

METODA LUI NEWTON ÎN OPTIMIZAREA CONVEXĂ. APLICAȚII ÎN PYTHON

Luminița JARDA

Abstract. Within this paper we present from both a theoretical and an applied point of view Newton's approximation method in the general context of convex optimization.

MSC 2000. 54H25.

Key words. fixed point property, coincidence theorems, commuting operators.

1. FORMULAREA PROBLEMEI I DEFINIREA SOLUIEI

Contextul general în care vom lucra este următorul:

$$\left\{ \begin{array}{l} f : \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\} \\ \text{dom } f \neq \emptyset \\ f \text{ este convex} \\ f \text{ este de clas } C^2 \text{ pe } \text{dom } f \end{array} \right.$$

Funcția f va fi numită **funcție obiectiv**.

Dorim să determinăm soluțiile optime ale următoarei probleme de optimizare:

$$(P) \quad \left\{ \begin{array}{l} \min f(x) \\ x \in \text{dom } f \end{array} \right.$$

Pentru aceasta, vom presupune că problema are soluție, adică există un punct de optim pentru aceasta, pe care îl notăm cu x^* . Un vector x^* din $\text{dom } f$ se numește **soluție pentru problema de optimizare (P)** dacă $f(x^*) \leq f(x)$, $\forall x \in \text{dom } f$. **Valoarea minimă a problemei (P)** o vom nota cu p^* , unde $p^* = f(x^*) = \inf_x f(x)$.

Având în vedere că f este convex și diferentiabil, această problemă ar putea fi rezolvată punând condiția ca gradientul funcției să se anuleze în x^* , ceea ce reprezintă un sistem de n ecuații în n variabile (x_1, \dots, x_n) . Din păcate, doar în câteva cazuri speciale putem determina soluția acestui sistem în mod analitic.

Tocmai de aceea, în această lucrare nu studiem această abordare a soluțiilor optime, ci vom calcula succesiv valorile unui șir de vectori $x^{(0)}, x^{(1)}, \dots \in \text{dom } f$ astfel încât $f(x^{(k)}) \rightarrow p^*$, când $k \rightarrow \infty$. Condiția de oprire a algoritmului este ca $f(x^{(k)}) - p^* \leq \epsilon$, unde ϵ este o toleranță specificată. Cu ajutorul unui astfel de algoritm vom putea obține o aproximație a soluției x^* cu precizia ϵ .

- **Punct de start**

Pentru metoda pe care o vom studia, cerem ca punctul de start, $x^{(0)}$, să satisfacă următoarele condiții: $x^{(0)} \in \text{dom} f = \mathbb{R}^n$, iar mulimea sa de nivel,

$$S = \{x \in \text{dom} f \mid f(x) \leq f(x^{(0)})\},$$

să fie închis. În particular, dacă f este o funcție continuă cu domeniul $\text{dom} f = \mathbb{R}^n$, toate mulțimile ei de nivel sunt închise. Prin urmare, pentru problema de minimizare considerată, cu $\text{dom} f = \mathbb{R}^n$, putem alege orice punct de start $x^{(0)} \in \mathbb{R}^n$.

- **Convexitate tare și consecințe**

În cele ce urmează, presupunem că funcția f este tare convexă pe S , ceea ce înseamnă (pe lângă faptul că f este convex), scris cu ajutorul unor inegalități matriciale, că există $m > 0$ astfel încât

$$(1) \quad mI \preceq \nabla^2 f(x), \forall x \in S.$$

Convexitatea tare are câteva consecințe interesante. Una dintre ele este cea care urmează. Pentru $x, y \in S$, avem că

$$f(y) = f(x) + \nabla f(x)^T(y - x) + \frac{1}{2}(y - x)^T \nabla^2 f(z)(y - x),$$

pentru un z aparținând segmentului $[x, y]$. Din condiția de convexitate tare avem că ultimul termen din membrul drept trebuie să fie cel puțin $\frac{m}{2}\|y - x\|_2^2$, aadar:

$$(2) \quad f(y) \geq f(x) + \nabla f(x)^T(y - x) + \frac{m}{2}\|y - x\|_2^2, \forall x, y \in A.$$

Inegalitatea (2) poate fi folosită pentru a mărui $f(x^*) - p^*$. Membrul drept al inegalității (2) este o funcție convexă quadratică de y (pentru un x fixat). Punând condiția ca gradientul în raport cu y să fie 0, găsim că $\tilde{y} = x - \frac{1}{m}\nabla f(x)$ minimizează membrul drept al inegalității. Avem aadar că

$$\begin{aligned} f(y) &\geq f(x) + \nabla f(x)^T(y - x) + \frac{m}{2}\|y - x\|_2^2 \\ &\geq f(x) + \nabla f(x)^T(\tilde{y} - x) + \frac{m}{2}\|\tilde{y} - x\|_2^2 \\ &= f(x) - \frac{1}{2m}\|\nabla^2 f(x)\|_2^2. \end{aligned}$$

