

Optymalizacja ciągła

2. Podstawy matematyczne

Wojciech Kotłowski

Instytut Informatyki PP

<http://www.cs.put.poznan.pl/wkotlowski/>

7.03.2019

Plan wykładu

1. Wektory i macierze
2. Pochodne cząstkowe, gradient i hesjan

Wektory i macierze

Przestrzeń wektorowa \mathbb{R}^n

Przestrzeń \mathbb{R}^n definiujemy jako n -krotny iloczyn kartezjański:

$$\mathbb{R}^n = \underbrace{\mathbb{R} \times \dots \times \mathbb{R}}_n$$

Elementy tej przestrzeni $\mathbf{x} = (x_1, x_2, \dots, x_n)$ nazywamy **wektorami**.

Przestrzeń wektorowa \mathbb{R}^n

Przestrzeń \mathbb{R}^n definiujemy jako n -krotny iloczyn kartezjański:

$$\mathbb{R}^n = \underbrace{\mathbb{R} \times \dots \times \mathbb{R}}_n$$

Elementy tej przestrzeni $\mathbf{x} = (x_1, x_2, \dots, x_n)$ nazywamy **wektorami**.

Działania na wektorach:

- Dodawanie: dla $\mathbf{x} = (x_1, \dots, x_n)$ i $\mathbf{y} = (y_1, \dots, y_n)$

$$\mathbf{x} + \mathbf{y} = (x_1 + y_1, \dots, x_n + y_n)$$

- Mnożenie przez skalar: dla $\mathbf{x} = (x_1, \dots, x_n)$ i $\alpha \in \mathbb{R}$

$$\alpha \mathbf{x} = (\alpha x_1, \dots, \alpha x_n)$$

Przestrzeń wektorowa \mathbb{R}^n

Przestrzeń \mathbb{R}^n definiujemy jako n -krotny iloczyn kartezjański:

$$\mathbb{R}^n = \underbrace{\mathbb{R} \times \dots \times \mathbb{R}}_n$$

Elementy tej przestrzeni $\mathbf{x} = (x_1, x_2, \dots, x_n)$ nazywamy **wektorami**.

Działania na wektorach:

- Dodawanie: dla $\mathbf{x} = (x_1, \dots, x_n)$ i $\mathbf{y} = (y_1, \dots, y_n)$

$$\mathbf{x} + \mathbf{y} = (x_1 + y_1, \dots, x_n + y_n)$$

- Mnożenie przez skalar: dla $\mathbf{x} = (x_1, \dots, x_n)$ i $\alpha \in \mathbb{R}$

$$\alpha \mathbf{x} = (\alpha x_1, \dots, \alpha x_n)$$


Specjalne oznaczenia:

$$\mathbf{0} = (0, 0, \dots, 0), \quad \mathbf{e}_k = (0, \dots, 0, \underbrace{1}_{k\text{-ta pozycja}}, 0, \dots, 0)$$

Norma wektora

Norma (długość) wektora:


$$\|\mathbf{x}\| = \sqrt{x_1^2 + \dots + x_n^2}$$



Norma wektora

Norma (długość) wektora:

$$\|\mathbf{x}\| = \sqrt{x_1^2 + \dots + x_n^2}$$




Fakt: Zachodzi $\|\alpha\mathbf{x}\| = |\alpha|\|\mathbf{x}\|$ dla dowolnego $\alpha \in \mathbb{R}$

Norma wektora

Norma (długość) wektora:

$$\|\mathbf{x}\| = \sqrt{x_1^2 + \dots + x_n^2}$$




Fakt: Zachodzi $\|\alpha\mathbf{x}\| = |\alpha|\|\mathbf{x}\|$ dla dowolnego $\alpha \in \mathbb{R}$

Wektor \mathbf{v} taki, że $\|\mathbf{v}\| = 1$, nazywamy **wektorem jednostkowym**

Norma wektora

Norma (długość) wektora:

$$\|\mathbf{x}\| = \sqrt{x_1^2 + \dots + x_n^2}$$



Fakt: Zachodzi $\|\alpha\mathbf{x}\| = |\alpha|\|\mathbf{x}\|$ dla dowolnego $\alpha \in \mathbb{R}$


Wektor \mathbf{v} taki, że $\|\mathbf{v}\| = 1$, nazywamy **wektorem jednostkowym**

Fakt: Wektor $\mathbf{v} = \frac{\mathbf{x}}{\|\mathbf{x}\|}$ jest jednostkowy

Norma wektora

Norma (długość) wektora:

$$\|\mathbf{x}\| = \sqrt{x_1^2 + \dots + x_n^2}$$



Fakt: Zachodzi $\|\alpha\mathbf{x}\| = |\alpha|\|\mathbf{x}\|$ dla dowolnego $\alpha \in \mathbb{R}$

Wektor \mathbf{v} taki, że $\|\mathbf{v}\| = 1$, nazywamy **wektorem jednostkowym**

Fakt: Wektor $\mathbf{v} = \frac{\mathbf{x}}{\|\mathbf{x}\|}$ jest jednostkowy

Dowód:

$$\|\mathbf{v}\| = \left\| \frac{\mathbf{x}}{\|\mathbf{x}\|} \right\| = \frac{1}{\|\mathbf{x}\|} \|\mathbf{x}\| = 1$$

Dygresja: norma ℓ_p

Normę wektora można uogólnić na tzw. normę ℓ_p , dla $p \in [1, \infty]$

$$\|\mathbf{x}\|_p = \sqrt[p]{|x_1|^p + \dots + |x_n|^p}$$

- $\|\mathbf{x}\|_1 = |x_1| + \dots + |x_n|$
- $\|\mathbf{x}\|_2 = \sqrt{x_1^2 + \dots + x_n^2} \equiv \|\mathbf{x}\|$
- $\|\mathbf{x}\|_\infty = \max_{i=1, \dots, n} |x_i|$




Dygresja: norma ℓ_p

Normę wektora można uogólnić na tzw. normę ℓ_p , dla $p \in [1, \infty]$

$$\|\mathbf{x}\|_p = \sqrt[p]{|x_1|^p + \dots + |x_n|^p}$$

- $\|\mathbf{x}\|_1 = |x_1| + \dots + |x_n|$
- $\|\mathbf{x}\|_2 = \sqrt{x_1^2 + \dots + x_n^2} \equiv \|\mathbf{x}\|$
- $\|\mathbf{x}\|_\infty = \max_{i=1, \dots, n} |x_i|$

Kula względem p -normy: $\mathcal{K}_p(r) = \{\mathbf{x} : |x_1|^p + \dots + |x_n|^p \leq r^p\}$




Iloczyn skalarny

Iloczyn skalarny między wektorami:

$$\mathbf{x} \cdot \mathbf{y} = \mathbf{y} \cdot \mathbf{x} = x_1y_1 + x_2y_2 + \dots + x_ny_n$$

W szczególności: $\mathbf{x} \cdot \mathbf{x} = \|\mathbf{x}\|^2$



Iloczyn skalarny


Iloczyn skalarny między wektorami:

$$\mathbf{x} \cdot \mathbf{y} = \mathbf{y} \cdot \mathbf{x} = x_1y_1 + x_2y_2 + \dots + x_ny_n$$

W szczególności: $\mathbf{x} \cdot \mathbf{x} = \|\mathbf{x}\|^2$

Zachodzi:

$$\cos \theta = \frac{\mathbf{x} \cdot \mathbf{y}}{\|\mathbf{x}\| \|\mathbf{y}\|} = \frac{\mathbf{x}}{\|\mathbf{x}\|} \cdot \frac{\mathbf{y}}{\|\mathbf{y}\|}$$




Iloczyn skalarny

Iloczyn skalarny między wektorami:

$$\mathbf{x} \cdot \mathbf{y} = \mathbf{y} \cdot \mathbf{x} = x_1y_1 + x_2y_2 + \dots + x_ny_n$$

W szczególności: $\mathbf{x} \cdot \mathbf{x} = \|\mathbf{x}\|^2$



Zachodzi:

$$\cos \theta = \frac{\mathbf{x} \cdot \mathbf{y}}{\|\mathbf{x}\| \|\mathbf{y}\|} = \frac{\mathbf{x}}{\|\mathbf{x}\|} \cdot \frac{\mathbf{y}}{\|\mathbf{y}\|}$$


Wektory dla których $\mathbf{x} \cdot \mathbf{y} = 0$ nazywamy **ortogonalnymi** (prostopadłymi)

Iloczyn skalarny

Iloczyn skalarny między wektorami:

$$\mathbf{x} \cdot \mathbf{y} = \mathbf{y} \cdot \mathbf{x} = x_1y_1 + x_2y_2 + \dots + x_ny_n$$

W szczególności: $\mathbf{x} \cdot \mathbf{x} = \|\mathbf{x}\|^2$



Zachodzi:

$$\cos \theta = \frac{\mathbf{x} \cdot \mathbf{y}}{\|\mathbf{x}\| \|\mathbf{y}\|} = \frac{\mathbf{x}}{\|\mathbf{x}\|} \cdot \frac{\mathbf{y}}{\|\mathbf{y}\|}$$

Wektory dla których $\mathbf{x} \cdot \mathbf{y} = 0$ nazywamy **ortogonalnymi** (prostopadłymi)

Nierówność Cauchy'ego-Schwarza:

$$|\mathbf{x} \cdot \mathbf{y}| \leq \|\mathbf{x}\| \|\mathbf{y}\|$$

(interpretacja: $|\cos \theta| \leq 1$)

Iloczyn skalarny

Zadanie: dla zadanego wektora x , znajdź wektor jednostkowy v , który
(i) maksymalizuje (ii) minimalizuje iloczyn skalarny $x \cdot v$

Iloczyn skalarny

Zadanie: dla zadanego wektora x , znajdź wektor jednostkowy v , który (i) maksymalizuje (ii) minimalizuje iloczyn skalarny $x \cdot v$

Odpowiedź: z nierówności Cauchy'ego-Schwarza:

$$-\|x\| \underbrace{\|v\|}_{=1} \leq x \cdot v \leq \|x\| \underbrace{\|v\|}_{=1}$$

Iloczyn skalarny

Zadanie: dla danego wektora \mathbf{x} , znajdź wektor jednostkowy \mathbf{v} , który
(i) maksymalizuje (ii) minimalizuje iloczyn skalarny $\mathbf{x} \cdot \mathbf{v}$

Odpowiedź: z nierówności Cauchy'ego-Schwarza:

$$-\|\mathbf{x}\| \leq \mathbf{x} \cdot \mathbf{v} \leq \|\mathbf{x}\|$$

Iloczyn skalarny

Zadanie: dla danego wektora x , znajdź wektor jednostkowy v , który (i) maksymalizuje (ii) minimalizuje iloczyn skalarny $x \cdot v$


Odpowiedź: z nierówności Cauchy'ego-Schwarza:

$$-\|x\| \leq x \cdot v \leq \|x\|$$

Biorąc wektor $v = \frac{x}{\|x\|}$ mamy:

$$x \cdot v = \frac{x \cdot x}{\|x\|} = \|x\|$$

Wektor $v = \frac{x}{\|x\|}$ **maksymalizuje** $x \cdot v$



Iloczyn skalarny

Zadanie: dla danego wektora x , znajdź wektor jednostkowy v , który (i) maksymalizuje (ii) minimalizuje iloczyn skalarny $x \cdot v$


Odpowiedź: z nierówności Cauchy'ego-Schwarza:

$$-\|x\| \leq x \cdot v \leq \|x\|$$

Biorąc wektor $v = \frac{x}{\|x\|}$ mamy:

$$x \cdot v = \frac{x \cdot x}{\|x\|} = \|x\|$$


Wektor $v = \frac{x}{\|x\|}$ **maksymalizuje** $x \cdot v$



Podobnie, biorąc wektor $v = -\frac{x}{\|x\|}$ mamy:

$$x \cdot v = -\|x\|$$

Wektor $v = -\frac{x}{\|x\|}$ **minimalizuje** $x \cdot v$



Macierze

Macierz wymiaru $m \times n$ to prostokątna tablica mn liczb o m wierszach i n kolumnach:

$$\mathbf{A} = \begin{bmatrix} A_{11} & A_{12} & \cdots & A_{1n} \\ A_{21} & A_{22} & \cdots & A_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ A_{m1} & A_{m2} & \cdots & A_{mn} \end{bmatrix}$$

