

1. Ułamkowe zadania

Przykład: $w(x) = \prod_{j=1}^{20} (x-j) = \sum_{k=0}^{20} a_k x^k = \underbrace{1}_{a_{20}} \cdot x^{20} - \underbrace{210}_{a_{19}} \cdot x^{19} + \dots$

Perfidny wielomian Wilsona

$w_\epsilon(x) = w(x) \pm \epsilon \cdot x^{19}$ (ϵ - małe)

zaburzy nieco współczynniki przy x^{19}

Wykresy $w(x)$ oraz $w_\epsilon(x)$ można się wzmagać już dla $\epsilon = 2^{-30}$, miejsca zerowe $w(x)$ są na $x=1, 2, \dots, 20$, a dla $w_\epsilon(x)$ jest ich 6 więcej zerowych w postaci liczb zespolonych.

Obserwacja: mała zmiana względna danych \Rightarrow duża względna zmiana wyniku

Przykład:

$H_n := \left[\frac{1}{i+j-1} \right]_{i,j=1,2,\dots,n} \in \mathbb{R}^{n \times n} \Rightarrow \det(H_n) = ?$

macierze Hilberta

$\tilde{H}_n := \left[\text{fl} \left(\frac{1}{i+j-1} \right) \right]_{i,j=1,2,\dots,n} \in \mathbb{R}^{n \times n} \Rightarrow \det(\tilde{H}_n) = ?$

macierze typu Hilberta, w których zamiast wartości

$\frac{1}{i+j-2}$ są ich odpowiedniki z fl

dla $n=5$ błąd około 4%;

$n=15: \det(H_n) = 0.10 \cdot 10^{-123}$
 $\det(\tilde{H}_n) = 0.48 \cdot 10^{-86}$,
 błąd ponad 100%

Obserwacja: jak użyć

Przykład: (1) $H_n x = b$, gdzie $b := H_n \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} \in \mathbb{R}^n \rightarrow$ rozwiązanie $x = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} \in \mathbb{R}^n$

(2) $\tilde{H}_n \tilde{x} = b$

uśrednianie

Jak bardzo \tilde{x} (rozwiązanie równania (2)) różni się od x (1)?

dla $n=5$ x_i ($i=1, 2, \dots, 5$) wyniki zbliżone do 1 (od 0.97 do 1.05)


$n=15$ x_i ($i=1, 2, \dots, 15$) wyniki odległe o ponad 40

$n=25$ x_i ($i=1, 2, \dots, 25$) wyniki odległe o ponad 450

Definicja - zadanie źle uwarunkowane:

Zadania, w których mała względna zmiana danych powoduje dużą, względną zmianę wyniku nazywamy zadaniami źle uwarunkowanymi. Wielkość α określa o tym w jaki sposób względna zmiana danych wpływa na względną wartość wyniku nazywaną wskaźnikami uwarunkowania. Zadania, które nie są źle uwarunkowane nazywamy dobrze uwarunkowanymi.

Intuicja:



mała zmiana argumentu powoduje ogólną zmianę wartości $f(x)$

Przykład: Zbadanie uwarunkowania zadania obliczenia wartości funkcji f w danym punkcie x ($h = \text{małe}$):

$$\left| \frac{f(x) - f(x+h)}{f(x)} \right| = \left| \frac{f(x+h) - f(x)}{h} \right| \cdot \left| \frac{h}{f(x)} \right| \approx \left| \frac{f'(x)}{f(x)} \right| \cdot |h| =$$

$\approx f'(x)$

względna zmiana wyniku

względna zmiana danych

$$\left| \frac{(x+h) - x}{x} \right| = \left| \frac{h}{x} \right|$$

$$= \left| \frac{x f'(x)}{f(x)} \right| \cdot \left| \frac{h}{x} \right|$$

wskaźnik uwarunkowania zadania obliczenia wartości funkcji f w danym punkcie

względna zmiana danych

Przykład: Niech dane będą wektory $a = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix}$ oraz $b = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{bmatrix} \in \mathbb{R}^n$. Zbadamy
 wskaźnik uwarunkowania obliczenia iloczynu skalarnego wektorów:

$$S(a, b) := a^T b = \sum_{i=1}^n a_i b_i$$

Zmiana danych:

$$\tilde{a} := \begin{bmatrix} a_1(1+\varepsilon_1) \\ a_2(1+\varepsilon_2) \\ \vdots \\ a_n(1+\varepsilon_n) \end{bmatrix}, \quad \tilde{b} = \begin{bmatrix} b_1(1+\alpha_1) \\ b_2(1+\alpha_2) \\ \vdots \\ b_n(1+\alpha_n) \end{bmatrix} \in \mathbb{R}^n : \quad \left| \frac{a_k - a_k(1+\varepsilon_k)}{a_k} \right| = |\varepsilon_k|$$

