

Cours 14: Opérateurs neuronaux et problèmes temporels

Emmanuel Franck^{*},

28 novembre, 2024

Master CMSI, M2, Strasbourg

^{*}MACARON project-team, Université de Strasbourg, CNRS, Inria, IRMA, France

The logo for Inria, featuring the word "Inria" in a red, cursive script font.The logo for IRMA, consisting of the letters "IRMA" in a blue, bold, sans-serif font. Below the letters is a horizontal blue line, and underneath that line, the text "Institut de Recherche Mathématique Avancée" is written in a smaller, blue, sans-serif font.

Opérateur neuronaux continue en temps

Opérateur neuronaux discret en temps

Objectif: inversion d'opérateur

- Soit un problème elliptique de la forme

$$\begin{cases} \partial_t u - \Delta u = f(t, \mathbf{x}), & \mathbf{x} \in \Omega \\ u(t, \mathbf{x}) = 0 & \mathbf{x} \in \partial\Omega \\ u(0, \mathbf{x}) = u_0(\mathbf{x}) & \mathbf{x} \in \Omega \end{cases}$$

- On voudrait prédire rapidement une solution pour un $f(t, \mathbf{x})$ ou un $u_0(\mathbf{x})$ généraux.
- Si la solution existe, on peut formellement dire qu'il existe $G : \mathcal{H}_x \rightarrow \mathcal{H}_y$ tel que

$$u(\cdot) = G^{-1}(f(\cdot), u_0(\cdot))$$

- Comme précédemment peut généraliser en **cherchant à approcher $G^+(\mathbf{a}(\cdot)) = u(\cdot)$ avec \mathbf{a} l'ensemble des fonctions qui sont des entrées du problème** (sources, conditions limites, conditions initiales, coefficients de l'EDP).
- Si on regarde précisément le problème:

$$u(t, \cdot) = G^{-1}(u_0(\cdot))$$

- On voit qu'il s'agit en faite **d'apprendre le flot d'EDP**. On retombe sur les problèmes du chapitre 5.
- **Deux cas: flot discret ou continue en temps.**

Opérateur neuronaux continue en temps

Opérateur neuronaux discret en temps

Opérateur neuronaux continue en temps

Problème temporelle et Green

- Peut t'on généraliser la théorie de Green ? **oui**

$$u(t, \mathbf{x}) = \int_{\Omega} G(t, 0, \mathbf{x}, \mathbf{y}) u_0(\mathbf{y}) d\mathbf{y} + \int_0^t \int_{\Omega} G(t, \tau, \mathbf{x}, \mathbf{y}) f(\tau, \mathbf{y}) d\mathbf{y} d\tau \\ + \int_0^t \int_{\partial\Omega} [u(t, \mathbf{x}) \nabla G(t, 0, \mathbf{x}, \mathbf{y}) - G(t, 0, \mathbf{x}, \mathbf{y}) \nabla u(t, \mathbf{x})] d\mathbf{y} d\tau$$

avec

$$(\partial_t - \Delta)G(t, \tau, \mathbf{x}, \mathbf{y}) = \delta(\mathbf{x} - \mathbf{y})\delta(t - \tau)$$

et des conditions initiales/bords nulles.

GreenNet

Il s'agit d'un réseau à une **un couche** sans couche d'extrapolation et de projection ou la couche principale est $G_{\theta} : H^s(\Omega)^p \rightarrow H^s(\Omega)^p$ est paramétrée de la façon suivante:

$$G_{\theta}(\mathbf{f}, \mathbf{u}_0) = \int_{\Omega} k_{\theta}(t, 0, \mathbf{x}, \mathbf{y}) \mathbf{u}_0(\mathbf{y}) d\mathbf{y} + \int_0^t \int_{\Omega} k_{\theta}(t, \tau, \mathbf{x}, \mathbf{y}) f(\tau, \mathbf{y}) d\mathbf{y} d\tau$$

avec k_{θ} un réseau de type MLP, Fourier etc.

