

Convergenta liniara a algoritmilor de ordinul I pentru probleme *ne-tari* convexe

Ion Necoara

Fac. de Automatica, UPB

Colaborare cu: **Yu. Nesterov** & **F. Glineur**
UCL, Belgium

2016

Ion Necoara

- ▶ 2000 matematica: Fac. Matematica, UB
- ▶ 2002 master in Statistica si Optimizari (Fac. Matematica)
- ▶ 2002–2006 doctorat in control, TU Delft
- ▶ 2007 –2009 postdoc, KU Leuven
- ▶ 2009 cadru didactic Fac. Automatica, UPB (2015 - profesor)
- ▶ 2014 - teza abilitare, conducator de doctorat din 2015
- ▶ domenii de interes
 - ▶ optimizare convexa/ne-convexa/Big Data
 - ▶ algoritmi numerici cu garantari matematice a eficientei
 - ▶ modelare/control bazat pe optimizare
- ▶ web-page: <http://acse.pub.ro/person/ion-necoara>

Motivatie

- ▶ Problema generala de optimizare:

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

- ▶ Presupuneri standard:
 - ▶ f functie convexa si X multime convexa
 - ▶ f continuu diferentiabila cu gradient Lipschitz (smooth)
 - ▶ ce alte conditii...?

Sub ce conditii/cum putem garanta convergenta liniara pentru metode de tip gradient?

- ▶ raspuns partial: N, Clipici, *Parallel random coordinate descent method for composite minimization: onvergence analysis and error bounds*, SIAM J. Optimization, 2016
- ▶ astazi un raspuns mai complet: N, Nesterov, Glineur: *Linear convergence of first-order methods for non-strongly convex optimization*, submitted, 2015

Clasificare metode de optimizare

• Informația ce indică comportamentul unei funcții $f \in \mathbb{R}^n \rightarrow \mathbb{R}$ într-un punct $x \in \mathbb{R}^n$ se poate clasifica:

- ▶ Informație de ordin 0: $f(x)$
- ▶ Informație de ordin 1: $f(x), \nabla f(x)$
- ▶ Informație de ordin 2: $f(x), \nabla f(x), \nabla^2 f(x)$
- ▶ ...

• Fie algoritmul iterativ definit de $x_{k+1} = \mathcal{M}(x_k)$; în funcție de ordinul informației utilizate în expresia lui \mathcal{M} :

- ▶ Metode de ordin 0: $f(x_k)$
- ▶ Metode de ordin 1: $f(x_k), \nabla f(x_k)$
- ▶ Metode de ordin 2: $f(x_k), \nabla f(x_k), \nabla^2 f(x_k)$
- ▶ ...

Rate de convergenta in optimizare

Problema generala de optimizare si metoda iterativa:

$$f^* = \min_{x \in X \subseteq \mathbb{R}^n} f(x) \quad \& \quad x_{k+1} = \mathcal{M}(x_k)$$

Dorim caracterizare rata convergenta la solutie (local/global):

$$x_k \rightarrow x^* \vee f(x_k) \rightarrow f^* \vee \|\nabla f(x_k)\| \rightarrow 0 \quad (X = \mathbb{R}^n)$$

- ▶ **Rezultat** classic din analiza: orice functie continua poate fi aproximata cu o functie diferentiabila, arbitrar de bine!
- ▶ Deci presupunand doar diferentiabilitate nu va fi suficient pentru a caracteriza rata de convergenta a unei metode
- ▶ E nevoie sa impunem o conditie pe *magnitudinea derivatei*

Classic in optimizare, se considera urmatoarele conditii:

- ▶ functia obiectiv f are gradient Lipschitz (permite rata locala)
- ▶ in plus: f (tare) convexa & X convexa (permit rate globale)


Convexitate tare - continuitate Lipschitz

- f diferentiabila este convexa daca:

$$f(y) \geq f(x) + \nabla f(x)^T (y - x) \quad \forall x, y$$


- f diferentiabila este *tare* convexa daca $\exists \sigma > 0$ a.i.:

$$f(y) \geq f(x) + \nabla f(x)^T (y - x) + \frac{\sigma}{2} \|y - x\|^2 \quad \forall x, y$$



- f are gradient Lipschitz daca $\exists L > 0$ a.i.:

$$\|\nabla f(x) - \nabla f(y)\| \leq L \|x - y\| \quad \forall x, y$$



Istoric - Metode de ordinul I

Cea mai *simpla* metoda de ordinul I: **Metoda Gradient**

solutie ec. $F(x) = 0 \iff$ punct fix iter. $x_{k+1} = x_k - \alpha F(x_k)$

- pasul $\alpha > 0$ constant sau variabil
 - iteratia foarte simpla (operatii vectoriale)!
 - convergenta rapida/lenta?
 - adecvata pentru x de dimensiune mare
-
- ▶ Prima aparitie in lucrarea [Cau:47] a lui Augustin-Louis Cauchy, 1847
 - ▶ Cauchy rezolva un sistem neliniar de 6 ecuatii cu 6 necunoscute, utilizand **metoda gradient**



