

Compréhension théorique des comportements non linéaires
dans les grands réseaux de neurones
Colloque GRETSI 2019

Zhenyu Liao, Romain Couillet

CentraleSupélec, Université Paris-Saclay
GIPSA-lab, Université Grenoble-Alpes

Lille, 26 août 2019



CentraleSupélec



- 1 Introduction
- 2 Résultats Principaux
- 3 Conclusion

Motivation: non-linéarité dans d'apprentissage automatique

Apprentissage automatique repose sur **transformation non linéaire**:

- ▶ la *fonction noyau* f dans les méthodes à noyaux (e.g., spectral clustering, SVM)
- ▶ la *fonction d'activation* σ pour les réseaux de neurones

Dans ce travail:

- ▶ lien entre réseaux de neurones (à poids aléatoires) et matrices à noyaux (i.e., σ et f)
- ▶ étude de l'effet des non-linéarités (σ et f) et des **interactions** aux données (nombre, dimension et **statistiques**)
- ▶ conséquence pratique: “**prédire**” la performance d'un réseau de neurones en fonction de la **fonction d'activation** σ appliquée

Réseau de neurones à une seule couche cachée




Figure: Illustration d'un réseau à une seule couche cachée.

- ▶ $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_n] \Rightarrow$ **matrice de "features"**: $\boldsymbol{\Sigma} \equiv \sigma(\mathbf{W}\mathbf{X}) = [\sigma(\mathbf{W}\mathbf{x}_1), \dots, \sigma(\mathbf{W}\mathbf{x}_n)]$.
- ▶ Seconde couche $\boldsymbol{\beta} \in \mathbb{R}^{N \times d}$ apprise sur (\mathbf{X}, \mathbf{Y}) :

$$\boldsymbol{\beta} = \arg \min_{\boldsymbol{\beta}} \frac{1}{n} \|\mathbf{Y} - \boldsymbol{\beta}^\top \boldsymbol{\Sigma}\|_F^2 + \lambda \|\boldsymbol{\beta}\|_F^2 = \frac{1}{n} \boldsymbol{\Sigma} \left(\frac{1}{n} \boldsymbol{\Sigma}^\top \boldsymbol{\Sigma} + \gamma \mathbf{I}_n \right)^{-1} \mathbf{Y}^\top$$

- ▶ Objet clé: $\frac{1}{n} \boldsymbol{\Sigma}^\top \boldsymbol{\Sigma}$: matrice de **corrélation** dans l'espace "features".

Comprendre la performance d'un réseau de neurones simple

Hypothèse 1: régime asymptotique

- ▶ $n, p, N \rightarrow \infty$ avec $n \sim p \sim N$;
- ▶ (\mathbf{X}, \mathbf{Y}) déterministe, $\|\mathbf{X}\| = O(1)$ et $\mathbf{Y}_{ij} = O(1)$.

Hypothèse 2: poids aléatoires

$\mathbf{W}_{ij} \sim \mathcal{N}(0, 1)$ i.i.d.

Dans [Louart et al., 2018], pour σ Lipschitziennes:

Conclusion 1: impact de la fonction d'activation, lien entre σ et f

Performance du réseau fonction de σ via **matrice à noyau**

$$\Phi(\mathbf{X}) \equiv \mathbb{E}_{\mathbf{w}}[\sigma(\mathbf{X}^T \mathbf{w})\sigma(\mathbf{w}^T \mathbf{X})], \quad \mathbf{w} \sim \mathcal{N}(\mathbf{0}, \mathbf{I}_p)$$

ou son entrée (i, j) : $\Phi(\mathbf{x}_i, \mathbf{x}_j) \equiv \mathbb{E}_{\mathbf{w}}[\sigma(\mathbf{x}_i^T \mathbf{w})\sigma(\mathbf{w}^T \mathbf{x}_j)] \equiv f(\mathbf{x}_i, \mathbf{x}_j)$.