Przestrzeń macierzy oznaczamy przez $\mathbb{R}^{m \times n}$

Działania na macierzach

- Mnożenie przez skalar: dla $\mathbf{A} \in \mathbb{R}^{m \times n}$ i $\alpha \in \mathbb{R}$

$$\mathbf{B} = \alpha \mathbf{A} \in \mathbb{R}^{m \times n} \quad \text{ma postać} \quad B_{ij} = \alpha A_{ij}$$

Działania na macierzach

- Mnożenie przez skalar: dla $\mathbf{A} \in \mathbb{R}^{m \times n}$ i $\alpha \in \mathbb{R}$

$$\mathbf{B} = \alpha \mathbf{A} \in \mathbb{R}^{m \times n} \quad \text{ma postać} \quad B_{ij} = \alpha A_{ij}$$

- Dodawanie macierzy: dla $\mathbf{A} \in \mathbb{R}^{m \times n}$ i $\mathbf{B} \in \mathbb{R}^{m \times n}$

$$\mathbf{C} = \mathbf{A} + \mathbf{B} \in \mathbb{R}^{m \times n} \quad \text{ma postać} \quad C_{ij} = A_{ij} + B_{ij}$$

Działania na macierzach

- Mnożenie przez skalar: dla $\mathbf{A} \in \mathbb{R}^{m \times n}$ i $\alpha \in \mathbb{R}$

$$\mathbf{B} = \alpha \mathbf{A} \in \mathbb{R}^{m \times n} \quad \text{ma postać} \quad B_{ij} = \alpha A_{ij}$$

- Dodawanie macierzy: dla $\mathbf{A} \in \mathbb{R}^{m \times n}$ i $\mathbf{B} \in \mathbb{R}^{m \times n}$

$$\mathbf{C} = \mathbf{A} + \mathbf{B} \in \mathbb{R}^{m \times n} \quad \text{ma postać} \quad C_{ij} = A_{ij} + B_{ij}$$

- Mnożenie macierzy: dla $\mathbf{A} \in \mathbb{R}^{m \times n}$ i $\mathbf{B} \in \mathbb{R}^{n \times p}$

$$\mathbf{C} = \mathbf{A}\mathbf{B} \in \mathbb{R}^{m \times p} \quad \text{ma postać} \quad C_{ij} = \sum_{k=1}^n A_{ik} B_{kj}$$

Uwaga: mnożenie macierzy nie jest przemienne!

Działania na macierzach

- Mnożenie przez skalar: dla $\mathbf{A} \in \mathbb{R}^{m \times n}$ i $\alpha \in \mathbb{R}$

$$\mathbf{B} = \alpha \mathbf{A} \in \mathbb{R}^{m \times n} \quad \text{ma postać} \quad B_{ij} = \alpha A_{ij}$$

- Dodawanie macierzy: dla $\mathbf{A} \in \mathbb{R}^{m \times n}$ i $\mathbf{B} \in \mathbb{R}^{m \times n}$

$$\mathbf{C} = \mathbf{A} + \mathbf{B} \in \mathbb{R}^{m \times n} \quad \text{ma postać} \quad C_{ij} = A_{ij} + B_{ij}$$

- Mnożenie macierzy: dla $\mathbf{A} \in \mathbb{R}^{m \times n}$ i $\mathbf{B} \in \mathbb{R}^{n \times p}$

$$\mathbf{C} = \mathbf{A}\mathbf{B} \in \mathbb{R}^{m \times p} \quad \text{ma postać} \quad C_{ij} = \sum_{k=1}^n A_{ik} B_{kj}$$

Uwaga: mnożenie macierzy nie jest przemienne!

- Transpozycja: dla $\mathbf{A} \in \mathbb{R}^{m \times n}$

$$\mathbf{B} = \mathbf{A}^T \in \mathbb{R}^{n \times m} \quad \text{ma postać} \quad B_{ij} = A_{ji}$$

Zachodzi $(\mathbf{A} + \mathbf{B})^T = \mathbf{A}^T + \mathbf{B}^T$ oraz $(\mathbf{A}\mathbf{B})^T = \mathbf{B}^T \mathbf{A}^T$

Macierze kwadratowe

Macierz dla której $n = m$ nazywamy **macierzą kwadratową stopnia n**

Macierze kwadratowe

Macierz dla której $n = m$ nazywamy **macierzą kwadratową stopnia n**

Macierz diagonalna

Niezerowe elementy wyłącznie na **diagonali**

$$\mathbf{A} = \begin{bmatrix} A_{11} & 0 & 0 & \cdots & 0 \\ 0 & A_{22} & 0 & \cdots & 0 \\ 0 & 0 & A_{33} & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & A_{nn} \end{bmatrix}$$

Macierze kwadratowe

Macierz dla której $n = m$ nazywamy **macierzą kwadratową stopnia n**

Macierz diagonalna

Niezerowe elementy wyłącznie na **diagonali**

$$\mathbf{A} = \begin{bmatrix} A_{11} & 0 & 0 & \cdots & 0 \\ 0 & A_{22} & 0 & \cdots & 0 \\ 0 & 0 & A_{33} & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & A_{nn} \end{bmatrix}$$

Macierz jednostkowa

Jest **elementem neutralnym mnożenia**,
tzn. dla każdego $\mathbf{A} \in \mathbb{R}^{n \times n}$, $\mathbf{AI} = \mathbf{IA} = \mathbf{A}$

$$\mathbf{I} = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \\ 0 & 1 & 0 & \cdots & 0 \\ 0 & 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & 1 \end{bmatrix}$$

Macierze kwadratowe

Macierz dla której $n = m$ nazywamy **macierzą kwadratową stopnia n**

Macierz diagonalna

Niezerowe elementy wyłącznie na **diagonali**

$$\mathbf{A} = \begin{bmatrix} A_{11} & 0 & 0 & \cdots & 0 \\ 0 & A_{22} & 0 & \cdots & 0 \\ 0 & 0 & A_{33} & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & A_{nn} \end{bmatrix}$$

Macierz jednostkowa

Jest **elementem neutralnym mnożenia**,
tzn. dla każdego $\mathbf{A} \in \mathbb{R}^{n \times n}$, $\mathbf{AI} = \mathbf{IA} = \mathbf{A}$

$$\mathbf{I} = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \\ 0 & 1 & 0 & \cdots & 0 \\ 0 & 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & 1 \end{bmatrix}$$

Macierz symetryczna: $\mathbf{A}^T = \mathbf{A}$, tzn. $A_{ij} = A_{ji}$.

Wektory jako macierze

Będziemy utożsamiać wektor $\mathbf{x} = (x_1, \dots, x_n)$ z macierzą $n \times 1$ (**wektor kolumnowy**), wtedy \mathbf{x}^\top o wymiarze $1 \times n$ jest **wektorem wierszowym**

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}, \quad \mathbf{x}^\top = \begin{bmatrix} x_1 & x_2 & \cdots & x_n \end{bmatrix}$$

Wektory jako macierze

Mnożenie macierzy i wektorów: w powyższej reprezentacji dla macierzy kwadratowej $A \in \mathbb{R}^{n \times n}$ i wektorów $x, y \in \mathbb{R}^n$

Wektory jako macierze

Mnożenie macierzy i wektorów: w powyższej reprezentacji dla macierzy kwadratowej $A \in \mathbb{R}^{n \times n}$ i wektorów $x, y \in \mathbb{R}^n$

- Ax jest wektorem kolumnowym o wymiarze $n \times 1$

Wektory jako macierze

Mnożenie macierzy i wektorów: w powyższej reprezentacji dla macierzy kwadratowej $A \in \mathbb{R}^{n \times n}$ i wektorów $x, y \in \mathbb{R}^n$

- Ax jest wektorem kolumnowym o wymiarze $n \times 1$
- $x^\top A$ jest wektorem wierszowym o wymiarze $1 \times n$

Wektory jako macierze

Mnożenie macierzy i wektorów: w powyższej reprezentacji dla macierzy kwadratowej $A \in \mathbb{R}^{n \times n}$ i wektorów $x, y \in \mathbb{R}^n$

- Ax jest wektorem kolumnowym o wymiarze $n \times 1$
- $x^\top A$ jest wektorem wierszowym o wymiarze $1 \times n$
- Mnożenia Ax^\top i xA nie mają sensu

Wektory jako macierze

Mnożenie macierzy i wektorów: w powyższej reprezentacji dla macierzy kwadratowej $A \in \mathbb{R}^{n \times n}$ i wektorów $x, y \in \mathbb{R}^n$

- Ax jest wektorem kolumnowym o wymiarze $n \times 1$
- $x^\top A$ jest wektorem wierszowym o wymiarze $1 \times n$
- Mnożenia Ax^\top i xA nie mają sensu
- $x^\top Ay$ jest skalar (liczbą)

Wektory jako macierze

Mnożenie macierzy i wektorów: w powyższej reprezentacji dla macierzy kwadratowej $A \in \mathbb{R}^{n \times n}$ i wektorów $x, y \in \mathbb{R}^n$

- Ax jest wektorem kolumnowym o wymiarze $n \times 1$
- $x^\top A$ jest wektorem wierszowym o wymiarze $1 \times n$
- Mnożenia Ax^\top i xA nie mają sensu
- $x^\top Ay$ jest skalar (liczbą)
- $x^\top Ay = y^\top A^\top x$, ponieważ z zasady transpozycji iloczynu $(ABC)^\top = C^\top B^\top A^\top$ zachodzi:

$$x^\top Ay = \underbrace{(x^\top Ay)^\top}_{\text{bo to liczba}} = y^\top A^\top (x^\top)^\top = y^\top A^\top x$$

Wektory jako macierze

Mnożenie macierzy i wektorów: w powyższej reprezentacji dla macierzy kwadratowej $A \in \mathbb{R}^{n \times n}$ i wektorów $x, y \in \mathbb{R}^n$

- Ax jest wektorem kolumnowym o wymiarze $n \times 1$
- $x^\top A$ jest wektorem wierszowym o wymiarze $1 \times n$
- Mnożenia Ax^\top i xA nie mają sensu
- $x^\top Ay$ jest skalar (liczbą)
- $x^\top Ay = y^\top A^\top x$, ponieważ z zasady transpozycji iloczynu $(ABC)^\top = C^\top B^\top A^\top$ zachodzi:

$$x^\top Ay = \underbrace{(x^\top Ay)^\top}_{\text{bo to liczba}} = y^\top A^\top (x^\top)^\top = y^\top A^\top x$$

- W szczególności, jeśli A jest symetryczna: $x^\top Ay = y^\top Ax$

Dla symetrycznej macierzy A zachodzi

$$x^\top Ay = y^\top Ax$$

Iloczyn skalarny i iloczyn zewnętrzny

Dla dowolnych $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ zachodzi w reprezentacji macierzowej:

$$\mathbf{x}^\top \mathbf{y} = \begin{bmatrix} x_1 & x_2 & \cdots & x_n \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = x_1 y_1 + \dots + x_n y_n = \mathbf{x} \cdot \mathbf{y}$$

Odtąd zapisujemy iloczyn skalarny jako $\mathbf{x}^\top \mathbf{y}$ (lub $\mathbf{y}^\top \mathbf{x}$).

W szczególności: $\mathbf{x}^\top \mathbf{x} = \|\mathbf{x}\|^2$

Iloczyn skalarny i iloczyn zewnętrzny

Dla dowolnych $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ zachodzi w reprezentacji macierzowej:

$$\mathbf{x}^\top \mathbf{y} = \begin{bmatrix} x_1 & x_2 & \cdots & x_n \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = x_1 y_1 + \dots + x_n y_n = \mathbf{x} \cdot \mathbf{y}$$

Odtąd zapisujemy iloczyn skalarny jako $\mathbf{x}^\top \mathbf{y}$ (lub $\mathbf{y}^\top \mathbf{x}$).