$$\left| \frac{b_k - b_k(1+\alpha_k)}{b_k} \right| = |\alpha_k|$$

względna zmiana k -tej
 współrzędnej wektora a, b

Względna zmiana wyniku:

$$\left| \frac{S(a, b) - S(\tilde{a}, \tilde{b})}{S(a, b)} \right| = \left| \frac{\sum_i a_i b_i - \sum_i a_i b_i (1+\alpha_i)(1+\beta_i)}{\sum_i a_i b_i} \right| =$$

gdy α_i, β_i są małe,
 to iloczyn $\alpha_i \beta_i$ możemy
 pominąć

$$= \left| \frac{\sum_i a_i b_i (\alpha_i + \beta_i)}{\sum_i a_i b_i} \right| \leq \frac{\sum_i |a_i b_i| |\alpha_i + \beta_i|}{\left| \sum_i a_i b_i \right|} \leq \max_i |a_i + \beta_i| \frac{\sum_i |a_i b_i|}{\left| \sum_i a_i b_i \right|}$$

maksymalna suma
 względna zmiana danych

Wobec tego wielkość $\frac{\sum_{i=1}^n |a_i b_i|}{\left| \sum_{i=1}^n a_i b_i \right|}$ można uważać za wskaźnik

uwarunkowania zadania obliczenia iloczynu skalarnego wektorów a, b .

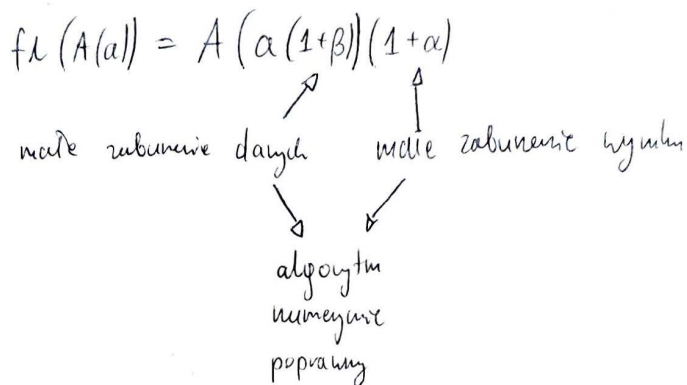
Wniosek: Jeśli a_i, b_i są tego samego znaku dla $i = 1, 2, \dots, n$, to $\text{Cond}(a, b) = 1$
 (gdzie $\text{Cond}(a, b)$ oznacza wskaźnik uwarunkowania) \Rightarrow zadanie dobrze uwarunkowane.

Jeśli np. $\sum |a_i b_i| = 1$, a $\sum a_i b_i = 10^{-100}$, to $\text{Cond}(a, b) = 10^{100}$, więc
 zadanie jest źle uwarunkowane.

Definicja: algorytm numerycznie poprawny:

Algorytm nazywamy numerycznie poprawny, jeśli wynik jego działania w ścisłej fl może być zinterpretowany jako mało zaburzony wynik dokładny dla mało zaburzonych danych.

Przykład: Chcemy obliczyć wartość $A(a)$. Wybrany algorytm wykonany w ścisłej fl wyprodukuje:



- Wnioski:
- (1) Uwarunkowane zadanie to celna zadania i nic tego nie zmienia.
 - (2) Zadanie dobrze uwarunkowane + algorytm numerycznie poprawny = SUKCES
 - (3) Zadanie źle uwarunkowane + algorytm numerycznie poprawny = KŁOPOTA

Przykład: Niech dane będą następujący algorytm obliczenia iloczynu liczb x_1, x_2, \dots, x_n :

$I := x_1$

FOR $i=2$ TO n

$I := I * x_i$

RETURN (I)

Dla uproszczenia załóżmy, że

$x_i = rd(x_i)$ dla $i=1, 2, \dots, n$,

x_i - liczby małyłone.

$$fl(I) = \left(\left(\left((x_1 \cdot x_2) (1 + \varepsilon_1) \cdot x_3 \right) (1 + \varepsilon_2) \cdot \dots \right) \cdot x_n \right) (1 + \varepsilon_{n-1}) =$$

$$= (x_1 \cdot x_2 \cdot \dots \cdot x_n) (1 + \varepsilon_1)(1 + \varepsilon_2) \dots (1 + \varepsilon_{n-1}) =$$

$$= (x_1(1 + \varepsilon_1))(x_2(1 + \varepsilon_2)) \dots (x_{n-1}(1 + \varepsilon_{n-1})) \cdot x_n =$$

$$= I(x_1(1 + \varepsilon_1), x_2(1 + \varepsilon_2), \dots, x_{n-1}(1 + \varepsilon_{n-1}), x_n)$$

\uparrow

wynik dokładny dla mało zaburzonych danych,

JEST TO ALGORYTM NUMERYCZNIE POPRAWNY