¹Cosme Louart, Zhenyu Liao, and Romain Couillet. A random matrix approach to neural networks. *The Annals of Applied Probability*, 28(2):1190–1248, 2018.

Calculer f pour différentes fonctions d'activation σ

Intuition:

- ▶ l'objet clé $\frac{1}{n} \Sigma^T \Sigma = \frac{1}{n} \sigma(\mathbf{X}^T \mathbf{W}^T) \sigma(\mathbf{W} \mathbf{X}) = \frac{1}{n} \sum_{i=1}^N \sigma(\mathbf{X}^T \mathbf{w}_i) \sigma(\mathbf{w}_i^T \mathbf{X})$
- ▶ $\mathbf{w}_i \sim \mathcal{N}(\mathbf{0}, \mathbf{I}_p)$, $i = 1, \dots, N$, **indépendant**
- ▶ asymptotique $N \rightarrow \infty$

$$\frac{1}{n} \Sigma^T \Sigma \Rightarrow \frac{1}{n} \mathbb{E}[\Sigma^T \Sigma] = \frac{1}{n} \sum_{i=1}^N \mathbb{E}[\sigma(\mathbf{X}^T \mathbf{w}_i) \sigma(\mathbf{w}_i^T \mathbf{X})] = \frac{N}{n} \Phi(\mathbf{X}),$$

avec l'entrée (i, j) $\Phi(\mathbf{x}_i, \mathbf{x}_j) \equiv \mathbb{E}_{\mathbf{w}}[\sigma(\mathbf{x}_i^T \mathbf{w}) \sigma(\mathbf{w}^T \mathbf{x}_j)] \equiv f(\mathbf{x}_i, \mathbf{x}_j)$.

Trouver f pour différentes σ : intégrale dans \mathbb{R}^p

$$f(\mathbf{x}_i, \mathbf{x}_j) \equiv \mathbb{E}_{\mathbf{w}}[\sigma(\mathbf{x}_i^T \mathbf{w}) \sigma(\mathbf{w}^T \mathbf{x}_j)] = (2\pi)^{-\frac{p}{2}} \int_{\mathbb{R}^p} \sigma(\mathbf{x}_i^T \mathbf{w}) \sigma(\mathbf{w}^T \mathbf{x}_j) e^{-\frac{\|\mathbf{w}\|^2}{2}} d\mathbf{w}$$

\Rightarrow solution explicite pour certains σ courants, e.g., $\text{ReLU}(t) \equiv \max(t, 0)$, quadratique $\sigma(t) = a_2 t^2 + a_1 t + a_0$, exponentiel $\sigma(t) = \exp(-t^2/2)$.

Feuille de route

$$\frac{1}{n} \Sigma^T \Sigma = \frac{1}{n} \sigma(\mathbf{X}^T \mathbf{W}^T) \sigma(\mathbf{W} \mathbf{X}) \Rightarrow \Phi(\mathbf{X}) = \{f(\mathbf{x}_i, \mathbf{x}_j)\}_{i,j=1}^n, \text{ par conséquent } \sigma \Rightarrow f.$$

