

## یک الگوریتم گرادیان مزدوج کارا برای حل مسایل بهینه‌سازی نامقید

فهیمة عبداللهی<sup>۱\*</sup>، سید مسعود فاطمی<sup>۲</sup>

۱- دانشجوی دکتری، دانشگاه صنعتی خواجه نصیرالدین طوسی، گروه ریاضی کاربردی، تهران، ایران

۲- استاد، دانشگاه صنعتی خواجه نصیرالدین طوسی، گروه ریاضی کاربردی، تهران، ایران

رسید مقاله: ۲ شهریور ۱۳۹۹

پذیرش مقاله: ۳ خرداد ۱۴۰۰

### چکیده

در این مقاله به معرفی یک روش گرادیان مزدوج کارآمد پرداخته می‌شود. این روش از حل یک مساله بهینه‌سازی که به کمک ویژگی‌های گرادیان مزدوج خطی و همچنین یک شرط سکانت اصلاح شده به دست آمده، حاصل می‌شود. پارامتر گرادیان مزدوج معرفی شده علاوه بر مقادیر گرادیان، در هر تکرار از مقادیر تابع نیز استفاده می‌کند. روش ارائه شده با فرضیات مناسب خاصیت همگرایی سراسری دارد. در انتها با استفاده از مسایل کتابخانه CUTER به مقایسه روش با برخی روش‌های شناخته شده موجود می‌پردازیم و کارایی روش را ارزیابی می‌کنیم.

**کلمات کلیدی:** روش گرادیان مزدوج، شرط سکانت بهبودیافته، بهینه‌سازی نامقید.

### ۱ مقدمه

در دهه‌های اخیر روش‌های گرادیان مزدوج به دلیل شرایط همگرایی قوی محلی و سراسری و نیز نیاز به حافظه‌ی کم برای حل مسایل بزرگ بسیار مورد توجه محققان بوده‌اند. مساله‌ی بهینه‌سازی نامقید را در نظر بگیرید:

$$\min_{x \in R^n} f(x) \quad (1)$$

که در اینجا  $f: R^n \rightarrow R$  یک تابع هموار است. الگوریتم‌های گرادیان مزدوج دنباله‌ی تکراری زیر را می‌سازند:

$$x_{k+1} = x_k + \alpha_k d_k, \quad (2)$$

که در آن  $\alpha_k > 0$  طول گام تولیدشده توسط روش جستجوی خطی دقیق یا غیردقیق مانند شرایط وولف قوی (یا استاندارد) است که عبارتند از:

$$f(x_k + \alpha_k d_k) \leq f(x_k) + c_1 \alpha_k d_k^T g_k, \quad (3)$$

و

\* عهده‌دار مکاتبات

آدرس الکترونیکی: fabdollahi@email.kntu.ac.ir

$$|d_k^T g_{k+1}| \leq -c_\nu d_k^T g_k \quad (d_k^T g_{k+1} \geq c_\nu d_k^T g_k), \quad (4)$$

که  $0 < c_1 < c_\nu < 1$  ثابت‌های دلخواه و  $g_k := \nabla f(x_k)$  است. همچنین جهت جستجوی  $d_k$  به صورت بازگشتی از رابطه‌ی زیر به دست می‌آید:

$$d_{k+1} = -g_{k+1} + \beta_k d_k \quad (d_k = -g_k). \quad (5)$$

پارامتر گرادیان مزدوج که غالباً با  $\beta_k$  نمایش داده می‌شود، یکی از مهم‌ترین پارامترهای این روش است و باید با دقت تعریف شود، زیرا انتخاب‌های متفاوت  $\beta_k$  منجر به تولید انواع روش‌های گرادیان مزدوج می‌شود.

همان‌طور که می‌دانیم، روش‌های گرادیان مزدوج برای مسایل درجه دوم محدب قوی با جستجوی خطی دقیق در هر دو شرط مزدوج بودن

$$d_{k+1}^T y_k = 0, \quad (6)$$

و تعامد

$$d_i^T g_k = 0 \quad i = 0, 1, \dots, k-1, \quad (7)$$

صدق می‌کنند، که در اینجا  $y_k := g_{k+1} - g_k$ .

برخی از انتخاب‌های شناخته‌شده برای  $\beta_k$  عبارتند از هستن و اشتیفل (HS) [۱]، فلچر و ریوس (FR) [۲]، پولاک و ریبر و پولیاک (PRP) [۳]، فلچر (CD) [۴]، لیو و استوری (LS) [۵] و دای و یوان (DY) [۶] که در اینجا به معرفی آنها پرداخته‌ایم

$$\beta_k^{HS} = \frac{g_{k+1}^T y_k}{d_k^T y_k}, \quad \beta_k^{FR} = \frac{\|g_{k+1}\|_2^2}{\|g_k\|_2^2}, \quad \beta_k^{PRP} = \frac{g_{k+1}^T y_k}{\|g_k\|_2^2},$$

$$\beta_k^{CD} = \frac{\|g_{k+1}\|_2^2}{-d_k^T g_k}, \quad \beta_k^{LS} = \frac{g_{k+1}^T y_k}{-d_k^T g_k}, \quad \beta_k^{DY} = \frac{\|g_{k+1}\|_2^2}{d_k^T y_k}$$

که  $\|\cdot\|_2$  نرم اقلیدسی است.

نتایج حاصل از مطالعات تئوری و عددی ارائه‌شده توسط آندری در [۷] نشان می‌دهد که برخی روش‌ها مانند HS، PRP و LS (که در صورت عبارت  $g_{k+1}^T y_k$  را دارند) عملکرد عددی بهتری نسبت به روش‌های FR، CD و DY (که در صورت عبارت  $\|g_{k+1}\|_2$  را دارند) نشان می‌دهند، در حالی که دسته‌ی دوم شرایط همگرایی قوی سراسری را دارند. امروزه محققان علاقمند به بهبود و معرفی پارمترهایی هستند که روش حاصل علاوه بر نتایج عددی خوب شرایط همگرایی سراسری را نیز داشته باشد. قابل ذکر است که اگر تابع  $f$  یک تابع درجه دوم محدب قوی باشد و جستجوی خطی دقیق به کار رود، روش‌های معرفی‌شده در بالا همگی معادل هستند.

