

PROBLEME DESCHISE ÎN ALGORITMI DE GRADIENT CONJUGAT PENTRU OPTIMIZARE FĂRĂ RESTRICȚII

Centenar Eduard Stiefel (1909-1978)

Neculai Andrei

*Institutul Național de Cercetare – Dezvoltare în Informatică, ICI, București
Academia Oamenilor de Știință din România, București*

Rezumat. Lucrarea prezintă câteva probleme deschise în algoritmi de gradient conjugat pentru optimizare fără restricții. Acestea se referă la direcția inițială de căutare, condiția de conjugare, calculul lungimii pașilor de deplasare, noi formule pentru parametrul de conjugare, bazate pe valorile funcției de minimizat, influența acurateții procedurii de căutare liniară, cum se poate introduce structura problemei în algoritmi de gradient conjugat, cum se poate considera informația de ordinul doi în acești algoritmi, care este cea mai bună procedură de restartare, care este cel mai bun algoritm de gradient conjugat hibrid, algoritmi de gradient conjugat scalat, care este cel mai bun criteriu de oprire a iterațiilor în acești algoritmi etc.

Cuvinte cheie: Gradient conjugat, condiția de conjugare, restartare, informația de ordinul doi, structură, gradient conjugat hibrid, scalare.

Abstract. The paper presents some open problems associated to the nonlinear conjugate gradient algorithms for unconstrained optimization. Mainly, these problems refer to the initial direction, the conjugacy condition, the steplength computation, new formula for conjugate gradient parameter computation based on function's values, the influence of accuracy of line search procedure, how we can take the problem's structure on conjugate gradient algorithms, how we can consider the second order information in these algorithms, what the best restart procedure is, what the best hybrid conjugate gradient algorithm is, scaled conjugate gradient algorithms, what the best stopping criterion in conjugate gradient algorithms is etc.

Keywords: Conjugate gradient, conjugacy condition, restart, second order information, structure, hybrid conjugate gradient, scaling.

1. Introducere

Metodele de gradient conjugat reprezintă o contribuție importantă în panoplia metodelor de optimizare fără restricții de mari dimensiuni. Algoritmii asociați acestor metode sunt caracterizați de cerințe modeste de memorie și au proprietăți foarte bune de convergență globală. Popularitatea lor este datorată în parte simplității expresiei lor algebrice, implementării foarte rapide și ușoare în programe de calcul, precum și eficienței lor în rezolvarea problemelor cu un număr mare de variabile.

Metodele de gradient conjugat au fost proiectate de Magnus Hestenes (1906-1991) și Eduard Stiefel (1909-1978) în lucrarea *Methods of conjugate gradients for solving linear systems*, J. Research Nat. Bur. Standards Sec. B. 48, 409-436 (1952) în care au prezentat un algoritm pentru rezolvarea sistemelor algebrice liniare, cu matricea simetrică și pozitiv definită. În 1964, metoda a fost extinsă de Fletcher și Reeves la probleme de optimizare neliniară fără restricții. De atunci, un număr foarte mare de algoritmi de gradient conjugat au fost elaborați. Chiar dacă algoritmi de gradient conjugat au peste 50 de ani de existență, totuși aceștia continuă să fie de un considerabil interes în particular datorită proprietăților lor de convergență și eficienței în rezolvarea problemelor de optimizare de mari dimensiuni. O scurtă schiță istorică este foarte interesantă.



Eduard Stiefel (1909-1978)

au elaborat aceeași metodă. Hestenes a numit-o metoda de gradient conjugat și a publicat-o ca un raport intern: *Iterative methods for solving equations*. NAML Report 52-9, National Bureau of Standards, Los Angeles, CA, July 1951. În timpul acestei vizite, Hestenes și Stiefel și-au combinat eforturile reușind să

Istoria acestei metode începe cu cercetările lui Eduard Stiefel la Eidgenössische Technische Hochschule Zürich - Swiss Federal Institute of Technology, și Cornelius Lanczos (1893-1974) și Magnus Hestenes (1906-1991) la The Institute for Numerical Analysis (National Applied Mathematics Laboratories of the United States National Bureau of Standards in Los Angeles). În 1951, Eduard Stiefel a proiectat o metodă în n -pași pentru rezolvarea sistemelor algebrice liniare cu matricea simetrică și pozitiv definită, pe care a publicat-o ca *Über einige Methoden der Relaxationsrechnung*. Z. Angew. Math. Phys., 3 (1952), pp. 1-33. În iulie 1951, invitat de Olga Taussky-Todd (1906-1995), Stiefel a vizitat Institutul pentru Analiză Numerică (INA) de la Biroul Național de Standarde – UCLA, Los Angeles, până în februarie 1952. Aici, a găsit că Magnus Hestenes în colaborare cu alți cercetători de la INA (Lanczos, Forsythe, Motzkin, Rosser, Stein)

publice lucrarea de 28 de pagini pe două coloane: *Methods of Conjugate Gradients for Solving Linear Systems* în Journal of Research of the National Bureau of Standards, vol.49, No. 6, December 1952 (Research Paper 2379), fiind una dintre cele mai influente lucrări în domeniul analizei numerice. Anumite detalii și precizări asupra acestei lucrări au fost aduse de Dianne P. O'Leary [O'Leary, D.P., *Conjugate gradients and related KMP algorithms: the beginnings*. in Linear and Nonlinear Conjugate Gradient – Related Methods, L. Adams and J.L. Nazareth (Eds.) SIAM, 1996, pp. 1-8]. Din acel moment, au fost elaborate peste 50 de variante de algoritmi de gradient conjugat și practic un număr nesfârșit de lucrări au fost publicate în legătură cu această metodă. O privire generală de ansamblu asupra acestei metode a fost dată de Hager și Zhang [40].

