Introduction au deep learning

ENSTA 2024

Adrien CHAN-HON-TONG
HDR ONERA

Rappel

Rappel

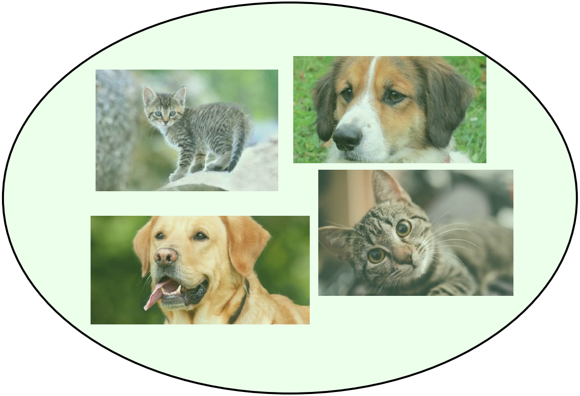

Rappel

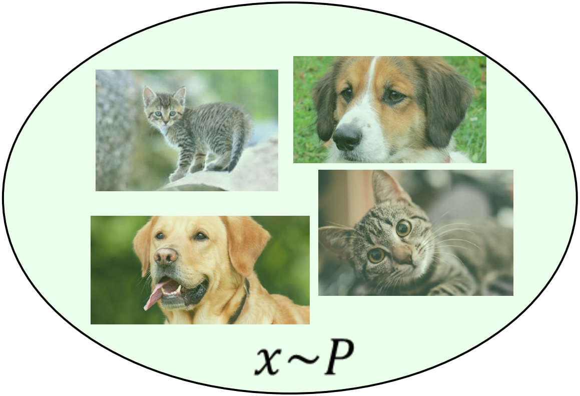

Rappel

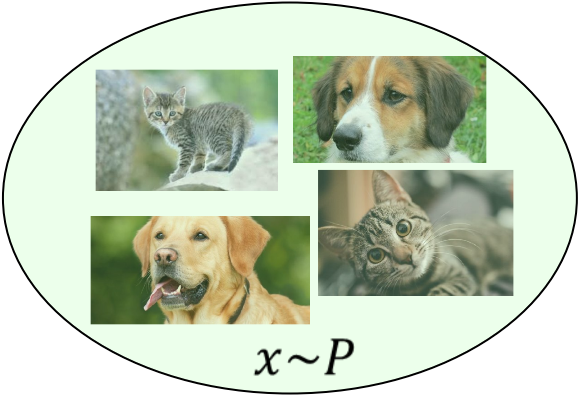

Rappel

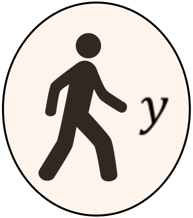

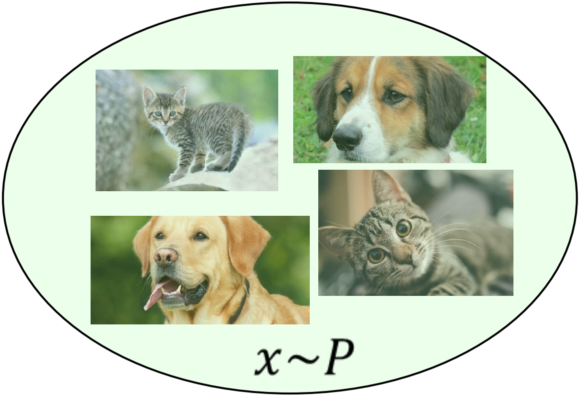

Rappel

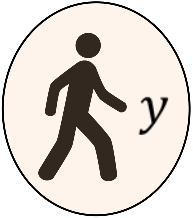

y

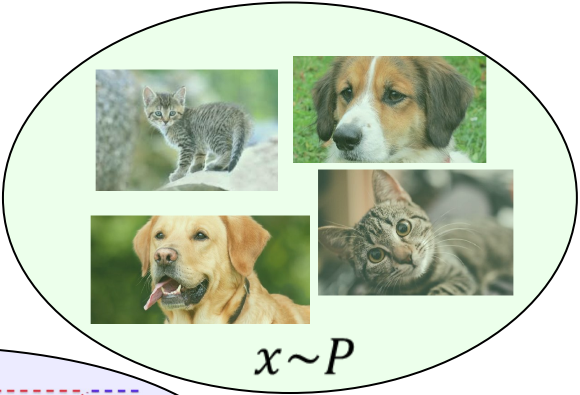

$x \sim P$

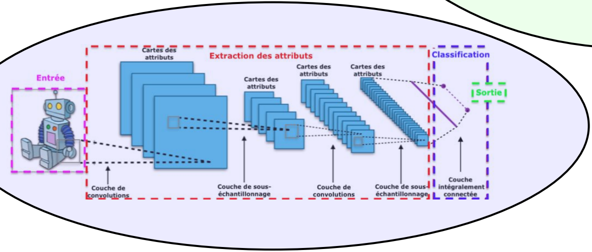

Entrée
Cartes des attributs
Extraction des attributs
Cartes des attributs
Cartes des attributs
Cartes des attributs
Classification
Sortie
Couche de convolutions
Couche de sous-échantillonnage
Couche de convolutions
Couche de sous-échantillonnage
Couche intégralement connectée

Rappel

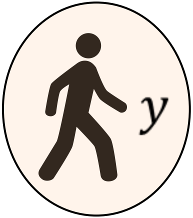
y

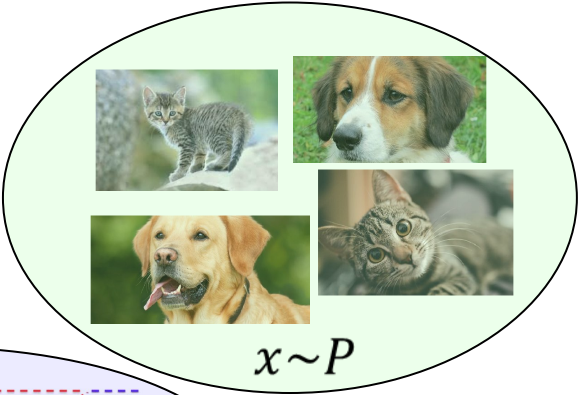
$x \sim P$

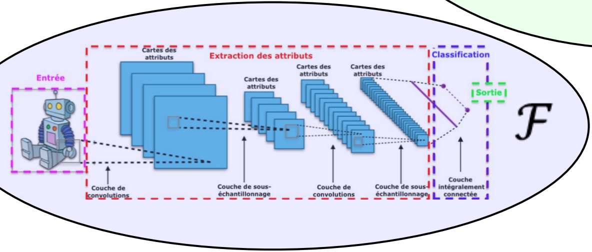
Entrée
Cartes des attributs
Extraction des attributs
Cartes des attributs
Cartes des attributs
Cartes des attributs
Classification
Sortie
Couche de convolutions
Couche de sous-échantillonnage
Couche de convolutions
Couche de sous-échantillonnage
Couche intégralement connectée
$\mathcal{F}$

Rappel

y

$x \sim P$

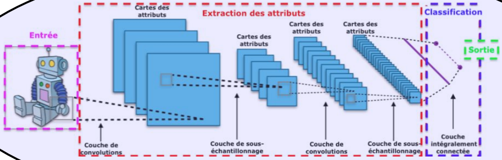

$\mathcal{F}$

Rappel

y

$x \sim P$

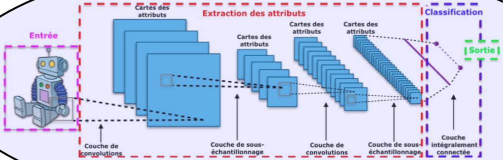

$\mathcal{F}$

$f \in \mathcal{F}$

Rappel

Est-ce que

$$f(x) \approx y(x)$$

pour $x \sim P$?

Rappel

Est-ce que

$$f(x) \approx y(x)$$

pour $x \sim P$?

Si *f* n'est pas une bonne approximation sur les données d'apprentissage, c'est de l'underfiting. Si *f* est une bonne approximation des données d'apprentissage mais pas de *P* c'est de l'overfiting.

Objectif du cours 1

Insister sur la différence entre architecture (i.e. famille de fonction) et fonction pour des MLP

La double descente ?

