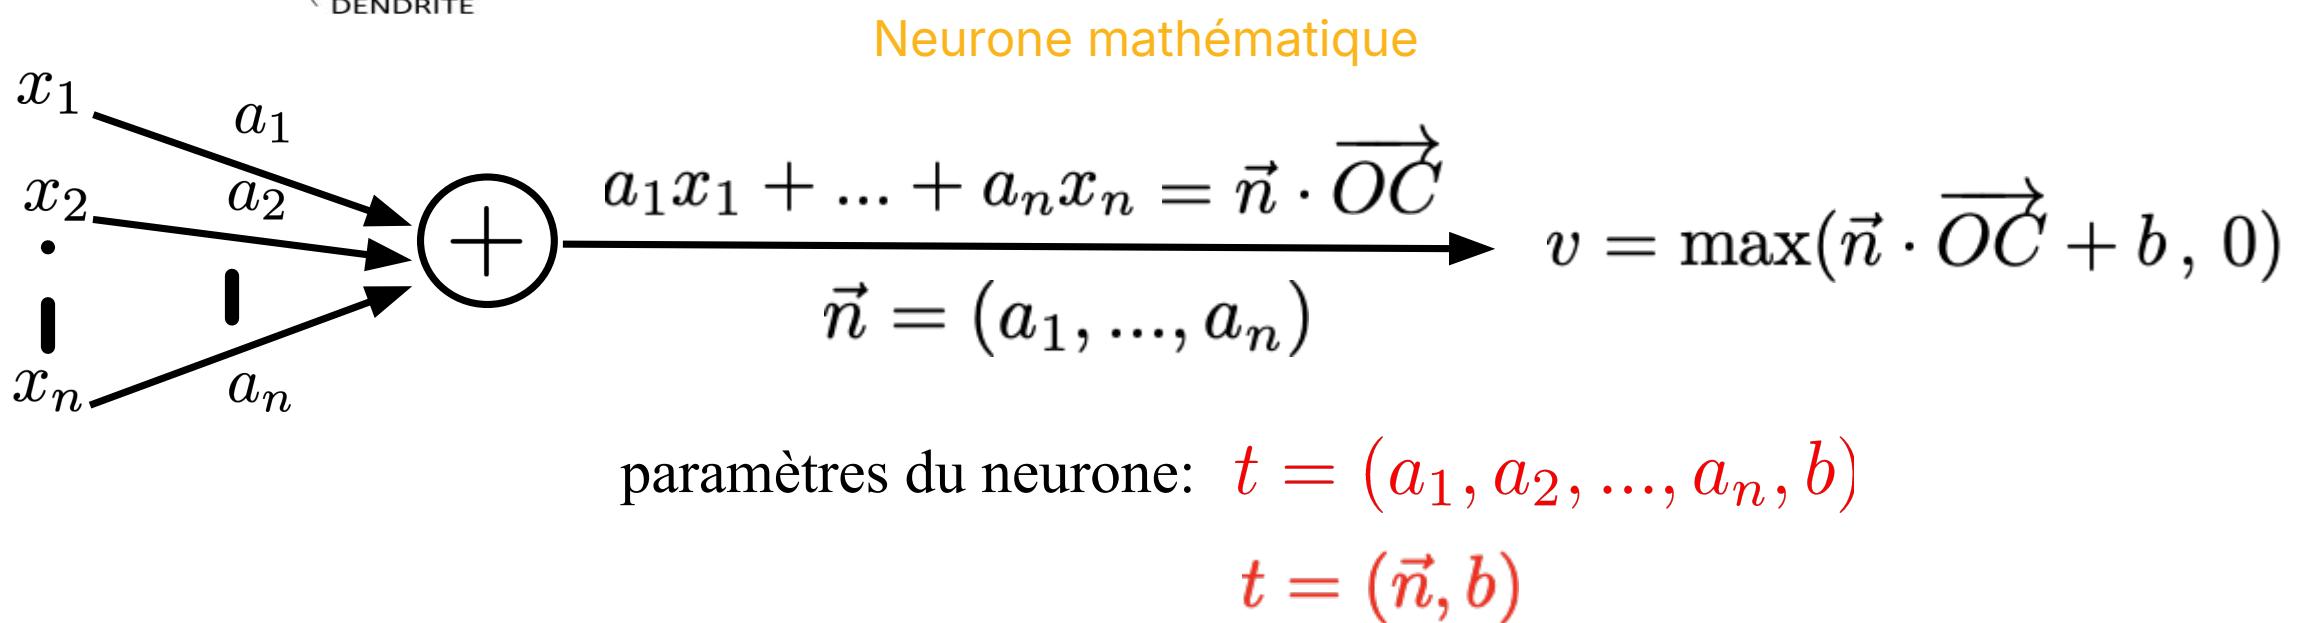


Il faut plus de caractéristiques $C = (x_1, x_2, \dots, x_n)$ pour différencier ces classes.

