


Réseaux de neurones : expressivité et espaces implicites


Plan

$$g(\vec{w} \cdot \vec{x} + b)$$




Introduction

$$\sum_{i=1}^k \beta_i g(A_i(\vec{x}))$$




Densité

$$g(K(\vec{w}, \vec{x}) + b)$$



Dualité


Neurone



Fonction associée

$$\begin{array}{ccccc} \mathbb{R}^L & \rightarrow & \mathbb{R}^L & \rightarrow & \mathbb{R} \\ w & \mapsto & e & \mapsto & \mathbb{R} \end{array}$$

Apprentissage - Descente de gradient




Apprendre $f : \mathbb{R}^L \rightarrow \mathbb{R}$.

$$Err(e, w) = \frac{1}{2}(S(e, w) - f(e))^2$$


$$w_i \mapsto w_i - \eta \frac{\partial Err}{\partial w_i}$$

$$w \mapsto w - \eta \overrightarrow{\text{grad}}_w Err$$

Biais



Biais




Fonction d'activation


$$g : \mathbb{R} \rightarrow \mathbb{R}.$$

$$N(w, b) : e \mapsto g \left(\sum_i w_i e_i + b \right)$$


Ex :



Exemple - Terre et Mer



Couche intermédiaire



$\Sigma^d(g)$

$g \in \mathcal{C}^0(\mathbb{R})$ et $d \in \mathbb{N}^*$.

\mathbb{A}^d ensemble des fonctions affines de \mathbb{R}^d dans \mathbb{R} .


On note

$$\Sigma^d(g) = \left\{ f : \mathbb{R}^d \rightarrow \mathbb{R} \mid \exists q \in \mathbb{N}^* \forall i \in \llbracket 1, q \rrbracket \exists (\beta_i, A_i) \in \mathbb{R} \times \mathbb{A}^d, \right. \\ \left. \forall x \in \mathbb{R}^d f(x) = \sum_{i=1}^q \beta_i g(A_i(x)) \right\}.$$

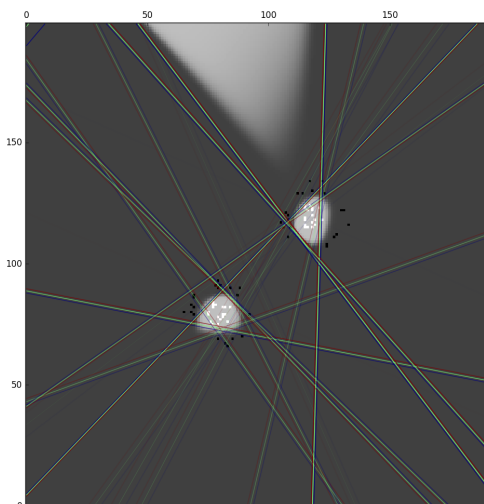
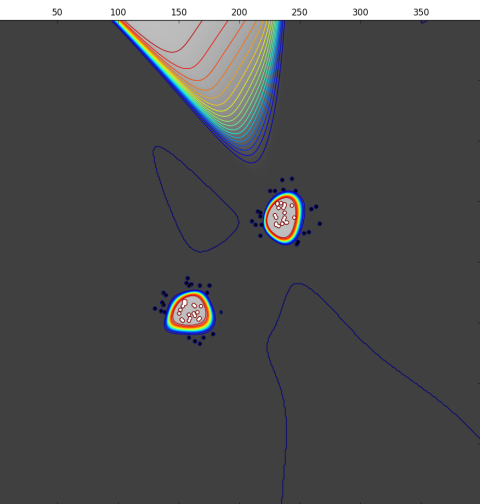
Couches intermédiaires

- ▶ Rétropropagation
- ▶ Non-linéarité des fonctions d'activation


Exemple - Îles



Exemple - Au cœur du réseau



Exemple - Reconnaissance d'images




60000 exemples dans la base d'entraînement.

