

Optymalizacja ciągła

5. Metody kierunków poparwy (metoda Newtona-Raphsona, metoda gradientów sprzężonych)

Wojciech Kotłowski

Instytut Informatyki PP

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

28.03.2019

Plan wykładu

Minimalizacja **różniczkowalnej** funkcji $f(x)$ **bez ograniczeń**:

$$\min_{x \in \mathbb{R}^n} f(x)$$

Często będziemy zakładać **wypukłość** $f(x)$

1. Wprowadzenie (poprzedni wykład)
2. Metoda spadku wzdłuż gradientu (poprzedni wykład)
3. Metoda Newtona-Raphsona
4. Modyfikacje metody Newtona-Raphsona
5. Metoda gradientów sprzężonych

Przypomnienie: metody kierunków poprawy

- Iteracyjne metody generujące punkty $\mathbf{x}_1, \mathbf{x}_2, \dots$ zgodnie z:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k,$$

- Kierunek \mathbf{v}_k jest **kierunkiem poprawy**: gwarantuje, że przy dostatecznie małych $\alpha \in \mathbb{R}$:

$$f(\mathbf{x}_k + \alpha \mathbf{v}_k) < f(\mathbf{x}_k)$$


Równoważnie, **pochodna kierunkowa** wzdłuż \mathbf{v}_k musi być **ujemna**:

$$\frac{\partial f(\mathbf{x}_k)}{\partial \mathbf{v}_k} = \nabla f(\mathbf{x}_k)^\top \mathbf{v}_k < 0$$

- **Długość kroku** α_k dobierana jest aby zapewnić odpowiednio duży spadek funkcji celu

Metoda Newtona-Raphsona

Przypomnienie: metoda Newtona



Metoda Newtona-Raphsona

Wielowymiarowa wersja metody Newtona

Generujemy iteracyjnie ciąg punktów $\mathbf{x}_1, \mathbf{x}_2, \dots$

W każdej iteracji $k = 1, 2, \dots$, przybliżamy funkcję $f(\mathbf{x})$ **wielomianem Taylora drugiego rzędu** w aktualnym punkcie \mathbf{x}_k :

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

Założenie: hesjan $\nabla^2 f(\mathbf{x}_k)$ jest **dodatnio określony**

Jako kolejny punkt \mathbf{x}_{k+1} bierzemy punkt minimalizujący $P_2(\mathbf{x}; \mathbf{x}_k)$

Metoda Newtona-Raphsona

Przypomnienie: Minimum funkcji kwadratowej $\mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c$ z dodatnio określoną macierzą \mathbf{A} ma postać $\mathbf{x}^* = -\frac{1}{2} \mathbf{A}^{-1} \mathbf{b}$

Metoda Newtona-Raphsona

Przypomnienie: Minimum funkcji kwadratowej $\mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c$ z dodatnio określoną macierzą \mathbf{A} ma postać $\mathbf{x}^* = -\frac{1}{2} \mathbf{A}^{-1} \mathbf{b}$

Wniosek: Minimum funkcji kwadratowej:

$$F(\mathbf{v}) = \frac{1}{2} \mathbf{v}^\top \nabla^2 f(\mathbf{x}_k) \mathbf{v} + \nabla f(\mathbf{x}_k)^\top \mathbf{v} + f(\mathbf{x}_k)$$

jest w punkcie $\mathbf{v} = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$

Metoda Newtona-Raphsona

Przypomnienie: Minimum funkcji kwadratowej $\mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c$ z dodatnio określoną macierzą \mathbf{A} ma postać $\mathbf{x}^* = -\frac{1}{2} \mathbf{A}^{-1} \mathbf{b}$

Wniosek: Minimum funkcji kwadratowej:

$$F(\mathbf{v}) = \frac{1}{2} \mathbf{v}^\top \nabla^2 f(\mathbf{x}_k) \mathbf{v} + \nabla f(\mathbf{x}_k)^\top \mathbf{v} + f(\mathbf{x}_k)$$

jest w punkcie $\mathbf{v} = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$

Wniosek: Biorąc $\mathbf{v} = \mathbf{x} - \mathbf{x}_k$, minimum wielomianu:

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

jest w punkcie \mathbf{x} spełniającym:

$$\mathbf{x} - \mathbf{x}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$

Metoda Newtona-Raphsona

Przypomnienie: Minimum funkcji kwadratowej $\mathbf{x}^\top \mathbf{A} \mathbf{x} + \mathbf{b}^\top \mathbf{x} + c$ z dodatnio określoną macierzą \mathbf{A} ma postać $\mathbf{x}^* = -\frac{1}{2} \mathbf{A}^{-1} \mathbf{b}$

Wniosek: Minimum funkcji kwadratowej:

$$F(\mathbf{v}) = \frac{1}{2} \mathbf{v}^\top \nabla^2 f(\mathbf{x}_k) \mathbf{v} + \nabla f(\mathbf{x}_k)^\top \mathbf{v} + f(\mathbf{x}_k)$$

jest w punkcie $\mathbf{v} = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$

Wniosek: Biorąc $\mathbf{v} = \mathbf{x} - \mathbf{x}_k$, minimum wielomianu:

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


jest w punkcie \mathbf{x} spełniającym:

$$\mathbf{x} - \mathbf{x}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$


Metoda Newtona-Raphsona:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - (\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$


Metoda Newtona-Raphsona



Metoda Newtona-Raphsona



Metoda Newtona-Raphsona



Metoda Newtona-Raphsona

Rozpocznij od punktu \mathbf{x}_1 i powtarzaj dla $k = 1, 2, \dots$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - (\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$

Metoda Newtona-Raphsona

Rozpocznij od punktu \mathbf{x}_1 i powtarzaj dla $k = 1, 2, \dots$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - (\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$

- Porównaj z metodą Newtona dla jednej zmiennej: $x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k)}$

Metoda Newtona-Raphsona

Rozpocznij od punktu \mathbf{x}_1 i powtarzaj dla $k = 1, 2, \dots$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - (\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$

- Porównaj z metodą Newtona dla jednej zmiennej: $x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k)}$
- Metoda obliczeniowo **wolniejsza** od spadku wzdłuż gradientu:
wymaga odwrócenia macierzy w każdej iteracji
(w praktyce zamiast odwracać macierz rozwiązuje się układ równań liniowych $\mathbf{A}\mathbf{x} = \mathbf{b}$ z $\mathbf{A} = \nabla^2 f(\mathbf{x}_k)$ i $\mathbf{b} = \nabla f(\mathbf{x}_k)$)

Metoda Newtona-Raphsona


Rozpocznij od punktu \mathbf{x}_1 i powtarzaj dla $k = 1, 2, \dots$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - (\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$

- Porównaj z metodą Newtona dla jednej zmiennej: $x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k)}$
- Metoda obliczeniowo **wolniejsza** od spadku wzdłuż gradientu:
wymaga odwrócenia macierzy w każdej iteracji
(w praktyce zamiast odwracać macierz rozwiązuje się układ równań liniowych $\mathbf{A}\mathbf{x} = \mathbf{b}$ z $\mathbf{A} = \nabla^2 f(\mathbf{x}_k)$ i $\mathbf{b} = \nabla f(\mathbf{x}_k)$)
- Zainicjalizowana dostatecznie blisko minimum zbiega bardzo szybko, ale źle zainicjalizowana może się rozbiec!


Metoda Newtona-Raphsona: przykład

$$f(x_1, x_2) = x_1^2 + 2x_2^2$$



Metoda Newtona-Raphsona: przykład

$$f(x_1, x_2) = x_1^2 + 2x_2^2$$



Metoda Newtona-Raphsona znajduje minimum funkcji kwadratowej:

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

w **jednym kroku**, niezależnie od punktu inicjalizacji!

Metoda Newtona-Raphsona dla funkcji kwadratowej

Rozważmy minimalizację funkcji kwadratowej z dodatnio określoną macierzą \mathbf{A} :

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

Metoda Newtona-Raphsona dla funkcji kwadratowej

Rozważmy minimalizację funkcji kwadratowej z dodatnio określoną macierzą \mathbf{A} :

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

$$\nabla f(\mathbf{x}) = 2\mathbf{A}\mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}, \quad (\nabla^2 f(\mathbf{x}))^{-1} = \frac{1}{2}\mathbf{A}^{-1}$$

Metoda Newtona-Raphsona dla funkcji kwadratowej

Rozważmy minimalizację funkcji kwadratowej z dodatnio określoną macierzą \mathbf{A} :

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

$$\nabla f(\mathbf{x}) = 2\mathbf{A}\mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}, \quad (\nabla^2 f(\mathbf{x}))^{-1} = \frac{1}{2}\mathbf{A}^{-1}$$

Rozpoczynamy od dowolnego punktu \mathbf{x}_1 i wybieramy punkt \mathbf{x}_2 jako:

$$\mathbf{x}_2 = \mathbf{x}_1 - (\nabla^2 f(\mathbf{x}_1))^{-1} \nabla f(\mathbf{x}_1)$$

Metoda Newtona-Raphsona dla funkcji kwadratowej

Rozważmy minimalizację funkcji kwadratowej z dodatnio określoną macierzą \mathbf{A} :

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

$$\nabla f(\mathbf{x}) = 2\mathbf{A}\mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}, \quad (\nabla^2 f(\mathbf{x}))^{-1} = \frac{1}{2}\mathbf{A}^{-1}$$

Rozpoczynamy od dowolnego punktu \mathbf{x}_1 i wybieramy punkt \mathbf{x}_2 jako:

$$\mathbf{x}_2 = \mathbf{x}_1 - \frac{1}{2}\mathbf{A}^{-1}(2\mathbf{A}\mathbf{x}_1 + \mathbf{b})$$

Metoda Newtona-Raphsona dla funkcji kwadratowej

Rozważmy minimalizację funkcji kwadratowej z dodatnio określoną macierzą \mathbf{A} :

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

$$\nabla f(\mathbf{x}) = 2\mathbf{A}\mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}, \quad (\nabla^2 f(\mathbf{x}))^{-1} = \frac{1}{2}\mathbf{A}^{-1}$$

Rozpoczynamy od dowolnego punktu \mathbf{x}_1 i wybieramy punkt \mathbf{x}_2 jako:

$$\mathbf{x}_2 = \mathbf{x}_1 - \underbrace{\mathbf{A}^{-1}\mathbf{A}}_I \mathbf{x}_1 - \frac{1}{2}\mathbf{A}^{-1}\mathbf{b}$$

Metoda Newtona-Raphsona dla funkcji kwadratowej

Rozważmy minimalizację funkcji kwadratowej z dodatnio określoną macierzą \mathbf{A} :

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

$$\nabla f(\mathbf{x}) = 2\mathbf{A}\mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}, \quad (\nabla^2 f(\mathbf{x}))^{-1} = \frac{1}{2}\mathbf{A}^{-1}$$

Rozpoczynamy od dowolnego punktu \mathbf{x}_1 i wybieramy punkt \mathbf{x}_2 jako:

$$\mathbf{x}_2 = \mathbf{x}_1 - \frac{1}{2}\mathbf{A}^{-1}\mathbf{b}$$

Metoda Newtona-Raphsona dla funkcji kwadratowej

Rozważmy minimalizację funkcji kwadratowej z dodatnio określoną macierzą \mathbf{A} :

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

$$\nabla f(\mathbf{x}) = 2\mathbf{A}\mathbf{x} + \mathbf{b}, \quad \nabla^2 f(\mathbf{x}) = 2\mathbf{A}, \quad (\nabla^2 f(\mathbf{x}))^{-1} = \frac{1}{2}\mathbf{A}^{-1}$$


Rozpoczynamy od dowolnego punktu \mathbf{x}_1 i wybieramy punkt \mathbf{x}_2 jako:

$$\mathbf{x}_2 = -\frac{1}{2}\mathbf{A}^{-1}\mathbf{b}$$

Ale jest to punkt minimum \mathbf{x}^* funkcji kwadratowej!


