

Modelos reducidos

Hagamos ahora el camino contrario, y tratemos de reducir PDEs no lineales a ODES con pocos grados de libertad.

Proyección de Galerkin

Este método, además de ser la base de métodos numéricos (pseudospectral), sirve para proyectar PDEs a espacios reducidos. Consideremos

$$\partial_t u = F(u) \quad \text{dónde } F \text{ puede incluir operadores espaciales en un dominio } S$$

Si tomamos

$$u(x,t) = \sum_{j=1}^N \alpha_j(t) \varphi_j(x)$$

base en S que cumple
cdc (y tal vez simetrías) + f

⇒ Reemplazando

$$\sum_j \dot{\alpha}_j \varphi_j = F(u)$$

$$\int \varphi_i \varphi_j \omega dV = \delta_{ij}$$

↑ peso $\omega(x)$

Wepo

$$\sum_j \dot{\alpha}_j \int \varphi_j \varphi_k \omega dV = \int F(u) \varphi_k \omega dV$$

$$\Rightarrow \boxed{\dot{\alpha}_k = \int F(u) \varphi_k \omega dV}$$

↑ no depende de x
y depende solo de t y de los
coeficientes $\{\alpha_i, i=1\dots N\}$

Es un conjunto
de ODES!

En general para no linealidades cuadráticas los coeficientes (los integrales) de la derecha se pueden calcular explícitamente (en forma analítica o numérica). Además en ese caso magnitudes cuadráticas conservadas por el sistema original se conservan en la truncación.

En otras palabras, si $F(u) = L(u) + N(u, u)$

$$\Rightarrow \int F(u) \varphi_k w dV = A_k \alpha_k + \sum_{l,m} B_{lmk} \alpha_l \alpha_m$$

dónde A_k, B_{lmk} se pueden calcular a priori.

Lorenz construyó su modelo (y varios otros) así.

Ejemplo: Volvamos a la ecuación de Burgers

$$u_t = -uu_x + v u_{xx}$$

con c.c. $u(0,t) = u(1,t) = 0$, v grande.

Tomo $u = \sum_{j=1}^N \alpha_j(t) \sqrt{2} \operatorname{sen}(j\pi x)$

δ_{jk} ↑ base $\sqrt{2} \operatorname{sen} j\pi x$ por los c.c.

$$\begin{aligned} \Rightarrow \sum_j \overbrace{\alpha_j 2 \int_0^1 \operatorname{sen}(j\pi x) \operatorname{sen}(k\pi x) dx}^{\delta_{jk}} &= B_{lmk} \\ - \sum_{l,m} \overbrace{\alpha_l \alpha_m m\pi 2\sqrt{2} \int_0^1 \operatorname{sen}(l\pi x) \cos(m\pi x) \operatorname{sen}(k\pi x) dx}^{} \\ - V j^2 \pi^2 \overbrace{\alpha_j 2 \int_0^1 \operatorname{sen}(j\pi x) \operatorname{sen}(k\pi x) dx}^{} \end{aligned}$$

$$B_{lmk} = \frac{1}{4} \int_0^1 [\cos((l-k+m)\pi x) + \cos((l-k-m)\pi x) - \cos((l+k+m)\pi x) - \cos((l+k-m)\pi x)] dx$$

Estas integrales son cero salvo cuando

$$l = \begin{cases} k-m \\ k+m \\ -k-m \\ -k+m \end{cases} \quad \text{y en esos casos} \\ \text{dan } \pm 1/4$$

$$\Rightarrow \dot{\alpha}_k = -k^2\pi^2 V \alpha_k - \frac{\pi}{\sqrt{2}} \sum_m m \alpha_m (\alpha_{k-m} + \alpha_{k+m} - \alpha_{-k-m} - \alpha_{-k+m})$$

↑ ↑
 disipación acoplamiento

Es un sistema de ODEs acopladas no linealmente.

Truquemos a 3 modos ($k=1,2,3$)

$$\left\{ \begin{array}{l} \dot{\alpha}_1 = -\pi^2 V \alpha_1 + \frac{\pi}{\sqrt{2}} (\alpha_1 \alpha_2 + \alpha_2 \alpha_3) \\ \dot{\alpha}_2 = -4\pi^2 V \alpha_2 - \frac{\pi}{\sqrt{2}} (\alpha_1^2 - 2\alpha_1 \alpha_3) \\ \dot{\alpha}_3 = -9\pi^2 V \alpha_3 - \frac{\pi}{\sqrt{2}} 3\alpha_1 \alpha_2 \end{array} \right.$$


Ec. ordinarias
autónomas

↑ orden más grande,
 más disipación

Este sistema se parece al de Lorenz, y no es casual (Lorenz consideró PDEs con no linearidades pares).

Si $\alpha = 0$ $u = A \sin(\pi x)$, empezamos solo con $\alpha_1 \neq 0$. Pero inmediatamente después

$$\alpha_2 \approx -\frac{\pi}{12} \alpha_1^2 \Delta t$$



En este caso si V no es grande, nada nos asegura que no se exciten más modos. Hay casos en los que V , las cdc. o las simetrías hacen que existan unos pocos modos dominantes en la dinámica. Pero este método no nos dice como "elevar" a esos modos.

Descomposición ortogonal empírica

La POD ("proper orthogonal decomposition") es un método para resolver este problema usando datos empíricos, que pueden venir de simulaciones o experimentos.

Tiene diferentes nombres (POD, descomposición de Karhunen-Loève, análisis de componentes principales) y en espacios vectoriales discretos es equivalente a SVD. Fue introducido en simultáneo en diferentes problemas por Lumley, Loève, Karhunen y Pougachev.

La idea es construir una base ϕ_j ortogonal en base a datos que sea óptima (ya veremos en qué sentido), de forma tal que esos modos capturen las estructuras dominantes en la solución. La POD puede usarse para análisis de datos o para luego hacer una proyección de Galerkin truncando a unos pocos modos y conociendo el error asociado a lo que se tira.

Supongamos que tenemos una medición (o una solución) $u(\underline{x}, t)$ (esto puede generalizarse para un conjunto de mediciones $\{u^k\}$).

Queremos una descomposición truncada a N modos

$$u_N(\underline{x}, t) = \sum_{j=1}^N a_j(t) \varphi_j(\underline{x})$$

que sea mejor que cualquier otra descomposición usando otra base.