


Approximation par des réseaux à 1 couche cachée

Léonard GERCHINOVITZ

Plusieurs théorèmes s'intéressent à l'universalité des réseaux de neurones feedforward à 1 couche cachée, de la forme :

$$x \in \mathbb{R}^d \mapsto \sum_{i=1}^N v_i \sigma(w_i \cdot x + b_i) \quad (1)$$

où $v_i \in \mathbb{R}$, $w_i \in \mathbb{R}^d$ et $b_i \in \mathbb{R}$ et $\sigma: \mathbb{R} \rightarrow \mathbb{R}$ "fonction d'activation"



Nous allons étudier un des premiers théorèmes, dû à Cybenko (1989).

Théorème (Cybenko '89).

Soit $\sigma: \mathbb{R} \rightarrow \mathbb{R}$ une fonction continue et sigmoidale, i.e., $\begin{cases} \lim_{-\infty} \sigma = 0 \\ \lim_{+\infty} \sigma = 1. \end{cases}$

Alors l'ensemble \mathcal{N}_1 des fonctions de la forme

$$x \in [0,1]^d \mapsto \sum_{i=1}^N v_i \sigma(w_i \cdot x + b_i); v_i, b_i \in \mathbb{R}, w_i \in \mathbb{R}^d$$

est dense dans l'ensemble $C([0,1]^d, \mathbb{R})$ des fonctions réelles continues sur $[0,1]^d$ (muni de $\|f\|_\infty = \sup_{x \in [0,1]^d} |f(x)|$).

Le théorème signifie que :

- $\mathcal{P}_1 \subset \mathcal{C}([0,1]^d, \mathbb{R})$

- $\forall f \in \mathcal{C}([0,1]^d, \mathbb{R}), \forall \varepsilon > 0, \exists N \geq 1, v_i, b_i \in \mathbb{R}, w_i \in \mathbb{R}^d:$

$$\sup_{x \in [0,1]^d} \left| f(x) - \sum_{i=1}^N v_i \cdot \varphi(w_i, x) + b_i \right| \leq \varepsilon$$

La preuve procède par contradiction (c'est une preuve non constructive) :

- On suppose qu'il existe $f_0 \in \mathcal{C}([0,1]^d, \mathbb{R}) \setminus \overline{\mathcal{P}}$
- On invoque alors le théorème de Hahn-Banach pour construire une forme linéaire continue $L : \mathcal{C}([0,1]^d, \mathbb{R}) \rightarrow \mathbb{R}$ telle que $L(f_0) = 1$ et $L(f) = 0 \quad \forall f \in \mathcal{P}$.
- On utilise ensuite le théorème de représentation de Riesz-Markov : $\exists \mu$ mesure de Borel signée sur $[0,1]^d$:

$$L(f) = \int f \, d\mu \quad \forall f \in \mathcal{C}([0,1]^d, \mathbb{R}).$$

- On montre ensuite que $\mu \equiv 0$ nécessairement (via la transformée de Fourier de μ), d'où $L(f_0) = 0$ et donc une contradiction.

Rappelons d'abord les 2 thms d'analyse fonctionnelle utilisés. Toutes les définitions et propriétés énoncées dans les sections 1 et 2 sont valables lorsque le corps des scalaires est \mathbb{R} ou \mathbb{C} .

1/ Théorème(s) de Hahn-Banach

Gf. Walter Rudin, Functional Analysis (Chapter 3), 1973.
Il existe plusieurs théorèmes de Hahn-Banach. En voici 2 :

Théorème de Hahn-Banach (propriété de séparation) :

Laissez X un espace vectoriel topologique localement convexe*.

M un sous-espace de X .

$$x_0 \in X \setminus \overline{M}$$

Alors, il existe une forme linéaire continue $L : X \xrightarrow{\text{fond }} \mathbb{R} \cup \mathbb{C}$

telle que • $L(x_0) = 1$

• $\forall x \in M, L(x) = 0$.

* Tout espace vectoriel normé est un espace vectoriel topologique localement convexe.

Théorème de Hahn-Banach (extension d'une forme lin. cont.)

Laissez X un espace vectoriel topologique localement convexe*.

M un sous-espace de X

f une forme linéaire continue sur M (\hookrightarrow valeurs $\mathbb{R} \cup \mathbb{C}$ selon X)

Alors, il existe une forme linéaire continue

L sur X telle que $L(x) = f(x) \quad \forall x \in M$.

