

1. [3pkt] Wyznacz analitycznie minimum funkcji jednej zmiennej na przedziale $[0, 1]$ zadanej wzorem: Krok 3:

$$f(x) = x - \sqrt{x + x^2}.$$

Wyznacz pochodną funkcji:

$$f'(x) =$$

Wyznacz kandydatów na minimum (pokaż obliczenia):

Odp: minimum w $x =$

Określ czy funkcja jest wypukła na przedziale $[0, 1]$:

2. [3pkt] Rozważ minimalizację funkcji jednej zmiennej:

$$f(x) = x^3 + 2x^2 - 7x + 13.75.$$

Rozpoczynając od przedziału $[-2, 14]$ wykonaj 3 kroki algorytmu bisekcji.

Wyznacz pochodną:

$$f'(x) =$$

Krok 1:

Krok 2:

4. [4pkt] Rozważ minimalizację funkcji dwóch zmiennych:

$$f(x, y) = (x^2 - y^2)^2 + x^2 + y^2.$$

Rozpoczynając od punktu $(x_0, y_0) = (1, 1)$ wykonaj jeden krok:

- metodą spadku wzdłuż gradientu z ustaloną długością kroku $\alpha = 1$,
- metodą Newtona-Raphsona.

Wyznacz pochodne cząstkowe $f(x, y)$:

Stąd $\nabla f(x_0, y_0) =$

Wyznacz drugie pochodne cząstkowe $f(x, y)$:

$$\text{Stąd } \nabla^2 f(x_0, y_0) =$$

$$(\nabla^2 f(x_0, y_0))^{-1} =$$

Rozwiązanie po pierwszym kroku algorytmu spadku wzdłuż gradientu (napisz wzór ogólny i wartość liczbową):

$$\mathbf{x}_1 = (x_1, y_1) =$$

Pierwszy krok algorytmu Newtona-Raphsona (napisz wzór ogólny i wartość liczbową):

$$\mathbf{x}_1 = (x_1, y_1) =$$

5. [2pkt] Przy każdym zdaniu dotyczącym metody gradientów sprzężonych (MGS) zaznacz, czy jest prawdziwe (P), czy fałszywe (F):

- (a) MGS znajduje dokładne rozwiązanie optymalne funkcji kwadratowej w n krokach, gdzie n to wymiar problemu.
- (b) Kierunki sprzężone są zawsze kierunkami poprawy, o ile tylko nie zostało osiągnięte rozwiązanie optymalne.
- (c) Metody Fletchera-Reevesa i Polaka-Ribière'a działają inaczej przy optymalizacji funkcji kwadratowej.
- (d) MGS wymaga policzenia hesjanu przy optymalizacji funkcji innej, niż kwadratowa.
- (e) Kierunki sprzężone są do siebie ortogonalne.

6. [2pkt] Przy każdym zdaniu dotyczącym omówionych metod spadkowych zaznacz, czy jest prawdziwe (P), czy fałszywe (F):

- (a) Żadna z metod nie gwarantuje znalezienia optymalnego rozwiązania funkcji niewypukłej.
- (b) Przy małej wartości wskaźnika uwarunkowania hesjanu w optimum metoda spadku wzdłuż gradientu będzie działać bardzo wolno.
- (c) Metoda Newtona-Raphsona zawsze zbiega do optymalnego rozwiązania dla funkcji wypukłych.
- (d) Liniowy rząd zbieżności oznacza, że odległość od optimum maleje odwrotnie proporcjonalnie do liczby iteracji k .
- (e) Kwadratowy rząd zbieżności oznacza, że odległość od optimum maleje podwójnie wykładniczo względem liczby iteracji k .
- (f) Metoda najszybszego spadku wzdłuż gradientu zbiega do optimum funkcji wypukłej z liniowym rzędem zbieżności.

7. [2pkt] Przy każdym zdaniu dotyczącym metody stochastycznego spadku wzdłuż gradientu (SGD) zaznacz, czy jest prawdziwe (P), czy fałszywe (F):

- (a) Jeżeli w problemie regresji liniowej z jedną zmienną ($\min_{a,b} \sum_{i=0}^n (y_i - (ax_i + b))^2$) zainicjalizujemy współczynnik kierunkowy a oraz wyraz wolny b na tę samą wartość to po jednej iteracji algorytmu SGD a nadal będzie równe b .
- (b) Jedna iteracja algorytmu SGD ma mniejszy koszt obliczeniowy niż jedna iteracja algorytmu spadku wzdłuż gradientu.
- (c) Technika mini-batch dla rozmiaru paczki równego 1 sprowadza się do algorytmu spadku wzdłuż gradientu.
- (d) Algorytm SGD zainicjalizowany w minimum funkcji może oddalić się od niego w pierwszej iteracji.

8. [3pkt] Dana jest wypukła wielowymiarowa funkcja $f(\mathbf{x})$. Używając definicji funkcji wypukłej udowodnij, że jednowymiarowa funkcja $g(\alpha) = f(\mathbf{x} - \alpha \nabla f(\mathbf{x}))$ optymalizowana w czasie iteracji algorytmu najszybszego spadku gradientu dla danego \mathbf{x} jest również wypukła.