



ACADEMIA ROMÂNĂ
SCOSAAR

REZUMATUL TEZEI DE ABILITARE

Optimizare Stochastică

Domeniul de abilitare: Matematică

Ion Necoară

Rezumat

0.1 Contribuțiile acestei teze

Considerăm spațiul Euclidian \mathbb{R}^n , înzestrat cu produsul scalar $\langle x, y \rangle = x^T y$ și norma corespunzătoare $\|x\| = \sqrt{\langle x, x \rangle}$ ¹. Problemele de optimizare considerate în aceasta teză sunt versiuni ale următoarei probleme stochastice, având funcția obiectiv exprimată ca medie a doi termeni:

$$\min_{x \in \text{dom} F} F(x) := \mathbf{E} [f(x, \xi) + g(x, \xi)], \quad (1)$$

unde ξ este o variabilă aleatoare peste un spațiu de probabilitate $(\Omega, \mathcal{F}, \mathbf{P})$. De asemenea, funcțiile $f : \mathbb{R}^n \times \Omega \rightarrow \bar{\mathbb{R}}$ și $g : \mathbb{R}^n \times \Omega \rightarrow \bar{\mathbb{R}}$ sunt proprii, inferior semicontinue și convexe în primul argument. Incertitudinile din majoritatea aplicațiilor practice de optimizare au determinat ca optimizarea stochastică să devină un instrument esențial pentru multe domenii din matematica aplicată, cum ar fi învățarea automată și statistică, control și procesarea semnalului, rețele de senzori și altele. Principala caracteristică a problemei (1) este faptul că nu putem evalua (sub)gradientul $\nabla F(x)$ al funcției F într-un punct $x \in \text{dom} F$, adică nu avem acces la subdiferențiala $\partial F(x)$. Pe de altă parte, pentru o realizare dată $\hat{\xi}$ a variabilei aleatoare ξ , putem accesa $f(x, \hat{\xi}), g(x, \hat{\xi})$ și respectiv (sub)gradienții $\nabla f(x, \hat{\xi}), \nabla g(x, \hat{\xi})$. În această teză presupunem că (sub)gradienții $\nabla f(x, \hat{\xi}), \nabla g(x, \hat{\xi})$ sunt estimatori imparțiali:

$$\mathbf{E} [\nabla f(x, \xi) + \nabla g(x, \xi)] \in \partial F(x).$$

De notat este faptul că această problema de optimizare (1) este foarte generală și apare în multe aplicații din inginerie, statistică și învățare automată.

Un caz particular al problemei stochastice (1) este $g \equiv 0$ și $F(x) = \mathbf{E} [f(x, \xi)]$. Aceasta este problema uzuală întâlnită în aplicațiile de învățare automată. În acest caz, cel mai utilizat algoritm pentru rezolvarea acestei probleme este stochastic gradient descent (SGD) propus de Robbins și Monro²:

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

unde ξ_k este o realizare a variabilei aleatoare ξ (adică un eșantion $\xi_k \sim \mathbf{P}$) și pentru a garanta convergența acestui proces stochastic iterativ pasul α_k trebuie ales de forma

$$\alpha_k = \frac{\alpha_0}{k^\gamma}, \quad \text{unde } \alpha_0 > 0 \text{ și } \gamma \in [0, 1].$$

În general, SGD converge lent și de aceea accelerarea acestui algoritm este una din principalele direcții de cercetare, mai ales în contextul actual de Big Data. Experimental, s-a observat că accelerarea convergenței metodei SGD se poate realiza folosind minibatch (mai multe eșantioane):

$$x_{k+1} = x_k - \alpha_k \frac{1}{|J_k|} \sum_{\xi \in J_k} \nabla f(x_k, \xi),$$

¹Majoritatea rezultatelor prezentate în această teză se pot extinde și la spații mai generale.

²H. Robbins and S. Monro, A stochastic approximation method, The Annals of Mathematical Statistics, 1951.

unde mulțimea de eșantioane $J_k \subset \Omega$ are cardinalitatea $|J_k| > 1$. Însă, această iterație nu accelerează convergența către punctul de optim dincolo de o anumită valoare a dimensiunii minibatch-ului, așa cum se observă din Figura 1³. În particular, pentru dimensiuni mari ale minibatch-ului avem nevoie de un număr mare de epoci (iterații), rezultând complexitate totală mare. Așadar, o problemă deschisă în literatura de optimizare stochastică este identificarea condițiilor pentru care avem garanții matematice ca minibatch-ul accelerează convergența și găsirea mărimii optime a minibatch-ului (numărul optim de eșantioane necesare la fiecare iterație).




