

Metody Numeryczne

Wykład 7 Optymalizacja

Wojciech Kordecki

Collegium Witelona
Wydział Nauk Technicznych i Ekonomicznych
Zakład Informatyki, Energetyki i Technologii Cyfrowych

Semestr letni 2025/26



Minima i maksima

Niech f będzie funkcją n zmiennych, to znaczy

$$f(x) = f(x_1, x_2, \dots, x_n),$$

czyli $x = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ jest wektorem.



Minima i maksima

Niech f będzie funkcją n zmiennych, to znaczy

$$f(x) = f(x_1, x_2, \dots, x_n),$$

czyli $x = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ jest wektorem.

Minimum globalne w punkcie p : $f(p) \leq f(x)$ dla każdego x .



Minima i maksima

Niech f będzie funkcją n zmiennych, to znaczy

$$f(x) = f(x_1, x_2, \dots, x_n),$$

czyli $x = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ jest wektorem.

Minimum globalne w punkcie p : $f(p) \leq f(x)$ dla każdego x .

Minimum lokalne w punkcie p : $f(p) \leq f(x)$ dla x należących do pewnego otwartego otoczenia punktu p .



Otoczenie otwarte punktu p

Założenie: $r > 0$ i oznaczenie $p = (p_1, p_2, \dots, p_n)$.



Otoczenie otwarte punktu p

Założenie: $r > 0$ i oznaczenie $p = (p_1, p_2, \dots, p_n)$.

Kule otwarte o środku p .



Otoczenie otwarte punktu p

Założenie: $r > 0$ i oznaczenie $p = (p_1, p_2, \dots, p_n)$.

Kule otwarte o środku p .

Prosta \mathbb{R} : odcinek $(p - r, p + r)$.



Otoczenie otwarte punktu p

Założenie: $r > 0$ i oznaczenie $p = (p_1, p_2, \dots, p_n)$.

Kule otwarte o środku p .

Prosta \mathbb{R} : odcinek $(p - r, p + r)$.

Płaszczyzna \mathbb{R}^2 : koło

$$\left\{ (x, y) : (x - p_x)^2 + (y - p_y)^2 < r^2 \right\}.$$



Otoczenie otwarte punktu p

Założenie: $r > 0$ i oznaczenie $p = (p_1, p_2, \dots, p_n)$.

Kule otwarte o środku p .

Prosta \mathbb{R} : odcinek $(p - r, p + r)$.

Płaszczyzna \mathbb{R}^2 : koło

$$\left\{ (x, y) : (x - p_x)^2 + (y - p_y)^2 < r^2 \right\}.$$

Przestrzeń n -wymiarowa \mathbb{R}^n : kula n -wymiarowa

$$\left\{ (x_1, x_2, \dots, x_n) : (x_1 - p_1)^2 + (x_2 - p_2)^2 + \dots + (x_n - p_n)^2 < r^2 \right\}.$$



Przykład – funkcja jednej zmiennej

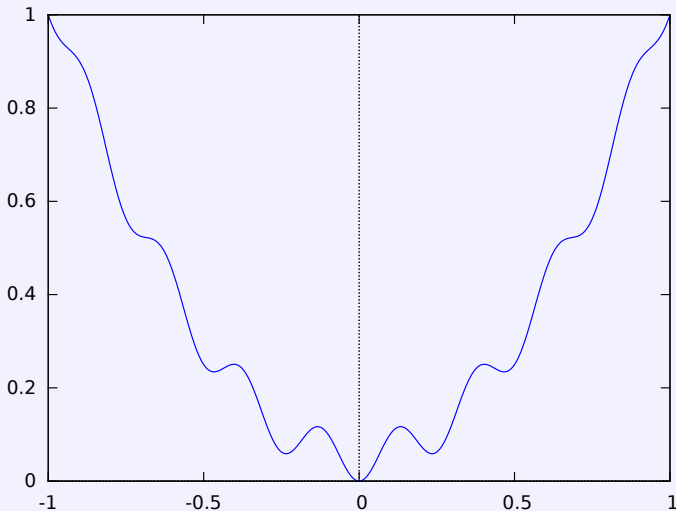
Funkcja

$$f(x) = x^2 - 0.1 (\cos^2(4\pi x) - 1)$$

określona na przedziale $[-1, 1]$ ma jedno minimum globalne w punkcie $x = 0$ i ponadto jeszcze cztery minima lokalne.



