

連続最適化および関連分野に関する夏季学校

連続最適化への応用に向けた
常微分方程式の数値解析入門

佐藤 峻

東京大学

2023 年 8 月 9 日

$$x^{(k+1)} = x^{(k)} - h_k \nabla f(x^{(k)})$$

連続最適化の視点

最小化問題 $\min f(x)$ に対する
最急降下法

- 目的：
最適解の発見
- h_k ：
関数値等を基準に選ぶ
- キーワード：
収束条件，収束レート，...


数値解析の視点


勾配流 $\dot{x} = -\nabla f(x)$ に対する
陽的 Euler 法

- 目的：
解軌道の忠実な再現
- h_k ：
誤差や安定性を基準に選ぶ
- キーワード：
収束性，安定性，精度，...

目的は違うが，全く同じ更新式が使われている

→ 数値解析の視点は連続最適化に有用である（こともある）






右向きの矢印：連続極限


左向きの矢印：既存の数値解法としての解釈

連続極限の方が扱いやすいことも多く、手法の設計に役立つ。


- 加速鏡像降下法 [Krichene et al., 2015]



- 凸と強凸に対する Nesterov の加速勾配法の統合 [Kim and Yang, 2023]



目的関数 $f: \mathbb{R}^d \rightarrow \mathbb{R}$ が μ -強凸 (かつ L -平滑) の場合 (f^* : 最適値)



数値解析でよく知られている「安定性」の条件から,

- 陽的 Euler 法 : $h_k = O\left(\frac{1}{L}\right) \rightarrow t_k := \sum_{i=0}^{k-1} h_i = O\left(\frac{k}{L}\right)$,
- 線形多段階法 : $h_k = O\left(\frac{1}{\sqrt{\mu L}}\right) \rightarrow t_k = O\left(\frac{k}{\sqrt{\mu L}}\right)$.

常微分方程式の数値解析の基礎をざっくりと理解する。

連続最適化に役立つ概念

- 各種の陽的数値解法
陽的：次のステップの数値解が直接計算できる。
- 安定性
安定：数値解（あるいは混入した誤差）が発散しない。
- 構造保存数値解法
微分方程式のもつ構造を再現する数値解法。

現状ではあまり有効活用されていない概念

- 各種の陰的数値解法
陰的：次のステップの数値解を計算するために、非線形方程式を解く。
- 収束性（精度）
ステップ幅を小さくした際の厳密解への近づき方。

- E. Hairer, S. P. Nørsett, and G. Wanner. Solving ordinary differential equations I, Nonstiff problems, Springer-Verlag, 1993, xvi+528 pp.
- E. Hairer and G. Wanner. Solving ordinary differential equations II, Stiff and differential-algebraic problems, Springer-Verlag, 1996, xvi+614 pp.

コメント：網羅的に ODE の数値解析の知見がまとめられている。数値実験例も豊富。和訳も「常微分方程式の数値解法 I」「常微分方程式の数値解法 II」という名前で出版されている。

- 三井 斌友. 常微分方程式の数値解法, 岩波書店, 2003, 146 pp.

コメント：常微分方程式の数値解析の基礎がコンパクトにまとめられている。演習問題に解答もついており、親切。

- E. Hairer, C. Lubich, G. Wanner. Geometric Numerical Integration, Springer-Verlag, 2006, xviii+644 pp.

コメント：ODE に対する構造保存数値解法 (後述) の定番教科書。

- ① 連続最適化問題に対する ODE アプローチの例
- ② 常微分方程式の数値解析の概要
- ③ 数値解法の安定性
- ④ 数値解法の精度 : Runge-Kutta 法
- ⑤ 数値解法の精度 : 線形多段階法
- ⑥ 構造保存数値解法
- ⑦ 微分方程式の数値解析の連続最適化への応用
- ⑧ まとめ

Nesterov の加速勾配法

$$\begin{cases} x^{(k+1)} = y^{(k)} - s \nabla f(y^{(k)}) \\ y^{(k+1)} = x^{(k+1)} + \frac{k}{k+3} (x^{(k+1)} - x^{(k)}) \end{cases}$$

収束レート :

$$f(x^{(k)}) - f^* = O\left(\frac{1}{k^2}\right)$$

→

連続極限

$$\ddot{x} + \frac{3}{t} \dot{x} + \nabla f(x) = 0$$

収束レート :

$$f(x(t)) - f^* = O\left(\frac{1}{t^2}\right)$$

- 「加速」の直感的な理解
 - $\frac{3}{t} \dot{x}$ は「摩擦項」
 - 連続系の収束レートの証明は簡潔 (後述)
- Nesterov の加速勾配法の変種の導出
- 鏡像降下法との組合せ [Krichene et al., 2015]
- 強凸版との統合 [Kim and Yang, 2023]

Nesterov の加速勾配法

$$\begin{cases} x^{(k+1)} = y^{(k)} - s \nabla f(y^{(k)}) \\ y^{(k+1)} = x^{(k+1)} + \frac{k}{k+3} (x^{(k+1)} - x^{(k)}) \end{cases}$$

↓ 第二式の時刻をずらす

$$\begin{cases} x^{(k+1)} = y^{(k)} - s \nabla f(y^{(k)}) \\ y^{(k)} = x^{(k)} + \frac{k-1}{k+2} (x^{(k)} - x^{(k-1)}) \end{cases}$$

↓ 二式のを

$$x^{(k+1)} = x^{(k)} + \frac{k-1}{k+2} (x^{(k)} - x^{(k-1)}) - s \nabla f(y^{(k)})$$

連続極限

$$\ddot{x} + \frac{3}{t} \dot{x} + \nabla f(x) = 0$$

Nesterov の加速勾配法

$$\begin{cases} x^{(k+1)} = y^{(k)} - s \nabla f(y^{(k)}) \\ y^{(k+1)} = x^{(k+1)} + \frac{k}{k+3} (x^{(k+1)} - x^{(k)}) \end{cases}$$

↓

$$x^{(k+1)} = x^{(k)} + \frac{k-1}{k+2} (x^{(k)} - x^{(k-1)}) - s \nabla f(y^{(k)})$$

$$\downarrow \frac{k-1}{k+2} = 1 - \frac{3}{k+2}$$

$$\frac{x^{(k+1)} - 2x^{(k)} + x^{(k-1)}}{s} + \frac{3}{(k+2)\sqrt{s}} \frac{x^{(k)} - x^{(k-1)}}{\sqrt{s}} + \nabla f(y^{(k)}) = 0$$

連続極限

$$\ddot{x} + \frac{3}{t} \dot{x} + \nabla f(x) = 0$$

Nesterov の加速勾配法

$$\begin{cases} x^{(k+1)} = y^{(k)} - s \nabla f(y^{(k)}) \\ y^{(k+1)} = x^{(k+1)} + \frac{k}{k+3} (x^{(k+1)} - x^{(k)}) \end{cases}$$

連続極限

$$\ddot{x} + \frac{3}{t} \dot{x} + \nabla f(x) = 0$$

↓

↑ $\sqrt{s} \rightarrow 0$

$$\frac{x^{(k+1)} - 2x^{(k)} + x^{(k-1)}}{s} + \frac{3}{(k+2)\sqrt{s}} \frac{x^{(k)} - x^{(k-1)}}{\sqrt{s}} + \nabla f(y^{(k)}) = 0$$

↓
↓
↓
↓

\ddot{x}
 $\frac{3}{t}$
 \dot{x}
 x

(この離散化は不自然)

$$x^{(k)} \approx x(k\sqrt{s}) \text{ という想定}$$

以下の関数を用いて、収束レートを示す (x^* : 最適解) :

$$\mathcal{E}(t) := t^2(f(x(t)) - f^*) + 2 \left\| x(t) + \frac{t}{2} \dot{x}(t) - x^* \right\|^2$$

- ① $\frac{d}{dt} \mathcal{E}(t) \leq 0$: $\mathcal{E}(t)$ は単調非増加.

$$\begin{aligned} \frac{d}{dt} \mathcal{E}(t) &= 2t(f(x) - f^*) + t^2 \langle \nabla f(x), \dot{x} \rangle + 4 \left\langle x + \frac{t}{2} \dot{x} - x^*, \frac{3}{2} \dot{x} + \frac{t}{2} \ddot{x} \right\rangle \\ &= 2t(f(x) - f^*) - 2t \langle \nabla f(x), x - x^* \rangle \\ &\leq 0 \quad \leftarrow \text{凸関数は接線で下から抑えられる} \end{aligned}$$

$$\begin{aligned} &= -\frac{t}{2} \nabla f(x) \\ &\text{(前頁の ODE)} \end{aligned}$$

- ② 収束レートの証明 :

$$f(x(t)) - f^* \leq \frac{\mathcal{E}(t)}{t^2} \leq \frac{\mathcal{E}(0)}{t^2} = \frac{2 \|x(0) - x^*\|^2}{t^2}$$

Nesterov の加速勾配法

$$\begin{cases} x^{(k+1)} = y^{(k)} - s \nabla f(y^{(k)}) \\ y^{(k+1)} = x^{(k+1)} + \frac{k}{k+3} (x^{(k+1)} - x^{(k)}) \end{cases}$$

収束レート：

$$f(x^{(k)}) - f^* = O\left(\frac{1}{k^2}\right)$$

→

連続極限

$$\ddot{x} + \frac{3}{t} \dot{x} + \nabla f(x) = 0$$

収束レート：

$$f(x(t)) - f^* = O\left(\frac{1}{t^2}\right)$$

- 「加速」の直感的な理解
 - $\frac{3}{t} \dot{x}$ は「摩擦項」
 - 連続系の収束レートの証明は簡潔
- Nesterov の加速勾配法の変種の導出
- 鏡像降下法との組合せ [Krichene et al., 2015]
- 強凸版との統合 [Kim and Yang, 2023]

- ① 連続最適化問題に対する ODE アプローチの例
- ② 常微分方程式の数値解析の概要
- ③ 数値解法の安定性
- ④ 数値解法の精度 : Runge-Kutta 法
- ⑤ 数値解法の精度 : 線形多段階法
- ⑥ 構造保存数値解法
- ⑦ 微分方程式の数値解析の連続最適化への応用
- ⑧ まとめ

常微分方程式 (ODE: Ordinary Differential Equation) 14/100

常微分方程式の初期値問題 ($x: [0, T) \rightarrow \mathbb{R}^d$, $\dot{x} := \frac{dx}{dt}$)

$$\dot{x}(t) = g(t, x(t)) \quad (t \in (0, T)), \quad x(0) = x_0.$$

$g(t, \cdot)$ が局所 Lipschitz 連続であれば, 解は一意に存在する.