L'apprentissage en pratique

Objectif du cours 2

pytorch

CNN

Transformer et perspective

PLAN

- COURS 1
  - **MLP**
  - Double descente ?
  - Apprentissage
- Cours 2
  - Pytorch
  - CNN
  - Transformer et perspective

Réseau de neurones

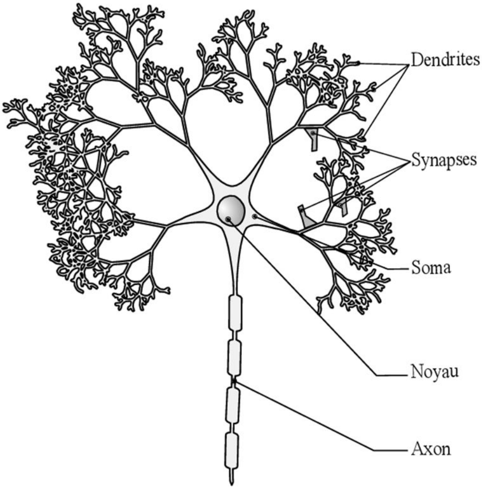

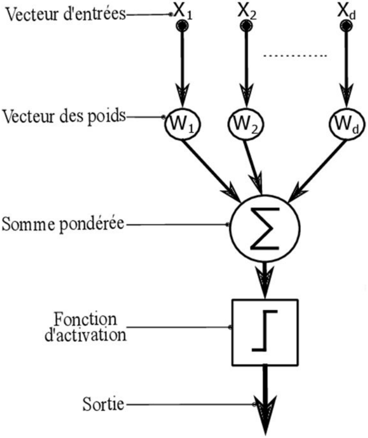

La classification

1 neurone
ne peut être que linéaire

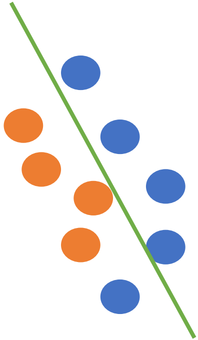

La classification

1 neurone
ne peut être que linéaire

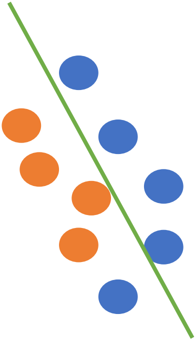

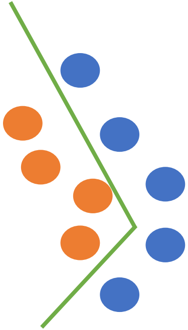

4 neurones + activation
peut être une fonction **non** linéaire

La classification

1 neurone
peut coder TOUTES
ces fonctions
(via la valeur des poids)

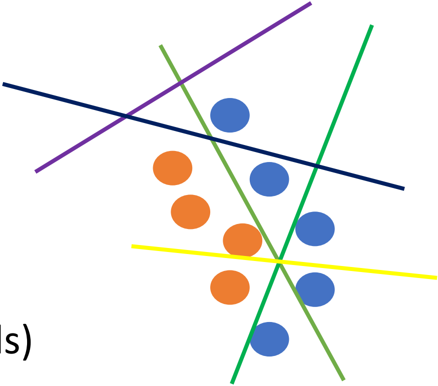

La classification

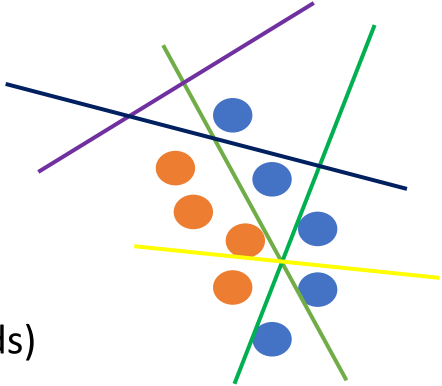

1 neurone
peut coder TOUTES
ces fonctions
(via la valeur des poids)

Le SVM en est 1 seule fonction
(optimisation des poids)

La classification

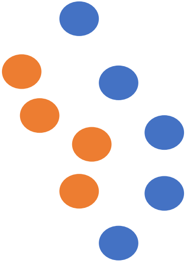

4 neurones + activation
=> On ne peut même pas dessiner l’ensemble des fonctions qu’on peut obtenir via les valeurs des poids !

Il va falloir en choisir 1

MLP

Notebook illustration

+

https://playground.tensorflow.org

MLP

1 neurone : $f(x) = w^T x + b = \sum_{d=1}^{D} w_d x_d + b$

1 couche de 2 neurones + 1 neurone :

$$f(x) = w_3^T \begin{pmatrix} \phi(w_1^T x + b_1) \\ \phi(w_2^T x + b_2) \end{pmatrix} + b_3$$

1 couche de 2 neurones
+ 1 couche de 3 neurones
+ 1 neurone :

$$f(x) = w_6^T \begin{pmatrix} \phi(w_3^T \begin{pmatrix} \phi(w_1^T x + b_1) \\ \phi(w_2^T x + b_2) \end{pmatrix} + b_3) \\ \phi(w_4^T \begin{pmatrix} \phi(w_1^T x + b_1) \\ \phi(w_2^T x + b_2) \end{pmatrix} + b_4) \\ \phi(w_5^T \begin{pmatrix} \phi(w_1^T x + b_1) \\ \phi(w_2^T x + b_2) \end{pmatrix} + b_5) \end{pmatrix} + b_6$$

MLP

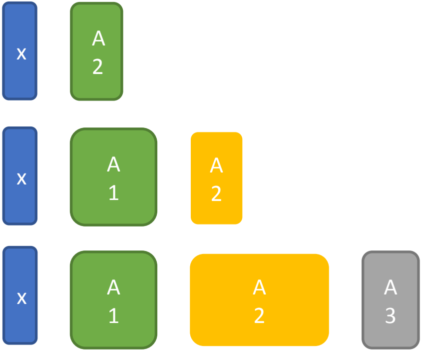

1 neurone : $f(x) = Ax + b$

1 couche de 2 neurones + 1 neurone :

$$f(x) = A_2\big(\phi(A_1 x + b_1)\big) + b_2$$

1 couche de 2 neurones
+ 1 couche de 3 neurones
+ 1 neurone :

$$f(x) = A_3\big(\phi(A_2(\phi(A_1 x + b_1)) + b_2)\big) + b_3$$

ϕ d'un vecteur c'est le vecteur des ϕ

MLP

la famille de MLP à activation φ et à Q couches de taille $i_1, \ldots, i_Q$
est la famille des fonctions qui peuvent s'écrire

$$f(x) = A_Q\left(\phi\left(A_{Q-1}\left(\ldots\phi\left(A_2\left(\phi(A_1x + b_1)\right) + b_2\right)\ldots\right) + b_{q-1}\right)\right) + b_q$$

Avec $A_q \in \mathbb{R}^{i_q \times i_{q-1}}$ et $b_q \in \mathbb{R}^{i_q}$

Convention i0 correspond à la dimension des entrées « x »

L'activation la plus classique est : $relu(t) = \max(t, 0)$

MLP

Notebook illustration

+

https://playground.tensorflow.org

PLAN

- COURS 1
  - MLP
  - **Double descente ?**
  - Apprentissage
- Cours 2
  - Pytorch
  - CNN
  - Transformer et perspective

Théorème d'universalité

Avec 100 neurones,
on peut faire

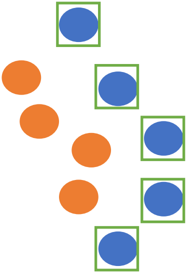

Théorème d'universalité

$$\forall x \in \mathbb{R}, |x| = relu(x) + relu(-x)$$

Théorème d'universalité

$\forall x \in \mathbb{R}, |x| = relu(x) + relu(-x)$
$\forall x \in \mathbb{R}^D, ||x||_1 = \mathbf{1}^T\,(relu(Ix) + relu(-Ix))$

Théorème d'universalité

$$\forall x \in \mathbb{R}, |x| = relu(x) + relu(-x)$$
$$\forall x \in \mathbb{R}^D, ||x||_1 = \mathbf{1}^T\left(relu(Ix) + relu(-Ix)\right)$$
$$\forall x, u \in \mathbb{R}^D, ||x - u||_1 = \mathbf{1}^T\left(relu(Ix - u) + relu(-Ix + u)\right)$$