دای و لیائو در [۸] پارامتری را به صورت زیر معرفی کرده‌اند

$$\beta_k^{DL} = \frac{g_{k+1}^T y_k - \tau g_{k+1}^T s_k}{y_k^T d_k}, \quad (8)$$

که در آن  $\tau > 0$  عدد ثابت و  $s_k := x_{k+1} - x_k$  است. با تغییر  $\tau$  یک خانواده از روش‌های گرادیان مزدوج معرفی می‌شود که برای توابع کلی همگرایی سراسری را دارند. جهت‌های جستجوی تولیدشده توسط این پارامتر در شرط مزدوج بودن متفاوتی به شکل  $d_{k+1}^T y_k = -\tau g_{k+1}^T s_k$  صدق می‌کنند، اما شرط کاهش کافی یعنی

$$d_k^T g_k \leq -c \|g_k\|^2, \quad (9)$$

که  $c > 0$  یک عدد ثابت است، لزوماً برقرار نیست. انتخاب مناسب  $\tau$  سبب نتایج بسیار خوبی می‌شود اما یک مقدار بهینه، که برای هر نوع مساله‌ای به خوبی عمل کند به صورت نظری برای آن ارایه نشده است. تلاش‌های بسیاری به منظور بهبود این پارامتر انجام شده است که می‌توان برخی از آنها را در مقالات [۹، ۱۰، ۱۱، ۱۲، ۱۳، ۱۴] مشاهده کرد.

فاطمی در [۱۴] یک روش گرادیان مزدوج جدید معرفی کرده است که همگرایی سراسری داشته و جهت جستجوی تولید شده در آن در شرط کاهش کافی صدق می‌کند. این روش با استفاده از یک مساله بهینه‌سازی و به کارگیری شرط سکانت تولیدشده و عملکرد قابل توجهی دارد.

در این کار با معرفی شرط سکانت اصلاح شده قصد داریم یک پارامتر گرادیان مزدوج کارا بر اساس حل یک مساله بهینه‌سازی معرفی کنیم که ایده اولیه این مساله بهینه‌سازی توسط فاطمی در [۱۴] معرفی شده است. ما نشان خواهیم داد استفاده از شرط سکانت اصلاح شده می‌تواند اقدام موثری در افزایش کارایی روش باشد. نتایج عددی ارایه شده در بخش آخر با استفاده از نمودار عملکرد دولان-موره [۱۵] نشان می‌دهد که روش جدید کاملاً کارآمد است. در بخش آخر با استفاده از مجموعه‌ای از مسایل CUTER و انتخاب‌های متفاوت برای پارامترهای اصلی یک مقایسه دقیق بین روش اصلی و برخی دیگر از روش‌های گرادیان مزدوج از جمله روش فاطمی و سه روش از خانواده دای-لیائو که از شرط سکانت بهبودیافته استفاده کرده‌اند، انجام شده است و نشان داده می‌شود که روش جدید عملکرد قابل توجهی دارد.

در بخش دوم خلاصه‌ای از مفاهیم اولیه بیان می‌شود. جزییات روش جدید و الگوریتم آن در بخش سوم ارایه خواهد شد. در بخش ۴ همگرایی روش مورد بررسی قرار خواهد گرفت. در بخش ۵ عملکرد عددی الگوریتم معرفی شده با حل مجموعه‌ای از مسایل CUTER و انتخاب‌های گوناگون برای پارامترهای اصلی با استفاده از نمودار عملکرد دولان-موره مورد ارزیابی قرار می‌گیرد.

## ۲ معرفی الزامات روش

روش‌های گرادیان مزدوج معمولاً از شرط سکانت

$$B_{k+1} s_k = y_k, \quad (10)$$

که در آن  $B_{k+1}$  تقریبی برای  $\nabla^2 f(x_{k+1}) := G_{k+1}$  است، به منظور بهره‌گیری از شرایط همگرایی زبرخطی همانند روش‌های شبه نیوتنی، استفاده می‌کنند. توجه داشته باشید که در این شرط تنها از گرادیان تابع استفاده

می‌شود. محققان تلاش‌های بسیاری به منظور بهبود (۱۰) انجام داده‌اند. ژنگ و همکارانش در [۱۶] و ژنگ و خی در [۱۷] شرط سکانت بهبودیافته را به صورت زیر معرفی کرده‌اند

$$B_{k+1} s_k = \hat{y}_k, \quad \hat{y}_k = y_k + \frac{\theta_k}{s_k^T u_k} u_k \quad (11)$$

که

$$\theta_k = \epsilon(f_k - f_{k+1}) + \nu(g_k + g_{k+1})^T s_k \quad (12)$$

برای هر بردار  $u_k$  با  $s_k^T u_k \neq 0$  و در نظر گرفتن  $B_{k+1}$  به عنوان تقریبی برای  $G_{k+1}$ . در [۱۸] نشان داده شده است که برای تابع درجه دوم محدب، با جستجوی خطی دقیق برای (۱۲) داریم  $\theta = 0$  و در نتیجه شرط سکانت بهبودیافته معادل است با شرط سکانت (۱۰).

در شرط سکانت بهبودیافته علاوه بر بردار گرادیان از مقادیر تابع نیز استفاده می‌شود، و در [۱۷] ثابت شده است که  $\hat{y}_k$  تقریب بهتری برای  $\nabla^2 f(x_{k+1}) s_k$  نسبت به  $y_k$  به دست می‌آورد.

برخی انتخاب‌های شناخته‌شده برای  $u_k$  که در شرط  $s_k^T u_k \neq 0$  صدق می‌کنند عبارتند از  $u_k = s_k$ ،  $u_k = \nabla f(x_k)$  و  $u_k = y_k$ .

مقالات بسیاری از جمله [۱۳، ۱۹، ۲۰، ۲۱، ۲۲، ۲۳، ۲۴، ۲۵] از شرط (۱۱) به منظور ساخت و بهبود روش‌های جدید گرادیان مزدوج استفاده کرده‌اند که از لحاظ تئوری و عددی نتایج بهتری را به دست آورده‌اند. به منظور ارایه یک روش گرادیان مزدوج کارا، فاطمی در [۱۴] یک مساله بهینه‌سازی با ترکیب سه شرط (۶)، (۷) و (۹) به صورت زیر معرفی کرده است

$$\min_{\beta_k} \left[ g_{k+1}^T d_{k+1} + M \left( (g_{k+1}^T s_k)^2 + (d_{k+1}^T y_k)^2 \right) \right], \quad (13)$$

که در آن  $M$  پارامتر جریمه‌ای است. با حل این مساله و استفاده از شرط سکانت (۱۰) یک پارامتر  $\beta_k$  جدید به صورت زیر حاصل شده است

$$\beta_k = \frac{-1}{2M(1+t^\nu)} \frac{g_{k+1}^T d_k}{(y_k^T d_k)^\nu} + \frac{y_k^T g_{k+1}}{y_k^T d_k} - \frac{t}{(1+t^\nu)} \frac{s_k^T g_{k+1}}{y_k^T d_k}. \quad (14)$$

(۱) این روش با انتخاب مناسب پارامترها دارای همگرایی سراسری برای توابع کلی بوده و مقایسات عددی ارایه‌شده توسط نویسنده بیانگر کارایی روش بر اساس نمودارهای دولان-موره است.