古典的な例

- 調和振動子 :

$$\begin{cases} \dot{p} = kx, \\ m\dot{x} = p. \end{cases}$$

- Lotka–Volterra 方程式 :

$$\begin{cases} \dot{x} = ax - bxy, \\ \dot{y} = cxy - dy. \end{cases}$$

近年の例

- 加速勾配法の連続極限
[Su et al., 2014] :

$$\ddot{x} + \frac{3}{t}\dot{x} + \nabla f(x) = 0.$$

- Neural ODE
[Chen et al., 2018] :

$$\dot{x} = f_{\text{NN}}(\theta, x, t).$$

陽的 Euler 法：

$$\frac{x^{(k+1)} - x^{(k)}}{h_k} = g(t_k, x^{(k)}) \quad (k = 0, 1, \dots), \quad x^{(0)} = x_0.$$

cf. ODE

$$\dot{x}(t) = g(t, x(t)) \quad (t \in (0, T)), \quad x(0) = x_0.$$

適切な仮定の下，

$$\|x^{(k)} - x(t_k)\| \leq Ch_{\max} \quad \left(h_{\max} := \max_i h_i \right).$$

- ステップ幅 h_k が十分小さいとき， $x^{(k)}$ は $x(t_k)$ の良い近似.
- 右辺が h_{\max} について 1 次なので，1 次精度という.

陽的 Euler 法 :

$$\frac{x^{(k+1)} - x^{(k)}}{h_k} = g(t_k, x^{(k)}) \quad (k = 0, 1, \dots), \quad x^{(0)} = x_0.$$

1 ステップの中に
内部段を作る

過去の情報の利用
($x^{(k-1)}$ など)

Runge-Kutta 法

- Heun 法
- いわゆる Runge-Kutta 法
- Dormand-Prince の方法
(MATLAB の ode45,
scipy.integrate.solve_ivp 等)

線形多段階法

- Adams-Bashforth 公式
- Adams-Moulton 公式
- 後退微分公式
(BDF: Backward
Differentiation Formula)

これらの共通の一般化 (一般線形法) や, これらに属さない手法もある。

定義：Runge-Kutta 法

$\dot{x} = g(t, x)$ に対する s 段 Runge-Kutta 法：

$$\begin{cases} X_i^{(k)} = x^{(k)} + h \sum_{j=1}^s a_{ij} g(t_k + c_j h, X_j^{(k)}) & (i = 1, \dots, s), \\ x^{(k+1)} = x^{(k)} + h \sum_{i=1}^s b_i g(t_k + c_i h, X_i^{(k)}). \end{cases}$$

$X_i^{(k)}$: 内部段

a_{ij}, b_i, c_i : パラメータ

例：陽的 Euler 法

$$\frac{x^{(k+1)} - x^{(k)}}{h} = g(t_k, x^{(k)}) \quad \longrightarrow \quad \begin{cases} X_1^{(k)} = x^{(k)} + h \cdot 0 \cdot g(t_k, X_1^{(k)}) \\ x^{(k+1)} = x^{(k)} + h \cdot 1 \cdot g(t_k, X_1^{(k)}) \end{cases}$$

問題設定 : 時刻 $T > 0$ の厳密解 $x(T)$ の誤差 $\varepsilon > 0$ 以内の近似の計算 (簡単のため, ステップ幅 $h := T/K$ は固定.)

- 陽的 Euler 法 : ベクトル場の計算回数 $O(\frac{1}{\varepsilon})$

$$\therefore \text{誤差評価 } \|x^{(K)} - x(T)\| \leq Ch = C\frac{T}{K} = \varepsilon \Rightarrow K = \frac{CT}{\varepsilon}$$


- p 次精度の Runge-Kutta 法 : ベクトル場の計算回数 $O\left(\left(\frac{1}{\varepsilon}\right)^{\frac{1}{p}}\right)$

$$\therefore \text{誤差評価 } \|x^{(K)} - x(T)\| \leq C_p h^p = C_p \left(\frac{T}{K}\right)^p = \varepsilon \Rightarrow K = T \left(\frac{C_p}{\varepsilon}\right)^{\frac{1}{p}}$$

数値例 :

$$\dot{x} = -x, T = 10.$$

要求精度が小さいとき,
次数が高いほど有利.



Runge–Kutta 法のパラメータは, [Butcher, 1964] に従って以下のように表示することが多い:

$$\begin{array}{c|ccc} c_1 & a_{11} & \cdots & a_{1s} \\ \vdots & \vdots & & \vdots \\ c_s & a_{s1} & \cdots & a_{ss} \\ \hline & b_1 & \cdots & b_s \end{array}$$

再掲: Runge–Kutta 法

$\dot{x} = g(t, x)$ に対する s 段 Runge–Kutta 法:

$$\begin{cases} X_i^{(k)} = x^{(k)} + h \sum_{j=1}^s a_{ij} g(t_k + c_j h, X_j^{(k)}) & (i = 1, \dots, s), \\ x^{(k+1)} = x^{(k)} + h \sum_{i=1}^s b_i g(t_k + c_i h, X_i^{(k)}). \end{cases}$$

定義：陽的 Runge-Kutta 法

Runge-Kutta 法が陽的 \iff 任意の $i \leq j$ に対して, $a_{ij} = 0$.
 そうでない場合, 陰的 Runge-Kutta 法と呼ばれる.

Heun 法 (陽的):

0	0	0	→	$X_1^{(k)}$ は陽的に計算可能
1	1	0	→	$X_2^{(k)}$ は陽的に計算可能
1/2	1/2	$X_2^{(k)} = x^{(k)} + h \cdot 1 \cdot g(t_k, X_1^{(k)}) + h \cdot 0 \cdot g(t_k + h, X_2^{(k)})$		

陰的台形則 (陰的):

0	0	0	→	$X_1^{(k)}$ は陽的に計算可能
1	1/2	1/2	→	$X_2^{(k)}$ は陽的に計算できない
1/2	1/2	$X_2^{(k)} = x^{(k)} + h \cdot \frac{1}{2} \cdot g(t_k, X_1^{(k)}) + h \cdot \frac{1}{2} \cdot g(t_k + h, X_2^{(k)})$		

- 1 次の方法:

陽的 Euler 法

$$\begin{array}{c|c} 0 & 0 \\ \hline & 1 \end{array}$$

陰的 Euler 法

$$\begin{array}{c|c} 1 & 1 \\ \hline & 1 \end{array}$$

- 2 次の方法:

陰的台形則

$$\begin{array}{c|cc} 0 & 0 & 0 \\ 1 & 1/2 & 1/2 \\ \hline & 1/2 & 1/2 \end{array}$$

陰的 midpoint 則

$$\begin{array}{c|c} 1/2 & 1/2 \\ \hline & 1 \end{array}$$

Heun 法

$$\begin{array}{c|cc} 0 & 0 & 0 \\ 1 & 1 & 0 \\ \hline & 1/2 & 1/2 \end{array}$$

- いわゆる Runge-Kutta 法 (4 次)

$$\begin{array}{c|ccc} 0 & & & \\ 1/2 & 1/2 & & \\ 1/2 & 0 & 1/2 & \\ 1 & 0 & 0 & 1 \\ \hline & 1/6 & 1/3 & 1/3 & 1/6 \end{array}$$

定義：線形多段階法（固定刻み幅）

$\dot{x} = g(t, x)$ に対する 線形 r 段階法：

$$\begin{aligned} & \alpha_r x^{(k+r)} + \alpha_{r-1} x^{(k+r-1)} + \cdots + \alpha_0 x^{(k)} \\ & = h(\beta_r g_{k+r} + \beta_{r-1} g_{k+r-1} + \cdots + \beta_0 g_k), \\ & g_k := g(t_k, x^{(k)}). \end{aligned}$$

α_i, β_i : パラメータ ($\alpha_r \neq 0, |\alpha_0| + |\beta_0| \neq 0$)

陽的 $\iff \beta_r = 0$, 陰的 $\iff \beta_r \neq 0$

例：陽的 Euler 法

$$\frac{x^{(k+1)} - x^{(k)}}{h} = g(t_k, x^{(k)})$$

$$\longrightarrow 1 \cdot x^{(k+1)} + (-1) \cdot x^{(k)} = h(0 \cdot g(t_{k+1}, x^{(k+1)}) + 1 \cdot g(t_k, x^{(k)}))$$

定義：線形多段階法（固定刻み幅）

$$\sum_{i=0}^r \alpha_i x^{(k+i)} = h \sum_{i=0}^r \beta_i g\left(t_{k+i}, x^{(k+i)}\right).$$

線形多段階法を用いるには，初期値 $x^{(0)}$ だけでなく，**出発値** $x^{(1)}, \dots, x^{(r-1)}$ も事前に用意しておく必要がある。

$x^{(i)} \approx x(ih)$ の計算法の例：

- 厳密解の Taylor 展開
- Runge-Kutta 法
- 低段階の多段階法

出発値が満たすべき条件は後述。

定義：線形多段階法（固定刻み幅）

$$\sum_{i=0}^r \alpha_i x^{(k+i)} = h \sum_{i=0}^r \beta_i g\left(t_{k+i}, x^{(k+i)}\right).$$

- Adams 型：積分表示の右辺を Lagrange 補間を用いて近似.

積分表示：
$$x(t_{k+r}) - x(t_{k+r-1}) = \int_{t_{k+r-1}}^{t_{k+r}} g(t, x(t)) dt.$$

- Adams–Bashforth 公式：陽的 ($x^{(k)}, \dots, x^{(k+r-1)}$) を用いる).
- Adams–Moulton 公式：陰的 ($x^{(k)}, \dots, x^{(k+r)}$) を用いる).
- 後退微分公式 (BDF)：ODE の左辺を高次の片側差分で近似.

$$\dot{x}(t_{k+r}) = g\left(t_{k+r}, x^{(k+r)}\right)$$

- ① 連続最適化問題に対する ODE アプローチの例
- ② 常微分方程式の数値解析の概要
- ③ 数値解法の安定性**
- ④ 数値解法の精度 : Runge-Kutta 法
- ⑤ 数値解法の精度 : 線形多段階法
- ⑥ 構造保存数値解法
- ⑦ 微分方程式の数値解析の連続最適化への応用
- ⑧ まとめ

目的関数は L -平滑 (勾配が L -Lipschitz 連続) とする.

凸関数に対する最急降下法の収束条件 cf. [Nesterov, 2004, Thm. 2.1.14]

最急降下法は, $h_k < 2/L$ のとき $f(x^{(k)}) \rightarrow f^*$ を満たす.

↓ 数値解析の言葉で言い換え

勾配流に対する陽的 Euler 法 (= 最急降下法) は,
 $h_k < 2/L$ のもとで平衡点に収束する.

数値解析の手法で同様の条件は出るか?

↓

線形安定性解析


定義：安定性と安定領域

Dahlquist のテスト方程式 ($\lambda \in \mathbb{C}$ は定数)

$$\dot{x} = \lambda x, \quad x(0) = 1$$

に対して 1 ステップ数値解法を適用した場合の出力を $R(h\lambda)$ とする。
このとき、 R を安定関数、 $S = \{z \in \mathbb{C} \mid |R(z)| \leq 1\}$ を安定領域という。

陽的 Euler 法の安定関数は $R(z) = 1 + z$



定義：安定性と安定領域

Dahlquist のテスト方程式 ($\lambda \in \mathbb{C}$ は定数) $\dot{x} = \lambda x$, $x(0) = 1$ に対して 1 ステップ数値解法を適用した場合の出力を $R(h\lambda)$ とする. このとき, R を安定性関数, $S = \{z \in \mathbb{C} \mid |R(z)| \leq 1\}$ を安定領域という.