Théorème d'universalité

$$\forall x \in \mathbb{R}, |x| = relu(x) + relu(-x)$$
$$\forall x \in \mathbb{R}^D, ||x||_1 = \mathbf{1}^T \left(relu(Ix) + relu(-Ix)\right)$$
$$\forall x, u \in \mathbb{R}^D, ||x-u||_1 = \mathbf{1}^T \left(relu(Ix-u) + relu(-Ix+u)\right)$$
$$\forall x, u \in \mathbb{R}^D, relu(1 - ||x-u||_1)$$

$$= relu\left(1 - \mathbf{1}^T \left(relu(Ix-u) + relu(-Ix+u)\right)\right)$$

Théorème d'universalité

$$\forall x \in \mathbb{R}, |x| = relu(x) + relu(-x)$$
$$\forall x \in \mathbb{R}^D, ||x||_1 = \mathbf{1}^T \left(relu(Ix) + relu(-Ix)\right)$$
$$\forall x, u \in \mathbb{R}^D, ||x-u||_1 = \mathbf{1}^T \left(relu(Ix-u) + relu(-Ix+u)\right)$$
$$\forall x, u \in \mathbb{R}^D, relu(1 - ||x-u||_1)$$

$$= relu\left(1 - \mathbf{1}^T \left(relu(Ix-u) + relu(-Ix+u)\right)\right)$$

$$\forall x, u, v \in \mathbb{R}^D, \begin{pmatrix} relu(1 - ||x-u||_1) \\ relu(1 - ||x-v||_1) \end{pmatrix}$$

$$= relu\left(\mathbf{1} - \begin{pmatrix} 1 & ... & 1 & 0 & ... & 0 \\ 0 & ... & 0 & 1 & ... & 1 \end{pmatrix} relu\begin{pmatrix} Ix-u \\ -Ix+u \\ Ix-v \\ -Ix+v \end{pmatrix}\right)$$

$$= \left[\mathbf{1} - \begin{pmatrix} 1 & ... & 1 & 0 & ... & 0 \\ 0 & ... & 0 & 1 & ... & 1 \end{pmatrix} \begin{bmatrix} Ix-u \\ -Ix+u \\ Ix-v \\ -Ix+v \end{bmatrix}_+\right]_+$$

Théorème d'universalité

Soit la matrice $W \in \mathbb{R}^{N\times(N\times 2D)}$ tel que $\forall n \in \{1,...,N\}, i \in \{1,...,N\times 2D\}$,

$$W_{n,i} = \begin{cases} 1 & ssi \quad 2nD \leq i < 2nD + 2D \\ 0 & sinon \end{cases}$$

alors, $\forall x_1, ..., x_N \in \mathbb{R}^D$

$$\left[\mathbf{1} - \begin{pmatrix} ||x - x_1||_1 \\ ||x - x_2||_1 \\ ... \\ ||x - x_N||_1 \end{pmatrix}\right]_+ = \left[\mathbf{1} - W \begin{bmatrix} Ix - x_1 \\ -Ix + x_1 \\ Ix - x_2 \\ -Ix + x_2 \\ ... \\ Ix - x_N \\ -Ix + x_N \end{bmatrix}_+\right]_+$$

Théorème d'universalité

Soit la matrice $W \in \mathbb{R}^{N\times(N\times 2D)}$ tel que $\forall n \in \{1,...,N\}, i \in \{1,...,N\times 2D\}$,

$$W_{n,i} = \begin{cases} 1 & ssi \quad 2nD \leq i < 2nD + 2D \\ 0 & sinon \end{cases}$$

alors, $\forall x_1,...,x_N \in \mathbb{R}^D$

$$\left[\mathbf{1} - \begin{pmatrix} ||x-x_1||_1 \\ ||x-x_2||_1 \\ ... \\ ||x-x_N||_1 \end{pmatrix}\right]_+ = \left[\mathbf{1} - W \begin{bmatrix} Ix - x_1 \\ -Ix + x_1 \\ Ix - x_2 \\ -Ix + x_2 \\ ... \\ Ix - x_N \\ -Ix + x_N \end{bmatrix}_+\right]_+$$

$\forall x_1,...,x_N \in \mathbb{Z}^D, y_1,...,y_N \in \{-1,1\}$ la fonction

$$f(x) = \begin{pmatrix} y_1 \\ y_2 \\ ... \\ y_N \end{pmatrix}^T \left[\mathbf{1} - W \begin{bmatrix} Ix - x_1 \\ -Ix + x_1 \\ Ix - x_2 \\ -Ix + x_2 \\ ... \\ Ix - x_N \\ -Ix + x_N \end{bmatrix}_+\right]_+$$

vérifie $\forall n \in \{1,...,N\},\ y_n f(x_n) > 0$.

Théorème d'universalité

Avec 100 neurones,
on peut faire ça

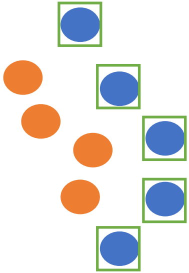

Théorème d'universalité

Avec 100 neurones,
on peut faire ça

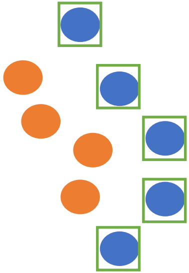

Sauf que c'est la pire chose possible

Théorème d'universalité

Avec 100 neurones,
on peut faire ça

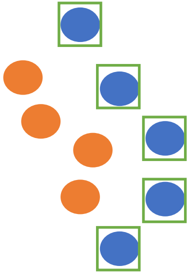

- Sauf que c'est la pire chose possible
- Il se trouve que ça arrive pas ????

Ancien paradigme

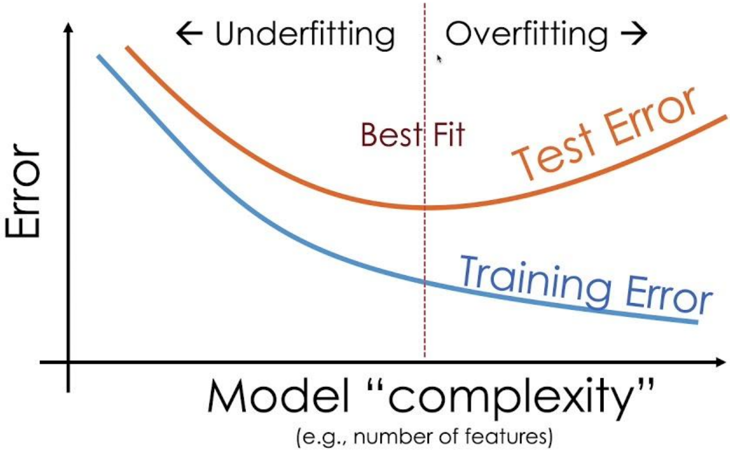

Ce qu'on observe

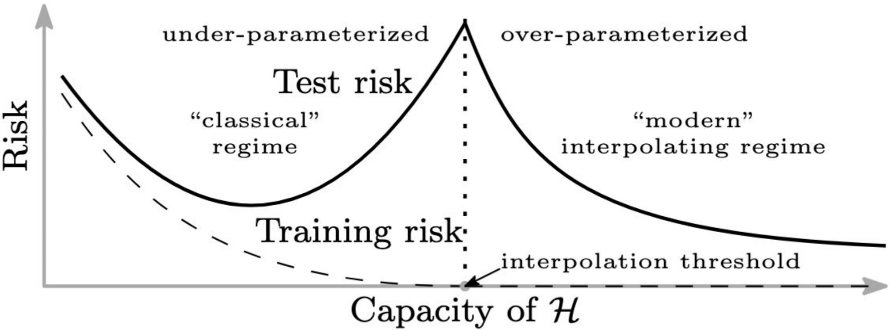

Ce qu’on observe

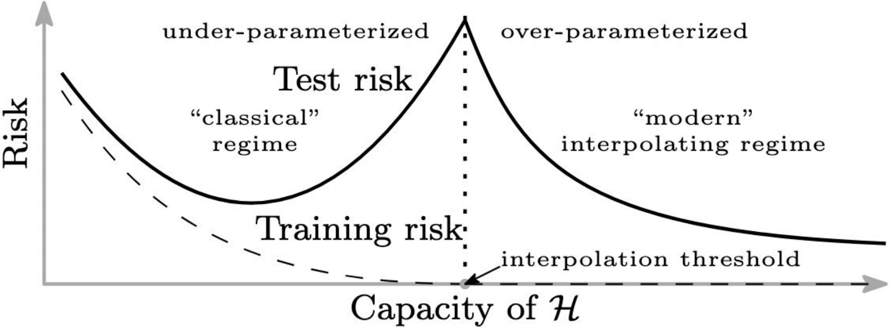

On pourrait penser que limiter le nombre de neurones est le moyen de limiter le sur-apprentissage.
En pratique, c’est plus compliqué.