10000 exemples dans la base de test.

$$\mathbb{R}^{28 \cdot 28} = \mathbb{R}^{784} \rightarrow \mathbb{R}^{10} \rightarrow \llbracket 0, 9 \rrbracket$$

Exemple - Poids

- ▶ Environ 10^6 itérations
- ▶ Erreur sur la base d'apprentissage : 1.13%
- ▶ Erreur sur la base de test : 2.28%
- ▶ Activations : tanh, sigmoïde.
- ▶ 200 neurones intermédiaires :



Énoncé

Théorème (Stone-Weierstrass)

K espace compact

A sous-algèbre de $\mathcal{C}(K, \mathbb{R})$ telle que :

- ▶ $\forall x, y \in K \exists f \in A, f(x) \neq f(y)$
- ▶ $\forall x \in K \exists f \in A, f(x) \neq 0$

Alors, au sens de la convergence uniforme,

$$\overline{A} = \mathcal{C}(K, \mathbb{R}).$$

Fonctions saturantes

On appelle *fonction saturante* toute fonction $\psi : \mathbb{R} \rightarrow \mathbb{R}$ continue et croissante telle que $\lim_{x \rightarrow -\infty} \psi(x) = 0$ et $\lim_{x \rightarrow +\infty} \psi(x) = 1$.

$$\Sigma_{|K}^d(g)$$

Définition

$K \subset \mathbb{R}^d$, g continue. $\Sigma_{|K}^d(g) = \left\{ f|_K \mid f \in \Sigma_{|K}^d(g) \right\}$

Théorème

$K \subset \mathbb{R}^d$ compact, ψ saturante.

Alors, au sens de la convergence uniforme,

$$\overline{\Sigma_{|K}^d(\psi)} = \mathcal{C}(K, \mathbb{R}).$$

$\Sigma\Pi^d(g)$

Définition

$g \in \mathcal{C}^0(\mathbb{R})$ et $d \in \mathbb{N}^*$. On note

$$\Sigma\Pi^d(g) = \left\{ f : \mathbb{R}^d \rightarrow \mathbb{R} \mid \exists q \in \mathbb{N}^* \forall i \in [1, q] \exists (\beta_i, l_i) \in \mathbb{R} \times \mathbb{N}^* \right. \\ \left. \forall k \in [1, l_i] \exists A_{i,k} \in \mathbb{A}^d, \forall x \in \mathbb{R}^d f(x) = \sum_{i=1}^q \prod_{k=1}^{l_i} \beta_{i,k} g(A_{i,k}(x)) \right\}.$$

Définition

$K \subset \mathbb{R}^d$, g continue. $\Sigma\Pi^d|_K(g) = \left\{ f|_K \mid f \in \Sigma\Pi^d(g) \right\}$

$\Sigma\Pi^d(g)$

Théorème

$g \in \mathcal{C}^0(\mathbb{R})$ non constante, $d \in \mathbb{N}^*$, $K \subset \mathbb{R}^d$ compact.

Alors, au sens de la convergence uniforme,

$$\overline{\Sigma\Pi^d|_K(g)} = \mathcal{C}(K, \mathbb{R}).$$

Réduction (1)

Lemme

$f, g \in \mathcal{C}^0(\mathbb{R}), d \in \mathbb{N}^*$.

Si $g \in \Sigma^1(f)$, alors

$$\Sigma^d(g) \subset \Sigma^d(f).$$

Lemme

$f, g \in \mathcal{C}^0(\mathbb{R}), d \in \mathbb{N}^*$.

Si $\forall M > 0, g_{|[-M,M]} \in \overline{\Sigma^1_{|[-M,M]}(f)}$,

alors pour tout compact $K \subset \mathbb{R}^d$,

$$\Sigma^d_{|K}(g) \subset \overline{\Sigma^d_{|K}(f)}$$

Réduction (2)

Proposition

ψ, φ des fonctions saturantes.

$$\varphi \in \overline{\Sigma^1(\psi)}.$$

Proposition

La fonction suivante est saturante :

$$\varphi : x \mapsto \begin{cases} 0 & \text{si } x < -\pi/2 \\ \frac{1+\cos(x)}{2} & \text{si } -\pi/2 \leq x < \pi/2 \\ 1 & \text{si } \pi/2 \leq x. \end{cases}$$

De plus, $\forall M > 0, \cos|_{[-M, M]} \in \Sigma^1_{[-M, M]}(\varphi)$.

Réduction (3)

$K \subset \mathbb{R}^d$ compact. ψ saturante.

Proposition

$$\Sigma_{|K}^d(\cos) \subset \overline{\Sigma_{|K}^d(\psi)}.$$

On en déduit que

$$\mathcal{C}(K, \mathbb{R}) = \overline{\Sigma \Pi_{|K}^d(\cos)} = \overline{\Sigma_{|K}^d(\cos)} \subset \overline{\Sigma_{|K}^d(\psi)} \subset \mathcal{C}(K, \mathbb{R}).$$

Nouvelles fonctions d'agrégation


$$\vec{w} \cdot \vec{x} + b \longrightarrow K(\vec{w}, \vec{x}) + b$$

Ex :

$$\begin{pmatrix} x \\ y \end{pmatrix} \mapsto \begin{pmatrix} x \\ y \\ x^2 + y^2 \end{pmatrix}$$

On a alors accès aux

$$f : \begin{pmatrix} x \\ y \\ z \end{pmatrix} \mapsto ax + by + (a^2 + b^2)z$$



Espaces de Hilbert (réels)

$(H, \langle \cdot, \cdot \rangle)$ préhilbertien réel, complet $[\langle \cdot, \cdot \rangle]$.

