



Méthodes numériques

Delphine BRESCH-PIETRI et Pauline Bernard

Stage Liesse
Mai 2022

Programme

Résolution d'équations

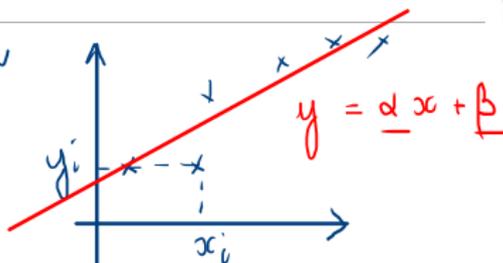
Equations linéaires

Equations non linéaires

Résolution d'équations différentielles

$$f(x) = 0$$

$$(x_i, y_i), 1 \leq i \leq p$$



► Régression linéaire

$$\begin{cases} \alpha x_1 + \beta = y_1 \\ \alpha x_2 + \beta = y_2 \\ \vdots \\ \alpha x_p + \beta = y_p \end{cases}$$

$$\rightarrow \sum_{i=1}^p (\alpha x_i + \beta - y_i)^2$$

$$= dx/dt$$

► Recherche de points d'équilibre

$$\dot{x} = f(x)$$

$$\text{points d'équilibre : } 0 = f(x)$$

$$n=2, \begin{cases} x_1 = \alpha \\ x_2 = \beta \end{cases}$$

$$\begin{cases} a_{j1} = x_j \\ a_{j2} = 1 \end{cases}$$

$$b_j = y_j$$

$$\begin{cases} \underbrace{a_{1,1}}_{=x_1} \widehat{x}_1 + \dots + \underbrace{a_{1,n}}_{=1} \widehat{x}_n = b_1 = y_1 \\ \vdots \\ a_{p,1} x_1 + \dots + a_{p,n} x_n = b_p \end{cases}$$

que l'on écrit sous forme matricielle

$$\underbrace{\text{EM}_{p \times n}(\mathbb{R})}_{\in \mathbb{R}^{p \times n}} \underbrace{Ax = b}_{\in \mathbb{R}^n} \underbrace{\in \mathbb{R}^p}_{\left(\begin{matrix} b_1 \\ \vdots \\ b_p \end{matrix} \right)}$$

$$f: \mathbb{R}^n \rightarrow \mathbb{R}$$

$$x \mapsto \|Ax - b\|^2$$

Cas $p > n$ (sur-déterminé) :

$$\min_{x \in \mathbb{R}^n} \|Ax - b\|^2 = \sum_{i=1}^p \left(\sum_{j=1}^n a_{ij} x_j - b_i \right)^2$$

où $\|\cdot\|$ est la norme euclidienne dans \mathbb{R}^p . On peut montrer que la solution de ce problème est unique et telle que

$$\nabla f(x^*) = 0 = \cancel{2A^T A x^*} - \cancel{2A^T b} \Leftrightarrow \boxed{x^* = (A^T A)^{-1} A^T b}$$

$$\|Ax - b\|^2 = (Ax - b)^T (Ax - b)$$

$$= \underbrace{x^T A^T A x}_{\text{red}} - \underbrace{2x^T A^T b}_{\text{green}} + \cancel{b^T b}$$

A de rang $n \Rightarrow A^T A$ inversible
(toujours faisable)

M $n = p$, A de rang n
 $\Rightarrow A$ inversible

$$x^* = A^{-1} \cancel{(A^T)^{-1}} A^T b$$

$$= A^{-1} b$$

$$\min \sum_{i=1}^m |x_i| = \|x\|_1$$

Cas $n > p$ (sous-déterminé) :

$$\min_{Ax=b} \|x\|^2$$

Il existe une unique solution qui est $x^* = A^T(AA^T)^{-1}b.$ $= A^{-A} b$ si $m = p$

lstsq(A, b, rcond)

de la librairie numpy.linalg, où

- ▶ A : array (p, n) des coefficients
- ▶ b : array ($p,$)
- ▶ rcond : optionnel, valeur de conditionnement de la matrice A. Mettre "rcond = None" pour éviter un warning.