2/ Théorème de représentation de Riesz-Markov

Gf. Walter Rudin, Analyse réelle et complexe (chap 3 et 6), 1973.

a) Quelques brefs rappels : $\mathcal{C}_0(X)$ et mesures complexes.

Déf: Lit X un espace topologique séparé totalement compact.*
 $f: X \rightarrow \mathbb{C}$ ou \mathbb{R}

On dit que f s'annule à l'infinissi : $\forall \varepsilon > 0$,
 $\exists K$ compact de X tel que $|f(x)| \leq \varepsilon$ pour tout $x \in X \setminus K$.

* Exemple : partie compacte d'un espace vectoriel normé (e.g., $[0,1]^d$).

On note $\mathcal{C}_0(X)$ l'ensemble des fonctions continues sur X qui s'annulent à l'infini.

Lorsque X est séparé compact, $\mathcal{C}_0(X) = \mathcal{C}(X)$.

Déf: Lit (X, \mathcal{M}) un espace mesurable.

- Une mesure complexe μ sur \mathcal{M} est une fonction $\mu: \mathcal{M} \rightarrow \mathbb{C}$ telle que : $\mu(E) = \sum_{i=1}^{+\infty} \mu(E_i)$ (convergence abs. dans \mathbb{C}) pour tout $E \in \mathcal{M}$ et toute partition mesurable $(E_i)_{i \geq 1}$ de E .
- mesure signée = idem mais avec $\mu: \mathcal{M} \rightarrow \mathbb{R}$

- La mesure de variation totale $|\mu|$ est définie par
 $|\mu|(E) := \sup \sum_{i=1}^{+\infty} |\mu(E_{i,i})| \geq |\mu(E)|, \quad E \in \mathcal{M},$
 où le sup est pris sur toutes les partitions mesurables de E .

Propriétés (valables pour μ mesure complexe ou signée)

- $|\mu|$ est une mesure positive sur \mathcal{M} et est toujours de masse finie : $|\mu|(X) < +\infty$.
- $\exists h: X \rightarrow \mathbb{C}$ ou \mathbb{R} mesurable telle que $|h(x)| = 1 \quad \forall x \in X$ et $d\mu = h d|\mu|$, i.e., $\forall E \in \mathcal{M}, \mu(E) = \int_E h d|\mu|$.
 On définit alors :

$$\forall f \in L^1(|\mu|), \int f d\mu := \int f h d|\mu|$$

NB : $h(x) = \pm 1$
 si μ signée.

b) Théorème de représentation de Riesz-Markov

Plusieurs théorèmes de représentation de Riesz. Le suivant est parfois appelé "théorème de Riesz-Markov".

Théorème de représentation de Riesz (version pour $\mathcal{G}(X)$) :

Soit X un espace topologique séparé localement compact.
 Soit L une forme linéaire continue sur $(\mathcal{G}(X), \|\cdot\|_\infty)$ $\xleftarrow{\text{salaires}} = \text{Rout}$

Alors, il existe une unique mesure de Borel complexe/signée et régulière μ qui représente L , au sens où :

$$\forall f \in \mathcal{G}(X), \quad L(f) = \int f d\mu.$$

De plus, $\|L\| := \sup_{\|f\|_\infty \leq 1} |L(f)|$ vérifie $\|L\| = \underbrace{|\mu|(X)}_{\text{"variation totale de } \mu\text{"}}$.

3/ Preuve du théorème d'approximation de Cybenko [P].

On a $\mathcal{P}_1 \subset \mathcal{G}([0,1]^d, \mathbb{R})$ or τ est continue.