Istoric - Metode de ordinul I

Rata de convergenta slaba a metodei gradient reprezinta motivatia dezvoltarii de alte metode de ordin I cu performante superioare

- ▶ **Metoda de Gradienti Conjugati** - autori independenti Lanczos, Hestenes, Stiefel (1952)
 - QP convex solutia in n iteratii



- ▶ **Metoda de Gradient Accelerat** - dezvoltata de Yurii Nesterov (1983)
 - cu un ordin mai rapida decat gradientul clasic
- MGA neutilizata pentru 2 decade! - acum este una din cele mai folosite metode de optimizare
- Google returneaza aprox. 20 mil. rezultate (≈ 2000 citari)



Metoda Gradient

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

- ▶ conditii de optimalitate: $\nabla f(x^*) = 0$
- ▶ metoda gradient (MG) pentru problema de optimizare:

$$x_{k+1} = x_k - \alpha_k \nabla f(x_k)$$

- ▶ Pasul α_k poate fi ales:
 - ▶ pas constant, conditii Wolfe, backtracking, pas ideal,...
- ▶ **Avantaje MG:**
 - ▶ complexitate de calcul redusa - $\mathcal{O}(n)$ + calcul $\nabla f(x)$
 - ▶ nu necesita informatii de ordin II
 - ▶ convergenta globala garantata in conditii obisnuite
 - ▶ robust la erori de calcul/la gradient inexact [NecNed:13]
- ▶ **Dezavantaje MG:**
 - ▶ rata convergenta destul de lenta - subliniara sau cel mult liniara (sub anumite conditii de regularitate)

Rate de convergenta pentru MG

Presupunem f are $\nabla f(x)$ Lipschitz, i.e.

$$\|\nabla f(x) - \nabla f(y)\| \leq L\|x - y\| \quad \forall x, y \in \text{dom}f$$

Metoda gradient (MG) cu pas constant $\alpha = 1/L$

$$x_{k+1} = x_k - 1/L \nabla f(x_k)$$

Teorema Sub convexitate si gradient Lipschitz, MG are rata de convergenta *subliniara* $\mathcal{O}(1/k)$:

$$f(x_k) - f^* \leq \frac{L\|x_0 - x^*\|^2}{2k}$$

Teorema Daca in plus f tare convexa cu constanta σ , i.e.

$$f(y) \geq f(x) + \langle \nabla f(x), y - x \rangle + \frac{\sigma}{2}\|x - y\|^2 \quad \forall x, y$$

atunci rata de convergenta liniara (numar conditionare $\mu = \sigma/L$):

$$f(x_k) - f^* \leq \left(\frac{1 - \mu}{1 + \mu}\right)^k \frac{L\|x_0 - x^*\|^2}{2}$$

Metoda de Gradient Accelerat (MGA)

Convergenta slaba a MG \implies dezvoltarea unor metode cu performante superioare:

- ▶ Metoda de Gradient Accelerat (Nesterov 1983) - cu un ordin mai rapida decat gradientul clasic in cazul problemelor convexe
- ▶ **Metoda de Gradient Accelerat implica:**

$$\text{Pas de gradient: } x_{k+1} = y_k - \frac{1}{L} \nabla f(y_k)$$

$$\text{O combinatie liniara : } y_{k+1} = x_{k+1} + \beta_k (x_{k+1} - x_k)$$

- ▶ Punctele initiale $x_0 = y_0$ si β_k ales in mod adecvat, e.g. pentru f tare convexa luam $\beta_k = \frac{\sqrt{L} - \sqrt{\sigma}}{\sqrt{L} + \sqrt{\sigma}}$.
- ▶ MGA are performante superioare fata de MG insa complexitatea pe iteratie ramane aceiasi (MGA este optima!).

Rate de convergenta pentru MGA

Metoda de Gradient Accelerat

$$\text{Pas de gradient: } x_{k+1} = y_k - \frac{1}{L} \nabla f(y_k)$$

$$\text{O combinatie liniara : } y_{k+1} = x_{k+1} + \beta_k (x_{k+1} - x_k)$$

Teorema Sub convexitate si gradient Lipschitz, MGA are rata de convergenta *subliniara* $\mathcal{O}(1/k^2)$:

$$f(x_k) - f^* \leq \frac{L \|x_0 - x^*\|^2}{k^2}$$

Teorema Daca in plus f tare convexa cu constanta σ , i.e.

$$f(y) \geq f(x) + \langle \nabla f(x), y - x \rangle + \frac{\sigma}{2} \|x - y\|^2 \quad \forall x, y$$

atunci rata de convergenta liniara (numar conditionare $\mu = \sigma/L$):

$$f(x_k) - f^* \leq (1 - \sqrt{\mu})^k \frac{L \|x_0 - x^*\|^2}{2}$$

Observam ca numarul de conditionare este sub radical in MGA!!!