La fonction renvoie :

- ▶ x : array à une dimension n contenant la solution
- ▶ residuals : scalaire, somme des résidus au carré (fonction coût)
- ▶ rank : rang de la matrice A
- ▶ s : valeurs singulières de la matrice A

$$\begin{aligned}
 &= \|Ax - b\|^2 \\
 &= \sum_i (\sum_j a_{ij} x_j - b_i)^2
 \end{aligned}$$

~~$$f(x) = Ax - b$$~~

$$\begin{pmatrix} f_1(x) \\ f_2(x) \\ \vdots \\ f_p(x) \end{pmatrix} = 0$$

Dans le cas non-linéaire, il est souvent impossible de déterminer de façon explicite une solution à l'équation

$$f(x) = 0$$

où $x \in \mathbb{R}^n$ et $f : \mathbb{R}^n \rightarrow \mathbb{R}^p$. On dispose néanmoins de méthodes numériques permettant de réaliser cela.

$$f(x) = 0 \Leftrightarrow x = g(x)$$

$$g: \mathbb{R}^n \rightarrow \mathbb{R}^n$$

Si la fonction $g = \del{g} est contractante, cad s'il existe une constante $\kappa \in [0, 1[$ telle que$

$$\forall (x_1, x_2) \in \mathbb{R}^n \times \mathbb{R}^n \quad \underline{\|g(x_1) - g(x_2)\| \leq \kappa \|x_1 - x_2\|}$$

on peut alors résoudre l'équation en itérant la relation

$$\boxed{x_{k+1} = g(x_k)} \del{x_{k+1} = g(x_k)}$$

Théorème du point fixe de Banach:

si g est contractante, il existe un unique u^* tq $u^* = g(u^*)$
 et $\left\{ \begin{array}{l} u_{k+1} = g(u_k) \\ x_0 \in \mathbb{R}^n \end{array} \right.$ est convergente et tq $\lim_{k \rightarrow +\infty} u_k = u^*$

$$\begin{cases} \dot{T} = -aT + bu(t) \\ T(0) = T_0 \end{cases}$$

on cherche t_1 le temps où $T(t_1) = T_1$

$$\text{on a } T(t) = e^{-at} T_0 + \int_0^t e^{-a(t-s)} bu(s) ds$$

$$\text{on veut trouver } e^{-at_1} T_0 + \int_0^{t_1} e^{-a(t_1-s)} bu(s) ds - T_1 = 0$$

$$\stackrel{\Delta}{=} f(t_1)$$

$$\text{cei est équivalent à } t_1 = -\frac{1}{a} \ln \left(\frac{T_1 - \int_0^{t_1} e^{-a(t_1-s)} bu(s) ds}{T_0} \right)$$

$$\stackrel{\Delta}{=} g(t_1)$$

Cas $n = p$:

$$f: \mathbb{R}^n \rightarrow \mathbb{R}^n$$

$$\left(\frac{\partial f_i}{\partial x_j} \right) = \begin{pmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} & \frac{\partial f_1}{\partial x_3} & \dots \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \dots & \dots \\ \vdots & \vdots & \vdots & \vdots \end{pmatrix}$$

Si f est différentiable,

$$f(x^*) = 0 = f(x) + J_f(x^*)(x - x^*) + o(\|x - x^*\|) \quad \in \mathcal{M}_{n \times n}(\mathbb{R})$$

où $J_f(x^*)$ est la matrice jacobienne de f au point x^* .

$$0 \approx f(x) + J_f(x)(x - x^*) \Rightarrow x^* = x - J_f(x)^{-1} f(x)$$

La méthode de Newton-Raphson consiste à utiliser cette approximation et à choisir

$$\begin{cases} x_0 \in \mathbb{R}^n \longleftarrow \\ x_{k+1} = x_k - J_f(x_k)^{-1} f(x_k) \end{cases}$$

on voudrait que cette relation converge vers x^* si $f \in C^2$ avec des hypothèses de bornitude, on a CV quadratique de cette méthode vers x^*

$$f \in C^2, f: \mathbb{R} \rightarrow \mathbb{R}$$

la méthode de Newton-Raphson consiste à itérer

$$x_{k+1} = x_k - \frac{1}{f'(x_k)} f(x_k)$$

[par ailleurs, par Taylor avec reste intégral,

$$\forall x \in \mathbb{R} \quad f(x) = f(x_k) + f'(x_k)(x - x_k) + \int_{x_k}^x f''(t)(x-t) dt$$

$$\text{on a } x_{k+1} - x^* = \cancel{x_k} - x^* - \frac{1}{f'(x_k)} \left[\overbrace{f(x^*) - f'(x_k)(x^* - x_k)} = 0 - \int_{x_k}^{x^*} f''(t)(x^* - t) dt \right]$$