Neurone Mathématique

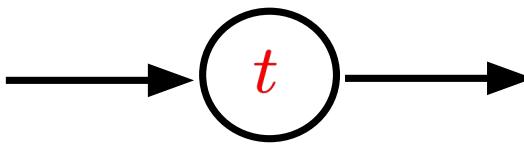


Neurone biologique

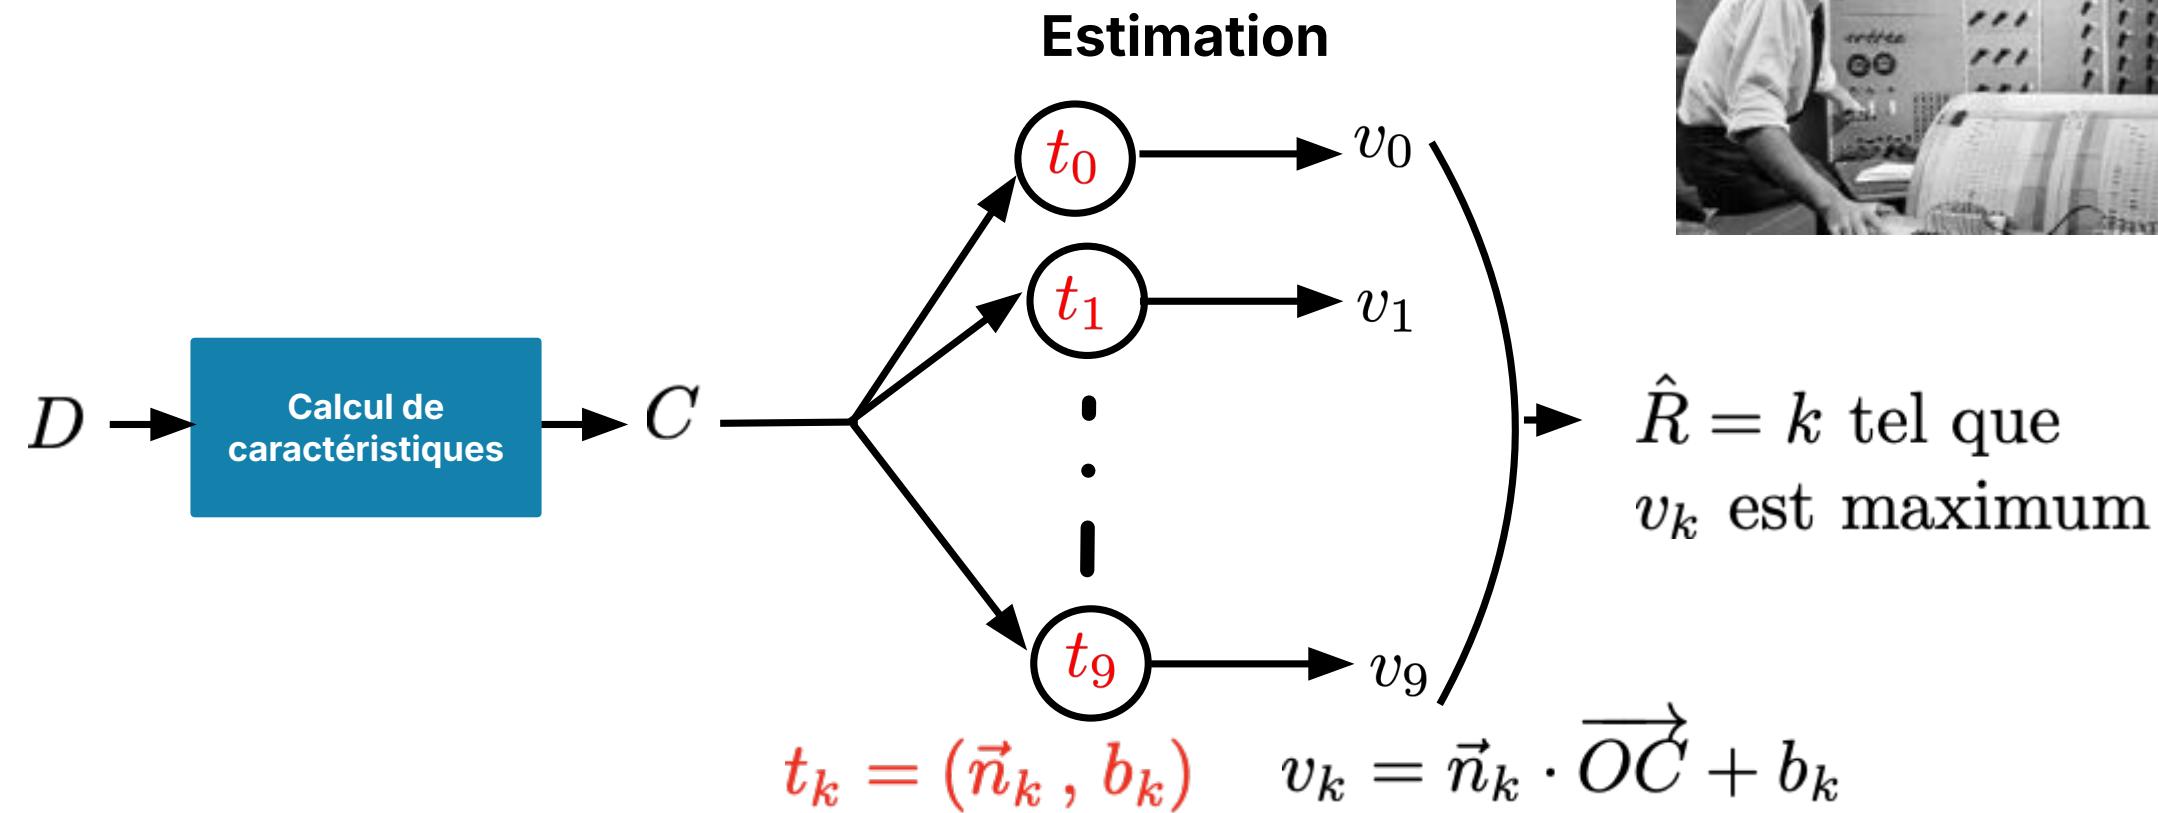


Estimation avec un réseau à 1 couche: perceptron

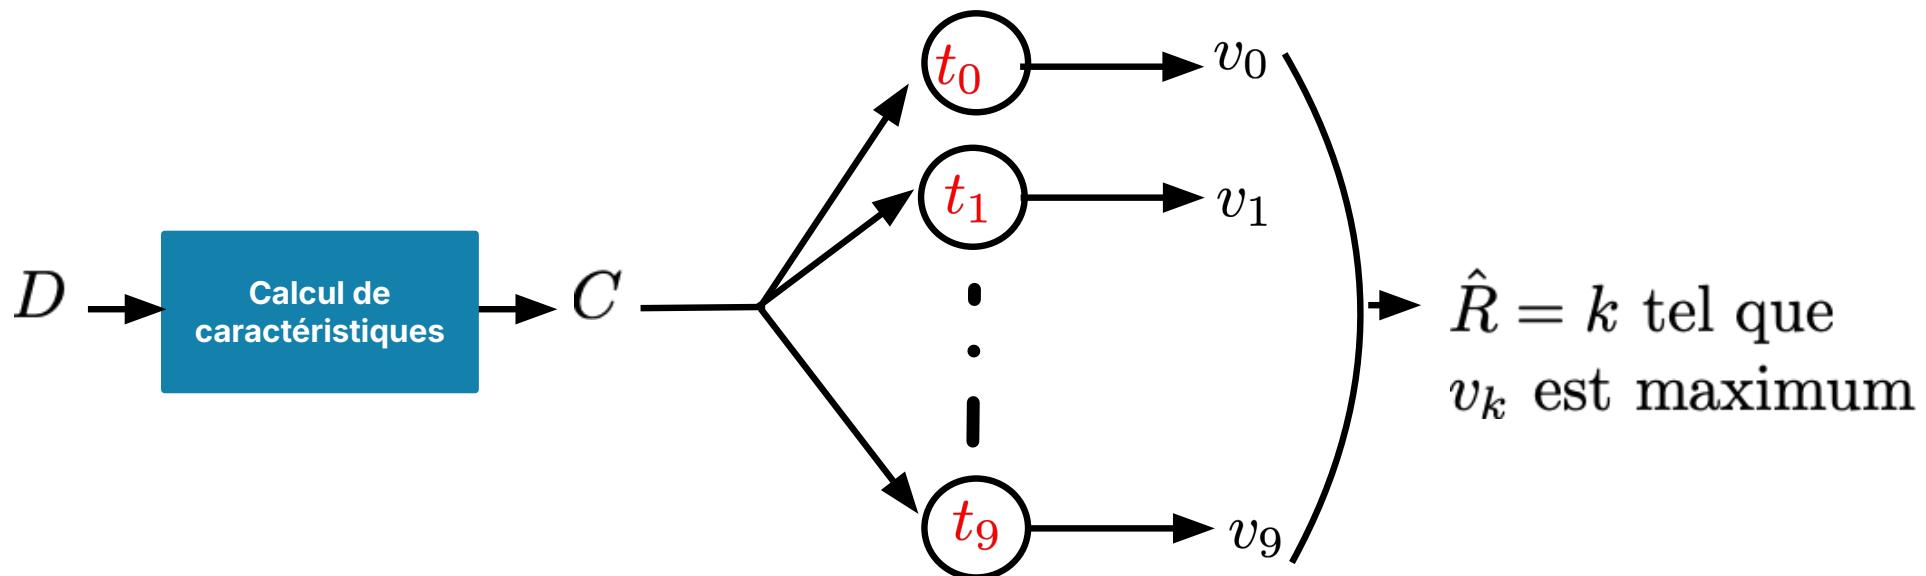
Un neurone :



Frank Rosenblatt (1957)



Apprentissage des paramètres



Perceptron : ajuste itérativement les $t_k = (\vec{n}_k, b_k)$ avec une règle Hebb

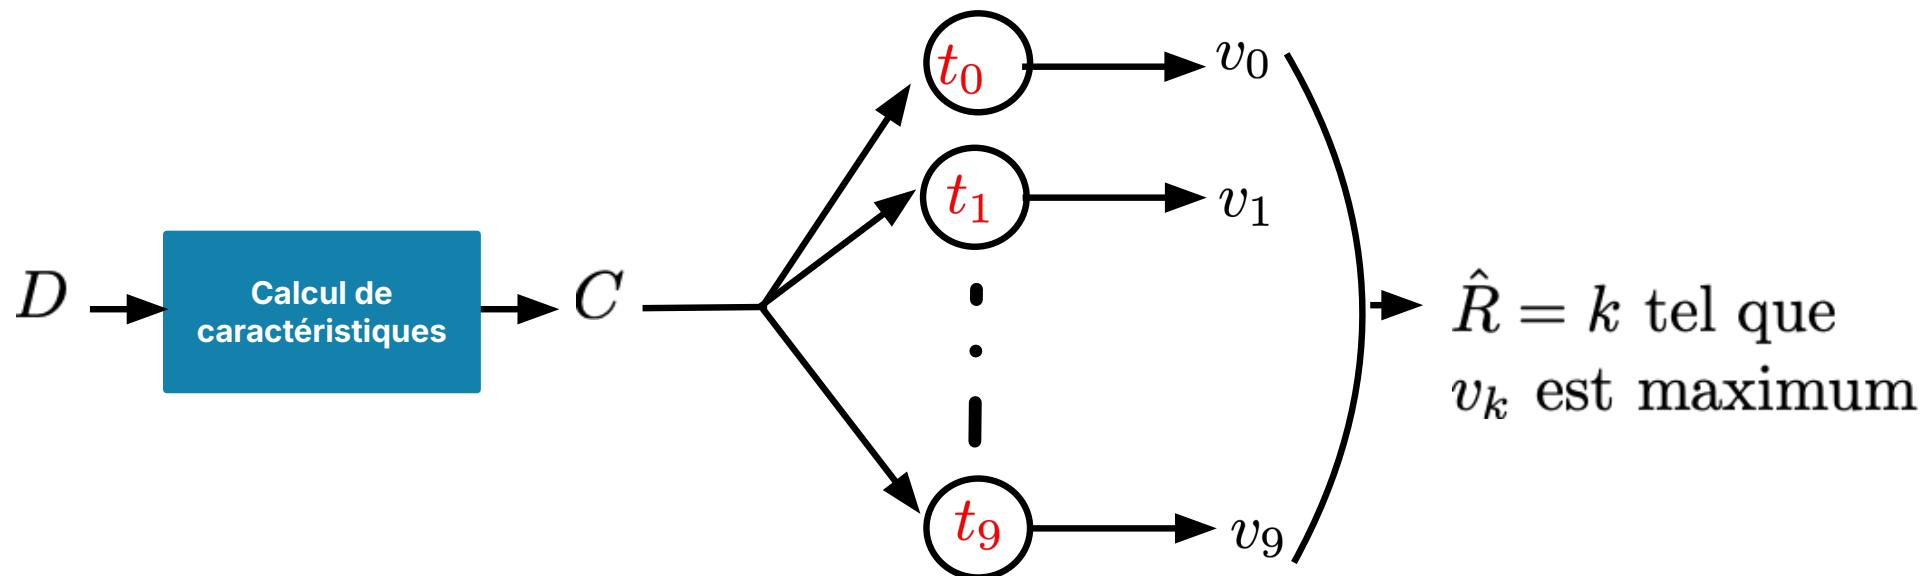
Pour chaque caractéristique C d'une donnée d'entraînement

si $\hat{R} \neq R$ (*erreur*) alors

pour $k = \hat{R}$ (*mauvaise classe*) $\vec{n}_k \xrightarrow{\text{inhibition}} \vec{n}_k - \epsilon \overrightarrow{OC}$ et $b_k \rightarrow b_k - \epsilon$

pour $k = R$ (*bonne classe*) $\vec{n}_k \xrightarrow{\text{excitation}} \vec{n}_k + \epsilon \overrightarrow{OC}$ et $b_k \rightarrow b_k + \epsilon$