W szczególności: $\mathbf{x}^\top \mathbf{x} = \|\mathbf{x}\|^2$

Iloczyn $\mathbf{x}\mathbf{y}^\top \in \mathbb{R}^{n \times n}$ nazywamy **iloczynem zewnętrznym** \mathbf{x} i \mathbf{y} :

$$\mathbf{x}\mathbf{y}^\top = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \begin{bmatrix} y_1 & y_2 & \cdots & y_n \end{bmatrix} = \begin{bmatrix} x_1 y_1 & x_1 y_2 & x_1 y_3 & \cdots & x_1 y_n \\ x_2 y_1 & x_2 y_2 & x_2 y_3 & \cdots & x_2 y_n \\ x_3 y_1 & x_3 y_2 & x_3 y_3 & \cdots & x_3 y_n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_n y_1 & x_n y_2 & x_n y_3 & \cdots & x_n y_n \end{bmatrix}$$

Wyznacznik macierzy

Wyznacznik macierzy kwadratowej A to funkcja $\det A$ o wartościach rzeczywistych, określona indukcyjnie:

1. Dla $A \in \mathbb{R}^{1 \times 1}$, $\det A = A_{11}$
2. Dla $A \in \mathbb{R}^{n \times n}$ z $n \geq 2$:

$$\det A = \sum_{i=1}^n (-1)^{i+j} A_{ij} \det A_{ij},$$

gdzie i jest dowolnym wierszem, a $A_{ij} \in \mathbb{R}^{(n-1) \times (n-1)}$ jest macierzą powstałą z A poprzez skreślenie i -tego wiersza i j -tej kolumny

Wyznacznik macierzy

Wyznacznik macierzy kwadratowej \mathbf{A} to funkcja $\det \mathbf{A}$ o wartościach rzeczywistych, określona indukcyjnie:

1. Dla $\mathbf{A} \in \mathbb{R}^{1 \times 1}$, $\det \mathbf{A} = A_{11}$
2. Dla $\mathbf{A} \in \mathbb{R}^{n \times n}$ z $n \geq 2$:

$$\det \mathbf{A} = \sum_{i=1}^n (-1)^{i+j} A_{ij} \det \mathbf{A}_{ij},$$

gdzie i jest dowolnym wierszem, a $\mathbf{A}_{ij} \in \mathbb{R}^{(n-1) \times (n-1)}$ jest macierzą powstałą z \mathbf{A} poprzez skreślenie i -tego wiersza i j -tej kolumny

Przykład dla macierzy $\mathbf{A} \in \mathbb{R}^{2 \times 2}$:

$$\det \mathbf{A} = \det \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} = A_{11}A_{22} - A_{12}A_{21}$$

Macierz odwrotna

Niech A będzie macierzą kwadratową stopnia n . **Macierz odwrotną** do A oznaczamy przez A^{-1} i definiujemy jako:

$$AA^{-1} = A^{-1}A = I$$

Macierz odwrotna

Niech A będzie macierzą kwadratową stopnia n . **Macierz odwrotną** do A oznaczamy przez A^{-1} i definiujemy jako:

$$AA^{-1} = A^{-1}A = I$$

Nie każda macierz ma macierz odwrotną!

Macierz, która ma macierz odwrotną, nazywamy **odwracalną**, a jeśli nie ma, nazywamy ją **osobliwą**

Macierz odwrotna

Niech A będzie macierzą kwadratową stopnia n . **Macierz odwrotną** do A oznaczamy przez A^{-1} i definiujemy jako:

$$AA^{-1} = A^{-1}A = I$$

Nie każda macierz ma macierz odwrotną!

Macierz, która ma macierz odwrotną, nazywamy **odwracalną**, a jeśli nie ma, nazywamy ją **osobliwą**

Fakt: macierz kwadratowa A jest odwracalna wtedy i tylko wtedy gdy $\det A \neq 0$.

Wyznaczanie macierzy odwrotnej

W ogólności macierz odwrotną można wyznaczyć np. **metodą eliminacji Gaussa** w czasie $O(n^3)$

Rozważymy dwa szczególne przypadki:

Wyznaczanie macierzy odwrotnej

W ogólności macierz odwrotną można wyznaczyć np. **metodą eliminacji Gaussa** w czasie $O(n^3)$

Rozważmy dwa szczególne przypadki:

- Macierz diagonalna:

$$\mathbf{A} = \begin{bmatrix} A_{11} & 0 & \cdots & 0 \\ 0 & A_{22} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & A_{nn} \end{bmatrix}, \quad \mathbf{A}^{-1} = \begin{bmatrix} A_{11}^{-1} & 0 & \cdots & 0 \\ 0 & A_{22}^{-1} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & A_{nn}^{-1} \end{bmatrix}$$

Wyznaczanie macierzy odwrotnej

W ogólności macierz odwrotną można wyznaczyć np. **metodą eliminacji Gaussa** w czasie $O(n^3)$

Rozważymy dwa szczególne przypadki:

- Macierz diagonalna:

$$\mathbf{A} = \begin{bmatrix} A_{11} & 0 & \cdots & 0 \\ 0 & A_{22} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & A_{nn} \end{bmatrix}, \quad \mathbf{A}^{-1} = \begin{bmatrix} A_{11}^{-1} & 0 & \cdots & 0 \\ 0 & A_{22}^{-1} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & A_{nn}^{-1} \end{bmatrix}$$

- Macierz 2×2 :

$$\mathbf{A} = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix}, \quad \mathbf{A}^{-1} = \frac{1}{\det \mathbf{A}} \begin{bmatrix} A_{22} & -A_{12} \\ -A_{21} & A_{11} \end{bmatrix}$$

Wartości i wektory własne macierzy symetrycznych

Niech $\mathbf{A} \in \mathbb{R}^{n \times n}$ będzie macierzą symetryczną ($\mathbf{A}^\top = \mathbf{A}$).
Jeśli dla $\lambda \in \mathbb{R}$ i jednostkowego wektora $\mathbf{v} \in \mathbb{R}^n$ zachodzi:

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v},$$

to λ i \mathbf{v} nazywamy, odpowiednio, **wartością własną** i stowarzyszonym z nią **wektorem własnym**

Wartości i wektory własne macierzy symetrycznych

Niech $\mathbf{A} \in \mathbb{R}^{n \times n}$ będzie macierzą symetryczną ($\mathbf{A}^\top = \mathbf{A}$).
Jeśli dla $\lambda \in \mathbb{R}$ i jednostkowego wektora $\mathbf{v} \in \mathbb{R}^n$ zachodzi:

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v},$$

to λ i \mathbf{v} nazywamy, odpowiednio, **wartością własną** i stowarzyszonym z nią **wektorem własnym**

Fakt: Macierz symetryczna stopnia n posiada n wartości własnych $\lambda_1, \dots, \lambda_n$ (mogą się one powtarzać), a stowarzyszone z nimi wektory własne $\mathbf{v}_1, \dots, \mathbf{v}_n$ są **ortogonalne**, tzn. $\mathbf{v}_i^\top \mathbf{v}_j = 0$ dla $i \neq j$.

Wartości i wektory własne macierzy symetrycznych

Niech $\mathbf{A} \in \mathbb{R}^{n \times n}$ będzie macierzą symetryczną ($\mathbf{A}^\top = \mathbf{A}$).
Jeśli dla $\lambda \in \mathbb{R}$ i jednostkowego wektora $\mathbf{v} \in \mathbb{R}^n$ zachodzi:

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v},$$

to λ i \mathbf{v} nazywamy, odpowiednio, **wartością własną** i stowarzyszonym z nią **wektorem własnym**

Fakt: Macierz symetryczna stopnia n posiada n wartości własnych $\lambda_1, \dots, \lambda_n$ (mogą się one powtarzać), a stowarzyszone z nimi wektory własne $\mathbf{v}_1, \dots, \mathbf{v}_n$ są **ortogonalne**, tzn. $\mathbf{v}_i^\top \mathbf{v}_j = 0$ dla $i \neq j$.

Fakt: Jeśli macierz symetryczna \mathbf{A} ma wektory własne $\mathbf{v}_1, \dots, \mathbf{v}_n$ i wartości własne $\lambda_1, \dots, \lambda_n$, to jej odwrotność \mathbf{A}^{-1} ma te same wektory własne i wartości własne $\lambda_1^{-1}, \dots, \lambda_n^{-1}$

Wartości i wektory własne macierzy symetrycznych

Niech $\mathbf{A} \in \mathbb{R}^{n \times n}$ będzie macierzą symetryczną ($\mathbf{A}^\top = \mathbf{A}$).
Jeśli dla $\lambda \in \mathbb{R}$ i jednostkowego wektora $\mathbf{v} \in \mathbb{R}^n$ zachodzi:

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v},$$

to λ i \mathbf{v} nazywamy, odpowiednio, **wartością własną** i stowarzyszonym z nią **wektorem własnym**

Fakt: Macierz symetryczna stopnia n posiada n wartości własnych $\lambda_1, \dots, \lambda_n$ (mogą się one powtarzać), a stowarzyszone z nimi wektory własne $\mathbf{v}_1, \dots, \mathbf{v}_n$ są **ortogonalne**, tzn. $\mathbf{v}_i^\top \mathbf{v}_j = 0$ dla $i \neq j$.

Fakt: Jeśli macierz symetryczna \mathbf{A} ma wektory własne $\mathbf{v}_1, \dots, \mathbf{v}_n$ i wartości własne $\lambda_1, \dots, \lambda_n$, to jej odwrotność \mathbf{A}^{-1} ma te same wektory własne i wartości własne $\lambda_1^{-1}, \dots, \lambda_n^{-1}$

Wniosek: Macierz symetryczna jest odwracalna wtedy i tylko wtedy gdy wszystkie jej wartości własne są **niezerowe**

Forma kwadratowa

Dla symetrycznej macierzy $\mathbf{A} \in \mathbb{R}^{n \times n}$, wyrażenie postaci:

$$\mathbf{x}^\top \mathbf{A} \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j$$

nazywamy **formą kwadratową** z macierzą formy \mathbf{A}

Forma kwadratowa

Dla symetrycznej macierzy $A \in \mathbb{R}^{n \times n}$, wyrażenie postaci:

$$\mathbf{x}^\top \mathbf{A} \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j$$

nazywamy **formą kwadratową** z macierzą formy A

Macierz A jest **dodatnio określona** jeśli dla dowolnego niezerowego wektora $v \in \mathbb{R}^n$, $v^\top A v > 0$, i **dodatnio półokreślona**, jeśli $v^\top A v \geq 0$.

Forma kwadratowa

Dla symetrycznej macierzy $\mathbf{A} \in \mathbb{R}^{n \times n}$, wyrażenie postaci:

$$\mathbf{x}^\top \mathbf{A} \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j$$

nazywamy **formą kwadratową** z macierzą formy \mathbf{A}

Macierz \mathbf{A} jest **dodatnio określona** jeśli dla dowolnego niezerowego wektora $\mathbf{v} \in \mathbb{R}^n$, $\mathbf{v}^\top \mathbf{A} \mathbf{v} > 0$, i **dodatnio półokreślona**, jeśli $\mathbf{v}^\top \mathbf{A} \mathbf{v} \geq 0$.

Fakt: Jeśli λ_{\min} i λ_{\max} to najmniejsza i największa wartość własna macierzy, to dla dowolnego wektora \mathbf{v} :

$$\lambda_{\min} \|\mathbf{v}\|^2 \leq \mathbf{v}^\top \mathbf{A} \mathbf{v} \leq \lambda_{\max} \|\mathbf{v}\|^2$$

Forma kwadratowa

Dla symetrycznej macierzy $\mathbf{A} \in \mathbb{R}^{n \times n}$, wyrażenie postaci:

$$\mathbf{x}^\top \mathbf{A} \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j$$

nazywamy **formą kwadratową** z macierzą formy \mathbf{A}

Macierz \mathbf{A} jest **dodatnio określona** jeśli dla dowolnego niezerowego wektora $\mathbf{v} \in \mathbb{R}^n$, $\mathbf{v}^\top \mathbf{A} \mathbf{v} > 0$, i **dodatnio półokreślona**, jeśli $\mathbf{v}^\top \mathbf{A} \mathbf{v} \geq 0$.

