



APPRENTISSAGE MACHINE & DEEP LEARNING

Deep Learning

A. Boulch, A. Chan Hon Tong, S. Herbin, B. Le Saux




retour sur innovation

Deep Learning

- Réseaux de neurones convolutifs
- Principales difficultés
- Deep learning
 - Couches de régularisation
 - Initialisation
 - Optimiseurs
 - Les données
- Réseaux et applications

Réseaux de neurones





Created by erogol



Réseaux de neurones



Données



Espace
adapté




Objectif

Caractéristiques
bien pensées

Apprentissage
Expertise

Réseaux de neurones



Created by erogol

Deep learning 90's → 2005


- Mise en place des premiers réseaux convolutifs



Données

Réseaux de neurones profonds

Recherche sur les architectures, les stratégies, la mise en forme des données



Objectif


Fully connected

Perceptron

(présentation précédente)

Un neurone est connecté à toutes les entrées

Si dimension d'entrée grande,
beaucoup de paramètres

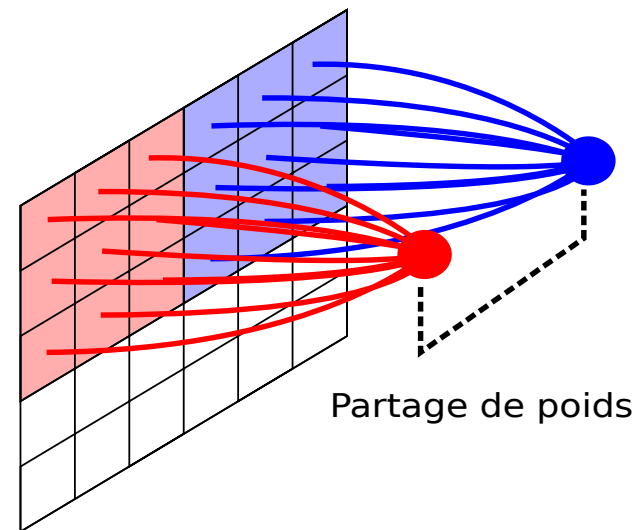
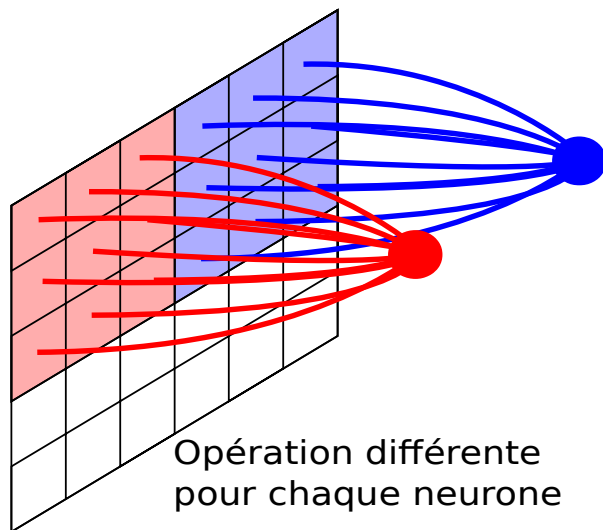


Fully connected


- MLP de plus en plus profonds (avant 2005)
 - Très grosses difficultés d'optimisation
 - Convergence difficile
 - Peu de données
 - Entraînement très long
- ⇒ Abandon progressif au profit des SVMs
 - Simples à utiliser
 - Preuves de convergence
 - Rapides

Réseaux convolutifs

Adapté aux données structurées



Convolution



Forward

$$x_{i,j}^l = \sum_a \sum_b \omega_{a,b} y_{i+a,j+b}^{l-1}$$

$$y_{i,j}^l = \sigma(x_{i,j}^l)$$

Convolution

Backward, « Delta rule » → mise à jour des poids de la convolution :

$$\frac{\partial E}{\partial \omega_{a,b}} = \sum_i \sum_j \frac{\partial E}{\partial x_{i,j}^l} \frac{\partial x_{i,j}^l}{\partial \omega_{a,b}} = \sum_i \sum_j \frac{\partial E}{\partial x_{i,j}^l} y_{i,j}^{l-1}$$

or

$$\frac{\partial E}{\partial x_{i,j}^l} = \frac{\partial E}{\partial y_{i,j}^l} \frac{\partial y_{i,j}^l}{\partial x_{i,j}^l} = \frac{\partial E}{\partial y_{i,j}^l} \sigma'(x_{i,j}^l)$$


$$\frac{\partial E}{\partial \omega_{a,b}} = \sum_i \sum_j \frac{\partial E}{\partial y_{i,j}^l} \sigma'(x_{i,j}^l) y_{i,j}^{l-1}$$

Convolution

Backward, « Chain rule » → erreur

$$\begin{aligned} \frac{\partial E}{\partial y_{i,j}^{l-1}} &= \sum_a \sum_b \frac{\partial E}{\partial x_{i-a,j-b}^l} \frac{\partial x_{i-a,j-b}^l}{\partial y_{i,j}^{l-1}} \\ &= \sum_a \sum_b \frac{\partial E}{\partial x_{i-a,j-b}^l} \omega_{a,b} \end{aligned}$$

Couches : convolution




Filtres de Gabor

Exemple poids appris
par la première couche
de convolution
d'AlexNet




Couches : Pooling

- Réduction de dimension
- Invariabilité en translation
- Mise en correspondance des pixels voisins
 - Réduction de la profondeur




Couches : Max Pooling



Forward

Transmission du maximum sur une fenêtre donnée



Backward

Transmission du gradient au maximum identifié, gradient nul sinon

LeNet