Przykład – wykres




Minima lokalne

Cztery minima tylko lokalne, co łatwo stwierdzić, patrząc na wykres pochodnej $f'(r)$.

Minima lokalne są w tych punktach r , w których $f'(r)$ zmienia znak z ujemnego na dodatni wraz ze wzrostem r .



Przykład – wykres pochodnej



Przykład – funkcja dwóch zmiennych


Funkcja

$$f(x, y) = x^2 + y^2 - 0.1 \left(\cos^2 \left(4\pi \sqrt{x^2 + y^2} \right) - 1 \right)$$

określona na kwadracie $[-1, 1] \times [-1, 1]$ ma jedno minimum globalne w punkcie $p = (0, 0)$ i ponadto jeszcze minima lokalne.



Przykład – wykres



Szczególny przypadek – funkcje jednej zmiennej

Algorytmy optymalizacji dla funkcji wielu zmiennych wymagają często jej badania wzdłuż pewnej prostej.

Sprowadza się to szukania minimów funkcji jednej zmiennej.



Szczególny przypadek – funkcje jednej zmiennej

Algorytmy optymalizacji dla funkcji wielu zmiennych wymagają często jej badania wzdłuż pewnej prostej.

Sprowadza się to szukania minimów funkcji jednej zmiennej.

Przykład. Ponieważ funkcja

$$f(x, y) = x^2 + y^2 - 0.1 \left(\cos^2 \left(4\pi \sqrt{x^2 + y^2} \right) - 1 \right)$$

ma stałą wartość na okręgu $x^2 + y^2 = r^2$, więc szukanie jej minimów sprowadza się do szukania minimów funkcji

$$f(r) = r^2 - 0.1 \left(\cos^2(4\pi r) - 1 \right)$$



Pochodne i minima

Szukamy minimum funkcji $f(x)$.



Pochodne i minima

Szukamy minimum funkcji $f(x)$.

Dwa typy algorytmów:

- używamy pochodnej funkcji f (o ile istnieje),
- nie używamy pochodnej (nawet jeśli istnieje).

Jeśli pochodna nie jest znana, to można stosować procedurę przeszukiwania, obliczając wartości $f(kh)$ dla $k = 0, \pm 1, \pm 2, \dots$, co może dać informację o minimum.



Pochodne i minima

Szukamy minimum funkcji $f(x)$.

Dwa typy algorytmów:

- używamy pochodnej funkcji f (o ile istnieje),
- nie używamy pochodnej (nawet jeśli istnieje).

Jeśli pochodna nie jest znana, to można stosować procedurę przeszukiwania, obliczając wartości $f(kh)$ dla $k = 0, \pm 1, \pm 2, \dots$, co może dać informację o minimum.

Uwaga. Dla każdego h można znaleźć taką funkcję, dla której ta procedura zawodzi.



Przykład

$$f(x) = x/2 + 0.1 \sin(10x + 0.2\pi)$$

Szukamy maksimum w przedziale $[-1, 1]$ co $h = 0.1$. Otrzymujemy w punktach $-0.1k$ dla $k = -10, -9, \dots, 9, 10$ wartości

-0.5053071546401395	-0.5368959789109834	-0.4885930409124076
-0.3588380696667052	-0.2209574179282806	-0.1557481516230514
-0.1771936000509204	-0.219607147414871	-0.1980242044553964
-0.08631825998141032	0.05877852522924731	0.1498346054151921
0.149103209793281	0.1032265495384814	0.1003531839311835
0.1890946414727188	0.3338322047647849	0.4474645950213138
0.4714884860962557	0.429786192740345	0.4066683805582128

Maksima są zaś osiągame w punktach

-0.481710873550435 , 0.1466076571675237 , 0.7749261878854823


i wynoszą odpowiednio

-0.1542528963967736 , 0.1599063689622057 , 0.4740656343211851 .