- Supposons un instant que $\overline{\mathcal{P}}_1 \neq \mathcal{G}([0,1]^d, \mathbb{R})$ et fixons $f_0 \in \mathcal{G}([0,1]^d, \mathbb{R}) \setminus \overline{\mathcal{P}}_1$.
- Appliquons le théorème de Hahn-Banach (version "réparation") à l'espace vectoriel normé $X = \mathcal{G}([0,1]^d, \mathbb{R})$ muni de $\|\cdot\|_\infty$ et au sous-espace \mathcal{P}_1 : on peut fixer une forme linéaire continue $L : \mathcal{G}([0,1]^d, \mathbb{R}) \rightarrow \mathbb{R}$ tq $L(f_0) = 1$ mais $L \equiv 0$ sur \mathcal{P}_1 .
- Or, d'après le théorème de représentation de Riesz pour $\mathcal{G}([0,1]^d, \mathbb{R}) = \mathcal{G}([0,1]^d, \mathbb{R})$, il existe une mesure de Borel séparée et compacte signée μ sur $[0,1]^d$ telle que :

$$\forall f \in \mathcal{G}([0,1]^d, \mathbb{R}), \quad L(f) = \int f \, d\mu \quad (2)$$

- Montrons que $\mu \equiv 0$, et donc $L(f_0) = 0$, d'où une contradiction.

Puisque L est nulle sur \mathcal{P}_1 et $x \mapsto \tau(\langle w, x \rangle + b) \in \mathcal{P}_1$, on a :

$$\forall w \in \mathbb{R}^d, \forall b \in \mathbb{R}, \int_{[0,1]^d} \sigma(\langle w, x \rangle + b) d\mu(x) = 0 \quad (3)$$

or continue et sigmoidale

Nous allons montrer que puisque σ est bornée et sigmoidale, la seule mesure de Borel signée vérifiant (3) est la mesure nulle. (On dit dans ce cas que σ est "discriminante".)

Fixe $w \in \mathbb{R}^d$ et $b, \lambda, \varphi \in \mathbb{R}$. Pour tout $x \in \mathbb{R}^d$,

$$\sigma_\lambda(x) := \sigma\left(\lambda(\langle w, x \rangle + b) + \varphi\right) \xrightarrow{\lambda \rightarrow +\infty} \gamma(x) := \begin{cases} 1 & \text{si } \langle w, x \rangle + b > 0 \\ 0 & \text{si } \langle w, x \rangle + b \leq 0 \\ \sigma(\varphi) & \text{si } \langle w, x \rangle + b = 0 \end{cases}$$

D'où, par convergence dominée (car σ est bornée, $d\mu = h d\mu$) avec $|h| = 1$, et $|h|$ est de masse finie :

$$0 = \int_{[0,1]^d} \sigma_\lambda(x) d\mu(x) \xrightarrow{\lambda \rightarrow +\infty} \int_{[0,1]^d} \gamma(x) d\mu(x) = \sigma(\varphi) \mu(\Pi_{w,b}) + \mu(H_{w,b})$$

$$\text{où } \Pi_{w,b} := \{x \in [0,1]^d : \langle w, x \rangle + b = 0\}$$

$$H_{w,b} := \{x \in [0,1]^d : \langle w, x \rangle + b > 0\}$$

On a donc montré :

$$\forall w \in \mathbb{R}^d, \forall b \in \mathbb{R}, \forall \varphi \in \mathbb{R}, \sigma(\varphi) \mu(\Pi_{w,b}) + \mu(H_{w,b}) = 0$$

Puisque σ est non-constante (ou sigmoidale), on a donc :

$$\forall w \in \mathbb{R}^d, \forall b \in \mathbb{R}, \mu(\Pi_{w,b}) = \mu(H_{w,b}) = 0.$$

Le fait que μ soit une mesure signée (pas nécessairement positive) ne permet pas tout de suite de conclure que $\mu \equiv 0$ (du moins, ce n'est pas évident à ce stade). [faire en dimension $d=1$ via un argument de classe monotone]

Soit $w \in \mathbb{R}^d$. Définissons, pour toute $h : [-\|w\|_1, \|w\|_1] \rightarrow \mathbb{C}$ bornée,

$$\psi(h) = \int_{[0,1]^d} h(\langle w, x \rangle) d\mu(x)$$

On remarque que ψ est linéaire et continue car

$$|\psi(h)| \leq \|h\|_\infty \cdot \underbrace{|\mu|([0,1]^d)}_{<+\infty}$$

Or, pour $h = 1_{[0,+\infty[}$, $\psi(h) = \mu(\Pi_{w,-\infty}) + \mu(H_{w,-\infty}) = 0$

De même, $\psi(1_{]0,+\infty[}) = \mu(H_{w,-\infty}) = 0$

Donc: $\psi(1_{[\alpha_1, \alpha_2]}) = \psi(1_{[\alpha_1, \alpha_2[}) = \psi(1_{]\alpha_1, \alpha_2]}) = \psi(1_{]\alpha_1, \alpha_2[}) = 0$

Par linéarité de ψ , on a donc $\psi(h) = 0$ pour toute fonction h en escalier sur $[-\|w\|_1, \|w\|_1]$.