Convergenta MG versus MGA

Conditii f

MG

MGA


$\nabla f(x)$ Lipschitz(L)

$$\mathcal{O}\left(\frac{LR^2}{k}\right)$$

$$\mathcal{O}\left(\frac{LR^2}{k^2}\right)$$

$\nabla f(x)$ Lipschitz


si $f(x)$ tare convexa(σ) $\mathcal{O}\left(\left(\frac{L-\sigma}{L+\sigma}\right)^k\right)$ $\mathcal{O}\left(\left(1-\sqrt{\frac{\sigma}{L}}\right)^k\right)$



Continuitate Lipschitz - convexitate tare


- Daca f are gradient Lipschitz atunci:

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



- Daca f este tare convexa atunci:

$$f(y) \geq f(x) + \nabla f(x)^T (y - x) + \frac{\sigma}{2} \|y - x\|^2$$



- Daca f tare convexa si gradient Lipschitz atunci co-coercivitate:

$$\langle \nabla f(y) - \nabla f(x), y - x \rangle \geq \frac{\sigma L}{\sigma + L} \|x - y\|^2 + \frac{1}{\sigma + L} \|\nabla f(y) - \nabla f(x)\|^2$$

Problema convexitatii tari a lui f

- ▶ **Clasic**: pentru a demonstra rata de convergenta liniara in metode de tip gradient este necesar ca f sa fie **tare convexa**
- ▶ **In practica**: convexitatea tare a lui f nu este des intalnita

Exemplu 1:

$$f(x) = x^T Q x \implies L = \|Q\| = \lambda_{\max}(Q) \quad \& \quad \sigma = 1/\|Q^{-1}\| = \lambda_{\min}(Q)$$

Exemplu 2:

$$f(x) = \log(1 + e^{a^T x}) \implies L = \|\nabla^2 f(x)\| = \left\| \frac{e^{a^T x}}{(1 + e^{a^T x})^2} a a^T \right\| \quad \& \quad \sigma = 0$$

Insa, multe aplicatii se modeleaza ca $\min_{x \in X} f(x)$, in care:

- ▶ funct. obiectiv de forma $f(x) = g(Ax) + c^T x$, cu g tare convexa
- ▶ multimea constrangerilor X este poliedrala: $X = \{x : Cx \leq c\}$

Aplicatie 1

- ▶ Problema celor mai mici patrate liniara (**regularizata**):

$$\min_{x \in \mathbb{R}^n} \|Ax - b\|^2 \quad (+\lambda \|x\|_1)$$

- ▶ Problema CMMP:

$$f(x) = x^T A^T A x - 2b^T A x + b^T b = g(Ax) + \langle q, x \rangle + r$$

- ▶ observam $g(t) = t^T t \implies g$ tare convexa in t cu $\sigma = 2$
- ▶ Problema CMMMP regularizata (lasso in compressed sensing):



$$z = (x, u) \implies f(z) = \|[A \ 0]z - b\|^2 + \lambda(0, e)^T z \quad \& \quad -u \leq x \leq u$$

- ▶ observam $g(t) = t^T t \implies g$ tare convexa in t cu $\sigma = 2$
- ▶ constrangeri poliedrale $X = \{z = (x, u) : -u \leq x \leq u\}$

Problema CMMP liniara (regularizata) apare in multe aplicatii:

identificare sisteme

reconstructie semnale




Aplicatie 2

- ▶ Consideram o problema de optimizare cu constrangeri liniare:

$$f^* = \min_u g(u)$$
$$\text{s.t. } Cu \leq c$$


- ▶ Probleme practice ce se pot formula astfel enumeram:
network utility maximization (NUM), direct current optimal power flow (DC-OPF), model predictive control (MPC)



DC-OPF



MPC



Aplicatie 2

- ▶ Obținem funcția duală: $f(x) = \min_{u \in \mathbb{R}^m} g(u) + \langle x, Cu - c \rangle$
- ▶ Sub dualitate puternică avem problema duală:

$$f^* = \max_{x \in \mathbb{R}_+^n} f(x)$$

- ▶ Fiind dată g convexă, notăm $\tilde{g}(t)$ conjugată ei:

$$\tilde{g}(t) = \max_{u \in \mathbb{R}^m} \langle t, u \rangle - g(u)$$

- ▶ **Lema:** dacă g are $\nabla g(u)$ Lipschitz cu constanta L , atunci $\tilde{g}(t)$ este tare convexă cu $\sigma = \frac{1}{L}$ și reciproc
- ▶ Obsv.1: funcția duală poate fi scrisă drept

$$f(x) = -\tilde{g}(-C^T x) - c^T x$$

unde $\tilde{g}(t)$ este tare convexă în t cu $\sigma = \frac{1}{L}$

- ▶ Obsv.2: mulțimea constrângerilor $X = \mathbb{R}_+^n$ poliedrală simplă

Aplicatie 2: MPC

- ▶ Exemplu din practica: problema MPC pe orizont N

$$V_N^*(x) = \min_{x(t), u(t)} V_N(x(t), u(t)) \quad \left(= \sum_{t=0}^{N-1} \ell(x(t), u(t)) + \ell_f(x(N)) \right)$$

s.l. $x(t+1) = Ax(t) + Bu(t)$, $x(0) = x$
 $u(t) \in U$, $\forall t \geq 0$

unde U este multime poliedrala.