Przykład – wykres

x	-0.481710873550435	0.1466076571675237	0.7749261878854823
$h(x)$	-0.1542528963967736	0.1599063689622057	0.4740656343211851



Przykład


$$f(x) = e^x + 0.1e^{-5000(x-0.5)^2} - 1.$$

Jak widać z wykresu funkcji tej funkcji, jej przeszukiwanie dla $h = 0.1$, począwszy od $x = 0$, nie znajdzie maksimum, które znajduje się w punkcie $x_0 = 0.5017$ i ma wartość $f(x_0) = 0.7501$. Wartości $f(x)$ w punktach 0.4, 0.5, 0.6 wynoszą odpowiednio 0.4918, 0.7487, 0.8221.

Inaczej mówiąc, przeszukiwanie co $h = 0.1$ „przeskoczy” punkt, w którym funkcja ma maksimum.



Przykład – wykres



Funkcje unimodalne

Funkcja $f(x)$ jest *unimodalna*, gdy ma tylko jedno minimum (maksimum) lokalne.

Przykład.

$$f(x) = 2 - \frac{1}{1+x^2}$$

jest funkcją unimodalną.



Funkcje unimodalne

Funkcja $f(x)$ jest *unimodalna*, gdy ma tylko jedno minimum (maksimum) lokalne.

Przykład.

$$f(x) = 2 - \frac{1}{1+x^2}$$

jest funkcją unimodalną.

Funkcje


$$f_1(x) = 2 - \frac{1}{1+(x-1)^2} - \frac{1}{1+(x+1)^2},$$

$$f_2(x) = 2 \frac{1}{1+(x-1)^2} - \frac{0.7}{1+(x+1)^2}$$


nie są funkcjami unimodalnymi.



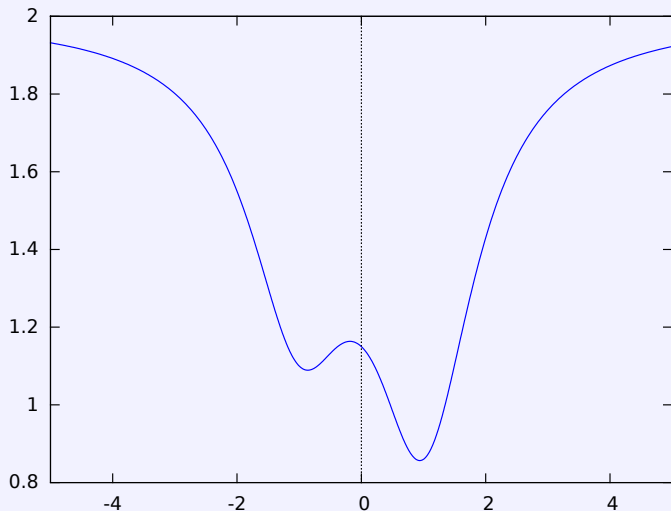
Funkcja $f(x)$ – wykres



Funkcja $f_1(x)$ – wykres



Funkcja $f_2(x)$ – wykres



Metoda złotego podziału odcinka

Taką metodę można stosować w przypadku funkcji unimodalnej.

$$r = \frac{1}{2} (\sqrt{5} - 1) = 0.6180339887498949 \dots,$$

jest pierwiastkiem równania

$$r^2 + r - 1 = 0.$$

Szukamy minimum funkcji $f(x)$ w przedziale $[a, b]$.

$$x_R = a + r(b - a),$$

$$x_L = b - r(b - a),$$

$$u = f(x_R),$$

$$v = f(x_L).$$



Metoda złotego podziału – algorytm

Jeśli $u > v$, to minimum jest w $[a, x_R]$.