$$x_{k+1} - x^* = \frac{1}{f'(x_k)} \int_{x_k}^{x^*} f''(t) (x^* - t) dt$$

on suppose ces termes bornés

$$\Rightarrow \|x_{k+1} - x^*\| \leq M \|x^* - x_k\|^2$$

convergence quadratique

$$\leq (M \|x_0 - x^*\|)^2$$

$< 1/M$

quelconque

Cas ~~A~~ x_k

On s'intéresse au problème

$$\begin{pmatrix} f_1(x) \\ \vdots \\ f_2(x) \\ \vdots \\ f_1(x) \end{pmatrix} = 0 \Leftrightarrow \sum_{i=1}^n f_i(x)^2 = 0$$

$$= \|f(x)\|^2 \quad (1)$$

$$\min_{x \in \mathbb{R}^n} \|f(x)\|^2 = F(x)$$

$$= -\ell \nabla F(x_k)^T \nabla F(x_k)$$

$$= -\ell \|\nabla F(x_k)\|^2 \leq 0$$

$F: \mathbb{R}^n \rightarrow \mathbb{R}$
 $x \mapsto \|f(x)\|^2$

Si F est différentiable, on a

$$F(x) = F(x_k) + \nabla F(x_k)^T (x - x_k) + o(\|x - x_k\|) \quad (2)$$

$$F(x_{k+1}) \approx F(x_k) + \nabla F(x_k)^T (x_{k+1} - x_k) \leq F(x_k) \leftarrow \text{on veut ceci}$$

Méthode de gradient à pas fixe

on choisit $x_{k+1} = x_k - \underset{\geq 0}{\ell} \nabla F(x_k)$

$$x_{k+1} = x_k - \nabla F(x_k) \quad (3)$$

dichotomie obligatoire

bisect(f, a, b, args)

de la librairie scipy.optimize, où

- ▶ ~~f~~ : fonction $\mathbb{R} \rightarrow \mathbb{R}$,
- ▶ a : scalaire de début d'intervalle
- ▶ b : scalaire de fin d'intervalle
- ▶ options : nombre maximal d'itérations, tolérance, ...

obligatoire

fsolve(f, x0, args)

de la librairie scipy.optimize, où

- ▶ ~~f~~ : fonction $\mathbb{R}^n \rightarrow \mathbb{R}^n$,
- ▶ x0 : condition initiale de taille n , *array à 1 dim*
- ▶ options : jacobien, nombre maximal d'itérations, tolérance, ...

Programme

Résolution d'équations

Equations linéaires

Equations non linéaires

$$\text{trouver } u \in \mathbb{R}^n \text{ tq } f(u) = 0$$

Résolution d'équations différentielles

$$\underline{x(t)} \text{ tq } \dot{x} = f(x)$$

Exemples

- concentrations des espèces chimiques dans une réaction $A + B \xrightleftharpoons[k']{k} C$

$$\begin{array}{l}
 \frac{dc_A}{dt} \\
 \frac{dc_C}{dt}
 \end{array}
 =
 \begin{array}{l}
 \\
 \\
 \end{array}
 \left|
 \begin{array}{l}
 \dot{c}_A = -k c_A c_B + k' c_C \\
 \dot{c}_B = -k c_A c_B + k' c_C \\
 \dot{c}_C = k c_A c_B - k' c_C
 \end{array}
 \right.
 \quad \text{"ordre 1"}$$

ou : masse - ressort :

- mécanique Newtonienne ou Lagrangienne



$$\underbrace{M\ddot{q}}_{\frac{d^2q}{dt^2}} = \sum_k F_k(t, q, \dot{q})$$

"ordre 2"

y de classe C^p vérifie

$$\| \underbrace{y^{(p)}(t)}_{=} = \underbrace{\psi(t, y(t), \dot{y}(t), \dots, y^{(p-1)}(t))}_{=}$$

équation scalaire
d'ordre p

si et seulement si $x = \underbrace{(y, \dot{y}, \ddot{y}, \dots, y^{(p-1)})}_{=}$ de classe C^1 vérifie

