

Estabilidad

ALN2022
Clase 14
20/10

En un mundo ideal, los algoritmos en análisis numérico
podrían dar soluciones exactas a nuestros problemas, pero esto
diste mucho de la realidad. Los problemas que estamos manejando
pertenechan al mundo continuo pero nuestras máquinas digitales viven
en un mundo discreto. En este sentido la medida de estabilidad
nos da una medida de la precisión de los outputs de nuestros algoritmos.

Recordando el mapa solución $S: I \rightarrow O$ del espacio de inputs
en el espacio de outputs (en general definido localmente como hemos visto)
podemos pensar en algoritmos como otro mapa $\tilde{S}: I \rightarrow O$ que
a un input $a \in I$ da como resultado una solución aproximada.

Más formalmente, tenemos $S: I \rightarrow O$, una computadora con la
aritmética dada anteriormente (de punto flotante), un algoritmo ~~para~~ y
su implementación. Luego dados un input $a \in I$, ~~se~~ introducimos
en la computadora ~~para~~ resultando en $fl(a)$ (el mapa redondeo)
para luego implementar el algoritmo y dar como resultado en
nº en punto flotante $\tilde{S}(a)$:

$$\text{Pensamiento: } a \in I \xrightarrow{\text{computadora}} fl(a) \xrightarrow{\text{algoritmo}} \tilde{S}(a) \in \mathbb{F}^L$$

Lo anterior de hecho está idealizado, de hecho la misma secuencia
de pasos nos podría dar una solución distinta por lo que $fl(a)$ o $\tilde{S}(a)$
puede no estar bien definido.

Pero, a pesar de las idealizaciones y complicaciones podemos hacer un
análisis riguroso de los algoritmos.

Precisión

Una forma natural de decir que nuestro algoritmo es preciso es que el output deseado por el algoritmo esté "muy cerca" del output verdadero.

En términos más wtf, decimos que el algoritmo es preciso si:

$$\forall a \in I, \quad \frac{\|\tilde{S}(a) - S(a)\|}{\|S(a)\|} = O(\text{Error}).$$

Esta expresión parece natural pero escríbela en detalle y verás que:

¿Qué entendemos por $O(\text{Error})$? ¿Es uniforme en todos los inputs?

Sabemos de la teoría del condicionamiento que el nº de condicionamiento es inenfrentable. Una vez que nuestro input se transforma de a a \tilde{a} tenemos una pequeña perturbación que puede ser muy significativa si el input a es mal condicionado.

Mencionando esto podemos decir que el algoritmo es preciso si:

$$\|\tilde{S}(a) - S(a)\| \leq C \cdot \mu(a) \cdot \text{Error} \cdot \|S(a)\| \quad \text{para algune cte. } C \text{ que sólo puede depender de las dimensiones.}$$

Estabilidad

La estabilidad de un algoritmo \tilde{S} asociado al mapeo S se describe de la siguiente manera. Decimos que \tilde{S} es estable si $\forall a \in I$

$$\frac{\|\tilde{S}(a) - S(\tilde{a})\|}{\|S(\tilde{a})\|} = O(\text{Error}) \quad \text{para } \tilde{a} \in I \text{ tg } \frac{\|a - \tilde{a}\|}{\|a\|} = O(\text{Error})$$

En palabras de Trefethen:

"Un algoritmo estable da casi la respuesta exacta a casi la pregunta correcta".

Backward Stability (Estabilidad Inversa)

Otra condición más fuerte que la estabilidad \tilde{S} es la est. inversa:

\tilde{S} es backward-stable si $\forall a \in I \quad \tilde{S}(a) = S(\bar{a})$

para $\bar{a} \in I$ tq $\frac{\|\bar{a}-a\|}{\|a\|} = O(\text{Error})$

i.e "Un algoritmo es b.s. stable si de la respuesta exacta a casi la pregunta correcta". Observar que si \tilde{S} es b.s. entonces

$$\begin{aligned} \|S(a) - S(\bar{a})\| &= \underbrace{\|\tilde{S}(a) - S(\bar{a})\|}_{\text{Error}} + \underbrace{\|\tilde{S}(\bar{a}) - S(\bar{a})\|}_{\text{Error}} \\ &= \|\tilde{S}(\bar{a}) - S(\bar{a})\| \leq \underbrace{\mu(\bar{a}) \cdot \|\bar{a}-a\|}_{\text{Error}} = \underbrace{\frac{\|\bar{a}-a\|}{\|\bar{a}\|}}_{\text{Error}} = O(\text{Error}) \end{aligned}$$

Estabilidad a la Smale

Supongamos que estamos en las condiciones vistos anteriormente de que tenemos que la variedad soporte $V = \{(a, x) \in I \times \mathcal{O} : F(a, x) = 0\}$ con F regular (algunas $F(a, \cdot)$ sea C^2), y las dimensiones adecuadas.