Metoda Newtona-Raphsona: przykład

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$



Metoda Newtona-Raphsona: przykład

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$



Metoda Newtona-Raphsona jako metoda spadkowa

Rozpocznij od punktu \mathbf{x}_1 i powtarzaj dla $k = 1, 2, \dots$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{v}_k, \quad \mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$

Z założenia $\nabla^2 f(\mathbf{x}_k)$ jest dodatnio określona, czyli ma wszystkie wartości własne dodatnie

Metoda Newtona-Raphsona jako metoda spadkowa

Rozpocznij od punktu \mathbf{x}_1 i powtarzaj dla $k = 1, 2, \dots$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{v}_k, \quad \mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$

Z założenia $\nabla^2 f(\mathbf{x}_k)$ jest dodatnio określona, czyli ma wszystkie wartości własne dodatnie

Wtedy $(\nabla^2 f(\mathbf{x}_k))^{-1}$ jest też dodatnio określona, gdyż wartości własne \mathbf{A}^{-1} są odwrotnościami wartości własnych \mathbf{A}

Metoda Newtona-Raphsona jako metoda spadkowa

Rozpocznij od punktu \mathbf{x}_1 i powtarzaj dla $k = 1, 2, \dots$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{v}_k, \quad \mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$

Z założenia $\nabla^2 f(\mathbf{x}_k)$ jest dodatnio określona, czyli ma wszystkie wartości własne dodatnie

Wtedy $(\nabla^2 f(\mathbf{x}_k))^{-1}$ jest też dodatnio określona, gdyż wartości własne \mathbf{A}^{-1} są odwrotnościami wartości własnych \mathbf{A}

Czyli $\mathbf{x}^\top (\nabla^2 f(\mathbf{x}_k))^{-1} \mathbf{x} > 0$ dla dowolnego niezerowego \mathbf{x}

Metoda Newtona-Raphsona jako metoda spadkowa

Rozpocznij od punktu \mathbf{x}_1 i powtarzaj dla $k = 1, 2, \dots$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{v}_k, \quad \mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$

Z założenia $\nabla^2 f(\mathbf{x}_k)$ jest dodatnio określona, czyli ma wszystkie wartości własne dodatnie

Wtedy $(\nabla^2 f(\mathbf{x}_k))^{-1}$ jest też dodatnio określona, gdyż wartości własne \mathbf{A}^{-1} są odwrotnościami wartości własnych \mathbf{A}

Czyli $\mathbf{x}^\top (\nabla^2 f(\mathbf{x}_k))^{-1} \mathbf{x} > 0$ dla dowolnego niezerowego \mathbf{x}

Wniosek: $\mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$ jest **kierunkiem poprawy**

$$\nabla f(\mathbf{x}_k)^\top \mathbf{v}_k = -\nabla f(\mathbf{x}_k) (\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k) < 0$$

Metoda Newtona-Raphsona jako metoda spadkowa

Rozpocznij od punktu \mathbf{x}_1 i powtarzaj dla $k = 1, 2, \dots$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{v}_k, \quad \mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$$

Z założenia $\nabla^2 f(\mathbf{x}_k)$ jest dodatnio określona, czyli ma wszystkie wartości własne dodatnie

Wtedy $(\nabla^2 f(\mathbf{x}_k))^{-1}$ jest też dodatnio określona, gdyż wartości własne \mathbf{A}^{-1} są odwrotnościami wartości własnych \mathbf{A}

Czyli $\mathbf{x}^\top (\nabla^2 f(\mathbf{x}_k))^{-1} \mathbf{x} > 0$ dla dowolnego niezerowego \mathbf{x}

Wniosek: $\mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$ jest **kierunkiem poprawy**

$$\nabla f(\mathbf{x}_k)^\top \mathbf{v}_k = -\nabla f(\mathbf{x}_k) (\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k) < 0$$

Uwaga: Długość kroku α_k jest **stała** i równa 1

Zbieżność metody Newtona-Raphsona

Jeśli funkcja $f(x)$ jest trzykrotnie różniczkowalna w sposób ciągły, algorytm Newtona zainicjalizowany **odpowiednio blisko** minimum lokalnego x^* z dodatnio określonym hesjanem $\nabla^2 f(x^*)$ zbiega z **kwadratowym** rzędem zbieżności

Dowód koncepcyjnie bardzo podobny jak w przypadku jednowymiarowym, ale skomplikowany przez wektorowo-macierzowe przybliżenie Taylora

Zbieżność metody Newtona-Raphsona

Jeśli funkcja $f(x)$ jest trzykrotnie różniczkowalna w sposób ciągły, algorytm Newtona zainicjalizowany **odpowiednio blisko** minimum lokalnego x^* z dodatnio określonym hesjanem $\nabla^2 f(x^*)$ zbiega z **kwadratowym** rzędem zbieżności

Dowód koncepcyjnie bardzo podobny jak w przypadku jednowymiarowym, ale skomplikowany przez wektorowo-macierzowe przybliżenie Taylora

Źle zainicjalizowana metoda Newtona-Raphsona może się nawet rozbiec!

Z tego powodu stosuje się **modyfikacje** metody, które mają zapobiec problemom ze zbieżnością

Modyfikacje metody Newtona-Raphsona

Zmienna długość kroku (*damped Newton-Raphson*)

Metoda Newtona-Raphsona (oryginalna):

Rozpocznij od punktu \mathbf{x}_1 i powtarzaj dla $k = 1, 2, \dots$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k), \quad \alpha_k = 1$$

Metoda nie gwarantuje spadku wartości funkcji $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$!

Zmienna długość kroku (*damped Newton-Raphson*)

Metoda Newtona-Raphsona (oryginalna):

Rozpocznij od punktu \mathbf{x}_1 i powtarzaj dla $k = 1, 2, \dots$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k), \quad \alpha_k = 1$$

Metoda nie gwarantuje spadku wartości funkcji $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$!


Jeśli hesjan $\nabla^2 f(\mathbf{x}_k)$ jest **dodatnio określony**, \mathbf{v}_k jest **kierunkiem poprawy** i możemy zmodyfikować metodę dobierając α_k :

- optymalnie: $\alpha_k = \operatorname{argmin}_{\alpha \geq 0} f(\mathbf{x}_k + \alpha \mathbf{v}_k)$,
- za pomocą algorytmu *backtracking*,

co zagwarantuje nam $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$


Metoda Newtona Raphsona z optymalnym doborem kroku

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$




Dla porównania: klasyczna metoda Newtona Raphsona

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$




Metoda Newtona Raphsona z optymalnym doborem kroku

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$



Metoda Newtona Raphsona z optymalnym doбором kroku

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$



Dlaczego algorytm „utknął” w x_2 ?

Analiza


$$\mathbf{x}_2 = (0.99, 1.46)$$

$$\nabla f(\mathbf{x}_2) = (0.77, 2.4)$$

$$\nabla^2 f(\mathbf{x}_2) = \begin{bmatrix} 16.8 & 9.9 \\ 9.9 & 5.0 \end{bmatrix}$$

$$\begin{aligned} \mathbf{v}_2 &= -(\nabla^2 f(\mathbf{x}_2))^{-1} \nabla f(\mathbf{x}_2) \\ &= (-1.42, -2.33) \end{aligned}$$

$$\nabla f(\mathbf{x}_2)^\top \mathbf{v}_2 = 4.5 > 0$$



Analiza

$$\mathbf{x}_2 = (0.99, 1.46)$$


$$\nabla f(\mathbf{x}_2) = (0.77, 2.4)$$

$$\nabla^2 f(\mathbf{x}_2) = \begin{bmatrix} 16.8 & 9.9 \\ 9.9 & 5.0 \end{bmatrix}$$

$$\begin{aligned} \mathbf{v}_2 &= -(\nabla^2 f(\mathbf{x}_2))^{-1} \nabla f(\mathbf{x}_2) \\ &= (-1.42, -2.33) \end{aligned}$$

$$\nabla f(\mathbf{x}_2)^\top \mathbf{v}_2 = 4.5 > 0$$

Kierunek \mathbf{v}_2 **nie jest kierunkiem poprawy**



Analiza


$$\mathbf{x}_2 = (0.99, 1.46)$$

$$\nabla f(\mathbf{x}_2) = (0.77, 2.4)$$

$$\nabla^2 f(\mathbf{x}_2) = \begin{bmatrix} 16.8 & 9.9 \\ 9.9 & 5.0 \end{bmatrix}$$

$$\begin{aligned} \mathbf{v}_2 &= -(\nabla^2 f(\mathbf{x}_2))^{-1} \nabla f(\mathbf{x}_2) \\ &= (-1.42, -2.33) \end{aligned}$$

$$\nabla f(\mathbf{x}_2)^\top \mathbf{v}_2 = 4.5 > 0$$



Kierunek \mathbf{v}_2 **nie jest kierunkiem poprawy**

Wartości własne hesjanu: $(22.4, -0.62) \implies$ **nie jest dodatnio określony**

Optymalna długość kroku to $\alpha_2 = 0$, ponieważ nie możemy polepszyć funkcji celu wzdłuż kierunku \mathbf{v}_2

Analiza


$$\mathbf{x}_2 = (0.99, 1.46)$$

$$\nabla f(\mathbf{x}_2) = (0.77, 2.4)$$

$$\nabla^2 f(\mathbf{x}_2) = \begin{bmatrix} 16.8 & 9.9 \\ 9.9 & 5.0 \end{bmatrix}$$

$$\begin{aligned} \mathbf{v}_2 &= -(\nabla^2 f(\mathbf{x}_2))^{-1} \nabla f(\mathbf{x}_2) \\ &= (-1.42, -2.33) \end{aligned}$$

$$\nabla f(\mathbf{x}_2)^\top \mathbf{v}_2 = 4.5 > 0$$



Kierunek \mathbf{v}_2 **nie jest kierunkiem poprawy**

Wartości własne hesjanu: $(22.4, -0.62) \implies$ **nie jest dodatnio określony**

Optymalna długość kroku to $\alpha_2 = 0$, ponieważ nie możemy polepszyć funkcji celu wzdłuż kierunku \mathbf{v}_2

Wniosek: Optymalizacja długości kroku może zawieść, jeśli hesjan nie jest dodatnio określony!

Wartości własne hesjanu

Dotychczas zakładaliśmy, że hesjan $\nabla^2 f(\mathbf{x}_k)$ jest **dodatnio określony**, czyli ma wszystkie wartości własne **dodatnie** i stąd jest **odwracalny**.

W praktyce:

- Nawet dla funkcji wypukłych, hesjan może być tylko dodatnio półokreślony i jedna lub więcej wartości własnych może być równa zero; wtedy odwrotność $(\nabla^2 f(\mathbf{x}_k))^{-1}$ nie istnieje
- Dla funkcji **niewypukłych**, wartości własne mogą być ujemne, a wtedy kierunek $\mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$ nie musi być już kierunkiem poprawy!

Przykład

Rozważmy minimalizację funkcji postaci:

$$f(\mathbf{x}) = x_1^4 + x_2^2 - x_1 - x_2$$

Przykład

Rozważmy minimalizację funkcji postaci:

$$f(\mathbf{x}) = x_1^4 + x_2^2 - x_1 - x_2$$

$$\frac{\partial f}{\partial x_1} = 4x_1^3 - 1, \quad \frac{\partial f}{\partial x_2} = 2x_2 - 1$$

Przykład

Rozważmy minimalizację funkcji postaci:

$$f(\mathbf{x}) = x_1^4 + x_2^2 - x_1 - x_2$$

$$\frac{\partial f}{\partial x_1} = 4x_1^3 - 1, \quad \frac{\partial f}{\partial x_2} = 2x_2 - 1$$

$$\frac{\partial^2 f}{\partial x_1^2} = 12x_1^2, \quad \frac{\partial^2 f}{\partial x_2^2} = 2, \quad \frac{\partial^2 f}{\partial x_1 \partial x_2} = 0, \quad \nabla^2 f(\mathbf{x}) = \begin{bmatrix} 12x_1^2 & 0 \\ 0 & 2 \end{bmatrix}$$

Przykład

Rozważmy minimalizację funkcji postaci:

$$f(\mathbf{x}) = x_1^4 + x_2^2 - x_1 - x_2$$

$$\frac{\partial f}{\partial x_1} = 4x_1^3 - 1, \quad \frac{\partial f}{\partial x_2} = 2x_2 - 1$$

$$\frac{\partial^2 f}{\partial x_1^2} = 12x_1^2, \quad \frac{\partial^2 f}{\partial x_2^2} = 2, \quad \frac{\partial^2 f}{\partial x_1 \partial x_2} = 0, \quad \nabla^2 f(\mathbf{x}) = \begin{bmatrix} 12x_1^2 & 0 \\ 0 & 2 \end{bmatrix}$$

Ponieważ hesjan w \mathbf{x} ma wartości własne $(12x_1^2, 2)$, **nieujemne** dla dowolnego x_1 , jest macierzą **dodatnio półokreśloną dla każdego \mathbf{x}** , a więc $f(\mathbf{x})$ jest funkcją **wypukłą**

Przykład

Rozważmy minimalizację funkcji postaci:

$$f(\mathbf{x}) = x_1^4 + x_2^2 - x_1 - x_2$$

$$\frac{\partial f}{\partial x_1} = 4x_1^3 - 1, \quad \frac{\partial f}{\partial x_2} = 2x_2 - 1$$

$$\frac{\partial^2 f}{\partial x_1^2} = 12x_1^2, \quad \frac{\partial^2 f}{\partial x_2^2} = 2, \quad \frac{\partial^2 f}{\partial x_1 \partial x_2} = 0, \quad \nabla^2 f(\mathbf{x}) = \begin{bmatrix} 12x_1^2 & 0 \\ 0 & 2 \end{bmatrix}$$

Ponieważ hesjan w \mathbf{x} ma wartości własne $(12x_1^2, 2)$, **nieujemne** dla dowolnego x_1 , jest macierzą **dodatnio półokreśloną dla każdego \mathbf{x}** , a więc $f(\mathbf{x})$ jest funkcją **wypukłą**

Rozpoczynając metodę Newtona-Raphsona od $\mathbf{x}_1 = \mathbf{0}$ mamy hesjan:

$$\nabla^2 f(\mathbf{x}_1) = \begin{bmatrix} 0 & 0 \\ 0 & 2 \end{bmatrix},$$


o wartościach własnych $(0, 2)$, nie dający się odwrócić!

