

Traitement et Analyse d'Images

Réseaux de neurones

Contexte

Acquisition / pré-traitement



Extraction de caractéristiques



Classification / Régression



Décision

Apprentissage profond





$$x^{(1)} = (x_1^{(1)}, \dots, x_N^{(1)})^T$$

$$x^{(2)} = (x_1^{(2)}, \dots, x_N^{(2)})^T$$

$$a^{(1)} = (a_1^{(1)}, \dots, a_D^{(1)})^T$$

$$a^{(2)} = (a_1^{(2)}, \dots, a_D^{(2)})^T$$



Contexte

▶ Base de données d'entraînement

- Apprendre à reconnaître des objets, des tendances, des groupes, ...



▶ Base de données de test

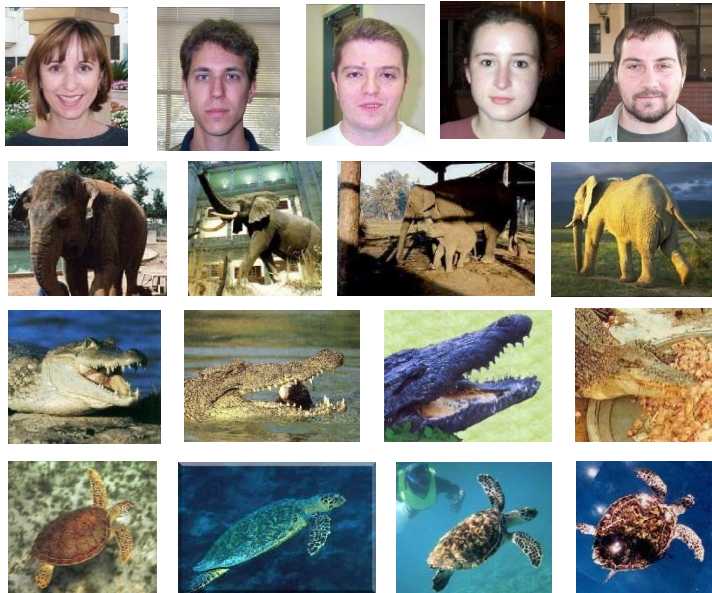
- Appliquer les modèles appris sur de nouvelles données (en dehors de la base d'entraînement)



Démarche générale

► Illustration

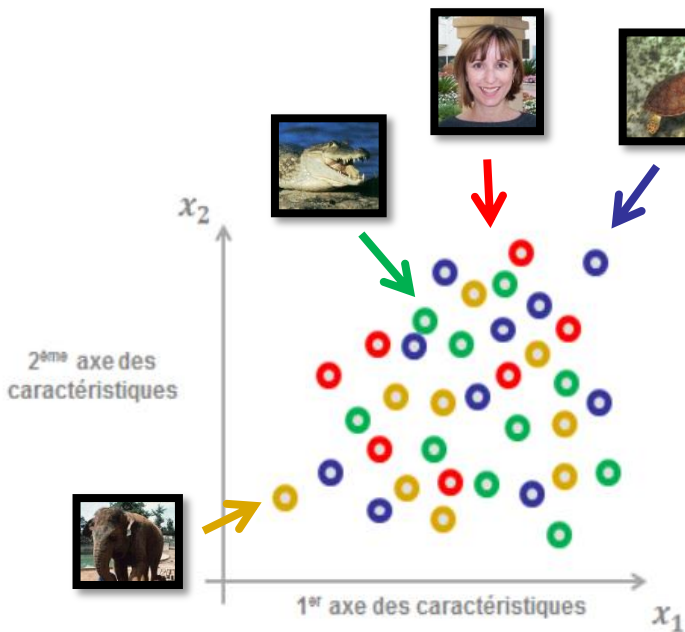
Reconnaissance de visages parmi un ensemble d'images



Données d'entraînement

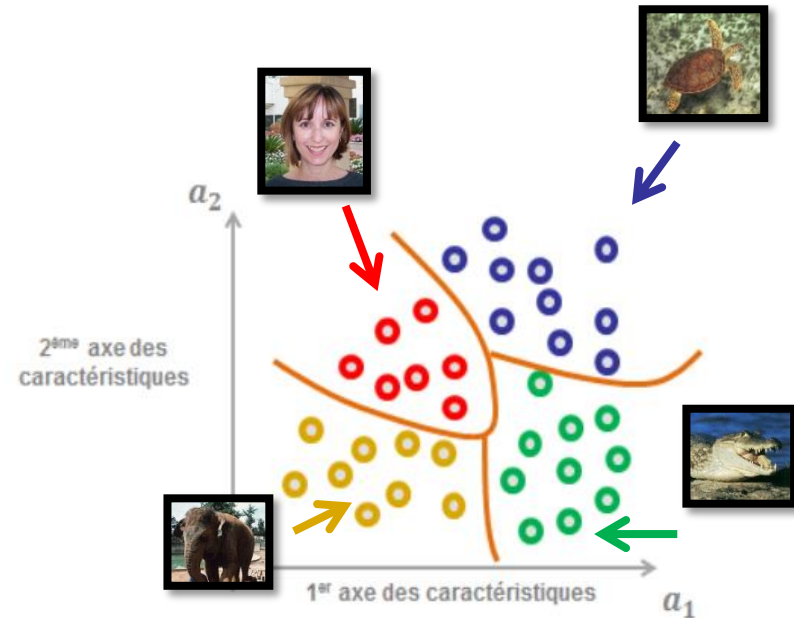
Apprentissage automatique et simultané des caractéristiques discriminantes et de la fonction de décision associée