### ۳ فرمول جدید برای $\beta_k$

یابه و تاکانو در [۱۳] یک توسیع از شرط سکانت اصلاح‌شده (۱۱) به صورت زیر ارایه داده‌اند

$$z_k = y_k + \rho_k \frac{\theta_k}{s_k^T u_k} u_k, \quad (15)$$

که در آن  $\rho_k \geq 0$  یک اسکالر است. شرط سکانت بهبودیافته را در نظر بگیرید

$$B_{k+1} s_k = z_k, \quad (16)$$

اگر  $\rho_k = 0$  یا  $\rho_k = 1$ ، این شرط به ترتیب با (۱۰) و (۱۱) معادل می شود.

تساوی زیر با حل (۱۳) و با استفاده از  $g_{k+1} \approx tB_{k+1}d_{k+1} + g_{k+1}$  به دست می آید [۱۴]:

$$\beta_k = \frac{-g_{k+1}^T d_k + \gamma M t^\gamma (s_k^T B_{k+1} g_{k+1})(s_k^T B_{k+1} d_k)}{\gamma M t^\gamma (s_k^T B_{k+1} d_k)^\gamma + \gamma M (y_k^T d_k)^\gamma} + \frac{-\gamma M t (s_k^T g_{k+1})(s_k^T B_{k+1} d_k) + \gamma M (y_k^T g_{k+1})(y_k^T d_k)}{\gamma M t^\gamma (s_k^T B_{k+1} d_k)^\gamma + \gamma M (y_k^T d_k)^\gamma}, \quad (17)$$

که در آن  $t > 0$  تقریبی از  $\alpha_{k+1}$  است. این پارامتر احتمال برقراری شرطهای (۶)، (۷) و (۹) را افزایش داده و در صورتی که  $M$  به سمت بینهایت میل کند به یک پارامتر دای-لیانو تبدیل می شود [۱۴]. حال با جایگذاری (۱۶) در (۱۷) پارامتر جدید  $\beta_k$  به صورت زیر به دست می آید:

$$\beta_k = \frac{-g_{k+1}^T d_k + \gamma M t^\gamma (z_k^T g_{k+1})(z_k^T d_k)}{\gamma M t^\gamma (z_k^T d_k)^\gamma + \gamma M (y_k^T d_k)^\gamma} + \frac{-\gamma t (s_k^T g_{k+1})(z_k^T d_k) + \gamma (y_k^T g_{k+1})(y_k^T d_k)}{\gamma t^\gamma (z_k^T d_k)^\gamma + \gamma (y_k^T d_k)^\gamma} \quad (18)$$

در این مرحله هدف ما معرفی یک مقدار مناسب برای پارامتر جریمه‌ای  $M$  است به طوری که شرطهای زیر برقرار باشند:

- جهت جستجوی  $d_{k+1}$  در شرط کاهش کافی (۹) صدق کند.

- در روند تکرارها به سمت بینهایت میل کند.

در لم زیر، یک پارامتر جریمه‌ای مناسب را پیشنهاد خواهیم کرد.

لم ۱: روش گرادیان مزدوج معرفی شده در روابط (۲) و (۵) با جستجوی خطی وولف قوی (۳) و (۴) و پارامتر  $\beta_k$  ارائه شده در (۱۸) را در نظر بگیرید. آنگاه، برای برخی اسکالره‌ای مثبت  $\gamma_1$  و  $\gamma_2$  به طوری که  $\gamma_1 + \gamma_2 < 1$ ، و

$$\rho_k \text{ که با شرط } \frac{1-c_\gamma}{3(1+c_\gamma-2c_1)} \leq \rho_k \leq 0 \text{ انتخاب شده است داریم}$$

$$d_{k+1}^T g_{k+1} \leq -(1-\gamma_1-\gamma_2) \|g_{k+1}\|^\gamma, \quad (19)$$

که در آن

$$(1-t) \leq \frac{\gamma_1 (y_k^T s_k)^\gamma}{(z_k^T s_k) \|s_k\|^\gamma}, \quad (20)$$

و

$$M = \frac{\gamma \gamma_2 (t^\gamma (z_k^T s_k)^\gamma + (y_k^T s_k)^\gamma)}{\|t^\gamma (z_k^T s_k) z_k + (y_k^T s_k) y_k - \lambda_k (z_k^T s_k) s_k\|^\gamma}, \quad (21)$$

که  $\lambda_k \leq 1$  یک اسکالر دلخواه است.

اثبات: برای اثبات از استقرای ریاضی استفاده می کنیم.

به وضوح، از (۵) داریم:

$$d_k^T g_k = -\|g_k\|^\gamma \leq -(1-\gamma_1-\gamma_2) \|g_k\|^\gamma.$$

فرض می کنیم

$$d_k^T g_k \leq -(1 - \gamma_1 - \gamma_r) \|g_k\|^r. \quad (22)$$

ابتدا به بررسی مقدار  $z_k^T s_k$  می‌پردازیم. با استفاده از (3)، (4)، (12) و (15) داریم

$$\begin{aligned} z_k^T s_k &= y_k^T s_k + \rho_k \theta_k \\ &= y_k^T s_k + \epsilon \rho_k (f_k - f_{k+1}) + \tau \rho_k (g_k + g_{k+1})^T s_k \\ &\geq (1 + \tau \rho_k) g_{k+1}^T s_k + (\tau \rho_k - 1) g_k^T s_k - \epsilon \rho_k c_1 g_k^T s_k \\ &= (1 + \tau \rho_k) g_{k+1}^T s_k + (\tau \rho_k - \epsilon \rho_k c_1 - 1) g_k^T s_k \\ &\geq (1 + \tau \rho_k) c_r g_k^T s_k + (\tau \rho_k - \epsilon \rho_k c_1 - 1) g_k^T s_k \\ &= (\tau \rho_k (1 + c_r - \epsilon c_1) + (c_r - 1)) g_k^T s_k. \end{aligned}$$

حال با استفاده از

$$g_k^T s_k = \alpha_k g_k^T d_k < 0,$$

و با توجه به این که  $0 \leq \rho_k < \frac{1 - c_r}{\tau(1 + c_r - \epsilon c_1)}$ ، ثابت  $m_1 > 0$  وجود دارد به طوری که

$$z_k^T s_k \geq -m_1 (g_k^T s_k) > 0. \quad (23)$$

و در نتیجه

$$z_k^T d_k > 0. \quad (24)$$

اکنون نشان می‌دهیم که شرط (19) برقرار است. با استفاده از (5) و (18)، داریم

$$\begin{aligned} d_{k+1}^T g_{k+1} &= -\|g_{k+1}\|^r + \beta_k d_k^T g_{k+1} = -\|g_{k+1}\|^r - \frac{(s_k^T g_{k+1})^r}{\tau M [t^r (z_k^T s_k)^r + (y_k^T s_k)^r]} \\ &\quad + \frac{[t^r (z_k^T g_{k+1})(z_k^T s_k) + (y_k^T g_{k+1})(y_k^T s_k)] (s_k^T g_{k+1})}{t^r (z_k^T s_k)^r + (y_k^T s_k)^r} - \frac{t (z_k^T s_k)(s_k^T g_{k+1})^r}{t^r (z_k^T s_k)^r + (y_k^T s_k)^r}. \end{aligned}$$