Pentru problema generală de optimizare fără restricții

$$\min_{x \in R^n} f(x), \quad (1.1)$$

unde $f: R^n \rightarrow R$ este o funcție continuu diferențiabilă, mărginită inferior, un algoritm de gradient conjugat

plecând dintr-un punct inițial x_0 dat, generează un șir de puncte $\{x_k\}$, conform formulei iterative:

$$x_{k+1} = x_k + \alpha_k d_k, \quad (1.2)$$

unde α_k este lungimea pasului de obicei calculată din condițiile de căutare liniară Wolfe,

$$f(x_k + \alpha_k d_k) - f(x_k) \leq \rho \alpha_k g_k^T d_k, \quad (1.3)$$

$$g_{k+1}^T d_k \geq \sigma g_k^T d_k, \quad (1.4)$$

în care $0 < \rho < 1/2 \leq \sigma < 1$, iar direcțiile d_k sunt calculate ca:

$$d_{k+1} = -g_{k+1} + \beta_k s_k, \quad d_0 = -g_0. \quad (1.5)$$

Aici, β_k este un scalar cunoscut ca parametrul algoritmului de gradient conjugat, $g_k = \nabla f(x_k)$ și $s_k = x_{k+1} - x_k$. În cele ce urmează definim $y_k = g_{k+1} - g_k$. Diferiți algoritmi de gradient conjugat corespund la diferite alegeri ale parametrului β_k . Deci, un element crucial în orice algoritm de gradient conjugat este formula de definiție a parametrului β_k . Orice algoritm de gradient conjugat are o structură foarte simplă, ilustrată ca mai jos.

Prototipul Algoritmului de Gradient Conjugat

<i>Pasul 1.</i>	Se selectează un punct inițial $x_0 \in \text{dom } f$ și se calculează: $f_0 = f(x_0)$ și $g_0 = \nabla f(x_0)$. Se pune $d_0 = -g_0$ și $k = 0$.
<i>Pasul 2.</i>	Se testează un criteriu de oprire a iterațiilor. De exemplu, dacă $\ g_k\ _\infty \leq \varepsilon$, atunci stop; altfel se continuă cu pasul 3.
<i>Pasul 3.</i>	Se determină lungimea pasului α_k .
<i>Pasul 4.</i>	Se actualizează variabilele ca: $x_{k+1} = x_k + \alpha_k d_k$. Se calculează f_{k+1} și g_{k+1} . Se calculează $y_k = g_{k+1} - g_k$ și $s_k = x_{k+1} - x_k$.
<i>Pasul 5.</i>	Se determină β_k .
<i>Pasul 6.</i>	Se calculează direcția de deplasare: $d_{k+1} = -g_{k+1} + \beta_k s_k$.
<i>Pasul 7.</i>	Criteriul de restartare a iterațiilor. De exemplu, dacă criteriul de restartare a iterațiilor al lui Powell $ g_{k+1}^T g_k > 0.2 \ g_{k+1}\ ^2$ este satisfăcut, atunci se pune $d_{k+1} = -g_{k+1}$.
<i>Pasul 8.</i>	Se calculează estimăția inițială a lungimii pasului, de exemplu $\alpha_k = \alpha_{k-1} \ d_{k-1}\ / \ d_k\ $, se pune $k = k + 1$ și se continuă cu pasul 2. ♦

Acesta este un prototip de algoritm de gradient conjugat, dar se cunosc variante mult mai sofisticate (CONMIN [51], [52], SCALCG [3], [4], [5], [6], ASCALCG [5], [19], ACGHES [18], [21], CG_DESCENT [39]). Aceste variante se concentrează pe proceduri de calcul ale parametrului β_k și a lungimii pasului α_k .

2. Probleme deschise

În cele ce urmează, vom prezenta 14 probleme deschise în algoritmi de gradient conjugat [20]. Aceste probleme se referă la o serie de aspecte teoretice și computaționale ale acestor algoritmi și, în acest context, constituie direcții de cercetare în acest domeniu.

Problema 1. De ce direcția inițială de căutare $d_0 = -g_0$ este esențială în algoritmi de gradient conjugat?

Crowder și Wolfe [29] au prezentat un exemplu de funcție pătratică tare convexă cu 3 variabile arătând că, dacă direcția inițială nu este direcția pasului descendent, atunci rata de convergență a algoritmului de gradient conjugat este liniară. Pe de altă parte, Beale [25] a arătat că, dacă

$$d_{k+1} = -g_{k+1} + \frac{y_0^T g_{k+1}}{y_0^T d_0} d_0 + \frac{g_{k+1}^T g_{k+1}}{g_k^T g_k} d_k \quad (2.1)$$

atunci dacă $d_0 \neq -g_0$, atunci direcțiile astfel calculate sunt conjugate. Deci, (2.1) permite să se obțină direcții conjugate plecând din orice direcție inițială d_0 . Totuși, deoarece d_0 rămâne în formula lui d_{k+1} acesta poate crea dificultăți în ceea ce privește viteza de convergență [34].

Mai târziu, Powell [49] a arătat că, dacă $f(x)$ este o funcție pătratică, atunci utilizând o direcție inițială arbitrară d_0 algoritmi de gradient conjugat au o rată de convergență liniară. Nazareth [45] a sugerat un algoritm de gradient conjugat ceva mai complicat în care direcția d_{k+1} este calculată sub forma:

$$d_{k+1} = -y_k + \frac{y_k^T y_k}{y_k^T d_k} d_k + \frac{y_{k-1}^T y_k}{y_{k-1}^T d_{k-1}} d_{k-1}, \quad (2.2)$$

unde $d_0 = 0$. Nazareth a demonstrat că, dacă $f(x)$ este o funcție pătratică convexă, atunci pentru orice lungime a pasului α_k direcțiile de căutare sunt conjugate în raport cu Hessianul lui f . Totuși, departe de minim, dacă $d_0 \neq -g_0$, atunci d_k poate deveni zero. Deși interesantă, această inovație nu s-a dovedit eficientă în practică. O altă abordare care permite direcții inițiale d_0 arbitrare pentru cazul funcțiilor pătratice a fost sugerată de Allwright [1] care a utilizat o schimbare de variabilă bazată pe o factorizare a Hessianului funcției f . Observăm că toate aceste observații sunt făcute numai pentru funcții pătratice, pentru funcții generale nu avem nici un răspuns la această problemă.