Démarche générale



Espace image initial

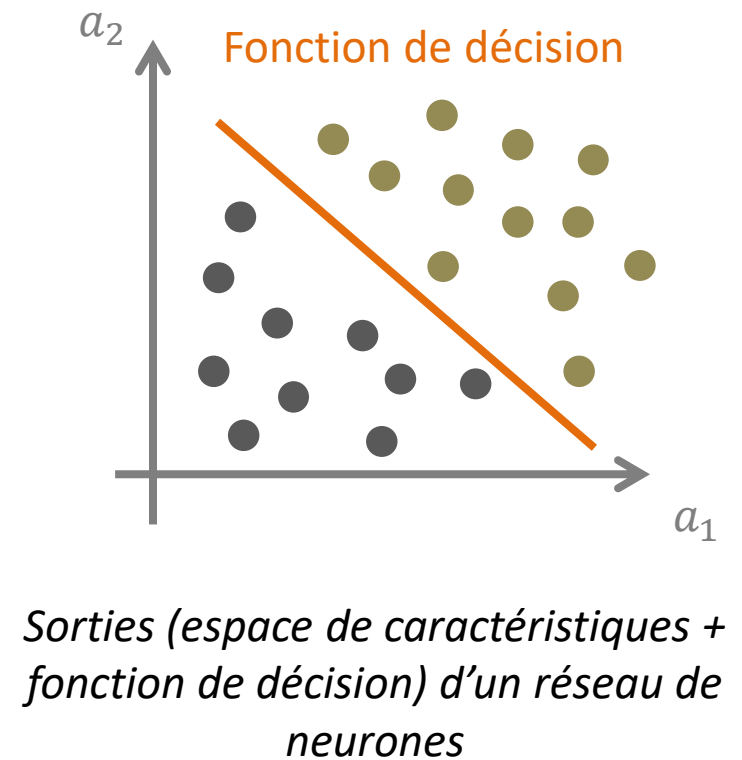
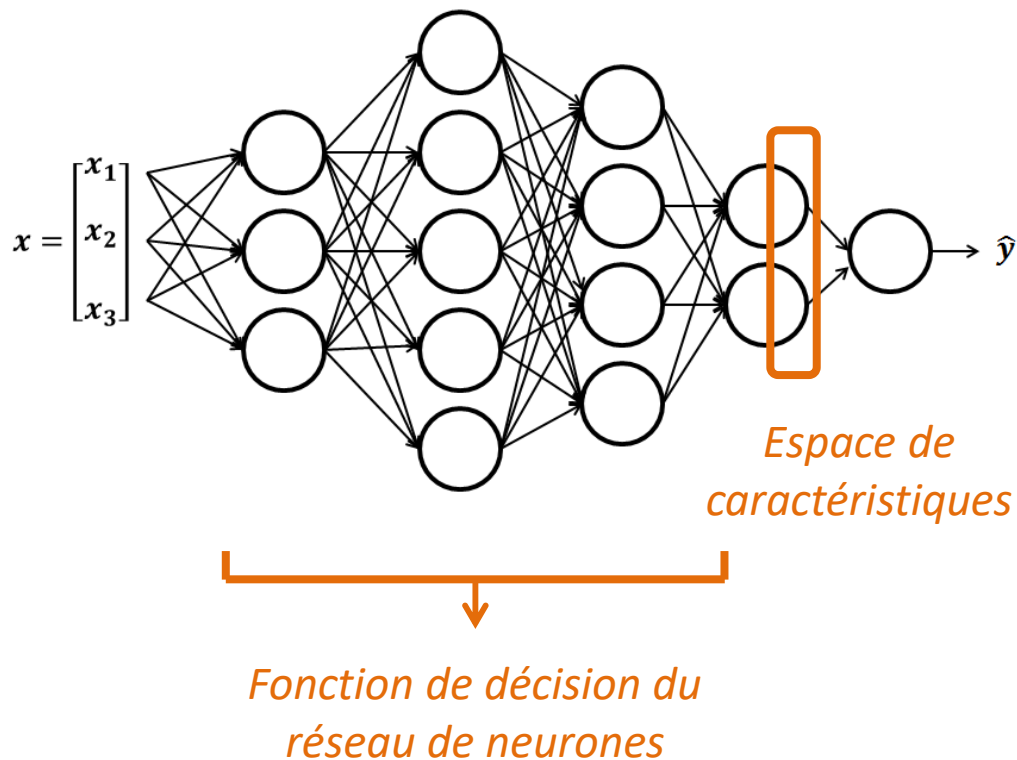
Algorithme
d'apprentissage
profond



*Espace de caractéristiques appris
avec la fonction de décision
associée*

MLP: Réseaux de neurones multicouches

- Famille de méthodes la plus simple en apprentissage profond

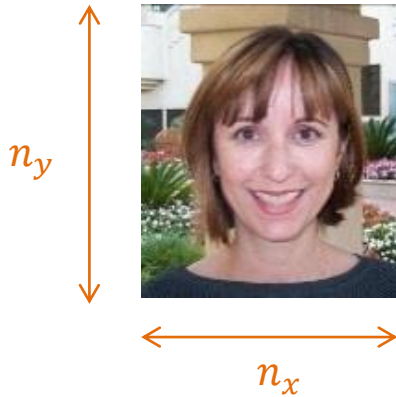


Les réseaux de neurones

Modélisation d'un neurone

Concepts de base

► Classification binaire



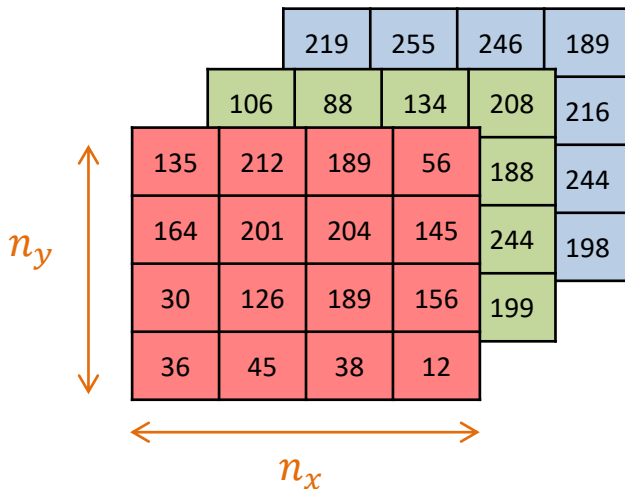
Présence d'un
visage ?



1 (visage)
0 (pas de visage)



y



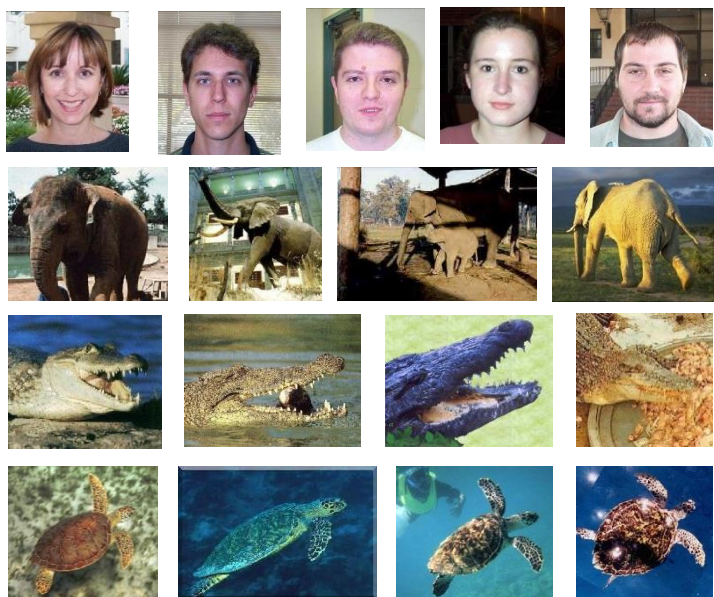
$$x = \begin{bmatrix} 135 \\ 212 \\ 189 \\ \vdots \\ 198 \end{bmatrix}$$