Przykład

Rozważmy minimalizację funkcji:

$$f(\mathbf{x}) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$

$$\nabla^2 f(\mathbf{x}) = \begin{bmatrix} 30x_1^2 - 10x_2 + 2 & -10x_1 \\ -10x_1 & 5 \end{bmatrix}$$




Przykład

Rozważmy minimalizację funkcji:

$$f(\mathbf{x}) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$

$$\nabla^2 f(\mathbf{x}) = \begin{bmatrix} 30x_1^2 - 10x_2 + 2 & -10x_1 \\ -10x_1 & 5 \end{bmatrix}$$



Rozpoczynając metodę Newtona-Raphsona od $\mathbf{x}_1 = (0, 0.3)$ dostajemy:


$$\nabla^2 f(\mathbf{x}_1) = \begin{bmatrix} -1 & 0 \\ 0 & 5 \end{bmatrix} \quad \text{o wartościach własnych } (-1, 5)$$

Przykład

Rozważmy minimalizację funkcji:

$$f(\mathbf{x}) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$

$$\nabla^2 f(\mathbf{x}) = \begin{bmatrix} 30x_1^2 - 10x_2 + 2 & -10x_1 \\ -10x_1 & 5 \end{bmatrix}$$



Rozpoczynając metodę Newtona-Raphsona od $\mathbf{x}_1 = (0, 0.3)$ dostajemy:


$$\nabla^2 f(\mathbf{x}_1) = \begin{bmatrix} -1 & 0 \\ 0 & 5 \end{bmatrix} \quad \text{o wartościach własnych } (-1, 5)$$

Wielomian Taylora w \mathbf{x}_1 nie jest funkcją wypukłą, a kolejny punkt \mathbf{x}_2 jest jego **punktem siodłowym**, a nie minimum!

Kierunek $-(\nabla^2 f(\mathbf{x}_1))^{-1} \nabla f(\mathbf{x}_1)$ nie jest kierunkiem poprawy!

Przykład

$$f(\mathbf{x}) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2, \quad \mathbf{x}_1 = (0, 0.3)$$



Przesunięcie wartości własnych

Fakt: jeśli symetryczna macierz A ma wartości własne $(\lambda_1, \dots, \lambda_n)$ to macierz $A + \epsilon I$ ma wartości własne $(\lambda_1 + \epsilon, \dots, \lambda_n + \epsilon)$

Przesunięcie wartości własnych

Fakt: jeśli symetryczna macierz A ma wartości własne $(\lambda_1, \dots, \lambda_n)$ to macierz $A + \epsilon I$ ma wartości własne $(\lambda_1 + \epsilon, \dots, \lambda_n + \epsilon)$

Dowód: Jeśli v_k jest wektorem własnym A z wartością własną λ_k :

$$Av_k = \lambda_k v_k,$$

to v_k jest też wektorem własnym $A + \epsilon I$ z wartością własną $\lambda_k + \epsilon$:

$$(A + \epsilon I)v_k = Av_k + \epsilon Iv_k = \lambda_k v_k + \epsilon v_k = (\lambda_k + \epsilon)v_k$$

Przesunięcie wartości własnych

Fakt: jeśli symetryczna macierz A ma wartości własne $(\lambda_1, \dots, \lambda_n)$ to macierz $A + \epsilon I$ ma wartości własne $(\lambda_1 + \epsilon, \dots, \lambda_n + \epsilon)$

Dowód: Jeśli v_k jest wektorem własnym A z wartością własną λ_k :

$$Av_k = \lambda_k v_k,$$


to v_k jest też wektorem własnym $A + \epsilon I$ z wartością własną $\lambda_k + \epsilon$:

$$(A + \epsilon I)v_k = Av_k + \epsilon Iv_k = \lambda_k v_k + \epsilon v_k = (\lambda_k + \epsilon)v_k$$

Wniosek: Przy odpowiednim doborze ϵ , możemy zagwarantować, że wszystkie wartości własne macierzy $A + \epsilon I$ będą **dodatnie** (tzn. macierz będzie **dodatnio określona**)


Przykład

$$f(\mathbf{x}) = 3x_1^2 - 8x_1x_2 + 2x_2^2, \quad \mathbf{x} = (x_1, x_2)$$




Przykład

$$f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x}, \quad \mathbf{A} = \begin{bmatrix} 3 & -4 \\ -4 & 2 \end{bmatrix}, \quad \lambda_1 = 6.53, \lambda_2 = -1.53$$




Przykład

$$f(\mathbf{x}) = \mathbf{x}^\top (\mathbf{A} + \mathbf{I})\mathbf{x}, \quad \mathbf{A} + \mathbf{I} = \begin{bmatrix} 4 & -4 \\ -4 & 3 \end{bmatrix}, \quad \lambda_1 = 7.53, \lambda_2 = -0.53$$



Przykład

$$f(\mathbf{x}) = \mathbf{x}^\top (\mathbf{A} + 2\mathbf{I})\mathbf{x}, \quad \mathbf{A} + 2\mathbf{I} = \begin{bmatrix} 5 & -4 \\ -4 & 4 \end{bmatrix}, \quad \lambda_1 = 8.53, \lambda_2 = 0.47$$



Metoda Levenberga-Marquardta

W każdej iteracji $k = 1, 2, \dots$ dodajemy do hesjanu macierz $\epsilon_k \mathbf{I}$ aby zapewnić jego dodatnią określoność:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k) + \epsilon_k \mathbf{I})^{-1} \nabla f(\mathbf{x}_k)$$

Metoda Levenberga-Marquardta

W każdej iteracji $k = 1, 2, \dots$ dodajemy do hesjanu macierz $\epsilon_k \mathbf{I}$ aby zapewnić jego dodatnią określoność:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k) + \epsilon_k \mathbf{I})^{-1} \nabla f(\mathbf{x}_k)$$

Dobór współczynnika ϵ_k :

- Dla funkcji **wypukłych** wystarczy stała, niewielka wartość ϵ , np. $\epsilon = 10^{-5}$. Długość kroku można dobrać jako $\alpha_k = 1$ (jak w metodzie Newtona-Raphsona) lub optymalizować
- Dla funkcji **niewypukłych**, w każdej iteracji trzeba wyznaczyć wartości własne hesjanu i wybrać ϵ_k tak, aby wszystkie przesunąć powyżej zera

W tym przypadku zaleca się zawsze używanie zmiennej (optymalizowanej) długości kroku α_k !

Metoda Levenberga-Marquardta: interpretacja

Rozważmy ogólną metodę spadkową postaci $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k$

Metoda Levenberga-Marquardta: interpretacja

Rozważmy ogólną metodę spadkową postaci $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k$

W metodzie Newtona-Rapshona $\mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$ możemy przedstawić jako rozwiązanie problemu minimalizacji funkcji kwadratowej:

$$g(\mathbf{v}) = \nabla f(\mathbf{x}_k)^\top \mathbf{v} + \frac{1}{2} \mathbf{v}^\top \nabla^2 f(\mathbf{x}_k) \mathbf{v}$$

Metoda Levenberga-Marquardta: interpretacja

Minimum funkcji kwadratowej $\mathbf{x}^\top \mathbf{b} + \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x}$
to $\mathbf{x}^* = -\mathbf{A}^{-1} \mathbf{b}$

W metodzie Newtona-Raphsona $\mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$ możemy przedstawić jako rozwiązanie problemu minimalizacji funkcji kwadratowej:

$$g(\mathbf{v}) = \nabla f(\mathbf{x}_k)^\top \mathbf{v} + \frac{1}{2} \mathbf{v}^\top \nabla^2 f(\mathbf{x}_k) \mathbf{v}$$

Metoda Levenberga-Marquardta: interpretacja

Rozważmy ogólną metodę spadkową postaci $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k$

W metodzie Newtona-Rapshona $\mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$ możemy przedstawić jako rozwiązanie problemu minimalizacji funkcji kwadratowej:

$$g(\mathbf{v}) = \nabla f(\mathbf{x}_k)^\top \mathbf{v} + \frac{1}{2} \mathbf{v}^\top \nabla^2 f(\mathbf{x}_k) \mathbf{v}$$

W metodzie spadku wzdłuż gradientu $\mathbf{v}_k = -\nabla f(\mathbf{x}_k)$ możemy przedstawić jako rozwiązanie problemu minimalizacji funkcji:

$$g(\mathbf{v}) = \nabla f(\mathbf{x}_k)^\top \mathbf{v} + \frac{1}{2} \mathbf{v}^\top \mathbf{I} \mathbf{v}$$

Metoda Levenberga-Marquardta: interpretacja

Rozważmy ogólną metodę spadkową postaci $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k$

W metodzie Newtona-Raphsona $\mathbf{v}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k)$ możemy przedstawić jako rozwiązanie problemu minimalizacji funkcji kwadratowej:

$$g(\mathbf{v}) = \nabla f(\mathbf{x}_k)^\top \mathbf{v} + \frac{1}{2} \mathbf{v}^\top \nabla^2 f(\mathbf{x}_k) \mathbf{v}$$

W metodzie spadku wzdłuż gradientu $\mathbf{v}_k = -\nabla f(\mathbf{x}_k)$ możemy przedstawić jako rozwiązanie problemu minimalizacji funkcji:

$$g(\mathbf{v}) = \nabla f(\mathbf{x}_k)^\top \mathbf{v} + \frac{1}{2} \mathbf{v}^\top \mathbf{I} \mathbf{v}$$


Metoda Levenberga-Marquardta jest **interpolacją** obu metod dobierając kierunek spadku jako rozwiązanie problemu minimalizacji funkcji:

$$g(\mathbf{v}) = \nabla f(\mathbf{x}_k)^\top \mathbf{v} + \frac{1}{2} \mathbf{v}^\top (\epsilon_k \mathbf{I} + \nabla^2 f(\mathbf{x}_k)) \mathbf{v}$$

Jest to szczególny przypadek **metod quasi-newtonowskich**, gdzie w funkcji kwadratowej dobiera się dowolną macierz dodatnio określoną \mathbf{A}_k


Metoda Newtona Raphsona z optymalnym doborem kroku

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$




M. Levenberga-Marquardta z optymalnym doborem kroku

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$



Dla porównania: klasyczna metoda Newtona Raphsona

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$



Podsumowanie

Dwie modyfikacje:

1. Optymalizacja długości kroku α_k
2. Zapewnienie dodatniej określoności hesjanu (Levenberg-Marquardt)

Podsumowanie

Dwie modyfikacje:

1. Optymalizacja długości kroku α_k
2. Zapewnienie dodatniej określoności hesjanu (Levenberg-Marquardt)

Jeśli stosujemy (1), powinniśmy również stosować (2), inaczej algorytm może się zatrzymać w nieoptymalnym rozwiązaniu!

Podsumowanie

Dwie modyfikacje:

1. Optymalizacja długości kroku α_k
2. Zapewnienie dodatniej określoności hesjanu (Levenberg-Marquardt)

Jeśli stosujemy (1), powinniśmy również stosować (2), inaczej algorytm może się zatrzymać w nieoptymalnym rozwiązaniu!