Problema 2. Care este cea mai bună condiție de conjugare?

Condiția de conjugare este exprimată ca $y_k^T d_{k+1} = 0$. Recent, Dai și Liao [30] au introdus o nouă condiție de conjugare sub forma $y_k^T d_{k+1} = -t s_k^T g_{k+1}$, unde $t \geq 0$ este un scalar. Această nouă condiție de conjugare este foarte rezonabilă deoarece în practică se utilizează căutarea liniară inexactă. Totuși, această condiție este dependentă de parametrul t , pentru care nu cunoaștem încă o formulă de calcul optimă.

Problema 3. De ce în algoritmi de gradient conjugat șirul $\{\alpha_k\}$ ale lungimii pasului au o evoluție total nepredictibilă și diferă de 1 cu până la două ordine de mărime?

Studii numerice intensive, cu diferite variante de algoritmi de gradient conjugat, au arătat că lungimea pasului de deplasare α_k diferă de 1 cu până la două ordine de mărime, în funcție de cum este scalată problema. Mai mult, mărimea pasului are o evoluție total nepredictibilă. Această comportare a algoritmilor de gradient conjugat este foarte diferită de aceea a metodei Newton sau a metodelor quasi-Newton, care, de obicei, admit lungimi unitare ale lungimii pasului în majoritatea iterațiilor finale ale procesului de optimizare. Studiile computaționale cu metoda quasi-Newton cu memorie limitată LBFGS arată că aceasta este foarte eficientă mai ales datorită abilității ei de a accepta lungimi unitare ale lui α_k . O încercare de a utiliza această comportare a algoritmilor de gradient conjugat a fost prezentată

de Andrei [13], care a sugerat o procedură de accelerare a acestor algoritmi prin modificarea lungimii α_k a pasului (calculată din condițiile Wolfe) prin intermediul unui parametru η_k , într-o manieră multiplicativă de tipul, $x_{k+1} = x_k + \eta_k \alpha_k d_k$, cu scopul de reducere a valorilor funcției de minimizat de-a lungul iterațiilor. Se demonstrează că schema de accelerare este liniar convergentă. Comparații numerice cu această schemă de accelerare sunt prezentate în [19]. O accelerare a algoritmului pasului descendent cu backtracking pentru optimizare fără restricții este dată în [2].

Problema 4. Care este influența acurateței procedurii de căutare liniară de determinare a lungimii pasului α_k asupra performanțelor algoritmilor de gradient conjugat?

Pentru orice algoritm de optimizare fără restricții, un element crucial este procedura de calcul a lungimii pasului de deplasare. În acest sens, s-au propus numeroase proceduri. În căutarea liniară exactă, lungimea α_k a pasului se calculează ca soluție a problemei

$$\alpha_k = \arg \min_{\alpha > 0} f(x_k + \alpha d_k), \quad (2.3)$$

unde d_k este o direcție descendentă. În anumite cazuri speciale (probleme pătratice, de exemplu) este posibil ca α_k să fie calculat analitic, dar pentru vasta majoritate a problemelor α_k se calculează pentru a reduce valorile funcției f de-a lungul razei $\{x_k + \alpha d_k : \alpha \geq 0\}$. În practică, cele mai uzitate sunt

procedurile inexacte de calcul ale lui α_k . O multitudine de astfel de proceduri au fost propuse: Goldstein [36], Armijo [24], Wolfe [54], Powell [49], Dennis și Schnabel [33], Potra și Shi [48], Lemaréchal [43], Moré și Thuente [44], Hager și Zhang [39] și multe altele. Cele mai utilizate sunt bazate pe condițiile Wolfe (1.3) și (1.4). O contribuție importantă în înțelegerea condițiilor Wolfe a fost dată de Hager și Zhang [39], [40], prin introducerea condițiilor Wolfe aproximative

$$(2\rho - 1)g_k^T d_k \geq g_{k+1}^T d_k \geq \sigma g_k^T d_k, \quad (2.4)$$

Prima inegalitate din (2.4) este o aproximație a primei condiții Wolfe (1.3). Când iterațiile sunt lângă punctul de optim, aceste aproximații date de (2.4) se pot evalua cu o acuratețe mai mare decât condițiile Wolfe originale, deoarece condițiile Wolfe aproximative sunt exprimate în termenii derivatei, și nu ca diferențe ale valorilor funcției. Subliniem faptul că prima condiție Wolfe (1.3) limitează acuratețea algoritmului de gradient conjugat la ordinul de mărime dat de rădăcina pătrată a preciziei mașinii, în timp ce condițiile Wolfe aproximative (2.4) realizează o acuratețe de ordinul preciziei mașinii [39]. Se pare că, cu cât lungimea pasului de deplasare este calculată cu o acuratețe mai mare, cu atât convergența algoritmului de gradient conjugat este mai pronunțată. De exemplu, algoritmul CG_DESCENT al lui Hager și Zhang [39] este unul dintre cei mai rapizi algoritmi de gradient conjugat. Totuși, impunând atât condiția de descendență, cât și pe cea de conjugare, și utilizând condițiile Wolfe originale (1.3) și (1.4), Andrei [22] a sugerat un alt algoritm de gradient conjugat accelerat mai rapid decât CG_DESCENT. În acest context, o altă chestiune deschisă interesantă este dacă sau nu căutarea liniară nemonotonă a lui Grippo, Lampariello și Lucidi, [38] este mai bună decât căutarea liniară Wolfe.