PLAN

- COURS 1
  - MLP
  - Double descente ?
  - **Apprentissage**
- Cours 2
  - Pytorch
  - CNN
  - Transformer et perspective

Rappel

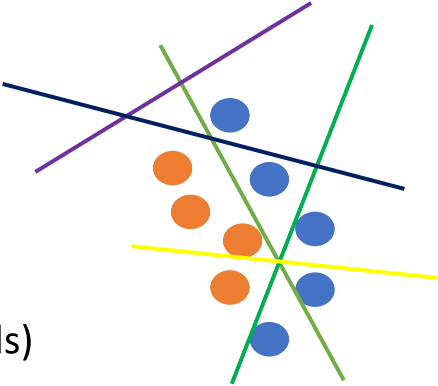

1 neurone
peut coder TOUTES
ces fonctions
(via la valeur des poids)

Le SVM en est 1 seule fonction
(optimisation des poids)

https://playground.tensorflow.org

Comment apprendre un MLP en pratique ?

- Descente de gradient
- Descente de gradient stochastique
- Fonction de perte
- Calcul du gradient

Descente de gradient

$$J(u+\varepsilon) \approx J(u) + [\nabla_u J]^T \varepsilon + \varepsilon o(\varepsilon)$$

Descente de gradient

$$J(u+\varepsilon) \approx J(u) + [\nabla_u J]^T \varepsilon + \varepsilon o(\varepsilon)$$

$$\begin{gathered} J(u - \lambda \nabla_u J) \\ \approx \; J(u) - \lambda [\nabla_u J]^T [\nabla_u J] + \lambda o(\lambda) \\ \approx \; J(u) - \|\nabla_u J\|^2 \times \lambda + \lambda o(\lambda) \end{gathered}$$

Descente de gradient

$$J(u+\varepsilon) \approx J(u) + [\nabla_u J]^T \varepsilon + \varepsilon o(\varepsilon)$$

$$\begin{gathered} J(u - \lambda \nabla_u J) \\ \approx\ J(u) - \lambda [\nabla_u J]^T [\nabla_u J] + \lambda o(\lambda) \\ \approx\ J(u) - \|\nabla_u J\|^2 \times \lambda + \lambda o(\lambda) \end{gathered}$$

$$\begin{gathered} \nabla_u J \neq 0 \Longrightarrow \exists \lambda > 0, \\ J(u - \lambda \nabla_u J) < J(u) \end{gathered}$$

Descente de gradient

- Initialiser u
- Si $\|\nabla_u J\| < \delta$, sortir
- Sinon
  - Initialiser λ
  - Si $\mathrm{J}(\mathrm{u} - \lambda\nabla_u J) < \mathrm{J}(\mathrm{u})$, alors $\mathrm{u} = \mathrm{u} - \lambda\nabla_u J$
  - Sinon réessayer avec $\lambda = \frac{\lambda}{2}$

Descente de gradient

- Initialiser u
- Si $\|\nabla_u J\| < \delta$, sortir
- Sinon
  - Initialiser λ
  - Si $\mathrm{J}(\mathrm{u} - \lambda \nabla_u J) < \mathrm{J}(\mathrm{u})$, alors $\mathrm{u} = \mathrm{u} - \lambda \nabla_u J$
  - Sinon réessayer avec $\lambda = \frac{\lambda}{2}$

⇒ Converge vers un point u tel que $\|\nabla_u J\| < \delta$

Si la fonction est bornée

Descente de gradient

$$u = A^{-1}b$$

$$\min_{u} \|Au - b\|^2$$

1. $u = 0$
2. Si $\|2A^T(Au - b)\| < 10^{-6}$, sortir
3. $u = u - \lambda A^T(Au - b)$, GOTO2

Descente de gradient

$$u = A^{-1}b$$

$$\min_{\mathrm{u}} \|Au - b\|^2$$

$O(N^{\gamma}L), \qquad \gamma \approx 2.34$

1. $u = 0$
2. Si $\|2A^T(Au - b)\| < 10^{-6}$, sortir
3. $u = u - \lambda A^T(Au - b)$, GOTO2

$O(N^2 2^L L)$

Descente de gradient **stochastique**

$$J(u) = \sum_{k=1}^{K} j_k(u)$$

Si je tire k uniformément dans {1,…,K}, et que $g = j_k(u)$

$$\mathbf{E}[\nabla g] = \frac{1}{\mathrm{K}} \sum_{k=1}^{K} \nabla j_k = \nabla J$$

Descente de gradient **stochastique**

$$J(u) = \sum_{k=1}^{K} j_k(u)$$

Si je tire *k* uniformément dans {1,…,*K*}, et que $g = j_k(u)$

$$\mathbf{E}[\nabla g] = \frac{1}{\mathrm{K}} \sum_{k=1}^{K} \nabla j_k = \nabla J$$

➡ Si *K* est très très grand, il n’y a pas d’alternative à chercher une approximation probabiliste du gradient

Descente de gradient **stochastique** pour un MLP

- Choisir une fonction de perte *J*
- Initialiser aléatoirement les poids *w*
- Faire un certain nombre de fois
  - Sélectionner un paquet de données *X*
  - Comparer *f(X)* et *y(X)* à travers *J*
  - Calculer le gradient correspondant *dw*
  - *w = w – lr * dw*

Calcul du gradient ?

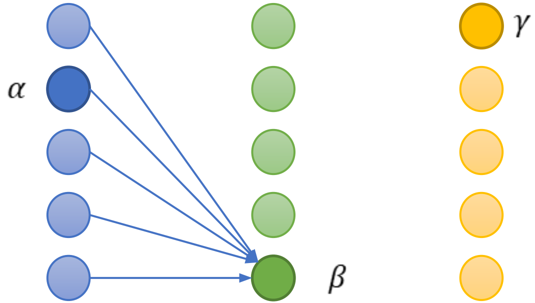

Calcul du gradient ?

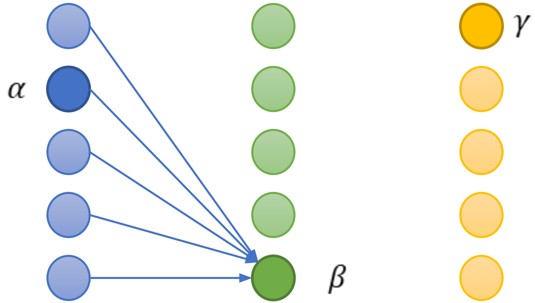

$$\beta = w_{\{\beta,\alpha\}}\alpha + \cdots$$
$$\gamma = w_{\{\gamma,\beta\}}\beta + \cdots$$

Calcul du gradient ?

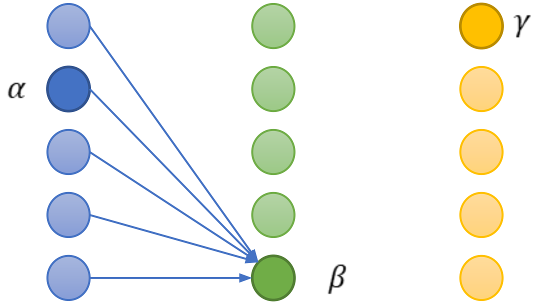

$$\beta = w_{\{\beta,\alpha\}}\alpha + \cdots \qquad \gamma\,(\alpha, \dots) = \gamma\,(\beta(\alpha, \dots), \dots)$$

$$\gamma = w_{\{\gamma,\beta\}}\beta + \cdots$$

Calcul du gradient ?