Figure 1: Compartamentul metodei SGD în funcție de dimensiunea minibatch-ului.

În aceasta teză rezolvăm (parțial) această problemă, analizând versiuni minibatch al algoritmului Kaczmarz, în Capitolul 3 (amintim că algoritmul Kaczmarz coincide cu SGD atunci când rezolvăm problema celor mai mici pătrate liniară), continuând cu algoritmi de proiecție stochastică pentru problema de fezabilitate convexă, în Capitolul 4 și în Capitolul 5 și terminând cu un algoritm de tip stochastic subgradient pentru probleme de optimizare cu multe constrângeri, în Capitolul 7.

În particular, în Capitolul 3, demonstrăm că algoritmul Kaczmarz, în care proiectăm simultan pe mai multe linii din matricea sistemului, converge liniar, având o rată de convergență care depinde de proprietățile geometrice ale submatricilor sistemului liniar pe care proiectăm și de dimensiunea lor (minibatch). Mai mult, analiza noastră de convergență arată că acest algoritm este eficient atunci când facem o eșantionare a liniilor matricei sistemului în submatrici bine condiționate și ne permite, de asemenea, să identificăm dimensiunea optimă a minibatch-ului.

În Capitolul 4, prezentăm o familie de metode de proiecție stochastică pentru a rezolva probleme de fezabilitate convexă, exprimate în termeni de intersecție (posibil infinită) de mulțimi convexe simple. Demonstrăm, sub anumite ipoteze de regularitate, că aceste metode au convergență liniară, cu o rată de convergență ce depinde de dimensiunea eșantionului de mulțimi considerat la fiecare iterație și de o constantă ce are o interpretare naturală ca număr de condiționare al problemei de fezabilitate. Am identificat constanta Lipschitz a problemei de fezabilitate ca parametru cheie care determină dacă minibatch-ul ajută la accelerarea convergenței, precum și cât de mult contribuie. În Capitolul 5, extindem aceste rezultate la probleme de fezabilitate convexă, unde fiecare mulțime din intersecție este descrisă de o funcție convexă Lipschitz. În acest caz, algoritmul nu presupune proiecții pe mulțimi individuale, ci un pas de subgradient pentru una din funcții. Din cunoștințele noastre, acestea sunt primele rezultate care determină teoretic condițiile pentru care metodele de proiecție stochastică de tip minibatch au o complexitate mai bună decât variantele lor bazate pe un singur eșantion.

³Preluată din Yin et al. 2018.

În Capitolul 7, considerăm probleme de optimizare cu multe constrângeri (posibil o infinitate) definite explicit cu ajutorul unor funcții convexe Lipschitz. Pentru aceste probleme generale, am propus un algoritm stochastic de tip subgradient urmat de un pas de fezabilitate care utilizează doar subgradienții unui eșantion de funcții care definesc mulțimea fezabilă. La fiecare iterație, algoritmul face un pas de subgradient, menit să minimizeze funcția obiectiv, și apoi un pas de subgradient care minimizează încălcarea fezabilității eșantionului (minibatch-ului) de constrângeri observat. Derivăm rate de convergență liniară pentru acest algoritm care depind în mod explicit de dimensiunea minibatch-ului și arătăm când minibatch-ul ajută o schemă de subgradient cu actualizări aleatorii de fezabilitate.

Pe de altă parte, analiza de convergență pentru SGD a fost dată pentru modele de optimizare simple, care satisfac ipoteze restrictive și pentru care ratele de convergență sunt în general subliniare și au loc doar pentru alegeri foarte specifice și descrescătoare ale pasului. De exemplu, în literatura convexă, analiza de convergență a metodei SGD pentru cazul funcțiilor obiectiv Lipschitz este diferită de cea a funcțiilor cu gradient continuu Lipschitz, deși ratele de convergență sunt la fel pentru ambele cazuri. De asemenea, analiza SGD-ului a fost derivată doar pentru cazul $g \equiv 0$. Însă, în multe aplicații practice apar constrângeri sau termeni de regularizare care conduc la o problemă de optimizare de forma (1), adică $g \neq 0$. Extensia analizei convergenței algoritmului SGD la cazuri mai generale, de exemplu pentru formularea (1), nu a fost făcută încă. De aceea, în partea a doua a acestei teze, extindem analiza de convergență a algoritmului SGD pentru problema de optimizare generală (1).