Exemples :

▶ \mathbb{R}^d

▶ $\ell_{\mathbb{R}}^2 = \{u \in \mathbb{R}^{\mathbb{N}} \mid \sum_{n=0}^{+\infty} u_n^2 < +\infty\},$

$$\langle u, v \rangle = \sum_{n=0}^{+\infty} u_n v_n$$

▶ $H_{\mathbb{R}}^1 = \{u \in \mathbb{R}^{\mathbb{N}} \mid u_0^2 + \sum_{n=1}^{+\infty} n^2 u_n^2 < +\infty\},$

$$\langle u, v \rangle = u_0 v_0 + \sum_{n=1}^{+\infty} n^2 u_n v_n$$

Sous-ev fermés : Projection, orthogonal

H espace de Hilbert, F sev fermé de H .

Il existe $P_F : H \rightarrow F$ linéaire telle que

$$\forall x \in F, \|x - P_F(x)\| = d(x, F).$$

De plus, $x - P_F(x) \in F^\perp$.

Ainsi,

$$F \oplus F^\perp = H.$$

Représentation de Riesz

$(H, \langle \cdot, \cdot \rangle)$ espace de Hilbert réel.

$$H' = \{f \in \mathcal{L}(H, \mathbb{R}) \mid f \text{ continue}\}.$$

$$\forall f \in H', \exists ! \tilde{f}, \forall x \in H, f(x) = \langle \tilde{f}, x \rangle.$$

En effet,

$$\begin{aligned} \varphi : H &\rightarrow H' && \text{est un isomorphisme isométrique.} \\ y &\mapsto \langle y, \cdot \rangle \end{aligned}$$

Noyau reproduisant

X ensemble, $H \subset \mathbb{R}^X$ espace de Hilbert.

H est un *espace de Hilbert à noyau reproduisant* ssi l'évaluation en chaque point $x \in X$ est continue

$$\begin{aligned} L_x &: H \rightarrow \mathbb{R} \\ f &\mapsto f(x). \end{aligned}$$

Dans ce cas,

$$\forall x \in X, \exists ! K_x \in H, \forall f \in H, f(x) = \langle f, K_x \rangle.$$

On définit alors le *noyau reproduisant* de H

$$\begin{aligned} K &: X \times X \rightarrow \mathbb{R} \\ (x, y) &\mapsto K_x(y) = \langle K_x, K_y \rangle. \end{aligned}$$

Théorème de Moore-Aronszajn

Théorème

X ensemble, $K : X \times X \rightarrow \mathbb{R}$ noyau symétrique défini positif.

Alors, il existe un unique espace de Hilbert minimal $H \subset \mathbb{R}^X$ dont K est un noyau reproduisant.

Pour $x \in X$, $K_x = K(x, \cdot)$.

Préhilbertien H_0 , complété en H si nécessaire :

$$H_0 = \text{Vect}\{K_x | x \in X\}$$

$$\left\langle \sum_{i=1}^n a_i K_{x_i}, \sum_{j=1}^m b_j K_{y_j} \right\rangle_{H_0} = \sum_{i=1}^n \sum_{j=1}^m a_i b_j K(x_i, y_j)$$

Construction d'espace

$$H_0 = \text{Vect}\{K_x | x \in X\}$$

$$\left\langle \sum_{i=1}^n a_i K_{x_i}, \sum_{j=1}^m b_j K_{y_j} \right\rangle_{H_0} = \sum_{i=1}^n \sum_{j=1}^m a_i b_j K(x_i, y_j)$$

Les suites de Cauchy de H_0 convergent simplement.

$$H = \{f \in \mathbb{R}^X | \exists (f_n) \in H_0^{\mathbb{N}} \text{ de Cauchy, } f_n \xrightarrow{\text{CVS}} f\}$$

$$\langle f, g \rangle_H = \lim_{n \rightarrow +\infty} \langle f_n, g_n \rangle_{H_0} \text{ où } f_n \xrightarrow{\text{CVS}} f, g_n \xrightarrow{\text{CVS}} g, \text{ de Cauchy } \in H_0^{\mathbb{N}}$$