Fakt: Jeśli λ_{\min} i λ_{\max} to najmniejsza i największa wartość własna macierzy, to dla dowolnego wektora \mathbf{v} :

$$\lambda_{\min} \|\mathbf{v}\|^2 \leq \mathbf{v}^\top \mathbf{A} \mathbf{v} \leq \lambda_{\max} \|\mathbf{v}\|^2$$

Fakt: Macierz \mathbf{A} jest dodatnio określona (półokreślona), jeśli wszystkie jej wartości własne są dodatnie (nieujemne)

Macierze dodatnio określone

Testowanie czy A jest dodatnio określone jest skomplikowane: wymaga np. wyznaczenia najmniejszej wartości własnej

Macierze dodatnio określone

Testowanie czy \mathbf{A} jest dodatnio określone jest skomplikowane: wymaga np. wyznaczenia najmniejszej wartości własnej

Dla macierzy 2×2 jest znacznie prostszy test: Macierz jest dodatnio określona wtedy i tylko wtedy gdy $\det \mathbf{A} > 0$ i $A_{11} > 0$

Macierze dodatnio określone

Testowanie czy \mathbf{A} jest dodatnio określone jest skomplikowane: wymaga np. wyznaczenia najmniejszej wartości własnej

Dla macierzy 2×2 jest znacznie prostszy test: Macierz jest dodatnio określona wtedy i tylko wtedy gdy $\det \mathbf{A} > 0$ i $A_{11} > 0$

Przykład: Rozważmy macierz:

$$\mathbf{A} = \begin{bmatrix} 3 & -1 \\ -1 & 2 \end{bmatrix}$$

Macierze dodatnio określone

Testowanie czy A jest dodatnio określone jest skomplikowane: wymaga np. wyznaczenia najmniejszej wartości własnej

Dla macierzy 2×2 jest znacznie prostszy test: Macierz jest dodatnio określona wtedy i tylko wtedy gdy $\det A > 0$ i $A_{11} > 0$

Przykład: Rozważmy macierz:

$$A = \begin{bmatrix} 3 & -1 \\ -1 & 2 \end{bmatrix} \quad \det A = 5, \quad A_{11} = 3$$

Wniosek: macierz A jest dodatnio określona
(faktycznie, wartości własne to $\lambda_1 = 3.62$, $\lambda_2 = 1.38$)

Macierze dodatnio określone

Testowanie czy \mathbf{A} jest dodatnio określone jest skomplikowane: wymaga np. wyznaczenia najmniejszej wartości własnej

Dla macierzy 2×2 jest znacznie prostszy test: Macierz jest dodatnio określona wtedy i tylko wtedy gdy $\det \mathbf{A} > 0$ i $A_{11} > 0$

Przykład: Rozważmy macierz:

$$\mathbf{A} = \begin{bmatrix} 3 & -1 \\ -1 & 2 \end{bmatrix} \quad \det \mathbf{A} = 5, \quad A_{11} = 3$$

Wniosek: macierz \mathbf{A} jest dodatnio określona
(faktycznie, wartości własne to $\lambda_1 = 3.62$, $\lambda_2 = 1.38$)

Przykład: Rozważmy macierz:

$$\mathbf{A} = \begin{bmatrix} 1 & -3 \\ -3 & 4 \end{bmatrix}$$

Macierze dodatnio określone

Testowanie czy A jest dodatnio określone jest skomplikowane: wymaga np. wyznaczenia najmniejszej wartości własnej

Dla macierzy 2×2 jest znacznie prostszy test: Macierz jest dodatnio określona wtedy i tylko wtedy gdy $\det A > 0$ i $A_{11} > 0$

Przykład: Rozważmy macierz:

$$A = \begin{bmatrix} 3 & -1 \\ -1 & 2 \end{bmatrix} \quad \det A = 5, \quad A_{11} = 3$$

Wniosek: macierz A jest dodatnio określona
(faktycznie, wartości własne to $\lambda_1 = 3.62, \lambda_2 = 1.38$)

Przykład: Rozważmy macierz:

$$A = \begin{bmatrix} 1 & -3 \\ -3 & 4 \end{bmatrix} \quad \det A = -5, \quad A_{11} = 1$$

Wniosek: macierz A nie jest dodatnio określona
(faktycznie, wartości własne to $\lambda_1 = 5.85, \lambda_2 = -0.85$)

Pochodne cząstkowe, gradient i hesjan

Pochodne cząstkowe

Funkcje jednej zmiennej. Pochodna funkcji $f: \mathbb{R} \rightarrow \mathbb{R}$ w punkcie x :

$$f'(x) = \frac{df(x)}{dx} = \lim_{\Delta \rightarrow 0} \frac{f(x + \Delta) - f(x)}{\Delta}$$

Pochodne cząstkowe

Funkcje jednej zmiennej. Pochodna funkcji $f: \mathbb{R} \rightarrow \mathbb{R}$ w punkcie x :

$$f'(x) = \frac{df(x)}{dx} = \lim_{\Delta \rightarrow 0} \frac{f(x + \Delta) - f(x)}{\Delta}$$

Funkcje wielu zmiennych. Pochodna cząstkowa funkcji $f: \mathbb{R}^n \rightarrow \mathbb{R}$ w punkcie \mathbf{x} ze względu na zmienną x_i :

$$\begin{aligned} \frac{\partial f(\mathbf{x})}{\partial x_i} &= \lim_{\Delta \rightarrow 0} \frac{f(x_1, x_2, \dots, x_i + \Delta, \dots, x_n) - f(\mathbf{x})}{\Delta} \\ &= \lim_{\Delta \rightarrow 0} \frac{f(\mathbf{x} + \Delta \mathbf{e}_i) - f(\mathbf{x})}{\Delta} \end{aligned}$$

Wszystkie zmienne poza x_i traktujemy jako stałe

Pochodne cząstkowe

Funkcje jednej zmiennej. Pochodna funkcji $f: \mathbb{R} \rightarrow \mathbb{R}$ w punkcie x :

$$f'(x) = \frac{df(x)}{dx} = \lim_{\Delta \rightarrow 0} \frac{f(x + \Delta) - f(x)}{\Delta}$$

Funkcje wielu zmiennych. Pochodna cząstkowa funkcji $f: \mathbb{R}^n \rightarrow \mathbb{R}$ w punkcie \mathbf{x} ze względu na zmienną x_i :

$$\begin{aligned} \frac{\partial f(\mathbf{x})}{\partial x_i} &= \lim_{\Delta \rightarrow 0} \frac{f(x_1, x_2, \dots, x_i + \Delta, \dots, x_n) - f(\mathbf{x})}{\Delta} \\ &= \lim_{\Delta \rightarrow 0} \frac{f(\mathbf{x} + \Delta \mathbf{e}_i) - f(\mathbf{x})}{\Delta} \end{aligned}$$

Wszystkie zmienne poza x_i traktujemy jako stałe

Przykład: dla $f(x_1, x_2) = x_1^2 e^{x_2} + x_2$

$$\frac{\partial f(x_1, x_2)}{\partial x_1} = 2x_1 e^{x_2}, \quad \frac{\partial f(x_1, x_2)}{\partial x_2} = x_1^2 e^{x_2} + 1$$

Gradient

Gradient funkcji $f(\mathbf{x})$ w punkcie \mathbf{x} to wektor pochodnych cząstkowych:

$$\nabla f(\mathbf{x}) = \left(\frac{\partial f(\mathbf{x})}{\partial x_1}, \dots, \frac{\partial f(\mathbf{x})}{\partial x_n} \right)$$

Gradient – przykłady

Zadanie: policz gradient funkcji liniowej

$$f(\mathbf{x}) = c + \mathbf{b}^\top \mathbf{x} = c + \sum_{i=1}^n b_i x_i$$

Gradient – przykłady

Zadanie: policz gradient funkcji liniowej

$$f(\mathbf{x}) = c + \mathbf{b}^\top \mathbf{x} = c + \sum_{i=1}^n b_i x_i$$

Odpowiedź: wykorzystując liniowość pochodnej:

$$\frac{\partial f(\mathbf{x})}{\partial x_k} = \frac{\partial}{\partial x_k} \left(c + \sum_{i=1}^n b_i x_i \right) = \underbrace{\frac{\partial c}{\partial x_k}}_0 + \sum_{i=1}^n b_i \underbrace{\frac{\partial x_i}{\partial x_k}}_{\delta_{ik}} = b_k,$$

gdzie δ_{ik} jest tzw. **deltą Kroneckera**: $\delta_{ik} = \begin{cases} 0 & i \neq k \\ 1 & i = k \end{cases}$

Gradient – przykłady

Zadanie: policz gradient funkcji liniowej

$$f(\mathbf{x}) = c + \mathbf{b}^\top \mathbf{x} = c + \sum_{i=1}^n b_i x_i$$

Odpowiedź: wykorzystując liniowość pochodnej:

$$\frac{\partial f(\mathbf{x})}{\partial x_k} = \frac{\partial}{\partial x_k} \left(c + \sum_{i=1}^n b_i x_i \right) = \underbrace{\frac{\partial c}{\partial x_k}}_0 + \sum_{i=1}^n b_i \underbrace{\frac{\partial x_i}{\partial x_k}}_{\delta_{ik}} = b_k,$$

gdzie δ_{ik} jest tzw. **deltą Kroneckera**: $\delta_{ik} = \begin{cases} 0 & i \neq k \\ 1 & i = k \end{cases}$

Stąd $\nabla f(\mathbf{x}) = \mathbf{b}$

Gradient – przykłady

Zadanie: policz gradient funkcji liniowej

$$f(\mathbf{x}) = c + \mathbf{b}^\top \mathbf{x} = c + \sum_{i=1}^n b_i x_i$$

Odpowiedź: wykorzystując liniowość pochodnej:

$$\frac{\partial f(\mathbf{x})}{\partial x_k} = \frac{\partial}{\partial x_k} \left(c + \sum_{i=1}^n b_i x_i \right) = \underbrace{\frac{\partial c}{\partial x_k}}_0 + \sum_{i=1}^n b_i \underbrace{\frac{\partial x_i}{\partial x_k}}_{\delta_{ik}} = b_k,$$

gdzie δ_{ik} jest tzw. **deltą Kroneckera**: $\delta_{ik} = \begin{cases} 0 & i \neq k \\ 1 & i = k \end{cases}$

Stąd $\nabla f(\mathbf{x}) = \mathbf{b}$

$$\nabla(c + \mathbf{b}^\top \mathbf{x}) = \mathbf{b}$$

Gradient – przykłady

Zadanie: policz gradient formy kwadratowej z symetryczną macierzą \mathbf{A}

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j$$

Gradient – przykłady

Zadanie: policz gradient formy kwadratowej z symetryczną macierzą A

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j$$

Odpowiedź: wykorzystując liniowość pochodnej:

$$\frac{\partial f(\mathbf{x})}{\partial x_k} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} \frac{\partial(x_i x_j)}{\partial x_k} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} \left(\underbrace{\frac{\partial x_i}{\partial x_k}}_{\delta_{ik}} x_j + x_i \underbrace{\frac{\partial x_j}{\partial x_k}}_{\delta_{jk}} \right)$$

Gradient – przykłady

Zadanie: policz gradient formy kwadratowej z symetryczną macierzą A

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j$$

Odpowiedź: wykorzystując liniowość pochodnej:

$$\begin{aligned} \frac{\partial f(\mathbf{x})}{\partial x_k} &= \sum_{i=1}^n \sum_{j=1}^n A_{ij} \frac{\partial(x_i x_j)}{\partial x_k} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} \left(\underbrace{\frac{\partial x_i}{\partial x_k}}_{\delta_{ik}} x_j + x_i \underbrace{\frac{\partial x_j}{\partial x_k}}_{\delta_{jk}} \right) \\ &= \sum_{j=1}^n A_{kj} x_j + \sum_{i=1}^n \underbrace{A_{ik}}_{A_{ki}} x_i = 2 \sum_{j=1}^n A_{kj} x_j \end{aligned}$$