Optymalizacja długości kroku zapewnia zbieżność algorytmu, ale niekoniecznie polepsza szybkość jego działania, a równocześnie zwiększa złożoność obliczeniową

Podsumowanie

Dwie modyfikacje:

1. Optymalizacja długości kroku α_k
2. Zapewnienie dodatniej określoności hesjanu (Levenberg-Marquardt)

Jeśli stosujemy (1), powinniśmy również stosować (2), inaczej algorytm może się zatrzymać w nieoptymalnym rozwiązaniu!

Optymalizacja długości kroku zapewnia zbieżność algorytmu, ale niekoniecznie polepsza szybkość jego działania, a równocześnie zwiększa złożoność obliczeniową

Dobry kompromis: Stosuj klasyczną metodę Newtona-Raphsona (z $\alpha_k = 1$), ale jeśli jej krok nie daje spadku funkcji celu (lub hesjan jest nieodwracalny), zastosuj krok Levenberga-Marquardta z optymalizacją α_k .

Metoda gradientów sprzężonych

Przypomnienie z algebry: baza przestrzeni wektorowej

Zbiór wektorów $\{v_1, \dots, v_m\}$ nazywamy **liniowo niezależnym**, jeśli żaden wektor z tego zbioru nie da się przedstawić w postaci kombinacji liniowej pozostałych

W przestrzeni \mathbb{R}^n zbiór wektorów liniowo niezależnych może składać się maksymalnie z n wektorów, i zbiór taki nazywamy **bazą przestrzeni wektorowej**

Wniosek: Jeśli $\{v_1, \dots, v_n\}$ jest bazą to **dowolny inny wektor** $x \in \mathbb{R}^n$ musi być kombinacją liniową wektorów z bazy, tzn. dla pewnych współczynników $c_1, \dots, c_n \in \mathbb{R}$

$$\mathbf{x} = \sum_{k=1}^n c_k \mathbf{v}_k$$

Wektory sprzężone

Niech A będzie macierzą **dodatnio określoną**

Zbiór **niezerowych** wektorów $\{v_1, \dots, v_n\}$ nazywamy **sprężonymi** (ze względu na macierz A), jeśli

$$v_i^\top A v_j = 0, \quad \text{dla dowolnych } i \neq j$$

Wektory sprzężone

Niech A będzie macierzą **dodatnio określoną**

Zbiór **niezerowych** wektorów $\{v_1, \dots, v_n\}$ nazywamy **sprężonymi** (ze względu na macierz A), jeśli

$$v_i^\top A v_j = 0, \quad \text{dla dowolnych } i \neq j$$

Fakt: Zbiór wektorów sprzężonych jest **bazą**

Wektory sprzężone

Niech A będzie macierzą **dodatnio określoną**

Zbiór **niezerowych** wektorów $\{v_1, \dots, v_n\}$ nazywamy **sprężonymi** (ze względu na macierz A), jeśli

$$v_i^\top A v_j = 0, \quad \text{dla dowolnych } i \neq j$$

Fakt: Zbiór wektorów sprzężonych jest **bazą**

Dowód: Wystarczy pokazać ich liniową niezależność. Załóżmy przeciwnie, że istnieje wektor v_k liniowo zależny od pozostałych, tzn.

$$v_k = \sum_{i \neq k} \alpha_i v_i$$

Wektory sprzężone

Niech A będzie macierzą **dodatnio określoną**

Zbiór **niezerowych** wektorów $\{v_1, \dots, v_n\}$ nazywamy **sprężonymi** (ze względu na macierz A), jeśli

$$v_i^\top A v_j = 0, \quad \text{dla dowolnych } i \neq j$$

Fakt: Zbiór wektorów sprzężonych jest **bazą**

Dowód: Wystarczy pokazać ich liniową niezależność. Załóżmy przeciwnie, że istnieje wektor v_k liniowo zależny od pozostałych, tzn.

$$v_k = \sum_{i \neq k} \alpha_i v_i$$

Ale oznacza to, że:

$$A v_k = \sum_{i \neq k} \alpha_i A v_i$$

Wektory sprzężone

Niech A będzie macierzą **dodatnio określoną**

Zbiór **niezerowych** wektorów $\{v_1, \dots, v_n\}$ nazywamy **sprężonymi** (ze względu na macierz A), jeśli

$$v_i^\top A v_j = 0, \quad \text{dla dowolnych } i \neq j$$

Fakt: Zbiór wektorów sprzężonych jest **bazą**

Dowód: Wystarczy pokazać ich liniową niezależność. Załóżmy przeciwnie, że istnieje wektor v_k liniowo zależny od pozostałych, tzn.

$$v_k = \sum_{i \neq k} \alpha_i v_i$$

Ale oznacza to, że:

$$v_k^\top A v_k = \sum_{i \neq k} \alpha_i v_k^\top A v_i$$

Wektory sprzężone

Niech A będzie macierzą **dodatnio określoną**

Zbiór **niezerowych** wektorów $\{v_1, \dots, v_n\}$ nazywamy **sprężonymi** (ze względu na macierz A), jeśli

$$v_i^\top A v_j = 0, \quad \text{dla dowolnych } i \neq j$$

Fakt: Zbiór wektorów sprzężonych jest **bazą**

Dowód: Wystarczy pokazać ich liniową niezależność. Załóżmy przeciwnie, że istnieje wektor v_k liniowo zależny od pozostałych, tzn.

$$v_k = \sum_{i \neq k} \alpha_i v_i$$

Ale oznacza to, że:

$$v_k^\top A v_k = \sum_{i \neq k} \alpha_i \underbrace{v_k^\top A v_i}_{=0}$$

Wektory sprzężone

Niech A będzie macierzą **dodatnio określoną**

Zbiór **niezerowych** wektorów $\{v_1, \dots, v_n\}$ nazywamy **sprężonymi** (ze względu na macierz A), jeśli

$$v_i^\top A v_j = 0, \quad \text{dla dowolnych } i \neq j$$

Fakt: Zbiór wektorów sprzężonych jest **bazą**

Dowód: Wystarczy pokazać ich liniową niezależność. Załóżmy przeciwnie, że istnieje wektor v_k liniowo zależny od pozostałych, tzn.

$$v_k = \sum_{i \neq k} \alpha_i v_i$$

Ale oznacza to, że:

$$v_k^\top A v_k = 0$$

co prowadzi do sprzeczności, ponieważ A jest dodatnio określona, a v_k jest niezerowy, więc $v_k^\top A v_k > 0$

Funkcja kwadratowa

Będziemy rozważali minimalizację funkcji kwadratowej:

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Pomijamy współczynnik c (nie wpływa na optymalizację)

Pozostałe współczynniki dobieramy w ten sposób, aby:

$$\nabla f(\mathbf{x}) = \mathbf{0} \quad \iff \quad \mathbf{A} \mathbf{x} = \mathbf{b},$$

tzn. minimum $\mathbf{x}^* = \mathbf{A}^{-1} \mathbf{b}$ jest rozwiązaniem układu równań $\mathbf{A} \mathbf{x}^* = \mathbf{b}$

Metoda gradientów sprzężonych: wprowadzenie

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ będzie zbiorem wektorów sprzężonych ze względu na \mathbf{A}

Będziemy rozważali metodę spadkową minimalizacji funkcji kwadratowej, w której kolejne kierunki poprawy to **kolejne wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn. } \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

natomiast współczynniki α_k wyznaczamy rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$

Metoda gradientów sprzężonych: wprowadzenie

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ będzie zbiorem wektorów sprzężonych ze względu na \mathbf{A}

Będziemy rozważali metodę spadkową minimalizacji funkcji kwadratowej, w której kolejne kierunki poprawy to **kolejne wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn. } \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

natomiast współczynniki α_k wyznaczamy rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$
$$g(\alpha) = \frac{1}{2} (\mathbf{x}_k + \alpha \mathbf{v}_k)^\top \mathbf{A} (\mathbf{x}_k + \alpha \mathbf{v}_k) - (\mathbf{x}_k + \alpha \mathbf{v}_k)^\top \mathbf{b}$$

Metoda gradientów sprzężonych: wprowadzenie

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ będzie zbiorem wektorów sprzężonych ze względu na \mathbf{A}

Będziemy rozważali metodę spadkową minimalizacji funkcji kwadratowej, w której kolejne kierunki poprawy to **kolejne wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn. } \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

natomiast współczynniki α_k wyznaczamy rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$
$$g(\alpha) = \frac{\alpha^2}{2} \mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k + \alpha (\mathbf{v}_k^\top \mathbf{A} \mathbf{x}_k - \mathbf{v}_k^\top \mathbf{b}) + \text{const}$$

Metoda gradientów sprzężonych: wprowadzenie

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ będzie zbiorem wektorów sprzężonych ze względu na \mathbf{A}

Będziemy rozważali metodę spadkową minimalizacji funkcji kwadratowej, w której kolejne kierunki poprawy to **kolejne wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn.} \quad \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

gradient: $\mathbf{A} \mathbf{x}_k - \mathbf{b} = \nabla f(\mathbf{x}_k)$

natomiast α_k oznaczamy przez g_k i rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{arg\,min}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$

$$g(\alpha) = \frac{\alpha^2}{2} \mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k + \alpha \mathbf{v}_k^\top (\mathbf{A} \mathbf{x}_k - \mathbf{b}) + \text{const}$$

Metoda gradientów sprzężonych: wprowadzenie

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ będzie zbiorem wektorów sprzężonych ze względu na \mathbf{A}

Będziemy rozważali metodę spadkową minimalizacji funkcji kwadratowej, w której kolejne kierunki poprawy to **kolejne wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn. } \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

natomiast współczynniki α_k wyznaczamy rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$
$$g(\alpha) = \frac{\alpha^2}{2} \mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k + \alpha \mathbf{v}_k^\top \mathbf{g}_k + \text{const}$$

Metoda gradientów sprzężonych: wprowadzenie

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ będzie zbiorem wektorów sprzężonych ze względu na \mathbf{A}

Będziemy rozważali metodę spadkową minimalizacji funkcji kwadratowej, w której kolejne kierunki poprawy to **kolejne wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn. } \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

natomiast współczynniki α_k wyznaczamy rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$

$$g'(\alpha) = \alpha \mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k + \mathbf{v}_k^\top \mathbf{g}_k$$

Metoda gradientów sprzężonych: wprowadzenie

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ będzie zbiorem wektorów sprzężonych ze względu na \mathbf{A}

Będziemy rozważali metodę spadkową minimalizacji funkcji kwadratowej, w której kolejne kierunki poprawy to **kolejne wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn. } \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

natomiast współczynniki α_k wyznaczamy rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$
$$g'(\alpha) = 0 \iff \alpha \mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k = -\mathbf{v}_k^\top \mathbf{g}_k$$

Metoda gradientów sprzężonych: wprowadzenie

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ będzie zbiorem wektorów sprzężonych ze względu na \mathbf{A}

Będziemy rozważali metodę spadkową minimalizacji funkcji kwadratowej, w której kolejne kierunki poprawy to **kolejne wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn. } \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

natomiast współczynniki α_k wyznaczamy rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$
$$\alpha_k = - \frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Metoda gradientów sprzężonych: wprowadzenie

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ będzie zbiorem wektorów sprzężonych ze względu na \mathbf{A}

Będziemy rozważali metodę spadkową minimalizacji funkcji kwadratowej, w której kolejne kierunki poprawy to **kolejne wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn. } \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

natomiast współczynniki α_k wyznaczamy rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$
$$\alpha_k = - \frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k} = - \frac{\mathbf{v}_k^\top (\mathbf{A} \mathbf{x}_k - \mathbf{b})}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Metoda gradientów sprzężonych: wprowadzenie

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ będzie zbiorem wektorów sprzężonych ze względu na \mathbf{A}

Będziemy rozważali metodę spadkową minimalizacji funkcji kwadratowej, w której kolejne kierunki poprawy to **kolejne wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn.} \quad \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

natomiast współczynniki α_k wyznaczamy rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$
$$\alpha_k = - \frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k} = - \frac{\mathbf{v}_k^\top (\mathbf{A} \mathbf{x}_k - \mathbf{A} \mathbf{x}_1 + \mathbf{A} \mathbf{x}_1 - \mathbf{b})}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Metoda gradientów sprzężonych: wprowadzenie

Ponieważ $\mathbf{x}_k - \mathbf{x}_1 = \sum_{i=1}^{k-1} \alpha_i \mathbf{v}_i$, otrzymujemy dodatnio określona

$$\mathbf{v}_k^\top \mathbf{A}(\mathbf{x}_k - \mathbf{x}_1) = \sum_{i=1}^{k-1} \alpha_i \underbrace{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_i}_{=0} = 0$$

sprzężonych ze względu na \mathbf{A} realizacji funkcji kwadratowej, **wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn.} \quad \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

natomiast współczynniki α_k wyznaczamy rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$
$$\alpha_k = - \frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k} = - \frac{\mathbf{v}_k^\top (\mathbf{A} \mathbf{x}_1 - \mathbf{b}) + \mathbf{v}_k^\top \mathbf{A} (\mathbf{x}_k - \mathbf{x}_1)}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Metoda gradientów sprzężonych: wprowadzenie

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ będzie zbiorem wektorów sprzężonych ze względu na \mathbf{A}

Będziemy rozważali metodę spadkową minimalizacji funkcji kwadratowej, w której kolejne kierunki poprawy to **kolejne wektory sprzężone**, tzn.:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \text{tzn. } \mathbf{x}_{k+1} = \mathbf{x}_1 + \sum_{i=1}^k \alpha_i \mathbf{v}_i,$$

natomiast współczynniki α_k wyznaczamy rozwiązując:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} \underbrace{f(\mathbf{x}_k + \alpha \mathbf{v}_k)}_{g(\alpha)}$$
$$\alpha_k = - \frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k} = \frac{\mathbf{v}_k^\top (\mathbf{b} - \mathbf{A} \mathbf{x}_1)}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Optymalna wartość α_k zależy tylko od punktu startowego \mathbf{x}_1 !

