

Jak trudne jest numeryczne całkowanie (O złożoności zadań ciągłych)

Leszek Plaskota

Uniwersytet Warszawski
Wydział Matematyki, Informatyki i Mechaniki
leszkep@mimuw.edu.pl

Horyzonty 2014
17-03-2014
Będlewo

Zadania numeryczne - przykłady

- *Rozwiązywanie układów równań liniowych:*
dla danych $A \in \mathbb{R}^{n,n}$, $\det A \neq 0$, $\vec{b} \in \mathbb{R}^n$, obliczyć $A^{-1}\vec{b}$
- *Interpolacja wielomianowa:*
dla danych wartości $f(t_j)$ funkcji $f : \mathbb{R} \rightarrow \mathbb{R}$, $0 \leq j \leq n$,
obliczyć współczynniki a_0, \dots, a_n rozwinięcia w bazie
 p_0, \dots, p_n wielomianu $w = \sum_{i=0}^n a_i p_i$, takiego że

$$w(t_j) = f(t_j), \quad 0 \leq j \leq n$$

- *Całkowanie funkcji:*
dla danej funkcji $f : D \rightarrow \mathbb{R}$ obliczyć (przybliżyć) całkę
 $\int_D f(x) dx$ na podstawie wartości $f(t_j)$, $1 \leq j \leq n$
- ...

Zadania numeryczne - schemat ogólny

Chcemy aproksymować wartości $S(f)$ odwzorowania

$$S : F \rightarrow G \quad (\text{zadanie})$$

gdzie F przestrzeń liniowa (dane), G unormowana (wyniki)

Schemat aproksymacji:

$$f \mapsto N(f) \mapsto \varphi(N(f))$$

$$N : F \rightarrow Y \quad (\text{informacja})$$

$$\varphi : Y \rightarrow G \quad (\text{algorytm})$$

$$S \sim \varphi \circ N$$

Błąd algorytmu (przypadek najgorszy)

Błąd algorytmu φ korzystającego z informacji N , na klasie $E \subseteq F$:

$$e^{\text{wor}}(\varphi, N) := \sup_{f \in E} \|S(f) - \varphi(Nf)\|_G$$

Algorytm φ^* jest optymalny dla N gdy

$$e^{\text{wor}}(\varphi^*, N) = \inf_{\varphi} e^{\text{wor}}(\varphi, N)$$

Twierdzenie (Promień informacji)

$$r^{\text{wor}}(N) := \inf_{\varphi} e^{\text{wor}}(\varphi, N) = \sup_{y \in N(E)} \text{rad}(S(E \cap N^{-1}y))$$

gdzie $\text{rad}(A)$ jest promieniem Czebyszewa zbioru A

$$S(E \cap N^{-1}y) = \{S(h) : h \in E, Nh = y\}$$

Optymalność algorytmów liniowych dla funkcjonałów

Niech zadanie $S : F \rightarrow \mathbb{R}$ będzie funkcjonałem liniowym, a $N : F \rightarrow \mathbb{R}^n$ informacją liniową

Twierdzenie (Smolak 1963)

Jeśli klasa $E \subset F$ jest wypukła i zbalansowana to dla informacji N istnieje algorytm liniowy φ^{lin} , który jest optymalny,

$$e^{\text{wor}}(\varphi^{\text{lin}}, N) = r^{\text{wor}}(N)$$

Wniosek: kwadratury numeryczne $Q_n(f) = \sum_{i=1}^n a_i f(t_i)$ korzystające z wartości funkcji są optymalne o ile klasa funkcji podcałkowych jest wypukła i zbalansowana

Dowód Tw. Smolaka

Lemat

$$r^{\text{wor}}(N) = \sup\{|Sh| : h \in E \cap \ker N\} = \text{rad}(S(E \cap \ker N))$$

Dowód (lematu). Dla dowolnego $y \in N(E)$ mamy

$$\begin{aligned} \text{rad}(S(E \cap N^{-1}y)) &= \frac{1}{2} \text{diam}(S(E \cap N^{-1}y)) \\ &= \sup \left\{ \left| S\left(\frac{f_1 - f_2}{2}\right) \right| : f_1, f_2 \in E, N\left(\frac{f_1 - f_2}{2}\right) = 0 \right\} \\ &\leq \sup\{|Sh| : h \in E, Nh = 0\} = \text{rad}(S(E \cap \ker N)) \end{aligned}$$

Z drugiej strony, $r^{\text{wor}}(N) \geq \text{rad}(S(E \cap \ker N))$. \square

Dowód Tw. Smolaka, c.d.