Acest lucru fiind valabil pentru orice $y \in S$, avem că

$$(3) \quad p^* \geq f(x) - \frac{1}{2m}\|\nabla^2 f(x)\|_2^2.$$

Ultima inegalitate ne spune că dacă gradientul într-un punct este suficient de mic, atunci punctul este aproape de optim. Inegalitatea (3) poate fi interpretată și ca o condiție de suboptimalitate, generalizând condiția de optimalitate (ca gradientul să fie nul):

$$(4) \quad \|\nabla f(x)\|_2 \leq (2m\epsilon)^{1/2} \Rightarrow f(x) - p^* \leq \epsilon.$$

Putem, de asemenea, să mărim distanța dintre un punct x și orice punct de optim, x^* . Pentru aceasta, folosim inegalitatea (2) cu $y = x^*$:

$$\begin{aligned} p^* = f(x^*) &\geq f(x) + \nabla f(x)^T(x^* - x) + \frac{m}{2}\|x^* - x\|_2^2 \\ &\geq f(x) - \|\nabla f(x)\|_2\|x^* - x\|_2 + \frac{m}{2}\|x^* - x\|_2^2, \end{aligned}$$

unde pentru a doua inegalitate am folosit inegalitatea Cauchy-Buniakovski-Schwarz.

Din moment ce $p^* \leq f(x)$, trebuie să avem că

$$-\|\nabla f(x)\|_2\|x^* - x\|_2 + \frac{m}{2}\|x^* - x\|_2^2 \leq 0,$$

ceea ce înseamnă că

$$\|x^* - x\|_2 \leq \frac{2}{m}\|\nabla f(x)\|_2.$$

O consecință a acestui rezultat este faptul că **punctul optimal x^* este unic**.

Inegalitatea (2) implică faptul că mulțimile de nivel ale lui S sunt mărginite, deci în particular S este mărginit. De aici rezultă că valoarea proprie maximă a funcției $\nabla^2 f(x)$, care este o funcție continuă pe S , este mărginit superior pe S , ceea ce înseamnă că există o constantă $M > 0$ astfel încât

$$\nabla^2 f(x) \preceq MI, \forall x \in S.$$

Această margine superioară pentru matricea Hessian implică faptul că pentru orice $x, y \in S$, avem că:

$$f(y) \leq f(x) + \nabla f(x)^T(y - x) + \frac{M}{2}\|y - x\|_2^2,$$

relație care este analoagă inegalității (2). Minimizăm fiecare membru după y și obținem:

$$p^* \leq f(x) - \frac{1}{2M}\|\nabla^2 f(x)\|_2^2,$$

echivalența relației (3).

OBSERVAȚIA 1. Este important de precizat că cele două constante specifice convexității tari, m și M , sunt rareori cunoscute în practică. Tocmai de aceea, condiția (4) nu poate fi folosită ca un criteriu practic de oprire. Ea este mai degrabă un criteriu de oprire conceptual, care ne spune că pentru valori suficient de mici ale gradientului ne apropiem din ce în ce mai mult de valoarea optimă. Prin urmare, dacă terminăm algoritmul cu $\|\nabla f(x)\|_2 \leq \eta$, unde η este ales suficient de mic, foarte probabil mai mic decât $(2m\epsilon)^{1/2}$, atunci vom avea $f(x^{(k)}) - p^* \leq \epsilon$ (foarte probabil).

În cele ce urmează vom demonstra convergența metodei lui Newton, stabilind niște margini superioare pentru numărul de iterații necesare până când $f(x^{(k)}) - p^* \leq \epsilon$, aceste valori depinzând de constantele m și M . Rezultatele obținute sunt valoroase conceptual, deoarece ele ne arată că algoritmul converge, chiar dacă marginea superioară a numărului de iterații depinde de constante care sunt necunoscute.

2. SCURT ISTORIC. IDEEA METODEI LUI NEWTON

Metoda lui Newton pornete de la ideea de liniarizare. Mai exact, presupunând că avem o funcție $g: \mathbb{R} \rightarrow \mathbb{R}$ derivabilă, vom încerca să rezolvăm ecuația

$$g(x) = 0.$$

Pornind cu un punct inițial, x_0 , se consideră aproximația liniară a lui g în apropierea lui x_0 :

$$g(x_0 + \Delta x) \approx g(x_0) + g'(x_0)\Delta x.$$

Prin urmare, rezolvând noua ecuație (una liniară), $g(x_0) + g'(x_0)\Delta x = 0$, vom obține o aproximație a soluției ecuației $g(x) = 0$. Considerând acest proces iterativ, avem că

$$x_{k+1} = x_k - g'(x_k)^{-1}g(x_k), \quad k = 0, 1, \dots$$

Newton a venit cu această metodă în 1669. Este important de precizat că Newton a lucrat numai cu funcții polinomiale. Exemplul pe care a demonstrat metoda este următorul:

$$g(x) = x^3 - 2x - 5.$$

O primă aproximație (punctul de start) a fost $x_0 = 2$, ecuația devenind

$$g(2 + \Delta x) = (\Delta x)^3 + 6(\Delta x)^2 + 10\Delta x - 1 = 0.$$

Newton a neglijat termenii superiori și a rezolvat ecuația liniară $10\Delta x - 1 = 0$. Noua aproximație a soluției a fost aadar $x = 2 + 0.1 = 2.1$. Apoi procesul se repetă pornind de la noul punct. Convergența spre rădăcină s-a dovedit a fi una foarte rapidă.