Tableau de f pour différentes σ

$\sigma(t)$	$f(\mathbf{x}_i, \mathbf{x}_j)$
t	$\mathbf{x}_i^\top \mathbf{x}_j$
$\max(t, 0)$	$\frac{1}{2\pi} \ \mathbf{x}_i\ \ \mathbf{x}_j\ \left(\angle(\mathbf{x}_i, \mathbf{x}_j) \arccos \left(-\angle(\mathbf{x}_i, \mathbf{x}_j) \right) + \sqrt{1 - \angle(\mathbf{x}_i, \mathbf{x}_j)^2} \right)$
$ t $	$\frac{2}{\pi} \ \mathbf{x}_i\ \ \mathbf{x}_j\ \left(\angle(\mathbf{x}_i, \mathbf{x}_j) \arcsin \left(\angle(\mathbf{x}_i, \mathbf{x}_j) \right) + \sqrt{1 - \angle(\mathbf{x}_i, \mathbf{x}_j)^2} \right)$
$\text{erf}(t)$	$\frac{2}{\pi} \arcsin \left(\frac{2\mathbf{x}_i^\top \mathbf{x}_j}{\sqrt{(1+2\ \mathbf{x}_i\ ^2)(1+2\ \mathbf{x}_j\ ^2)}} \right)$
$1_{t>0}$	$\frac{1}{2} - \frac{1}{2\pi} \arccos \left(\angle(\mathbf{x}_i, \mathbf{x}_j) \right)$
$\text{sign}(t)$	$\frac{2}{\pi} \arcsin \left(\angle(\mathbf{x}_i, \mathbf{x}_j) \right)$
$\cos(t)$	$\exp \left(-\frac{1}{2} \left(\ \mathbf{x}_i\ ^2 + \ \mathbf{x}_j\ ^2 \right) \right) \cosh(\mathbf{x}_i^\top \mathbf{x}_j)$
$\sin(t)$	$\exp \left(-\frac{1}{2} \left(\ \mathbf{x}_i\ ^2 + \ \mathbf{x}_j\ ^2 \right) \right) \sinh(\mathbf{x}_i^\top \mathbf{x}_j)$

Table: Valeurs de $f(\mathbf{x}_i, \mathbf{x}_j)$ pour $\mathbf{w} \sim \mathcal{N}(\mathbf{0}, \mathbf{I}_p)$, avec $\angle(\mathbf{x}_i, \mathbf{x}_j) \equiv \frac{\mathbf{x}_i^\top \mathbf{x}_j}{\|\mathbf{x}_i\| \|\mathbf{x}_j\|}$.

Toujours **peu explicite** avec **non linéarité** et pas facile à comprendre ou interpréter!

Classification binaire: modèle de mélange gaussien

Les \mathbf{x} sont **aléatoires** et tirés **indépendamment** d'un modèle de mélange Gaussien à deux classes $\mathcal{C}_1, \mathcal{C}_2$:

$$\mathcal{C}_1 : \sqrt{p}\mathbf{x}_i \sim \mathcal{N}(\boldsymbol{\mu}_1, \mathbf{C}_1) \quad \text{versus} \quad \mathcal{C}_2 : \sqrt{p}\mathbf{x}_i \sim \mathcal{N}(\boldsymbol{\mu}_2, \mathbf{C}_2)$$

pour $\boldsymbol{\mu}_a \in \mathbb{R}^p$ et $\mathbf{C}_a \in \mathbb{R}^p$, $a = 1, 2$.

Objective: influence des différentes σ pour classifier $\mathcal{N}(\boldsymbol{\mu}_a, \mathbf{C}_a)$.

Hypothèse 3: "distance" minimale

Pour $p \rightarrow \infty$, on demande

- ▶ $\|\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2\| = O(1)$;
- ▶ $\|\mathbf{C}_a\| = O(1)$, $\text{tr}(\mathbf{C}_1 - \mathbf{C}_2) = O(\sqrt{p})$ et $\|\mathbf{C}_1 - \mathbf{C}_2\|_F^2 = O(p)$.

Théorème 1: comportement asymptotique de $\Phi(\mathbf{X})$ [Liao et Couillet, 2018]

Sous les Hypothèses 1–3, pour $\Phi(\mathbf{X}) = \{f(\mathbf{x}_i, \mathbf{x}_j)\}_{i,j=1}^n$ et (σ, f) listés dans Table 1,

$$\|\Phi - \tilde{\Phi}\| \xrightarrow{p.s.} 0, \quad \tilde{\Phi} = d_1 \cdot \mathbf{M}_1(\boldsymbol{\mu}_1, \boldsymbol{\mu}_2) + d_2 \cdot \mathbf{M}_2(\mathbf{C}_1, \mathbf{C}_2) + *$$

quand $n, p \rightarrow \infty$.