Gradient – przykłady

Zadanie: policz gradient formy kwadratowej z symetryczną macierzą A

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j$$

Odpowiedź: wykorzystując liniowość pochodnej:

$$\begin{aligned} \frac{\partial f(\mathbf{x})}{\partial x_k} &= \sum_{i=1}^n \sum_{j=1}^n A_{ij} \frac{\partial(x_i x_j)}{\partial x_k} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} \left(\underbrace{\frac{\partial x_i}{\partial x_k}}_{\delta_{ik}} x_j + x_i \underbrace{\frac{\partial x_j}{\partial x_k}}_{\delta_{jk}} \right) \\ &= \sum_{j=1}^n A_{kj} x_j + \sum_{i=1}^n \underbrace{A_{ik}}_{A_{ki}} x_i = \underbrace{2 \sum_{j=1}^n A_{kj} x_j}_{\text{macierz} \times \text{wektor}} \end{aligned}$$

Gradient – przykłady

Zadanie: policz gradient formy kwadratowej z symetryczną macierzą A

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j$$

Odpowiedź: wykorzystując liniowość pochodnej:

$$\begin{aligned} \frac{\partial f(\mathbf{x})}{\partial x_k} &= \sum_{i=1}^n \sum_{j=1}^n A_{ij} \frac{\partial(x_i x_j)}{\partial x_k} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} \left(\underbrace{\frac{\partial x_i}{\partial x_k}}_{\delta_{ik}} x_j + x_i \underbrace{\frac{\partial x_j}{\partial x_k}}_{\delta_{jk}} \right) \\ &= \sum_{j=1}^n A_{kj} x_j + \sum_{i=1}^n \underbrace{A_{ik}}_{A_{ki}} x_i = \underbrace{2 \sum_{j=1}^n A_{kj} x_j}_{\text{macierz} \times \text{wektor}} \end{aligned}$$

Stąd: $\nabla f(\mathbf{x}) = 2\mathbf{A}\mathbf{x}$

Gradient – przykłady

Zadanie: policz gradient formy kwadratowej z symetryczną macierzą A

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} x_i x_j$$

Odpowiedź: wykorzystując liniowość pochodnej:

$$\begin{aligned} \frac{\partial f(\mathbf{x})}{\partial x_k} &= \sum_{i=1}^n \sum_{j=1}^n A_{ij} \frac{\partial(x_i x_j)}{\partial x_k} = \sum_{i=1}^n \sum_{j=1}^n A_{ij} \left(\underbrace{\frac{\partial x_i}{\partial x_k}}_{\delta_{ik}} x_j + x_i \underbrace{\frac{\partial x_j}{\partial x_k}}_{\delta_{jk}} \right) \\ &= \sum_{j=1}^n A_{kj} x_j + \sum_{i=1}^n \underbrace{A_{ik}}_{A_{ki}} x_i = \underbrace{2 \sum_{j=1}^n A_{kj} x_j}_{\text{macierz} \times \text{wektor}} \end{aligned}$$

Stąd: $\nabla f(\mathbf{x}) = 2\mathbf{A}\mathbf{x}$

$$\nabla (\mathbf{x}^\top \mathbf{A} \mathbf{x}) = 2\mathbf{A}\mathbf{x}$$

Reguła łańcuchowa

Złożenie dwóch funkcji jednej zmiennej

Pochodna funkcji złożonej $g(x) = f(y(x))$ dla $x \in \mathbb{R}$

$$g'(x) = f'(y(x)) \cdot y'(x),$$

lub w notacji Leibniza:

$$\frac{dg(x)}{dx} = \frac{df(y)}{dy} \cdot \frac{dy(x)}{dx}$$

Reguła łańcuchowa

Złożenie dwóch funkcji jednej zmiennej

Pochodna funkcji złożonej $g(x) = f(y(x))$ dla $x \in \mathbb{R}$

$$g'(x) = f'(y(x)) \cdot y'(x),$$

lub w notacji Leibniza:

$$\frac{dg(x)}{dx} = \frac{df(y)}{dy} \cdot \frac{dy(x)}{dx}$$

Złożenie funkcji wielu zmiennej z funkcjami jednej zmiennej

Pochodna funkcji złożonej $g(x) = f(\mathbf{y}(x))$ dla $x \in \mathbb{R}$,

gdzie $\mathbf{y}(x) = (y_1(x), \dots, y_n(x))$

$$\frac{dg(x)}{dx} = \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot \frac{dy_i(x)}{dx}$$

Reguła łańcuchowa – przykład

Rozważmy funkcję $g(\alpha)$ dla $\alpha \in \mathbb{R}$ postaci:

$$g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$$

dla ustalonych wektorów $\mathbf{x}, \mathbf{v} \in \mathbb{R}^n$

Reguła łańcuchowa – przykład

Rozważmy funkcję $g(\alpha)$ dla $\alpha \in \mathbb{R}$ postaci:

$$g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$$

dla ustalonych wektorów $\mathbf{x}, \mathbf{v} \in \mathbb{R}^n$

Definiujemy $\mathbf{y}(\alpha) = \mathbf{x} + \alpha\mathbf{v}$, stąd $g(\alpha) = f(\mathbf{y}(\alpha))$

Reguła łańcuchowa – przykład

Rozważmy funkcję $g(\alpha)$ dla $\alpha \in \mathbb{R}$ postaci:

$$g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$$

dla ustalonych wektorów $\mathbf{x}, \mathbf{v} \in \mathbb{R}^n$

Definiujemy $\mathbf{y}(\alpha) = \mathbf{x} + \alpha\mathbf{v}$, stąd $g(\alpha) = f(\mathbf{y}(\alpha))$

Z reguły łańcuchowej:

$$\frac{dg(\alpha)}{d\alpha} = \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot \frac{dy_i(\alpha)}{d\alpha}$$

Reguła łańcuchowa – przykład

Rozważmy funkcję $g(\alpha)$ dla $\alpha \in \mathbb{R}$ postaci:

$$g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$$

dla ustalonych wektorów $\mathbf{x}, \mathbf{v} \in \mathbb{R}^n$

Definiujemy $\mathbf{y}(\alpha) = \mathbf{x} + \alpha\mathbf{v}$, stąd $g(\alpha) = f(\mathbf{y}(\alpha))$

Z reguły łańcuchowej:

$$\frac{dg(\alpha)}{d\alpha} = \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot \frac{d \overbrace{y_i(\alpha)}^{x_i + \alpha v_i}}{d\alpha}$$

Reguła łańcuchowa – przykład

Rozważmy funkcję $g(\alpha)$ dla $\alpha \in \mathbb{R}$ postaci:

$$g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$$

dla ustalonych wektorów $\mathbf{x}, \mathbf{v} \in \mathbb{R}^n$

Definiujemy $\mathbf{y}(\alpha) = \mathbf{x} + \alpha\mathbf{v}$, stąd $g(\alpha) = f(\mathbf{y}(\alpha))$

Z reguły łańcuchowej:

$$\begin{aligned} \frac{dg(\alpha)}{d\alpha} &= \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot \frac{d \overbrace{y_i(\alpha)}^{x_i + \alpha v_i}}{d\alpha} \\ &= \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot v_i = \nabla f(\mathbf{y})^\top \mathbf{v} \end{aligned}$$

Reguła łańcuchowa – przykład

Rozważmy funkcję $g(\alpha)$ dla $\alpha \in \mathbb{R}$ postaci:

$$g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$$

dla ustalonych wektorów $\mathbf{x}, \mathbf{v} \in \mathbb{R}^n$

Definiujemy $\mathbf{y}(\alpha) = \mathbf{x} + \alpha\mathbf{v}$, stąd $g(\alpha) = f(\mathbf{y}(\alpha))$

Z reguły łańcuchowej:

$$\begin{aligned} \frac{dg(\alpha)}{d\alpha} &= \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot \frac{d \overbrace{y_i(\alpha)}^{x_i + \alpha v_i}}{d\alpha} \\ &= \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot v_i = \nabla f(\mathbf{y})^\top \mathbf{v} \end{aligned}$$

$$\boxed{\frac{df(\mathbf{x} + \alpha\mathbf{v})}{d\alpha} = \nabla f(\mathbf{x} + \alpha\mathbf{v})^\top \mathbf{v}}$$

Pochodna kierunkowa

Pochodną kierunkową funkcji $f(\mathbf{x})$ wzdłuż wektora \mathbf{v} w punkcie \mathbf{x} nazywamy granicę:

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{v}} = \lim_{\Delta \rightarrow 0} \frac{f(\mathbf{x} + \Delta \mathbf{v}) - f(\mathbf{x})}{\Delta}$$

Uwaga: zauważmy, że $\frac{\partial f(\mathbf{x})}{\partial x_i}$ jest pochodną kierunkową wzdłuż wektora \mathbf{e}_i

Pochodna kierunkowa

Pochodną kierunkową funkcji $f(\mathbf{x})$ wzdłuż wektora \mathbf{v} w punkcie \mathbf{x} nazywamy granicę:

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{v}} = \lim_{\Delta \rightarrow 0} \frac{f(\mathbf{x} + \Delta \mathbf{v}) - f(\mathbf{x})}{\Delta}$$

Uwaga: zauważmy, że $\frac{\partial f(\mathbf{x})}{\partial x_i}$ jest pochodną kierunkową wzdłuż wektora \mathbf{e}_i

Definiując funkcję $g(\Delta) = f(\mathbf{x} + \Delta \mathbf{v})$, otrzymujemy:

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{v}} = \lim_{\Delta \rightarrow 0} \frac{g(\Delta) - g(0)}{\Delta} = g'(0)$$

Pochodna kierunkowa

Pochodną kierunkową funkcji $f(\mathbf{x})$ wzdłuż wektora \mathbf{v} w punkcie \mathbf{x} nazywamy granicę:

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{v}} = \lim_{\Delta \rightarrow 0} \frac{f(\mathbf{x} + \Delta \mathbf{v}) - f(\mathbf{x})}{\Delta}$$

Uwaga: zauważmy, że $\frac{\partial f(\mathbf{x})}{\partial x_i}$ jest pochodną kierunkową wzdłuż wektora \mathbf{e}_i

Definiując funkcję $g(\Delta) = f(\mathbf{x} + \Delta \mathbf{v})$, otrzymujemy:

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{v}} = \lim_{\Delta \rightarrow 0} \frac{g(\Delta) - g(0)}{\Delta} = g'(0)$$

Używając reguły z poprzedniego slajdu (z Δ w roli α):

$$g'(0) = \left. \frac{df(\mathbf{x} + \Delta \mathbf{v})}{d\Delta} \right|_{\Delta=0} = \left. \nabla f(\mathbf{x} + \Delta \mathbf{v})^\top \mathbf{v} \right|_{\Delta=0} = \nabla f(\mathbf{x})^\top \mathbf{v}$$

Pochodna kierunkowa

Pochodną kierunkową funkcji $f(\mathbf{x})$ wzdłuż wektora \mathbf{v} w punkcie \mathbf{x} nazywamy granicę:

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{v}} = \lim_{\Delta \rightarrow 0} \frac{f(\mathbf{x} + \Delta \mathbf{v}) - f(\mathbf{x})}{\Delta}$$

Uwaga: zauważmy, że $\frac{\partial f(\mathbf{x})}{\partial x_i}$ jest pochodną kierunkową wzdłuż wektora \mathbf{e}_i

Definiując funkcję $g(\Delta) = f(\mathbf{x} + \Delta \mathbf{v})$, otrzymujemy:

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{v}} = \lim_{\Delta \rightarrow 0} \frac{g(\Delta) - g(0)}{\Delta} = g'(0)$$

Używając reguły z poprzedniego slajdu (z Δ w roli α):

$$g'(0) = \left. \frac{df(\mathbf{x} + \Delta \mathbf{v})}{d\Delta} \right|_{\Delta=0} = \left. \nabla f(\mathbf{x} + \Delta \mathbf{v})^\top \mathbf{v} \right|_{\Delta=0} = \nabla f(\mathbf{x})^\top \mathbf{v}$$

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{v}} = \nabla f(\mathbf{x})^\top \mathbf{v}$$

Pochodne wyższych rzędów

$$\underbrace{\frac{\partial^2 f(\mathbf{x})}{\partial x_i^2} = \frac{\partial}{\partial x_i} \left(\frac{\partial f(\mathbf{x})}{\partial x_i} \right)}_{\text{pochodne czyste}},$$

$$\underbrace{\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = \frac{\partial}{\partial x_i} \left(\frac{\partial f(\mathbf{x})}{\partial x_j} \right)}_{\text{pochodne mieszane}},$$