Luego x es punto de a $F_a(x) = 0$ con $F_a(\cdot) = F(a, \cdot)$.

Se puede construir un mapa de Neumann asociado a la función

$$F_a : \mathcal{O} \rightarrow \mathbb{R}^k, \quad y \text{ lo definimos por } N_{F_a}$$

Smale define el output de ~~un~~ algoritmo a un apart $\tilde{x} = \tilde{S}(a)$ tal que \tilde{x} ~~esta~~ esté en la cuenca de atracción inmediata ~~del~~ apart de convergencia cuadrática del ~~un~~ N_{F_a} al cero x .

$$\text{i.e. } \cancel{\text{El error}} \quad d(N_{F_a}^k(\tilde{x}), x) \leq \left(\frac{1}{2}\right)^{2^{k-1}} d(\tilde{x}, x).$$

Observar que la definición de Smale

Smale le da el nombre de "cero aproximado" a los ~~punto~~ puntos que están en la vecindad de atracción anterior.

Por lo tanto si metemos algoritmos nos de un cero aproximado, es muy fácil ~~que~~ diseñar un algoritmo estable ya que a medida que pasan los problemas aplicar el método de Newton para obtener la precisión que deseamos.

~~Algunos Ejemplos de Estabilidad~~

Estabilidad de Aritmética de Punto Flotante

Veamos que las operaciones básicas (sus correspondientes algoritmos) son back-estables.

Resta: Sean $(a_1, a_2) \in \mathbb{I}^n$ y mettere función $\tilde{S}(a_1, a_2) = a_1 - a_2$

Tengamos nuestra computadora (o el axioma fundamental) define el algoritmo

$$\tilde{S}(a_1, a_2) = fl(a_1) \ominus fl(a_2)$$

i.e. redondea $a_i \mapsto fl(a_i)$, para luego proceder a realizar el cálculo en $\overline{\mathbb{F}}$ (que desconocemos) para dar un resultado en $\overline{\mathbb{F}}$. Recordando el mapa $fl: \mathbb{R} \rightarrow \overline{\mathbb{F}}$ y el axioma se tiene que:

$$fl(a_1) = q_1(1+\epsilon_1) \quad fl(a_2) = q_2(1+\epsilon_2) \quad \text{con } |\epsilon_1|, |\epsilon_2| \leq \epsilon_{\text{max}}$$

Luego: $fl(a_1) \oplus fl(a_2) = (fl(a_1) - fl(a_2))(1+\epsilon_3)$
 $| \epsilon_3 | \leq \epsilon_{\text{max}}$.

Por lo tanto

$$\tilde{S}(a_1, a_2) = [q_1(1+\epsilon_1) - q_2(1+\epsilon_2)] \cdot (1+\epsilon_3)$$

$$= q_1(1+\epsilon_1)(1+\epsilon_3) - q_2(1+\epsilon_2)(1+\epsilon_3)$$

$$= q_1(1+\epsilon_4) - q_2(1+\epsilon_5)$$

$$\left(\text{con } |\epsilon_4| \leq 2\epsilon_{\text{max}} + O(\epsilon_{\text{max}}^2) \right).$$

γ / ϵ_5

Hemos concluido que $\tilde{S}(a_1, a_2) = S(\tilde{a}_1, \tilde{a}_2)$

con $\tilde{a}_1 := a_1(1+\epsilon_4)$, $\tilde{a}_2 := a_2(1+\epsilon_5)$ satisface el

$$\frac{\|\tilde{a}_1 - a_1\|}{\|a_1\|} = O(\epsilon_{\text{max}}), \quad \frac{\|\tilde{a}_2 - a_2\|}{\|a_2\|} = O(\epsilon_{\text{max}})$$

y por lo tanto $\frac{\|\tilde{(a_1, a_2)} - (a_1, a_2)\|}{\|(a_1, a_2)\|} = O(\epsilon_{\text{max}})$

concluimos que es backward-stable.