Conclusion 2: impact des non linéarités dans la classification

- ▶ l'influence de la non linéarité (σ et f) ne dépend que **deux** scalaires d_1 et d_2 ;
- ▶ ces deux paramètres “contrôlent” **indépendamment** les moyennes $\boldsymbol{\mu}_a$ et les covariances \mathbf{C}_a .

²Zhenyu Liao, Romain Couillet, “On the Spectrum of Random Features Maps of High Dimensional Data”. *Proceedings of the 35th International Conference on Machine Learning (ICML'18)*, 80: 3063–3071, 2018.

Comprendre la fonction d'activation σ

$\sigma(t)$	$f(\mathbf{x}_i, \mathbf{x}_j)$	d_1	d_2
t	$\mathbf{x}_i^T \mathbf{x}_j$	1	0
$\sin(t)$	$\exp(-\frac{1}{2}(\ \mathbf{x}_i\ ^2 + \ \mathbf{x}_j\ ^2)) \sinh(\mathbf{x}_i^T \mathbf{x}_j)$	$e^{-\tau}$	0
$\operatorname{erf}(t)$	$\frac{2}{\pi} \arcsin\left(\frac{2\mathbf{x}_i^T \mathbf{x}_j}{\sqrt{(1+2\ \mathbf{x}_i\ ^2)(1+2\ \mathbf{x}_j\ ^2)}}\right)$	$\frac{4}{\pi(2\tau+1)}$	0
$ t $	$\frac{2}{\pi} \ \mathbf{x}_i\ \ \mathbf{x}_j\ \left(\angle(\mathbf{x}_i, \mathbf{x}_j) \arcsin(\angle(\mathbf{x}_i, \mathbf{x}_j)) + \sqrt{1 - \angle(\mathbf{x}_i, \mathbf{x}_j)^2} \right)$	0	$\frac{1}{2\pi\tau}$
$\cos(t)$	$\exp(-\frac{1}{2}(\ \mathbf{x}_i\ ^2 + \ \mathbf{x}_j\ ^2)) \cosh(\mathbf{x}_i^T \mathbf{x}_j)$	0	$\frac{1}{4} e^{-\tau}$
$\exp(-t^2/2)$	$\frac{1}{\sqrt{(1+\ \mathbf{x}_i\ ^2)(1+\ \mathbf{x}_j\ ^2) - (\mathbf{x}_i^T \mathbf{x}_j)^2}}$	0	$\frac{1}{4(\tau+1)^3}$
$\max(t, 0)$	$\frac{1}{2\pi} \ \mathbf{x}_i\ \ \mathbf{x}_j\ \left(\angle(\mathbf{x}_i, \mathbf{x}_j) \arccos(-\angle(\mathbf{x}_i, \mathbf{x}_j)) + \sqrt{1 - \angle(\mathbf{x}_i, \mathbf{x}_j)^2} \right)$	$\frac{1}{4}$	$\frac{1}{8\pi\tau}$

Table: Valeur de $f(\mathbf{x}_i, \mathbf{x}_j)$ et les coefficients associés d_1, d_2 dans Théorème 1, $\angle(\mathbf{x}_i, \mathbf{x}_j) \equiv \frac{\mathbf{x}_i^T \mathbf{x}_j}{\|\mathbf{x}_i\| \|\mathbf{x}_j\|}$.

Conséquence: différents σ en trois groupes

Avec $\tilde{\Phi} = d_1 \cdot \mathbf{M}_1(\boldsymbol{\mu}_1, \boldsymbol{\mu}_2) + d_2 \cdot \mathbf{M}_2(\mathbf{C}_1, \mathbf{C}_2) + *$,

- moyenne-orienté:** $d_1 \neq 0$ et $d_2 = 0$, contient t , $\sin(t)$ et $\operatorname{erf}(t)$ qui "effacent" l'information dans les covariances $\mathbf{M}_2(\mathbf{C}_1, \mathbf{C}_2)$;
- cov-orienté:** $d_1 = 0$ et $d_2 \neq 0$ $|t|$, $\cos(t)$ et $e^{-\frac{t^2}{2}}$ et efface les moyennes $\mathbf{M}_1(\boldsymbol{\mu}_1, \boldsymbol{\mu}_2)$;
- équilibré:** $d_1, d_2 \neq 0$, ici pour $\operatorname{ReLU}(t) \equiv \max(t, 0)$.