- ▶ Daca luam

$$\mathbf{u} = \left[u(0)^T, u(1)^T, \dots, u(N-1)^T \right]^T$$

atunci prin eliminarea starilor, problema de MPC poate fi scrisa drept:

$$V_N^*(x) = \min_{\mathbf{u}} g(\mathbf{u})$$

s.l. $C\mathbf{u} \leq c$

Metode de tip gradient: abordarea primala vrs. duala

- ▶ Reamintim problema de optimizare generala:

$$\min_{u \in U} g(u)$$

- ▶ Iteratiile metodei gradient trebuie sa ramana fezabile \rightarrow metoda de gradient proiectat

$$u_{k+1} = [u_k - \alpha_k \nabla g(u_k)]_U$$

- ▶ **Avantaj major** abordare primala: sub $\nabla g(u)$ Lipschitz si convexitate tare \Rightarrow convergenta liniara pentru MG proiectat
- ▶ **Dezavantaj major** abordare primala: trebuie realizata proiectia $[u_k - \alpha_k \nabla g(u_k)]_U$
- ▶ Daca U nu este simpla (e.g. descrisa de $Cu \leq c$, cu C matrice generala), atunci proiectia este foarte dificil de calculat \rightarrow abordarea duala

Metode de tip gradient: abordarea primala vrs. duala

- ▶ Abordarea duala: rezolvam problema duala

$$\max_{x \in X} f(x) \quad \text{cu } X = \mathbb{R}_+^n$$

- ▶ **Avantaj major** fata de abordarea primala: proiectia nu trebuie realizata decat pentru multiplicatorul Lagrange pentru constrangerile de inegalitate $x \in \mathbb{R}_+^n$ - **simpla!**
- ▶ **Dezavantaj major**: din literatura existenta prin abordarea duala convergenta NU este liniara
- ▶ Rezultate existente pentru algoritmi de tip dual gradient sunt de convergenta subliniara ($\mathcal{O}\left(\frac{1}{k^p}\right)$, $p = 1, 2$) [NecSuy:08], [NecNed:13] sau convergenta **locala** liniara [LuoTse:93]

gaura in teoria convergentei metodelor de tip gradient dual!

[NecSuy:08] Necoara, Suykens, *Application of a smoothing technique to decomposition in convex optimization*, IEEE T. Automatic Control, 53(11), 2008

[NecNed:13] Necoara, Nedelcu, *Rate analysis of inexact dual first order methods: application to dual decomposition*, IEEE T. Automatic Control, 59(5), 2014

[LuoTse:93] Luo, Tseng, *On the convergence rate of dual ascent methods for strictly convex minimization*, Math. Oper. Res., 18, 1993

Obtinerea convergentei liniare pt. metode de tip gradient

- ▶ **Intrebari cheie pt. problema convexa smooth** $\min_{x \in X} f(x)$:
 - ▶ Se poate obtine o rata de convergenta liniara pentru problema $\min_{x \in X} f(x)$ cand f **nu este tare convexa**?
 - ▶ Se poate obtine **rata liniara si pe abordarea duala** a problemei primale cu constrangeri liniare $\min_{x: Cx \leq c} f(x)$?
- ▶ **Raspuns:** DA (in anumite cazuri).

▶ **Intrebare cheie:** cum?

▶ **Raspuns:** prin conceptul de **Relaxarea Convexitatii Tari**.

▶ **Relaxarea convexitatii tari:** in esenta presupune relaxarea conditiei de convexitate tare (valabila pentru orice $x, y \in \mathbb{R}^n$) la o conditie valabila pentru x sau y bine fixat:

$$f(y) \geq f(x) + \nabla f(x)^T (y - x) + \frac{\sigma}{2} \|y - x\|^2 \quad \forall x, y \in \mathbb{R}^n$$

▶ **Aspect esential:** nu este necesar ca f sa fie tare convexa (TC) pentru a avea o proprietate de tip TC numai in x sau y .

Resultate existente - marginirea erorii in optimizare

Primele contributii aduse de Tseng (1992)

Cadrul general: pentru problema convexa

$$X^* = \arg \min_{x \in X} f(x)$$

$$\bar{x} = [x]_{X^*} \quad \& \quad \nabla^+ f(x) = x - [x - \nabla f(x)]_X$$



Lema: Daca f tare convexa si $\nabla f(x)$ Lipschitz atunci:

$$\|x - y\|^2 \leq \frac{1 + L}{\sigma} \|\nabla^+ f(x) - \nabla^+ f(y)\| \|x - y\| \quad \forall x, y$$

Fixand $y = \bar{x}$ rezulta o relatie de marginire a erorii (ME):

$$ME: \quad \|x - \bar{x}\| \leq \frac{1 + L}{\sigma} \|\nabla^+ f(x)\| \quad \forall x \in X$$

- ▶ f are gradient Lipschitz si convexa
- ▶ in plus, relatia de marginire a erorii, ME, are loc



- ▶ clasica metoda gradient converge liniar!