Problema 5. Cum se pot utiliza valorile funcției f în formula de calcul a parametrului β_k pentru a genera noi algoritmi eficienți de gradient conjugat?

În general, în algoritmii de gradient conjugat parametrul β_k este calculat utilizând scalarii: $\|g_k\|$, $\|g_{k+1}\|$, $\|y_k\|$, $\|s_k\|$, $y_k^T s_k$, $g_k^T g_{k+1}$, $y_k^T g_{k+1}$ și $s_k^T g_{k+1}$. După cum se vede în formula pentru β_k diferența $f(x_k) - f(x_{k+1})$ nu este utilizată. Yabe și Takano [55], utilizând un rezultat al lui Zhang, Deng și Chen [57], au sugerat următoarea formulă pentru β_k :

$$\beta_k^{YT} = \frac{g_{k+1}^T (z_k - t s_k)}{d_k^T z_k}, \quad (2.5)$$

unde $z_k = y_k + \frac{\delta \eta_k}{s_k^T u_k} u_k$, $\eta_k = 6(f(x_k) - f(x_{k+1})) + 3(g_k + g_{k+1})^T s_k$, $\delta > 0$ este o constantă și $u_k \in R^n$ satisface $s_k^T u_k \neq 0$; de exemplu $u_k = s_k$. În același context bazat pe condiția secantei modificată a lui Zhang, Deng și Chen [57], cu $u_k = s_k$, Andrei [14] a propus următoarea formulă pentru β_k :

$$\beta_k = \left(\frac{\delta \eta_k}{\|s_k\|^2} - 1 \right) \frac{s_k^T g_{k+1}}{y_k^T s_k + \delta \eta_k} + \frac{y_k^T g_{k+1}}{y_k^T s_k + \delta \eta_k}, \quad (2.6)$$

unde $\delta \geq 0$ este un parametru scalar. O altă posibilitate este prezentată de Yuan [56] ca

$$\beta_k^Y = \frac{y_k^T g_{k+1}}{(f_k - f_{k+1}) / \alpha_k - d_k^T g_k / 2}. \quad (2.7)$$

Problema 6. Cum se poate utiliza structura problemei pentru a proiecta algoritmi eficienți de gradient conjugat neliniar?

Când problema este parțial separabilă, adică aceasta se poate exprima ca o sumă de funcții elementare fiecare dintre ele având un subspațiu invariant [28], se poate atunci formula o procedură de actualizare a lui β_k pentru a obține un algoritm eficient de gradient conjugat? Ideea descompunerii funcțiilor parțial separabile a fost considerată de Conn, Gould și Toint [27]. Avantajul acestui mod de abordare este că informația conținută într-o astfel de descriere a funcției se poate utiliza pentru a explora funcția numai în anumite direcții relevante. Ideea este de a ignora anumite subspații ale funcției f și de a considera complementul acestora. Chestiunea este dacă acest tip de informație se poate utiliza pentru a proiecta noi formule de calcul pentru β_k .

Problema 7. Cum se poate utiliza informația de ordinul doi în algoritmi de gradient conjugat?

Andrei [3], [4], [5], [16] a sugerat următoarea formulă de calcul pentru β_k :

$$\beta_k = \frac{s_k^T \nabla^2 f(x_{k+1}) g_{k+1} - s_k^T g_{k+1}}{s_k^T \nabla^2 f(x_{k+1}) s_k}. \quad (2.8)$$

Observăm că, dacă este exactă căutarea liniară, atunci (2.8) este chiar metoda lui Daniel [32]. Ceea ce este interesant în această formulă este prezența Hessianului. În practică, pentru probleme de mari dimensiuni, formulele de actualizare a anumitor parametri care nu cer evaluarea matricei Hessian sunt de preferat față de cele care implică această matrice. O posibilitate de a utiliza informația de ordinul doi, dată de Matricea Hessian, este de a calcula în mod direct produsul Hessian/vector $\nabla^2 f(x_{k+1}) s_k$. Totuși, experimentele noastre computaționale au arătat că produsul $\nabla^2 f(x_{k+1}) s_k$ este consumator de timp, mai ales pentru probleme de mari dimensiuni chiar dacă Hessianul este o matrice cu structuri speciale (tridiagonală, bloc diagonală). În plus, ce se întâmplă dacă $s_k \in \text{Ker} \nabla^2 f(x_{k+1})$? Într-un efort de a

utiliza Hessianul în formula de calcul a lui β_k Andrei [18], [21] a sugerat un algoritm de gradient conjugat neliniar în care produsul Hessian/vector $\nabla^2 f(x_{k+1}) s_k$ este aproximat prin diferențe finite ca:

$$\nabla^2 f(x_{k+1}) s_k = \frac{\nabla f(x_{k+1} + \delta s_k) - \nabla f(x_{k+1})}{\delta}, \quad (2.9)$$

unde

$$\delta = \frac{2\sqrt{\varepsilon_m} (1 + \|x_{k+1}\|)}{\|s_k\|}, \quad (2.10)$$

și ε_m este epsilon mașină.