Opérateur neurone temporel

GreenNet temporel de Bas rang

Soit \mathbf{f} une fonction uniquement spatiale (condition initiale) ou dépendant du temps (source). On propose de prendre:

$$G_{\theta}(\mathbf{f}) = \sum_{k=1}^R \langle \mathbf{f}, \psi_i \rangle_{L^2} \phi_{\theta,k}(\mathbf{x}, t)$$

avec

$$\langle \mathbf{f}, \psi_i \rangle_{L^2} = \frac{1}{m} \sum_{j=1}^m \psi_{\theta,i}(\mathbf{x}_j, t_j) f(\mathbf{x}_j, t_j), \quad \text{ou} \quad \langle \mathbf{f}, \psi_i \rangle_{L^2} = \frac{1}{m} \sum_{j=1}^m \psi_{\theta,i}(\mathbf{x}_j, t_j) f(\mathbf{x}_j),$$

DeepONet temporel

Soit \mathbf{a} une fonction uniquement spatiale (condition initiale) ou dépendant du temps (source). On propose de prendre:

$$G_{\theta}(\mathbf{a}(t_1, \mathbf{x}_1), \dots, \mathbf{a}(t_m, \mathbf{x}_m)) = \sum_{i=1}^R \alpha_i b_{\theta,i}(\mathbf{x}, t)$$

avec b_{θ} un réseau de type MLP de \mathbb{R}^d dans \mathbb{R}^R et

$$t_{\theta}(\mathbf{a}(t_1, \mathbf{x}_1), \dots, \mathbf{a}(t_m, \mathbf{x}_m)) \rightarrow (\alpha_1, \dots, \alpha_K)$$

un réseau de $\mathbb{R}^{q \times m}$ dans \mathbb{R}^R

FNO continue en temps

- Une couche de Fourier est donnée par:

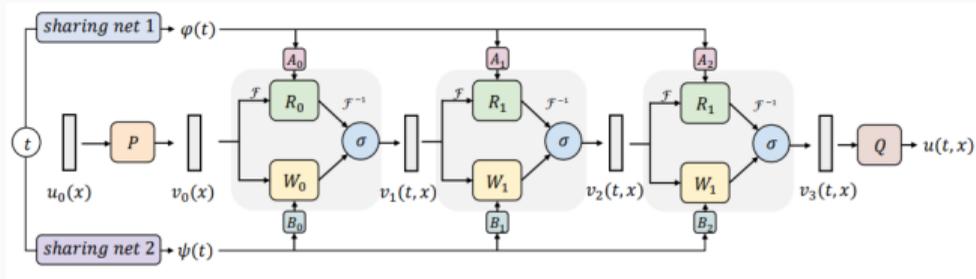
$$\mathbf{v}_{l+1} = \sigma(W_l \mathbf{v}_l + (\mathcal{F}^{-1} \circ \hat{\mathbf{k}}_{\theta_l} \circ \mathcal{F})(\mathbf{v}_l))$$

- Pour l'étendre au temporel il est proposé une **modulation temporelle des poids** de chaque couche:

$$\mathbf{v}_{l+1} = \sigma(\psi_{\theta_t}(t) W \mathbf{v}_l + (\mathcal{F}^{-1} \circ \phi_{\theta_t}(t, \mathbf{k}) \hat{\mathbf{k}}_{\theta_l} \circ \mathcal{F})(\mathbf{v}_l))$$

avec \mathbf{k} les fréquences.

- Il est proposé de prendre $\phi_{\theta_t}(t, \mathbf{k}) = \phi(t) A_l(\mathbf{k})$ avec $A(\mathbf{k})$ une matrice entraînable.
- Il est proposé de prendre $\phi_{\theta_t}(t, \mathbf{k}) = \text{diag}(\psi(t) B_l)$ avec B_l une matrice entraînable.
- les fonctions $\psi(t)$ et $\phi(t)$ sont communes à toutes les couches.



Transformeur

- Pour les transformeurs il est proposé de **moduler temporellement** une sous couche du modèle.

Bloc d'un opérateur neuronal de type transformeur temporel

Le bloc est donné par

$$\begin{aligned} \mathbf{v}^{(l-1)}(\mathbf{x}) &\leftarrow W_1 \mathbf{v}^{(l-1)}(\mathbf{x}) + A_{\text{MultiHead}}(\mathbf{v}^{(l-1)}), \\ \mathbf{v}^{(l-1)}(\mathbf{x}) &\leftarrow F_{\text{LayerNorm}}(\mathbf{v}^{(l-1)}(\mathbf{x})), \\ \mathbf{v}^{(l-1)}(\mathbf{x}) &\leftarrow W_2 \mathbf{v}^{(l-1)}(\mathbf{x}) + F_{\text{NN}}(\mathbf{v}^{(l-1)}(\mathbf{x})), \\ \mathbf{v}^{(l)}(\mathbf{x}) &\leftarrow F_{\text{LayerNorm}}(\mathbf{v}^{(l-1)}(\mathbf{x})), \end{aligned} \quad \text{avec}$$

$$(F_{\text{LayerNorm}}(\mathbf{v}; \gamma, \beta)(\mathbf{x}))_k = \gamma_k(t) \cdot \frac{(\mathbf{v}(\mathbf{x}))_k - m(\mathbf{v}(\mathbf{x}))}{\sqrt{\sigma^2(\mathbf{v}(\mathbf{x})) + \epsilon}} + \beta_k(t),$$