$$\in \mathbb{R}^{[n_X \times 1]}$$

$$\text{avec } n_X = n_x \times n_y \times 3$$

Concepts de base

► Base de données



Base de données composée de m échantillons

- Chaque échantillon (image) est labélisé

$$(x^{(i)}, y^{(i)})$$

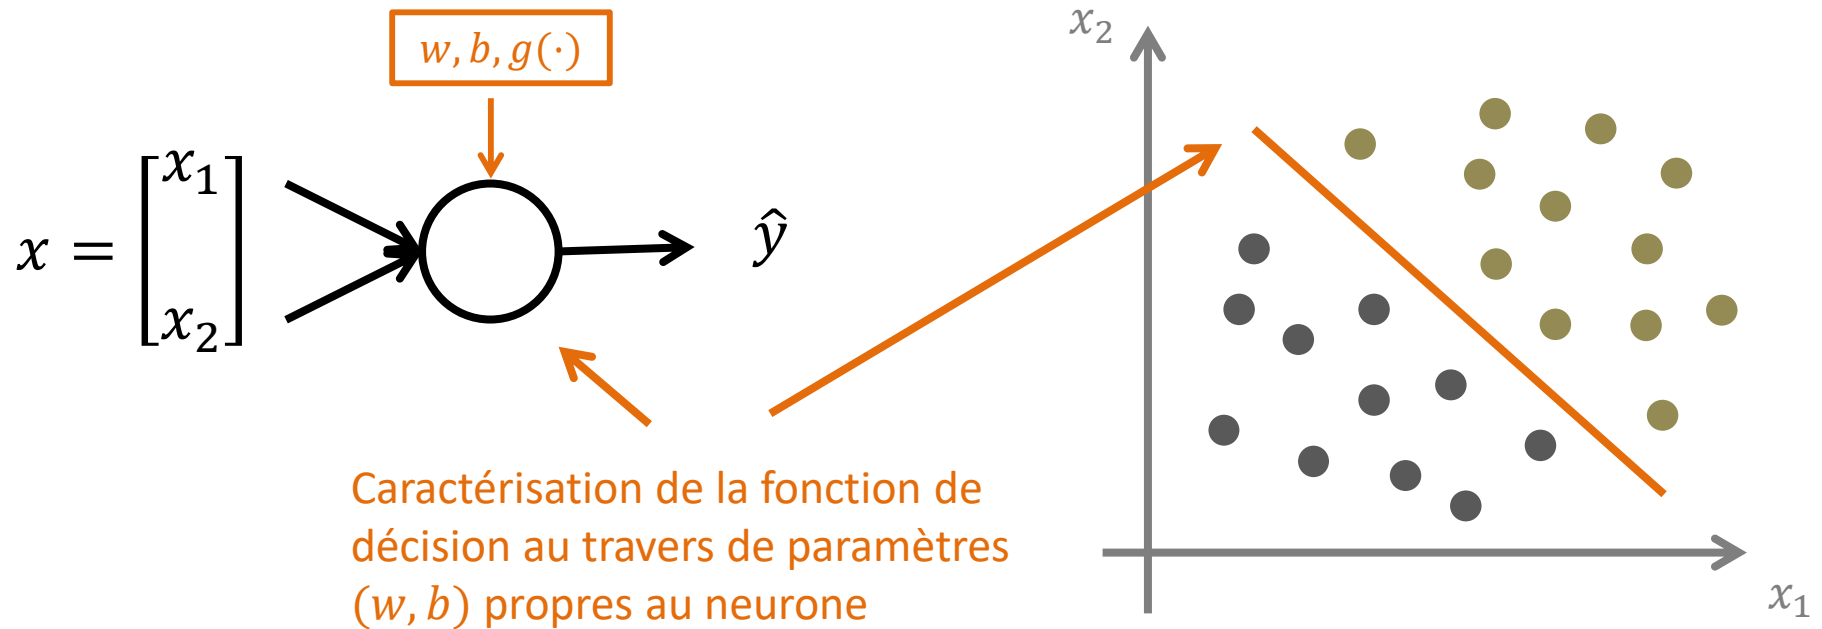
$$x^{(i)} \text{ image et } y^{(i)} = \begin{cases} 1 \rightarrow \text{visage} \\ 2 \rightarrow \text{éléphant} \\ 3 \rightarrow \text{croco.} \\ 4 \rightarrow \text{tortue} \end{cases}$$

- Base de données composée de m échantillons

$$\{(x^{(1)}, y^{(1)}), \dots, (x^{(i)}, y^{(i)}), \dots, (x^{(N)}, y^{(N)})\}$$


Fonction de décision

- Comment définir au niveau d'un neurone une fonction de décision qui permet de classifier les échantillons ?



Fonction de décision

► Deux éléments clés



1) Projection du vecteur de données x sur un vecteur de paramètres w avec un décalage de b

2) Application d'une transformation non-linéaire (fonction d'activation) afin de prendre une décision

Paramétrage d'un neurone

- ▶ Paramètres intervenant dans le 1^{er} élément


$$w \in \mathbb{R}^{[n_X \times 1]} \text{ et } b \in \mathbb{R}$$

- ▶ Fonction d'activation intervenant dans le 2^{ème} élément

Fonction sigmoïde


$$g(z) = \frac{1}{1+e^{-z}}$$

$$g'(z) = \frac{e^{-z}}{1+e^{-z}} = g(z) \cdot (1 - g(z))$$



Utilisation d'un neurone

► Définition



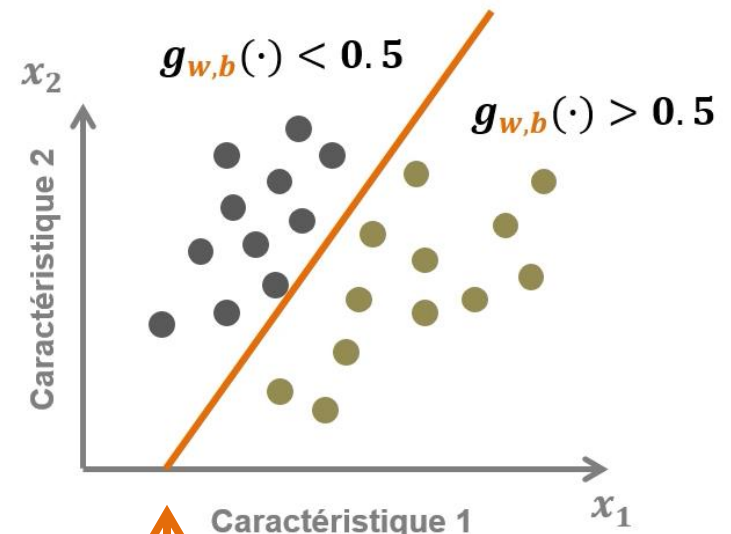
$$\hat{y} = 0.5 \Rightarrow g(w^T x + b) = 0.5$$

$$w^T x + b = 0$$

$$w_1 x_1 + w_2 x_2 + b = 0$$

Équation d'une droite


► Frontière de décision



Frontière de décision
dépendant de w et b

Apprentissage de la fonction de décision

- ▶ A partir d'une base de données, comment apprendre les paramètres d'un neurone ?
 - Les paramètres d'un neurone doivent permettre de reconnaître la classe y associée à l'échantillon entrant x
 - **Approche probabiliste**





Apprentissage de la fonction de décision

► Fonction de perte à minimiser

$$\mathcal{L}(\hat{y}, y) = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})]$$

- Quand $y = 1$
 $\mathcal{L}(\hat{y}, 1)$ est minimum lorsque $\hat{y} \rightarrow 1$
- Quand $y = 0$
 $\mathcal{L}(\hat{y}, 0)$ est minimum lorsque $\hat{y} \rightarrow 0$