După cum cunoaștem, în metodele quasi-Newton o aproximare B_k a matricei Hessian $\nabla^2 f(x_k)$ este actualizată astfel încât noua matrice B_{k+1} satisface ecuația (condiția) secantei $B_{k+1}s_k = y_k$. Deci, așa după cum se detaliază în [3], [4], [5], pentru a avea un algoritm de gradient conjugat pentru rezolvarea problemelor de mari dimensiuni, se poate presupune că perechea (s_k, y_k) satisface ecuația secantei. Cu această presupunere obținem

$$\beta_k = \frac{(\theta_{k+1}y_k - s_k)^T g_{k+1}}{y_k^T s_k}, \quad (2.11)$$

unde θ_{k+1} este un parametru. Birgin și Martínez [26] au ajuns la această formulă pentru β_k , utilizând o interpretare a minimizării funcțiilor pătratice. În [14], [16], se prezintă detalii teoretice și computaționale cu un algoritm în care produsul Hessian/vector $\nabla^2 f(x_{k+1})s_k$ este aproximat printr-o tehnică utilizând ecuația secantei modificată introdusă de Zhang, Deng și Chen [57] și de Zhang și Xu [58], obținând β_k ca în (2.6).

Problema 8. Care este cel mai bun algoritm de gradient conjugat scalat?

Anumiți autori au propus următoarea direcție de căutare

$$d_{k+1} = -\theta_{k+1}g_{k+1} + \beta_k s_k, \quad (2.12)$$

unde θ_{k+1} este un scalar pozitiv sau o matrice simetrică și pozitiv definită [3], [4], [5], [26]. Formula (2.12) este cunoscută ca algoritmul de gradient conjugat scalat. Observăm că dacă $\theta_{k+1} = 1$, atunci obținem algoritmi clasici de gradient conjugat, în funcție de formula utilizată pentru β_k . Pe de altă parte, dacă $\beta_k = 0$, atunci obținem o altă clasă de algoritmi, în funcție de procedura de selecție a lui θ_{k+1} . Considerând $\beta_k = 0$, atunci dispunem de două posibilități pentru θ_{k+1} : un scalar pozitiv sau o matrice simetrică și pozitiv definită. Dacă $\theta_{k+1} = 1$, atunci avem metoda pasului descendent. Dacă $\theta_{k+1} = \nabla^2 f(x_{k+1})^{-1}$, sau o aproximație a acestei matrice, atunci obținem metoda Newton sau respectiv quasi-Newton. Vedem deci că, în cazul general când $\theta_{k+1} \neq 0$ este selectat ca în metodele quasi-Newton și $\beta_k \neq 0$, atunci (2.12) reprezintă o combinație a metodelor quasi-Newton și a celor de gradient conjugat. Totuși, dacă θ_{k+1} este o matrice care conține informații relevante asupra inversei Hessianului funcției f , atunci se pare că este mai bine să considerăm $d_{k+1} = -\theta_{k+1}g_{k+1}$ deoarece adăugarea termenului $\beta_k s_k$ în (2.12) poate deteriora caracterul de direcție descendentă a lui d_{k+1} . Andrei [3], [4], [5], și Birgin și Martínez, [26] selectează θ_{k+1} ca inversa cîtului Rayleigh. O altă selecție este bazată pe valorile funcției de minimizat în două puncte succesive, așa numita procedură anticipativă [12].

Problema 9. Care este cel mai bun algoritm hibrid de gradient conjugat?

Algoritmii hibridi de gradient conjugat au fost proiectați pentru a utiliza și combina proprietățile (bune) de convergență ale algoritmilor clasici de gradient conjugat. Touati-Ahmed și Storey [53], Hu și Storey [42], Gilbert și Nocedal [37] au sugerat algoritmi de gradient conjugat utilizând proiecții ale algoritmilor Fletcher-Reeves [35], Polak-Ribière [46] și Polyak [47]. O altă sursă de algoritmi de gradient conjugat hibridi se bazează pe conceptual de combinație convexă a algoritmilor de gradient conjugat clasici. Andrei [7], [8] a introdus această clasă de algoritmi de gradient conjugat hibrid ca o combinație convexă a algoritmilor Polak-Ribière-Polyak [46] și Dai-Yuan [31]. În [9], [10], [15], [17], se prezintă detalii teoretice și computaționale asupra algoritmilor hibridi de gradient conjugat ca niște combinații convexe a algoritmilor Hestenes-Stiefel [41] și Dai-Yuan [31]. În general, performanțele variantelor hibride bazate pe conceptul de combinație convexă sunt superioare algoritmilor care participă în această combinație, dar care este cea mai bună alegere a algoritmilor clasici de gradient conjugat, care să participe în această combinație convexă rămâne o chestiune deschisă.

Problema 10. Care este cea mai bună procedură de restartare a algoritmilor de gradient conjugat?

Primii algoritmi de gradient conjugat erau restartați ori de câte ori $k = n$ sau $k = n + 1$. Când n este foarte mare și valorile proprii ale Hessianului funcției de minimizat se grupează într-un număr mic de grupe, această strategie de restartare poate fi inefficientă. Powell [50] a sugerat restartarea algoritmilor de gradient conjugat ori de câte ori

$$\left| g_k^T g_{k+1} \right| \geq 0.2 \|g_{k+1}\|^2 \quad (2.13)$$

Pentru funcții pătratice, membrul stâng din (2.13) este un indicator al neconjugării direcțiilor de căutare și, deci, un semnal că ciclul curent din cadrul procesului de optimizare trebuie încheiat și altul trebuie început cu direcția negativă a gradientului în punctul curent. De asemenea, restartarea este recomandată de îndată ce direcția de căutare încetează de a fi descendentă. Powell sugerează restartarea dacă

$$-1.2 \|g_k\|^2 < d_k^T g_k < -0.8 \|g_k\|^2 \quad (2.14)$$

nu este satisfăcut. Un alt criteriu de restartare a iterațiilor în algoritmi de gradient conjugat a fost proiectat de Birgin și Martínez [26]

$$d_{k+1}^T g_{k+1} > -10^{-3} \|d_{k+1}\|_2 \|g_{k+1}\|_2 \quad (2.15)$$

În (2.15), când unghiul dintre d_{k+1} și $-g_{k+1}$ nu este suficient de ascuțit, atunci algoritmul se restartează cu direcția negativă a gradientului $-g_{k+1}$. Evident, se pot imagina diferite proceduri de restartare, dar care este cea mai bună rămâne de studiat.

