

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 ( $k=1,2,3$ )

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

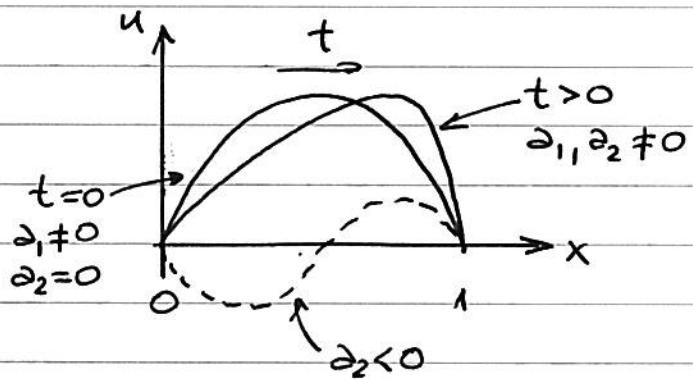
Ec. ordinarias  
autónomas

↑ 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

$$\omega_2 \approx -\frac{\pi}{12} \omega_1^2 \Delta t$$



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  $\phi_j$  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)  $u(x, t)$  (esto puede generalizarse para un conjunto de mediciones  $\{u^k\}$ ).

Queremos una descomposición truncada a  $N$  modos

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

que sea mejor que cualquier otra descomposición usando otra base.

Para simplificar consideremos el caso 1D,  $u = u(x, t)$   
Trabajemos en el dominio  $[0, 1]$  y pensemos que tenemos un producto interno  $(f, g)$ .

Por ejemplo

$$(f, g) = \int_0^1 f(x) g^*(x) dx$$

escalar  
✓  
 $f$  y  $g$  viven en Hilbert, así que si son vectores

$$(f, g) = f \cdot g^*$$

Tenemos norma

$$\|f\| = (f, f)^{1/2}$$

$$\text{Prop: } (f, g) = (g, f)^*$$

La POD es óptima en el sentido de que las  $\varphi$  son tales que el error cuadrático medio entre  $u$  y su proyección en las  $\varphi$  es mínimo:

$$8 \|u - \frac{(u, \varphi)}{\|\varphi\|^2} \varphi\|^2 = 0$$

Como variamos las  $\varphi$ ,

esto es equivalente a maximizar la proyección sobre  $\varphi$

$$8 \frac{|(u, \varphi)|^2}{\|\varphi\|^2} = 0$$

← Esto tiene  $\infty$  soluciones,  
cada una es un elemento  
de la base empírica.