چون  $\lambda_k \leq 1$ ، داریم

$$\begin{aligned} d_{k+1}^T g_{k+1} &\pm \frac{(s_k^T g_{k+1})^r (z_k^T s_k)}{t^r (z_k^T s_k)^r + (y_k^T s_k)^r} \leq -\|g_{k+1}\|^r - \frac{(s_k^T g_{k+1})^r}{\tau M [t^r (z_k^T s_k)^r + (y_k^T s_k)^r]} \\ &\quad + \frac{[t^r (z_k^T s_k)(z_k^T g_{k+1}) + (y_k^T s_k)(y_k^T g_{k+1}) - \lambda_k (z_k^T s_k)(s_k^T g_{k+1})] (s_k^T g_{k+1})}{t^r (z_k^T s_k)^r + (y_k^T s_k)^r} \\ &\quad + \frac{(1-t)(z_k^T s_k)(s_k^T g_{k+1})^r}{t^r (z_k^T s_k)^r + (y_k^T s_k)^r} \end{aligned}$$

$$\begin{aligned} \Rightarrow d_{k+1}^T g_{k+1} &\leq -\|g_{k+1}\|^{\gamma} - \frac{(s_k^T g_{k+1})^{\gamma}}{\gamma M \left[ t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma} \right]} \\ &+ \frac{\left[ t^{\gamma} (z_k^T s_k) z_k + (y_k^T s_k) y_k - \lambda_k (z_k^T s_k) s_k \right]^T g_{k+1} (s_k^T g_{k+1})}{t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma}} \\ &+ \frac{(1-t)(z_k^T s_k)(s_k^T g_{k+1})^{\gamma}}{t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma}}. \end{aligned}$$

در اینجا با استفاده از نامساوی  $ab \leq \frac{l}{\varphi} a^{\gamma} + \frac{1}{l} b^{\gamma}$  که در آن  $a, b$  و  $l$  اسکالرهای مثبت هستند، داریم

$$\begin{aligned} d_{k+1}^T g_{k+1} &\leq -\|g_{k+1}\|^{\gamma} - \frac{(s_k^T g_{k+1})^{\gamma}}{\gamma M \left[ t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma} \right]} + \frac{(1-t)(z_k^T s_k)(s_k^T g_{k+1})^{\gamma}}{t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma}} \\ &+ \frac{l}{\varphi} \left( \left[ t^{\gamma} (z_k^T s_k) z_k + (y_k^T s_k) y_k - \lambda_k (z_k^T s_k) s_k \right]^T g_{k+1} \right)^{\gamma} + \frac{1}{l} \left( \frac{(s_k^T g_{k+1})^{\gamma}}{t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma}} \right)^{\gamma}. \end{aligned}$$

قرار می‌دهیم  $l = \frac{\gamma M}{t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma}}$

$$\begin{aligned} d_{k+1}^T g_{k+1} &\leq -\|g_{k+1}\|^{\gamma} + \frac{(1-t)(z_k^T s_k)(s_k^T g_{k+1})^{\gamma}}{t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma}} \\ &+ \frac{M}{\gamma (t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma})} \left( \left[ t^{\gamma} (z_k^T s_k) z_k + (y_k^T s_k) y_k - \lambda_k (z_k^T s_k) s_k \right]^T g_{k+1} \right)^{\gamma}. \end{aligned}$$

در آخر، با استفاده از نامساوی کوشی-شوارتز داریم

$$\begin{aligned} d_{k+1}^T g_{k+1} &\leq -\left[ 1 - \frac{(1-t)(z_k^T s_k) \|s_k\|^{\gamma}}{t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma}} - \right. \\ &\left. \frac{M}{\gamma \left[ t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma} \right]} \left\| \left[ t^{\gamma} (z_k^T s_k) z_k + (y_k^T s_k) y_k - \lambda_k (z_k^T s_k) s_k \right] \right\|^{\gamma} \right] \|g_{k+1}\|^{\gamma}. \end{aligned}$$

با استفاده از (۲۰)، (۲۱) و (۲۴) اثبات کامل می‌شود.

به منظور سرعت بخشیدن به نرخ رشد  $M$  که دومین هدف ما است، مینیمم‌سازی مخرج کسر در رابطه (۲۱) نتیجه می‌دهد که

$$\lambda_k = \min \left\{ 1, \frac{t^{\gamma} (z_k^T s_k)^{\gamma} + (y_k^T s_k)^{\gamma}}{(z_k^T s_k) \|s_k\|^{\gamma}} \right\} \quad (25)$$

توجه ۱: بر خلاف روش نیوتن که  $\alpha_k = 1$  یک همگرایی درجه دوم را نتیجه می‌دهد، در الگوریتم‌های گرادینان مزدوج یک مقدار طول گام مناسب، قابل پیش‌بینی نیست و روند زیر توصیه می‌شود:

$$t = \min\{t, T\} \quad (26)$$

که در آن

$$t_1 = \begin{cases} \alpha_k & \text{if } (1 - \alpha_k) \leq \frac{\gamma_1 (y_k^T s_k)^2}{(z_k^T s_k) \|s_k\|^2} \\ \left| 1 - \frac{\gamma_1 (y_k^T s_k)^2}{(z_k^T s_k) \|s_k\|^2} \right| & \text{o.w.} \end{cases}$$

و  $T > 0$  یک عدد ثابت دلخواه بزرگ است.

در نهایت، با جایگذاری (۲۱) در (۱۸) داریم:

$$\beta_k = \frac{(y_k^T g_{k+1})(y_k^T d_k)}{t^2 (z_k^T d_k)^2 + (y_k^T d_k)^2} - \frac{t (s_k^T g_{k+1})(z_k^T d_k)}{t^2 (z_k^T d_k)^2 + (y_k^T d_k)^2} + \frac{t^2 (z_k^T g_{k+1})(z_k^T d_k)}{t^2 (z_k^T d_k)^2 + (y_k^T d_k)^2} \quad (27)$$

$$- \frac{\|t^2 (z_k^T s_k) z_k + (y_k^T s_k) y_k - \lambda_k (z_k^T s_k) s_k\|^2}{4\gamma_1 [t^2 (z_k^T s_k)^2 + (y_k^T s_k)^2]} \frac{g_{k+1}^T d_k}{t^2 (z_k^T d_k)^2 + (y_k^T d_k)^2}$$

حال با جمع بندی آنچه گفته شد الگوریتم گرادیان مزدوج جدید خود را معرفی می‌کنیم.