Pochodne wyższych rzędów

$$\underbrace{\frac{\partial^2 f(\mathbf{x})}{\partial x_i^2} = \frac{\partial}{\partial x_i} \left(\frac{\partial f(\mathbf{x})}{\partial x_i} \right)}_{\text{pochodne czyste}}$$

$$\underbrace{\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = \frac{\partial}{\partial x_i} \left(\frac{\partial f(\mathbf{x})}{\partial x_j} \right)}_{\text{pochodne mieszane}}$$

Przykład: dla $f(x_1, x_2) = x_1^2 e^{x_2} + x_2$

$$\frac{\partial f}{\partial x_1} = 2x_1 e^{x_2}, \quad \frac{\partial f}{\partial x_2} = x_1^2 e^{x_2} + 1$$

$$\frac{\partial^2 f}{\partial x_1^2} = 2e^{x_2}, \quad \frac{\partial^2 f}{\partial x_2 \partial x_1} = 2x_1 e^{x_2}, \quad \frac{\partial^2 f}{\partial x_2^2} = x_1^2 e^{x_2}, \quad \frac{\partial^2 f}{\partial x_1 \partial x_2} = 2x_1 e^{x_2}$$

Pochodne wyższych rzędów

$$\underbrace{\frac{\partial^2 f(\mathbf{x})}{\partial x_i^2} = \frac{\partial}{\partial x_i} \left(\frac{\partial f(\mathbf{x})}{\partial x_i} \right)}_{\text{pochodne czyste}}$$

$$\underbrace{\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = \frac{\partial}{\partial x_i} \left(\frac{\partial f(\mathbf{x})}{\partial x_j} \right)}_{\text{pochodne mieszane}}$$

Przykład: dla $f(x_1, x_2) = x_1^2 e^{x_2} + x_2$

$$\frac{\partial f}{\partial x_1} = 2x_1 e^{x_2}, \quad \frac{\partial f}{\partial x_2} = x_1^2 e^{x_2} + 1$$

$$\frac{\partial^2 f}{\partial x_1^2} = 2e^{x_2}, \quad \frac{\partial^2 f}{\partial x_2 \partial x_1} = 2x_1 e^{x_2}, \quad \frac{\partial^2 f}{\partial x_2^2} = x_1^2 e^{x_2}, \quad \frac{\partial^2 f}{\partial x_1 \partial x_2} = 2x_1 e^{x_2}$$

Fakt: Jeśli f ma ciągłe drugie pochodne mieszane to

$$\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = \frac{\partial^2 f(\mathbf{x})}{\partial x_j \partial x_i}$$

Hesjan

Hesjan funkcji $f(\mathbf{x})$ w punkcie \mathbf{x} to macierz drugich pochodnych cząstkowych:

$$\nabla^2 f(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2 f(\mathbf{x})}{\partial x_1^2} & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_2^2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial^2 x_n} \end{bmatrix}$$

Hesjan jest macierzą **symetryczną**

Hesjan

Hesjan funkcji $f(\mathbf{x})$ w punkcie \mathbf{x} to macierz drugich pochodnych cząstkowych:

$$\nabla^2 f(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2 f(\mathbf{x})}{\partial x_1^2} & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_2^2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial^2 x_n} \end{bmatrix}$$

Hesjan jest macierzą **symetryczną**

Przykład: dla $f(x_1, x_2) = x_1^2 e^{x_2} + x_2$

$$\frac{\partial^2 f}{\partial x_1^2} = 2e^{x_2}, \quad \frac{\partial^2 f}{\partial x_2 \partial x_1} = 2x_1 e^{x_2}, \quad \frac{\partial^2 f}{\partial x_2^2} = x_1^2 e^{x_2}, \quad \frac{\partial^2 f}{\partial x_1 \partial x_2} = 2x_1 e^{x_2}$$

$$\text{Stąd: } \nabla^2 f(\mathbf{x}) = \begin{bmatrix} 2e^{x_2} & 2x_1 e^{x_2} \\ 2x_1 e^{x_2} & x_1^2 e^{x_2} \end{bmatrix}$$

Hesjan – przykład

Wyznacz hesjan funkcji liniowej $f(\mathbf{x}) = c + \mathbf{b}^\top \mathbf{x}$

Hesjan – przykład

Wyznacz hesjan funkcji liniowej $f(\mathbf{x}) = c + \mathbf{b}^\top \mathbf{x}$

Rozwiązanie:

$$\frac{\partial f(\mathbf{x})}{\partial x_i} = b_i, \quad \frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = 0$$

stąd $\nabla^2 f(\mathbf{x}) = \mathbf{0}$ jest **macierzą zerową**

Hesjan – przykład

Wyznacz hesjan formy kwadratowej $f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x}$ dla symetrycznej macierzy \mathbf{A}

Hesjan – przykład

Wyznacz hesjan formy kwadratowej $f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x}$ dla symetrycznej macierzy \mathbf{A}

Rozwiązanie: wyznaczyliśmy już poprzednio

$$\frac{\partial f(\mathbf{x})}{\partial x_i} = 2 \sum_{j=1}^n A_{ij} x_j,$$

stąd:

$$\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = 2A_{ij}$$

Hesjan – przykład

Wyznacz hesjan formy kwadratowej $f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x}$ dla symetrycznej macierzy \mathbf{A}

Rozwiązanie: wyznaczyliśmy już poprzednio

$$\frac{\partial f(\mathbf{x})}{\partial x_i} = 2 \sum_{j=1}^n A_{ij} x_j,$$

stąd:

$$\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = 2A_{ij}$$

$$\nabla^2 (\mathbf{x}^\top \mathbf{A} \mathbf{x}) = 2\mathbf{A}$$

Hesjan – przykład

Wyznacz hesjan formy kwadratowej $f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x}$ dla symetrycznej macierzy \mathbf{A}

Rozwiązanie: wyznaczyliśmy już poprzednio

$$\frac{\partial f(\mathbf{x})}{\partial x_i} = 2 \sum_{j=1}^n A_{ij} x_j,$$

stąd:

$$\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = 2A_{ij}$$

$$\nabla^2 (\mathbf{x}^\top \mathbf{A} \mathbf{x}) = 2\mathbf{A}$$

Wniosek: Hesjan ogólnej funkcji kwadratowej

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}$$

Hesjan – przykład

Wyznacz drugą pochodną funkcji złożonej $g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$

Hesjan – przykład

Wyznacz drugą pochodną funkcji złożonej $g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$

Pokazaliśmy już, że $g'(\alpha) = \nabla f(\mathbf{x} + \alpha\mathbf{v})^\top \mathbf{v}$

Hesjan – przykład

Wyznacz drugą pochodną funkcji złożonej $g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$

Pokazaliśmy już, że $g'(\alpha) = \nabla f(\mathbf{x} + \alpha\mathbf{v})^\top \mathbf{v}$

Możemy potraktować $g'(\alpha)$ jako funkcję złożoną $h(\mathbf{y}(\alpha))$, gdzie

$$\mathbf{y}(\alpha) = \mathbf{x} + \alpha\mathbf{v}, \quad h(\mathbf{y}) = \nabla f(\mathbf{y})^\top \mathbf{v} = \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot v_i$$

Hesjan – przykład

Wyznacz drugą pochodną funkcji złożonej $g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$

Pokazaliśmy już, że $g'(\alpha) = \nabla f(\mathbf{x} + \alpha\mathbf{v})^\top \mathbf{v}$

Możemy potraktować $g'(\alpha)$ jako funkcję złożoną $h(\mathbf{y}(\alpha))$, gdzie

$$\mathbf{y}(\alpha) = \mathbf{x} + \alpha\mathbf{v}, \quad h(\mathbf{y}) = \nabla f(\mathbf{y})^\top \mathbf{v} = \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot v_i$$

Z reguły łańcuchowej:

$$g''(\alpha) = \frac{dg'(\alpha)}{d\alpha} = \sum_{i=1}^n \frac{\partial h(\mathbf{y})}{\partial y_i} \cdot \frac{d \overbrace{y_i}^{x_i + \alpha v_i}}{d\alpha}$$

Hesjan – przykład

Wyznacz drugą pochodną funkcji złożonej $g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$

Pokazaliśmy już, że $g'(\alpha) = \nabla f(\mathbf{x} + \alpha\mathbf{v})^\top \mathbf{v}$

Możemy potraktować $g'(\alpha)$ jako funkcję złożoną $h(\mathbf{y}(\alpha))$, gdzie

$$\mathbf{y}(\alpha) = \mathbf{x} + \alpha\mathbf{v}, \quad h(\mathbf{y}) = \nabla f(\mathbf{y})^\top \mathbf{v} = \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot v_i$$

Z reguły łańcuchowej:

$$g''(\alpha) = \frac{dg'(\alpha)}{d\alpha} = \sum_{i=1}^n \frac{\partial h(\mathbf{y})}{\partial y_i} \cdot \frac{d \overbrace{y_i}^{x_i + \alpha v_i}}{d\alpha} = \sum_{i=1}^n \frac{\partial}{\partial y_i} \left(\sum_{j=1}^n \frac{\partial f(\mathbf{y})}{\partial y_j} v_j \right) v_i$$

Hesjan – przykład

Wyznacz drugą pochodną funkcji złożonej $g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$

Pokazaliśmy już, że $g'(\alpha) = \nabla f(\mathbf{x} + \alpha\mathbf{v})^\top \mathbf{v}$

Możemy potraktować $g'(\alpha)$ jako funkcję złożoną $h(\mathbf{y}(\alpha))$, gdzie

$$\mathbf{y}(\alpha) = \mathbf{x} + \alpha\mathbf{v}, \quad h(\mathbf{y}) = \nabla f(\mathbf{y})^\top \mathbf{v} = \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot v_i$$

Z reguły łańcuchowej:

$$\begin{aligned} g''(\alpha) &= \frac{dg'(\alpha)}{d\alpha} = \sum_{i=1}^n \frac{\partial h(\mathbf{y})}{\partial y_i} \cdot \frac{d \overbrace{y_i}^{x_i + \alpha v_i}}{d\alpha} = \sum_{i=1}^n \frac{\partial}{\partial y_i} \left(\sum_{j=1}^n \frac{\partial f(\mathbf{y})}{\partial y_j} v_j \right) v_i \\ &= \sum_{i=1}^n \sum_{j=1}^n \frac{\partial^2 f(\mathbf{y})}{\partial y_i \partial y_j} v_i v_j \end{aligned}$$

Hesjan – przykład

Wyznacz drugą pochodną funkcji złożonej $g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$

Pokazaliśmy już, że $g'(\alpha) = \nabla f(\mathbf{x} + \alpha\mathbf{v})^\top \mathbf{v}$

Możemy potraktować $g'(\alpha)$ jako funkcję złożoną $h(\mathbf{y}(\alpha))$, gdzie

$$\mathbf{y}(\alpha) = \mathbf{x} + \alpha\mathbf{v}, \quad h(\mathbf{y}) = \nabla f(\mathbf{y})^\top \mathbf{v} = \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot v_i$$

Z reguły łańcuchowej:

$$\begin{aligned} g''(\alpha) &= \frac{dg'(\alpha)}{d\alpha} = \sum_{i=1}^n \frac{\partial h(\mathbf{y})}{\partial y_i} \cdot \frac{d \overbrace{y_i}^{x_i + \alpha v_i}}{d\alpha} = \sum_{i=1}^n \frac{\partial}{\partial y_i} \left(\sum_{j=1}^n \frac{\partial f(\mathbf{y})}{\partial y_j} v_j \right) v_i \\ &= \sum_{i=1}^n \sum_{j=1}^n \frac{\partial^2 f(\mathbf{y})}{\partial y_i \partial y_j} v_i v_j = \mathbf{v}^\top \nabla^2 f(\mathbf{y}) \mathbf{v} \end{aligned}$$

Hesjan – przykład

Wyznacz drugą pochodną funkcji złożonej $g(\alpha) = f(\mathbf{x} + \alpha\mathbf{v})$

Pokazaliśmy już, że $g'(\alpha) = \nabla f(\mathbf{x} + \alpha\mathbf{v})^\top \mathbf{v}$

Możemy potraktować $g'(\alpha)$ jako funkcję złożoną $h(\mathbf{y}(\alpha))$, gdzie

$$\mathbf{y}(\alpha) = \mathbf{x} + \alpha\mathbf{v}, \quad h(\mathbf{y}) = \nabla f(\mathbf{y})^\top \mathbf{v} = \sum_{i=1}^n \frac{\partial f(\mathbf{y})}{\partial y_i} \cdot v_i$$

Z reguły łańcuchowej:

$$\begin{aligned} g''(\alpha) &= \frac{dg'(\alpha)}{d\alpha} = \sum_{i=1}^n \frac{\partial h(\mathbf{y})}{\partial y_i} \cdot \frac{d \overbrace{y_i}^{x_i + \alpha v_i}}{d\alpha} = \sum_{i=1}^n \frac{\partial}{\partial y_i} \left(\sum_{j=1}^n \frac{\partial f(\mathbf{y})}{\partial y_j} v_j \right) v_i \\ &= \sum_{i=1}^n \sum_{j=1}^n \frac{\partial^2 f(\mathbf{y})}{\partial y_i \partial y_j} v_i v_j = \mathbf{v}^\top \nabla^2 f(\mathbf{y}) \mathbf{v} \end{aligned}$$

$$\frac{d^2 f(\mathbf{x} + \alpha\mathbf{v})}{d\alpha^2} = \mathbf{v}^\top \nabla^2 f(\mathbf{x} + \alpha\mathbf{v}) \mathbf{v}$$

Minimum lokalne


Minimum lokalne: Funkcja $f(x)$ ma w punkcie x_0 minimum lokalne, jeśli istnieje takie ϵ , że dla dowolnych x spełniających $\|x - x_0\| \leq \epsilon$, mamy $f(x_0) \leq f(x)$.