Forma generală ($x_{k+1} = x_k - g'(x_k)^{-1}g(x_k)$) a fost introdusă în 1690 de către J. Raphson, motiv pentru care metoda se mai numește Newton-Raphson. Acesta nu a considerat funcția ca fiind neapărat polinomială, ci o funcție derivabilă.

La progresul acestei metode au contribuit și alți matematicieni celebri. Fourier a demonstrat în 1818 că metoda converge quadratic în apropierea rădăcinii, iar Cauchy (1829, 1847) a extins metoda pentru cazul multidimensional.

Datele istorice au fost preluate din lucrarea lui Polyak [3].

3. METODE DESCENDENTE. CUTARE BACKTRACKING

Pentru a rezolva problema de minimizare (P), ne propunem să determinăm un ir minimizant $x^{(k)}$, unde $k = 0, 1, \dots$, iar

$$x^{(k+1)} = x^{(k)} + t^{(k)}\Delta x^{(k)}.$$

Numărul iterației este dat de k , $\Delta x^{(k)}$ este un vector din \mathbb{R}^n și se numește *pasul* sau *direcția de cutare* (chiar dacă nu e nevoie să aibă norma unitară), iar $t^{(k)} \geq 0$ ($t^{(k)} \in \mathbb{R}$) se numește *mărimea pasului* sau *lungimea pasului* la iterația k ($=0$ când $x^{(k)}$ este punct de optim).

O metodă este **considerată metodă descendentă** dacă

$$f(x^{(k+1)}) < f(x^{(k)}),$$

cu excepția situației în care $x^{(k)}$ este punct de optim. Asta implică faptul că pentru orice k avem că $x^{(k)} \in S$, unde S este mulțimea de nivel inițial, iar în particular $x^{(k)} \in \text{dom} f$. Din convexitate ținem că $\nabla(x^{(k)})^T(y - x^{(k)}) \geq 0$ implică $f(y) \geq f(x^{(k)})$, aadar direcția de cutare pentru o metodă descendentă trebuie să satisfacă

$$\nabla(x^{(k)})^T(y - x^{(k)}) < 0.$$

DEFINIȚIA 1. Numim **direcție descendentă** a funcției f în punctul $x^{(k)}$ un vector care face un unghi optim cu gradientul funcției în acel punct.

ALGORITMUL 1. *Algoritm general pentru o metodă descendentă*

Se dă un punct de start, $x \in \text{dom} f$.

repeat

1. Determină o direcție descendentă, Δx .
2. Alege mărimea pasului, $t > 0$.
3. Modifică: $x = x + t\Delta x$.

until criteriul de oprire este satisfăcut.

În ce privește criteriul de terminare, acesta poate fi verificat imediat după ce este determinată direcția descendentă, Δx .

Cel de-al doilea pas ne spune unde de-a lungul semidreptei $\{x + t\Delta x \mid t \in \mathbb{R}_+\}$ va fi următoarea iterație.

OBSERVAȚIA 2. Mărimea pasului, t , poate fi determinată prin mai multe metode. Una dintre ele este o metodă exactă, analitică, când determinăm $t = \arg\min_{s \geq 0} f(x + s\Delta x)$. Această metodă se aplică atunci când costul (timp, memorie) aplicării ei este scăzut comparativ cu determinarea direcției descendente năse.

• Metoda Backtracking pentru determinarea mrimii pasului

Majoritatea metodelor de determinare a mrimii pasului folosite în practică sunt *inexacte*. Una dintre ele este o metodă de tip *backtracking*. Acest algoritm de determinare a mrimii pasului utilizat în cadrul metodei lui Newton (la care ne vom referi ulterior) funcționează aproape la fel de eficient ca o metodă *exactă* în ceea ce privește convergența metodei. Algoritmul depinde de două constante, α și β , cu $0 < \alpha < 0.5$ și $0 < \beta < 1$.

ALGORITMUL 2. *Backtracking pentru măsura pasului*

Se dă o direcție descendentă Δx pentru f și un punct $x \in \text{dom} f$, $\alpha \in (0, 0.5)$, $\beta \in (0, 1)$.