Możemy wyznaczyć α_k niezależnie od pozostałych współczynników i wcześniejszych kroków algorytmu

Funkcja kwadratowa a wektory sprzężone

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ – zbiór wektorów sprzężonych. Ponieważ jest to baza,

$$\mathbf{x}^* - \mathbf{x}_1 = \sum_{i=1}^n \alpha_i \mathbf{v}_i$$

Wyznamy optymalne współczynniki α_k

Funkcja kwadratowa a wektory sprzężone

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ – zbiór wektorów sprzężonych. Ponieważ jest to baza,

$$\mathbf{x}^* - \mathbf{x}_1 = \sum_{i=1}^n \alpha_i \mathbf{v}_i$$

Wyznamy optymalne współczynniki α_k

$$\mathbf{A} \mathbf{x}^* - \mathbf{A} \mathbf{x}_1 = \sum_{i=1}^n \alpha_i \mathbf{A} \mathbf{v}_i$$

Funkcja kwadratowa a wektory sprzężone

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ – zbiór wektorów sprzężonych. Ponieważ jest to baza,

$$\mathbf{x}^* - \mathbf{x}_1 = \sum_{i=1}^n \alpha_i \mathbf{v}_i$$

Wyznamy optymalne współczynniki α_k

$$\mathbf{b} - \mathbf{A} \mathbf{x}_1 = \sum_{i=1}^n \alpha_i \mathbf{A} \mathbf{v}_i$$

Funkcja kwadratowa a wektory sprzężone

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ – zbiór wektorów sprzężonych. Ponieważ jest to baza,

$$\mathbf{x}^* - \mathbf{x}_1 = \sum_{i=1}^n \alpha_i \mathbf{v}_i$$

Wyznamy optymalne współczynniki α_k

$$\mathbf{v}_k^\top (\mathbf{b} - \mathbf{A} \mathbf{x}_1) = \sum_{i=1}^n \alpha_k \underbrace{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_i}_{=0 \text{ dla } k \neq i}$$

Funkcja kwadratowa a wektory sprzężone

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ – zbiór wektorów sprzężonych. Ponieważ jest to baza,

$$\mathbf{x}^* - \mathbf{x}_1 = \sum_{i=1}^n \alpha_i \mathbf{v}_i$$

Wyznamy optymalne współczynniki α_k

$$\mathbf{v}_k^\top (\mathbf{b} - \mathbf{A} \mathbf{x}_1) = \alpha_k \mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k$$

Funkcja kwadratowa a wektory sprzężone

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ – zbiór wektorów sprzężonych. Ponieważ jest to baza,

$$\mathbf{x}^* - \mathbf{x}_1 = \sum_{i=1}^n \alpha_i \mathbf{v}_i$$

Wyznamy optymalne współczynniki α_k

$$\alpha_k = \frac{\mathbf{v}_k^\top (\mathbf{b} - \mathbf{A} \mathbf{x}_1)}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k},$$

Funkcja kwadratowa a wektory sprzężone

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ – zbiór wektorów sprzężonych. Ponieważ jest to baza,

$$\mathbf{x}^* - \mathbf{x}_1 = \sum_{i=1}^n \alpha_i \mathbf{v}_i$$

Wyznamy optymalne współczynniki α_k

$$\alpha_k = \frac{\mathbf{v}_k^\top (\mathbf{b} - \mathbf{A} \mathbf{x}_1)}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k},$$

Ale są to **te same** współczynniki, które dobiera w kolejnych krokach metoda gradientów sprzężonych, tzn.

$$\mathbf{x}_{n+1} = \mathbf{x}_1 + \sum_{k=1}^n \alpha_k \mathbf{v}_k = \mathbf{x}^*$$

Funkcja kwadratowa a wektory sprzężone

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}, \quad \mathbf{A} - \text{dodatnio określona}$$

Niech $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ – zbiór wektorów sprzężonych. Ponieważ jest to baza,

$$\mathbf{x}^* - \mathbf{x}_1 = \sum_{i=1}^n \alpha_i \mathbf{v}_i$$

Wyznamy optymalne współczynniki α_k

$$\alpha_k = \frac{\mathbf{v}_k^\top (\mathbf{b} - \mathbf{A} \mathbf{x}_1)}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k},$$

Ale są to **te same** współczynniki, które dobiera w kolejnych krokach metoda gradientów sprzężonych, tzn.

$$\mathbf{x}_{n+1} = \mathbf{x}_1 + \sum_{k=1}^n \alpha_k \mathbf{v}_k = \mathbf{x}^*$$

Wniosek: Metoda gradientów sprzężonych w każdym kroku optymalnie dobiera współczynnik α_k , a rozwiązanie \mathbf{x}^* otrzymujemy po n iteracjach!

Ortogonalność gradientów

Gradient w danej iteracji $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$ jest **ortogonalny** do wszystkich poprzednich kierunków poprawy $\mathbf{v}_1, \dots, \mathbf{v}_{k-1}$, tzn.

$$\mathbf{v}_i^\top \mathbf{g}_k = 0, \quad \text{dla } i = 1, \dots, k-1$$

Ortogonalność gradientów

Gradient w danej iteracji $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$ jest **ortogonalny** do wszystkich poprzednich kierunków poprawy $\mathbf{v}_1, \dots, \mathbf{v}_{k-1}$, tzn.

$$\mathbf{v}_i^\top \mathbf{g}_k = 0, \quad \text{dla } i = 1, \dots, k-1$$

Dowód:

$$\mathbf{v}_i^\top \mathbf{g}_k = \mathbf{v}_i^\top (\mathbf{A}\mathbf{x}_k - \mathbf{b})$$

Ortogonalność gradientów

Gradient w danej iteracji $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$ jest **ortogonalny** do wszystkich poprzednich kierunków poprawy $\mathbf{v}_1, \dots, \mathbf{v}_{k-1}$, tzn.

$$\mathbf{v}_i^\top \mathbf{g}_k = 0, \quad \text{dla } i = 1, \dots, k-1$$

Dowód:

$$\begin{aligned} \mathbf{v}_i^\top \mathbf{g}_k &= \mathbf{v}_i^\top (\mathbf{A}\mathbf{x}_k - \mathbf{b}) \\ &= \mathbf{v}_i^\top \left(\mathbf{A}\mathbf{x}_1 + \mathbf{A} \left(\sum_{j=1}^{k-1} \alpha_j \mathbf{v}_j \right) - \mathbf{b} \right) \end{aligned}$$

Ortogonalność gradientów

Gradient w danej iteracji $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$ jest **ortogonalny** do wszystkich poprzednich kierunków poprawy $\mathbf{v}_1, \dots, \mathbf{v}_{k-1}$, tzn.

$$\mathbf{v}_i^\top \mathbf{g}_k = 0, \quad \text{dla } i = 1, \dots, k-1$$

Dowód:

$$\begin{aligned} \mathbf{v}_i^\top \mathbf{g}_k &= \mathbf{v}_i^\top (\mathbf{A}\mathbf{x}_k - \mathbf{b}) \\ &= \mathbf{v}_i^\top \left(\mathbf{A}\mathbf{x}_1 + \mathbf{A} \left(\sum_{j=1}^{k-1} \alpha_j \mathbf{v}_j \right) - \mathbf{b} \right) \\ &= \mathbf{v}_i^\top (\mathbf{A}\mathbf{x}_1 - \mathbf{b}) + \sum_{j=1}^{k-1} \alpha_j \underbrace{\mathbf{v}_i^\top \mathbf{A}\mathbf{v}_j}_{=0 \text{ dla } i \neq j} \end{aligned}$$

Ortogonalność gradientów

Gradient w danej iteracji $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$ jest **ortogonalny** do wszystkich poprzednich kierunków poprawy $\mathbf{v}_1, \dots, \mathbf{v}_{k-1}$, tzn.

$$\mathbf{v}_i^\top \mathbf{g}_k = 0, \quad \text{dla } i = 1, \dots, k-1$$

Dowód:

$$\begin{aligned} \mathbf{v}_i^\top \mathbf{g}_k &= \mathbf{v}_i^\top (\mathbf{A}\mathbf{x}_k - \mathbf{b}) \\ &= \mathbf{v}_i^\top \left(\mathbf{A}\mathbf{x}_1 + \mathbf{A} \left(\sum_{j=1}^{k-1} \alpha_j \mathbf{v}_j \right) - \mathbf{b} \right) \\ &= \mathbf{v}_i^\top (\mathbf{A}\mathbf{x}_1 - \mathbf{b}) + \sum_{j=1}^{k-1} \alpha_j \underbrace{\mathbf{v}_i^\top \mathbf{A}\mathbf{v}_j}_{=0 \text{ dla } i \neq j} \\ &= \mathbf{v}_i^\top (\mathbf{A}\mathbf{x}_1 - \mathbf{b}) + \alpha_i \mathbf{v}_i^\top \mathbf{A}\mathbf{v}_i \end{aligned}$$

Ortogonalność gradientów

Gradient w danej iteracji $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$ jest **ortogonalny** do wszystkich poprzednich kierunków poprawy $\mathbf{v}_1, \dots, \mathbf{v}_{k-1}$, tzn.

$$\mathbf{v}_i^\top \mathbf{g}_k = 0, \quad \text{dla } i = 1, \dots, k-1$$

Dowód:

$$\begin{aligned} \mathbf{v}_i^\top \mathbf{g}_k &= \mathbf{v}_i^\top (\mathbf{A}\mathbf{x}_k - \mathbf{b}) \\ &= \mathbf{v}_i^\top \left(\mathbf{A}\mathbf{x}_1 + \mathbf{A} \left(\sum_{j=1}^{k-1} \alpha_j \mathbf{v}_j \right) - \mathbf{b} \right) \\ &= \mathbf{v}_i^\top (\mathbf{A}\mathbf{x}_1 - \mathbf{b}) + \sum_{j=1}^{k-1} \alpha_j \underbrace{\mathbf{v}_i^\top \mathbf{A}\mathbf{v}_j}_{=0 \text{ dla } i \neq j} \\ &= \mathbf{v}_i^\top (\mathbf{A}\mathbf{x}_1 - \mathbf{b}) + \alpha_i \mathbf{v}_i^\top \mathbf{A}\mathbf{v}_i \\ &= \mathbf{v}_i^\top (\mathbf{A}\mathbf{x}_1 - \mathbf{b}) + \frac{\mathbf{v}_i^\top (\mathbf{b} - \mathbf{A}\mathbf{x}_1)}{\mathbf{v}_i^\top \mathbf{A}\mathbf{v}_i} \mathbf{v}_i^\top \mathbf{A}\mathbf{v}_i = 0 \end{aligned}$$

Jak znaleźć kierunki sprzężone?

Jak znaleźć kierunki sprzężone?

- Jako pierwszy kierunek sprzężony możemy obrać negatywny gradient:

$$\mathbf{v}_1 = -\nabla f(\mathbf{x}_1) = -\mathbf{g}_1$$

Jak znaleźć kierunki sprzężone?

