Introduction aux réseaux de neurones

2017-2018

Introduction aux réseaux de neurones

http://www.grappa.univ-lille3.fr/~gilleron/PolyApp/node15.html

- Van Leeuwenhoek (1718) : première description fidèle des axones.
- Dutrochet (1824) : observation du corps cellulaire des neurones.
- Valentin (1836) : découverte des dendrites.
- Deiters (1865) : image actuelle de la cellule nerveuse.
- Sherrington (1897) : synapses.
- 1900--1950 : neurotransmetteurs.

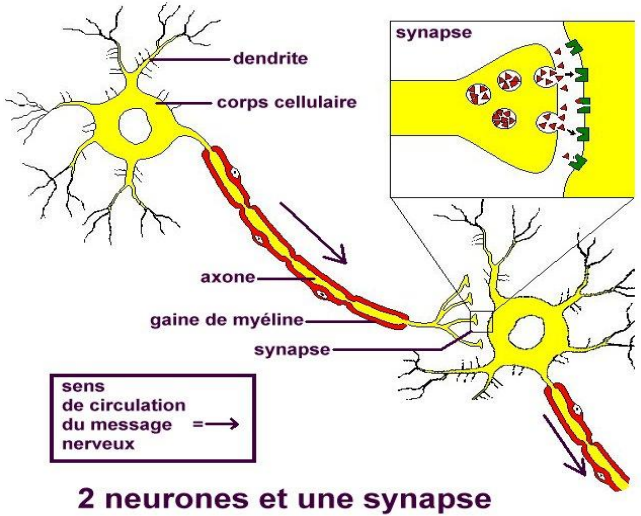

2 neurones et une synapse

Propriétés des neurones humains

Neurones humains

- Un cerveau contient 100 milliards de neurones.
- Seulement quelques dizaines de catégories distinctes.
- Aucune catégorie de neurones n'est propre à l'homme.
- Propagation de l'influx nerveux de l'ordre de 100m/s (très inférieur à la vitesse dans un circuit électronique= ⅔ vitesse lumière).
- Plusieurs dizaines de milliers de contacts synaptiques au maximum par neurone.
- Nombre total de connexions d'environ 10^{15}.
- La connectique du cerveau est impossible à coder dans une structure biologique (ADN) pour des raisons de combinatoire.
- Il nécessite donc une phase d'apprentissage (contacts avec l'environnement).

Historique des neurones formels

Neurones formels

- 1943 : première définition par McCulloch et Pitts.
- 1949 : association de 2 neurones en entrée d'un troisième par Hebb (associationnisme).
- 1958 : perceptron de Rosenblatt, ajout d'un processus d'apprentissage.
- 1969 : critique dans *Perceptrons: an introduction to computational geometry* (Minsky(1927-2016) et Papert(1928-2016)), sonne le glas des RN jusqu'en 1980.
- 1970--1980 : RAS.

Historique des neurones formels

- 1980 : réseaux multi-couches et rétropropagation du gradient par Rumelhart et McClelland, Parker, Hinton, Le Cun.
- 1982 : réseaux complètement connectés par Hopfield (attracteurs, mémoires associatives).
- 1984: cartes de Kohonen avec algorithme non supervisé basé sur l'auto organisation.
- 1985 : machines de Boltzmann, utilisant Monte--Carlo.
- 1985--2015: RAS.
- 2015 : deep learning (Facebook, Google) avec des réseaux de convolutions à très grand nombre de couches, distribués sur des clusters de calcul.
- 2016 : annonce de traducteurs automatiques comparables à la traduction humaine GNMT.

Alphago Deepmind

- 2016 : AlphaGo bat 4-1 le champion de Go Lee Sedol classé au niveau maximal (9e dan professionnel).

- 2017 : AlphaGo bat 3-0 le champion de Go Ke Jie.

- 2017 : AlphaGo Zero bat la version précédente 100-0 sans accès à des parties jouées par des humains.

  AlphaGo Zero: learning from scratch

Perceptron

Perceptron (Rosenblatt 1958) :
Un perceptron linéaire à seuil prend en entrée p valeurs $x_1,\ldots,x_p$ et calcule une sortie o.
Il est défini via p constantes : les coefficients synaptiques $w_1,\ldots,w_p$ et un seuil (ou biais) q.
Sa valeur est calculée par la formule :

$$o = 1 \text{ si } \sum_{1}^{p} w_i x_i > q$$

$$o = 0 \text{ sinon}$$

Perceptron

Perceptron (Rosenblatt 1958) :

On préférera :

$$o = 1 \text{ si } \sum_{0}^{p} w_i x_i > 0 \text{ avec } w_0 = -q \text{ et } x_0 = 1$$

Il s'agit donc d'une fonction linéaire affine, qui nous permet de ne pas avoir à traiter le biais (q) comme un cas particulier.

Perceptron pour la fonction OR

Soit le réseau suivant :

$$w_0 = -0.5, w_1 = 1, w_2 = 1$$

Exercice :
Dessiner le réseau ci--dessus.
Vérifier qu'il correspond bien au OR (avec F=0 et V=1)

Interprétation géométrique

$$y = -x + 0.5$$

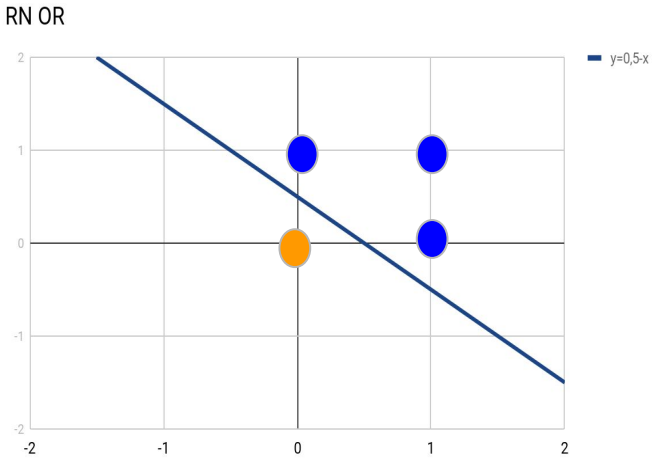

Théorème : L'ensemble des données est linéairement séparable dans R^n ssi cet ensemble est discriminable via un perceptron.