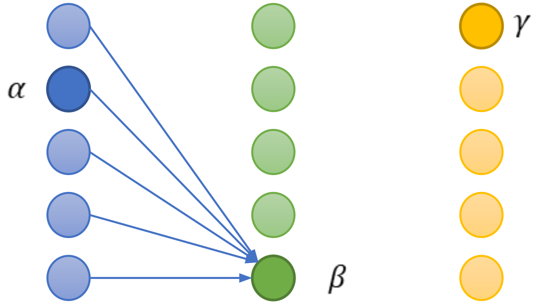

$$\beta = w_{\{\beta,\alpha\}}\alpha + \cdots$$
$$\gamma = w_{\{\gamma,\beta\}}\beta + \cdots$$

$$\gamma\,(\alpha, \dots) = \gamma\,(\beta(\alpha, \dots), \dots)$$

$$\frac{\partial\gamma}{\partial\alpha} = \frac{\partial\gamma}{\partial\beta}\frac{\partial\beta}{\partial\alpha} + \cdots$$

Calcul du gradient

Et en pratique à la fin c’est pytorch qui le calcul pour vous !

Rappel

y

$x \sim P$

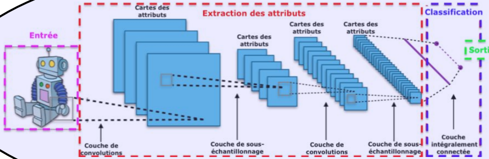

$\mathcal{F}$

$f \in \mathcal{F}$

Pourquoi une fonction de perte ?

Ce qu'on veut c'est trouver w tel que

$$f_W(x) \approx y(x)$$

sur la base d'apprentissage.

Pourquoi une fonction de perte ?

Ce qu'on veut c'est trouver w tel que

$$f_w(x) \approx y(x)$$

sur la base d'apprentissage.

⇒ 1 erreur c'est χ tel que $y(\chi)f_w(\chi) \leq 0$

Pourquoi une fonction de perte ?

Ce qu'on veut c'est trouver w tel que

$$f_w(x) \approx y(x)$$

sur la base d'apprentissage.

1 erreur c'est χ tel que $y(\chi) f_w(\chi) \leq 0$

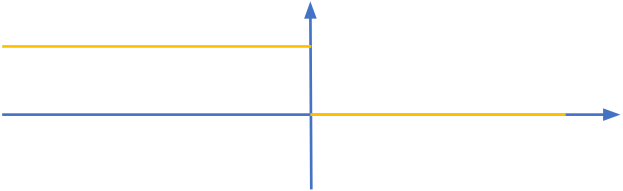

Pourquoi une fonction de perte ?

Ce qu'on veut c'est trouver w tel que

$$f_w(x) \approx y(x)$$

sur la base d'apprentissage.

1 erreur c'est χ tel que $y(\chi) f_w(\chi) \leq 0$

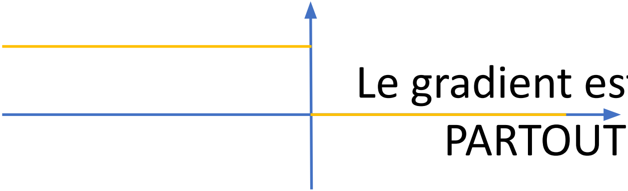

fonction de perte

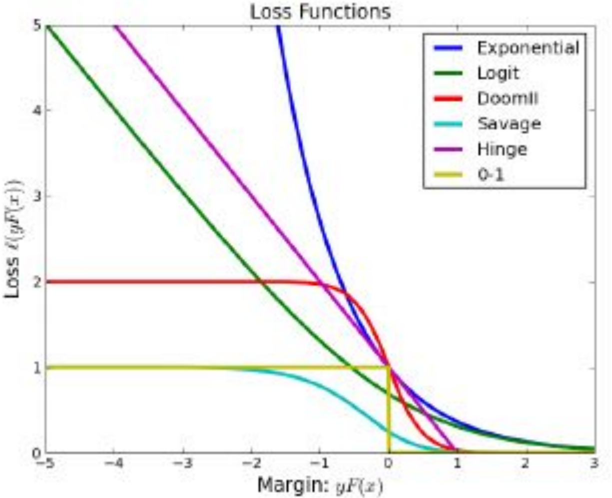

https://playground.tensorflow.org

fonction de perte

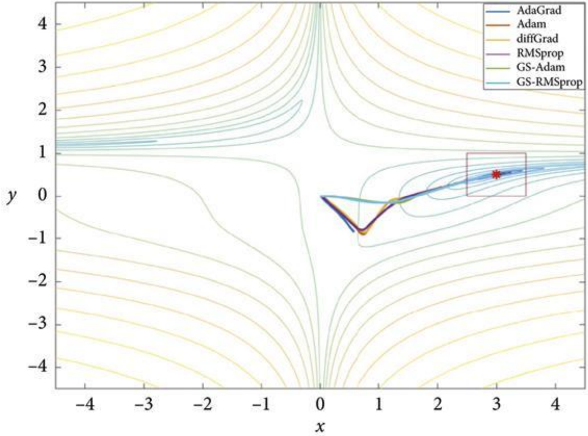

https://playground.tensorflow.org

Bilan : MLP

- Choisir une architecture
- Choisir une fonction de perte
- Choisir une variante de la SGD
- Effectuer une SGD sur les données d'apprentissage (en utilisant les gradients calculés par pytorch)

Bilan : MLP

- Choisir une architecture MLP
- Choisir une fonction de perte
- Choisir une variante de la SGD
- Effectuer une SGD sur les données d'apprentissage (en utilisant les gradients calculés par pytorch)

PLAN

- COURS 1
  - MLP
  - Double descente ?
  - Apprentissage
- Cours 2
  - **Pytorch**
  - CNN
  - Transformer et perspective

Pytorch

Voir notebooks

PLAN

- COURS 1
  - MLP
  - Double descente ?
  - Apprentissage
- Cours 2
  - Pytorch
  - **CNN**
  - Transformer et perspective

À la recherche de l'information visuelle

À la recherche de l'information visuelle

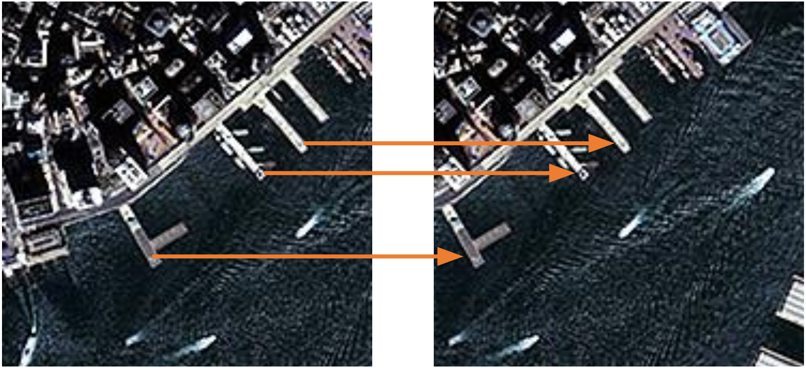

À la recherche de l'information visuelle

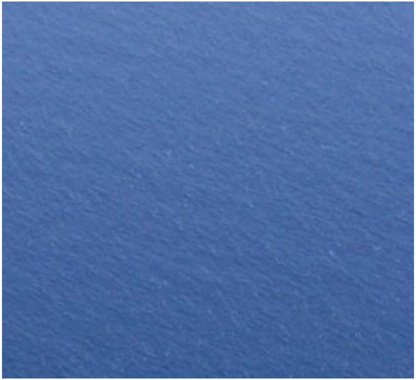

À la recherche de l'information visuelle

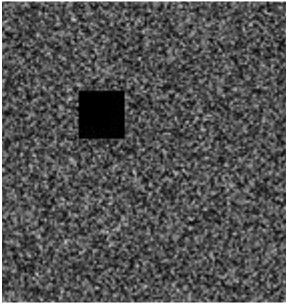

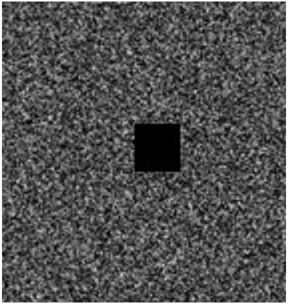

À la recherche de l’information visuelle

À la recherche de l’information visuelle : les contours ?