- Jako pierwszy kierunek sprzężony możemy obrać negatywny gradient:

$$\mathbf{v}_1 = -\nabla f(\mathbf{x}_1) = -\mathbf{g}_1$$

- Załóżmy, że dobraliśmy już kierunki sprzężone $\mathbf{v}_1, \dots, \mathbf{v}_k$ i chcemy dobrać kierunek \mathbf{v}_{k+1} . Ponownie, sensownym kandydatem jest $-\mathbf{g}_{k+1}$, ale niekoniecznie jest on sprzężony do $\{\mathbf{v}_1, \dots, \mathbf{v}_k\}$

Jak znaleźć kierunki sprzężone?

- Jako pierwszy kierunek sprzężony możemy obrać negatywny gradient:

$$\mathbf{v}_1 = -\nabla f(\mathbf{x}_1) = -\mathbf{g}_1$$

- Załóżmy, że dobraliśmy już kierunki sprzężone $\mathbf{v}_1, \dots, \mathbf{v}_k$ i chcemy dobrać kierunek \mathbf{v}_{k+1} . Ponownie, sensownym kandydatem jest $-\mathbf{g}_{k+1}$, ale niekoniecznie jest on sprzężony do $\{\mathbf{v}_1, \dots, \mathbf{v}_k\}$
- **Pomysł:** dodajmy do gradientu kombinację liniową poprzednich kierunków aby stał się sprzężony, tzn. aby $\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_{k+1} = 0$ dla $j \leq k$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \mathbf{v}_i$$

Jak znaleźć kierunki sprzężone?

- Jako pierwszy kierunek sprzężony możemy obrać negatywny gradient:

$$\mathbf{v}_1 = -\nabla f(\mathbf{x}_1) = -\mathbf{g}_1$$

- Załóżmy, że dobraliśmy już kierunki sprzężone $\mathbf{v}_1, \dots, \mathbf{v}_k$ i chcemy dobrać kierunek \mathbf{v}_{k+1} . Ponownie, sensownym kandydatem jest $-\mathbf{g}_{k+1}$, ale niekoniecznie jest on sprzężony do $\{\mathbf{v}_1, \dots, \mathbf{v}_k\}$
- **Pomysł:** dodajmy do gradientu kombinację liniową poprzednich kierunków aby stał się sprzężony, tzn. aby $\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_{k+1} = 0$ dla $j \leq k$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \mathbf{v}_i$$

- Wyznamy te współczynniki:

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \mathbf{v}_i$$

Jak znaleźć kierunki sprzężone?

- Jako pierwszy kierunek sprzężony możemy obrać negatywny gradient:

$$\mathbf{v}_1 = -\nabla f(\mathbf{x}_1) = -\mathbf{g}_1$$

- Załóżmy, że dobraliśmy już kierunki sprzężone $\mathbf{v}_1, \dots, \mathbf{v}_k$ i chcemy dobrać kierunek \mathbf{v}_{k+1} . Ponownie, sensownym kandydatem jest $-\mathbf{g}_{k+1}$, ale niekoniecznie jest on sprzężony do $\{\mathbf{v}_1, \dots, \mathbf{v}_k\}$
- **Pomysł:** dodajmy do gradientu kombinację liniową poprzednich kierunków aby stał się sprzężony, tzn. aby $\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_{k+1} = 0$ dla $j \leq k$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \mathbf{v}_i$$

- Wyznamy te współczynniki:

$$\mathbf{A} \mathbf{v}_{k+1} = -\mathbf{A} \mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \mathbf{A} \mathbf{v}_i$$

Jak znaleźć kierunki sprzężone?

- Jako pierwszy kierunek sprzężony możemy obrać negatywny gradient:

$$\mathbf{v}_1 = -\nabla f(\mathbf{x}_1) = -\mathbf{g}_1$$

- Załóżmy, że dobraliśmy już kierunki sprzężone $\mathbf{v}_1, \dots, \mathbf{v}_k$ i chcemy dobrać kierunek \mathbf{v}_{k+1} . Ponownie, sensownym kandydatem jest $-\mathbf{g}_{k+1}$, ale niekoniecznie jest on sprzężony do $\{\mathbf{v}_1, \dots, \mathbf{v}_k\}$
- **Pomysł:** dodajmy do gradientu kombinację liniową poprzednich kierunków aby stał się sprzężony, tzn. aby $\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_{k+1} = 0$ dla $j \leq k$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \mathbf{v}_i$$

- Wyznamy te współczynniki:

$$\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_{k+1} = -\mathbf{v}_j^\top \mathbf{A} \mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \underbrace{\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_i}_{=0 \text{ dla } j \neq i}$$

Jak znaleźć kierunki sprzężone?

- Jako pierwszy kierunek sprzężony możemy obrać negatywny gradient:

$$\mathbf{v}_1 = -\nabla f(\mathbf{x}_1) = -\mathbf{g}_1$$

- Załóżmy, że dobraliśmy już kierunki sprzężone $\mathbf{v}_1, \dots, \mathbf{v}_k$ i chcemy dobrać kierunek \mathbf{v}_{k+1} . Ponownie, sensownym kandydatem jest $-\mathbf{g}_{k+1}$, ale niekoniecznie jest on sprzężony do $\{\mathbf{v}_1, \dots, \mathbf{v}_k\}$
- **Pomysł:** dodajmy do gradientu kombinację liniową poprzednich kierunków aby stał się sprzężony, tzn. aby $\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_{k+1} = 0$ dla $j \leq k$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \mathbf{v}_i$$

- Wyznamy te współczynniki:

$$\underbrace{\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_{k+1}}_{=0} = -\mathbf{v}_j^\top \mathbf{A} \mathbf{g}_{k+1} + \beta_{k,j} \mathbf{v}_j^\top \mathbf{A} \mathbf{v}_j$$

Jak znaleźć kierunki sprzężone?

- Jako pierwszy kierunek sprzężony możemy obrać negatywny gradient:

$$\mathbf{v}_1 = -\nabla f(\mathbf{x}_1) = -\mathbf{g}_1$$

- Załóżmy, że dobraliśmy już kierunki sprzężone $\mathbf{v}_1, \dots, \mathbf{v}_k$ i chcemy dobrać kierunek \mathbf{v}_{k+1} . Ponownie, sensownym kandydatem jest $-\mathbf{g}_{k+1}$, ale niekoniecznie jest on sprzężony do $\{\mathbf{v}_1, \dots, \mathbf{v}_k\}$
- **Pomysł:** dodajmy do gradientu kombinację liniową poprzednich kierunków aby stał się sprzężony, tzn. aby $\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_{k+1} = 0$ dla $j \leq k$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \mathbf{v}_i$$

- Wyznamy te współczynniki:

$$\mathbf{v}_j^\top \mathbf{A} \mathbf{g}_{k+1} = \beta_{k,j} \mathbf{v}_j^\top \mathbf{A} \mathbf{v}_j$$

Jak znaleźć kierunki sprzężone?

- Jako pierwszy kierunek sprzężony możemy obrać negatywny gradient:

$$\mathbf{v}_1 = -\nabla f(\mathbf{x}_1) = -\mathbf{g}_1$$

- Załóżmy, że dobraliśmy już kierunki sprzężone $\mathbf{v}_1, \dots, \mathbf{v}_k$ i chcemy dobrać kierunek \mathbf{v}_{k+1} . Ponownie, sensownym kandydatem jest $-\mathbf{g}_{k+1}$, ale niekoniecznie jest on sprzężony do $\{\mathbf{v}_1, \dots, \mathbf{v}_k\}$
- **Pomysł:** dodajmy do gradientu kombinację liniową poprzednich kierunków aby stał się sprzężony, tzn. aby $\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_{k+1} = 0$ dla $j \leq k$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \mathbf{v}_i$$

- Wyznamy te współczynniki:

$$\beta_{k,j} = \frac{\mathbf{v}_j^\top \mathbf{A} \mathbf{g}_{k+1}}{\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_j}$$

Jak znaleźć kierunki sprzężone?

- Jako pierwszy kierunek sprzężony możemy obrać negatywny gradient:

$$\mathbf{v}_1 = -\nabla f(\mathbf{x}_1) = -\mathbf{g}_1$$

- Załóżmy, że dobraliśmy już kierunki sprzężone $\mathbf{v}_1, \dots, \mathbf{v}_k$ i chcemy dobrać kierunek \mathbf{v}_{k+1} . Ponownie, sensownym kandydatem jest $-\mathbf{g}_{k+1}$, ale niekoniecznie jest on sprzężony do $\{\mathbf{v}_1, \dots, \mathbf{v}_k\}$
- **Pomysł:** dodajmy do gradientu kombinację liniową poprzednich kierunków aby stał się sprzężony, tzn. aby $\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_{k+1} = 0$ dla $j \leq k$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \mathbf{v}_i$$

- Wyznamy te współczynniki:

$$\beta_{k,j} = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j}{\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_j}$$

Problem: w danej iteracji trzeba wyznaczyć k współczynników $\beta_{k,1}, \dots, \beta_{k,k}$ i zapamiętać poprzednie kierunki poprawy $\mathbf{v}_1, \dots, \mathbf{v}_k$

Jak znaleźć kierunki sprzężone?

- Jako pierwszy kierunek sprzężony możemy obrać negatywny gradient:

$$\mathbf{v}_1 = -\nabla f(\mathbf{x}_1) = -\mathbf{g}_1$$

- Załóżmy, że dobraliśmy już kierunki sprzężone $\mathbf{v}_1, \dots, \mathbf{v}_k$ i chcemy dobrać kierunek \mathbf{v}_{k+1} . Ponownie, sensownym kandydatem jest $-\mathbf{g}_{k+1}$, ale niekoniecznie jest on sprzężony do $\{\mathbf{v}_1, \dots, \mathbf{v}_k\}$
- **Pomysł:** dodajmy do gradientu kombinację liniową poprzednich kierunków aby stał się sprzężony, tzn. aby $\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_{k+1} = 0$ dla $j \leq k$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \sum_{i=1}^k \beta_{k,i} \mathbf{v}_i$$

- Wyznamy te współczynniki:

$$\beta_{k,j} = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j}{\mathbf{v}_j^\top \mathbf{A} \mathbf{v}_j}$$

Proble **Magia gradientów sprzężonych:**

$\beta_{k,1}, \dots$ Zachodzi $\beta_{k,j} = 0$ dla $j = 1, \dots, k-1$, czyli pozostaje \dots, \mathbf{v}_k tylko **jeden** niezerowy współczynnik $\beta_{k,k}$

Kluczowy punkt konstrukcji algorytmu

Zachodzi $\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j = 0$ dla $j = 1, \dots, k - 1$

Kluczowy punkt konstrukcji algorytmu

Zachodzi $\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j = 0$ dla $j = 1, \dots, k - 1$

Dowód: Najpierw pokazujemy, że gradient \mathbf{g}_{k+1} jest **ortogonalny** do wszystkich poprzednich gradientów, tzn.

$$\mathbf{g}_{k+1}^\top \mathbf{g}_j = 0, \quad \text{dla } j = 1, \dots, k$$

Kluczowy punkt konstrukcji algorytmu

Zachodzi $\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j = 0$ dla $j = 1, \dots, k - 1$

Dowód: Najpierw pokazujemy, że gradient \mathbf{g}_{k+1} jest **ortogonalny** do wszystkich poprzednich gradientów, tzn.

$$\mathbf{g}_{k+1}^\top \mathbf{g}_j = 0, \quad \text{dla } j = 1, \dots, k$$

- Pokazaliśmy już, że gradient jest ortogonalny do poprzednich kierunków poprawy, tzn. dla $j \leq k$ mamy $\mathbf{g}_{k+1}^\top \mathbf{v}_j = 0$

Kluczowy punkt konstrukcji algorytmu

Zachodzi $\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j = 0$ dla $j = 1, \dots, k-1$

Dowód: Najpierw pokazujemy, że gradient \mathbf{g}_{k+1} jest **ortogonalny** do wszystkich poprzednich gradientów, tzn.