Metoda złotego podziału – algorytm

Jeśli $u > v$, to minimum jest w $[a, x_R]$.

$$b \leftarrow x_R, x_R \leftarrow x_L,$$

$$x_L \leftarrow b - r(b - a).$$



Metoda złotego podziału – algorytm

Jeśli $u > v$, to minimum jest w $[a, x_R]$.

$$b \leftarrow x_R, x_R \leftarrow x_L, \\ x_L \leftarrow b - r(b - a).$$

Jeśli $u \leq v$, to minimum jest w $[x_L, b]$.



Metoda złotego podziału – algorytm

Jeśli $u > v$, to minimum jest w $[a, x_R]$.


$$\begin{aligned} b &\leftarrow x_R, x_R \leftarrow x_L, \\ x_L &\leftarrow b - r(b - a). \end{aligned}$$

Jeśli $u \leq v$, to minimum jest w $[x_L, b]$.

$$\begin{aligned} a &\leftarrow x_L, x_L \leftarrow x_R, \\ x_R &\leftarrow a + r(b - a). \end{aligned}$$



Ilustracja algorytmu (1)



Ilustracja algorytmu (2)

Funkcja ta jest unimodalna i ma minimum w punkcie x_0 .

Ponieważ $v = f(x_L) > f(x_R) = u$, to minimum znajduje się w przedziale $[x_L, b]$.


Podstawiamy $a \leftarrow x_L$, $x_L \leftarrow x_R$, wyznaczamy nowe x_R i ponawiamy szukanie minimum według tej samej procedury.

Powtarzamy procedurę, aż $\delta = |a - b|$ będzie mniejsza niż założona dokładność.



Przykład (1)

$$f(x) = 2 + \frac{x}{4} - \frac{1}{1+x^2}.$$



Przykład (2)

Przedział $[-1, 1]$, czyli $a = -1$, $b = 1$.

Stąd $x = 0.2360679774997898$, $y = -0.2360679774997896$,

$u = 1.11180339887499$, $v = 0.9937694101250946$, $u > v$.



Przykład (2)

Przedział $[-1, 1]$, czyli $a = -1$, $b = 1$.

Stąd $x = 0.2360679774997898$, $y = -0.2360679774997896$,
 $u = 1.11180339887499$, $v = 0.9937694101250946$, $u > v$.

Minimum jest w przedziale $[-1, 0.2360679774997898]$.



Przykład (2)

Przedział $[-1, 1]$, czyli $a = -1$, $b = 1$.

Stąd $x = 0.2360679774997898$, $y = -0.2360679774997896$,
 $u = 1.11180339887499$, $v = 0.9937694101250946$, $u > v$.

Minimum jest w przedziale $[-1, 0.2360679774997898]$.

Powtarzamy procedurę szukania minimum w przedziale
 $[-1, 0.2360679774997898]$.

Teraz $u = -0.5278640450004205 < v = 0.2360679774997898$,
więc minimum jest w przedziale
 $[-0.5278640450004205, 0.2360679774997898]$.



Przykład (3)

Pochodna

$$f'(x) = \frac{2x}{x^2 + 1} + 0.25 = \frac{x^4 + 2x^2 + 8x + 1}{4x^4 + 8x^2 + 4}$$

zeruje się w punkcie $x_0 = -0.1292085522452846$.

Przykład (3)

Pochodna

$$f'(x) = \frac{2x}{x^2 + 1} + 0.25 = \frac{x^4 + 2x^2 + 8x + 1}{4x^4 + 8x^2 + 4}$$


zeruje się w punkcie $x_0 = -0.1292085522452846$.

W tym punkcie funkcja $f(x)$ ma minimum.

$$f(x_0) = 0.9841185706437151.$$



Przykład (4)



Przykład (5) – kolejne przybliżenia

k	a	b
0	-1	1
1	-1	0.2361
2	-0.5279	0.2361
3	-0.2361	0.2361
...
19	-0.1294	-0.1290
20	-0.1294	-0.1291



Gradient i hesjan

Niech $x \in \mathbb{R}^n$.