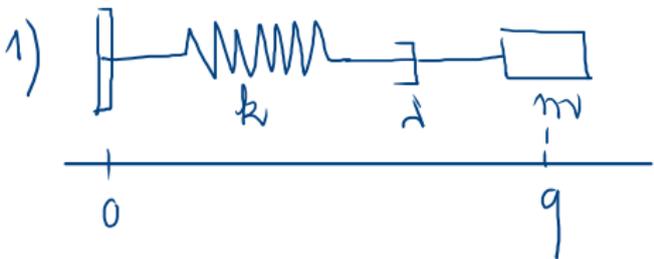
$$\dot{x} = f(t, x), \quad \|$$

équation vectorielle ($\in \mathbb{R}^p$)
d'ordre 1

où f est définie par

$$\dot{x} = \begin{pmatrix} \dot{y} \\ \dot{y} \\ \dot{y} \\ \vdots \\ \dot{y}^{(p)} \end{pmatrix} = \begin{pmatrix} x_2 \\ x_3 \\ \dots \\ x_p \\ \psi(t, x_1, x_2, \dots, x_p) \end{pmatrix} \triangleq f(t, x_1, x_2, \dots, x_p)$$

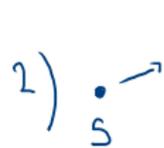
\Rightarrow toujours se mettre sous la forme $\dot{x} = f(t, x)$ crucial pour étude mathématique et numérique !



Newton: $m\ddot{q} = -kq - \lambda \dot{q}$

$$x = \begin{pmatrix} q \\ \dot{q} \end{pmatrix} \text{ et alors } \dot{x} = \begin{pmatrix} x_2 \\ -\frac{1}{m}(kx_1 + \lambda x_2) \end{pmatrix}$$

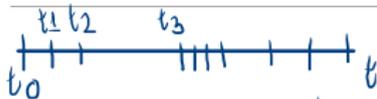
$$= f(x)$$



$$m_S \ddot{q}_S = \dots$$

$$m_T \ddot{q}_T = \dots$$

$$x = \begin{pmatrix} q_S \\ \dot{q}_S \\ q_T \\ \dot{q}_T \end{pmatrix} \quad \dot{x} = \begin{pmatrix} \dot{q}_S \\ \ddot{q}_S \\ \dot{q}_T \\ \ddot{q}_T \end{pmatrix} \begin{pmatrix} \dots \\ \dots \\ \dots \\ \dots \end{pmatrix}$$



$$\dot{x} = f(t, x) \quad , \quad x(t_0) = x_0$$

forme
intégrale

$$x(t) = x_0 + \int_{t_0}^t f(s, x(s)) ds = x_0 + \sum_{j=0}^{J-1} \int_{t_j}^{t_{j+1}} f(s, x(s)) ds$$

$$t_0 < t_1 < \dots < t_J = t$$

Idée : approximer l'intégrale sur des intervalles $[t_j, t_{j+1}]$ suffisamment petits.