À la recherche de l'information visuelle : les contours ?

$$
\begin{bmatrix}
100 & 100 & 100 & 100 & 100 \\
100 & 100 & 100 & 100 & 100 \\
100 & 100 & 150 & 100 & 100 \\
100 & 100 & 100 & 100 & 100 \\
100 & 100 & 100 & 100 & 100
\end{bmatrix}
*
\begin{bmatrix}
0 & -1 & 0 \\
-1 & 5 & -1 \\
0 & -1 & 0
\end{bmatrix}
=
\begin{bmatrix}
100 & 100 & 100 & 100 & 100 \\
100 & 100 & 50 & 100 & 100 \\
100 & 50 & 350 & 50 & 100 \\
100 & 100 & 50 & 100 & 100 \\
100 & 100 & 100 & 100 & 100
\end{bmatrix}
$$

À la recherche de l'information visuelle : les contours ?

$$\mathbf{G_x} = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} * \mathbf{A} \quad \text{et} \quad \mathbf{G_y} = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} * \mathbf{A}$$

À la recherche de l'information visuelle : les contours ?

Image

Bords

Reconnaissance des formes

À la recherche de l'information visuelle : les contours ?

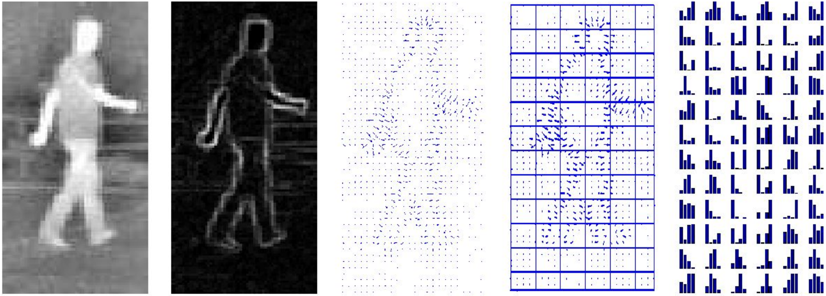

a b c d e

À la recherche de l’information visuelle : les contours ?

Image → Bords → Histogrammes

↓

Représentation globale → Classification

À la recherche de l'information visuelle : coin de Harris

À la recherche de l'information visuelle : coin de Harris

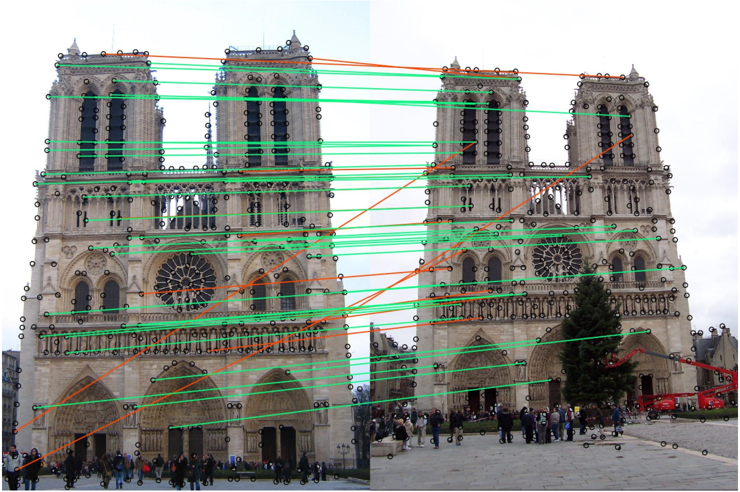

À la recherche de l'information visuelle : coin de Harris

Robert Collins
CSE486, Penn State

Harris Corner Detection Algorithm

1. Compute x and y derivatives of image

$$I_x = G_\sigma^x * I \quad I_y = G_\sigma^y * I$$

2. Compute products of derivatives at every pixel

$$I_{x2} = I_x . I_x \quad I_{y2} = I_y . I_y \quad I_{xy} = I_x . I_y$$

3. Compute the sums of the products of derivatives at each pixel

$$S_{x2} = G_{\sigma'} * I_{x2} \quad S_{y2} = G_{\sigma'} * I_{y2} \quad S_{xy} = G_{\sigma'} * I_{xy}$$

4. Define at each pixel (x, y) the matrix

$$H(x,y) = \begin{bmatrix} S_{x2}(x,y) & S_{xy}(x,y) \\ S_{xy}(x,y) & S_{y2}(x,y) \end{bmatrix}$$

5. Compute the response of the detector at each pixel

$$R = Det(H) - k(Trace(H))^2$$

6. Threshold on value of R. Compute nonmax suppression.

À la recherche de l'information visuelle : rappel

$$\mathbf{G_x} = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} * \mathbf{A} \quad \text{et} \quad \mathbf{G_y} = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} * \mathbf{A}$$