#### الگوریتم ۱: الگوریتم گرادیان مزدوج سکانت بهبودیافته (MSCG)

**گام ۱:** نقطه اولیه  $x_0 \in R^n$  و مقادیر مناسب برای پارامترهای نامفی  $\rho_k$ ،  $T$ ،  $0 < c_1 < c_2 < 1$  و

$\gamma_1 + \gamma_2 < 1$  را انتخاب کنید.  $g_0 = \nabla f(x_0)$  را محاسبه کرده و قرار دهید  $d_0 = -g_0$  و  $k = 0$ .

**گام ۲:** شرط توقف را بررسی کرده و در صورت برقراری متوقف شوید، در غیراین صورت به گام ۳ بروید.

**گام ۳:** با استفاده از شرایط وولف قوی (۳) و (۴) طول گام  $\alpha_k$  را محاسبه کنید.

**گام ۴:** قرار دهید  $x_{k+1} = x_k + \alpha_k d_k$ ،  $f_{k+1} = f(x_{k+1})$ ،  $g_{k+1} = \nabla f(x_{k+1})$ ،  $s_k = x_{k+1} - x_k$  و  $y_k = g_{k+1} - g_k$ .

**گام ۵:** بردار مناسب  $u_k \in R^n$  را به گونه‌ای انتخاب کرده که  $s_k^T u_k \neq 0$  و سپس  $\theta_k$  و  $z_k$  را به ترتیب با استفاده از روابط (۱۲) و (۱۵) به دست آورید.

**گام ۶:**  $\lambda_k$  و  $t$  را با استفاده از (۲۵) و (۲۶) حساب کنید.

**گام ۷:** پارامتر گرادیان مزدوج  $\beta_k$  را با استفاده از (۲۷) به دست آورید.

**گام ۸:** جهت جستجوی  $d_{k+1} = -g_{k+1} + \beta_k d_k$  را حساب کنید.

**گام ۹:** قرار دهید  $k = k + 1$  و به گام ۲ بروید.

هدف نهایی ما بررسی شرایط همگرایی سراسری برای الگوریتم ۱ (MSCG) است.

#### ۴ همگرایی سراسری

برای تضمین همگرایی نیاز است مطابق آنچه در ادبیات موضوع مرسوم است تغییراتی جزئی را به صورت زیر در

پارامتر  $\beta_k$  ایجاد کنیم، و پارامتر را به صورت زیر تعریف می‌کنیم



$$\beta_k^N = \max(\beta_k, \chi_k) \quad (28)$$

که در آن

- $\chi_k$  یک تابع حقیقی مقدار است،
- $\|\chi_k\| \|d_k\|$  از بالا کراندار است،

$$\chi_k \leq \frac{\varepsilon \|g_{k+1}\|^r}{g_{k+1}^T d_k} \quad \text{برای برخی } \varepsilon < 1 \text{ و } g_{k+1}^T d_k > 0 \text{ داریم}$$

قبل از بررسی همگرایی قضیه زیر را بیان می‌کنیم.

**قضیه ۱:** فرض کنید،  $f$  یک تابع از پایین کراندار است و تابع گرادیان  $g(x)$  بر روی مجموعه کراندار زیر پیوسته‌ی لیپ شیتز می‌باشد،

$$V = \{x \in R^n : f(x) \leq f(x_0)\}, \quad (29)$$

یعنی،  $L > 0$  وجود دارد به طوری که

$$\|g(x) - g(y)\| \leq L \|x - y\| \quad (30)$$

به علاوه، دنباله‌ی حاصل از تکرارهای الگوریتم یعنی  $x_k$ ، کراندار است. برای هر روش کاهش‌ی مانند (۲) که در آن  $\alpha_k$  با استفاده از جستجوی خطی و وولف قوی محاسبه می‌شود، داریم:

$$\sum_{k=1}^{\infty} \frac{(g_k^T d_k)^r}{\|d_k\|^r} < \infty \quad (31)$$

اثبات: به مقاله [۶] مراجعه شود.

حال با استفاده از قضیه ۱ همگرایی سراسری الگوریتم ۱ را اثبات می‌کنیم.

**قضیه ۲:** الگوریتم MSCG با  $\beta_k^N$  معرفی شده در (۲۸) را در نظر بگیرید، آنگاه برای تابع دلخواه  $f$  با جستجوی

خطی و وولف قوی با شرایط (۳) و (۴) و  $\left\{ \frac{1-c_\gamma}{3(1+c_\gamma-2c_\gamma)}, m y_k^T s_k \right\}$  که  $0 \leq \rho_k < \min$  ثابت بزرگ و

مثبتی است، داریم

$$\liminf_{k \rightarrow \infty} \|g_k\| = 0$$

اثبات: از لم ۱ و با روشی مشابه اثبات لم ۴ در [۱۴] داریم

$$d_{k+1}^T g_{k+1} \leq -\max(1-\varepsilon, 1-\gamma_1-\gamma_\gamma) \|g_{k+1}\|^2. \quad (32)$$

اگر برای یک زیر دنباله  $k_j$ ، داشته باشیم  $\beta_{k_j}^N = \chi_{k_j}$ ، آنگاه با توجه به کرانداری  $\|\chi_k\| \|d_k\|$  برای  $\varepsilon > 0$  داریم

$$\|d_{k_j+1}\| = \|-g_{k_j+1} + \beta_{k_j}^N d_{k_j}\| \leq \|g_{k_j+1}\| + \|\chi_{k_j}\| \|d_{k_j}\| \leq \varepsilon$$

کران حاصل برای  $d_{k_j+1}$  و (۳۲) با استفاده از (۳۱) سبب به وجود آمدن تناقض شده و اثبات کامل می‌شود.

اگر برای  $k$  به اندازه کافی بزرگ، داشته باشیم  $\beta_k^N = \beta_k$ ، آنگاه یک کران روی  $\beta_k$  به صورت زیر حاصل می‌شود.