Problema 11. Care este cel mai bun criteriu de oprire a iterațiilor în algoritmi de gradient conjugat?

În precizie infinită, o condiție necesară pentru ca x^* să fie minimul exact al funcției f este ca $\nabla f(x^*) = 0$. Într-un algoritm iterativ care lucrează în precizie finită această condiție trebuie modificată sub forma $\nabla f(x^*) \cong 0$. Deși $\nabla f(x^*) = 0$ poate să apară într-un punct de maxim sau într-un punct șă, totuși procedura de căutare liniară de-a lungul direcției de deplasare ne asigură că obținem un punct de minim al funcției f . Deci, $\nabla f(x^*) = 0$ se poate foarte bine considera ca o condiție necesară și suficientă pentru ca x^* să fie un minim local al funcției f .

Pentru algoritmi de gradient conjugat liniar, diferite criterii de oprire a iterațiilor au fost analizate de Arioli și Loghin [23]. Pentru algoritmi de gradient conjugat neliniar, de obicei, algoritmiștii utilizează următoarele criterii de oprire a iterațiilor

$$\|\nabla f(x_k)\|_\infty \leq \varepsilon_g, \quad (2.16)$$

$$\alpha_k g_k^T d_k \leq \varepsilon_f |f(x_{k+1})|, \quad (2.17)$$

$$\|\nabla f(x_k)\|_\infty \leq \varepsilon_g (1 + |f(x_k)|), \quad (2.18)$$

$$\|\nabla f(x_k)\|_\infty \leq \max \{ \varepsilon_g, \varepsilon_0 \|\nabla f(x_0)\|_\infty \}, \quad (2.19)$$

$$\|\nabla f(x_k)\|_2 \leq \varepsilon_g, \quad (2.20)$$

unde, de exemplu $\varepsilon_f = 10^{-20}$, $\varepsilon_g = 10^{-6}$ și $\varepsilon_0 = 10^{-12}$. Pentru probleme de mari dimensiuni mai convenabil este să se utilizeze norma $\|\nabla f(x_k)\|_\infty$, dar pentru probleme de mici dimensiuni se pare că mai bine este de a se utiliza norma $\|\nabla f(x_k)\|_2$. Dintre toate aceste criterii de mai sus, rămâne ca o problemă deschisă care este cel mai bun.

În legătură directă cu acest subiect, deseori ne întrebăm: Ce este mai important: „valoarea optimă locală f^* a funcției de minimizat sau punctul de optim local x^* ”? În comparațiile numerice deseori se preferă să se utilizeze valorile optime locale obținute de diferiți algoritmi.

Problema 12. Componentele afine ale gradientului

Metoda Newton are o proprietate foarte frumoasă. Pentru orice componentă afină a gradientului $\nabla f(x)$, fiecare iterație generată de metoda Newton este o soluție a acestor componente, aceasta deoarece modelul afîn asociat sistemului $\nabla f(x) = 0$ întotdeauna este exact pentru aceste funcții. Este această proprietate valabilă și pentru algoritmi de gradient conjugat?

Problema 13. Care este relația dintre algoritmi de gradient conjugat și cei quasi-Newton?

Ambele clase de algoritmi au o anumită maturitate, cu rezultate bine fundamentate matematic și susținute computațional de programe de calcul foarte performante. Chestiunea este aceea că, la ora actuală, nu vedem un progres semnificativ în proiectarea de algoritmi eficienți și robusți, care să utilizeze concepte din ambele aceste clase de algoritmi.

Problema 14. Cum se pot extinde algoritmi de gradient conjugat pentru rezolvarea problemelor de optimizare cu restricții margini simple?

Să considerăm problema

$$\min_{x \in R^n} \{f(x) \mid l \leq x \leq u\}, \quad (2.21)$$

unde l și u sunt vectori cunoscuți din R^n . Problema este cum se pot adapta algoritmi de gradient conjugat pentru rezolvarea problemei (2.21). O posibilitate este de a considera tehnici de punct interior și de a proiecta un algoritm de gradient conjugat în care marginile simple nu sunt manevrate într-o manieră explicită.

3. Concluzie

De mai bine de 50 de ani, algoritmi de gradient conjugat au fost obiectul unor cercetări și analize teoretice și computaționale intensive. Și în prezent, acești algoritmi continuă să reprezinte o componentă importantă a metodelor de optimizare fără restricții, dovedindu-și caracterul lor de inepuizabilitate. În această lucrare, am prezentat câteva probleme deschise, care constituie subiecte de meditație și cercetare pentru proiectarea și implementarea în programe de calcul de noi algoritmi eficienți de gradient conjugat.