x^j : approximation de $x(t_j)$

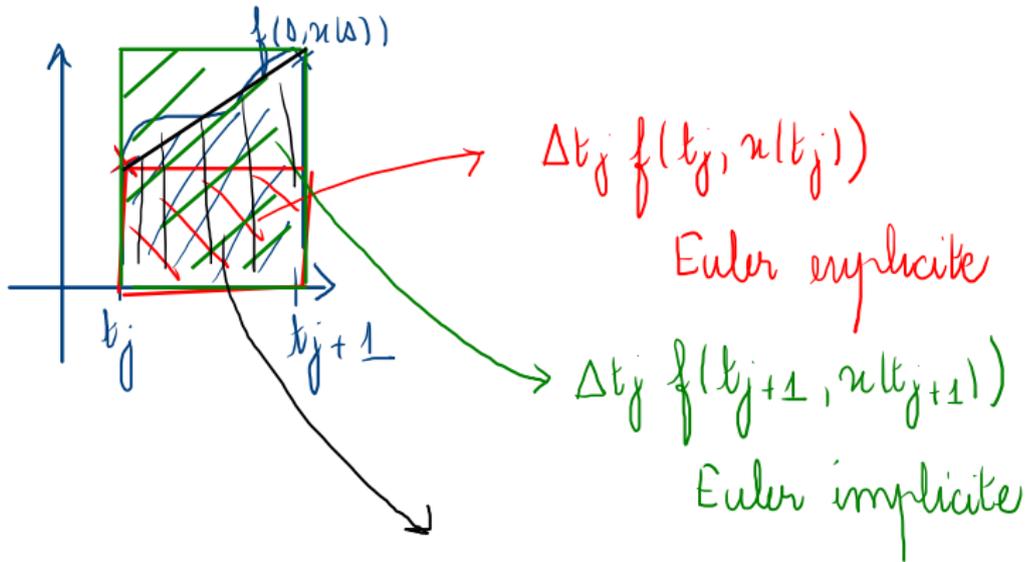
$$\Delta t_j = t_{j+1} - t_j$$

On implémente

$$x^{j+1} = x^j + \Delta t_j \Phi(t_j, x^j, \Delta t_j)$$

tel que

$$\Phi(t_j, x^j, \Delta t_j) \approx \frac{1}{\Delta t_j} \int_{t_j}^{t_{j+1}} f(s, x(s)) ds$$



Trapezöide

$$\frac{1}{2} \Delta t_j [f(t_j, x(t_j)) + f(t_{j+1}, x(t_{j+1}))]$$

$$\begin{cases} \dot{x} = f(t, x) \\ x(t_0) = x_0 \end{cases} \longrightarrow \begin{cases} x_{j+1} = x_j + \Delta t_j f(t_j, x_j) \\ x_0 = x_0 \end{cases}$$

Taylor à l'ordre 1 pour x :

$$\begin{aligned} x(t_{j+1}) &= x(t_j) + \Delta t_j \dot{x}(t_j) + o(\Delta t_j) \\ &= x(t_j) + \Delta t_j f(t_j, x(t_j)) + o(\Delta t_j) \end{aligned}$$

on a donc

$$\| \max_{1 \leq j \leq J} \| x(t_j) - x_j \| \leq \underbrace{c}_{\in \mathbb{R}_+} \Delta t \quad \text{avec } \Delta t = \max_{1 \leq i \leq J} \Delta t_j$$

Limites $\begin{cases} \rightarrow \text{ordre 1} \\ \rightarrow \text{systèmes "raides" (avec des échelles de temps \neq \text{les})} \\ \rightarrow \text{systèmes conservatifs / hamiltoniens} \end{cases}$

$$\begin{cases} \underline{x_{j+1}} = \underline{x_j} + \Delta t_j f(t_{j+1}, \underline{x_{j+1}}) \stackrel{\Delta}{=} F(x_{j+1}) \\ x_0 = x_0 \end{cases}$$

ou

$$F: \textcircled{x} \mapsto \underline{x_j} + \Delta t_j f(t_{j+1}, \textcircled{x})$$

on souhaite résoudre cette équation par point fixe et il faut donc que F soit contractante

[supposons que f est Lipschitzienne de constante K par rapport à x :
 cad $\forall (a, b) \in \mathbb{R}^m \times \mathbb{R}^m \forall t \in \mathbb{R}$
 $\|f(t, a) - f(t, b)\| \leq K \|a - b\|$

alors

$$\begin{aligned} \|F(a) - F(b)\| &= \|\underline{x_j} + \Delta t_j f(t_{j+1}, a) - [\underline{x_j} + \Delta t_j f(t_{j+1}, b)]\| \\ &= \Delta t_j \|f(t_{j+1}, a) - f(t_{j+1}, b)\| \leq \frac{\Delta t_j K}{< 1} \|a - b\| \text{ si } \Delta t_j < 1/K \end{aligned}$$

on résout l'équation sur x_{j+1} par point fixe

$$\text{on choisit } \begin{cases} x_{j+1}^0 = x_j + \Delta t_j f(t_j, x_j) \\ x_{j+1}^{k+1} = F(x_{j+1}^k) \end{cases} \text{ avec Euler explicite}$$

$$\text{arrêt lq } \|x_{j+1}^{k+1} - x_{j+1}^k\| \leq \text{Tol}$$

\Rightarrow méthode d'ordre 1

$$x(t) = e^{-\lambda t} \quad \leftarrow \quad \dot{x} = -\lambda x \quad x(0) = 1 \quad \text{avec } \lambda > 0$$

Euler explicite: $x_{j+1} = x_j + \Delta t (-\lambda x_j)$
 $= (1 - \lambda \Delta t) x_j$

$x_j \xrightarrow{j \rightarrow +\infty} 0$ seulement si $|1 - \lambda \Delta t| < 1$

donc pour $\Delta t < \frac{2}{\lambda}$

Euler implicite: $x_{j+1} = x_j + \Delta t (-\lambda x_{j+1})$
 donc $(1 + \lambda \Delta t) x_{j+1} = x_j$
 $x_{j+1} = \frac{1}{1 + \lambda \Delta t} x_j \xrightarrow{j \rightarrow +\infty} 0$

convergence
 inconditionnelle
 sur Δt

\Rightarrow Explicite ou implicite pour $\dot{x} = \begin{pmatrix} -1 & 0 \\ 0 & -\mu \end{pmatrix} x$ avec $\mu \gg 1$?