Resultate existente - marginirea erorii in optimizare

Din conditiile de optimalitate - multimea solutiilor se scrie ca:

$$X^* = \{x \in \mathbb{R}^n : x = [x - \nabla f(x)]_X\}$$

- ▶ Intuitiv, pentru un algoritm iterativ, cantitatea:

$$\|x_k - [x_k - \nabla f(x_k)]_X\|$$

reprezinta o masura buna a optimalitatii punctului x_k .

- ▶ Contributia lui Tseng la problema $\min_{x \in X} f(x)$:
 - ▶ pentru probleme unde $f(x) = g(Ax)$, iar $g(t)$ tare convexa
 - ▶ multimea constrangerilor X poliedrala
- ▶ utilizand conditiile de optimalitate si concepte din analiza variationala (Robinson'78), a demonstrat ca $\exists \kappa > 0$ a.i. notand $\bar{x} = [x]_{X^*}$ & $\nabla^+ f(x) = x - [x - \nabla f(x)]_X$ avem :

$$\|x - \bar{x}\| \leq \kappa \|\nabla^+ f(x)\| \quad \forall x \in \mathcal{N}(X^*)$$

- ▶ Neajunsuri ale contributiilor lui Tseng: proprietatea de error bound este asigurata doar local, i.e. pentru x suficient de aproape de X^* (intr-o vecintata a lui X^*)

Resultate existente - marginirea erorii in optimizare

Teorema Sub proprietatea de marginirea erorii locala, Tseng a demonstrat convergenta liniara *locala* a gradientului proiectat.

Neajunsuri si probleme deschise:

1. Desi convergenta liniara locala este o contributie majora, dorim convergenta globala (ca si in cazul tare convex)
2. Problema deschisa: met. gradient accelerat poate converge linear pt. probleme care relaxeaza convexitatea tare?
3. De ce este mai dificil de analizat MGA fata de MG?
 - ▶ MG desi nu utilizeaza informatie legata de convexitate tare in iteratie (σ), totusi converge linear pt functii smooth tari convexe!
 - ▶ Pe de alta parte, MGA utilizeaza informatie legata de convexitate tare in iteratie $\beta = \frac{\sqrt{L}-\sqrt{\sigma}}{\sqrt{L}+\sqrt{\sigma}}$. Deci daca aceasta conditie TC nu mai este valabila ($\sigma = 0$) ce putem face?

Ideea de baza a lui Tseng?

Functia f are proprietatea de convexitatea tare (σ), atunci:

$$(TC) : f(y) \geq f(x) + \nabla f(x)^T (y - x) + \frac{\sigma}{2} \|y - x\|^2 \quad \forall x, y$$

Reamintim notatiile: $\bar{x} = [x]_{X^*}$ & $\nabla^+ f(x) = x - [x - \nabla f(x)]_X$

Lema: Daca f tare convexa (σ) si $\nabla f(x)$ Lipschitz (L), atunci:

$$\|x - y\|^2 \leq \frac{1 + L}{\sigma} \|\nabla^+ f(x) - \nabla^+ f(y)\| \|x - y\| \quad \forall x, y$$

Fixand $y = \bar{x}$ rezulta o relatie de marginire a erorii (ME):

$$ME : \quad \|x - \bar{x}\| \leq \frac{1 + L}{\sigma} \|\nabla^+ f(x)\| \quad \forall x \in X$$

Obs.: Marginirea erorii (ME) NU implica convexitatea tare (TC)!!!

Vom proceda intr-o maniera similara!

Ideea de baza a noastra

Funcția f cu gradient Lipschitz (L) și tare convexa (σ), atunci:

$$(TC) : f(y) \geq f(x) + \nabla f(x)^T (y - x) + \frac{\sigma}{2} \|y - x\|^2 \quad \forall x, y$$

Fie $X^* = \arg \min_{x \in X} f(x)$ și notăm $\bar{x} = [x]_{X^*}$. Atunci:

Lema: Avem următoarele relaxări ale convexității tari (TC):

1. Luând $y = \bar{x}$ obt. prima cond. de relaxare a convexității tari:

$$\mathbf{TC1} : f^* \geq f(x) + \nabla f(x)^T (\bar{x} - x) + \frac{\sigma}{2} \|x - \bar{x}\|^2 \quad \forall x,$$

2. Luând $y = x$ & $x = \bar{x}$ obt. a doua condiție de relaxare a TC:

$$\mathbf{TC2} : f(x) \geq f^* + \nabla f(\bar{x})^T (x - \bar{x}) + \frac{\sigma}{2} \|x - \bar{x}\|^2 \quad \forall x,$$

3. Luând $y = x$ & $x = \bar{x}$ și tinând seama că $\nabla f(\bar{x})^T (x - \bar{x}) \geq 0$ obținem a treia condiție de relaxare a convexității tari:

$$\mathbf{TC3} : f(x) \geq f^* + \frac{\sigma}{2} \|x - \bar{x}\|^2 \quad \forall x,$$

Teorema: Avem $TC \Rightarrow TC1 \Rightarrow TC2 \Rightarrow TC3 \Leftrightarrow ME$
(implicații stricte!)