Apprentissage de la fonction de décision

► Fonction de perte à minimiser

- Application à l'ensemble de la base de données

$$J(w, b) = \frac{1}{N} \sum_{i=1}^N \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$$


- La minimisation de $J(w, b)$ a pour but de trouver les paramètres du neurone $\{w, b\}$ qui permettent de reconnaître pour chaque échantillon $x^{(i)}$ de la base de données la classe $y^{(i)}$ associée

Apprentissage de la fonction de décision

- Fonction de perte à minimiser


$$J(w, b) = \frac{1}{N} \sum_{i=1}^N \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$$

- Les paramètres optimaux $\{\tilde{w}, \tilde{b}\}$ peuvent être estimés par une méthode de descente de gradient



Élément de modélisation

- Calculer les dérivées partielles $\frac{\partial J}{\partial b}$ et $\frac{\partial J}{\partial w}$ dans le cas où la fonction de perte est l'entropie croisée



$$J(w, b) = \frac{1}{N} \sum_{i=1}^N \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$$

avec $\mathcal{L}(\hat{y}^{(i)}, y^{(i)}) = -[y^{(i)} \log(\hat{y}^{(i)}) + (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})]$

$$\left\{ \begin{array}{l} \frac{\partial J}{\partial b} = \frac{1}{N} \sum_{i=1}^N \frac{\partial \mathcal{L}}{\partial b} = \frac{1}{N} \sum_{i=1}^N \left(\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} \cdot \frac{\partial \hat{y}^{(i)}}{\partial z^{(i)}} \cdot \frac{\partial z^{(i)}}{\partial b} \right) \\ \frac{\partial J}{\partial w} = \frac{1}{N} \sum_{i=1}^N \frac{\partial \mathcal{L}}{\partial w} = \frac{1}{N} \sum_{i=1}^N \left(\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} \cdot \frac{\partial \hat{y}^{(i)}}{\partial z^{(i)}} \cdot \frac{\partial z^{(i)}}{\partial w} \right) \end{array} \right.$$

Apprentissage de la fonction de décision

► Approche empirique - Descente de gradient

Initialisation de w et b

Répéter jusqu'à convergence

{


calcul de $A = [\hat{y}^{(1)}, \dots, \hat{y}^{(m)}]$

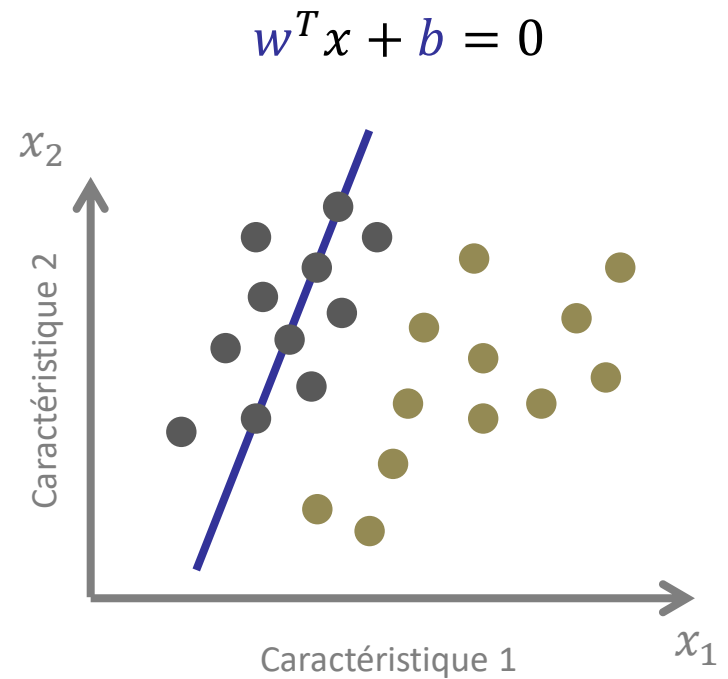


calcul de $J(w, b)$




$$w := w - \alpha \frac{\partial J(w, b)}{\partial w}$$

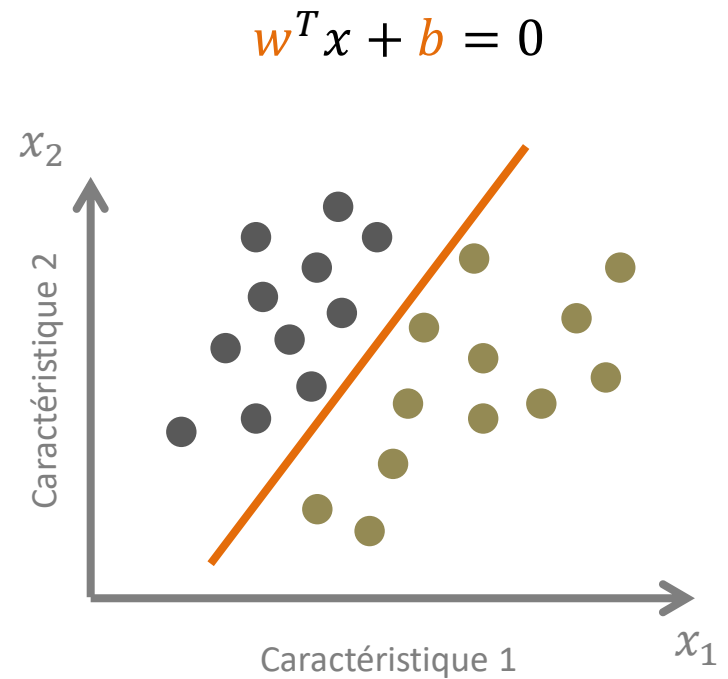


$$b := b - \alpha \frac{\partial J(w, b)}{\partial b}$$

}



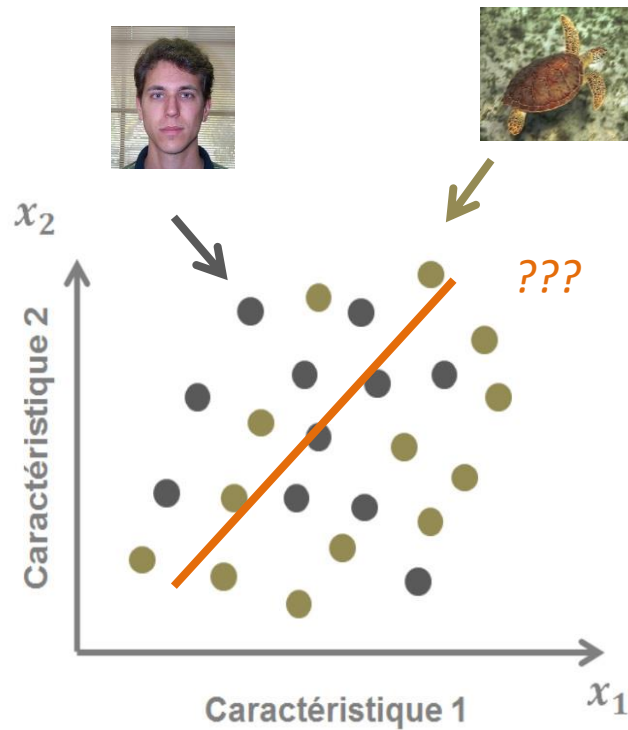






Problématique

- Comment faire lorsque les données d'entrée sont trop complexes ?