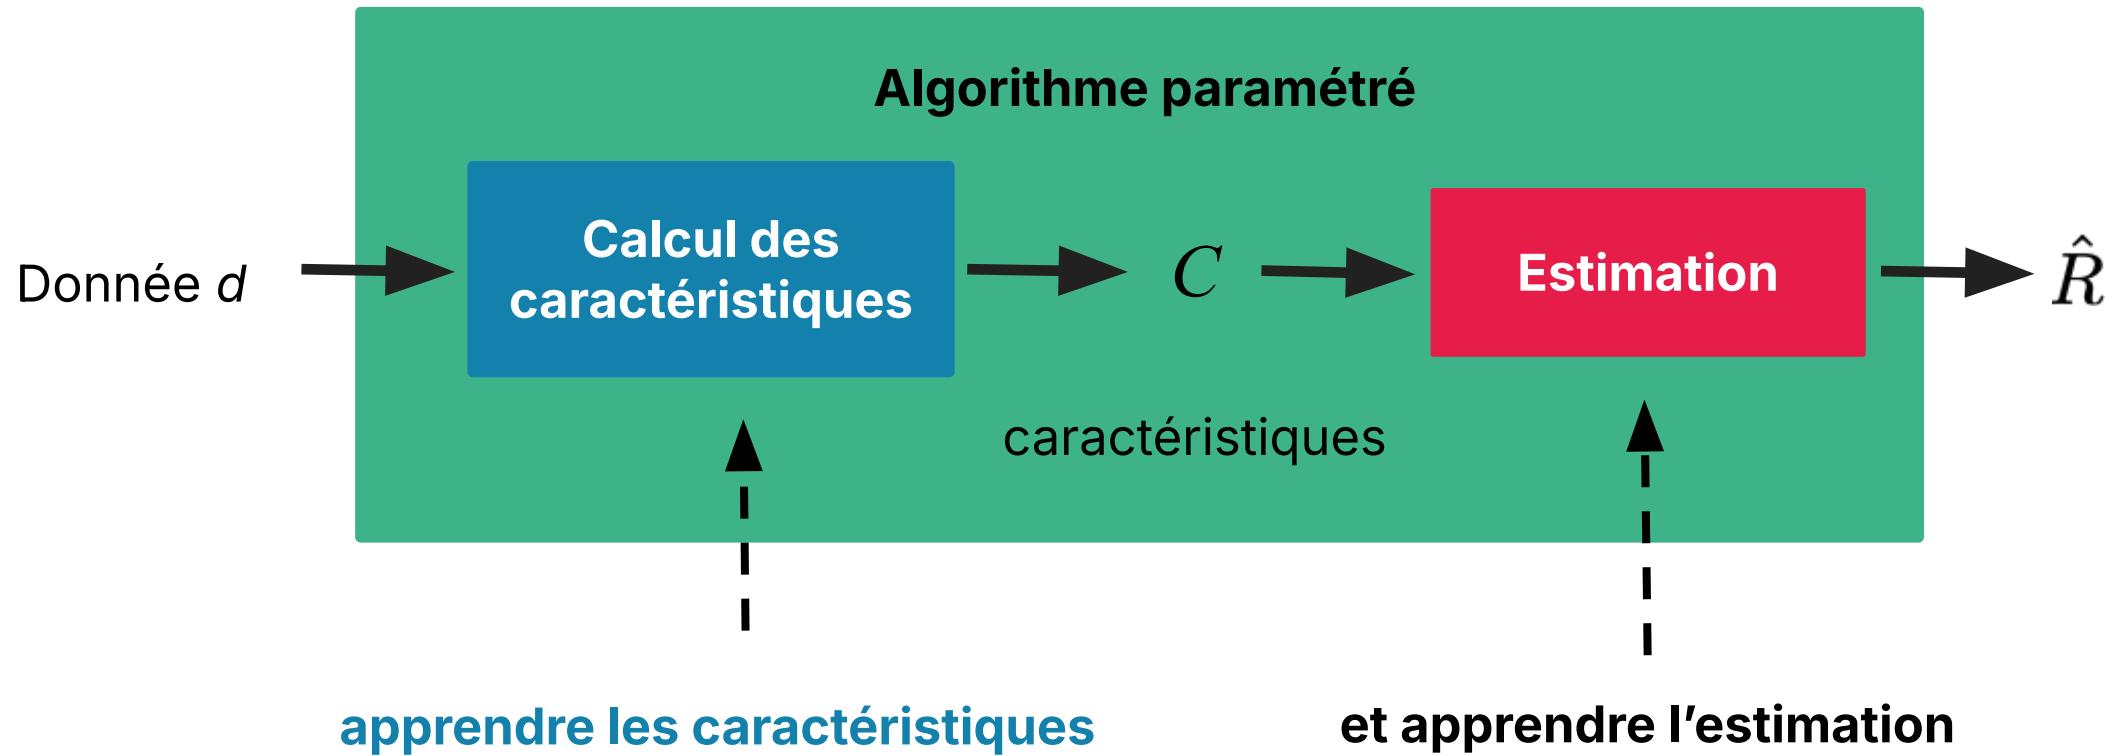
Apprentissage des paramètres



Perceptron : ajuste itérativement les $t_k = (\vec{n}_k, b_k)$ avec une règle Hebb