Relaxarea convexitatii tari 1

Luand $y = \bar{x}$ obtinem prima conditie de relaxare a convexitatii tari:

$$\mathbf{TC1} : f^* \geq f(x) + \nabla f(x)^T (\bar{x} - x) + \frac{\sigma_1}{2} \|x - \bar{x}\|^2 \quad \forall x$$

Teorema. Sub prima conditie de relaxare a convexitatii tari avem (numar conditionare $\mu_1 = \sigma_1/L$):

- ▶ Metoda gradient converge liniar:

$$f(x_k) - f^* \leq \left(\frac{1 - \mu_1}{1 + \mu_1} \right)^k \frac{L \|x_0 - x^*\|^2}{2}$$

- ▶ Metoda gradient accelerat converge liniar cu $\beta_k = \frac{\sqrt{L} - \sqrt{\sigma_1}}{\sqrt{L} + \sqrt{\sigma_1}}$

$$f(x_k) - f^* \leq (1 - \sqrt{\mu_1})^k (f(x_0) - f^*)$$

Teorema. Problema smooth convexa:

$$\min_{x: Cx \leq d} g(Ax)$$

unde g este tare convexa si cu gradiet Lipschitz, iar matricea A oarecare, satisface TC1 global!

Relaxarea convexitatii tari 3

Luand $y = \bar{x}$ obtinem prima conditie de relaxare a convexitatii tari:

$$\mathbf{TC3} : f(x) \geq f^* + \frac{\sigma_3}{2} \|x - \bar{x}\|^2 \quad \forall x$$

Teorema. Sub a treia conditie de relaxare a convexitatii tari avem (numar conditionare $\mu_3 = \sigma_3/L$):

- ▶ Metoda gradient converge liniar:

$$f(x_k) - f^* \leq \left(\frac{1}{1 + \mu_3} \right)^k \frac{L \|x_0 - x^*\|^2}{2}$$

- ▶ Metoda gradient accelerat *restartata* la fiecare $K_e = 2e/\sqrt{\mu_3}$ iteratii, converge liniar:

$$f(x_k) - f^* \leq \left(1 - \frac{\sqrt{\mu_3}}{e} \right)^k (f(x_0) - f^*).$$

Teorema. Problema smooth convexa:

$$\min_{x: Cx \leq d} g(Ax) + c^T x$$

unde g este tare convexa si cu gradiet Lipschitz, iar matricea A oarecare, satisface TC3 pe orice multime subnivel $\{x : f(x) \leq M\}$.

Relaxarea convexitatii tari 4: “Marginirea Erorii Generalizata”

- ▶ Extindem clasa de probleme $\min_{x \in X} f(x)$ ce satisfac proprietatea de error bound la proprietate de error bound generalizat:

$$\text{(GEB): } \|x - \bar{x}\| \leq (\kappa_1 + \kappa_2 \|x - \bar{x}\|^2) \|\nabla^+ f(x)\| \quad \forall x \in X$$

- unde $\bar{x} = [x]_{X^*}$ si $\nabla^+ f(x) = x - [x - \nabla f(x)]_X$
- unde $\kappa_1 > 0$ si $\kappa_2 \geq 0$
- ▶ **Observatie:** proprietatea de error bound introdusa de Tseng este inclusa in categoria (GEB):

$$\kappa_1 = \kappa, \kappa_2 = 0 \rightarrow \|x - \bar{x}\| \leq \kappa \|\nabla^+ f(x)\|$$

- ▶ **Contributia noastra:**
 - (i) proprietatea de marginirea erorii generalizata este globala pentru o clase de probleme de optimizare mai larga
 - (ii) include toate celalalte clase definite pana in prezent

Marginirea erorii generalizata global in optimizare: caz 1

- ▶ Consideram problema generala de tip composite:

$$\min_{x \in \mathbb{R}^n} F(x) \quad (= f(x) + \Psi(x)),$$

in care presupunem $f(x) = g(Ax)$, cu A matrice oarecare, si urmatoarele conditii:

- ▶ $g(t)$ tare convexa in t si cu gradient Lipschitz
 - ▶ $\Psi(x)$ functie poliedrala (supragraficul - multime poliedrala)
 - ▶ $\Psi(x)$ este mariginita superior (i.e. $\Psi(x) \leq \bar{\Psi} \forall x \in \text{dom}\Psi$)
 - ▶ $\Psi(x)$ este Lipschitz continua cu constanta L_Ψ
- ▶ Atunci F va satisface proprietatea (GEB):

$$\|x - \bar{x}\| \leq (\kappa_1 + \kappa_2 \|x - \bar{x}\|^2) \|\nabla^+ F(x)\| \quad \forall x \in X$$

unde $\nabla^+ F(x) = x - \text{prox}_\Psi(x - \nabla f(x))$

Cerintele nu sunt restrictive:

- $\psi(x) = 1_X(x)$, unde X poliedru (nu neaparat mariginat)
- $\psi(x) = \|x\|_p + 1_X(X)$, unde X politop si $p = 1, \infty$

Marginirea erorii generalizata global in optimizare: caz 2

Consideram urmatoarea problema primala constransa liniar

$$\min_{u \in \mathbb{R}^m} \{g(u) : Au \leq 0\}$$

unde g tare convexa si gradient Lipschitz \Rightarrow gradientul proiectat pe primala converge liniar!