$t := 1$.

while $f(x + t\Delta x) > f(x) + \alpha t \nabla(x)^T \Delta x$ **do**

$t := \beta t$.

end while

Această metodă se numește *backtracking* deoarece începe cu un pas unitate și îl reduce prin factorul β până la îndeplinirea condiției de oprire, $f(x + t\Delta x) \leq f(x) + \alpha t \nabla(x)^T \Delta x$. Din moment ce Δx este o direcție descendentă, avem că $\nabla(x)^T \Delta x < 0$, aadar pentru un t suficient de mic avem că

$$f(x + t\Delta x) \approx f(x) + t \nabla(x)^T \Delta x < f(x) + \alpha t \nabla(x)^T \Delta x,$$

ceea ce sugerează faptul că algoritmul se termină în cele din urmă.

Condiția de backtracking este ilustrată în Figura 3.1.




Figura. 3.1 – *Cutare backtracking*. Condiția de backtracking este ca f să rămână deasupra liniei punctate $f(x) + \alpha t \nabla f(x)^T \Delta x$, adică $0 \leq t \leq t_0$.

4. METODA LUI NEWTON ÎN OPTIMIZARE. EXEMPLE ÎN \mathbb{R}

Ideea de optimizare presupune existența unei funcții obiectiv, pe care dorim să o minimizăm, să o maximizăm. Din punct de vedere teoretic, a studia un singur caz, pentru care maximizarea unei funcții f este echivalentă cu minimizarea funcției $-f$. Pentru aceasta, pornim de la un punct oarecare al domeniului funcției și realizăm modificări asupra lui după o anumită regulă. Procesul se încheie fie când am ajuns suficient de aproape de valoarea optimă, fie după un număr maxim de iterații prestabilit.

Pentru a nelege cum se aplică metoda lui Newton în optimizare, vom considera o funcție $f : \mathbb{R} \rightarrow \mathbb{R}$ polinomială. Fie ea

$$f(x) = -2x^3 + 8x^2 - 7x + 2.$$

Codul surs pentru implementarea metodei pe acest exemplu este scris în Python. Acest exemplu a fost inspirat din articolul Valentinei Alto [1]. Avem mai jos reprezentarea funcției pe intervalul $[-1, 1.3]$. Am considerat un interval pe care funcția f este convexă.

```
import numpy as np
import matplotlib.pyplot as plt
def f(x):
    return -2*x**3+8*x**2-7*x+2
x = np.linspace(-1, 1.3)
fig, ax = plt.subplots()
ax.plot(x, f(x), label='target')
ax.grid()
plt.legend()
```

Este important de precizat că funcțiile pe care se aplică metoda lui Newton trebuie să fie de două ori derivabile, iar $f''(x) \neq 0$.




Figura. 4.2 – $f(x) = -2x^3 + 8x^2 - 7x + 2$ pe intervalul $[-1, 1.3]$

Pentru a îndeplini condiția cu privire la derivata a doua nenulă, vom considera funcția f restrânsă la intervalul $[-1, 1.3]$ și pe acest interval vom căuta punctul de optim (în acest caz, de minim).

Metoda lui Newton în optimizare pornete de la ideea de a aproxima curba noastră cu funcția lui Taylor de ordin doi. Astfel, vom determina această aproximație pentru un punct inițial $x = x_0$, după care vom calcula minimumul acestei funcții. Punctul în care aproximația quadratică atinge valoarea minimă va fi noul nostru x . Procesul continuu iterativ, obținându-se astfel o secvență care se apropie tot mai mult de punctul de optim, x^* .

Mai înti calculăm aproximația lui Taylor în punctul inițial x_0 :

$$f(x) = f(x_0) + f'(x_0)(x - x_0) + \frac{1}{2}f''(x_0)(x - x_0)^2.$$

Pentru a determina minimumul acestei funcții, punem condiția ca prima ei derivată să fie nulă. Derivata este calculată în raport cu $(x - x_0)$, care reprezintă ce trebuie adăugat la x_0 pentru a obține minimumul:

$$\frac{\partial [f(x_0) + f'(x_0)(x - x_0) + \frac{1}{2}f''(x_0)(x - x_0)^2]}{\partial (x - x_0)} = 0$$

$$f'(x_0) + f''(x_0)(x - x_0) = 0$$

$$x = x_0 - \frac{f'(x_0)}{f''(x_0)}.$$

Procesul fiind unul iterativ, putem generaliza formula:

$$x_{t+1} = x_t - \frac{f'(x_t)}{f''(x_t)}.$$

Pentru funcția dată mai sus va trebui să calculăm aadar prima derivată, a doua derivată, la care adăugăm și aproximația quadratică:

```
def fprime(x):
    return -6*x**2+16*x-7
```

```
def fsecond(x):
    return -12*x + 16
def quadraticapprox(x, x0, f, fprime, fsecond):
    return f(x0)+fprime(x0)*(x-x0)+0.5*fsecond(x0)*(x-x0)**2
```