Gradient i hesjan

Niech $x \in \mathbb{R}^n$.

Gradient $G = \nabla f$ – wektor o składowych

$$\frac{\partial f(x)}{\partial x_i}, \quad 1 \leq i \leq n.$$

Hesjan – macierz H o elementach

$$\frac{\partial^2 f(x)}{\partial x_i \partial x_j}, \quad 1 \leq i, j \leq n.$$



Wzór Taylora

Początkowe wyrazy wzoru Taylora dla funkcji f :

$$f(x+h) = f(x) + G(x)^T h + \frac{1}{2} h^T H(x) h + \dots$$



Wzór Taylora

Początkowe wyrazy wzoru Taylora dla funkcji f :

$$f(x+h) = f(x) + G(x)^T h + \frac{1}{2} h^T H(x) h + \dots$$

Gradient pokazuje kierunek najszybszego wzrostu funkcji f , a w przeciwnym kierunku – najszybszego spadku.


Przybliżenie:

$$f(x) \approx f(x_0) + G(x_0)^T (x - x_0) + \frac{1}{2} (x - x_0)^T H(x_0) (x - x_0). \quad (1)$$



Przykład funkcji

$$f(x, y) = -e^{-(x^2+y^2)} + 0.24(x + y),$$



Obliczenia (1)

$$\frac{\partial f}{\partial x} = 2xe^{-y^2-x^2} + 0.24,$$

$$\frac{\partial f}{\partial y} = 2ye^{-y^2-x^2} + 0.24,$$

$$\frac{\partial^2 f}{\partial x^2} = -(4x^2 - 2) e^{-y^2-x^2},$$

$$\frac{\partial^2 f}{\partial y^2} = -(4y^2 - 2) e^{-y^2-x^2},$$

$$\frac{\partial^2 f}{\partial x \partial y} = -4xye^{-y^2-x^2}.$$



Obliczenia (2)

Stąd gradient

$$G(x, y) = \begin{bmatrix} 2xe^{-y^2-x^2} + 0.24 \\ 2ye^{-y^2-x^2} + 0.24 \end{bmatrix}$$

i hesjan

$$H(x, y) = \begin{bmatrix} -(4x^2 - 2)e^{-y^2-x^2} & -4xye^{-y^2-x^2} \\ -4xye^{-y^2-x^2} & -(4y^2 - 2)e^{-y^2-x^2} \end{bmatrix}.$$

W punkcie (0,0) mamy

$$G(0,0) = \begin{bmatrix} 0.24 \\ 0.24 \end{bmatrix}$$

oraz

$$H(0,0) = \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix}.$$



Obliczenia (3) – przybliżenie

$$f(x, y) \approx t(x, y) = -1 + 0.24(x + y) + (x^2 + y^2)$$

dla (x, y) w pobliżu punktu $(0, 0)$.



Obliczenia (3) – przybliżenie

$$f(x, y) \approx t(x, y) = -1 + 0.24(x + y) + (x^2 + y^2)$$

dla (x, y) w pobliżu punktu $(0, 0)$.

Istotnie $t(x, y)$ jest tylko przybliżeniem $f(x, y)$. Na przykład $f(0.1, 0.1) = -0.9322$, natomiast $t(0.1, 0.1) = -1.068$.



Szukamy minimum

$$f(x, y) = -e^{-(x^2+y^2)} + 0.24(x + y),$$



Szukamy minimum

$$f(x, y) = -e^{-(x^2+y^2)} + 0.24(x + y),$$

$f(x, y) = f(y, x)$ dla dowolnej pary (x, y) .

Jeśli $f(x, y)$ ma minimum, to będzie ono leżeć na prostej o równaniu $y = x$. Wtedy wystarczy znaleźć minimum funkcji

$$g(x) = f(x, x) = -e^{-2x^2} + 0.48x.$$

Dowolną metodą znajdujemy punkt, w którym $g(x)$ ma minimum.