- ▶ In multe aplicatii inasa, proiectia pe multimea fezabila $U = \{u : Au \leq 0\}$ este prea complexa \Rightarrow abordam problema duala in loc de problema primala:

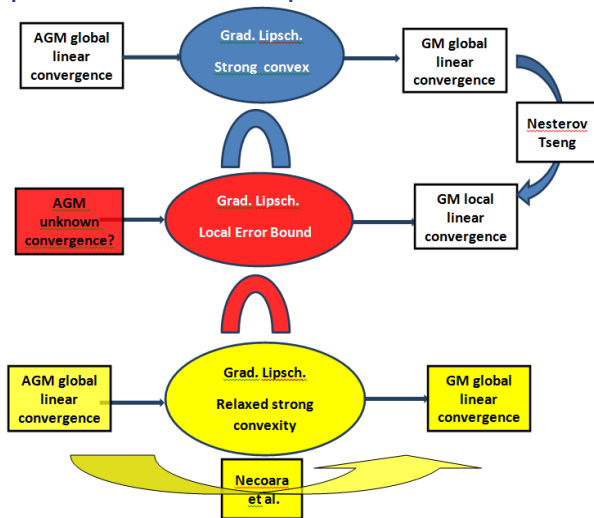
$$\max_x -\tilde{g}(-A^T x) - \Psi(x),$$

unde \tilde{g} este conjugata convexa a lui g iar $\Psi(x) = \mathbf{I}_{\mathbb{R}_+^n}(x)$.

- ▶ Daca $g(x)$ tare convexa si cu gradient Lipschitz, atunci problema duala va satisface (GEB) global

Theorema: sub (GEB) gradientul clasic converge liniar!

Recap: raspunsuri la cateva probleme deschise



- Condițiile de relaxare a convexității tari conțin clase cunoscute de probleme + altele noi cu multe implicații în aplicații reale
⇒ convergența liniară pt. GM/AGM

Aplicatia 1: rezolvarea sistemelor liniare

Matrice simetrica pozitiv semidefnita $Q \succeq 0$ si sistemul:

$$Qx + q = 0 \quad \Leftrightarrow \quad \min_{x \in \mathbb{R}^n} f(x) \quad =: \quad \frac{1}{2}x^T Qx + q^T x$$

Daca consideram descompunerea Cholesky $Q = L_Q^T L_Q$, atunci:

$$f(x) = \frac{1}{2} \|L_Q x\|^2 + (L_Q^T L_Q x_s)^T x = g(L_Q x)$$

unde $g(z) = \frac{1}{2} \|z\|^2 + (L_Q x_s)^T z$ functie tare convexa!

Teorema. Functia f satisface TC1 cu $\sigma_1 = \lambda_{\min}(Q)$ (cea mai mica valoare proprie nenula a lui Q).

- ▶ Teoria dezvoltata permite rezolvarea sistemului cu acuratete ϵ in $\sqrt{\text{cond}(Q)} \log \frac{1}{\epsilon}$ iteratii de metoda gradient accelerat.
- ▶ Gradientul conjugat are aceeasi complexitate dar pentru matrici $Q \succ 0$! Pentru $Q \succeq 0$ exista rezultate???
- ▶ Alte rezultate din literatura au complexitate $\text{cond}(Q) \log \frac{1}{\epsilon}$.
- ▶ Extensie imediata la cazul general $Ax = b$ cu $A \in \mathbb{R}^{m \times n}$ utilizand $f(x) = \|Ax - b\|^2$.

Aplicatia 2: Programare liniara

Fie problema de programare liniara:

$$(LP) : \min_u c^T u \quad \text{s.t. :} \quad Eu = b, u \geq 0.$$

Considerand formularea primala-duala obtinem sistemul liniar:

$$\begin{cases} Ax = d \\ x \in \mathbf{K} = \mathbb{R}_+^n \times \mathbb{R}^m \times \mathbb{R}_+^n, \end{cases}$$

$$\text{unde } x = \begin{bmatrix} u \\ v \\ s \end{bmatrix}, \quad A = \begin{bmatrix} 0 & E^T & I_n \\ E & 0 & 0 \\ c^T & -b^T & 0 \end{bmatrix}, \quad d = \begin{bmatrix} c \\ b \\ 0 \end{bmatrix}.$$

LP echivalenta cu urmatoarea problema QP cu structura:

$$\min_{x \in \mathbf{K}} \|Ax - d\|^2.$$

Teorema. Functia f satisface TC1 si deci teoria dezvoltata permite rezolvarea problemelor de programare liniara in $\log \frac{1}{\epsilon}$ iteratii de metoda gradient accelerat (operatii matrice-vector).