Acum putem defini metoda lui Newton, folosind o precizie epsilon pentru a ne apropia de optim:

```
def newton(x0, fprime, fsecond, maxiter=100, eps=0.0001):
    x=x0
    for i in range(maxiter):
        xnew=x-(fprime(x)/fsecond(x))
        if np.abs(xnew-x)<eps:
            return xnew
        x = xnew
    return x
```

Realiznd un grafic al funciei noastre, precum i pentru aproximaia quadratic n x^* obinut prin metoda lui Newton, putem observa c minimul lor coincide aproximativ.

```
xstar=newton(0, fprime, fsecond)
fig, ax = plt.subplots()
ax.plot(x, f(x), label='target')
ax.grid()
ax.plot(x, quadraticapprox(x, xstar, f, fprime, fsecond),
        color='red', label='quadratic approximation')
ax.set_ylim([-2,3])
ax.axhline(y=0, color='k')
ax.axvline(x=0, color='k')
ax.axvline(x = xstar, color='green')
plt.legend()
```





Figura. 4.3 – Funcția $f(x) = -2x^3 + 8x^2 - 7x + 2$ este ilustrat cu albastru, iar aproximația quadratică în x^* determinat cu metoda lui Newton este ilustrat cu roșu. Cu verde este ilustrat verticala ce trece prin x^* .

OBSERVAȚIA 3. *n cazul de față, timpul de rulare al algoritmului nu a fost lung, pentru că am pornit din apropierea soluției ($x_0 = 0$). Metoda lui Newton s-a dovedit să fie extrem de eficientă și pentru situații mai puțin avantajoase ale alegerii punctului de start. Cu toate acestea, ea poate fi aplicată numai în condițiile precizate mai sus, adică în cazul funcțiilor care se comportă bine, cum este funcția noastră polinomială.*

• Aplicația 2

Fie funcția $f : \mathbb{R} \rightarrow \mathbb{R}$,

$$f(x) = 7x^4 + e^x - \cos(x),$$

o funcție convexă pe \mathbb{R} , nepolinomială de data aceasta. Pentru reprezentare vom folosi numai intervalul $[-1, 1]$, unde se găsește de fapt și punctul de minim.

Codul pentru implementarea metodei lui Newton pe acest exemplu este similar cu cel folosit anterior, cu următoarele diferențe pentru definirea funcțiilor (f și primele două derivate ale sale), precum și a intervalului de reprezentare grafic:

```
def f(x):
    return 7*x**4+np.exp(x)-np.cos(x)
x = np.linspace(-1, 1)

def fprime(x):
    return 28*x**3+np.exp(x)+np.sin(x)
def fsecond(x):
    return 84*x**2 + np.exp(x)+np.cos(x)
n continuare ne vom referi la metoda lui Newton pe  $\mathbb{R}^n$ .
```

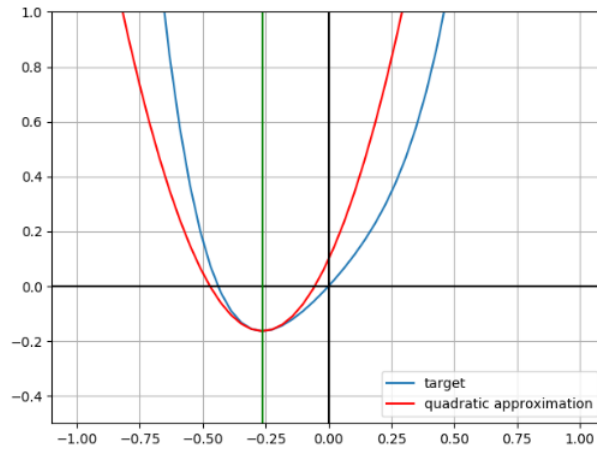


Figura. 4.4 – Funcția obiectiv, $f(x) = 7x^4 + e^x - \cos(x)$, este ilustrat cu albastru, iar aproximația quadratică în x^* determinat cu metoda lui Newton este ilustrat cu roșu. Cu verde este ilustrat verticala ce trece prin x^* . Se observă că minimele coincid aproximativ.

5. PASUL LUI NEWTON

DEFINIȚIA 2. Pentru un $x \in \text{dom} f = \mathbb{R}^n$, definim pasul lui Newton (direcția lui Newton) ca fiind vectorul:

$$(5) \quad \Delta x_{nt} = -\nabla^2 f(x)^{-1} \nabla f(x).$$

OBSERVAȚIA 4. Se poate observa că pentru $n = 1$, pasul lui Newton este cel folosit în exemplul anterior, adică $-\frac{f'(x)}{f''(x)}$. De asemenea, este important de precizat că în exemplul de mai sus s-a luat un pas unitar (măsură pasului $t = 1$). Pe \mathbb{R}^n vom lucra în cu pași care nu sunt unitari, iar pașii unitari vor corespunde fazei pure din aplicarea metodei lui Newton.