ابتدا، با استفاده از (۴) و (۱۹) داریم

$$d_k^T y_k = d_k^T g_{k+1} - d_k^T g_k \geq (c_r - 1) d_k^T g_k > 0, \quad (33)$$

فرض کنید  $\eta_1 > 0$  وجود دارد به طوری که  $\|g_k\| > \eta_1$ ، آنگاه با استفاده از (32) و (33) داریم

$$d_k^T y_k \geq (1 - c_r) \max(1 - \varepsilon, 1 - \gamma_1 - \gamma_r) \eta_1^2, \quad (34)$$

و

$$\frac{|d_k^T g_{k+1}|}{|d_k^T y_k|} \leq \max\left(\frac{c_r}{1 - c_r}, 1\right), \quad (35)$$

(به [25] مراجعه شود). از طرف دیگر، (9) و (23) نتیجه می‌دهند که

$$d_k^T z_k \geq -m_1 (d_k^T g_k) \geq m_1 c \|g_k\|^r \geq m_1 c \eta_1^r. \quad (36)$$

سپس، نشان می‌دهیم که ثابت  $R > 0$  وجود دارد به طوری که

$$|\beta_k| \leq R \|s_k\|. \quad (37)$$

به وضوح داریم

$$t^r (z_k^T d_k)^r + (y_k^T d_k)^r \geq t^r (z_k^T d_k)^r \quad (38)$$

و

$$t^r (z_k^T d_k)^r + (y_k^T d_k)^r \geq (y_k^T d_k)^r \quad (39)$$

با استفاده از (27)، (38)، (39) و  $s_k = \alpha_k d_k$  داریم

$$\begin{aligned} |\beta_k| &\leq \frac{|y_k^T g_{k+1}| \|y_k^T d_k\|}{(y_k^T d_k)^r} + \frac{|t| \|s_k^T g_{k+1}\| \|z_k^T d_k\|}{(y_k^T d_k)^r} + \frac{t^r |z_k^T g_{k+1}| \|z_k^T d_k\|}{t^r (z_k^T d_k)^r} \\ &\quad + \frac{|g_{k+1}^T d_k|}{\varepsilon \gamma_r (t^r (z_k^T d_k)^r + (y_k^T d_k)^r)} \left( \frac{\|t^r (z_k^T s_k) z_k\|^r}{t^r (z_k^T s_k)^r} + \frac{\|(y_k^T s_k) y_k\|^r}{(y_k^T s_k)^r} + \frac{\|(z_k^T s_k) s_k\|^r}{(y_k^T s_k)^r} \right) \\ &\quad + \frac{\varepsilon \|t^r (z_k^T s_k) z_k\| \cdot \|(y_k^T s_k) y_k\|}{t^r (z_k^T s_k)^r} + \frac{\varepsilon \|t^r (z_k^T s_k) z_k\| \cdot \|(z_k^T s_k) s_k\|}{t^r (z_k^T s_k)^r} + \frac{\varepsilon \|(y_k^T s_k) y_k\| \cdot \|(z_k^T s_k) s_k\|}{(y_k^T s_k)^r} \\ \Rightarrow |\beta_k| &\leq \frac{|y_k^T g_{k+1}|}{y_k^T d_k} + \frac{|t| \|s_k^T g_{k+1}\| \|z_k^T d_k\|}{(y_k^T d_k)^r} + \frac{|z_k^T g_{k+1}|}{z_k^T d_k} \\ &\quad + \frac{1}{\varepsilon \gamma_r} \left( \|z_k\|^r \times \frac{|g_{k+1}^T d_k|}{(z_k^T d_k)^r} + \|y_k\|^r \times \frac{|g_{k+1}^T d_k|}{(y_k^T d_k)^r} + \frac{(z_k^T s_k)^r \|s_k\|^r}{(y_k^T s_k)^r} \times \frac{|g_{k+1}^T d_k|}{(y_k^T d_k)^r} \right) \\ &\quad + \frac{\varepsilon \|z_k\| \cdot \|y_k\|}{(z_k^T d_k)^r} \times \frac{|g_{k+1}^T d_k|}{(y_k^T d_k)^r} + \varepsilon \|z_k\| \cdot \|s_k\| \times \frac{|g_{k+1}^T d_k|}{(y_k^T d_k)^r} + \frac{\varepsilon (z_k^T s_k)^r \cdot \|y_k\| \cdot \|s_k\|}{(y_k^T s_k)^r} \times \frac{|g_{k+1}^T d_k|}{(y_k^T d_k)^r} \end{aligned}$$

$$\begin{aligned} \Rightarrow |\beta_k| &\leq \frac{1}{y_k^T d_k} (|y_k^T g_{k+1}| + |t| \|s_k^T g_{k+1}\| + \frac{|z_k^T s_k|}{(y_k^T s_k)} + \frac{\|y_k\|}{\epsilon \gamma_\tau} \times \frac{|g_{k+1}^T d_k|}{y_k^T d_k} \\ &+ \frac{\|s_k\|}{\epsilon \gamma_\tau} \times \frac{(z_k^T s_k)^\tau}{(y_k^T s_k)^\tau} \times \frac{|g_{k+1}^T d_k|}{y_k^T d_k} + \frac{\|z_k\| \cdot \|s_k\|}{\tau \gamma_\tau} \times \frac{|g_{k+1}^T d_k|}{y_k^T d_k} + \frac{\|y_k\| \cdot \|s_k\|}{\tau \gamma_\tau} \times \frac{|z_k^T s_k|}{(y_k^T s_k)} \times \frac{|g_{k+1}^T d_k|}{y_k^T d_k} \\ &+ \frac{1}{z_k^T d_k} (|z_k^T g_{k+1}| + \frac{\|z_k\|}{\epsilon \gamma_\tau} \times \frac{|g_{k+1}^T d_k|}{z_k^T d_k} + \frac{\|z_k\| \cdot \|y_k\|}{\tau \gamma_\tau} \times \frac{|g_{k+1}^T d_k|}{y_k^T d_k}) \end{aligned} \quad (40)$$

اکنون با استفاده از قضیه مقدار میانگین کران بالای  $\theta_k$  در رابطه (۱۵) را به دست می آوریم

$$\begin{aligned} \theta_k &= \epsilon(f_k - f_{k+1}) + \tau(\nabla f_k + \nabla f_{k+1})^T s_k \\ &= \epsilon \nabla f(\eta_k)^T (x_k - x_{k+1}) + \tau(\nabla f_k + \nabla f_{k+1})^T s_k \\ &= -\epsilon \nabla f(\eta_k)^T s_k + \tau(\nabla f_k + \nabla f_{k+1})^T s_k \\ &= \tau \{ \nabla f_k - \nabla f(\eta_k) + \nabla f_{k+1} - \nabla f(\eta_k) \}^T s_k \end{aligned}$$

که در اینجا  $\eta_k = \omega x_k + (1-\omega)x_{k+1}$  و  $\omega \in (0, 1)$  در نتیجه با استفاده از (۳۰) داریم

$$\begin{aligned} |\theta_k| &\leq \tau (\|\nabla f_k - \nabla f(\eta_k)\| + \|\nabla f_{k+1} - \nabla f(\eta_k)\|) \|s_k\| \\ &\leq \tau (L\|x_k - \eta_k\| + L\|x_{k+1} - \eta_k\|) \|s_k\| \\ &= \tau (L(1-\omega)\|x_k - x_{k+1}\| + L\omega\|x_{k+1} - x_k\|) \|s_k\| \\ &= \tau L \|s_k\|^\tau. \end{aligned} \quad (41)$$