Niech $r := r^{\text{wor}}(N) > 0$,

$$A = \{(Nf, Sf) : f \in E\} \subset \mathbb{R}^{n+1}$$

A jest wypukły i zbalansowany. Przy (upraszczających) założeniach, że jest też pochłaniający i ograniczony, *funkcjał Minkowskiego*

$$\|u\| := \inf\{t > 0 : u/t \in A\}$$

definiuje normę w \mathbb{R}^{n+1} .

Zdefiniujmy na $P = \{(0, g) : g \in \mathbb{R}\}$ funkcjał

$$\xi_1(0, g) = g/r$$

Ponieważ $\|(0, g)\| = |g|/r$ to $|\xi_1(0, g)| \leq \|(0, g)\|$.

Dowód Tw. Smolaka, c.d.

ξ_1 można teraz rozszerzyć (Tw. Hahna-Banacha!) do funkcjonału ξ_2 na \mathbb{R}^{n+1} z zachowaniem normy, tzn.

(i) $\xi_2(x) = \xi_1(x)$ dla $x = (0, g)$, $g \in \mathbb{R}$

(ii) $|\xi_2(x)| \leq 1$ dla $x \in \mathbb{R}^{n+1}$

Stąd

$$|\xi_2(y, g)| = |\xi_2(0, g) + \xi_2(y, 0)| = \left| \frac{g}{r} + \xi_2(y, 0) \right| \leq 1$$

Przyjmując $y = Nf$, $g = Sf$,

$$\varphi(y) = -r \xi_2(y, 0)$$

dostajemy $|Sf - \varphi(Nf)| \leq r$. \square

Adaptacja nie pomaga

Informacja *adaptacyjna* $y = N^{\text{ada}}(f)$

$$y_1 = f(x_1)$$

$$y_2 = f(x_2(y_1))$$

...

$$y_n = f(x_n(y_1, y_2, \dots, y_{n-1}))$$

ozn. wybór x_i zależy od wartości y_1, \dots, y_{i-1} z poprzednich kroków

Dla N^{ada} definiujemy informację *nieadaptacyjną*

$$N^{\text{non}}(f) = [f(x_1), f(x_2(0)), \dots, f(x_n(\underbrace{0, \dots, 0}_{n-1}))]$$

Adaptacja nie pomaga, c.d.

Twierdzenie (Bachwałow 1971)

$$r^{\text{wor}}(N^{\text{non}}) \leq r^{\text{wor}}(N^{\text{ada}})$$

Dowód.

$$\begin{aligned} r^{\text{wor}}(N^{\text{ada}}) &= \sup_{y \in N^{\text{ada}}(E)} \text{rad}(\{Sf : f \in E, N^{\text{ada}}(f) = y\}) \\ &\geq \text{rad}(\{Sh : h \in E, N^{\text{ada}}(h) = 0\}) \\ &= \text{rad}(\{Sh : h \in E, N^{\text{non}}(h) = 0\}) \\ &= r^{\text{wor}}(N^{\text{non}}). \quad \square \end{aligned}$$

Całkowanie funkcji lipschitzowskich

Zadanie:

$$S_d(f) = \int_{[0,1]^d} f(x) dx, \quad f \in E$$

$$E = \{f : [0, 1]^d \rightarrow \mathbb{R} : \|f\|_F \leq 1\}$$

$$\|f\|_F = \max \left(\sup_{x \in [0,1]^d} |f(x)|, \sup_{x,y \in [0,1]^d} \frac{|f(x) - f(y)|}{\|x - y\|_\infty} \right)$$

Informacja:

$$N_n(f) = [f(t_1), f(t_2), \dots, f(t_n)], \quad t_j \in [0, 1]^d$$

ε -złożoność zadania:

$$n^{\text{WOR}}(\varepsilon, d) = \min\{n : \exists N_n r^{\text{WOR}}(N_n) \leq \varepsilon\}$$

Całkowanie funkcji lipschitzowskich, c.d.