Având în vedere că matricea Hessian, $\nabla^2 f(x)$, este pozitiv semidefinit în fiecare punct la domeniului de definiție (f este convex), este ușor de verificat că direcția (pasul) lui Newton este una descendentă:

$$\nabla f(x)^T \Delta x_{nt} = -\nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x) < 0,$$

pentru orice x cu excepția situației în care x este optim ($\nabla f(x) = 0$).

• Minimizador pentru a doua aproximație a lui Taylor

La fel ca în exemplul pe \mathbb{R} , pasul lui Newton reprezintă ce trebuie adăugat la a doua aproximație a lui Taylor pentru f ca aceasta (aproximația) să ia valoarea minimă.

• Soluție pentru condiția liniară de optimalitate

Condiția de optimalitate pentru un punct x^* este ca $\nabla f(x^*) = 0$. Linearizând această condiție în apropierea lui x , avem că

$$\nabla f(x + v) \approx \nabla f(x) + \nabla^2 f(x)v = 0.$$

Această ecuație liniară are soluția $v = \Delta x_{nt}$. Prin urmare, pasul lui Newton este ceea ce trebuie adăugat la x pentru ca să aibă loc condiția liniarizată de optimalitate.

- **Invarianța afină**

O caracteristică foarte importantă a pasului lui Newton este faptul că este **afin invariant**. Cu alte cuvinte, pasul lui Newton este independent de schimbările affine de coordonate.

Demonstrație. Fie $T \in \mathbb{R}^{n \times n}$ o matrice nesingulară și definim $g(y) = f(Ty)$. Atunci, avem că:

$$\nabla g(y) = T^T \nabla f(x), \text{ iar } \nabla^2 g(y) = T^T \nabla^2 f(x) T,$$

unde $x = Ty$. Calculăm pasul lui Newton pentru g în y :

$$\Delta y_{nt} = -(T^T \nabla^2 f(x) T)^{-1} (T^T \nabla f(x))$$

$$\Delta y_{nt} = -T^{-1} \nabla^2 f(x)^{-1} \nabla f(x)$$

$$\Delta y_{nt} = T^{-1} \Delta x_{nt}.$$

Prin urmare, pasul lui Newton pentru f și pentru g sunt legate prin aceeași transformare liniară, iar:

$$x + \Delta x_{nt} = T(y + \Delta y_{nt}).$$

□

6. DECREMENTUL LUI NEWTON

DEFINIȚIA 3. *Numim decrementul lui Newton în punctul x următoarea cantitate:*

$$(6) \quad \lambda(x) = (\nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x))^{1/2}.$$

Decrementul lui Newton este foarte important în studiul convergenței metodei lui Newton. El este folosit, de asemenea, ca și criteriu de oprire al algoritmului.

Fie \tilde{f} a doua aproximație a lui Taylor pentru f . Calculăm următoarea cantitate:

$$f(x) - \inf_y \tilde{f}(y) = f(x) - \tilde{f}(x + \Delta x_{nt}) = \frac{1}{2} \lambda^2(x)$$

Prin urmare, $\lambda^2/2$ este un estimator pentru $f(x) - p^*$, estimator bazat pe aproximația quadratică a lui f în x .

- **Cutarea backtracking**

Decrementul lui Newton apare și în cutarea de tip backtracking a mării pasului lui Newton, nruct

$$\nabla f(x)^T \Delta x_{nt} = -\lambda(x)^2.$$

Aceasta este constanta folosită în cutarea de tip backtracking și ea poate fi interpretată ca derivata după direcție a lui f în x după direcția pasului lui Newton:

$$-\lambda(x)^2 = \nabla f(x)^T \Delta x_{nt} = \left. \frac{\partial}{\partial t} f(x + \Delta x_{nt} t) \right|_{t=0}.$$

OBSERVAȚIA 5. *Decrementul lui Newton este, la fel ca pasul lui Newton, afin invariant.*

7. ALGORITMUL METODEI LUI NEWTON

ALGORITMUL 3. *Algoritmul metodei lui Newton*

Se d un punct de start, $x \in \text{dom} f$ i o toleran, $\epsilon > 0$.

Repet

1. Calculeaz pasul i decrementul lui Newton:

$$\Delta x_{nt} := -\nabla^2 f(x)^{-1} \nabla f(x); \lambda^2 = \nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x).$$

2. Criteriu de oprire. Oprete-te dac $\lambda^2/2 \leq \epsilon$.

3. Msura pasului lui Newton. Se alege msura pasului, t , prin metoda back-tracking.

4. $x := x + t\Delta x_{nt}$.

Metoda descris mai sus este o metod general descendent n care am utilizat pasul lui Newton ca i direcie de cutare. Singura diferen este c se verific criteriul de oprire imediat dup calcularea decrementului lui Newton, iar nu dup datarea lui x .