Punto Flotante (Revertido)

Fijaremos la base $\beta=2$, y nos permitiremos trabajar con t y s distintos siendo t la cantidad de bits para la mantisa y s cantidad de bits para el exponente.

Recordar que en \mathbb{R} real $x \in \mathbb{R}$ se puede escribir en expansión binaria como $x = \pm d_0 + d_1 2^{-1} + d_2 2^{-2} + \dots + d_m 2^{-m}$

$$x = \pm (d_m 2^m + d_{m-1} 2^{m-1} + \dots + d_1 2^1 + \dots + d_0)$$

donde los d_k son dígitos binarios, i.e. $d_k \in \{0, 1\}$.

Una forma abreviada de lo anterior es escribir

$$x = \pm (d_m d_{m-1} \dots d_1 d_0)_{2^{\text{exponent}}}$$

Un n° en punto flotante lo escribimos como $x = m \times 2^e$

$$d_t d_{t-1} \dots d_1 d_0$$

mantisa

$$\text{donde } m = \pm (b_{t-1} b_{t-2} \dots b_1 b_0)_2, \quad e = \pm (c_{s-1} \dots c_1 c_0)_2$$

A diferencia de lo visto pasando al exponente lo escribimos explícitamente el exponente. Recordar que \overline{F} son los normalizados, es decir $b_1 = 1$. Tomando Observar que ahora \overline{F} quedará bien definida y sólo dependerá de los parámetros (t, s), y podemos notar el $\overline{F} = R(t, s)$.

(S.i. x no está normalizado corrije para hacerlo lo multiplicamos por 2^{-e}) -81-

Luego la representación física del punto flotante se modela con los siguientes ejemplos

$$\boxed{\pm |b_1| b_2 \cdot 1 \dots \dots |b_t| \pm |c_{s-1}| c_{s-2} \dots \dots |c_1| c_0}$$

t bits
mantisa

$s-t$ bits
expón. e.

El conjunto $R(t,s)$ es finito. Calculemos explícitamente, en función de los parámetros t,s cuál es el n^o mayor, y cuál es el más cercano al 0.

$$\max_{x \in R(t,s)} |x| = \left(\frac{1}{2} + \frac{1}{2^2} + \dots + \frac{1}{2^t} \right) \times 2^{s-1} = \boxed{\left(1 - \frac{1}{2^t} \right)^{-1} 2^{s-1}}$$

~~2^{s-1}~~

$$\min_{x \in R(t,s)} |x| = \frac{1}{2} \times 2^{-s} = \boxed{2^{-s}}$$

~~2^{s-1}~~

En 32-bits $\rightarrow t=23, s=7$ se tiene $\max \approx 2^{128} = 2^{10} \approx 10^{38}$
y $\min \approx 2^{-128} = 10^{-38}$

En 64-bits ($t=53, s=10$) el resultado es 10^{308} y 10^{-308} respectivamente.

Funció Redondeo (Parte)

La función $f_l : \mathbb{R} \rightarrow \mathbb{F} = \mathbb{R}(t,s)$ ya la vimos y la idea que opera igual que la función redondeo ~~round~~, ~~round~~, ~~round~~, que ya conocemos. En este caso es más sencillo saber qué hay que veremos como aplica en el caso binario (que de hecho es más simple).

Sea $x \in \mathbb{R}$, $x = \pm \left(\sum_{k=1}^{+\infty} b_k \cdot 2^{-k} \right) 2^e$

Luego cortamos (función chop)

$$f_l(x) = x^* (\text{chop}(x)) = \pm \left(\sum_{k=1}^{t+1} b_k 2^{-k} \right) 2^e$$

Hay otra posibilidad, que funciona también que es cortar y decidir si le mandamos a izq o a derecha (tipo $\overline{10,5} = 11$)
 $(f_l(x) = \text{chop}(x + \frac{1}{2} 2^t \cdot 2^e))$

$$\begin{aligned} \text{Observar que } |x^* - x| &= \left| \pm \sum_{k=t+1}^{+\infty} b_k 2^{-k} \right| 2^e \leq \left(\sum_{k=t+1}^{+\infty} 2^{-k} \right) 2^e \\ &= 2^{-t} \cdot 2^e. \end{aligned}$$

Por lo tanto, y como era responder, el error relativo es

$$\frac{|x^* - x|}{|x|} \leq \frac{2^{-t} \cdot 2^e}{\frac{1}{2} 2^e} = 2^{-t+1}.$$