Bibliografie

1. **ALLWRIGHT, J.C.:** Improving the Conditioning of Optimal Control Problems Using Simple Methods. Recent Mathematical Developments in Control, Edited by O.J. Bell, Academic Press, London, 1972.
2. **ANDREI, N.:** An Acceleration of Gradient Descent Algorithm with Backtracking for Unconstrained Optimization. Numerical Algorithms, No. 42, 2006, pp. 63-73.
3. **ANDREI, N.:** Scaled Conjugate Gradient Algorithms for Unconstrained Optimization. Computational Optimization and Applications, No. 38, 2007, pp. 401-416.
4. **ANDREI, N.:** Scaled Memoryless BFGS Preconditioned Conjugate Gradient Algorithm for Unconstrained Optimization. Optimization Methods and Software, No. 22, 2007, pp. 561-571.
5. **ANDREI, N.:** A Scaled BFGS Preconditioned Conjugate Gradient Algorithm for Unconstrained Optimization. Applied Mathematics Letters, No. 20, 2007, pp. 645-650.
6. **ANDREI, N.:** SCALCG – Scaled Conjugate Gradient Algorithms for Unconstrained Optimization. Technical Report ICI, No. 17/2007. March 30, 2007. (CD inclus)
7. **ANDREI, N.:** New Hybrid Conjugate Gradient Algorithms for Unconstrained Optimization. ICI Technical Report, 26 September, 2007. (Acceptată de Journal of Optimization Theory and Applications, 2009 as: Hybrid Conjugate Gradient Algorithm for Unconstrained Optimization.)
8. **ANDREI, N.:** New Hybrid Conjugate Gradient Algorithms as a Convex Combination of PRP and DY for Unconstrained Optimization. ICI Technical Report, October 1, 2007.
9. **ANDREI, N.:** A Hybrid Conjugate Gradient Algorithm for Unconstrained Optimization as a Convex Combination of Hestenes-Stiefel and Dai-Yuan. ICI Technical Report, 14 January, 2008.
10. **ANDREI, N.:** A Hybrid Conjugate Gradient Algorithm with Modified Secant Condition for Unconstrained Optimization. ICI Technical Report, 6 February, 2008.

11. **ANDREI, N.:** Accelerated Scaled Memoryless BFGS Preconditioned Conjugate Gradient Algorithm for Unconstrained Optimization. ICI Technical Report, 24 March, 2008.
12. **ANDREI, N.:** A Scaled Nonlinear Conjugate Gradient Algorithm for Unconstrained Optimization. Optimization. A journal of Mathematical Programming and Operations Research. Vol. 57, No. 4, August, 2008, pp. 549-570.
13. **ANDREI, N.:** Acceleration of Conjugate Gradient Algorithms for Unconstrained Optimization. ICI Technical Report, 24 October, 2008.
14. **ANDREI, N.:** Accelerated Conjugate Gradient Algorithm with Modified Secant Condition for Unconstrained Optimization. ICI Technical Report, 3 March, 2008.
15. **ANDREI, N.:** A Hybrid Conjugate Gradient Algorithm for Unconstrained Optimization as a Convex Combination of Hestenes-Stiefel and Dai-Yuan. Studies in Informatics and Control, Vol. 17, No. 1, March 2008, pp. 55-70.
16. **Andrei, N.:** A Hybrid Conjugate Gradient Algorithm with Modified Secant Condition for Unconstrained Optimization as a Convex Combination of Hestenes-Stiefel and Dai-Yuan Algorithms. Studies in Informatics and Control, Vol. 17, 2008, pp. 373-392.
17. **ANDREI, N.:** Another Hybrid Conjugate Gradient Algorithm for Unconstrained Optimization. Numerical Algorithms. Vol. 47, No. 2 / February, 2008, pp. 143-156.
18. **ANDREI, N.:** Accelerated Conjugate Gradient Algorithm with Finite Difference Hessian / Vector Product Approximation for Unconstrained Optimization. ICI Technical Report, 4 March, 2008. (Acceptată de Journal of Computational and Applied Mathematics, 2009.)
19. **ANDREI, N.:** ASCALCG – Accelerated Scaled Memoryless BFGS Preconditioned Conjugate Gradient Algorithm for Unconstrained Optimization. Technical Report ICI, No. 17, 2008. (CD inclus).
20. **ANDREI, N.:** Open Problems in Nonlinear Conjugate Gradient Algorithms for Unconstrained Optimization. ICI Technical Report, 30 July, 2008.
21. **ANDREI, N.:** Numerical Experiments with Accelerated Conjugate Gradient Algorithm with Hessian / Vector Product - ACGHES - for Unconstrained Optimization. ICI Technical Report, September 22, 2008.
22. **ANDREI, N.:** An Accelerated Conjugate Gradient Algorithm with Guaranteed Descent and Conjugacy Conditions for Unconstrained Optimization. ICI Technical Report, 3 December, 2008.
23. **ARIOLI, M., D. LOGHIN:** Stopping Criteria for Mixed Finite Element Problems. RAL-TR-2006-010, 2007, pp. 1-15.
24. **ARMIJO, L.:** Minimization of Function Having Lipschitz Continuous First Partial Derivatives. Pacific Journal on Mathematics, 16, 1966, pp. 1-3.
25. **BEALE, E.M.L.:** A Derivation of Conjugate Gradients. În: Lotsma, F.A., (Ed.) Numerical Methods for Nonlinear Optimization. Academic Press, New-York, 1972, pp. 39-43.
26. **Birgin, E., J.M. Martínez:** A Spectral Conjugate Gradient Method for Unconstrained Optimization. Applied Math. and Optimization, No. 43, 2001, pp. 117-128.
27. **CONN, A.R., N.I.M. GOULD, P.H.L. TOINT:** LANCELOT – A Fortran Package for Large-scale Nonlinear Optimization (Release A), Springer Verlag, Berlin, 1992.
28. **CONN, A.R., N.I.M. GOULD, P.H.L. TOINT:** Improving the Decomposition of Partially Separable Functions in the Context of Large-scale Optimization: A First Approach. În: Hager, W.W., Hearn, D.W. and Pardalos, P.M., (Eds.) Large Scale Optimization: State of the Art, Kluwer Academic Publishers, 1994, pp. 82-94.
29. **CROWDER, H.P., P. WOLFE, P.:** Linear Convergence of the Conjugate Gradient Method. IBM J. Res. Dev., No. 16, 1969, pp. 431-433.
30. **DAI, Y.H., L.Z. LIAO, L.Z.:** New Conjugate Conditions and Related Nonlinear Conjugate Gradient Methods, Appl. Math. Optim., NO. 43, 2001, pp. 87-101.
31. **DAI, Y.H., Y. YUAN, Y.:** A Nonlinear Conjugate Gradient Method with a Strong Global Convergence Property, SIAM J. Optim., No. 10, 1999, pp. 177-182.
32. **DANIEL, J.W.:** The Conjugate Gradient Method for Linear and Nonlinear Operator Equations, SIAM J. Numer. Anal., No. 4, 1967, pp. 10-26.
33. **DENNIS, J.E., R.B. SCHNABEL:** Numerical Methods for Unconstrained Optimization and Nonlinear Equations, Prentice-Hall, Englewood Cliffs, New Jersey, 1983.