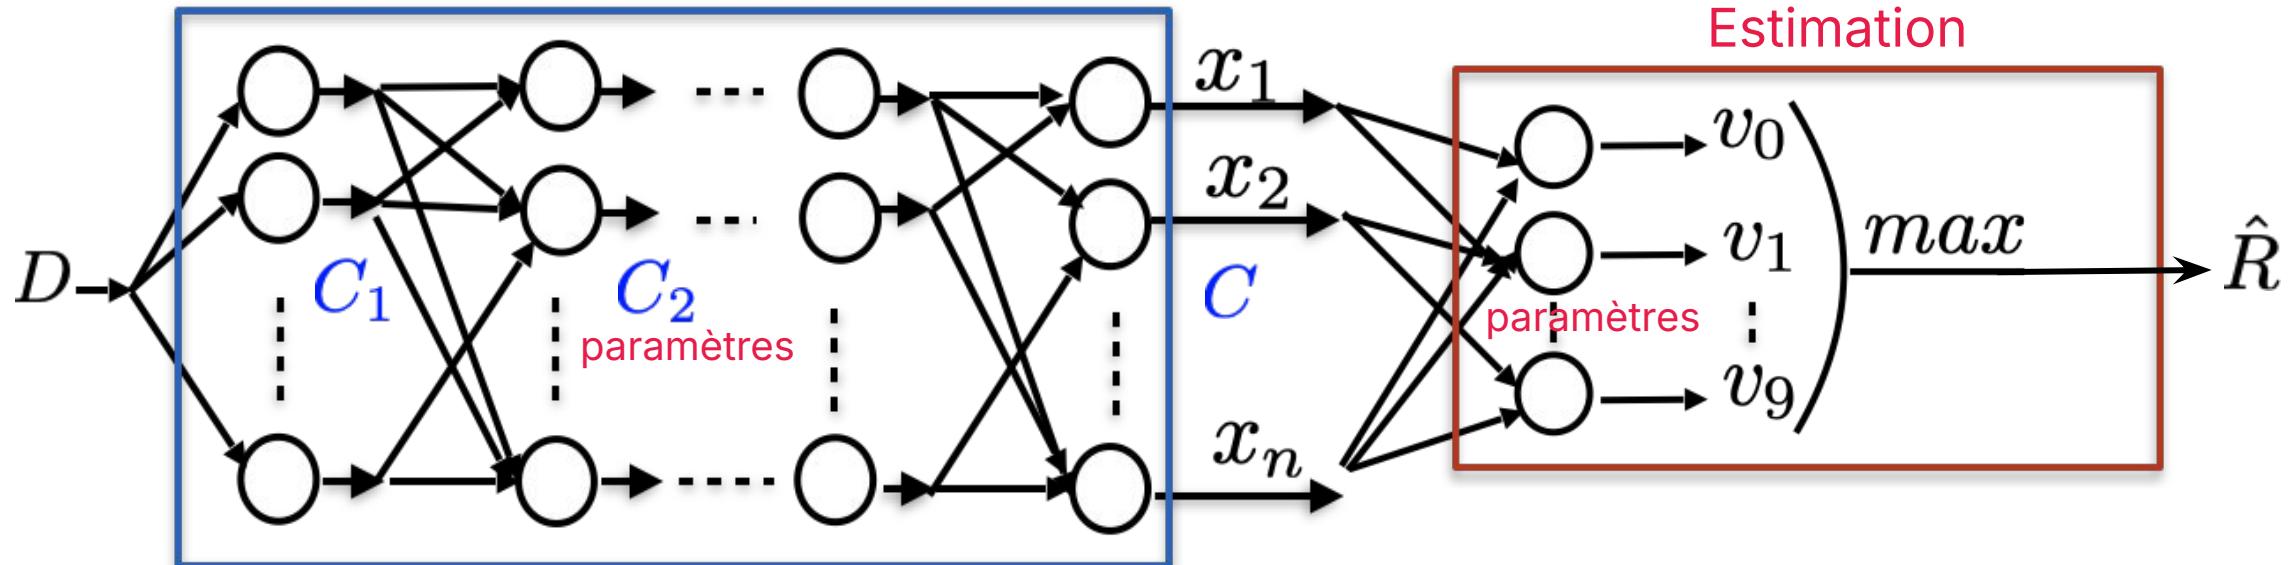
Descente de dérivée/gradient : sur l'erreur $f(t_0, t_1, \dots, t_9)$

Apprentissage des caractéristiques

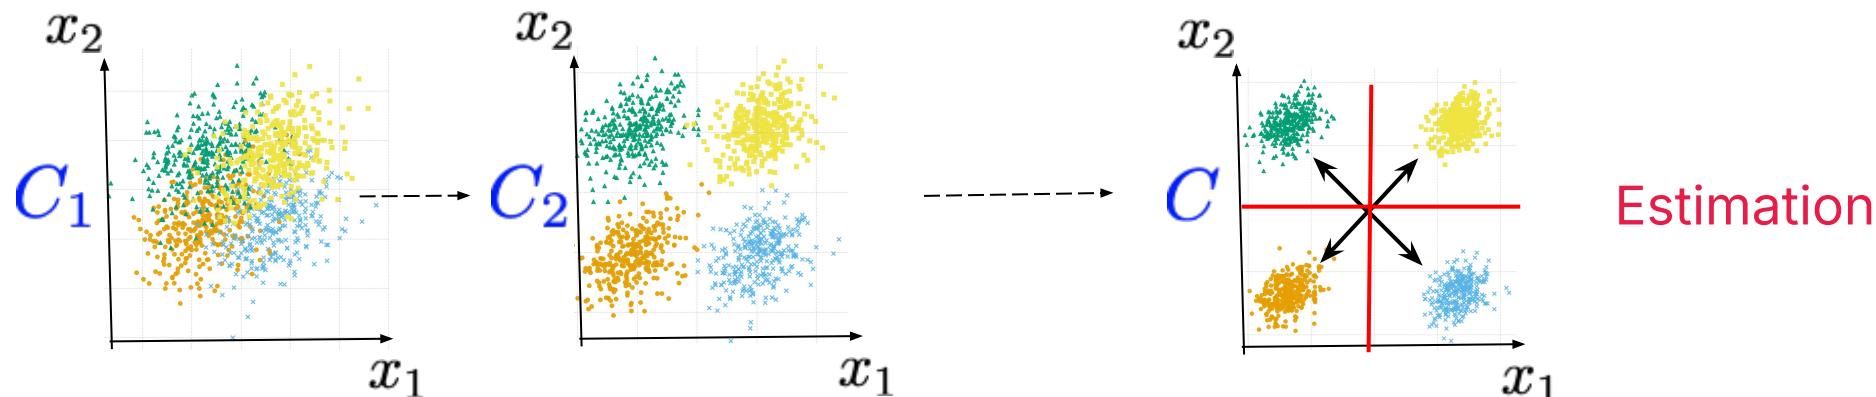


Apprendre les caractéristiques avec un réseau profond

Calcul des caractéristiques



Apprentissage des paramètres t par descente de dérivées/gradient pour minimiser l'erreur $f(t)$



Après l'apprentissage le réseau sépare progressivement les caractéristiques: **transport**.