Jest nim $x = -0.1237$: $f(x, y)$ ma minimum w punkcie

$(-0.1237, -0.1237)$, a jego wartość wynosi -1.0292 .

Można też obliczyć pochodną funkcji $g(x)$:

$$g'(x) = 4xe^{-2x^2} + 0.48.$$



Metoda gradientu

Jest to metoda największego spadku.

- 1 Startujemy z dowolnego punktu x^0 i idziemy w kierunku $-\nabla f(x^0)$.
- 2 Na półprostej $\{x^0 - t\nabla f(x^0) : t \geq 0\}$ znajdujemy punkt x^1 , w którym $f(x)$ ma minimum, a z niego powtarzamy algorytm, otrzymując dalsze punkty x^i .



Metoda gradientu prostego


Prostsza wersja tego algorytmu zastępuje szukanie minimum na półprostej z kroku 2 przez wybór następnego punktu $x^{i+1} = x^i - h \nabla f(x^i)$, gdzie $h > 0$ jest ustalonym, małym parametrem.



Przykład

$$f(x, y) = -e^{-(x^2+y^2)} + 0.24(x+y),$$

Korzystamy z prostszej wersji algorytmu i przyjmujemy $h = 0.8$.



Przykład c.d.

Jako początkowy punkt wybrano $(2, 0)$. Ponieważ

$$\nabla f(2, 0) = (0.3133, 0.24),$$

to następnym punktem jest

$$(2, 0) - h\nabla f(2, 0) = (1.7494, -0.1920).$$

W nim ponownie obliczamy gradient i idziemy do następnego punktu.



Kolejne punkty

i	x_i	y_i	$f(x_i, y_i)$
0	2.0000	0.0000	0.4617
1	1.7494	-0.1920	0.3286
2	1.4309	-0.3701	0.1421
3	0.9813	-0.4955	-0.1820
4	0.3204	-0.4507	-0.4507



Wielomian kwadratowy

Zakłada się, że funkcję f można lokalnie przybliżyć wielomianem kwadratowym

$$p(x) = a - b^T x + \frac{1}{2} x^T A x,$$

gdzie

a – skalar,

b – wektor o n składowych,

A – macierz kwadratowa, symetryczna, stopnia n .



Wielomian kwadratowy

Zakłada się, że funkcję f można lokalnie przybliżyć wielomianem kwadratowym

$$p(x) = a - b^T x + \frac{1}{2} x^T A x,$$

gdzie

a – skalar,

b – wektor o n składowych,

A – macierz kwadratowa, symetryczna, stopnia n .

Funkcja f ma minimum, gdy jest nieujemnie określona.



Wielomian kwadratowy c.d.

$$f(x) = a - \sum_{i=1}^n b_i x_i + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j .$$



Wielomian kwadratowy c.d.

$$f(x) = a - \sum_{i=1}^n b_i x_i + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j.$$

Gradient ∇f ma składowe

$$\frac{\partial f}{\partial x_k} = b_k + \sum_{i=1}^n A_{ik} x_i,$$



Wielomian kwadratowy c.d.

$$f(x) = a - \sum_{i=1}^n b_i x_i + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j.$$

Gradient ∇f ma składowe

$$\frac{\partial f}{\partial x_k} = b_k + \sum_{i=1}^n A_{ik} x_i,$$


czyli

$$\nabla f(x) = Ax - b.$$



Przykład – jest minimum

$$A = \begin{bmatrix} 3 & 2 \\ 1 & 3 \end{bmatrix}, \quad b = \begin{bmatrix} 1 \\ 2 \end{bmatrix}, \quad x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}, \quad a = -1, \quad \det A > 0.$$



Przykład – nie ma minimum

$$A = \begin{bmatrix} 1 & 2 \\ 1 & 1 \end{bmatrix}, \quad b = \begin{bmatrix} 1 \\ 2 \end{bmatrix}, \quad x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}, \quad a = -1, \quad \det A < 0.$$