$$\mathbf{g}_{k+1}^\top \mathbf{g}_j = 0, \quad \text{dla } j = 1, \dots, k$$

- Pokazaliśmy już, że gradient jest ortogonalny do poprzednich kierunków poprawy, tzn. dla $j \leq k$ mamy $\mathbf{g}_{k+1}^\top \mathbf{v}_j = 0$
- Z zasady doboru kierunku poprawy:

$$\mathbf{v}_j = -\mathbf{g}_j + \sum_{i=1}^{j-1} \beta_{j-1,i} \mathbf{v}_i \quad \implies \quad \mathbf{g}_j = -\mathbf{v}_j + \sum_{i=1}^{j-1} \beta_{j-1,i} \mathbf{v}_i$$

Kluczowy punkt konstrukcji algorytmu

Zachodzi $\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j = 0$ dla $j = 1, \dots, k-1$

Dowód: Najpierw pokazujemy, że gradient \mathbf{g}_{k+1} jest **ortogonalny** do wszystkich poprzednich gradientów, tzn.

$$\mathbf{g}_{k+1}^\top \mathbf{g}_j = 0, \quad \text{dla } j = 1, \dots, k$$

- Pokazaliśmy już, że gradient jest ortogonalny do poprzednich kierunków poprawy, tzn. dla $j \leq k$ mamy $\mathbf{g}_{k+1}^\top \mathbf{v}_j = 0$
- Z zasady doboru kierunku poprawy:

$$\mathbf{v}_j = -\mathbf{g}_j + \sum_{i=1}^{j-1} \beta_{j-1,i} \mathbf{v}_i \quad \Longrightarrow \quad \mathbf{g}_j = -\mathbf{v}_j + \sum_{i=1}^{j-1} \beta_{j-1,i} \mathbf{v}_i$$

- Czyli dla $j \leq k$:

$$\mathbf{g}_{k+1}^\top \mathbf{g}_j = -\underbrace{\mathbf{g}_{k+1}^\top \mathbf{v}_j}_{=0} + \sum_{i=1}^{j-1} \beta_{j-1,i} \underbrace{\mathbf{g}_{k+1}^\top \mathbf{v}_i}_{=0} = 0$$

Kluczowy punkt konstrukcji algorytmu

Zachodzi $\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j = 0$ dla $j = 1, \dots, k - 1$

Dowód: Pokazaliśmy, że gradient \mathbf{g}_{k+1} jest **ortogonalny** do wszystkich poprzednich gradientów, tzn. $\mathbf{g}_{k+1}^\top \mathbf{g}_j = 0$ dla $j = 1, \dots, k$

Kluczowy punkt konstrukcji algorytmu

Zachodzi $\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j = 0$ dla $j = 1, \dots, k-1$

Dowód: Pokazaliśmy, że gradient \mathbf{g}_{k+1} jest **ortogonalny** do wszystkich poprzednich gradientów, tzn. $\mathbf{g}_{k+1}^\top \mathbf{g}_j = 0$ dla $j = 1, \dots, k$

Teraz wykorzystamy fakt, że:

$$\mathbf{g}_{k+1} = \mathbf{A} \mathbf{x}_{k+1} - \mathbf{b} = \mathbf{A}(\mathbf{x}_k + \alpha_k \mathbf{v}_k) - \mathbf{b} = \underbrace{\mathbf{A} \mathbf{x}_k - \mathbf{b}}_{=\mathbf{g}_k} + \mathbf{A} \alpha_k \mathbf{v}_k,$$

Kluczowy punkt konstrukcji algorytmu

Zachodzi $\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j = 0$ dla $j = 1, \dots, k-1$

Dowód: Pokazaliśmy, że gradient \mathbf{g}_{k+1} jest **ortogonalny** do wszystkich poprzednich gradientów, tzn. $\mathbf{g}_{k+1}^\top \mathbf{g}_j = 0$ dla $j = 1, \dots, k$

Teraz wykorzystamy fakt, że:

$$\mathbf{g}_{k+1} = \mathbf{A} \mathbf{x}_{k+1} - \mathbf{b} = \mathbf{A}(\mathbf{x}_k + \alpha_k \mathbf{v}_k) - \mathbf{b} = \underbrace{\mathbf{A} \mathbf{x}_k - \mathbf{b}}_{=\mathbf{g}_k} + \mathbf{A} \alpha_k \mathbf{v}_k,$$

Jeśli $\alpha_k = 0$, to $\mathbf{g}_{k+1} = \mathbf{g}_k$, a ponieważ $\mathbf{g}_{k+1}^\top \mathbf{g}_k = 0$, wnioskujemy, że $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1}) = \mathbf{0}$, czyli **jesteśmy w optimum**.

Kluczowy punkt konstrukcji algorytmu

Zachodzi $\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j = 0$ dla $j = 1, \dots, k-1$

Dowód: Pokazaliśmy, że gradient \mathbf{g}_{k+1} jest **ortogonalny** do wszystkich poprzednich gradientów, tzn. $\mathbf{g}_{k+1}^\top \mathbf{g}_j = 0$ dla $j = 1, \dots, k$

Teraz wykorzystamy fakt, że:

$$\mathbf{g}_{k+1} = \mathbf{A} \mathbf{x}_{k+1} - \mathbf{b} = \mathbf{A}(\mathbf{x}_k + \alpha_k \mathbf{v}_k) - \mathbf{b} = \underbrace{\mathbf{A} \mathbf{x}_k - \mathbf{b}}_{=\mathbf{g}_k} + \mathbf{A} \alpha_k \mathbf{v}_k,$$

Jeśli $\alpha_k = 0$, to $\mathbf{g}_{k+1} = \mathbf{g}_k$, a ponieważ $\mathbf{g}_{k+1}^\top \mathbf{g}_k = 0$, wnioskujemy, że $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1}) = \mathbf{0}$, czyli **jesteśmy w optimum**.

Jeśli $\alpha_k \neq 0$, mamy:

$$\mathbf{A} \mathbf{v}_k = \frac{1}{\alpha_k} (\mathbf{g}_{k+1} - \mathbf{g}_k)$$

Kluczowy punkt konstrukcji algorytmu

Zachodzi $\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j = 0$ dla $j = 1, \dots, k-1$

Dowód: Pokazaliśmy, że gradient \mathbf{g}_{k+1} jest **ortogonalny** do wszystkich poprzednich gradientów, tzn. $\mathbf{g}_{k+1}^\top \mathbf{g}_j = 0$ dla $j = 1, \dots, k$

Teraz wykorzystamy fakt, że:

$$\mathbf{g}_{k+1} = \mathbf{A} \mathbf{x}_{k+1} - \mathbf{b} = \mathbf{A}(\mathbf{x}_k + \alpha_k \mathbf{v}_k) - \mathbf{b} = \underbrace{\mathbf{A} \mathbf{x}_k - \mathbf{b}}_{=\mathbf{g}_k} + \mathbf{A} \alpha_k \mathbf{v}_k,$$

Jeśli $\alpha_k = 0$, to $\mathbf{g}_{k+1} = \mathbf{g}_k$, a ponieważ $\mathbf{g}_{k+1}^\top \mathbf{g}_k = 0$, wnioskujemy, że $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1}) = \mathbf{0}$, czyli **jesteśmy w optimum**.

Jeśli $\alpha_k \neq 0$, mamy:

$$\mathbf{A} \mathbf{v}_k = \frac{1}{\alpha_k} (\mathbf{g}_{k+1} - \mathbf{g}_k)$$

Stąd otrzymujemy dla $j \leq k-1$:

$$\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_j = \frac{1}{\alpha_k} \mathbf{g}_{k+1}^\top (\mathbf{g}_{j+1} - \mathbf{g}_j) = \frac{1}{\alpha_k} \left(\underbrace{\mathbf{g}_{k+1}^\top \mathbf{g}_{j+1}}_{=0} - \underbrace{\mathbf{g}_{k+1}^\top \mathbf{g}_j}_{=0} \right) = 0$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

$$\begin{aligned} \mathbf{v}_1 &= -\mathbf{g}_1 \\ \mathbf{v}_{k+1} &= -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}, \end{aligned}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

$$\begin{aligned} \mathbf{v}_1 &= -\mathbf{g}_1 \\ \mathbf{v}_{k+1} &= -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}, \end{aligned}$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{-\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ n **Zgodnie z $\mathbf{v}_k = -\mathbf{g}_k + \beta_{k-1} \mathbf{v}_{k-1}$**

$$\mathbf{v}_1 = -\mathbf{g}_1$$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k},$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{(\mathbf{g}_k - \beta_{k-1} \mathbf{v}_{k-1})^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone są gradient ortogonalny do poprzednich kierunków:

$$\mathbf{v}_j^\top \mathbf{g}_k = 0 \text{ dla } j < k$$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k},$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k - \beta_{k-1} \mathbf{v}_{k-1}^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

$$\begin{aligned} \mathbf{v}_1 &= -\mathbf{g}_1 \\ \mathbf{v}_{k+1} &= -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}, \end{aligned}$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

$$\begin{aligned} \mathbf{v}_1 &= -\mathbf{g}_1 \\ \mathbf{v}_{k+1} &= -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}, \end{aligned}$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Podobnie, dla współczynnika β_k :

$$\beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

$$\begin{aligned} \mathbf{v}_1 &= -\mathbf{g}_1 \\ \mathbf{v}_{k+1} &= -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}, \end{aligned}$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Podobnie, dla współczynnika β_k :

$$\beta_k = \frac{\mathbf{g}_{k+1}^\top (\alpha_k \mathbf{A} \mathbf{v}_k)}{\mathbf{v}_k^\top (\alpha_k \mathbf{A} \mathbf{v}_k)}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

W dowodzie na poprzednim slajdzie pokazaliśmy, że:

$$\alpha_k \mathbf{A} \mathbf{v}_k = \mathbf{g}_{k+1} - \mathbf{g}_k$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Podobnie, dla współczynnika β_k :

$$\beta_k = \frac{\mathbf{g}_{k+1}^\top (\alpha_k \mathbf{A} \mathbf{v}_k)}{\mathbf{v}_k^\top (\alpha_k \mathbf{A} \mathbf{v}_k)}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

$$\begin{aligned} \mathbf{v}_1 &= -\mathbf{g}_1 \\ \mathbf{v}_{k+1} &= -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}, \end{aligned}$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Podobnie, dla współczynnika β_k :

$$\beta_k = \frac{\mathbf{g}_{k+1}^\top (\mathbf{g}_{k+1} - \mathbf{g}_k)}{\mathbf{v}_k^\top (\mathbf{g}_{k+1} - \mathbf{g}_k)}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

gradient ortogonalny do poprzednich gradientów:

$$\mathbf{g}_{k+1}^\top \mathbf{g}_j = 0 \text{ dla } j \leq k$$

$$\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Podobnie, dla współczynnika β_k :

$$\beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{g}_{k+1} - \mathbf{g}_{k+1}^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{g}_{k+1} - \mathbf{v}_k^\top \mathbf{g}_k}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

$$\mathbf{v}_1 = -\mathbf{g}_1$$

$$\mathbf{v}_j = -\mathbf{g}_j + \mathbf{A} \mathbf{v}_{j-1}$$

gradient ortogonalny do poprzednich kierunków:

$$\mathbf{v}_j^\top \mathbf{g}_{k+1} = 0 \text{ dla } j \leq k$$

Uwaga: Zwy

$$\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Podobnie, dla współczynnika β_k :

$$\beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{g}_{k+1}}{\mathbf{v}_k^\top \mathbf{g}_{k+1} - \mathbf{v}_k^\top \mathbf{g}_k}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

$$\mathbf{v}_1 = -\mathbf{g}_1$$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k$$

Pokazaliśmy przy przekształceniu α_k , że

$$-\mathbf{v}_k^\top \mathbf{g}_k = \mathbf{g}_k^\top \mathbf{g}_k$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Podobnie, dla współczynnika β_k :

$$\beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{g}_{k+1}}{-\mathbf{v}_k^\top \mathbf{g}_k}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

$$\begin{aligned} \mathbf{v}_1 &= -\mathbf{g}_1 \\ \mathbf{v}_{k+1} &= -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}, \end{aligned}$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Podobnie, dla współczynnika β_k :

$$\beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{g}_{k+1}}{\mathbf{g}_k^\top \mathbf{g}_k}$$

Dobór kierunków sprzężonych

Wniosek: W algorytmie gradientów sprzężonych:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k, \quad \alpha_k = -\frac{\mathbf{v}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

kierunki sprzężone $\{\mathbf{v}_1, \dots, \mathbf{v}_n\}$ można otrzymać jako:

$$\begin{aligned} \mathbf{v}_1 &= -\mathbf{g}_1 \\ \mathbf{v}_{k+1} &= -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \beta_k = \frac{\mathbf{g}_{k+1}^\top \mathbf{A} \mathbf{v}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}, \end{aligned}$$