Twierdzenie (Sucharew 1979)

Jeśli $\varepsilon = 1/((2 + 2/d)m)$ dla pewnej m to

$$n^{\text{wor}}(\varepsilon, d) = \frac{1}{(1 + 1/d)^d} \left(\frac{1}{2\varepsilon}\right)^d = \frac{1 + o(1)}{e} \left(\frac{1}{2\varepsilon}\right)^d$$

Optymalną kwadraturą jest złożona kwadratura trapezów oparta na siatce jednorodnej.

Jeśli, np. $\varepsilon = 0.05$ ale $d = 20$ to $n^{\text{wor}}(\varepsilon, d) \asymp 10^{20}$

\implies przekleństwo wymiaru

Podatność i przekleństwo wymiaru

$$S_d : F_d \rightarrow G_d, \quad d = 1, 2, 3, \dots$$

Definicja

Zadanie S_d jest podatne wielomianowo gdy istnieją C, p, q , że

$$n^{\text{wor}}(\varepsilon, d) \leq C d^q \varepsilon^{-p} \quad \forall d \quad \forall \varepsilon \in (0, 1)$$

Definicja

Zadanie S_d podlega przekleństwu wymiaru gdy istnieje $\alpha > 0$, że

$$n^{\text{wor}}(\varepsilon, d) \geq (1 + \alpha)^d \quad \text{dla prawie wszystkich } d$$

Wniosek:

całkowanie funkcji lipschitzowskich podlega przekleństwu wymiaru

Całkowanie funkcji r -gładkich

$$F = F_{d,r} = \left\{ f : [0, 1]^d \rightarrow \mathbb{R} : \|f\|_{d,r} := \max_{|\alpha| \leq r} \max_{x \in [0,1]^d} |D^\alpha f(x)| \leq 1 \right\}$$

Twierdzenie (Bachwałow 1959)

$$n^{\text{wor}}(\varepsilon, d) = c_{r,d} \left(\frac{1}{\varepsilon} \right)^{d/r}$$

Wniosek: Całkowanie funkcji r -gładkich nie jest podatne wielomianowo

Czy występuje przekleństwo wymiaru?

TAK! \implies Hinrichs, Novak, Ullrich, Woźniakowski (2013)

Algorytmy randomizacyjne (Monte Carlo)

Informacja i algorytm:

$$(N, \varphi) = \{(N_\omega, \varphi_\omega)\} \quad \omega - \text{zmienna losowa}$$

Błąd algorytmu randomizacyjnego:

$$e^{\text{rand}}(N, \varphi) = \sup_{f \in E} \sqrt{\mathbb{E}_\omega |S_d(f) - \varphi_\omega(N_\omega f)|^2}$$

Przykład: (klasyczne Monte Carlo)

$$\text{MC}_n(f) = \frac{1}{n} \sum_{j=1}^n f(t_j)$$

t_j - niezależne zmienne losowe z rozkładu jednostajnego na $[0, 1]^d$

Algorytmy randomizacyjne (Monte Carlo), c.d.