حال با استفاده از فرض قضیه و همچنین روابط (۱۵)، (۳۰) و (۴۱) داریم

$$\left| \frac{z_k^T s_k}{y_k^T s_k} \right| = \left| \frac{y_k^T s_k + \rho_k \frac{\theta_k}{s_k^T u_k} u_k^T s_k}{y_k^T s_k} \right| = \left| 1 + \frac{\rho_k \theta_k}{y_k^T s_k} \right| < 1 + |m\theta_k| < 1 + \tau L m \|s_k\|^\tau. \quad (42)$$

و

$$\|z_k\| = \left\| y_k + \rho \frac{\theta_k}{s_k^T u_k} u_k \right\| \leq \|y_k\| + m|\theta_k| \|u_k\| \leq L\|s_k\| + \tau L m \|s_k\|^\tau \|u_k\|,$$

در نامساوی فوق با توجه به کراندار بودن  $\|s_k\|$  و  $\|y_k\|$  با هر یک از انتخاب های  $u_k = y_k$  یا  $u_k = s_k$  می توان فرض کرد ثابت  $L' > 0$  وجود دارد به طوری که

$$\|z_k\| \leq L' \|s_k\| \quad (43)$$

در ادامه با استفاده از (۲۶)، (۳۰)، (۴۲)، (۴۳)، نامساوی کوشی-شوارتز و این فرض که  $\eta_\tau$  یک کران بالا برای  $\|g_k\|$  است، داریم

$$\begin{aligned} |\beta_k| &\leq \frac{1}{y_k^T d_k} (L\eta_\tau \|s_k\| + T\eta_\tau (1 + \tau L m \|s_k\|^\tau) \|s_k\| + \frac{L^\tau \|s_k\|^\tau}{\epsilon \gamma_\tau} \times \frac{|g_{k+1}^T d_k|}{y_k^T d_k} \\ &+ \frac{\|s_k\|^\tau}{\epsilon \gamma_\tau} \times (1 + \tau L m \|s_k\|^\tau)^\tau \times \frac{|g_{k+1}^T d_k|}{y_k^T d_k} + \frac{L' \|s_k\|^\tau}{\tau \gamma_\tau} \times \frac{|g_{k+1}^T d_k|}{y_k^T d_k} + \frac{L \|s_k\|^\tau}{\tau \gamma_\tau} \times (1 + \tau L m \|s_k\|^\tau) \times \frac{|g_{k+1}^T d_k|}{y_k^T d_k} \\ &+ \frac{1}{z_k^T d_k} (L\eta_\tau \|s_k\| + \frac{L^\tau \|s_k\|^\tau}{\epsilon \gamma_\tau} \times \frac{|g_{k+1}^T d_k|}{y_k^T d_k} + \frac{LL' \|s_k\|^\tau}{\tau \gamma_\tau} \times \frac{|g_{k+1}^T d_k|}{y_k^T d_k}). \end{aligned} \quad (44)$$

از روابط (۳۴)، (۳۵)، (۳۶)،

$$D = (1 - c_r) \max(1 - \varepsilon, 1 - \gamma_1 - \gamma_r) \eta_1^r, \quad W = \max\left(\frac{c_r}{1 - c_r}, 1\right)$$

و کراننداری دنباله تکرارها می‌توان ثابت  $R > 0$  در رابطه (۳۷) را به صورت زیر معرفی کرد

$$R = \frac{1}{D} \left( L\eta_r + T\eta_r(1 + \nu Lm \|s_k\|^r) + \frac{L^r \|s_k\|}{4\gamma_r} \times W \right. \\ \left. + \frac{\|s_k\|}{4\gamma_r} \times (1 + \nu Lm \|s_k\|^r) \times W + \frac{L^r \|s_k\|}{2\gamma_r} \times W + \frac{L \|s_k\|}{2\gamma_r} \times (1 + \nu Lm \|s_k\|^r) \times W \right) \\ + \frac{1}{m_1 c \eta_1^r} \left( L^r \eta_r + \frac{L^r \|s_k\|}{4\gamma_r} \times W + \frac{LL^r \|s_k\|}{2\gamma_r} \times W \right).$$

ادامه اثبات مشابه قضیه ۲-۳ در [۲۶] است.

## ۵ نتایج عددی و مقایسه‌ها

در این بخش نتایج عددی به دست آمده را گزارش می‌دهیم. در ادامه روند تکراری (۲) و (۵) را به ازای پنج مقدار متفاوت برای  $\beta_k$  در نظر می‌گیریم:

$\beta_k^{New}$ : پارامتر ارایه شده در الگوریتم ۱ (MSCG) به ازای

$$\rho_k = 0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1$$

$\beta_k^F$ : پارامتر ارایه شده توسط فاطمی در [۱۴].

$\beta_k^{YT}$ : پارامتر ارایه شده توسط یابه و تاکانو در [۱۳] به ازای  $(\rho = 0.5, t = 0.3)$  و  $(\rho = 0.7, t = 0.5)$ .

$\beta_k^{BG1}$ : پارامتر (۳.۲۱) ارایه شده توسط بابایی کفاکی و همکارانش در [۲۲] با  $t = 0.5005$ .

$\beta_k^{BG2}$ : پارامتر (۳.۵۳) ارایه شده توسط بابایی کفاکی و همکارانش در [۲۲] با  $t = 0.5010$ .

تمام پارامترهای گرادیان مزدوج در نظر گرفته شده متعلق به خانواده‌ی دای-لیائو هستند و از شرط سکانت اصلاح شده استفاده کرده‌اند به جز پارامتر  $\beta_k^F$ .

همچنین موارد زیر در پیاده‌سازی الگوریتم‌ها در نظر گرفته شده است:

- از روند جستجوی خطی CG-DESCENT با پارامترهای اولیه ارایه شده در [۲۷] استفاده شده است.
- دو انتخاب برای  $u_k$  در نظر گرفته شده است:  $s_k$  و  $y_k$ .
- شرط توقف الگوریتم‌ها عبارت است از

$$\|\nabla f(x_k)\|_\infty \leq \max(10^{-6}, 10^{-12} \|\nabla f(x_1)\|_\infty)$$

و یا تعداد استفاده بیش از ۳۰۰۰ بار از مقدار تابع.

- انتخاب  $\gamma_1 = 0.1$  و  $\gamma_r = 0.98$ .

به منظور بررسی و مقایسه کارایی الگوریتم‌ها، ۸۰ مساله از مجموعه CUTer با ابعاد مختلف در نظر گرفته

شده است که در جدول ۱ معرفی شده‌اند (به منظور مشاهده مسایل به [۲۸] مراجعه شود). از آنجایی که روش‌های


گرایان مزدوج برای حل مسایل اندازه بزرگ بسیار کارآمد هستند، لذا سعی کرده‌ایم که بیشتر از این مسایل استفاده کنیم. علاوه بر آن برخی مسایل اندازه کوچک که حل آنها توسط بسیاری از الگوریتم‌ها دشوار بوده و ممکن است بدوضع باشند نیز در نظر گرفته شده‌اند.