Espace image initial


Les réseaux de neurones

Modélisation par couches de neurones

Concept de base

- ▶ Passage d'un neurone à un ensemble de neurones organisés suivant un réseau

$a_1^{[1]}$: activation d'un neurone




$$a_1^{[1]} = g^{[1]}(w_{1,1}^{[1]}x_1 + w_{1,2}^{[1]}x_2 + b_1^{[1]})$$

Concept de base

- ▶ Passage d'un neurone à un ensemble de neurones organisés suivant un réseau

$a_2^{[1]}$: activation d'un neurone




$$a_2^{[1]} = g^{[1]}(w_{2,1}^{[1]}x_1 + w_{2,2}^{[1]}x_2 + b_2^{[1]})$$

Concept de base

- ▶ Passage d'un neurone à un ensemble de neurones organisés suivant un réseau

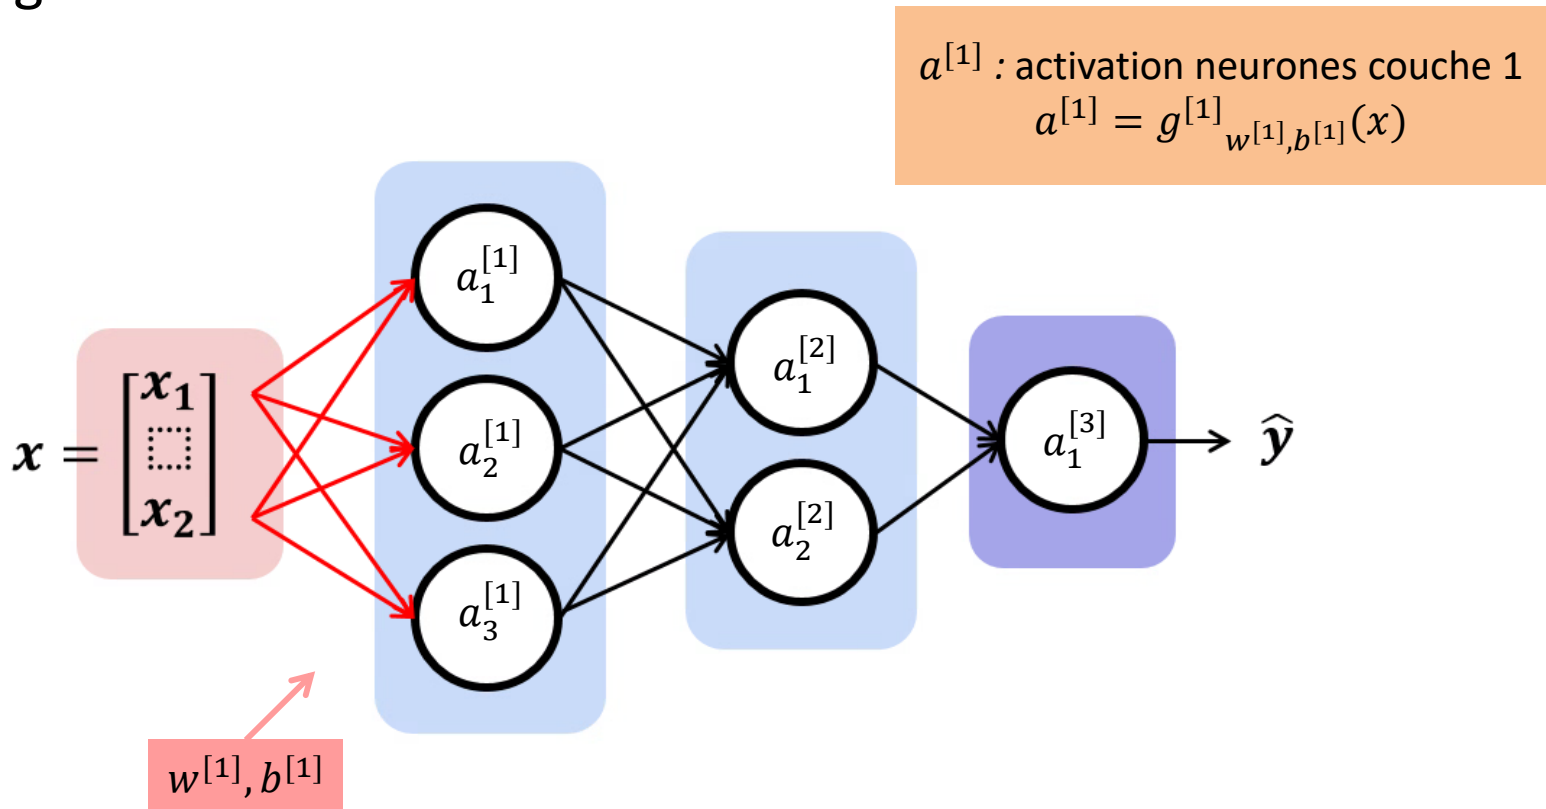
$a_3^{[1]}$: activation d'un neurone



$$a_3^{[1]} = g^{[1]}(w_{3,1}^{[1]}x_1 + w_{3,2}^{[1]}x_2 + b_3^{[1]})$$

Concept de base

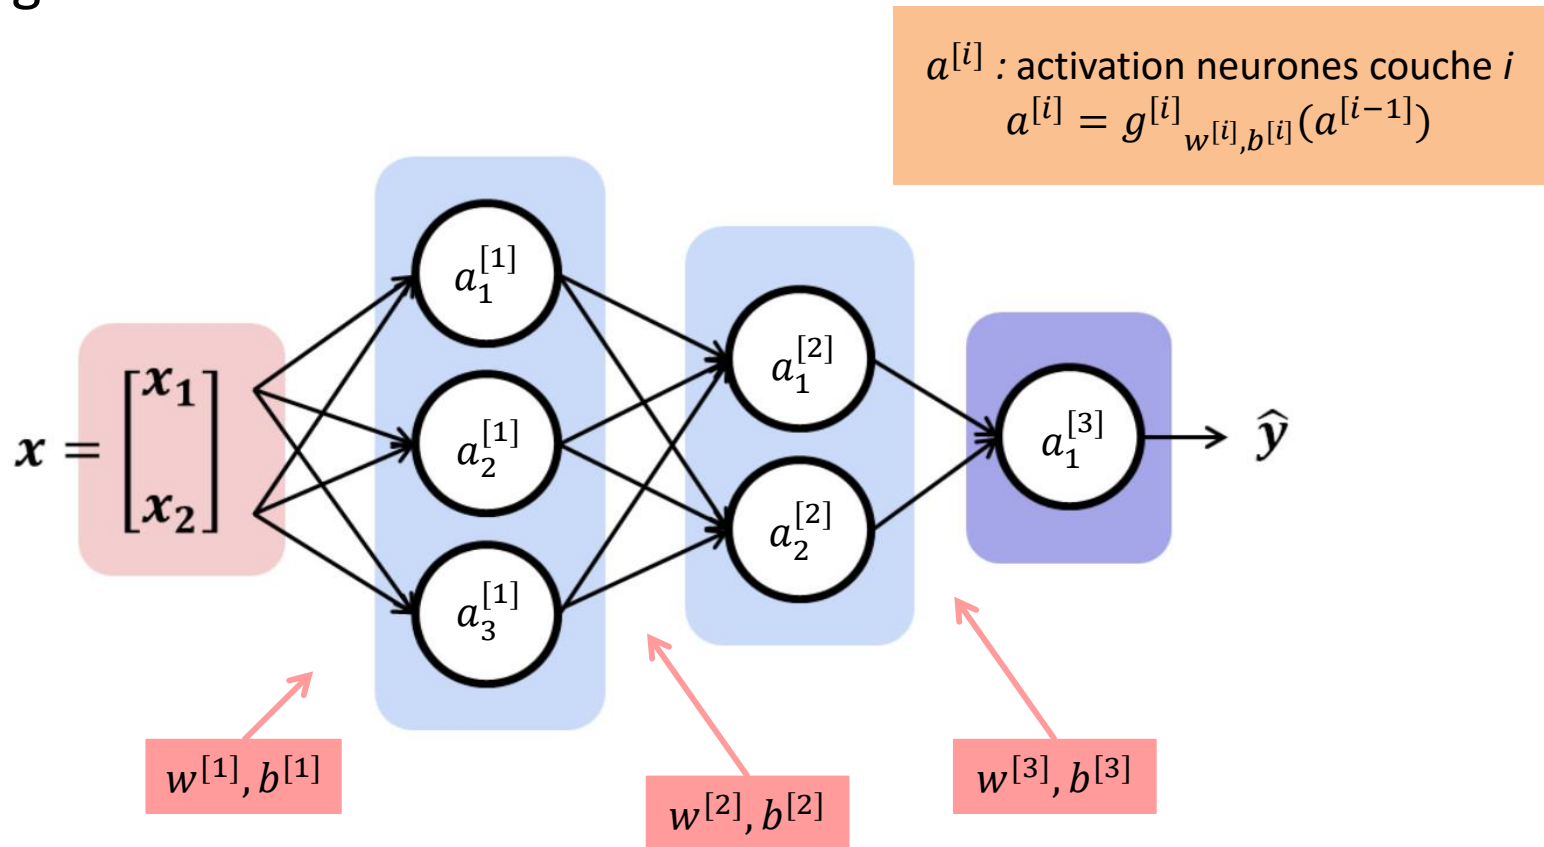
- ▶ Passage d'un neurone à un ensemble de neurones organisés suivant un réseau



Représentation matricielle

Concept de base


- ▶ Passage d'un neurone à un ensemble de neurones organisés suivant un réseau



Fonctions d'activation


- ▶ Différentes fonctions d'activation peuvent être utilisées au travers des couches

Sigmoïde



$$g^{[l]}(z) = \frac{1}{1 + e^{-z}}$$

Tangente hyperbolique




$$g^{[l]}(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

Fonctions d'activation


- ▶ Différentes fonctions d'activation peuvent être utilisées au travers des couches

Rectified Linear Unit (ReLU)



$$g^{[l]}(z) = \max(0, z)$$


leaky ReLU



$$g^{[l]}(z) = \max(0.01 \cdot z, z)$$

Élément de modélisation

- Calculer les dérivées partielles $\frac{\partial J}{\partial b^{[1]}}$, $\frac{\partial J}{\partial b^{[2]}}$ et $\frac{\partial J}{\partial w^{[1]}}$, $\frac{\partial J}{\partial w^{[2]}}$ dans le cas du réseau de neurones à deux couches suivant




$$J(w, b) = \frac{1}{N} \sum_{i=1}^N \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$$

avec $\mathcal{L}(\hat{y}^{(i)}, y^{(i)}) = -[y^{(i)} \log(\hat{y}^{(i)}) + (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})]$