与えられたパラメータ $\lambda \in \mathbb{C}$ に対して,
ステップ幅 h で数値解法を適用したとき,

$$x^{(k)} = (R(h\lambda))^k x^{(0)}.$$

\Rightarrow 「 $\sup_k |x^{(k)}| < \infty \iff |R(h\lambda)| \leq 1$ 」


安定領域の意味

与えられたパラメータ $\lambda \in \mathbb{C}$ に対して, $h\lambda \in S$ を満たすようにステップ幅 h を取れば, 数値解は有界に留まる.

ODE : 勾配流

- 勾配流 $\dot{x} = -\nabla f(x)$ の線形化 : $\dot{\delta} = -\nabla^2 f(x)\delta$
- f が L -平滑な凸関数 $\Rightarrow \nabla^2 f(x)$ の固有値は $[0, L]$ に含まれる.
- $\nabla^2 f(x)$ の対角化により, d 個の独立なスカラー線形方程式 (Dahlquist のテスト方程式) に分離できる.
- 分離後の各 ODE について, $\lambda \in [-L, 0]$.

数値解法 : 陽的 Euler 法の安定領域



安定領域の意味 :

$\forall \lambda \in [-L, 0], \lambda h \in S \Rightarrow$ 安定

$$\begin{array}{c} \Downarrow \\ h \leq \frac{2}{L} \end{array}$$

(最急降下法がよく知られているステップ幅上限を再現).

命題：RK 法の安定性関数 (cf. [Hairer and Wanner, 1996, IV, Prop. 3.2])

$A = (a_{ij})$, $b = (b_i)$ とおくと, RK 法の安定性関数 R は以下を満たす:

$$R(z) = \frac{\det(I - zA + z\mathbf{1}b^\top)}{\det(I - zA)}.$$

($I \in \mathbb{R}^{s \times s}$: 単位行列, $\mathbf{1} \in \mathbb{R}^s$: 全要素が 1 のベクトル)

- 陽的 RK の場合 (A が狭義下三角), R は s 次多項式.
- 陰的 RK の場合, R は有理関数
(分母, 分子ともに s 次以下の多項式).

Dahlquist のテスト方程式に, RK 法を適用すると, 直ちに

$$R(z) = 1 + zb^\top(I - zA)^{-1}\mathbf{1}$$

が得られる. 上の命題は Schur 補行列を使えば容易に示せる (演習問題).

s 段 p 次陽的 Runge–Kutta 法の安定性関数

- 安定性関数は s 次多項式
- Dahlquist のテスト方程式の厳密解 $x(h) = \exp(\lambda h)$
 $\rightarrow R(z)$ の p 次以下の係数は $\exp(z)$ の Taylor 展開と一致.
- $p = s$ の場合 ($s \leq 4$), $R(z) = 1 + z + \frac{z^2}{2!} + \cdots + \frac{z^s}{s!}$.




Fig. 2.1. Stability domains for explicit Runge-Kutta methods of order $p = s$




Fig. 2.2. Stability domains for DOPRI methods

[Hairer and Wanner, 1996] より引用.

Dahlquist のテスト方程式 $\dot{x} = \lambda x$ の厳密解 $x(t) = \exp(\lambda t)$ が有界



$$\iff \lambda \in \mathbb{C}^- := \{z \in \mathbb{C} \mid \operatorname{Re} z \leq 0\}$$

定義：A 安定性

数値解法が A 安定 \iff 安定性領域 S が $S \supseteq \mathbb{C}^-$ を満たす.

- A 安定な数値解法：

陰的 Euler 法 (1 段 1 次), Gauss 法 (s 段 $2s$ 次), ...



- 1 次以上の精度をもつ陽的 Runge-Kutta 法は A 安定にならない.

線形多段階法には、よく考えられる安定性が2種類ある：

- 絶対安定性：Dahlquist のテスト方程式に対する安定性
- 零安定性： $\dot{x} = 0$ に対する安定性 ← 多段階法特有の問題

線形 r 段階法は、 $r + 1$ 項間漸化式なので、安定性の議論において、特性多項式が有用。

定義：特性多項式

第一特性多項式： $\rho(\zeta) := \alpha_r \zeta^r + \alpha_{r-1} \zeta^{r-1} + \cdots + \alpha_0,$

第二特性多項式： $\sigma(\zeta) := \beta_r \zeta^r + \beta_{r-1} \zeta^{r-1} + \cdots + \beta_0.$

線形多段階法を (ρ, σ) で表すこともある。

復習：線形 r 段階法 (固定刻み幅)

$$\sum_{i=0}^r \alpha_i x^{(k+i)} = h \sum_{i=0}^r \beta_i g(t_{k+i}, x^{(k+i)}).$$

定義：零安定性

線形多段階法 (ρ, σ) が**零安定**

\iff 第一特性多項式 ρ が以下の条件 (根条件) を満たす.

- 全ての根の絶対値が 1 以下 ;
- 根の絶対値がちょうど 1 であるとき, 単根である.

零安定性の意味 :

$\dot{x} = 0$ に線形多段階法 (ρ, σ) を適用した

$$\alpha_r x^{(k+r)} + \alpha_{r-1} x^{(k+r-1)} + \cdots + \alpha_0 x^{(k)} = 0$$

の解が有界に留まる.

ラフな説明 : ρ が相異なる r 個の根 ζ_1, \dots, ζ_r をもつとき,

$$x^{(k)} = C_1 \zeta_1^k + C_2 \zeta_2^k + \cdots + C_r \zeta_r^k$$

(C_1, \dots, C_r は出発値から定まる).


陽的 2 段階法 (3 次精度)

$$x^{(k+2)} + 4x^{(k+1)} - 5x^{(k)} = h \left(4g \left(t_{k+1}, x^{(k+1)} \right) + 2g \left(t_k, x^{(k)} \right) \right)$$

の第一特性多項式 $\rho(\zeta) = \zeta^2 + 4\zeta - 5$ の根は $1, -5 \Rightarrow$ 零安定でない.

数値実験 ($\dot{x} = 0$):

2 通りの初期値 $0, 1.01$ に対して, $x^{(1)}$ をそれぞれ $0, 1.01$ (厳密解) とした.
ステップ幅 h を小さくすると, 数値計算結果は発散 (丸め誤差の拡大).



Dahlquist のテスト方程式 $\dot{x} = \lambda x$ に対する線形多段階法

$$\sum_{i=0}^r \alpha_i x^{(k+i)} = \lambda h \sum_{i=0}^r \beta_i x^{(k+i)}.$$

この漸化式の特性多項式： $\rho(\zeta) - \lambda h \sigma(\zeta)$.

定義：絶対安定性

線形多段階法 (ρ, σ) の絶対安定領域：

$$S := \{ z \in \mathbb{C} \mid \pi(\zeta; z) := \rho(\zeta) - z\sigma(\zeta) \text{ が根条件を満たす} \}.$$

$S \supseteq \mathbb{C}^-$ のとき，A 安定という。

(復習) 根条件：

- 全ての根の絶対値が 1 以下；
- 根の絶対値がちょうど 1 であるとき，単根である。

μ -強凸 L -平滑関数に対する Nesterov の加速勾配法

$$y^{(k+1)} = x^{(k)} - \frac{1}{L} \nabla f(x^{(k)}),$$

$$x^{(k+1)} = y^{(k+1)} + \gamma(y^{(k+1)} - y^{(k)}), \quad \gamma := \frac{1 - \sqrt{\frac{\mu}{L}}}{1 + \sqrt{\frac{\mu}{L}}}.$$

y を消去すると,

$$x^{(k+1)} - (1 + \gamma)x^{(k)} + \gamma x^{(k-1)} = \frac{1 + \gamma}{L} \left(-\nabla f(x^{(k)}) \right) - \frac{\gamma}{L} \left(-\nabla f(x^{(k-1)}) \right).$$

$h = \frac{1}{L(1-\gamma)}$ とする (後述).

加速勾配法に対応する線形多段階法

$$x^{(k+2)} - (1 + \gamma)x^{(k+1)} + \gamma x^{(k)} = h \left((1 - \gamma^2)g(x^{(k+1)}) - \gamma(1 - \gamma)g(x^{(k)}) \right)$$


加速勾配法に対応する線形多段階法

$$x^{(k+2)} - (1+\gamma)x^{(k+1)} + \gamma x^{(k)} = h \left((1-\gamma^2)g(x^{(k+1)}) - \gamma(1-\gamma)g(x^{(k)}) \right)$$

上の線形多段階法について $\left(\gamma = \left(1 - \sqrt{\frac{\mu}{L}} \right) / \left(1 + \sqrt{\frac{\mu}{L}} \right) \right)$,

$$\rho(\zeta) = \zeta^2 - (1+\gamma)\zeta + \gamma, \quad \sigma(\zeta) = (1-\gamma^2)\zeta - \gamma(1-\gamma),$$

$$\pi(\zeta; z) = \rho(\zeta) - z\sigma(\zeta) = \zeta^2 - (1+\gamma)(1+z(1-\gamma))\zeta + \gamma(1+z(1-\gamma)).$$




安定領域の形状は L/μ に依存.

安定領域の左端 $\approx -\frac{2}{3}\sqrt{\frac{L}{\mu}}$ (演習問題).

勾配流の場合は $\lambda \in [-L, 0]$ に相当
 \Rightarrow 刻み幅制限は $O(1/\sqrt{\mu L})$.

目的関数 $f: \mathbb{R}^d \rightarrow \mathbb{R}$ が μ -強凸 (かつ L -平滑) の場合 (f^* : 最適値)



数値解析でよく知られている「安定性」の条件から,

- 陽的 Euler 法 : $h_k = O\left(\frac{1}{L}\right) \rightarrow t_k := \sum_{i=0}^{k-1} h_i = O\left(\frac{k}{L}\right)$,
- 線形多段階法 : $h_k = O\left(\frac{1}{\sqrt{\mu L}}\right) \rightarrow t_k = O\left(\frac{k}{\sqrt{\mu L}}\right)$.

- ① 連続最適化問題に対する ODE アプローチの例
- ② 常微分方程式の数値解析の概要
- ③ 数値解法の安定性
- ④ 数値解法の精度 : Runge-Kutta 法
- ⑤ 数値解法の精度 : 線形多段階法
- ⑥ 構造保存数値解法
- ⑦ 微分方程式の数値解析の連続最適化への応用
- ⑧ まとめ

一般的な非自励系 $\dot{x} = g(t, x)$ に対して, 自励系

$$\frac{d}{dt} \begin{bmatrix} x \\ s \end{bmatrix} = \begin{bmatrix} g(s, x) \\ 1 \end{bmatrix}$$

を考えると, $s = t$ より両者は等価 \Rightarrow (大抵の場合) 自励系を考えれば十分.