34. **DIXON, L.C.W., P.G. DUCKSBURY, P. SINGH:** A New Three-term Conjugate Gradient Method. *Journal of Optimization Theory and Applications*, No. 47, 1985, pp. 285-300.
35. **FLETCHER, R., C.M. REEVES:** Function Minimization by Conjugate Gradients *Comput. J.*, No. 7, 1964, pp. 149-154.
36. **GOLDSTEIN, A.A.:** On Steepest Descent, *SIAM J. Control*, Vol. 3, 1965, pp. 147-151.
37. **GILBERT, J.C., J. NOCEDAL:** Global Convergence Properties of Conjugate Gradient Methods for Optimization, *SIAM J. Optim.*, No. 2, 1992, pp. 21-42.
38. **GRIPPO, L., F. LAMPARIELLO, S. LUCIDI:** A Nonmonotone Line Search Technique for Newton's Method, *SIAM Journal on Numerical Analysis*, No. 23, 1986, pp. 707-716.
39. **HAGER, W.W., H. ZHANG:** A New Conjugate Gradient Method with Guaranteed Descent and an Efficient Line Search, *SIAM Journal on Optimization*, No. 16, 2005, pp. 170-192.
40. **HAGER, W.W., H. ZHANG:** A Survey of Nonlinear Conjugate Gradient Methods. *Pacific Journal of Optimization*, No. 2, 2006, pp. 35-58.
41. **HESTENES, M.R., E. STIEFEL:** Methods of Conjugate Gradients for Solving Linear Systems, *J. Research Nat. Bur. Standards Sec. B.* 48, 1952, pp. 409-436.
42. **HU, Y.F., C. STOREY:** Global Convergence Result for Conjugate Gradient Methods, *J. Optim. Theory Appl.*, No. 71, 1991, pp. 399-405.
43. **LEMARECHAL, C.:** A View of Line Search. În: Auslander, Oettli, J. Stoer (Eds.) *Optimization and Optimal Control*, Springer, 1981, pp. 59-78.
44. **MORÉ, J.J. D.J. THUENTE:** On Line Search Algorithms with Guaranteed Sufficient Decrease. *Mathematics and Computer Science Department Preprint MCD-P153-0590*, Argonne National Laboratory, June, 1990.
45. **NAZARETH, J.L.:** A Conjugate Direction Algorithm without Line Search, *Journal of Optimization Theory and Applications*, No. 23, 1977, pp. 373-387.
46. **POLAK E., G. RIBIÈRE:** Note sur la convergence de methods de directions conjuguées, *Revue Francaise Informat. Reserche Opérationnelle*, No. 16, 1969, pp. 35-43.
47. **POLYAK, B.T.:** The Conjugate Gradient Method in Extreme Problems, *USSR Comp. Math. Math. Phys.*, No. 9, 1969, pp. 94-112.
48. **POTRA, F.A., Y. SHI:** Efficient Line Search Algorithm for Unconstrained Optimization, *Journal of Optimization Theory and Applications*, Vol. 85, 1995, pp. 677-704.
49. **POWELL, M.J.D.:** Some Convergence Properties of the Conjugate Gradient Method. *Math. Programming*, No. 11, 1976, pp. 42-49.
50. **POWELL, M.J.D.:** Restart Procedures for the Conjugate Gradient Method, *Math. Programming*, No. 12, 1977, pp. 241-254.
51. **SHANNO, D.F.:** Conjugate Gradient Methods with Inexact Searches, *Mathematics of Operations Research*, No. 3, 1978, pp. 244-256.
52. **SHANNO, D.F.:** On the Convergence of a New Conjugate Gradient Algorithm, *SIAM J. Numer. Anal.*, No. 15, 1978, pp. 1247-1257.
53. **TOUATI-AHMED, D., C. STOREY:** Efficient Hybrid Conjugate Gradient Techniques, *Journal of Optimization Theory and Applications*, No. 64, 1990, pp. 379-397.
54. **WOLFE, P.:** Convergence Conditions for Ascent Methods, *SIAM Rev.*, No. 11, 1969, pp. 226-235.
55. **YABE, H., M. TAKANO:** Global Convergence Properties of Nonlinear Conjugate Gradient Methods with Modified Secant Condition, *Computational Optimization and Applications*, No. 28, 2004, pp. 203-225.
56. **YUAN Y.:** Some Problems in Nonlinear Programming. În: Yuan, Y., (Ed.) *Numerical Linear Algebra and Optimization*, Science Press, Beijing / New York, 2003, pp. 90-110.
57. **ZHANG, J.Z., N.Y. DENG, L.H. CHEN:** New Quasi-Newton Equation and Related Methods for Unconstrained Optimization, *J. Optim. Theory Appl.*, No. 102, 1999, pp. 147-167.
58. **ZHANG, J.Z., C.X. XU:** Properties and Numerical Performance of Quasi-Newton Methods with Modified Quasi-Newton Equations, *Journal of Computational and Applied Mathematics*, No. 137, 2001, pp. 269-278.

30 ianuarie, 2009