Mai întâi, extindem analiza convergenței metodei SGD la cazul problemelor de optimizare cu multe constrângeri exprimate, fie prin mulțimi convexe (Capitolul 6), fie prin funcții convexe (Capitolul 7), posibil într-un număr infinit. În acest caz, g în (1) reprezintă funcția indicator a unei mulțimi din familia de mulțimi care definește mulțimea fezabilă. De asemenea, deși SGD este un algoritm ușor de implementat și cu performanțe practice bune în anumite circumstanțe, studii recente arată că această metodă este instabilă și sensibilă față de anumite alegeri ale parametrilor, de exemplu constanta de convexitate tare. De aceea, analizăm și o versiune mai generală a metodei SGD, numită stochastic proximal point (SPP) în Capitolul 6. Din ratele de convergență derivate în Capitolul 6 pentru ambele cazuri, funcții convexe Lipschitz și cu gradient Lipschitz, se poate observa că SPP este, în general, atât mai robust la alegerea parametrilor, cât și cu performanțe mai bune față de SGD.

În Capitolul 8, prezentăm un cadru teoretic pentru analiza metodelor stochastice de ordinul întâi (SGD și SPP) pentru problema generală (1). Analiza noastră se bazează pe o ipoteză nouă asupra funcției obiectiv pe care am numit-o condiția de mărginire a gradientului stochastic. Această condiție include obișnuitele clase de funcții analizate în literatură, funcții Lipschitz și funcții cu gradient Lipschitz, și ne permite să derivăm o analiză de convergență comună pentru metodele stochastice bazate pe (sub)gradienți. În plus, ratele noastre de convergență sunt optime pentru această clasă de probleme.

În ultimul capitol prezentăm câteva direcții de cercetare pe care dorim să le abordăm în viitor.

În final, menționăm că toți algoritmi prezentați în această teză au fost testați numeric pe aplicații concrete, folosind date sintetice sau reale, și comparați cu alți algoritmi din literatură. Rezultatele numerice, fie le confirmă pe cele teoretice, fie arată performanțe superioare ale metodelor noastre.

0.2 Articole în reviste ISI

Rezultatele prezentate în aceasta teză au fost publicate sau acceptate spre publicare în reviste ISI de top. Prezentăm mai jos lista de publicații din ultimii 3 ani, pe care se bazează această teză.

- **I. Necoara**, *Faster randomized block Kaczmarz algorithms*, Siam Journal on Matrix Analysis and Applications, vol. 40, nr. 4, 1425–1452, 2019 (Q1 if/ais - Applied Mathematics).
- **I. Necoara**, P. Richtarik, A. Patrascu, *Randomized projection methods for convex feasibility problems: Conditioning and convergence rates*, Siam Journal on Optimization, vol. 29, nr. 4, 2814–2852, 2019 (Q1 if/ais - Applied Mathematics).
- **I. Necoara**, A. Nedich, *Minibatch stochastic subgradient-based projection algorithms for solving convex inequalities*, partially accepted in Computational Optimization and Applications, 2020 (Q1 if/ais - Applied Mathematics).
- A. Nedich, **I. Necoara**, *Random minibatch subgradient algorithms for convex problems with functional constraints*, Applied Mathematics and Optimization, vol. 80, nr. 3, 801–833, 2019 (Q1 if/ais - Applied Mathematics).
- A. Patrascu, **I. Necoara**, *Nonasymptotic convergence of stochastic proximal point methods for constrained convex optimization*, Journal of Machine Learning Research, vol. 18, no. 198, 1–42, 2018 (Q1 if/ais - Automation & Control Systems).
- **I. Necoara**, *General convergence analysis of stochastic first order methods for composite optimization*, Journal of Optimization Theory and Applications, doi: 10.1007/s10957-021-01821-2, 2021 (Q2 if/ais - Applied Mathematics).

La două din lucrările de mai sus sunt unic autor, altele două au fost scrise în colaborare cu un fost student de la doctorat (A. Patrascu) și două lucrări sunt în colaborare cu prof. A. Nedich de la Arizona State University (SUA).