À la recherche de l'information visuelle

À la recherche de l’information visuelle : sac de mots

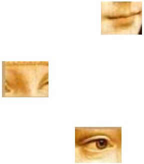

À la recherche de l'information visuelle : sac de mots

À la recherche de l’information visuelle : sac de mots

À la recherche de l'information visuelle : sac de mots

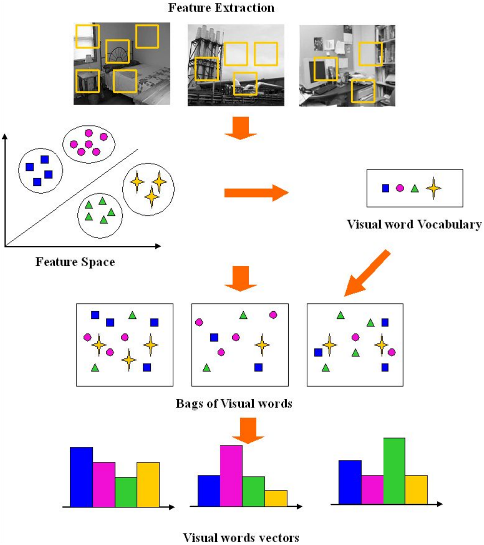

À la recherche de l'information visuelle : sac de mots

Phase1

Images ⟶ Mot**s** ⟶ Dictionnaire

À la recherche de l'information visuelle : sac de mots

Phase1

Images → Mot**s** → Dictionnaire

Phase2

Image → Mots → Histogramme

Classification

À la recherche de l'information visuelle : apprentissage profond

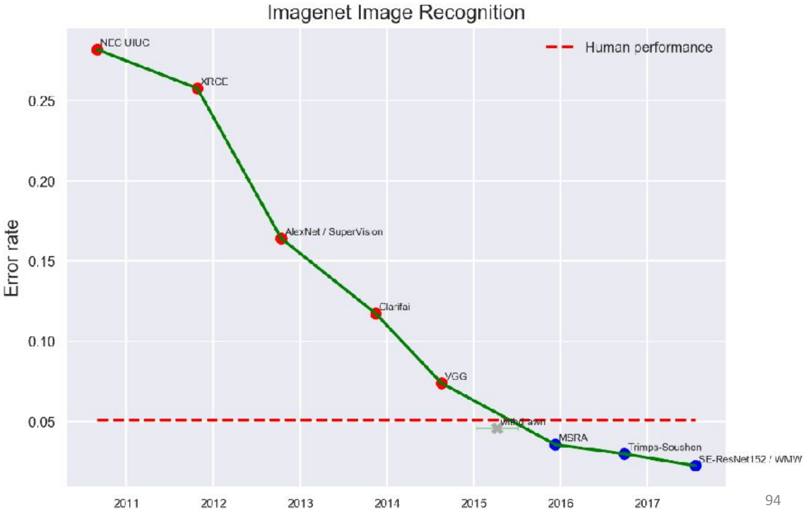

À la recherche de l'information visuelle : apprentissage profond

Image $\longrightarrow$ Classification

À la recherche de l'information visuelle : apprentissage profond

Image $\longrightarrow$ Classification

C'est le réseau qui trouve l'information visuelle et l'exploite en même temps

ConvNet : convolution

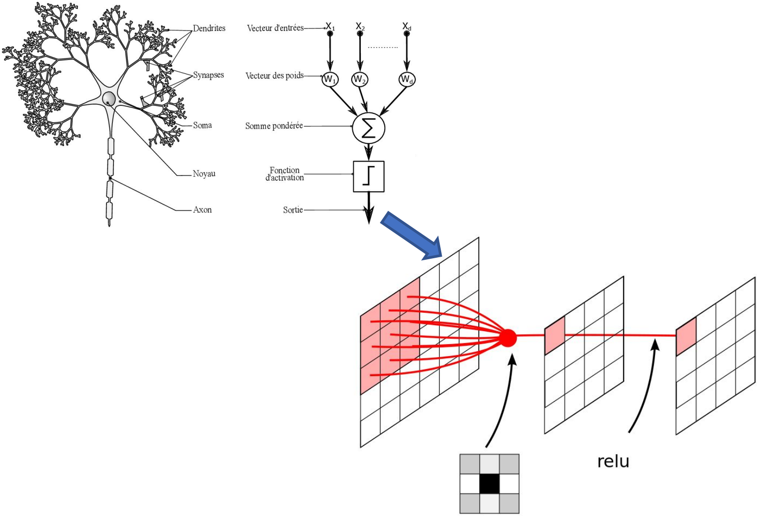

ConvNet

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

	1	
1	-4	1
	1	

4	3	2	1	-6
-5	0	0	0	-11
-10	0	0	0	-16
-15	0	0	0	-21
-46	-27	-28	-29	-56

$\longrightarrow$

4	3	2	1	0
0	0	0	0	0
0	0	0	0	0
0	0	0	0	0
0	0	0	0	0

ConvNet : pooling

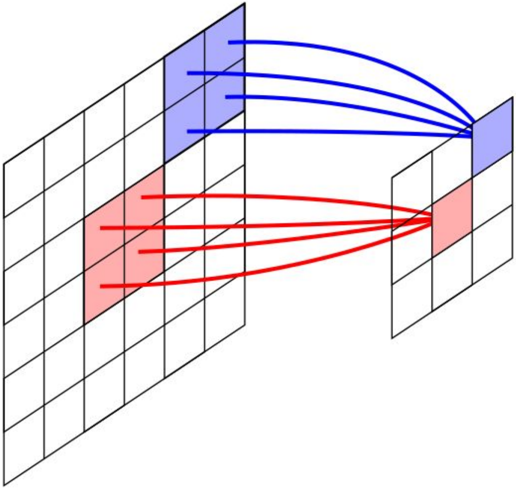

ConvNet

1	2	3	4
6	7	8	9
11	12	13	14
16	17	18	19

7	9
17	19

Attention : on oublie souvent la dimension spectrale

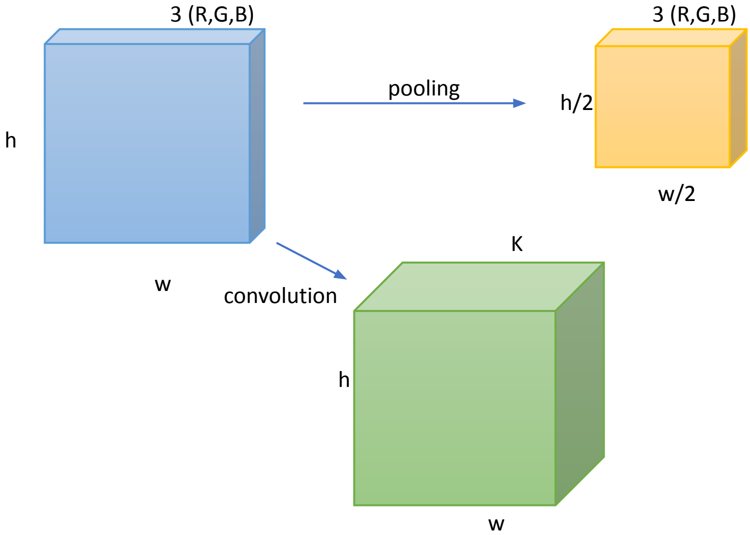

Attention, on manipule des paquets (donc 4D)

paquet

dimensions spatiales

$$x \in \mathbb{R}^{B \times C \times H \times W}$$

dimension spectrale

Lenet

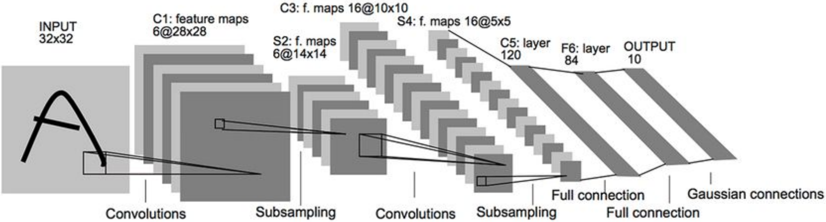

INPUT
32x32
C1: feature maps
6@28x28
S2: f. maps
6@14x14
C3: f. maps 16@10x10
S4: f. maps 16@5x5
C5: layer
120
F6: layer
84
OUTPUT
10
Convolutions
Subsampling
Convolutions
Subsampling
Full connection
Full connection
Gaussian connections

Alexnet et VGG

Resnet

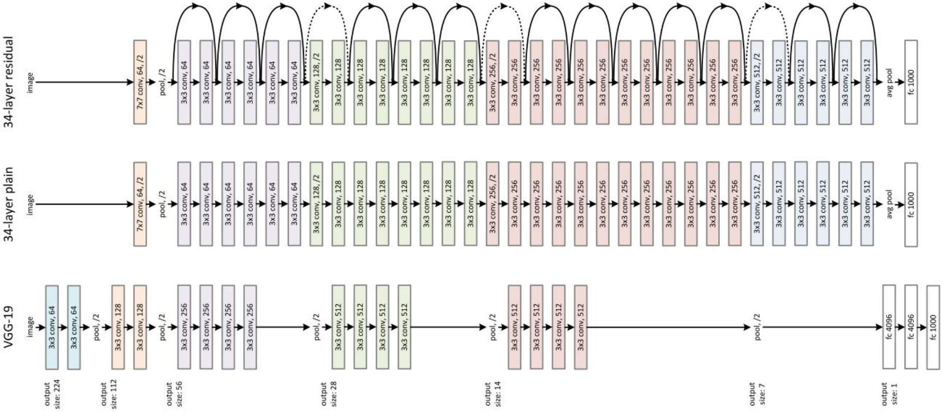
34-layer residual
image
7x7 conv, 64, /2
pool, /2
3x3 conv, 64
3x3 conv, 64
3x3 conv, 64
3x3 conv, 64
3x3 conv, 64
3x3 conv, 64
3x3 conv, 128, /2
3x3 conv, 128
3x3 conv, 128
3x3 conv, 128
3x3 conv, 128
3x3 conv, 128
3x3 conv, 128
3x3 conv, 128
3x3 conv, 256, /2
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 512, /2
3x3 conv, 512
3x3 conv, 512
3x3 conv, 512
3x3 conv, 512
3x3 conv, 512
avg pool
fc 1000
34-layer plain
image
7x7 conv, 64, /2
pool, /2
3x3 conv, 64
3x3 conv, 64
3x3 conv, 64
3x3 conv, 64
3x3 conv, 64
3x3 conv, 64
3x3 conv, 128, /2
3x3 conv, 128
3x3 conv, 128
3x3 conv, 128
3x3 conv, 128
3x3 conv, 128
3x3 conv, 128
3x3 conv, 128
3x3 conv, 256, /2
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 512, /2
3x3 conv, 512
3x3 conv, 512
3x3 conv, 512
3x3 conv, 512
3x3 conv, 512
avg pool
fc 1000
VGG-19
image
3x3 conv, 64
3x3 conv, 64
pool, /2
3x3 conv, 128
3x3 conv, 128
pool, /2
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
3x3 conv, 256
pool, /2
3x3 conv, 512
3x3 conv, 512
3x3 conv, 512
3x3 conv, 512
pool, /2
3x3 conv, 512
3x3 conv, 512
3x3 conv, 512
3x3 conv, 512
pool, /2
fc 4096
fc 4096
fc 1000
output size: 224
output size: 112
output size: 56
output size: 28
output size: 14
output size: 7
output size: 1