En approchant $h(t) = e^{it} = \cos(t) + i \sin(t)$ par des fonctions en escalier sur $[-\|w\|_1, \|w\|_1]$, on en déduit, par continuité de ψ :

$$\int_{[0,1]^d} e^{i\langle w, x \rangle} d\mu(x) = 0 \quad \forall w \in \mathbb{R}^d.$$

On reconnaît la transformée de Fourier de μ !

Déduisons-en que μ est nulle.

On admettra pour cela qu'il suffit de montrer que $\int f d\mu = 0$ pour tout $f = g|_{[0,1]^d}$ avec $g: \mathbb{R}^d \rightarrow \mathbb{R}$ de classe C^∞ et à support compact.

Pour tout $x \in [0,1]^d$, on a :

$$f(x) = g(x) = \int_{\mathbb{R}^d} \hat{g}(w) e^{i\langle w, x \rangle} dw$$

(formule d'inversion
valable car, par essc,
 g est dans l'espace
de Schwartz)

où $\hat{g}(w) = \frac{1}{(2\pi)^d} \int_{\mathbb{R}^d} g(x) e^{-i\langle w, x \rangle} dx$ est la transformée de Fourier de g .

Donc lors :

$$\begin{aligned} \int_{[0,1]^d} f(x) d\mu(x) &= \int_{[0,1]^d} \left(\int_{\mathbb{R}^d} \hat{g}(w) e^{i\langle w, x \rangle} dw \right) d\mu(x) \\ &\stackrel{\text{Fubini}}{=} \int_{\mathbb{R}^d} \hat{g}(w) \underbrace{\left(\int_{[0,1]^d} e^{i\langle w, x \rangle} d\mu(x) \right)}_{=0} dw \\ &= 0 \end{aligned}$$

- Donc $\mu \equiv 0$ et donc $L(f_\phi) = \int f_\phi d\mu = 0$, ce qui contredit $L(f_\phi) \neq 1$. Donc \mathcal{P}_1 est dense dans $G([0,1]^d, \mathbb{R})$. ■

Take-home messages :

- Le résultat de densité $\widehat{\mathcal{P}}_1 = \mathcal{C}([0,1]^d, \mathbb{R})$
- La technique de preuve, non constructive, par contradiction. L'utilisation du théorème de Bohn-Bonach pour prouver un résultat de densité est classique.

4/ Annexe : nullité de μ à partir de fonctions test.

On a utilisé le lemme suivant avec la mesure signée μ étendue à \mathbb{R}^d ($\mathcal{I}(A) := \mu(A \cap [0,1]^d)$ pour tout borelien $A \subset \mathbb{R}^d$).

Lemme :

plus généralement : complexe

Soit \mathcal{I} une mesure de Borel signée sur \mathbb{R}^d telle que

$$\int g d\mathcal{I} = 0$$

pour toute fonction $g: \mathbb{R}^d \rightarrow \mathbb{R}$ de classe C_c^∞ à support compact (on écrit : $g \in C_c^\infty(\mathbb{R}^d)$).

Alors \mathcal{I} est la mesure nulle sur \mathbb{R}^d .

Preuve : sit A un borelien de \mathbb{R}^d . Par densité de $C_c^\infty(\mathbb{R}^d)$ dans $L^1(\mathbb{R}^d, |\mathcal{I}|)$, il existe $g_m \in C_c^\infty(\mathbb{R}^d)$ telles que

$$\int_{\mathbb{R}^d} |g_m - 1|_A |d|\mathcal{I}| \xrightarrow[n \rightarrow +\infty]{} 0$$

D'où :

$$\begin{aligned} \left| \underbrace{\int g_m d\mathcal{I}}_{=0} - \mathcal{I}(A) \right| &= \left| \int (g_m - 1)_A d\mathcal{I} \right| \\ &\leq \int |g_m - 1|_A |d|\mathcal{I}| \xrightarrow[n \rightarrow +\infty]{} 0 \end{aligned}$$

et donc $\mathcal{I}(A) = 0$ pour tout borelien A . ■