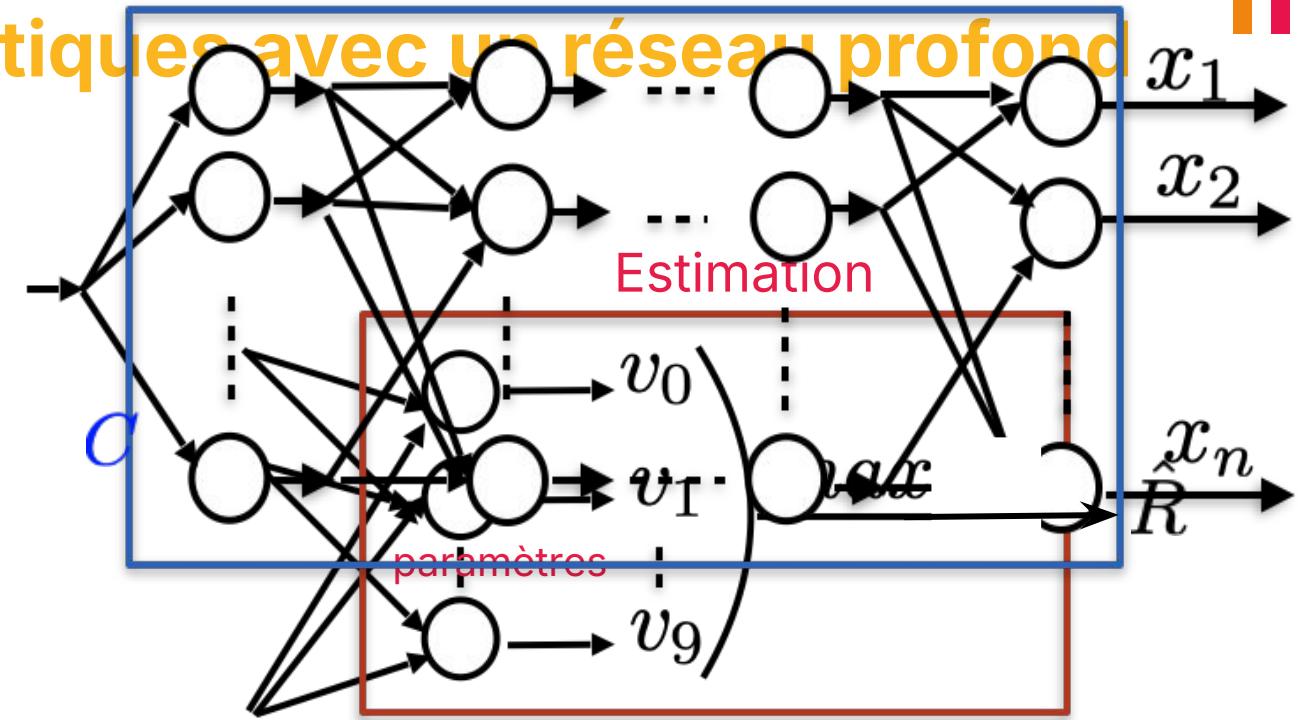
Apprendre les caractéristiques avec un réseau profond

Calcul des caractéristiques

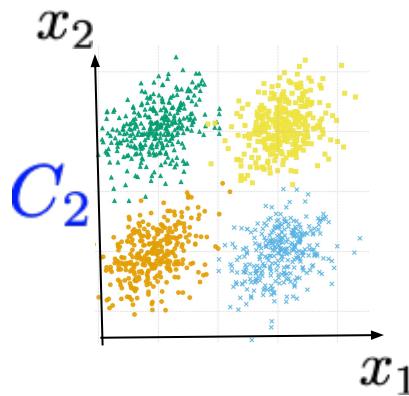
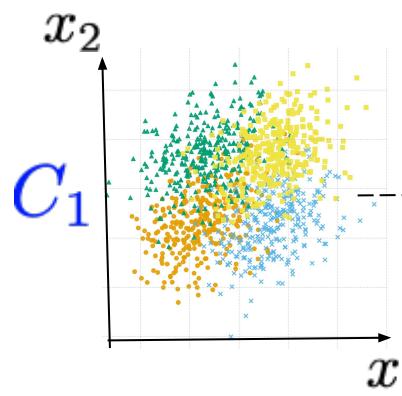
D

C_1

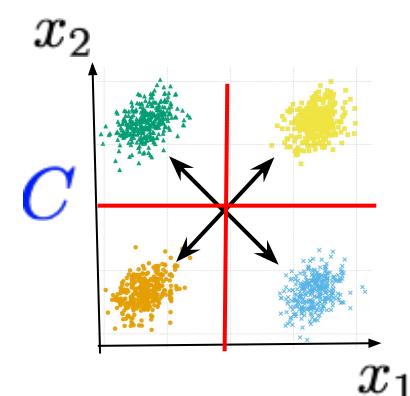
C_2
paramètres



Apprentissage des paramètres t par descente de dérivées/gradient pour minimiser l'erreur $f(t)$