例: Runge-Kutta 法

上記の自励系に対する Runge-Kutta 法

$$X_i^{(k)} = x^{(k)} + h \sum_{j=1}^s a_{ij} g(S_j^{(k)}, X_j^{(k)}), \quad S_i^{(k)} = s^{(k)} + h \sum_{j=1}^s a_{ij},$$

$$x^{(k+1)} = x^{(k)} + h \sum_{i=1}^s b_i g(S_i^{(k)}, X_i^{(k)}), \quad s^{(k+1)} = s^{(k)} + h \sum_{i=1}^s b_i.$$

$c_i = \sum_{j=1}^s a_{ij}$, $\sum_{i=1}^s b_i = 1$ の下, 前述の Runge-Kutta 法と一致.

$$\text{局所誤差評価：} \quad \left\| x^{(1)} - x(h) \right\| \leq Ch^{p+1}$$

大域誤差評価：

ODE に沿って時間 h 進める写像 (flow map) $\varphi_h: \mathbb{R}^d \rightarrow \mathbb{R}^d$ を用いて、誤差 $e^{(k)} := \left\| x^{(k)} - x(kh) \right\|$ を評価：

$$e^{(k+1)} \leq \left\| x^{(k+1)} - \varphi_h(x^{(k)}) \right\| + \left\| \varphi_h(x^{(k)}) - \varphi_h(x(kh)) \right\|$$

局所誤差

ODE の性質

$$\leq Ch^{p+1} + \exp(Lh)e^{(k)}$$

$$\Rightarrow e^{(k)} \leq C \exp(Lkh)kh^{p+1} \leq C \exp(LT)Th^p \quad (\because kh \leq T).$$

ODE の性質 (演習問題)

ODE を定める写像 g が L -Lipschitz 連続のとき、

$$\left\| \varphi_h(x) - \varphi_h(y) \right\| \leq \exp(Lh) \|x - y\| \quad (x, y \in \mathbb{R}^d).$$

定義：Runge-Kutta 法の精度

Runge-Kutta 法が p 次精度である

\iff 十分滑らかな任意の ODE に対して、以下の局所誤差評価が成立：

$$\|x^{(1)} - x(h)\| \leq Ch^{p+1}.$$

自励系 $\dot{x} = g(x)$ に対する Runge-Kutta 法

$$\begin{cases} X_i^{(k)} = x^{(k)} + h \sum_{j=1}^s a_{ij} g(X_j^{(n)}) & (i = 1, \dots, s), \\ x^{(k+1)} = x^{(k)} + h \sum_{i=1}^s b_i g(X_i^{(k)}). \end{cases}$$

以下の展開より、 $\|x^{(1)} - x(h)\| \leq Ch^2$ が成立：

$$\begin{aligned} \text{数値解：} \quad x^{(1)} &= x^{(0)} + hg(x^{(0)}) \\ &= \underline{x_0 + hg(x_0)}. \end{aligned}$$

$$\begin{aligned} \text{厳密解：} \quad x(h) &= x(0) + h \frac{dx}{dt}(0) + \frac{h^2}{2} \frac{d^2x}{dt^2}(0) + \cdots \\ &= \underline{x(0) + hg(x_0)} + \frac{h^2}{2} g'(x_0)g(x_0) + \cdots. \end{aligned}$$

ここで、以下の関係式を用いた：

$$\begin{aligned} \frac{dx}{dt}(t) &= g(x(t)), \\ \frac{d^2x}{dt^2}(t) &= \frac{d}{dt}g(x(t)) = g'(x(t)) \frac{dx}{dt}(t) = g'(x(t))g(x(t)). \end{aligned}$$

p 次精度の Runge-Kutta 法を扱うには、 $\frac{d^k x}{dt^k}(0)$ ($k = 1, \dots, p$) が必要.

注意：

- $x(t)$ は引数を省略して x と書く。
- $g_{i_1 i_2 \dots i_n}^j := \frac{\partial^n g^j}{\partial x^{i_1} \partial x^{i_2} \dots \partial x^{i_n}}$ とする。ここで $g(x) = (g^1(x), \dots, g^d(x))^\top$ 。
- Einstein の和の規約を利用する。

$$\frac{dx^i}{dt} = g^i(x)$$

$$\frac{d^2 x^i}{dt^2} = \frac{d}{dt} g^i(x) = g_{jk}^i(x) \frac{dx^j}{dt} = g_{jk}^i(x) g^j(x)$$

$$\frac{d^3 x^i}{dt^3} = \frac{d}{dt} (g_{jk}^i(x) g^j(x)) = g_{jkl}^i(x) g^j(x) g^k(x) + g_{jk}^i(x) g_k^j(x) g^k(x)$$



$$\frac{d^4 x^i}{dt^4} = \frac{d}{dt} (g_{jkl}^i(x) g^j(x) g^k(x) + g_{jk}^i(x) g_k^j(x) g^k(x)) = \dots$$

容易に計算できるが、煩雑。






$$\frac{d^2 x^i}{dt^2} = \underline{g_j^i(x) g^j(x)}.$$



$$\frac{d^3 x^i}{dt^3} = \underline{g_{jk}^i(x) g^j(x) g^k(x)} + \underline{g_j^i(x) g_k^j(x) g^k(x)}$$




$$\frac{d^4 x^i}{dt^4} = g_{jkl}^i g^j g^k g^l + g_{jk}^i g_l^j g^l g^k + g_{jk}^i g^j g_l^k g^l + g_{jl}^i g_k^j g^k g^l + g_j^i g_{kl}^j g^k g^l + g_j^i g_k^j g_l^k g^l$$



これらの項は同一：単なるインデックスの付け替え

$$\frac{d^4 x^i}{dt^4} = g_{jkl}^i g^j g^k g^l + g_{jk}^i g_l^j g^l g^k + g_{jk}^i g^j g_l^k g^l + g_{jl}^i g_k^j g^k g^l + g_j^i g_{kl}^j g^k g^l + g_j^i g_k^j g_l^k g^l$$





これらのラベル付き木は形状が同じ



$x(t)$ の高階導関数は根つき木で整理できる。

定義：ラベルつき木

全順序集合 S_q が、最小の要素 i をもち、 $|S_q| = q$ を満たすとする。このとき、 q 次の (根つき) ラベルつき木とは、写像 $\tau: S_q \setminus \{i\} \rightarrow S_q$ であり、任意の $z \in S_q$ に対して、 $\tau(z) < z$ を満たすものである。次数 q のラベルつき木全体のなす集合を \mathcal{LT}_q で表す。

 \mathcal{LT}_3 : $(S_3 = \{i < j < k\})$  \mathcal{LT}_4 : $(S_4 = \{i < j < k < l\})$ 

定義：根つき木

根つき木の集合 \mathcal{T} を以下のように再帰的に定義する：

- 頂点を1つだけもつグラフ \bullet は \mathcal{T} に属す；
- $\tau_1, \dots, \tau_m \in \mathcal{T}$ であるとき, τ_1, \dots, τ_m の根を新たに用意した一つの頂点に繋げてできるグラフも \mathcal{T} に属す. この操作を

$$\tau = [\tau_1, \dots, \tau_m]$$

と表す. ここで, 新たに導入した頂点が τ の根である.

注意： $[\tau_1, \dots, \tau_m]$ は τ_1, \dots, τ_m の並べ方に依存しない.

例：

$$\bullet = [\bullet], \quad \begin{array}{c} \bullet \\ | \\ \bullet \end{array} = [\bullet, \bullet], \quad \begin{array}{c} \bullet \\ | \\ \bullet \\ | \\ \bullet \end{array} = [\bullet] = [[\bullet]]$$

$$\begin{array}{c} \bullet \\ | \\ \bullet \\ | \\ \bullet \end{array} = [\bullet, \bullet, \bullet], \quad \begin{array}{c} \bullet \\ | \\ \bullet \\ | \\ \bullet \\ | \\ \bullet \end{array} = [\bullet, \bullet] = [\bullet, [\bullet]]$$

$$\mathcal{T} = \left\{ \bullet, \begin{array}{c} \bullet \\ | \\ \bullet \end{array}, \begin{array}{c} \bullet \\ | \\ \bullet \\ | \\ \bullet \end{array}, \begin{array}{c} \bullet \\ | \\ \bullet \\ | \\ \bullet \\ | \\ \bullet \end{array}, \begin{array}{c} \bullet \\ | \\ \bullet \\ | \\ \bullet \\ | \\ \bullet \\ | \\ \bullet \end{array}, \dots \right\}.$$

定義：要素的微分

木 $\tau \in \mathcal{T}$ に対して、要素的微分とは、 $G(\bullet)(x) = g(x)$ と

$$G^i([\tau_1, \dots, \tau_m])(x) = g_{j_1, \dots, j_m}^i(x) G^{j_1}(\tau_1)(x) \cdots G^{j_m}(\tau_m)(x)$$

により再帰的に定義される写像 $G(\tau): \mathbb{R}^d \rightarrow \mathbb{R}^d$ である。

例：

$$G^i(\bullet)(x) = G^i([\bullet])(x) = g_j^i(x) G^j(\bullet)(x) = g_j^i(x) g^j(x)$$

$$G^i(\bullet\bullet)(x) = G^i([\bullet, \bullet])(x) = g_{jk}^i(x) G^j(\bullet)(x) G^k(\bullet)(x) = g_{jk}^i(x) g^j(x) g^k(x)$$

$$G^i(\bullet\bullet\bullet)(x) = G^i([\bullet\bullet])(x) = g_j^i(x) G^j(\bullet\bullet)(x) = g_j^i(x) g_k^j(x) g^k(x)$$

「根を除いた頂点の個数」 = 「微分の階数」

定理 : 厳密解 $x(t)$ の q 階導関数 cf. [Hairer et al., 1993, II, Thm. 2.6]

$$\frac{d^q x}{dt^q}(0) = \sum_{|\tau|=q} \alpha(\tau) G(\tau)(x_0).$$

ここで,

- $|\tau|$ は, $\tau \in \mathcal{T}$ の頂点の個数を表す ;
- $\alpha(\tau)$ は, τ と同値なラベルつき木の個数を表す.

τ								
$ \tau $	1	2	3	3	4	4	4	4
$\alpha(\tau)$	1	1	1	1	1	3	1	1

Runge–Kutta 法の内部段 $X_i^{(1)}$ (と出力 $y^{(1)}$) の h に関する Taylor 展開:

$$\begin{aligned} X_i^{(1)}(0) &= x_0 \\ \frac{d}{dh} X_i^{(1)}(0) &= \sum_{j=1}^s a_{ij} g \left(X_j^{(1)}(h) \right) \\ &\quad + h \sum_{j=1}^s a_{ij} g' \left(X_j^{(1)}(h) \right) \left(\frac{d}{dh} X_j^{(1)}(h) \right) \Big|_{h=0} \\ &= \sum_{j=1}^s a_{ij} g(x_0) \end{aligned}$$

$$\begin{cases} X_i^{(1)} = x_0 + h \sum_{j=1}^s a_{ij} g \left(X_j^{(1)} \right) & (i = 1, \dots, s), \\ x^{(1)} = x_0 + h \sum_{i=1}^s b_i g \left(X_i^{(1)} \right). \end{cases}$$

引数 h は省略する.

$$\begin{aligned}\frac{d^2}{dh^2}X_i^{(1)}(h) &= \frac{d}{dh} \left(\sum_{j=1}^s a_{ij}g \left(X_j^{(1)} \right) + h \sum_{j=1}^s a_{ij}g' \left(X_j^{(1)} \right) \left(\frac{d}{dh}X_j^{(1)} \right) \right) \\ &= 2 \sum_{j=1}^s a_{ij}g' \left(X_j^{(1)} \right) \left(\frac{d}{dh}X_j^{(1)} \right) + h \sum_{j=1}^s a_{ij}g'' \left(X_j^{(1)} \right) \left(\frac{d}{dh}X_j^{(1)}, \frac{d}{dh}X_j^{(1)} \right) \\ &\quad + h \sum_{j=1}^s a_{ij}g' \left(X_j^{(1)} \right) \left(\frac{d^2}{dh^2}X_j^{(1)} \right)\end{aligned}$$