$$\left[\begin{array}{l} \frac{\partial J}{\partial b^{[2]}} = \frac{1}{N} \sum_{i=1}^N \frac{\partial \mathcal{L}}{\partial b^{[2]}} = \frac{1}{N} \sum_{i=1}^N \left(\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} \cdot \frac{\partial \hat{y}^{(i)}}{\partial z^{[2]^{(i)}}} \cdot \frac{\partial z^{[2]^{(i)}}}{\partial b^{[2]}} \right) \\ \frac{\partial J}{\partial b^{[1]}} = \frac{1}{N} \sum_{i=1}^N \frac{\partial \mathcal{L}}{\partial b^{[1]}} = \frac{1}{N} \sum_{i=1}^N \left(\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} \cdot \frac{\partial \hat{y}^{(i)}}{\partial z^{[2]^{(i)}}} \cdot \frac{\partial z^{[2]^{(i)}}}{\partial a^{[1]^{(i)}}} \cdot \frac{\partial a^{[1]^{(i)}}}{\partial z^{[1]}} \cdot \frac{\partial z^{[1]^{(i)}}}{\partial b^{[1]}} \right) \end{array} \right.$$

Élément de modélisation

- Calculer les dérivées partielles $\frac{\partial J}{\partial b^{[1]}}$, $\frac{\partial J}{\partial b^{[2]}}$ et $\frac{\partial J}{\partial w^{[1]}}$, $\frac{\partial J}{\partial w^{[2]}}$ dans le cas du réseau de neurones à deux couches suivant




$$J(w, b) = \frac{1}{N} \sum_{i=1}^N \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$$

avec $\mathcal{L}(\hat{y}^{(i)}, y^{(i)}) = -[y^{(i)} \log(\hat{y}^{(i)}) + (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})]$

$$\left[\begin{aligned} \frac{\partial J}{\partial w^{[2]}} &= \frac{1}{N} \sum_{i=1}^N \frac{\partial \mathcal{L}}{\partial w^{[2]}} = \frac{1}{N} \sum_{i=1}^N \left(\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} \cdot \frac{\partial \hat{y}^{(i)}}{\partial z^{[2]^{(i)}}} \cdot \frac{\partial z^{[2]^{(i)}}}{\partial w} \right) \\ \frac{\partial J}{\partial w^{[1]}} &= \frac{1}{N} \sum_{i=1}^N \frac{\partial \mathcal{L}}{\partial w^{[1]}} = \frac{1}{N} \sum_{i=1}^N \left(\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} \cdot \frac{\partial \hat{y}^{(i)}}{\partial z^{[2]^{(i)}}} \cdot \frac{\partial z^{[2]^{(i)}}}{\partial a^{[1]^{(i)}}} \cdot \frac{\partial a^{[1]^{(i)}}}{\partial z^{[1]^{(i)}}} \cdot \frac{\partial z^{[1]^{(i)}}}{\partial w^{[1]}} \right) \end{aligned} \right.$$

Concept de base

- ▶ Apprentissage simultané d'un espace d'informations discriminantes et d'une fonction de décision associée