OBSERVAȚIA 6. *Metoda lui Newton de mai sus este numit i metoda amortizat a lui Newton sau metoda pzit, pentru a fi deosebit de metoda pur a lui Newton, care foloseste mereu un pas unitar, adic $t = 1$.*

8. ANALIZA CONVERGENEI

• Presupuneri

Presupunem, ca mai devreme, c f este de dou ori diferentiabil i tare convex, cu constanta $m > 0$, ceea ce nseamn c $mI \preceq \nabla^2 f(x)$ pentru orice x din S . De asemenea, am vzut c tare convexitatea implic i existena unei constante $M > 0$ astfel nct $\nabla^2 f(x) \preceq MI$ pentru orice $x \in S$.

Pe lng aceste condiii, adugm i faptul ca matricea Hessian a lui f s fie Lipschitz-continuu pe S , cu constanta L :

$$(7) \quad \|\nabla^2 f(x) - \nabla^2 f(y)\|_2 \leq L\|x - y\|_2, \forall x, y \in S.$$

La modul general, coeficientul L ne indic ct de bine poate fi aproximat f de o funcie quadratic. Astfel, ne putem atepta ca pentru o funcie a crei aproximaie quadratic variaaz puin, metoda lui Newton va funciona bine.

• Ideea demonstraiei convergenei

Vom demonstra c exist dou constante γ i η corespunztoare, fiecare dintre ele, uneia din cele dou faze ale desfurrii algoritmului. Cele dou constante ndeplinesc urmtoarele constrngeri: $0 < \eta < m^2/L$ i $\gamma > 0$.

n ceea ce privete fazele algoritmului, prima dintre ele mai este numit i faza *amortizat* a metodei lui Newton, deoarece poate alege i pai care s nu fie ntregi(msura pasului, t , s nu fie 1), iar cea de-a doua faz este faza *pur* a metodei lui Newton, cnd sunt luai numai pai ntregi($t = 1$). Vom vedea c faza

a doua mai este numit i *faza de convergen quadratic*, iar odat ajuns n această faz, convergen este foarte rapid.

Cele dou faze sunt descrise matematic dup cum urmeaz:

1. **Faza amortizat.** Dac $\|\nabla f(x^{(k)})\|_2 \geq \eta$, atunci

$$(8) \quad f(x^{(k+1)}) - f(x^{(k)}) \leq -\gamma.$$

2. **Faza pur.** Dac $\|\nabla f(x^{(k)})\|_2 < \eta$, atunci cutarea de tip backtracking ia msura pasului $t^{(k)} = 1$ i

$$(9) \quad \frac{L}{2m^2} \|\nabla f(x^{(k+1)})\|_2 \leq \left(\frac{L}{2m^2} \|\nabla f(x^{(k)})\|_2\right)^2.$$

OBSERVAȚIA 7. *Analiznd implicațiile pentru a doua faz, observm c dac la iteraia k avem $\|\nabla f(x^{(k)})\|_2 < \eta$, atunci, din moment ce $\eta \leq m^2/L$, avem c*

$$\|\nabla f(x^{(k+1)})\|_2 < \frac{L}{2m^2} \eta^2 < \eta/2 < \eta.$$

Prin urmare, condiia pentru a doua faz este satisfcut i pentru iteraia $k+1$. Asta nseamn c odat ce are loc a doua condiie, (9), ea va avea loc pentru toate iterațiile viitoare, adic pentru orice $l \geq k$ msura pasului luat va fi $t = 1$ i

$$(10) \quad \frac{L}{2m^2} \|\nabla f(x^{(l+1)})\|_2 \leq \left(\frac{L}{2m^2} \|\nabla f(x^{(l)})\|_2\right)^2.$$

Aplicnd recursiv relaia (10), obinem c pentru orice $l \geq k$

$$\frac{L}{2m^2} \|\nabla f(x^{(l)})\|_2 \leq \left(\frac{L}{2m^2} \|\nabla f(x^{(k)})\|_2\right)^{2^{l-k}} \leq \left(\frac{1}{2}\right)^{2^{l-k}},$$

acest rezultat implicnd faptul c

$$f(x^{(l)}) - p^* \leq \frac{1}{2m} \|\nabla f(x^{(l)})\|_2^2 \leq \frac{2m^3}{L^2} \left(\frac{1}{2}\right)^{2^{l-k+1}}.$$

Ultima relaie ne spune c odat satisfcut a doua condiie, convergen este extrem de rapid. Mai mult, putem spune c dup un numr suficient de mare de iteraii, numrul de cifre corecte se dubleaz la fiecare iteraie. Acest fenomen poart numele de *convergen quadratic*.

n continuare, vom estima convergen total a metodei, lund n considerare cele dou etape menionate mai sus.