Resnet

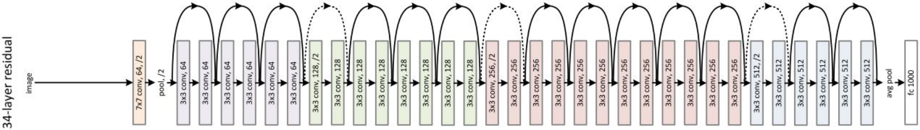

$$BN(x) = \frac{x - \left(\sum_b x_b\right)}{\sqrt{\sum_b \left(x_b - \left(\sum_{b'} x_{b'}\right)\right)^2 + 0.0000001}}$$

EfficientNet, ConvNext

https://pytorch.org/vision/stable/models.html

EfficientNet, ConvNext

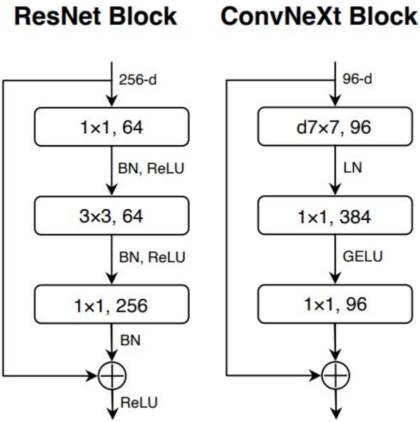

EfficientNet, ConvNext

https://pytorch.org/vision/stable/models.html

PLAN

- COURS 1
  - MLP
  - Double descente ?
  - Apprentissage
- Cours 2
  - Pytorch
  - CNN
  - **Transformer et perspective**

Transformer

Si $H = h_1, \dots, h_R$ sont *R* vecteurs de dimension *D*, la self attention s'exprime comme

$$\mathrm{S}(H) = softmax\left(\frac{(QH)(KH)^T}{\sqrt{L}}\right)(VH)$$

avec $\mathrm{Q}, \mathrm{K} \in \mathbb{R}^{L \times D}$

Transformer

Si $H = h_1, \dots, h_R$ sont *R* vecteurs de dimension *D*, la self attention s'exprime comme

$$\mathrm{S}(H) = softmax\left(\frac{(QH)(KH)^T}{\sqrt{L}}\right)(VH)$$

avec $\quad \mathrm{Q}, \mathrm{K} \in \mathbb{R}^{L \times D}$

⇒ Le nombre de poids ne dépend pas de *R* !

Visual transformer

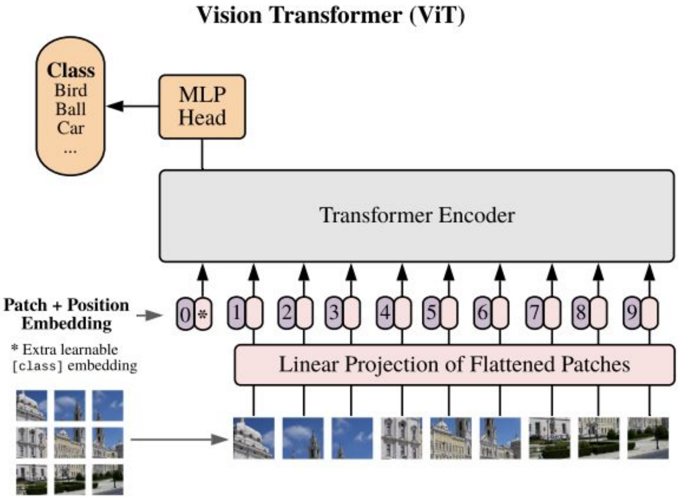

ViT vs ConvNet

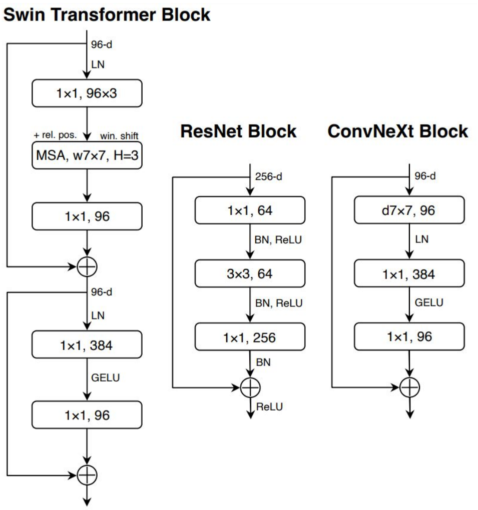

ViT vs ConvNet

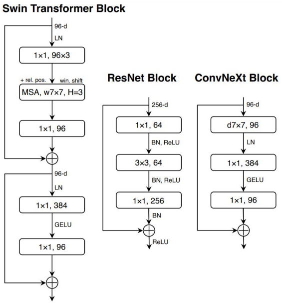

$$S(H) = softmax\left(\frac{(QH)(KH)^T}{\sqrt{L}}\right)(VH)$$

Augmenter brutalement la taille n'apporte pas tant que cela sur des architectures convolutives, alors que l'augmentation de performance semble constante avec des architectures Transformer !

L’état de l’art de la vision par ordinateur

https://pytorch.org/vision/stable/models.html

Performance vs tailles-données-modèles

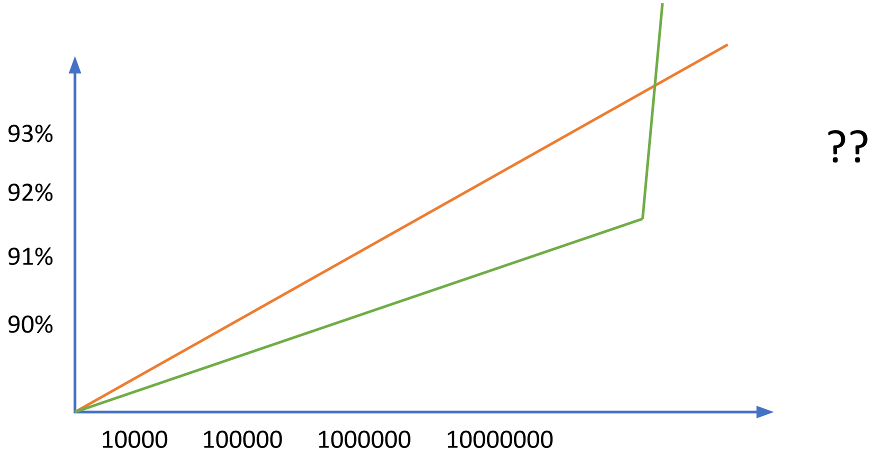

Fondation models

EfficientNet

100 Mo

SAM (Segment Everything by Meta)

2Go de poids

21Go pour faire un batch de 2 sur le petit modèle

LLAMA (un concurrent de chatGPT)

128 Go de poids !!!!!!!!!!!!!!!!!!!!!!!!

8 x 32Go pour le faire tourner

200000€

Fondation models

Sam Scarpino
@svscarpino

"Most good ideas still come from academia." 💯💯💯

Prof @ylecun on the role of academia in AI and the importance of good ideas (even if you don't have access to 50k gpus for compute). Fireside chat @Northeastern with @Experiential_AI's @usamaf.

Traduire le Tweet

8:32 PM · 24 mai 2023 depuis Boston, MA · **25,5 k** vues

Fondation models

- Lenet	AT&T
- Alexnet	toronto / google
- VGG	Oxford
- Resnet	Microsoft
- Gpipe	Google
- Efficientnet	Google
- ViT	Google
- SWIM	Microsoft
- ConvNext	Meta

Sam Scarpino
@svscarpino

"Most good ideas still come from academia." 💯💯💯

Prof @ylecun on the role of academia in AI and the importance of good ideas (even if you don't have access to 50k gpus for compute). Fireside chat @Northeastern with @Experiential_AI's @usamaf.

Traduire le Tweet

8:32 PM · 24 mai 2023 depuis Boston, MA · **25,5 k** vues

Perspectives

Il existe de très bon modèles convolutifs (EfficientNet, ConvNext) mais leurs performances saturent

L'utilisation de couche Transformer est autant prometteuse que couteuse !

Le passage à l'échelle ne se fera pas dans les labos, car les ordres de grandeur mis en jeux ont explosé !

Merci pour votre attention