Apprentissage de la fonction de décision

► Phase d'apprentissage

Initialisation des $w^{[l]}$ et $b^{[l]}$

Répéter jusqu'à convergence

{


propagation avant



propagation arrière



}



Apprentissage de la fonction de décision

► Phase d'apprentissage

Initialisation des $w^{[l]}$ et $b^{[l]}$

Répéter jusqu'à convergence

{


propagation avant



propagation arrière



}



Apprentissage de la fonction de décision

► Phase d'apprentissage

Initialisation des $w^{[l]}$ et $b^{[l]}$

Répéter jusqu'à convergence

{


propagation avant



propagation arrière



}



Apprentissage de la fonction de décision

► Phase d'apprentissage

Initialisation des $w^{[l]}$ et $b^{[l]}$

Répéter jusqu'à convergence

{


propagation avant



propagation arrière



}



$$\text{Calcul de } J(w, b) = \frac{1}{N} \sum_{i=1}^N \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$$

Apprentissage de la fonction de décision

- ▶ Approche empirique - Descente de gradient

Initialisation des $w^{[l]}$ et $b^{[l]}$

Répéter jusqu'à convergence

{


propagation avant



propagation arrière



}



Apprentissage de la fonction de décision

- Approche empirique - Descente de gradient

Initialisation des $w^{[l]}$ et $b^{[l]}$

Répéter jusqu'à convergence

{


propagation avant



propagation arrière



}



Apprentissage de la fonction de décision

- ▶ Approche empirique - Descente de gradient

Initialisation des $w^{[l]}$ et $b^{[l]}$

Répéter jusqu'à convergence

{


propagation avant



propagation arrière



}



Apprentissage de la fonction de décision

► Approche empirique - Descente de gradient

Initialisation des $w^{[l]}$ et $b^{[l]}$

Répéter jusqu'à convergence

{

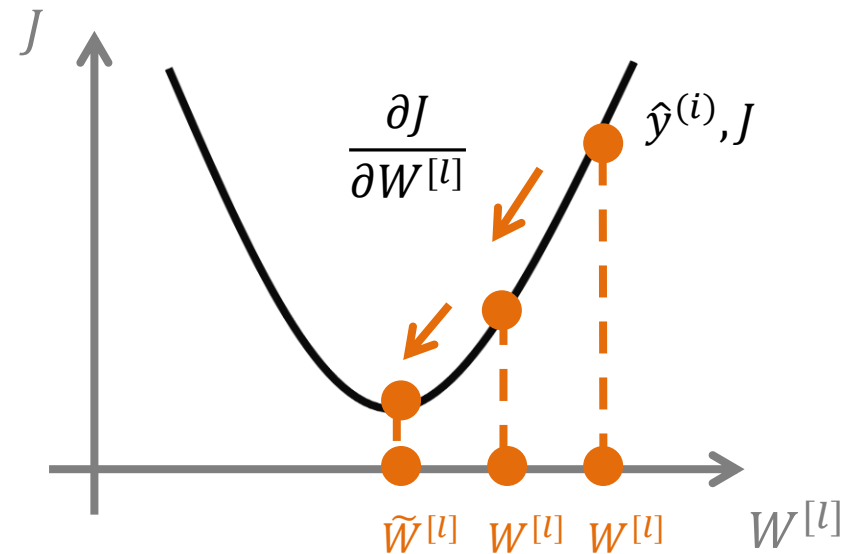
propagation avant

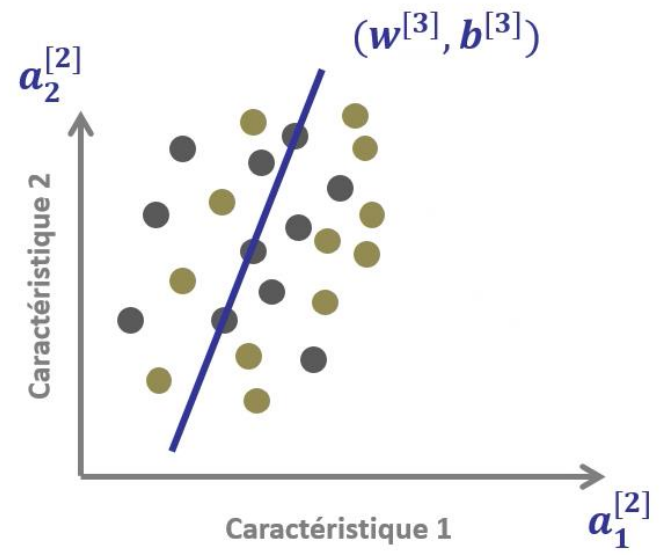
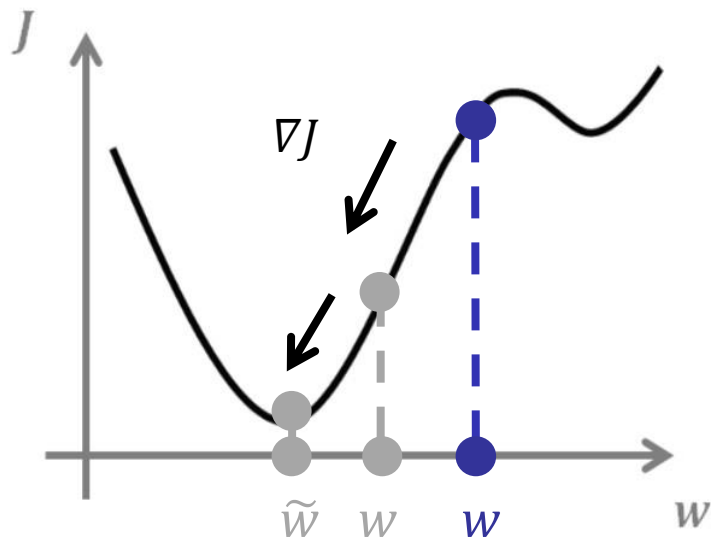