W klasie $F_{d,r}$ mamy

$$e^{\text{rand}}(\text{MC}_n) = n^{-1/2}$$

Rzeczywiście, oznaczając $X = \text{MC}_n(f)$ mamy $\mathbb{E}(X) = S_d(f)$,

$$(e^{\text{rand}}(\text{MC}_n))^2 = \mathbb{E}(X - \mathbb{E}(X))^2 = \mathbb{E}(X^2) - \mathbb{E}^2(X)$$

$$\begin{aligned} \mathbb{E}\left(\frac{1}{n} \sum_{i=1}^n f(t_i)\right)^2 &= \frac{1}{n^2} \mathbb{E}\left(\sum_{i=1}^n f^2(t_i) + 2 \sum_{i < j} f(t_i)f(t_j)\right) \\ &= \frac{1}{n} S_d(f^2) + \frac{n-1}{n} (S_d(f))^2 \end{aligned}$$

$$\mathbb{E}(X^2) - \mathbb{E}^2(X) = \frac{S_d(f^2) - (S_d(f))^2}{n} \leq \frac{1}{n} \int_{[0,1]^d} f^2(t) dt \leq \frac{1}{n}$$

Algorytmy randomizacyjne (Monte Carlo), c.d.

Powyższe implikuje silną wielomianową podatność

$$n^{\text{rand}}(\varepsilon, d) \leq \varepsilon^{-2}$$

przy czym wykładnik 2 jest optymalny

Twierdzenie (Bachwałow 1959)

$$n^{\text{rand}}(\varepsilon, d) = c_{r,d} \left(\frac{1}{\varepsilon}\right)^{2/(1+2r/d)}$$

Algorytm:

$$\widetilde{\text{MC}}_n(f) = S_d(A_n f) + \text{MC}_n(f - A_n f)$$

gdzie $A_n f$ jest kawałkami wielomianową aproksymacją funkcji f

Dyskrepancja i quasi-Monte Carlo

Definicja (Dyskrepancja)

$$\text{disc}(t_1, \dots, t_n) = \sup_{x \in [0,1]^d} \left| \text{Vol}([0, x]) - \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{[0, x]}(t_i) \right|$$

Rozpatrujemy algorytmy postaci

$$\text{QMC}_n(f) = \frac{1}{n} \sum_{j=1}^n f(t_j)$$

gdzie t_1, \dots, t_n są wybrane deterministycznie, dla klasy

$$E = \{f : [0, 1]^d \rightarrow \mathbb{R} : f(\dots, 1, \dots) = 0, \|f\|_{d,*} \leq 1\}$$

$$\|f\|_{d,*} = \sup_{x \in [0,1]^d} \left| \frac{\partial^d f}{\partial x_1 \dots \partial x_d}(x) \right|$$

Dyskrepancja i quasi-Monte Carlo, c.d.

Twierdzenie (Zaremba-Koksma-Hlavka)

$$e^{\text{wor}}(\text{QMC}_n) = \text{disc}(t_1, \dots, t_n)$$

Najlepsze konstrukcje punktów t_i dają

$$\text{disc}(t_1, \dots, t_n) \leq c_d \frac{\ln^{d-1} n}{n}$$

Twierdzenie (Heinrich, Novak, Wasilkowski, Woźniakowski 2001)

Istnieją punkty t_i^ , takie że*

$$\text{disc}(t_1^*, \dots, t_n^*) \leq C d^{1/2} n^{-1/2}$$

To daje podatność wielomianową

Dowód jest niekonstruktywny(!)

Bibliografia (IBC)

- 1 A. Hinrichs, E. Novak, M. Ullrich, H. Woźniakowski, The curse of dimensionality for numerical integration of smooth functions, przyjęta do *Math. Comp.* 2013
- 2 E. Novak, H. Woźniakowski, *Tractability of Multivariate Problems, Vol. I, II, III*, EMS Tracts in Mathematics **6** 2008, **12** 2010, **18** 2012
- 3 L. Plaskota, *Noisy Information and Computational Complexity*, Cambridge Univ. Press, Cambridge, 1996
- 4 K. Ritter, *Average Case Analysis of Numerical Problems*, Lecture Notes in Math. **1733**, Springer-Verlag, Berlin, 2000
- 5 J.F. Traub, G.W. Wasilkowski, H. Woźniakowski, *Information-Based Complexity*, Academic Press, New York, 1988