“Choisir” σ en fonction des statistiques discriminantes des données

Feuille de route

$\frac{1}{n} \Sigma^T \Sigma = \frac{1}{n} \sigma(\mathbf{X}^T \mathbf{W}^T) \sigma(\mathbf{W} \mathbf{X}) \Rightarrow \Phi(\mathbf{X}) = \{f(\mathbf{x}_i, \mathbf{x}_j)\}_{i,j=1}^n$, on sait $\sigma \Rightarrow f \Rightarrow (d_1, d_2)$.




Figure: Base de données MNIST³ et EEG épileptiques.⁴

	$\ \hat{\mu}_1 - \hat{\mu}_2\ $	$\ \hat{C}_1 - \hat{C}_2\ $
MNIST (6 vs. 8)	172.4	86.0
EEG (B vs. E)	1.2	182.7

Table: Estimation empirique des statistiques de la base MNIST et EEG.

³<http://yann.lecun.com/exdb/mnist/>

⁴<http://www.meb.unibonn.de/epileptologie/science/physik/eegdata.html>.

Validation numérique sur la base de données MNIST et EEG

Application: spectral clustering en utilisant $\frac{1}{n}\Sigma^T\Sigma$.

	$\ \hat{\mu}_1 - \hat{\mu}_2\ $	$\ \hat{C}_1 - \hat{C}_2\ $
MNIST (6 vs. 8)	172.4	86.0
EEG (B vs. E)	1.2	182.7

Table: Estimation empirique des statistiques de la base MNIST et EEG.

	$\sigma(t)$	$n = 64$	$n = 128$
moyenne-orienté	t	88.94%	87.30%
	$\sin(t)$	87.81%	87.50%
	$\operatorname{erf}(t)$	87.28%	86.59%
covariance-orienté	$ t $	60.41%	57.81%
	$\cos(t)$	59.56%	57.72%
	$\exp(-t^2/2)$	60.44%	58.67%
équilibré	$\operatorname{ReLU}(t)$	85.72%	82.27%

Table: Précision de classification sur MNIST.

	$\sigma(t)$	$n = 64$	$n = 128$
moyenne-orienté	t	70.31%	69.58%
	$\sin(t)$	70.34%	68.22%
	$\operatorname{erf}(t)$	70.59%	67.70%
covariance-orienté	$ t $	99.69%	99.50%
	$\cos(t)$	99.38%	99.36%
	$\exp(-t^2/2)$	99.81%	99.77%
équilibré	$\operatorname{ReLU}(t)$	87.91%	90.97%

Table: Précision de classification sur EEG.

Conclusion

Messages:

- ▶ étude de la matrice de **corrélation** dans l'espace "**features (non linéaires)**": $\frac{1}{n} \Sigma^T \Sigma$, pour comprendre la fonction d'activation σ
- ▶ comportement lié à la matrice à noyau $\Phi(\mathbf{X}) = f\{\mathbf{x}_i, \mathbf{x}_j\}_{i,j=1}^n, \sigma \Rightarrow f$
- ▶ dans la classification des mélanges de gaussiennes, $\Phi(\mathbf{X})$ est (asymptotiquement) accessible, et dépend de f seulement via la paire (d_1, d_2)
- ▶ conséquence: on sait comment "choisir" la fonction σ pour différents types de problèmes/données

References:

- ▶ Cosme Louart, Zhenyu Liao, and Romain Couillet. "A random matrix approach to neural networks". *The Annals of Applied Probability*, 28(2) :1190–1248, 2018.
- ▶ Zhenyu Liao, Romain Couillet, "On the Spectrum of Random Features Maps of High Dimensional Data". *Proceedings of the 35th International Conference on Machine Learning (ICML'18)*, 80: 3063–3071, 2018.

Merci!