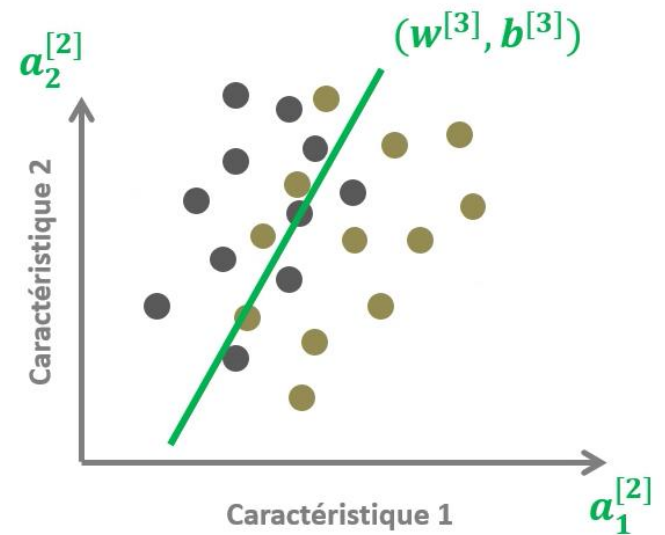


propagation arrière

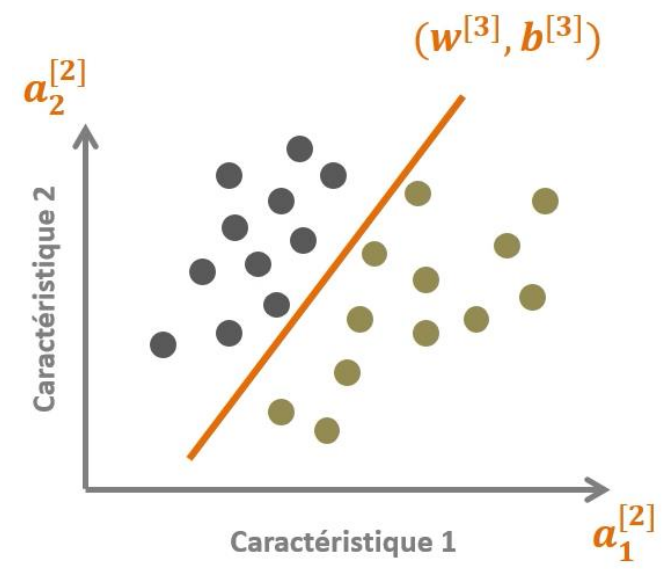




}











Evolution de l'espace des caractéristiques de la dernière couche au cours des itérations




Et maintenant jouons !


Moodle / TdSI 2 - Processing / jupyter / cm4_MLP /
pytorch_mnist_mlp.ipynb



Base de données MNIST
Reconnaissance de chiffres manuscrits



That's all folks



$$J(w, b) = \frac{1}{N} \sum_{i=1}^N \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$$

$$\begin{aligned} \mathcal{L}(\hat{y}^{(i)}, y^{(i)}) &= -[y^{(i)} \log(\hat{y}^{(i)}) \\ &+ (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})] \end{aligned}$$


$$\frac{\partial J}{\partial b} = \frac{1}{N} \sum_{i=1}^N \frac{\partial \mathcal{L}}{\partial b} = \frac{1}{N} \sum_{i=1}^N \left(\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} \cdot \frac{\partial \hat{y}^{(i)}}{\partial z^{(i)}} \cdot \frac{\partial z^{(i)}}{\partial b} \right)$$

$$\mathcal{L}(\hat{y}^{(i)}, y^{(i)}) = -[y^{(i)} \log(\hat{y}^{(i)}) + (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})]$$

$$\Rightarrow \frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} = -\frac{y^{(i)}}{\hat{y}^{(i)}} + \frac{1 - y^{(i)}}{1 - \hat{y}^{(i)}}$$

$$\hat{y}^{(i)} = g(z^{(i)}) = \frac{1}{1 + e^{-z^{(i)}}} \quad \Rightarrow \quad \frac{\partial \hat{y}^{(i)}}{\partial z^{(i)}} = \hat{y}^{(i)}(1 - \hat{y}^{(i)})$$

$$z^{(i)} = wx^{(i)} + b \quad \Rightarrow \quad \frac{\partial z^{(i)}}{\partial b} = 1$$



$$J(w, b) = \frac{1}{N} \sum_{i=1}^N \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$$


$$\begin{aligned} \mathcal{L}(\hat{y}^{(i)}, y^{(i)}) &= -[y^{(i)} \log(\hat{y}^{(i)}) \\ &+ (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})] \end{aligned}$$

$$\frac{\partial J}{\partial b} = \frac{1}{N} \sum_{i=1}^N \frac{\partial \mathcal{L}}{\partial b} = \frac{1}{N} \sum_{i=1}^N \left(\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} \cdot \frac{\partial \hat{y}^{(i)}}{\partial z^{(i)}} \cdot \frac{\partial z^{(i)}}{\partial b} \right)$$


$$\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} = -\frac{y^{(i)}}{\hat{y}^{(i)}} + \frac{1 - y^{(i)}}{1 - \hat{y}^{(i)}}$$

$$\frac{\partial \hat{y}^{(i)}}{\partial z^{(i)}} = \hat{y}^{(i)}(1 - \hat{y}^{(i)})$$

$$\frac{\partial z^{(i)}}{\partial b} = 1$$



$$\frac{\partial J}{\partial b} = \frac{1}{N} \sum_{i=1}^N (\hat{y}^{(i)} - y^{(i)})$$



$$J(w, b) = \frac{1}{N} \sum_{i=1}^N \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$$

$$\begin{aligned} \mathcal{L}(\hat{y}^{(i)}, y^{(i)}) &= -[y^{(i)} \log(\hat{y}^{(i)}) \\ &\quad + (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})] \end{aligned}$$


$$\frac{\partial J}{\partial w} = \frac{1}{N} \sum_{i=1}^N \frac{\partial \mathcal{L}}{\partial b} = \frac{1}{N} \sum_{i=1}^N \left(\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} \cdot \frac{\partial \hat{y}^{(i)}}{\partial z^{(i)}} \cdot \frac{\partial z^{(i)}}{\partial w} \right)$$

$$\mathcal{L}(\hat{y}^{(i)}, y^{(i)}) = -[y^{(i)} \log(\hat{y}^{(i)}) + (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})]$$

$$\Rightarrow \frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} = -\frac{y^{(i)}}{\hat{y}^{(i)}} + \frac{1 - y^{(i)}}{1 - \hat{y}^{(i)}}$$

$$\hat{y}^{(i)} = g(z^{(i)}) = \frac{1}{1 + e^{-z^{(i)}}} \quad \Rightarrow \quad \frac{\partial \hat{y}^{(i)}}{\partial z^{(i)}} = \hat{y}^{(i)}(1 - \hat{y}^{(i)})$$

$$z^{(i)} = wx^{(i)} + b \quad \Rightarrow \quad \frac{\partial z^{(i)}}{\partial w} = x^{(i)}$$



$$J(w, b) = \frac{1}{N} \sum_{i=1}^N \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$$


$$\begin{aligned} \mathcal{L}(\hat{y}^{(i)}, y^{(i)}) &= -[y^{(i)} \log(\hat{y}^{(i)}) \\ &+ (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})] \end{aligned}$$

$$\frac{\partial J}{\partial w} = \frac{1}{N} \sum_{i=1}^N \frac{\partial \mathcal{L}}{\partial b} = \frac{1}{N} \sum_{i=1}^N \left(\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} \cdot \frac{\partial \hat{y}^{(i)}}{\partial z^{(i)}} \cdot \frac{\partial z^{(i)}}{\partial w} \right)$$

$$\frac{\partial \mathcal{L}}{\partial \hat{y}^{(i)}} = -\frac{y^{(i)}}{\hat{y}^{(i)}} + \frac{1 - y^{(i)}}{1 - \hat{y}^{(i)}}$$

$$\frac{\partial \hat{y}^{(i)}}{\partial z^{(i)}} = \hat{y}^{(i)}(1 - \hat{y}^{(i)})$$

$$\frac{\partial z^{(i)}}{\partial w} = x^{(i)}$$



$$\frac{\partial J}{\partial w} = \frac{1}{N} \sum_{i=1}^N (\hat{y}^{(i)} - y^{(i)}) \cdot x^{(i)}$$