Corollaire : Le XOR ne peut pas être calculé par un perceptron.

Apprentissage des réseaux de neurones

Algorithme par correction d'erreur

```
initialisation des poids (par exemple aléatoire)
repeter jusque critère d'arrêt (convergence ou nb iter)
    sélectionner un exemple (x,c)
    calculer o pour x
    pour i de 0 a p
        wi := wi + (c-o)xi
    fpour
frepeter
```

Propriétés des réseaux de neurones à une couche

- **Correction** : convergence garantie en temps fini

- **Inapplicable** : si l'ensemble d'apprentissage est non linéairement séparable (pas de détection de la non convergence).
- **Robustesse** : non garantie même en cas de convergence.
  - l'hyperplan de séparation peut être très proche d'un des exemples.
  - un nouvel exemple ou une variation minime d'un exemple existant peut remettre en cause l'apprentissage.

Descente du gradient

Algorithme descente du gradient :

```
initialisation des poids
repeter
    pour i de 0 a p
        Dwi := 0
    fpour
    pour tout exemple (x,c)
        calculer o pour x
        pour i de 0 a p
            Dwi := Dwi + e(c-o)xi
        fpour
    fpour
    pour i de 0 a p
        wi := wi + Dwi
    fpour
frepeter
```

Intérêt : permet de résoudre le problème de la robustesse.

Algorithme Adaline (gradient stochastique)

Algorithme Adaline (ajustement adaptatif des poids) :

```
initialisation des poids
repeter
    selectionner un exemple (x,c)
    calculer o pour x
    pour i de 1 a p
        wi := wi + e(c-o)xi
        fpour
    fpour
frepeter
```

Problème : on ne règle pas le problème des ensembles non linéairement séparables.

Solution : rajouter des couches de neurones.

Réseaux de neurones multi-couches

Exemple : XOR (1 couche cachée de 4 neurones => 3+4+1=8 neurones)

couche d'entrée (x_0, x_1, x_2), couche cachée (x_3, x_4, x_5, x_6), couche sortie (x_7)

$w_{13} = 1$ $w_{14} = -1.5$ $w_{24} = 1$ $w_{25} = 1$ $w_{04} = 1$ $w_{06} = 1$ $w_{37} = -0.5$ $w_{47} = -2$ $w_{57} = 1$ $w_{67} = 1.5$

Exercice : Dessiner le réseau ci--dessus avec (biais $x_0 = 1$).

Vérifier qu'il correspond bien au XOR (toujours avec F=0 et V=1).

Propriétés des réseaux multicouches

- Cellules réparties en q couches (entrée couche $k+1$= sortie couche k , sauf pour k=0 et k=q).
- Toute fonction booléenne peut être calculée par un réseau de neurones à une couche cachée.
- Nouveau problème : au 2^p maximum neurones dans la couche cachée.
- Deux nouvelles questions se posent :
  - Comment choisir l'architecture (nombre et tailles des couches cachées) : pas de solution garantie en 2017.
  - Quel algorithme d'apprentissage choisir : rétropropagation du gradient depuis 1980 (backpropagation)

Rétropropagation du gradient

Algorithme de rétropropagation du gradient :

```
initialisation des poids
repeter
    selectionner un exemple (x,c)
    calculer o pour x
    pour toute cellule i de sortie
        di := oi(1-oi)(ci-oi)
    fpour
    pour chaque couche de q-1 a 1
        pour toute cellule i de la couche courante
            di := oi(1-oi)*somme(dk*wik) avec k=succ(i)
        fpour
    fpour
    pour tout poid wij
        wij := wij + eps*di*xij
    fpour
frepeter
```

Problème : trouver les valeurs de eps (learning rate)

Retropropagation du gradient avec momentum

Algorithme de rétropropagation du gradient avec momentum :

- pondération de la mise à jour des poids en fonction du nombre d'itérations déjà effectuées.
- limitation des oscillations liées aux optimums locaux.
- amélioration de la vitesse de convergence.

Problème : trouver les valeurs de eps et alpha

```
initialisation des poids
repeter
    selectionner un exemple (x,c)
    calculer o pour x
    pour toute cellule i de sortie
        di := oi(1-oi)(ci-oi)
    fpour
    pour chaque couche de q-1 a 1
        pour toute cellule i de la couche courante
            di := oi(1-oi)*somme(dk*wik) avec k=succ(i)
        fpour
    fpour
    pour tout poid wij
        wij := wij + Dwij(t) avec Dwij(t)=eps*di*xij+alpha*Dwij(t-1)
    fpour
frepeter
```

Bibliographie

Yann LE CUN

profil quora

cours au Collège de France

MOOC de Geoff HINTON

Jeremy KUN

The perceptron and all the things it can’t perceive

Neural networks and the backpropagation algorithm

Bibliographie

Neural networks par 3blue1brown (série en cours)

Neural networks demystified par Welch Labs

How to create a mind par Ray KURZWEIL

TED

Ken JENNINGS: Watson, Jeopardy and me,the obsolete know-it-all

Sebastian SEUNG: I am my connectome

Fei-Fei LI

Garry KASPAROV

Ray KURZWEIL

Bibliographie

playground.tensorflow.org

Science Étonnante