Schéma convergent à l'ordre p si $\exists c_v > 0$ (indépendent de Δt) tel que

$$\max_{1 \leq j \leq J} \|x^j - x(t_j)\| \leq c_v (\Delta t)^p.$$

Détermination numérique de l'ordre :

on réalise plusieurs simulations pour un Δt différent à chaque fois
on plotte $\log(\max \|x^j - x(t_j)\|)$ par rapport $\log \Delta t$

Détermination analytique de l'ordre :

$$x(t_{j+1}) = x(t_j) + \Delta t_j \underbrace{f(t_j, x(t_j))}_{f(t_j, x(t_j))} + \frac{\Delta t_j^2}{2} \underbrace{f'(t_j, x(t_j))}_{f'(t_j, x(t_j))} + o(\Delta t_j^2)$$
$$\partial_t f(t_j, x(t_j)) + \partial_x f(t_j, x(t_j)) f(t_j, x(t_j))$$

- ▶ méthode de Heun (ordre 2) :

$$x^{j+1} = x^j + \frac{\Delta t_j}{2} \left(f(t_j, x^j) + f(t_{j+1}, x^j + \Delta t_j f(t_j, x^j)) \right),$$

ou sa version implicite méthode des trapèzes (ou Crank–Nicolson) :

$$x^{j+1} = x^j + \frac{\Delta t_j}{2} \left(f(t_j, x^j) + f(t_{j+1}, x^{j+1}) \right). \quad ||$$

- ▶ schéma de Runge–Kutta d'ordre 4 (RK4) largement utilisée:

$$x^{j+1} = x^j + \Delta t_j \frac{F_1 + 2F_2 + 2F_3 + F_4}{6} \quad \text{avec} \quad \begin{cases} F_1 = f(t_j, x^j) \\ F_2 = f\left(t_j + \frac{\Delta t_j}{2}, x^j + \frac{\Delta t_j}{2} F_1\right) \\ F_3 = f\left(t_j + \frac{\Delta t_j}{2}, x^j + \frac{\Delta t_j}{2} F_2\right) \\ F_4 = f(t_j + \Delta t_j, x^j + \Delta t_j F_3), \end{cases}$$



▶ adaptation du pas

Δt_j

oblig.
odeint(fun, y0, t, args)

de la librairie scipy.integrate, où

- ▶ fun : fonction prenant en entrée (y, t) et renvoyant un array $f(y, t)$,
- ▶ y0 : la condition initiale
- ▶ t : suite des temps auxquels on souhaite résoudre y
- ▶ options : jacobien de la fonction, tolérance, points critiques, pas de temps min ou max, ...

La fonction renvoie :

- ▶ y : array à deux dimensions de taille (len(t), len(y0))

```
solve_ivp(fun,t_span,x0,method,t_eval)
```

de la librairie scipy.integrate, où

- ▶ fun : fonction prenant en entrée (t, x) et renvoyant un array $f(t, x)$,
- ▶ t_span : intervalle d'intégration $[t_0, t_f]$
- ▶ x0 : la condition initiale
- ▶ method : méthode d'intégration : par défaut, en mettant `[]` ou en nommant les entrées suivantes, c'est "RK45", le Runge-Kutta explicite d'ordre 5 (avec contrôle du pas à l'ordre 4). Lorsque cela échoue ou demande trop d'itérations, le système est peut-être raide : utiliser alors les méthodes implicites "Radau" ou "BDF".
- ▶ t_eval : array donnant les temps auxquels vous voulez qu'il vous renvoie la solution (doit être dans l'intervalle `t_span`)
- ▶ options :

La fonction renvoie un objet `sol` de type `bunch` :

- (▶ `sol.t` : array à une dimension contenant les temps
- (▶ `sol.y` : array à deux dimensions (`dim_x, dim_t`), de façon à ce que `sol.y[k]` donne l'array du k -ième état au cours du temps.