→



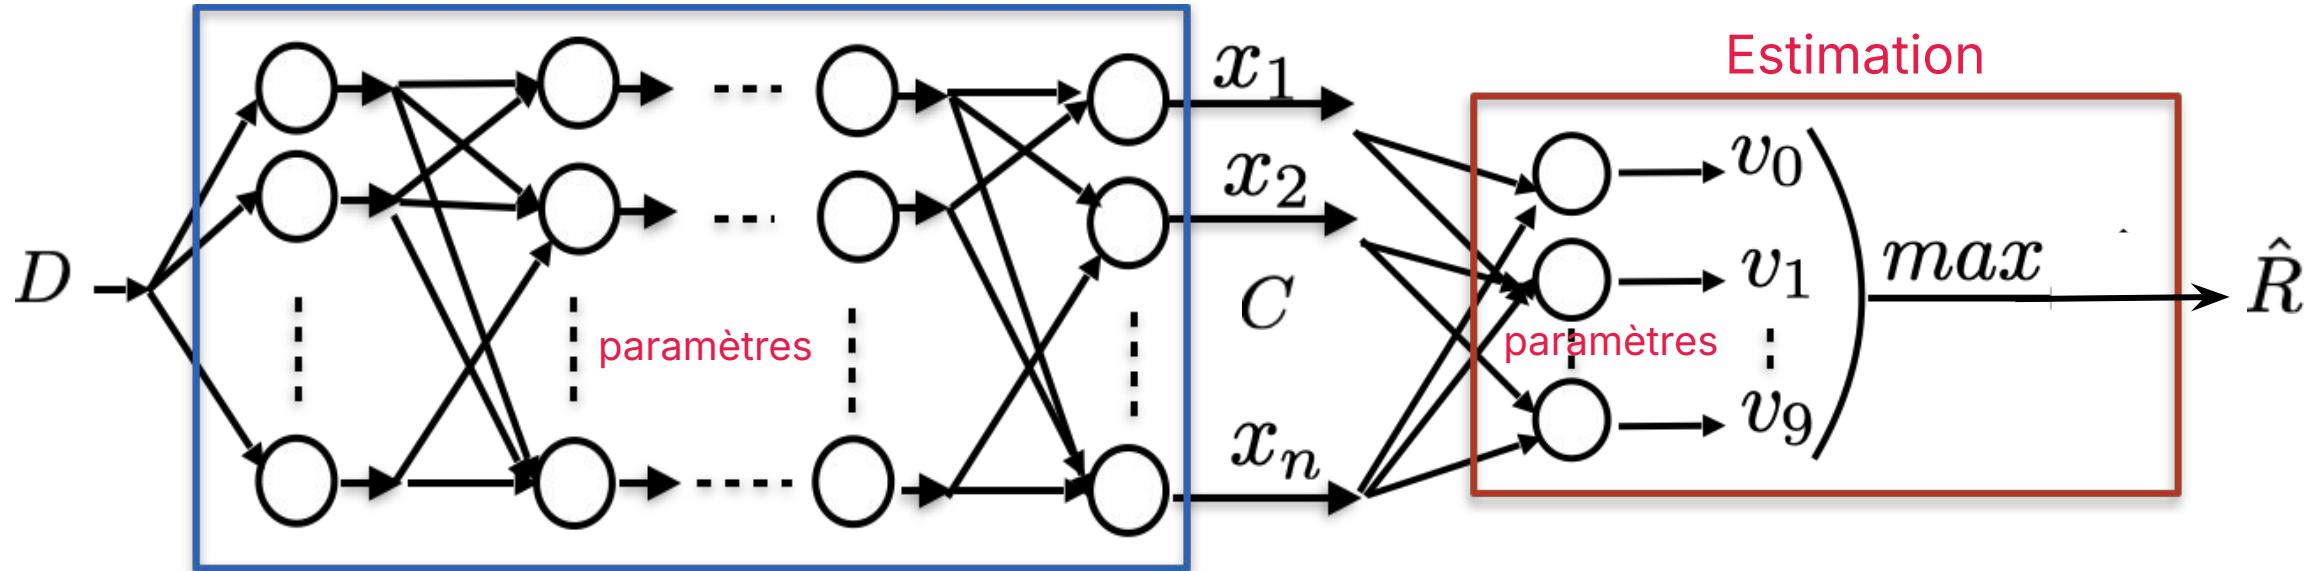
Estimation

Après l'apprentissage le réseau sépare progressivement les caractéristiques: **transport**.



Apprendre la réponse optimale avec un réseau profond

Calcul des caractéristiques



Énormément de paramètres donc énormément d'exemples pour généraliser.

Bonnes approximations de l'estimateur optimal de Bayes:

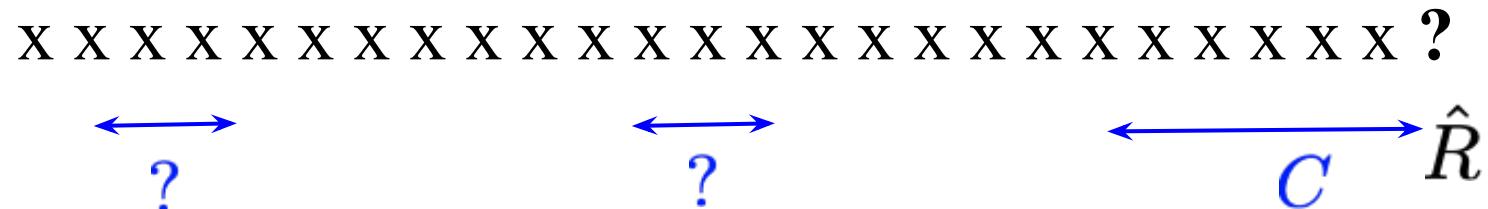
$$\hat{R} \text{ maximise } \hat{Prob}(\hat{R} = R|C) \approx Prob(\hat{R} = R|D)$$

Comment le réseau a-t-il évité la malédiction de la grande dimension ?

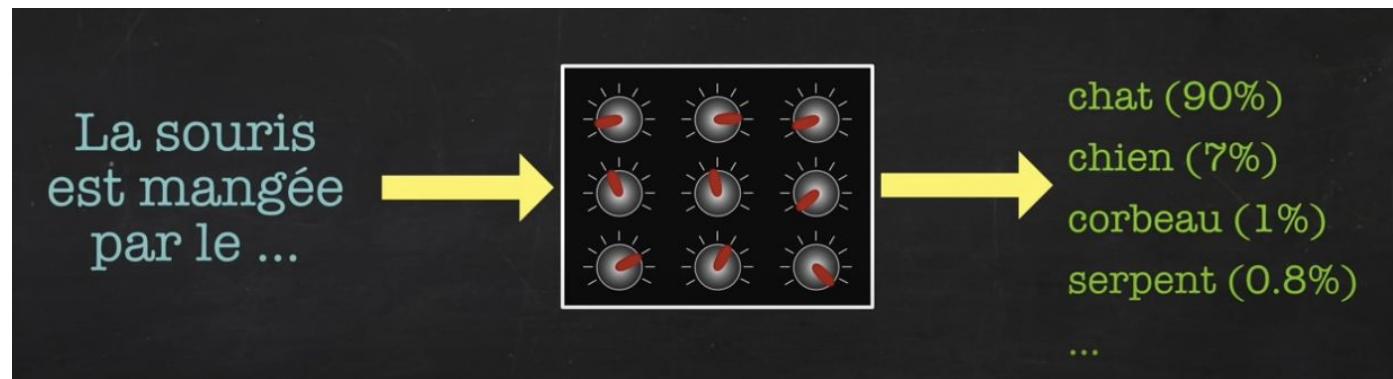
Grands modèles de langage

Modèle de Langage : réseau de neurone qui calcule itérativement le prochain mot \hat{R} étant connu le prompt et les mots précédents (donnée D):

Transformer : Mécanisme d'attention



Calcule \hat{R} qui maximise $\hat{Prob}(\hat{R} = R|C)$ où C est un contexte.