Analogicznie definiujemy **maksimum lokalne**

Minimum lokalne

Minimum lokalne: Funkcja $f(x)$ ma w punkcie x_0 minimum lokalne, jeśli istnieje takie ϵ , że dla dowolnych x spełniających $\|x - x_0\| \leq \epsilon$, mamy $f(x_0) \leq f(x)$.

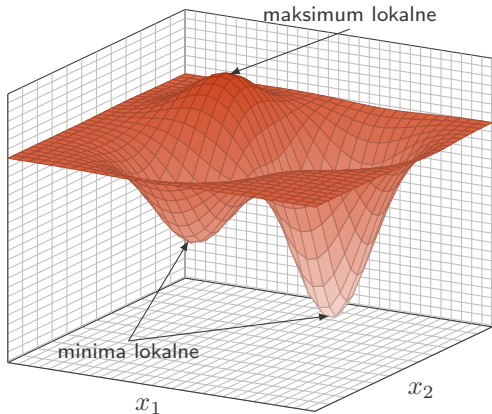
Analogicznie definiujemy **maksimum lokalne**



Minimum lokalne

Minimum lokalne: Funkcja $f(x)$ ma w punkcie x_0 minimum lokalne, jeśli istnieje takie ϵ , że dla dowolnych x spełniających $\|x - x_0\| \leq \epsilon$, mamy $f(x_0) \leq f(x)$.

Analogicznie definiujemy **maksimum lokalne**



Punkty stacjonarne

Niech $f(\boldsymbol{x})$ będzie różniczkowalna na swojej dziedzinie. Punkty, dla których $\nabla f(\boldsymbol{x}) = \mathbf{0}$ nazywamy **punktami stacjonarnymi (krytycznymi)**

Punkty stacjonarne

Niech $f(\boldsymbol{x})$ będzie różniczkowalna na swojej dziedzinie. Punkty, dla których $\nabla f(\boldsymbol{x}) = \mathbf{0}$ nazywamy **punktami stacjonarnymi (krytycznymi)**

Warunek konieczny na ekstremum: Jeśli różniczkowalna funkcja $f(\boldsymbol{x})$ ma w \boldsymbol{x}_0 ekstremum, to \boldsymbol{x}_0 jest punktem stacjonarnym.


Punkty stacjonarne

Niech $f(x)$ będzie różniczkowalna na swojej dziedzinie. Punkty, dla których $\nabla f(x) = 0$ nazywamy **punktami stacjonarnymi (krytycznymi)**


Warunek konieczny na ekstremum: Jeśli różniczkowalna funkcja $f(x)$ ma w x_0 ekstremum, to x_0 jest punktem stacjonarnym.

Uwaga: Nie wszystkie punkty stacjonarne to ekstrema.


maksimum lokalne



minimum lokalne



punkt siodłowy



Warunek wystarczający na minimum

Jeśli x_0 jest punktem stacjonarnym dwukrotnie różniczkowalnej funkcji $f(x)$, tzn. $\nabla f(x_0) = \mathbf{0}$, oraz hesjan $\nabla^2 f(x_0)$ jest **dodatnio określony**, to $f(x)$ ma **minimum lokalne w x_0**

Warunek wystarczający na minimum

Jeśli x_0 jest punktem stacjonarnym dwukrotnie różniczkowalnej funkcji $f(x)$, tzn. $\nabla f(x_0) = \mathbf{0}$, oraz hesjan $\nabla^2 f(x_0)$ jest **dodatnio określony**, to $f(x)$ ma **minimum lokalne w x_0**

Przypomnienie: symetryczna macierz A jest dodatnio określona jeśli $v^T A v > 0$ dla dowolnego niezerowego wektora v

Równoważnie, wszystkie wartości własne A są dodatnie

Minimum funkcji kwadratowej

Rozważmy funkcję kwadratową o ogólnej postaci:

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c$$

gdzie \mathbf{A} jest symetryczna i odwracalna.

Minimum funkcji kwadratowej

Rozważmy funkcję kwadratową o ogólnej postaci:

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c$$

gdzie \mathbf{A} jest symetryczna i odwracalna.

Wyznaczamy gradient i hesjan:

$$\nabla f(\mathbf{x}) = 2\mathbf{A}\mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}$$

Minimum funkcji kwadratowej

Rozważmy funkcję kwadratową o ogólnej postaci:

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c$$

gdzie \mathbf{A} jest symetryczna i odwracalna.

Wyznaczamy gradient i hesjan:

$$\nabla f(\mathbf{x}) = 2\mathbf{A}\mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}$$

Znajdujemy punkt stacjonarny:

$$\nabla f(\mathbf{x}) = \mathbf{0} \iff 2\mathbf{A}\mathbf{x} = -\mathbf{b} \iff \mathbf{x} = -\frac{1}{2}\mathbf{A}^{-1}\mathbf{b}$$

Jest to **minimum**, gdy \mathbf{A} jest **dodatnio określona**

Minimum funkcji kwadratowej

Rozważmy funkcję kwadratową o ogólnej postaci:

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c$$

gdzie \mathbf{A} jest symetryczna i odwracalna.

Wyznaczamy gradient i hesjan:

$$\nabla f(\mathbf{x}) = 2\mathbf{A}\mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}$$

Znajdujemy punkt stacjonarny:

$$\nabla f(\mathbf{x}) = \mathbf{0} \iff 2\mathbf{A}\mathbf{x} = -\mathbf{b} \iff \mathbf{x} = -\frac{1}{2}\mathbf{A}^{-1}\mathbf{b}$$

Jest to **minimum**, gdy \mathbf{A} jest **dodatnio określona**

Wniosek: Minimum funkcji kwadratowej:

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c, \quad \mathbf{A} - \text{dodatnio określona,}$$

ma postać $\mathbf{x}^* = -\frac{1}{2}\mathbf{A}^{-1}\mathbf{b}$

Funkcja kwadratowa – przykład

$$f(x_1, x_2) = 3x_1^2 + 3x_2^2 - 2x_1x_2 + x_1 - 2x_2 + 1$$

Funkcja kwadratowa – przykład

$$f(x_1, x_2) = 3x_1^2 + 3x_2^2 - 2x_1x_2 + x_1 - 2x_2 + 1$$

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c \quad \text{gdzie } c = 1, \mathbf{b} = \begin{bmatrix} 1 \\ -2 \end{bmatrix}, \mathbf{A} = \begin{bmatrix} 3 & -1 \\ -1 & 3 \end{bmatrix}$$

Funkcja kwadratowa – przykład

$$f(x_1, x_2) = 3x_1^2 + 3x_2^2 - 2x_1x_2 + x_1 - 2x_2 + 1$$

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c \quad \text{gdzie } c = 1, \mathbf{b} = \begin{bmatrix} 1 \\ -2 \end{bmatrix}, \mathbf{A} = \begin{bmatrix} 3 & -1 \\ -1 & 3 \end{bmatrix}$$

$$\mathbf{A}^{-1} = \frac{1}{8} \begin{bmatrix} 3 & 1 \\ 1 & 3 \end{bmatrix}$$

Funkcja kwadratowa – przykład

$$f(x_1, x_2) = 3x_1^2 + 3x_2^2 - 2x_1x_2 + x_1 - 2x_2 + 1$$

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c \quad \text{gdzie } c = 1, \mathbf{b} = \begin{bmatrix} 1 \\ -2 \end{bmatrix}, \mathbf{A} = \begin{bmatrix} 3 & -1 \\ -1 & 3 \end{bmatrix}$$

$$\mathbf{A}^{-1} = \frac{1}{8} \begin{bmatrix} 3 & 1 \\ 1 & 3 \end{bmatrix} \quad \Longrightarrow \quad \mathbf{x}^* = -\mathbf{A}^{-1} \mathbf{b} = \begin{bmatrix} -\frac{1}{16} \\ \frac{5}{16} \end{bmatrix}$$

Punkt \mathbf{x}^* jest punktem stacjonarnym

Funkcja kwadratowa – przykład

$$f(x_1, x_2) = 3x_1^2 + 3x_2^2 - 2x_1x_2 + x_1 - 2x_2 + 1$$

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c \quad \text{gdzie } c = 1, \mathbf{b} = \begin{bmatrix} 1 \\ -2 \end{bmatrix}, \mathbf{A} = \begin{bmatrix} 3 & -1 \\ -1 & 3 \end{bmatrix}$$

$$\mathbf{A}^{-1} = \frac{1}{8} \begin{bmatrix} 3 & 1 \\ 1 & 3 \end{bmatrix} \quad \Longrightarrow \quad \mathbf{x}^* = -\mathbf{A}^{-1} \mathbf{b} = \begin{bmatrix} -\frac{1}{16} \\ \frac{5}{16} \end{bmatrix}$$

Punkt \mathbf{x}^* jest punktem stacjonarnym

Ponieważ $\det \mathbf{A} = 8$ i $A_{11} = 3$, \mathbf{A} jest **dodatnio określona**, stąd funkcja ma **minimum w \mathbf{x}^***

Wielomiany Taylora dla funkcji wielu zmiennych

Dla danej funkcji $f(\mathbf{x})$ i punktu \mathbf{x}_0 , rozważmy funkcję **jednej zmiennej**:

$$g(\alpha) = f(\mathbf{x}_0 + \alpha(\mathbf{x} - \mathbf{x}_0))$$

Zachodzi $g(0) = f(\mathbf{x}_0)$ i $g(1) = f(\mathbf{x})$.

Wielomiany Taylora dla funkcji wielu zmiennych

Dla danej funkcji $f(\mathbf{x})$ i punktu \mathbf{x}_0 , rozważmy funkcję **jednej zmiennej**:

$$g(\alpha) = f(\mathbf{x}_0 + \alpha(\mathbf{x} - \mathbf{x}_0))$$

Zachodzi $g(0) = f(\mathbf{x}_0)$ i $g(1) = f(\mathbf{x})$.

Konstrukcja wielomianu Taylora dla funkcji $f(\mathbf{x})$ wokół punktu \mathbf{x}_0 :

- Wyznaczamy wielomian Taylora $P_k(\alpha; 0)$ funkcji $g(\alpha)$ wokół $\alpha = 0$
- Ponieważ $P_k(\alpha; 0)$ przybliża $g(\alpha)$ wokół $\alpha = 0$, oraz $g(0) = f(\mathbf{x}_0)$ i $g(1) = f(\mathbf{x})$, to $P_k(1; 0)$ przybliża funkcję $f(\mathbf{x})$ wokół $\mathbf{x} = \mathbf{x}_0$

Wielomiany Taylora dla funkcji wielu zmiennych

Dla danej funkcji $f(\mathbf{x})$ i punktu \mathbf{x}_0 , rozważmy funkcję **jednej zmiennej**:

$$g(\alpha) = f(\mathbf{x}_0 + \alpha(\mathbf{x} - \mathbf{x}_0))$$

Zachodzi $g(0) = f(\mathbf{x}_0)$ i $g(1) = f(\mathbf{x})$.