- Choix simple: $\beta(t) = \beta_1 + \beta_2 t$ et $\gamma(t) = \gamma_1 + \gamma_2 t$
- autre choix: des réseaux de neurones type MLP.

Propriété de semi groupe

Si on cherche à prédire la solution à partir de la condition initiale sans source. Le flot qui sera approché par l'opérateur neuronale satisfait la **structure de semi-groupe**.

- La fonction de coût classique est donnée par:

$$\bar{\mathcal{L}}(\theta) := \frac{1}{M(K+1)} \sum_{i=1}^M \sum_{k=0}^K \|G(t_k, a_i(\mathbf{x})) - u_i(t_k, \mathbf{x})\|_{L^p(D)}^p,$$

avec $u_i(t_k, \mathbf{x})$ la solution associée à la condition initiale $a_i(\mathbf{x})$

- On impose faiblement la structure de semi-groupe

$$\widehat{\mathcal{L}}(\theta) := \frac{1}{M\widehat{K}} \sum_{i=1}^M \sum_{k, \bar{k}=0, k \leq \bar{k}}^K \|u_i(t_{\bar{k}}, \mathbf{x}) - G_{\theta}(t_{\bar{k}} - t_k, u_i(t_k, \mathbf{x}))\|_{L^p(D)}^p,$$

Opérateur neuronaux continue en temps

Opérateur neuronaux discret en temps

Opérateur neuronal discret en temps

Flot discret et opérateur neuraux

Idée

On demande à l'opérateur neuronale de prédire **la solution à des temps discret**.

- On se donne un opérateur neuronale $G_\theta(u)$
- Plusieurs options:
 - ▶ On prédit un temps avec un temps: $u_{t_{k+1}}(\mathbf{x}) = G_\theta(u_{t_k}(\mathbf{x}))$
 - ▶ On prédit m temps avec m temps: $u_{t_{k+m}}(\mathbf{x}), \dots, u_{t_{k+1}}(\mathbf{x}) = G_\theta(u_{t_k}(\mathbf{x}), \dots, u_{t_{k-m}}(\mathbf{x}))$

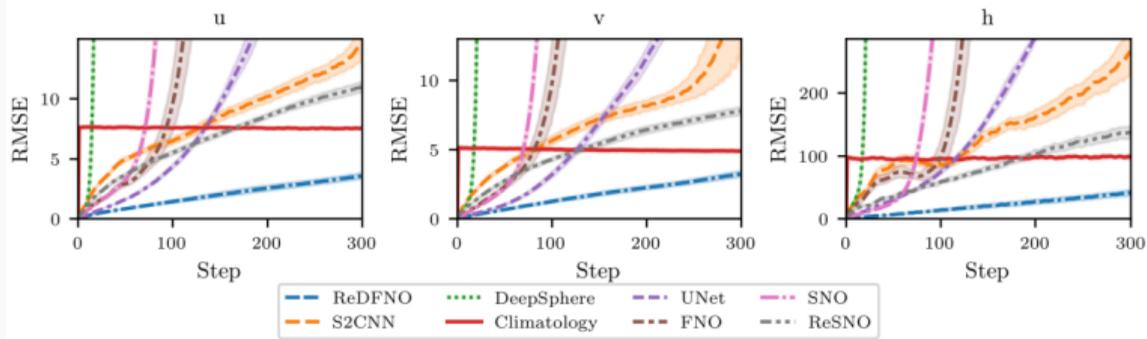
NO auto-régressif

On utilise donc les opérateurs neuronaux de façon auto-régressif:

$$u_{t_n}(\mathbf{x}) = (G_\theta \circ \dots \circ G_\theta)(u_0(\mathbf{x}))$$

Question centrale

Est ce ce type de prédiction est **stable** en temps ?



- Un entraînement sur plusieurs pas de temps (unrolled) peut stabiliser les opérateurs neuronaux.