n *faza amortizat*, observm c f descrete la fiecare iteraie cu cel puin γ . Aadar, numrul maxim de iteraii pentru această etap va fi maxim

$$\frac{f(x^{(0)}) - p^*}{\gamma}.$$

Cu privire la etapa de convergen quadratic, n *faza pur*, avem c

$$\frac{2m^3}{L^2} \left(\frac{1}{2}\right)^{2^n} < \epsilon \Rightarrow \left(\frac{1}{2}\right)^{2^n} < \epsilon/\epsilon_0,$$

unde cu ϵ_0 am notat pe $\frac{2m^3}{L^2}$ i cu n numrul de iteraii

$$\Rightarrow 2^n = \log_{\frac{1}{2}}(\epsilon/\epsilon_0) = \frac{\log_2(\epsilon/\epsilon_0)}{\log_2 \frac{1}{2}} = \log_2(\epsilon_0/\epsilon).$$

Avem aadar c numrul de iteraii pentru a doua faz nu poate depi $\log_2 \log_2(\epsilon_0/\epsilon)$. Prin urmare, numrul maxim de iteraii pn cnd $f(x) - p^* \leq \epsilon$ este mrginit superior de

$$\frac{f(x^{(0)})-p^*}{\gamma} + \log_2 \log_2(\epsilon_0/\epsilon).$$

OBSERVAȚIA 8. Pentru cel de-al doilea termen, $\log_2 \log_2(\epsilon_0/\epsilon)$, corespunztor etapei de convergen quadratic, acesta crete extrem de ncet pentru un ϵ dat. Astfel, acesta poate fi considerat o constant din motive practice. Se observ c pentru o constant egal cu 6 (6 iteraii n faza de convergen quadratic) se obine o precizie foarte bun, $\epsilon \approx 5 * 10^{-20} \epsilon_0$. Prin urmare, o margine superior pentru numrul de iteraii n metoda lui Newton pentru a obine o aproximaie foarte bun a soluiei este

$$\frac{f(x^{(0)})-p^*}{\gamma} + 6.$$

Din analiza celor doua faze ale metodei lui Newton reies urmtoarele valori pentru γ i η (n funcie de constantele m, M i L):

$$\gamma = \alpha\beta\eta^2 \frac{m}{M^2}, \quad \eta = \min\{1, 3(1-2\alpha)\} \frac{m^2}{L}.$$

OBSERVAȚIA 9. Putem spune, deci, c pentru o aproximaie foarte bun a soluiei, numrul maxim de iteraii necesare este mrginit superior de

$$6 + \frac{1}{\alpha\beta\eta^2 \frac{m}{M^2}} (f(x^{(0)}) - p^*) =$$

$$6 + \frac{M^2 L^2 / m^5}{\alpha\beta \min\{1, 9(1-2\alpha)^2\}} (f(x^{(0)}) - p^*).$$

Ideile de baz privind optimizarea convex, metodele descendente, algoritmul, pasul, decrementul lui Newton, precum i analiza convergenei metodei au fost preluate din lucrarea lui Boyd i Vandenberghe [2], unde se gsete i demonstraia complet privind convergena metodei.

9. AVANTAJE I DEZAVANTAJE

Teoria i practica au relevat cteva avantaje nsemnate pentru metoda lui Newton:

- Este afin invariant, dup cum pasul i decrementul lui Newton sunt.
- Convergena n metoda lui Newton este rapid n general i quadratic n apropierea lui x^* . Odat ce s-a trecut n etapa de convergen quadratic, e nevoie de aproximativ 6 iteraii pentru a obine o soluie foarte precis.
- Metoda lui Newton se scaleaz bine n funcie de dimensiunea problemei. Performana ei pe probleme n \mathbb{R}^{10000} este asemntoare cu cea n \mathbb{R}^{10} . Ele difer printr-o cretere mic a numrului de pai cerui.
- Performana acestei metode nu depinde de parametrii algoritmului (pentru diferite alegeri ale parametrilor α i β din cadrul cutrii backtracking numrul de iteraii pentru a obine o soluie foarte bun variaz nesemnificativ).

Principalul dezavantaj al metodei lui Newton este costul formării și memorării matricei Hessiene, împreună cu costul calculării pasului lui Newton. Cu toate acestea, există multe cazuri în care se poate exploata structura problemei și reduce substanțial costul calculării pasului lui Newton.

OBSERVAȚIA 10. În ceea ce privește efortul computațional, amintim și o altă alternativă. Există o familie de algoritmi numiți metode cuasi-Newton, care necesită mai puțin efort de calcul pentru a determina direcția de căutare, dar au aceeași convergență rapidă în apropierea lui x^ .*

BIBLIOGRAFIE

- [1] Valentina ALTO: *Optimization algorithms: the Newton Method*, <https://medium.com/swlh/optimization-algorithms-the-newton-method-4bc6728fb3b6>.
- [2] Stephan BOYD, Lieven VANDENBERGHE : *Convex optimization*, Cambridge University Press, United Kingdom, 2004.
- [3] B.T. POLYAK: *Newtons method and its use in optimization*, https://www.researchgate.net/publication/221989049_Newton's_method_and_its_use_in_optimization.

*Faculty of Mathematics and Computer Science
"Babeș-Bolyai" University
Str. Kogălniceanu, no. 1
400084 Cluj-Napoca, Romania*