Konstrukcja wielomianu Taylora dla funkcji $f(\mathbf{x})$ wokół punktu \mathbf{x}_0 :

- Wyznaczamy wielomian Taylora $P_k(\alpha; 0)$ funkcji $g(\alpha)$ wokół $\alpha = 0$
- Ponieważ $P_k(\alpha; 0)$ przybliża $g(\alpha)$ wokół $\alpha = 0$, oraz $g(0) = f(\mathbf{x}_0)$ i $g(1) = f(\mathbf{x})$, to $P_k(1; 0)$ przybliża funkcję $f(\mathbf{x})$ wokół $\mathbf{x} = \mathbf{x}_0$

Pokazaliśmy już wcześniej (dla $\mathbf{v} = \mathbf{x} - \mathbf{x}_0$), że:

$$g'(\alpha) = \nabla f(\mathbf{x}_0 + \alpha(\mathbf{x} - \mathbf{x}_0))^\top (\mathbf{x} - \mathbf{x}_0)$$

$$g''(\alpha) = (\mathbf{x} - \mathbf{x}_0)^\top \nabla^2 f(\mathbf{x}_0 + \alpha(\mathbf{x} - \mathbf{x}_0)) (\mathbf{x} - \mathbf{x}_0)$$

Wielomiany Taylora dla funkcji wielu zmiennych

Dla danej funkcji $f(\mathbf{x})$ i punktu \mathbf{x}_0 , rozważmy funkcję **jednej zmiennej**:

$$g(\alpha) = f(\mathbf{x}_0 + \alpha(\mathbf{x} - \mathbf{x}_0))$$

Zachodzi $g(0) = f(\mathbf{x}_0)$ i $g(1) = f(\mathbf{x})$.

Konstrukcja wielomianu Taylora dla funkcji $f(\mathbf{x})$ wokół punktu \mathbf{x}_0 :

- Wyznaczamy wielomian Taylora $P_k(\alpha; 0)$ funkcji $g(\alpha)$ wokół $\alpha = 0$
- Ponieważ $P_k(\alpha; 0)$ przybliża $g(\alpha)$ wokół $\alpha = 0$, oraz $g(0) = f(\mathbf{x}_0)$ i $g(1) = f(\mathbf{x})$, to $P_k(1; 0)$ przybliża funkcję $f(\mathbf{x})$ wokół $\mathbf{x} = \mathbf{x}_0$

Pokazaliśmy już wcześniej (dla $\mathbf{v} = \mathbf{x} - \mathbf{x}_0$), że:

$$g'(0) = \nabla f(\mathbf{x}_0)^\top (\mathbf{x} - \mathbf{x}_0)$$

$$g''(0) = (\mathbf{x} - \mathbf{x}_0)^\top \nabla^2 f(\mathbf{x}_0) (\mathbf{x} - \mathbf{x}_0)$$

Wielomiany Taylora dla funkcji wielu zmiennych

Dla danej funkcji $f(\mathbf{x})$ i punktu \mathbf{x}_0 , rozważmy funkcję **jednej zmiennej**:

$$g(\alpha) = f(\mathbf{x}_0 + \alpha(\mathbf{x} - \mathbf{x}_0))$$

Zachodzi $g(0) = f(\mathbf{x}_0)$ i $g(1) = f(\mathbf{x})$.

Konstrukcja wielomianu Taylora dla funkcji $f(\mathbf{x})$ wokół punktu \mathbf{x}_0 :

- Wyznaczamy wielomian Taylora $P_k(\alpha; 0)$ funkcji $g(\alpha)$ wokół $\alpha = 0$
- Ponieważ $P_k(\alpha; 0)$ przybliża $g(\alpha)$ wokół $\alpha = 0$, oraz $g(0) = f(\mathbf{x}_0)$ i $g(1) = f(\mathbf{x})$, to $P_k(1; 0)$ przybliża funkcję $f(\mathbf{x})$ wokół $\mathbf{x} = \mathbf{x}_0$

Pokazaliśmy już wcześniej (dla $\mathbf{v} = \mathbf{x} - \mathbf{x}_0$), że:

$$g'(0) = \nabla f(\mathbf{x}_0)^\top (\mathbf{x} - \mathbf{x}_0)$$

$$g''(0) = (\mathbf{x} - \mathbf{x}_0)^\top \nabla^2 f(\mathbf{x}_0) (\mathbf{x} - \mathbf{x}_0)$$

Stąd:

$$P_0(\alpha; 0) = g(0)$$

$$P_1(\alpha; 0) = g(0) + g'(0)\alpha$$

$$P_2(\alpha; 0) = g(0) + g'(0)\alpha + \frac{g''(0)}{2}\alpha^2$$

Wielomiany Taylora dla funkcji wielu zmiennych

Dla danej funkcji $f(\mathbf{x})$ i punktu \mathbf{x}_0 , rozważmy funkcję **jednej zmiennej**:

$$g(\alpha) = f(\mathbf{x}_0 + \alpha(\mathbf{x} - \mathbf{x}_0))$$

Zachodzi $g(0) = f(\mathbf{x}_0)$ i $g(1) = f(\mathbf{x})$.

Konstrukcja wielomianu Taylora dla funkcji $f(\mathbf{x})$ wokół punktu \mathbf{x}_0 :

- Wyznaczamy wielomian Taylora $P_k(\alpha; 0)$ funkcji $g(\alpha)$ wokół $\alpha = 0$
- Ponieważ $P_k(\alpha; 0)$ przybliża $g(\alpha)$ wokół $\alpha = 0$, oraz $g(0) = f(\mathbf{x}_0)$ i $g(1) = f(\mathbf{x})$, to $P_k(1; 0)$ przybliża funkcję $f(\mathbf{x})$ wokół $\mathbf{x} = \mathbf{x}_0$

Pokazaliśmy już wcześniej (dla $\mathbf{v} = \mathbf{x} - \mathbf{x}_0$), że:

$$g'(0) = \nabla f(\mathbf{x}_0)^\top (\mathbf{x} - \mathbf{x}_0)$$

$$g''(0) = (\mathbf{x} - \mathbf{x}_0)^\top \nabla^2 f(\mathbf{x}_0) (\mathbf{x} - \mathbf{x}_0)$$

Stąd:

$$P_0(\alpha; 0) = f(\mathbf{x})$$

$$P_1(\alpha; 0) = f(\mathbf{x}_0) + \alpha \nabla f(\mathbf{x}_0)^\top (\mathbf{x} - \mathbf{x}_0)$$

$$P_2(\alpha; 0) = f(\mathbf{x}_0) + \alpha \nabla f(\mathbf{x}_0)^\top (\mathbf{x} - \mathbf{x}_0) + \frac{\alpha^2}{2} (\mathbf{x} - \mathbf{x}_0)^\top \nabla^2 f(\mathbf{x}_0) (\mathbf{x} - \mathbf{x}_0)$$

Wielomiany Taylora dla funkcji wielu zmiennych

Wielomiany Taylora dla funkcji $f(\mathbf{x})$ wokół punktu \mathbf{x}_0 :

$$P_0(\mathbf{x}; \mathbf{x}_0) = f(\mathbf{x}_0)$$

$$P_1(\mathbf{x}; \mathbf{x}_0) = f(\mathbf{x}_0) + \nabla f(\mathbf{x}_0)^\top (\mathbf{x} - \mathbf{x}_0)$$

$$P_2(\mathbf{x}; \mathbf{x}_0) = f(\mathbf{x}_0) + \nabla f(\mathbf{x}_0)^\top (\mathbf{x} - \mathbf{x}_0) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_0)^\top \nabla^2 f(\mathbf{x}_0) (\mathbf{x} - \mathbf{x}_0)$$

$$\dots = \dots$$

Wielomiany Taylora dla funkcji wielu zmiennych

Wielomiany Taylora dla funkcji $f(\mathbf{x})$ wokół punktu \mathbf{x}_0 :

$$P_0(\mathbf{x}; \mathbf{x}_0) = f(\mathbf{x}_0)$$

$$P_1(\mathbf{x}; \mathbf{x}_0) = f(\mathbf{x}_0) + \nabla f(\mathbf{x}_0)^\top (\mathbf{x} - \mathbf{x}_0)$$

$$P_2(\mathbf{x}; \mathbf{x}_0) = f(\mathbf{x}_0) + \nabla f(\mathbf{x}_0)^\top (\mathbf{x} - \mathbf{x}_0) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_0)^\top \nabla^2 f(\mathbf{x}_0) (\mathbf{x} - \mathbf{x}_0)$$

$$\dots = \dots$$

Wzór Taylora (tylko dla drugiego rzędu):

$$f(\mathbf{x}) = f(\mathbf{x}_0) + \nabla f(\mathbf{x}_0)^\top (\mathbf{x} - \mathbf{x}_0) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_0)^\top \nabla^2 f(\boldsymbol{\xi}) (\mathbf{x} - \mathbf{x}_0),$$

gdzie $\boldsymbol{\xi}$ jest punktem między \mathbf{x}_0 a \mathbf{x}

Wielomian Taylora dla funkcji kwadratowej

Rozważmy funkcję kwadratową z dodatnio określoną macierzą \mathbf{A}

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c, \quad \nabla f(\mathbf{x}) = 2\mathbf{A} \mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}$$

Wielomian Taylora dla funkcji kwadratowej

Rozważmy funkcję kwadratową z dodatnio określoną macierzą A

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c, \quad \nabla f(\mathbf{x}) = 2\mathbf{A} \mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}$$

Przybliżenie funkcji kwadratowej wielomianem drugiego stopnia (funkcją kwadratową!) jest **dokładne**, a ze wzoru Taylora dla $\mathbf{x}_0 = \mathbf{x}^*$:

Wielomian Taylora dla funkcji kwadratowej

Rozważmy funkcję kwadratową z dodatnio określoną macierzą A

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c, \quad \nabla f(\mathbf{x}) = 2\mathbf{A} \mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}$$

Przybliżenie funkcji kwadratowej wielomianem drugiego stopnia (funkcją kwadratową!) jest **dokładne**, a ze wzoru Taylora dla $\mathbf{x}_0 = \mathbf{x}^*$:

$$f(\mathbf{x}) = f(\mathbf{x}^*) + \nabla f(\mathbf{x}^*)^\top (\mathbf{x} - \mathbf{x}^*) + \frac{1}{2} (\mathbf{x} - \mathbf{x}^*)^\top \nabla^2 f(\boldsymbol{\xi}) (\mathbf{x} - \mathbf{x}^*)$$

Wielomian Taylora dla funkcji kwadratowej

Rozważmy funkcję kwadratową z dodatnio określoną macierzą A

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c, \quad \nabla f(\mathbf{x}) = 2\mathbf{A} \mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}$$

Przybliżenie funkcji kwadratowej wielomianem drugiego stopnia (funkcją kwadratową!) jest **dokładne**, a ze wzoru Taylora dla $\mathbf{x}_0 = \mathbf{x}^*$:

$$f(\mathbf{x}) = f(\mathbf{x}^*) + \nabla f(\mathbf{x}^*)^\top (\mathbf{x} - \mathbf{x}^*) + \frac{1}{2} (\mathbf{x} - \mathbf{x}^*)^\top \nabla^2 f(\boldsymbol{\xi}) (\mathbf{x} - \mathbf{x}^*)$$

Ponieważ $\nabla f(\mathbf{x}^*) = \mathbf{0}$ (bo \mathbf{x}^* jest punktem minimum), a $\nabla^2 f(\boldsymbol{\xi}) = 2\mathbf{A}$:

Dla funkcji kwadratowej z dodatnio określoną macierzą A :

$$f(\mathbf{x}) = f(\mathbf{x}^*) + (\mathbf{x} - \mathbf{x}^*)^\top \mathbf{A} (\mathbf{x} - \mathbf{x}^*)$$