Aplicatia 3: optimizare in sisteme retelizate

- ▶ In multe aplicatii, e.g. controlul sistemelor retelizate, data ranking sau procesare imagine, avem un sistem format din mai multe **entitati interconectate**
- ▶ Interconexiunea dintre sisteme se denota printr-un **graf bipartit**:

$G = ([N] \times [\bar{N}], E)$, unde $[N] = \{1, \dots, N\}$, $[\bar{N}] = \{1, \dots, \bar{N}\}$
iar $E \in \{0, 1\}^{N \times \bar{N}}$ este o matrice de incidenta

- ▶ Introducem conceptul de sisteme vecine:

$$\mathcal{N}_j = \{i \in [N] : E_{ij} = 1\} \quad \forall j \in [\bar{N}]$$

$$\bar{\mathcal{N}}_i = \{j \in [\bar{N}] : E_{ij} = 1\} \quad \forall i \in [N].$$

- ▶ Multimile \mathcal{N}_j si $\bar{\mathcal{N}}_i$, reprezinta e.g. multimea surselor ce **impart link-ul** $j \in [\bar{N}]$, respectiv **link-urile utilizate de sursele** $i \in [N]$

Aplicatia 3: optimizare in sisteme retelizate

- ▶ Sub un sistem retelizat, multe probleme din practica pot fi formulate drept probleme composite partial separabile:

$$F^* = \min_{x \in \mathbb{R}^n} F(x) \quad \left(= \sum_{j=1}^{\bar{N}} f_j(x_{\mathcal{N}_j}) + \sum_{i=1}^N \psi_i(x_i) \right)$$

- ▶ In mod obisnuit se considera componenta smooth a functiei $F(x)$ are proprietate de **gradient Lipschitz pe coordonate**:

$$\|\nabla_i f(x + U_i y_i) - \nabla_i f(x)\| \leq L_i \|y_i\| \quad \forall x \in \mathbb{R}^n, y_i \in \mathbb{R}^{n_i}$$

- ▶ Noi consideram inasa ca **functiile individuale** $f_j(x)$ au gradient Lipschitz:

$$\|\nabla f_j(x_{\mathcal{N}_j}) - \nabla f_j(y_{\mathcal{N}_j})\| \leq L_{\mathcal{N}_j} \|x_{\mathcal{N}_j} - y_{\mathcal{N}_j}\| \quad \forall x_{\mathcal{N}_j}, y_{\mathcal{N}_j} \in \mathbb{R}^{n_{\mathcal{N}_j}}.$$

Aplicatia 3: problema Lasso

- ▶ Problema Lasso constransa (utilizata in reconstructie de semnale, etc):

$$\min_{x_i \in X_i \subseteq \mathbb{R}^{n_i}} F(x) \quad \left(= \frac{1}{2} \|Ax - b\|^2 + \sum_{i=1}^N \lambda_i \|x_i\|_1 \right),$$

Aceasta problema poate fi scrisa sub forma **composite separabila**:

- ▶ $\Psi(x) = \sum_{i=1}^N [\lambda_i \|x_i\|_1 + \mathbf{1}_{X_i}(x_i)]$ **separabila**
- ▶ $f_j(x_{\mathcal{N}_j}) = \frac{1}{2} (a_{\mathcal{N}_j}^T x_{\mathcal{N}_j} - b_j)^2$, unde $a_{\mathcal{N}_j} \rightarrow$ reprezinta vectorul format din **componentele nenule ale liniei** j a lui A , corespunzand unei multimi \mathcal{N}_j .
- ▶ **Theorema**: Problema Lasso satisface (**GEB**) daca X_i politop si deci o putem rezolva cu complexitate liniara prin metoda gradient (accelerat).

Aplicatia 3: duala

- ▶ Unele probleme din practica (NUM, DC-OPF) pot fi formulate:

$$f^* = \min_{u: Au \leq b} \sum_{j=1}^{\bar{N}} g_j(u_j)$$

unde g_j sunt tari convexe cu constantele σ_j . Drept rezultat, conjugatele convexe \tilde{g}_j au gradient Lipschitz cu $L_j = \frac{1}{\sigma_j}$.

- ▶ Duala problemei originale are forma:

$$f^* = \max_{x \in \mathbb{R}^n} \sum_{j=1}^{\bar{N}} -\tilde{g}_j(-A_j^T x) - \langle x, b \rangle - \Psi(x),$$

unde $\Psi(x) = \mathbf{I}_{\mathbb{R}_+^n}(x)$.

- ▶ Daca luam $f_j(x_{\mathcal{N}_j}) = -\tilde{g}_j(-A_{\mathcal{N}_j}^T x_{\mathcal{N}_j}) - \langle x_{\mathcal{N}_j}, \bar{b}_{\mathcal{N}_j} \rangle$ atunci problema dual **satisface (GEB)** si poate fi rezolvata cu complexitate liniara.

Concluzii finale

- ▶ Relaxam conditia de convexitate tare; relaxare ce conduce la probleme de optimizare des intalnite in practica (sisteme liniare, lasso, duala, optimizare in retele): $g(Ax)$
- ▶ Derivam clase mai generale de probleme de optimizare pentru care metode de tip gradient converg liniar
- ▶ Aratam ca si gradientul accelerat converge liniar pe aceste clase de probleme

Mulumesc colaboratorilor:

Yu. Nesterov

F. Glineur

D. Clipici

Mai multe detalii pe pagina mea web:

<http://acse.pub.ro/person/ion-necoara>

Intrebari?