Optimal: $\hat{Prob}(\hat{R} = R|C) \approx Prob(\hat{R} = R|D)$ si on a assez de contexte

4- Enseigner les maths avec des challenges d'IA



MathAData : Enseigner les maths avec des Challenges d'IA

La résolution d'un challenge d'IA met en jeux toutes les mathématiques du Lycée et Collège: géométrie, analyse, algèbre, statistiques, probabilités,...

Motiver et donner du sens aux mathématiques



à partir de challenges d'IA

Comprendre les maths en manipulant et expérimentant



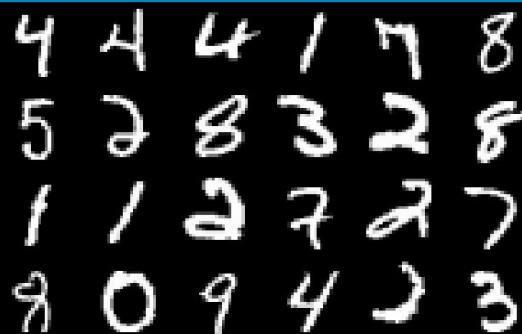
puis en pratiquant les maths sur des exercices.

Des challenges d'IA pour les lycéens

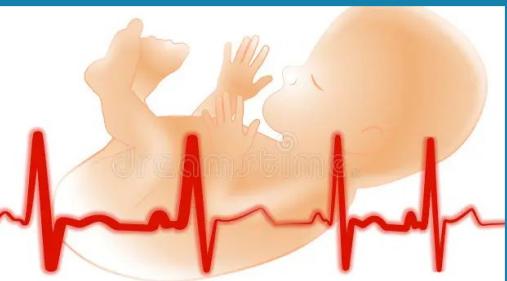


Challenge : estimer la réponse R à une question à partir de données numériques D

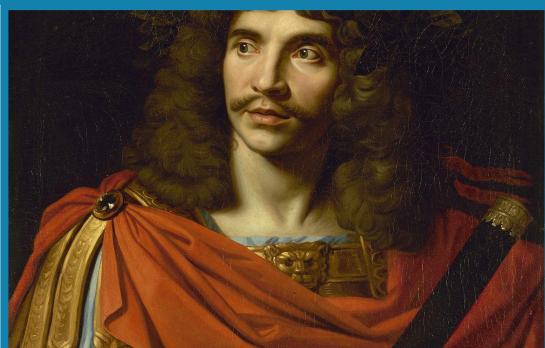
Quel chiffre écrit dans l'image ?



Le foetus est-il sain ou malade ?



Corneille ou Molière a écrit ce texte ?

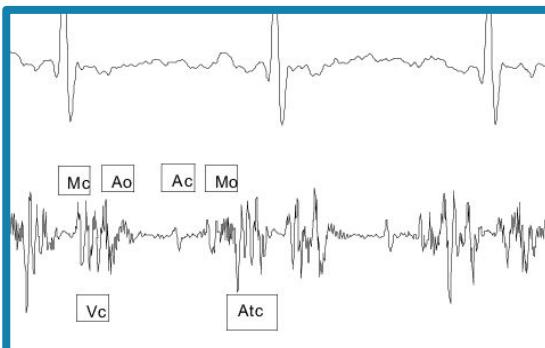


Décoder les chants des baleines



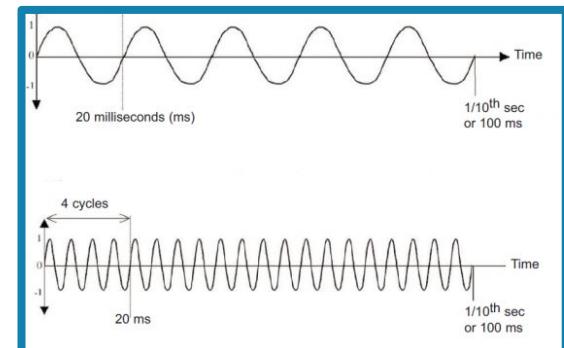
Données numériques d

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
26	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
27	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0



Valeurs des pixels de l'image

Je n'aurais rien à craindre, si tout le monde vous voyait des yeux dont je vous vois, et je trouve en votre personne de quoi avoir raison aux choses que je fais pour vous. Mon coeur, pour sa défense, a tout votre mérite,



Électrocardiogramme.

Mots du texte

Enregistrement du chant



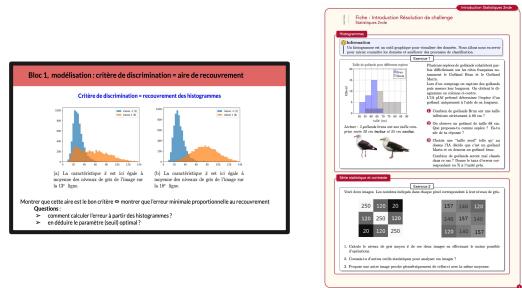
MathAData propose des séquences et outils pédagogiques pour enseigner les maths au programme avec des challenges d'IA.

co-développés avec des professeurs de l'éducation nationale



1. Cadre math et IA

DIAPO et FICHE INTRO



Intro du Challenge d'IA

Intro des concepts maths du programme

2. Pratique numérique

NOTEBOOK



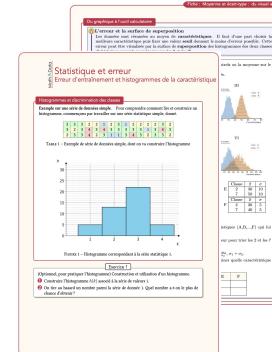
Résoudre le challenge

Manipuler les maths

Ludique

3. Pratiquer les maths

FICHES EXOS PAPIER



Exercices liés au challenge

Exercices du programme