↓


$$\begin{aligned}\frac{d^2}{dh^2}X_i^{(1)}(0) &= 2 \sum_{j=1}^s a_{ij}g' (x_0) \left(\sum_{k=1}^s a_{jk}g (x_0) \right) \\ &= 2 \sum_{j=1}^s \sum_{k=1}^s a_{ij}a_{jk}g'(g)\end{aligned}$$

$$\begin{aligned}
\frac{d^3}{dh^3} X_i^{(1)}(h) &= \frac{d}{dh} \left(2 \sum_{j=1}^s a_{ij} g' \left(X_j^{(1)} \right) \frac{d}{dh} X_j^{(1)} + h \sum_{j=1}^s a_{ij} g'' \left(X_j^{(1)} \right) \left(\frac{d}{dh} X_j^{(1)}, \frac{d}{dh} X_j^{(1)} \right) \right. \\
&\quad \left. + h \sum_{j=1}^s a_{ij} g' \left(X_j^{(1)} \right) \frac{d^2}{dh^2} X_j^{(1)} \right) \\
&= 3 \sum_{j=1}^s a_{ij} g'' \left(X_j^{(1)} \right) \left(\frac{d}{dh} X_j^{(1)}, \frac{d}{dh} X_j^{(1)} \right) + 3 \sum_{j=1}^s a_{ij} g' \left(X_j^{(1)} \right) \frac{d^2}{dh^2} X_j^{(1)} \\
&\quad + h \sum_{j=1}^s a_{ij} g''' \left(X_j^{(1)} \right) \left(\frac{d}{dh} X_j^{(1)}, \frac{d}{dh} X_j^{(1)}, \frac{d}{dh} X_j^{(1)} \right) \\
&\quad + 3h \sum_{j=1}^s a_{ij} g'' \left(X_j^{(1)} \right) \left(\frac{d^2}{dh^2} X_j^{(1)}, \frac{d}{dh} X_j^{(1)} \right) + h \sum_{j=1}^s a_{ij} g' \left(X_j^{(1)} \right) \frac{d^3}{dh^3} X_j^{(1)}
\end{aligned}$$


↓

$$\begin{aligned}
\frac{d^3}{dh^3} X_i^{(1)}(0) &= 3 \sum_{j=1}^s a_{ij} \left(g''(x_0) \left(\sum_{k=1}^s a_{jk} g(x_0), \sum_{l=1}^s a_{jl} g(x_0) \right) + g'(x_0) \frac{d^2}{dh^2} X_j^{(1)}(0) \right) \\
&= 3 \sum_{j,k,l} a_{ij} a_{jk} a_{jl} g''(g, g) + 3 \sum_{j,k,l} a_{ij} a_{jk} a_{kl} g'(g'(g)).
\end{aligned}$$

$$\frac{d^2}{dh} X_i^{(1)} = 2 \sum_{j,k} a_{ij} a_{jk} g'(g)$$



$$\frac{d^3}{dh^3} X_i^{(1)}(0) = 3 \sum_{j,k,l} a_{ij} a_{jk} a_{jl} g''(g, g) + 3 \sum_{j,k,l} a_{ij} a_{jk} a_{kl} g'(g'(g))$$



⋮

定理： RK 法にまつわる q 階導関数 cf. [Hairer et al., 1993, II, Thm. 2.11]

$$\frac{d^q}{dh^q} X_i^{(1)}(0) = \sum_{|\tau|=q} \alpha(\tau) \tau! \sum_{j=1}^s a_{ij} \Phi_j(\tau) G(\tau)(x_0),$$

$$\frac{d^q}{dh^q} y^{(1)}(0) = \sum_{|\tau|=q} \alpha(\tau) \tau! \sum_{i=1}^s b_i \Phi_i(\tau) G(\tau)(x_0),$$

- 木 τ の階乗 $\tau!$ は、 $0! = 1$ と以下の式で再帰的に定義される：

$$[\tau_1, \dots, \tau_m]! = |[\tau_1, \dots, \tau_m]| (\tau_1!) \cdots (\tau_m!);$$

- Φ_j は、 $\Phi_j(\bullet) = 1$ と以下の式で再帰的に定義される：

$$\Phi_j([\tau_1, \dots, \tau_m]) = \sum_{k_1, \dots, k_m} a_{jk_1} a_{jk_2} \cdots a_{jk_m} \Phi_{k_1}(\tau_1) \cdots \Phi_{k_m}(\tau_m).$$

定義 : B 級数

写像 $\delta: \mathcal{T} \cup \{\emptyset\} \rightarrow \mathbb{R}$ に対して, 以下の形式的級数を B 級数という :

$$B(\delta, x_0) = \delta(\emptyset)x_0 + \sum_{\tau \in \mathcal{T}} \frac{h^{|\tau|}}{\sigma(\tau)} \delta(\tau) G(\tau)(x_0)$$

対称度 $\sigma(\tau)$ は, $\sigma(\bullet) = 1$ と以下の式で定義される :

$$\sigma([\tau_1, \dots, \tau_m]) = \sigma(\tau_1) \cdots \sigma(\tau_m) \mu_1! \mu_2! \cdots$$

ここで, 整数 μ_1, μ_2, \dots は τ_1, \dots, τ_m の中の同じ木の個数である.

例 :

$$\sigma(\bullet) = \sigma([\bullet]) = 1,$$

$$\sigma(\bullet\bullet) = \sigma([\bullet, \bullet]) = 1 \cdot 1 \cdot 2!$$

$$\sigma(\bullet\bullet\bullet) = \sigma([\bullet\bullet]) = 1$$

$$\sigma(\bullet\bullet\bullet\bullet) = \sigma([\bullet, \bullet, \bullet]) = 1 \cdot 1 \cdot 1 \cdot 3!$$

$$\sigma(\bullet\bullet\bullet) = \sigma([\bullet, \bullet\bullet]) = 1 \cdot 1$$

$$\sigma(\bullet\bullet\bullet) = \sigma([\bullet\bullet\bullet]) = 2$$

厳密解の Taylor 展開 :

$$x(h) = \mathbf{1} \cdot x_0 + \sum_{\tau \in \mathcal{T}} \frac{h^{|\tau|}}{\sigma(\tau)} \frac{1}{\tau!} G(\tau)(x_0)$$

Runge–Kutta 法の出力の Taylor 展開 :

$$x^{(1)}(h) = \mathbf{1} \cdot x_0 + \sum_{\tau \in \mathcal{T}} \frac{h^{|\tau|}}{\sigma(\tau)} \sum_{i=1}^s b_i \Phi_i(\tau) G(\tau)(x_0)$$

$$B(\delta, x_0) = \delta(\emptyset) x_0 + \sum_{\tau \in \mathcal{T}} \frac{h^{|\tau|}}{\sigma(\tau)} \delta(\tau) G(\tau)(x_0)$$

定理：次数条件 cf. [Hairer et al., 1993, II, Thm. 2.13]

Runge–Kutta 法が p 次精度 \iff

$$\sum_{i=1}^s b_i \Phi_i(\tau) = \frac{1}{\tau!} \quad \text{for } |\tau| \leq p.$$

厳密解：
$$x(h) = 1 \cdot x_0 + \sum_{\tau \in \mathcal{T}} \frac{h^{|\tau|}}{\sigma(\tau)} \frac{1}{\tau!} G(\tau)(x_0),$$

数値解：
$$x^{(1)}(h) = 1 \cdot x_0 + \sum_{\tau \in \mathcal{T}} \frac{h^{|\tau|}}{\sigma(\tau)} \sum_{i=1}^s b_i \Phi_i(\tau) G(\tau)(x_0),$$

Table: 次数条件の個数

次数 p	1	2	3	4	5	6	7	8	9	10
条件の数	1	2	4	8	17	37	85	200	486	1205

$$\sum_{i=1}^s b_i \Phi_i(\tau) = \frac{1}{\tau!} \quad \text{for } |\tau| \leq p.$$

$$\bullet \quad \sum_i b_i = 1$$

$$\bullet \quad \sum_{i,j} b_i a_{ij} = \frac{1}{2}$$

$$\bullet \quad \sum_{i,j,k} b_i a_{ij} a_{ik} = \frac{1}{3}$$

$$\bullet \quad \sum_{i,j,k} b_i a_{ij} a_{jk} = \frac{1}{6}$$

$$\bullet \quad \sum_{i,j,k,l} b_i a_{ij} a_{ik} a_{il} = \frac{1}{4}$$

$$\bullet \quad \sum_{i,j,k,l} b_i a_{ij} a_{ik} a_{kl} = \frac{1}{8}$$

$$\bullet \quad \sum_{i,j,k,l} b_i a_{ij} a_{jk} a_{jl} = \frac{1}{12}$$

$$\bullet \quad \sum_{i,j,k,l} b_i a_{ij} a_{jk} a_{kl} = \frac{1}{24}$$

p : 次数, s : 段数

- $p = s$ を満たす陽的 Runge–Kutta 法は, $p \leq 4$ で存在する.
- $p \geq 5$ 次精度の陽的 Runge–Kutta 法は, $s \geq p + 1$ 段必要.
- $p \geq 7$ 次精度の陽的 Runge–Kutta 法は, $s \geq p + 2$ 段必要.
- $p \geq 8$ 次精度の陽的 Runge–Kutta 法は, $s \geq p + 3$ 段必要.

- [Hairer, 1978] が, 17 段 10 次の陽的 Runge–Kutta 法を提案.
注 : 決めるべきパラメータ 153 個, 満たすべき次数条件 1205 個.

- 40 年以上を経て, [Zhang, 2019] は,
16 段 10 次の陽的 Runge–Kutta 法が構成できたと主張している.
ただし, これは次数条件を最小二乗問題として数値的に解いた結果.
(BFGS 法と, いろいろな実装上の工夫の賜物とのこと.)

- 任意の正整数 p に対して, $s = p(p - 1)/2 + 1$ 段の
 p 次陽的 Runge–Kutta 法が存在 (非実用的) [Zhang, 2019, Prop. 1.28].

選点法 (陰的 Runge–Kutta 法とも解釈できる)

c_1, \dots, c_s を相異なる実数とする. s 次選点多項式 u を

$$u(t_k) = x^{(k)}, \quad \dot{u}(t_k + c_i h) = g(u(t_k + c_i h)) \quad (i = 1, \dots, s)$$

から定め, $x^{(k+1)} = u(t_k + h)$ を出力とする.

定理 : 選点法の次数 cf. [Hairer et al., 2006, II, Thm. 1.5]

選点法の精度 p は, c_1, \dots, c_s を用いる数値積分公式の次数と一致する.

数値積分 :

$$\int_0^1 f(x) dx \approx \frac{1}{s} \sum_{i=1}^s b_i f(c_i)$$

Gauss 法 : shifted Legendre 多項式の零点を c_i として用いると, $p = 2s$.

- ① 連続最適化問題に対する ODE アプローチの例
- ② 常微分方程式の数値解析の概要
- ③ 数値解法の安定性
- ④ 数値解法の精度 : Runge-Kutta 法
- ⑤ 数値解法の精度 : 線形多段階法**
- ⑥ 構造保存数値解法
- ⑦ 微分方程式の数値解析の連続最適化への応用
- ⑧ まとめ

線形多段階法における局所誤差： $\|x^{(r)} - x(rh)\|$

ただし、 $x^{(1)}, \dots, x^{(r-1)}$ は正確な出発値 $x^{(i)} = x(ih)$ ($i = 1, \dots, r-1$).