Uwaga: Zwykle stosuje się inną postać współczynników α_k :

$$\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$$

Podobnie, dla współczynnika β_k :

$$\beta_k = \frac{\|\mathbf{g}_{k+1}\|^2}{\|\mathbf{g}_k\|^2}$$

Kierunki sprzężone są kierunkami poprawy

Używając definicji kierunku sprzężonego:

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k$$

mamy:

$$\mathbf{g}_{k+1}^\top \mathbf{v}_{k+1} = -\mathbf{g}_{k+1}^\top \mathbf{g}_{k+1} + \beta_k \mathbf{g}_{k+1}^\top \mathbf{v}_k$$

Kierunki sprzężone są kierunkami poprawy

Używając definicji kierunku sprzężonego:

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k$$

mamy:

$$\mathbf{g}_{k+1}^\top \mathbf{v}_{k+1} = -\mathbf{g}_{k+1}^\top \mathbf{g}_{k+1} + \beta_k \mathbf{g}_{k+1}^\top \mathbf{v}_k$$

gradient ortogonalny do poprzednich kierunków:

$$\mathbf{g}_{k+1}^\top \mathbf{v}_j = 0 \text{ dla } j \leq k$$

Kierunki sprzężone są kierunkami poprawy

Używając definicji kierunku sprzężonego:

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k$$

mamy:

$$\mathbf{g}_{k+1}^\top \mathbf{v}_{k+1} = -\mathbf{g}_{k+1}^\top \mathbf{g}_{k+1}$$

Kierunki sprzężone są kierunkami poprawy

Używając definicji kierunku sprzężonego:

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k$$

mamy:

$$\mathbf{g}_{k+1}^\top \mathbf{v}_{k+1} = -\|\mathbf{g}_{k+1}\|^2 < 0,$$

więc \mathbf{v}_{k+1} jest **kierunkiem poprawy**

Metoda gradientów sprzężonych dla funkcji kwadratowej

Wybierz punkt startowy \mathbf{x}_1

Wyznacz gradient $\mathbf{g}_1 = \nabla f(\mathbf{x}_1)$ oraz początkowy kierunek $\mathbf{v}_1 = -\mathbf{g}_1$

Powtarzaj dla $k = 1, 2, \dots$:


1. Wyznacz optymalną długość kroku $\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$
2. Uaktualnij rozwiązanie: $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k$
3. Wyznacz gradient $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1})$
4. Jeśli $\mathbf{g}_{k+1} = \mathbf{0}$, zatrzymaj algorytm, w przeciwnym przypadku wyznacz nowy kierunek poprawy:

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \beta_k = \frac{\|\mathbf{g}_{k+1}\|^2}{\|\mathbf{g}_k\|^2},$$

Algorytm zatrzymuje się po co najwyżej n krokach zwracając rozwiązanie optymalne \mathbf{x}^*


Metoda gradientów sprzężonych – przykład

$$f(x_1, x_2) = x_1^2 + 2x_2^2$$



Dla porównania: algorytm najszybszego spadku

$$f(x_1, x_2) = x_1^2 + 2x_2^2$$



Metoda gradientów sprzężonych dla dowolnej funkcji

Metodę można łatwo uogólnić na minimalizację dowolnych, niekoniecznie kwadratowych, funkcji, wprowadzając następujące zmiany:

Metoda gradientów sprzężonych dla dowolnej funkcji

Metodę można łatwo uogólnić na minimalizację dowolnych, niekoniecznie kwadratowych, funkcji, wprowadzając następujące zmiany:

- Dla funkcji kwadratowej optymalną długość kroku $\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$ uzyskaliśmy poprzez:

$$\alpha_k = \operatorname{argmin}_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{v}_k)$$

Dla funkcji nie-kwadratowej trzeba rozwiązać powyższy problem jednowymiarowej optymalizacji numerycznie

Metoda gradientów sprzężonych dla dowolnej funkcji

Metodę można łatwo uogólnić na minimalizację dowolnych, niekoniecznie kwadratowych, funkcji, wprowadzając następujące zmiany:

- Dla funkcji kwadratowej optymalną długość kroku $\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$ uzyskaliśmy poprzez:

$$\alpha_k = \operatorname{argmin}_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{v}_k)$$

Dla funkcji nie-kwadratowej trzeba rozwiązać powyższy problem jednowymiarowej optymalizacji numerycznie

- Ponieważ nie mamy już gwarancji, że poszczególne gradienty \mathbf{g}_k są ortogonalne, można zastąpić:

$$\beta_k = \frac{\|\mathbf{g}_{k+1}\|^2}{\|\mathbf{g}_k\|^2} = \frac{\mathbf{g}_{k+1}^\top \mathbf{g}_{k+1}}{\|\mathbf{g}_k\|^2} \Rightarrow \beta_k = \frac{\mathbf{g}_{k+1}^\top (\mathbf{g}_{k+1} - \mathbf{g}_k)}{\|\mathbf{g}_k\|^2}$$

W zależności, którego wzoru używamy, mamy dwie wersje algorytmu: **Fletchera-Reevesa** oraz **Polaka-Ribière'a**.

Metoda gradientów sprzężonych dla dowolnej funkcji

Metodę można łatwo uogólnić na minimalizację dowolnych, niekoniecznie kwadratowych, funkcji, wprowadzając następujące zmiany:

- Dla funkcji kwadratowej optymalną długość kroku $\alpha_k = \frac{\mathbf{g}_k^\top \mathbf{g}_k}{\mathbf{v}_k^\top \mathbf{A} \mathbf{v}_k}$ uzyskaliśmy poprzez:

$$\alpha_k = \operatorname{argmin}_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{v}_k)$$

Dla funkcji nie-kwadratowej trzeba rozwiązać powyższy problem jednowymiarowej optymalizacji numerycznie

- Ponieważ nie mamy już gwarancji, że poszczególne gradienty \mathbf{g}_k są ortogonalne, można zastąpić:

$$\beta_k = \frac{\|\mathbf{g}_{k+1}\|^2}{\|\mathbf{g}_k\|^2} = \frac{\mathbf{g}_{k+1}^\top \mathbf{g}_{k+1}}{\|\mathbf{g}_k\|^2} \Rightarrow \beta_k = \frac{\mathbf{g}_{k+1}^\top (\mathbf{g}_{k+1} - \mathbf{g}_k)}{\|\mathbf{g}_k\|^2}$$

W zależności, którego wzoru używamy, mamy dwie wersje algorytmu: **Fletchera-Reevesa** oraz **Polaka-Ribière'a**.

- Nie mamy gwarancji, że algorytm skończy się po n iteracjach, więc jako warunek stopu przyjmujemy $\|\nabla f(\mathbf{x}_k)\| < \epsilon$ dla ϵ bliskiego zeru.

Metoda gradientów sprzężonych dla dowolnej funkcji (Fletcher-Reevesa i Polaka-Ribière'a)

Wybierz punkt startowy \mathbf{x}_1

Wyznacz gradient $\mathbf{g}_1 = \nabla f(\mathbf{x}_1)$ oraz początkowy kierunek $\mathbf{v}_1 = -\mathbf{g}_1$

Powtarzaj dla $k = 1, 2, \dots$:

1. Wyznacz optymalną długość kroku $\alpha_k = \operatorname{argmin}_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{v}_k)$
2. Uaktualnij rozwiązanie: $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k$
3. Wyznacz gradient $\mathbf{g}_{k+1} = \nabla f(\mathbf{x}_{k+1})$
4. Jeśli $\|\mathbf{g}_{k+1}\| < \epsilon$, zatrzymaj algorytm, w przeciwnym przypadku wyznacz nowy kierunek poprawy:

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k, \quad \text{gdzie:}$$

$$\text{(F-R)} \quad \beta_k = \frac{\|\mathbf{g}_{k+1}\|^2}{\|\mathbf{g}_k\|^2} \quad \text{lub} \quad \text{(P-R)} \quad \beta_k = \frac{\mathbf{g}_{k+1}^\top (\mathbf{g}_{k+1} - \mathbf{g}_k)}{\|\mathbf{g}_k\|^2}$$

Metoda Polaka-Ribière'a preferowana w praktyce

Kierunki sprzężone są kierunkami poprawy

Ponieważ:

$$\alpha_k = \operatorname{argmin}_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{v}_k),$$

Mamy:

$$\left. \frac{df(\mathbf{x}_k + \alpha \mathbf{v}_k)}{d\alpha} \right|_{\alpha=\alpha_k} = 0$$

Kierunki sprzężone są kierunkami poprawy

Ponieważ:

$$\alpha_k = \operatorname{argmin}_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{v}_k),$$

Mamy:

$$\left. \frac{df(\mathbf{x}_k + \alpha \mathbf{v}_k)}{d\alpha} \right|_{\alpha=\alpha_k} = 0$$

Z reguły łańcuchowej:

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

a tym samym:

$$\nabla f(\mathbf{x}_k + \alpha_k \mathbf{v}_k)^\top \mathbf{v}_k = 0$$

Kierunki sprzężone są kierunkami poprawy

Ponieważ:

$$\alpha_k = \operatorname{argmin}_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{v}_k),$$

Mamy:

$$\left. \frac{df(\mathbf{x}_k + \alpha \mathbf{v}_k)}{d\alpha} \right|_{\alpha=\alpha_k} = 0$$

Z reguły łańcuchowej:

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

a tym samym:

$$\nabla f(\mathbf{x}_{k+1})^\top \mathbf{v}_k = 0$$

Kierunki sprzężone są kierunkami poprawy

Ponieważ:

$$\alpha_k = \underset{\alpha}{\operatorname{argmin}} f(\mathbf{x}_k + \alpha \mathbf{v}_k),$$

Mamy:

$$\left. \frac{df(\mathbf{x}_k + \alpha \mathbf{v}_k)}{d\alpha} \right|_{\alpha=\alpha_k} = 0$$

Z reguły łańcuchowej:

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

a tym samym:

$$\mathbf{g}_{k+1}^\top \mathbf{v}_k = 0$$

Kierunki sprzężone są kierunkami poprawy

Ponieważ:

$$\alpha_k = \operatorname{argmin}_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{v}_k),$$

Mamy:

$$\left. \frac{df(\mathbf{x}_k + \alpha \mathbf{v}_k)}{d\alpha} \right|_{\alpha=\alpha_k} = 0$$

Z reguły łańcuchowej:

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

a tym samym:

$$\mathbf{g}_{k+1}^\top \mathbf{v}_k = 0$$

$$\mathbf{v}_{k+1} = -\mathbf{g}_{k+1} + \beta_k \mathbf{v}_k$$

Kierunki sprzężone są kierunkami poprawy

Ponieważ:

$$\alpha_k = \operatorname{argmin}_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{v}_k),$$

Mamy:

$$\left. \frac{df(\mathbf{x}_k + \alpha \mathbf{v}_k)}{d\alpha} \right|_{\alpha=\alpha_k} = 0$$

Z reguły łańcuchowej:

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

a tym samym:

$$\mathbf{g}_{k+1}^\top \mathbf{v}_k = 0$$

$$\mathbf{g}_{k+1}^\top \mathbf{v}_{k+1} = -\mathbf{g}_{k+1}^\top \mathbf{g}_{k+1} + \beta_k \underbrace{\mathbf{g}_{k+1}^\top \mathbf{v}_k}_{=0}$$

Kierunki sprzężone są kierunkami poprawy

Ponieważ:

$$\alpha_k = \operatorname{argmin}_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{v}_k),$$

Mamy:

$$\left. \frac{df(\mathbf{x}_k + \alpha \mathbf{v}_k)}{d\alpha} \right|_{\alpha=\alpha_k} = 0$$

Z reguły łańcuchowej:

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

a tym samym:


$$\mathbf{g}_{k+1}^\top \mathbf{v}_k = 0$$

$$\mathbf{g}_{k+1}^\top \mathbf{v}_{k+1} = -\|\mathbf{g}_{k+1}\|^2 < 0,$$

więc \mathbf{v}_{k+1} jest **kierunkiem poprawy**


Metoda Fletchera-Reevesa – przykład

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$




Metoda Polaka-Ribière'a – przykład

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$




Metoda Fletchera-Reevesa – przykład

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$



Metoda Polaka-Ribière'a – przykład

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$



Dla porównania: algorytm najszybszego spadku

$$f(x_1, x_2) = 2.5(x_1^2 - x_2)^2 + (1 - x_1)^2$$