復習：線形 r 段階法 (固定刻み幅)

$$\sum_{i=0}^r \alpha_i x^{(k+i)} = h \sum_{i=0}^r \beta_i g(t_{k+i}, x^{(k+i)}).$$

定義と、「正確な出発値」の仮定より、(簡潔性のため、自励系とする)
 $\dot{x}(ih)$

$$\sum_{i=0}^r \left(\alpha_i x(ih) - h \beta_i g(x(ih)) \right) = \alpha_r \left(x(rh) - x^{(r)} \right)$$

||

$$- h \beta_r \left(g(x(rh)) - g(x^{(r)}) \right)$$

$$\mathcal{L}(x; h) := \sum_{i=0}^r \left(\alpha_i x(ih) - h \beta_i \dot{x}(ih) \right)$$

$$= \left(\alpha_r I - h \beta_r \frac{\partial g}{\partial x}(\eta) \right) \left(x(rh) - x^{(r)} \right)$$

(最後の等号は平均値の定理より従う)

前ページで確認したこと：

$$\mathcal{L}(x; h) := \sum_{i=0}^r (\alpha_i x(ih) - h\beta_i \dot{x}(ih)) \approx \alpha_r (x(rh) - x^{(r)}).$$

p 次精度 ($\|x^{(r)} - x(rh)\| \leq Ch^{p+1}$)

\iff 十分滑らかな $x: \mathbb{R} \rightarrow \mathbb{R}^d$ について, $\|\mathcal{L}(x; h)\| \leq C'h^{p+1}$.

$\iff p$ 次以下の多項式 P について, $\mathcal{L}(P; h) = 0$.

定理：線形多段階法の次数 [Hairer et al., 1993, III, Thm. 2.4]

線形多段階法 (ρ, σ) が p 次精度

$$\iff \sum_{i=0}^r \alpha_i = 0 \quad \text{かつ} \quad \sum_{i=0}^r \alpha_i i^q = q \sum_{i=0}^r \beta_i i^{q-1} \quad (q = 1, \dots, p).$$

μ -強凸 L -平滑関数に対する Nesterov の加速勾配法の書き換え：

$$\underbrace{1}_{\alpha_2} x^{(k+1)} + \underbrace{(-1-\gamma)}_{\alpha_1} x^{(k)} + \underbrace{\gamma}_{\alpha_0} x^{(k-1)} = \underbrace{\frac{1+\gamma}{L}}_{h\beta_1} \left(-\nabla f(x^{(k)}) \right) + \underbrace{\frac{-\gamma}{L}}_{h\beta_0} \left(-\nabla f(x^{(k-1)}) \right).$$

- $\sum_{i=0}^2 \alpha_i = \gamma + (-1 - \gamma) + 1 = 0.$
- $q = 1$ の条件：

$$0 = \sum_{i=0}^2 \alpha_i i - \sum_{i=0}^2 \beta_i = 1 - \gamma - \frac{1}{hL} \quad \Rightarrow \quad h = \frac{1}{L(1-\gamma)}.$$

定理：線形多段階法の次数条件 [Hairer et al., 1993, III, Thm. 2.4]

$$p \text{ 次} \iff \sum_{i=0}^r \alpha_i = 0 \quad \text{かつ} \quad \sum_{i=0}^r \alpha_i i^q = q \sum_{i=0}^r \beta_i i^{q-1} \quad (q = 1, \dots, p).$$

加速勾配法に対応する線形多段階法

$$x^{(k+2)} - (1+\gamma)x^{(k+1)} + \gamma x^{(k)} = h \left((1-\gamma^2)g(x^{(k+1)}) - \gamma(1-\gamma)g(x^{(k)}) \right)$$

定理：線形多段階法の次数条件 [Hairer et al., 1993, III, Thm. 2.4]

$$p \text{ 次} \iff \sum_{i=0}^r \alpha_i = 0 \quad \text{かつ} \quad \sum_{i=0}^r \alpha_i i^q = q \sum_{i=0}^r \beta_i i^{q-1} \quad (q = 1, \dots, p).$$

$q = 2$ の条件は成立しない：

$$\sum_{i=0}^2 \alpha_i i^2 = \gamma \cdot 0^2 + (-1-\gamma) \cdot 1^2 + 2^2 = 3 - \gamma,$$

$$2 \sum_{i=0}^2 \beta_i i = 2(-\gamma(1-\gamma) \cdot 0 + (1-\gamma^2)) = 2(1-\gamma^2)$$

定義：線形多段階法の収束性

線形多段階法が p 次収束

\iff ある正の数 $h_0 \in \mathbb{R}$ が存在し, $h \leq h_0$ に対して, 出発値が

$$\|x^{(i)} - x(ih)\| \leq C_0 h^p \quad (i = 0, 1, \dots, r-1)$$

を満たすとき, 以下が成立する:

$$\|x^{(k)} - x(kh)\| \leq Ch^p \quad (k = r, r+1, \dots).$$

定理：収束性の必要十分条件 [Hairer et al., 1993, III, Thm. 4.2 and 4.5]

線形多段階法が p 次収束 \iff 線形多段階法が p 次精度かつ零安定

- 線形多段階法が p 次精度であるための条件は $p + 1$ 個の線形方程式.
- 線形 r 段階法のパラメータの自由度は $2r + 1$ (陽的に限ると $2r$) 個.

→ 陰的では $p = 2r$, 陽的では $p = 2r - 1$ が達成可能?

→ 達成可能だが, 零安定性が成立しない.

定理 : Dahlquist の第 1 障壁 [Hairer et al., 1993, III, Thm. 3.5]

零安定な線形 r 段階法の次数 p は以下の関係を満たす :

- r が偶数のとき, $p \leq r + 2$.
- r が奇数のとき, $p \leq r + 1$.
- $\frac{\beta_r}{\alpha_r} \leq 0$ (陽的な場合を含む) のとき, $p \leq r$.

定理 : Dahlquist の第 2 障壁 [Hairer and Wanner, 1996, V, Thm. 1.4]


A 安定な線形多段階法は高々 2 次精度である.

- ① 連続最適化問題に対する ODE アプローチの例
- ② 常微分方程式の数値解析の概要
- ③ 数値解法の安定性
- ④ 数値解法の精度 : Runge-Kutta 法
- ⑤ 数値解法の精度 : 線形多段階法
- ⑥ 構造保存数値解法**
- ⑦ 微分方程式の数値解析の連続最適化への応用
- ⑧ まとめ


例：非線形波動のシミュレーション (KdV 方程式)

時間発展



汎用解法



構造保存数値解法



$T = 2.07$



汎用解法

Runge-Kutta 法, 線形多段階法, ...

- + 全ての方程式に利用可能
- + 豊富な理論 (精度, 安定性)
- 難しい問題に対しては非効率的

特殊解法

Störmer 法, Verlet 法, ...

- + 優れたパフォーマンス (特に長時間積分)
- 「方程式」に強く依存

構造保存数値解法 (GNI: Geometric Numerical Integration)

- 方程式の「重要な」性質を抽出
symplecticity (symplectic 法), 保存性/散逸性 (離散勾配法,...), ...
- 優れた長時間挙動
- 適用範囲の拡大: 離散勾配法の場合
各論 → Hamilton 系 [Gonzalez, 1996]
→ (任意の) 保存/散逸系 [McLachlan et al., 1999]

散逸系

$$\dot{x} = S(x)\nabla V(x)$$

- $S : \mathbb{R}^d \rightarrow \mathbb{R}^{d \times d}$, $V : \mathbb{R}^d \rightarrow \mathbb{R}$
- $S(x)$ が半負定値 ($\forall x \in \mathbb{R}^d$) $\Rightarrow V$ は散逸 : $\frac{d}{dt}V(x(t)) \leq 0$
- 勾配流, 散逸的 PDE の空間離散化

散逸の数値解法

$V(x^{(k+1)}) \leq V(x^{(k)})$ を満たす数値解法

- 各種の構成方法 : 離散勾配法, 射影法, ...
- 優れた長時間挙動
- 理論解析のサポート

勾配流

$$\dot{x} = S(x)\nabla V(x)$$

散逸則

$$\frac{d}{dt}V(x(t)) = \langle \nabla V(x), \dot{x} \rangle = \langle \nabla V(x), S(x)\nabla V(x) \rangle \leq 0$$

連鎖律

半負定値性

離散勾配法 [Gonzalez, 1996],[McLachlan et al., 1999]

スキーム

$$\frac{x^{(k+1)} - x^{(k)}}{h} = \bar{S}(x^{(k+1)}, x^{(k)}) \bar{\nabla}V(x^{(k+1)}, x^{(k)})$$

散逸則

$$\frac{V(x^{(k+1)}) - V(x^{(k)})}{h} = \left\langle \bar{\nabla}V, \frac{x^{(k+1)} - x^{(k)}}{h} \right\rangle = \langle \bar{\nabla}V, \bar{S} \bar{\nabla}V \rangle = 0$$

離散連鎖律

半負定値性

離散勾配

C^1 級関数 $V : \mathbb{R}^d \rightarrow \mathbb{R}$ に対して,

以下の性質を満たす連続写像 $\bar{\nabla}V : \mathbb{R}^d \times \mathbb{R}^d \rightarrow \mathbb{R}^d$ を離散勾配という :

- 1 $\langle \bar{\nabla}V(x, y), x - y \rangle = V(x) - V(y)$;
- 2 $\bar{\nabla}V(x, x) = \nabla V(x)$.

- Gonzalez の離散勾配 [Gonzalez, 1996]

$$\bar{\nabla}_G V(x, y) = \nabla V\left(\frac{x+y}{2}\right) + \frac{V(x) - V(y) - \langle \nabla V\left(\frac{x+y}{2}\right), x - y \rangle}{\|x - y\|_2^2} (x - y)$$

- Average Vector Field (AVF) [Quispel and McLaren, 2008]

$$\bar{\nabla}_{AVF} V(x, y) = \int_0^1 \nabla V(\xi x + (1 - \xi)y) d\xi$$

- Itoh-Abe の離散勾配 [Itoh and Abe, 1988] (次のページ)

勾配流 $\dot{x} = -\nabla V(x)$ に対する Itoh-Abe の離散勾配法

$$\begin{bmatrix} \frac{x_1^{(k+1)} - x_1^{(k)}}{h} \\ \frac{x_2^{(k+1)} - x_2^{(k)}}{h} \\ \vdots \\ \frac{x_d^{(k+1)} - x_d^{(k)}}{h} \end{bmatrix} = - \begin{bmatrix} \frac{V(x_1^{(k+1)}, x_2^{(k)}, \dots, x_d^{(k)}) - V(x_1^{(k)}, x_2^{(k)}, \dots, x_d^{(k)})}{x_1^{(k+1)} - x_1^{(k)}} \\ \frac{V(x_1^{(k+1)}, x_2^{(k+1)}, x_3^{(k)}, \dots, x_d^{(k)}) - V(x_1^{(k+1)}, x_2^{(k)}, \dots, x_d^{(k)})}{x_2^{(k+1)} - x_2^{(k)}} \\ \vdots \\ \frac{V(x_1^{(k+1)}, \dots, x_{d-1}^{(k+1)}, x_d^{(k+1)}) - V(x_1^{(k+1)}, \dots, x_{d-1}^{(k+1)}, x_d^{(k)})}{x_d^{(k+1)} - x_d^{(k)}} \end{bmatrix}$$

- 第一式に含まれる未知量は $x_1^{(k+1)}$ のみ。
1 変数の非線形方程式を解けばよい。
- $x_1^{(k+1)}$ を得たら、第二式の未知量は $x_2^{(k+1)}$ のみ。以下同様。
- 1 変数非線形方程式を d 回解けばよい。

離散勾配法の弱点：計算コスト

陰的非線形スキーム, i.e., 毎ステップ非線形方程式を解く必要あり

高速化のための工夫

多段線形化：多段エネルギーを散逸

- 離散変分法 (PDE 版の離散勾配法)
の陰的線形多段化 [Matsuo and Furihata, 2001]

補助変数を入れて陰的線形化：修正エネルギーを散逸

- 非線形 Schrödinger 方程式に対する Besse の方法 [Besse, 2004]
- Invariant Energy Quadraticization 法 [Yang and Han, 2017]
- Scalar Auxiliary Variable 法 [Shen et al., 2018]

補助変数を入れて 1 変数の非線形方程式に帰着：元のエネルギーを散逸

- Lagrange Multiplier 法 [Cheng et al., 2020]

離散勾配法のおさらい

$$\frac{x^{(k+1)} - x^{(k)}}{h} = -\bar{\nabla} f(x^{(k+1)}, x^{(k)})$$


- 離散勾配 $\bar{\nabla} f$ を巧妙に用いて散逸性を再現
- 離散勾配は必ず $x^{(k+1)}$ に依存するため、陰的解法
- (非線形方程式の解が存在する限り) $f(x^{(k+1)}) \leq f(x^{(k)})$

最適化への応用：

- 各種の標準的な離散勾配法の可解性
- 最適化手法としての収束レートの証明
- 関連研究
 - 画像関係の最適化問題への応用 [Ringholm et al., 2018]
 - 非凸非平滑関数の最適化への応用 [Riis et al., 2022]

- ① 連続最適化問題に対する ODE アプローチの例
- ② 常微分方程式の数値解析の概要
- ③ 数値解法の安定性
- ④ 数値解法の精度 : Runge-Kutta 法
- ⑤ 数値解法の精度 : 線形多段階法
- ⑥ 構造保存数値解法
- ⑦ 微分方程式の数値解析の連続最適化への応用
- ⑧ まとめ


最適化に適したダイナミクス



我々の周辺で得た成果

(A) 最適化に適したダイナミクス

80/100



(B) 構造保存数値解法の適用 [Onuma and Sato, 2023]

Lagrange Multiplier 法 [Cheng et al., 2020] の勾配流への適用

(A) 本質的な収束レート [Ushiyama et al., 2022b]

連続時間ダイナミクスにおける収束レートの不定性を除去した本質的収束レート

(B) 安定な陽解法の適用 [Ushiyama et al., 2022a]

(B) 弱い離散勾配による手法の構成と統一的収束証明 [Ushiyama et al., 2023]

離散勾配の定義を最適化用に拡張, 収束レートの証明

(B) 加速勾配法の可変刻み線形多段階法解釈 [Nozawa, 2022]

加速勾配法が可変刻み線形多段階法とみなせることの指摘, 手法の拡張

仮定 : 関数 $V: \mathbb{R}^d \rightarrow \mathbb{R}$ が $V(x) = \frac{1}{2}\langle x, Qx \rangle + f(x)$ とかける

勾配流に対する Lagrange Multiplier (LM) 法 [Cheng et al., 2020]

$$\begin{cases} \frac{x^{(k+1)} - x^{(k)}}{h} = -\left(Q \frac{x^{(k+1)} + x^{(k)}}{2} + \eta^{(k)} \nabla f(x^{(k)})\right) \\ f(x^{(k+1)}) - f(x^{(k)}) = \eta^{(k)} \langle \nabla f(x^{(k)}), x^{(k+1)} - x^{(k)} \rangle \end{cases}$$

- 未知量 $x^{(k+1)}, \eta^{(k)}$ は (n 次元線形方程式を 2 回と) 1 次元非線形方程式を 1 回解くだけで計算可能
- (非線形方程式の解が存在する限り) $V(x^{(k+1)}) \leq V(x^{(k)})$
- Cahn–Hilliard 方程式などの散逸量をもつ PDE に適用

→ 最適化に使えるそう！

問題点：

非線形方程式の可解性が未解決。

→ 本研究：可解性（ここでは Q が零行列の場合だけを扱う）

Lagrange Multiplier 法の特例ケース

$$\begin{cases} \frac{x^{(k+1)} - x^{(k)}}{h} = -\eta^{(k)} \nabla f(x^{(k)}) \\ f(x^{(k+1)}) - f(x^{(k)}) = \eta^{(k)} \langle \nabla f(x^{(k)}), x^{(k+1)} - x^{(k)} \rangle \end{cases}$$

解くべき非線形方程式 :

$$F_h(\eta) := f\left(x^{(k)} - \eta h \nabla f\left(x^{(k)}\right)\right) - f\left(x^{(k)}\right) + h\eta^2 \left\| \nabla f\left(x^{(k)}\right) \right\|^2 = 0$$

定理 : 可解性

任意の $h > 0$ に対して, ある $\eta \in \mathbb{R}$ が存在し, $F_h(\eta) = 0$ と $\eta \geq (1 + Lh/2)^{-1}$ を満たす.

さらに, f が凸の場合, $\eta \in [(1 + Lh/2)^{-1}, 1]$ を満たす解が存在する.

Lagrange Multiplier 法の特殊ケース

$$\begin{cases} \frac{x^{(k+1)} - x^{(k)}}{h} = -\eta^{(k)} \nabla f(x^{(k)}) \\ f(x^{(k+1)}) - f(x^{(k)}) = \eta^{(k)} \langle \nabla f(x^{(k)}), x^{(k+1)} - x^{(k)} \rangle \end{cases}$$

提案手法 : 不等式への緩和

$$\begin{cases} \frac{x^{(k+1)} - x^{(k)}}{h} = -\eta^{(k)} \nabla f(x^{(k)}) \\ f(x^{(k+1)}) - f(x^{(k)}) \leq \eta^{(k)} \langle \nabla f(x^{(k)}), x^{(k+1)} - x^{(k)} \rangle \end{cases}$$

- 離散散逸則が成立.
- 満たすべき不等式 $F_h(\eta) \leq 0$ について :
 $\eta \in [0, (1 + Lh/2)^{-1}]$ のとき, $F_h(\eta) \leq 0$
→ バックトラッキングで求解可能.
- 特殊なステップ幅基準を採用した最急降下法にともみなせる.

定理 : 収束レート

f の条件	収束レート	勾配流の収束レート
	$\min_{0 \leq i \leq k} \ \nabla f(x^{(k)})\ = O(k^{-1/2})$	$O(t^{-1/2})$
凸	$f(x^{(k)}) - f^* = O(k^{-1})$	$O(t^{-1})$
μ -強凸	$f(x^{(k)}) - f^* = O\left(\exp\left(\frac{-2\mu kh}{(Lh+2)^2}\right)\right)$	$O(\exp(-2\mu t))$

- 散逸則のおかげで証明は比較的シンプル
- 任意の $h > 0$ に対して収束が保証されるが、実際の挙動は h に依存
 $\rightarrow h$ を適応的に変更する手法も提案.
- 数値実験では、通常 of 最急降下法と同程度のパフォーマンス (当然?)

事実

関数 $f: \mathbb{R}^d \rightarrow \mathbb{R}^d$ が L -平滑な凸関数であるとき、
勾配流 $\dot{x} = -\nabla f(x)$ の任意の解 x について、

$$f(x(t)) - f^* = O\left(\frac{1}{t}\right).$$

時間スケールリング $t = \alpha(\tau)$ により、 $\tilde{x}(\tau) = x(\alpha(\tau))$ とすると...

ODE :
$$\frac{d}{d\tau} \tilde{x}(\tau) = -\alpha'(\tau) \nabla f(\tilde{x}(\tau))$$

収束レート :
$$f(\tilde{x}(\tau)) - f^* = O\left(\frac{1}{\alpha(\tau)}\right)$$

任意の収束レートが達成可能...?

収束レートが不定であれば,

- 「最適な」連続時間ダイナミクスという問いは無意味
- 離散時間ダイナミクスにおける最適レートの理論と不整合


→ 我々のアプローチ:

「最終的に時間離散化する」ことを前提に「本質的な収束レート」を定義

観察

例: $O(1/\tau^2)$ を達成する ODE $\frac{d}{d\tau}\tilde{x}(\tau) = -\tau\nabla f(\tilde{x}(\tau))$

線形化した場合の最小固有値 = $-\tau L$:



固有値が左に動いていく

→ ステップ幅を小さくする必要あり

アイデア

- 時間スケールリングでうつりあう ODE は同値類でまとめる
- 「本質的な収束レート」は「同値類」に対して定義する

定義：適切な代表元と収束レート

漸近的に最適解に向かうベクトル場の集合 \mathcal{G} 上の同値関係 \sim を

$$g \sim \tilde{g} \iff \exists \text{時間スケールリング } \alpha \text{ s.t. } \alpha'(t)g(\alpha(t), x) = \tilde{g}(t, x)$$

で定め、 g の同値類を $[g]$ と書く。 $g \in \mathcal{G}$ に対して、 $g_0 \in [g]$ が $t \rightarrow \infty$ で $\rho\left(\frac{\partial g_0(t, x)}{\partial x}\right) = \Theta(1)$ を満たすとき、 g_0 を $[g]$ の適切な代表元という。適切な代表元 g_0 に対応する解 x が $f(x(t)) - f^* = \Theta(\beta(t))$ を満たすとき、 β を $[g]$ の収束レートという。

- $[\dot{x} = -\nabla f(x)]$ の収束レートは $1/t$
- $[\ddot{x} + \frac{3}{t}\dot{x} + \nabla f(x) = 0]$ の収束レートは $1/t^2$

定理

仮定 :

- (A0) 数値解法の安定領域は有界.
- (A1) 任意の k において, $h_k \frac{\partial g}{\partial x}(t_{k-1}, x^{(k-1)})$ の全ての固有値が安定領域に含まれる ($t_k := \sum_{i=1}^k h_i$).
- (A2) ある $h_{\max} \in \mathbb{R}_{>0}$ が存在し, 任意の k で $h_k \leq h_{\max}$ が成立.

$g \in \mathcal{G}$ に対して, g_0 が $[g]$ の適切な代表元であり, α が g と g_0 の間の時間スケリングとする ($g(x, t) = \alpha'(t)g_0(\alpha(t), x)$). このとき, 任意の k に対して $0 < \rho\left(\frac{\partial g}{\partial x}(t_{k-1}, x^{(k-1)})\right) < \infty$ ならば, $\alpha(t_k) = O(k)$ が成立.

仮定 (A0) について :


陽的解法を想定すると, この仮定は妥当.

例 : 全ての陽的 Runge-Kutta 法の安定領域は有界


定理

(A0), (A1), (A2) を仮定する.

$g \in \mathcal{G}$ に対して, g_0 が $[g]$ の適切な代表元であり, α が g と g_0 の間の時間スケールングとする ($g(t, x) = \alpha'(t)g_0(\alpha(t), x)$). このとき, 任意の k に対して $0 < \rho\left(\frac{\partial g}{\partial x}(t_{k-1}, x^{(k-1)})\right) < \infty$ ならば, $\alpha(t_k) = O(k)$ が成立.




安定領域 :
 $(|\lambda h + 1| \leq 1)$



L 平滑凸関数に対する
 勾配流では $\lambda \in [-L, 0]$
 $\rightarrow h \in [0, \frac{2}{L}]$ で安定
 (最急降下法の収束条件と一致)

\rightarrow 実軸の負の方向に広い安定領域をもつ陽解法は、最適化に使いそう。



ある s 段陽的 Runge-Kutta 法の安定領域

通常のアプローチ :

数値解法の構成 (精度などを基準とする) \rightarrow 安定領域を調べる

広い安定領域をもつ解法を構成するアプローチ :

安定領域を作る \rightarrow それに合うような数値解法を作る.

具体例 (前ページの図) : RKC (Runge–Kutta–Chebyshev) 法
 s 次 Chebyshev 多項式 T_s を「うまく」シフト, スケーリング :

$$R_s(z) := \frac{T_s(w_0 + w_1 z)}{T_s(w_0)} \quad w_0 := 1 + \frac{\eta}{s^2} \quad w_1 := \frac{T_s(w_0)}{T_s'(w_0)}$$


- 安定領域の左端 $\approx -2T_s'(1) = -2s^2$
- 陽的 Euler 法 s 個の合成で実現可能

	最大ステップ幅	勾配の評価回数	比
陽的 Euler	2	1	2
s 次の場合	$2s^2$	s	$2s$

安定な陽解法の適用 (3/5) : s 段 RKC 法のイメージ 92/100

$\Phi_h^{(s)}(x)$: 初期値 x に対して s 段 RKC 法を 1 回適用した際の実出力.

$s = 1, 2, 3, 5$ のそれぞれで, h を動かした曲線 :



- s を大きくしても (精度は上がっていないので) 厳密解には近づかない.
- s が大きい RKC 法は非常に大きな h を使える ($2s^2/L$ 程度).

安定な陽解法の適用 (4/5) : RKC 法の実装について 93/100

同じ安定性関数をもつ複数の Runge–Kutta 法が存在

- 微分方程式が線形であれば、出力は同じ (安定性関数のみで定まる)
- 所望の安定性関数が s 次多項式 $\Rightarrow s$ 段陽的 Runge–Kutta 法


実装の方法 :

- 陽的 Euler 法の合成 :
Chebyshev 多項式の根を用いる。根の並べ方に注意が必要。
- 2 段 RK 法の合成 :
Chebyshev 多項式の根のペアを用いる。ペアの並べ方に注意が必要。
- Chebyshev 多項式の漸化式を用いる方法 :
 - Chebyshev 多項式の 3 項間漸化式を用いて定める。
 - 内部段も安定に計算でき、計算手順に任意性がない。
 - 強凸 2 次関数の最適化への応用 [Eftekhari et al., 2021]
 - Chebyshev iterative method (最適化), Chebyshev 加速法 (線形計算) と関係がある。

目的関数 (強凸) ($d = 128$, $L \approx 512 + \alpha$, $\mu \approx 0.0759$, $\kappa \approx 6760$) :

$$f(x) = \frac{d}{2} \left(x_1^2 + \sum_{i=2}^d (x_i - x_{i-1})^2 + x_d^2 \right) + \alpha \log \left(\sum_{i=1}^d \exp(x_i) \right).$$

勾配ノルムが 10^{-10} 以下になるまでの勾配計算の回数 :




強凸ではない (凸でもない) 場合の数値実験でもよく動く。

- ① 連続最適化問題に対する ODE アプローチの例
- ② 常微分方程式の数値解析の概要
- ③ 数値解法の安定性
- ④ 数値解法の精度 : Runge-Kutta 法
- ⑤ 数値解法の精度 : 線形多段階法
- ⑥ 構造保存数値解法
- ⑦ 微分方程式の数値解析の連続最適化への応用
- ⑧ まとめ

常微分方程式の数値解析の基礎をざっくりと説明した。

- Runge–Kutta 法
- 線形多段階法
- 安定性
- 収束性 (精度)
- 構造保存数値解法



- [Besse, 2004] Besse, C. (2004).
A relaxation scheme for the nonlinear Schrödinger equation.
SIAM Journal on Numerical Analysis, 42(3):934–952.
- [Butcher, 1964] Butcher, J. C. (1964).
Implicit Runge-Kutta processes.
Mathematics of Computation, 18:50–64.
- [Chen et al., 2018] Chen, R. T. Q., Rubanova, Y., Bettencourt, J., and Duvenaud, D. K. (2018).
Neural ordinary differential equations.
In *Advances in Neural Information Processing Systems*, volume 31.
- [Cheng et al., 2020] Cheng, Q., Liu, C., and Shen, J. (2020).
A new Lagrange multiplier approach for gradient flows.
Computer Methods in Applied Mechanics and Engineering, 367:113070.
- [Eftekhari et al., 2021] Eftekhari, A., Vandereycken, B., Vilmart, G., and Zygalkakis, K. C. (2021).
Explicit stabilised gradient descent for faster strongly convex optimisation.
BIT Numerical Mathematics, 61:119–139.
- [Ehrhardt et al., 2018] Ehrhardt, M. J., Riis, E. S., Ringholm, T., and Schönlieb, C.-B. (2018).
A geometric integration approach to smooth optimisation: Foundations of the discrete gradient method.
arXiv, arXiv:1805.06444.
- [Gonzalez, 1996] Gonzalez, O. (1996).
Time integration and discrete Hamiltonian systems.
Journal of Nonlinear Science, 6:449–467.
- [Hairer, 1978] Hairer, E. (1978).
A Runge–Kutta method of order 10.
IMA Journal of Applied Mathematics, 21(1):47–59.

- [Hairer et al., 2006] Hairer, E., Lubich, C., and Wanner, G. (2006).
Geometric numerical integration, Structure-preserving algorithms for ordinary differential equations, volume 31 of *Springer Series in Computational Mathematics*.
Springer-Verlag, Berlin, second edition.
- [Hairer et al., 1993] Hairer, E., Nørsett, S. P., and Wanner, G. (1993).
Solving ordinary differential equations I, Nonstiff problems, volume 8 of *Springer Series in Computational Mathematics*.
Springer-Verlag, Berlin, second edition.
- [Hairer and Wanner, 1996] Hairer, E. and Wanner, G. (1996).
Solving ordinary differential equations II, Stiff and differential-algebraic problems, volume 14 of *Springer Series in Computational Mathematics*.
Springer-Verlag, Berlin.
- [Itoh and Abe, 1988] Itoh, T. and Abe, K. (1988).
Hamiltonian-conserving discrete canonical equations based on variational difference quotients.
Journal of Computational Physics, 76(1):85–102.
- [Kim and Yang, 2023] Kim, J. and Yang, I. (2023).
Unifying Nesterov’s accelerated gradient methods for convex and strongly convex objective functions.
In *Proceedings of the 40th International Conference on Machine Learning*, volume 202.
- [Krichene et al., 2015] Krichene, W., Bayen, A., and Bartlett, P. L. (2015).
Accelerated mirror descent in continuous and discrete time.
In *Advances in Neural Information Processing Systems*, volume 28.
- [Matsuo and Furihata, 2001] Matsuo, T. and Furihata, D. (2001).
Dissipative or conservative finite-difference schemes for complex-valued nonlinear partial differential equations.
Journal of Computational Physics, 171(2):425–447.
- [McLachlan et al., 1999] McLachlan, R. I., Quispel, G. R. W., and Robidoux, N. (1999).
Geometric integration using discrete gradients.
Philosophical Transactions of the Royal Society A, 357:1021–1045.

- [Nesterov, 2004] Nesterov, Y. (2004).
Introductory lectures on convex optimization: A basic course, volume 87.
Springer Science & Business Media.
- [Nozawa, 2022] Nozawa, R. (2022).
Analysis and construction of continuous optimization algorithms via variable step size linear multistep methods (in Japanese).
Bachelor's thesis, The University of Tokyo.
- [Onuma and Sato, 2023] Onuma, K. and Sato, S. (2023).
Existence results on Lagrange multiplier approach for gradient flows and application to optimization.
to appear in Japan Journal of Industrial and Applied Mathematics.
- [Polyak, 1964] Polyak, B. T. (1964).
Some methods of speeding up the convergence of iteration methods.
USSR Computational Mathematics and Mathematical Physics, 4(5):1–17.
- [Quispel and McLaren, 2008] Quispel, G. R. W. and McLaren, D. I. (2008).
A new class of energy-preserving numerical integration methods.
Journal of Physics A: Mathematical and Theoretical, 41:045206.
- [Riis et al., 2022] Riis, E. S., Ehrhardt, M. J., Quispel, G., and Schönlieb, C.-B. (2022).
A geometric integration approach to nonsmooth, nonconvex optimisation.
Foundations of Computational Mathematics, 22:1351–1394.
- [Ringholm et al., 2018] Ringholm, T., Lazić, J., and Schönlieb, C.-B. (2018).
Variational image regularization with Euler's elastica using a discrete gradient scheme.
SIAM Journal on Imaging Sciences, 11(4):2665–2691.
- [Scieur et al., 2017] Scieur, D., Roulet, V., Bach, F., and d'Aspremont, A. (2017).
Integration methods and optimization algorithms.
In *Advances in Neural Information Processing Systems*, volume 30.
- [Shen et al., 2018] Shen, J., Xu, J., and Yang, J. (2018).
The scalar auxiliary variable (SAV) approach for gradient flows.
Journal of Computational Physics, 353:407–416.

- [Su et al., 2014] Su, W., Boyd, S., and Candes, E. (2014).
A differential equation for modeling Nesterov's accelerated gradient method: Theory and insights.
In *Advances in Neural Information Processing Systems*, volume 27.
- [Ushiyama et al., 2022a] Ushiyama, K., Sato, S., and Matsuo, T. (2022a).
Deriving efficient optimization methods based on stable explicit numerical methods.
SIAM Letters, 14:29–32.
- [Ushiyama et al., 2022b] Ushiyama, K., Sato, S., and Matsuo, T. (2022b).
Essential convergence rate of ordinary differential equations appearing in optimization.
SIAM Letters, 14:119–122.
- [Ushiyama et al., 2023] Ushiyama, K., Sato, S., and Matsuo, T. (2023).
A new unified framework for designing convex optimization methods with prescribed theoretical convergence estimates: A numerical analysis approach.
arXiv, arXiv:2302.07404.
- [Yang and Han, 2017] Yang, X. and Han, D. (2017).
Linearly first- and second-order, unconditionally energy stable schemes for the phase field crystal model.
Journal of Computational Physics, 330:1116–1134.
- [Zhang, 2019] Zhang, D. K. (2019).
Discovering new Runge-Kutta methods using unstructured numerical search.
arXiv, arXiv:1911.00318.