نتایج با استفاده از یک کامپیوتر با پردازنده Intel Core(TM) i7-5500 و رم 8GB و سیستم عامل لینوکس در محیط برنامه برنامه‌نویسی MATLAB R2015a به دست آمده‌اند.


الگوریتم پیشنهادی ما تمام مسایل را با موفقیت حل کرده، در حالی که پارامترهای  $\beta_k^{BG2}$  و  $\beta_k^{BG1}$ ،  $\beta_k^{YT}$  برای مساله DANWOODLS بدون جواب بوده‌اند. با مشاهده نتایج و بررسی نمودار عملکرد معرفی شده در [۱۵] برای تعداد محاسبات تابع، تعداد محاسبات گرایان و زمان پردازنده در اجرای مسایل (CPU time)، در می‌یابیم که الگوریتم ۱ با پارامتر  $\beta_k^{New}$  برای بسیاری از انتخاب‌های  $\rho_k$  از سایر الگوریتم‌ها کارآمدتر است، به ویژه برای  $u_k = s_k$ . ما مقادیر  $\rho_k = 0/7$  و  $\rho_k = 0/8$  را به عنوان بهترین انتخاب‌ها برای الگوریتم معرفی می‌کنیم. تصاویر ۱ تا ۳، نمودارهای عملکرد را برای تمام الگوریتم‌ها نشان می‌دهند.

جدول ۱. مسایل


| تابع       | بعد   | تابع       | بعد  | تابع      | بعد   | تابع     | بعد   |
|------------|-------|------------|------|-----------|-------|----------|-------|
| AKIVA      | 2     | DANWOODLS  | 2    | HILBERTA  | 2     | QUARTC   | 5000  |
| ALLINITU   | 4     | DENSCHA    | 2    | HILBERTB  | 10    | ROSENBR  | 2     |
| ARGLBLE    | 200   | DENSCHB    | 2    | HUMPS     | 2     | S308     | 2     |
| ARGLCLE    | 200   | DIXMAANA   | 3000 | INTEQNELS | 12    | SBRYBND  | 5000  |
| ARGLINA    | 200   | DIXMAANB   | 3000 | JENSMP    | 2     | SCHMVETT | 5000  |
| ARGLINB    | 200   | DIXMAANC   | 3000 | KOWOSB    | 4     | SENSORS  | 100   |
| ARGLINC    | 200   | DIXMAAND   | 3000 | KOWOSBNE  | 4     | SINEVAL  | 2     |
| ARWHEAD    | 5000  | DIXMAANE   | 3000 | LIARWHD   | 5000  | SISSER   | 2     |
| BARD       | 3     | DIXMAANF   | 3000 | LOGHAIRY  | 2     | SPARSOUR | 10000 |
| BEALE      | 2     | DIXMAANG   | 3000 | LSCILS    | 3     | SPMSRTLS | 4999  |
| BIGGS6     | 6     | DIXMAANH   | 3000 | MANCINO   | 100   | SROSENBR | 5000  |
| BOX3       | 3     | DJTL       | 2    | MARATOSB  | 2     | TOINTGOR | 50    |
| BROWNAL    | 200   | DQDRTIC    | 5000 | MGH09LS   | 4     | TOINTGSS | 5000  |
| BROYDN3DLS | 10    | ECKERLE4LS | 3    | MGH10LS   | 3     | TOINTQOR | 50    |
| BRYBND     | 500   | EG2        | 1000 | MODBEALE  | 2000  | TQUARTIC | 5000  |
| CHAINWOO   | 4000  | ENSOLS     | 9    | MOREBV    | 5000  | VARDIM   | 200   |
| CHNROSNB   | 50    | EXTROSNB   | 1000 | NONDIA    | 5000  | VAREIGVL | 50    |
| CHNRSNB    | 50    | FMINSURF   | 5625 | PENALTY1  | 1000  | WOODS    | 4000  |
| COSINE     | 10000 | GENROSE    | 500  | POWELLSG  | 5000  | YFITU    | 3     |
| DANIWOODLS | 2     | HAIRY      | 2    | POWER     | 10000 | ZANGWIL2 | 2     |



شکل ۱. نمودار عملکرد تعداد محاسبات تابع (بالا سمت راست:  $\rho_k = 0/7$  و  $u_k = s_k$ ، بالا سمت چپ:  $\rho_k = 0/8$  و  $u_k = s_k$ ، پایین:  $u_k = y_k$  و  $\rho_k = 0/8$ )



شکل ۲. نمودار عملکرد تعداد محاسبات گرادینان (بالا سمت راست:  $\rho_k = 0/7$  و  $u_k = s_k$ ، بالا سمت چپ:  $\rho_k = 0/8$  و  $u_k = s_k$ ، پایین:  $u_k = y_k$  و  $\rho_k = 0/8$ )



شکل ۳. نمودار عملکرد زمان پردازنده (بالا سمت راست:  $\rho_k = 0/7$  و  $u_k = s_k$ ، بالا سمت چپ:  $\rho_k = 0/8$  و  $u_k = s_k$ ، پایین:  $u_k = y_k$  و  $\rho_k = 0/8$ )

## ۶ نتیجه گیری

نتایج قابل قبول حاصل از به کارگیری شرط سکانت بهبود یافته، ما را ترغیب کرد تا به ارایه یک روش گرادیان مزدوج کارا مبتنی بر این شرط پردازیم. این روش علاوه بر همگرایی سراسری در شرط کاهش کافی صدق می کند. نتایج عددی نشان می دهند که با انتخاب پارامترهای مناسب این روش بسیار قابل قبول بوده و عملکرد بهتری نسبت به روش های دیگر به ویژه روش ارایه شده توسط فاطمی در [۱۴] و روش یابه و تاکانو در [۱۳] دارد. در ادامه پیشنهاداتی برای کارهای آتی ارایه می شود.

- بررسی کارایی روش در حل مسایل در حوزه های مهندسی و به ویژه پردازش تصویر.
- امکان سنجی تاثیر پارامترهای جدید در بهبود عملکرد روش و معرفی پارامترهای بهینه.
- بررسی تغییرات پارامترهای روش به جهت طراحی یک الگوریتم کارا برای حل مسایل ناهموار.

## منابع

- [1] Hestenes, M. R., Stiefel, E., (1952). Methods of conjugate gradients for solving linear systems. NBS Washington, DC, 49(1).
- [2] Fletcher, R., Reeves, C. M., (1964). Function minimization by conjugate gradients. *Comput. J.*, 7, 149-154.
- [3] Polyak, B. T., (1969). The conjugate gradient method in extremal problems. *USSR Comput. Math. Math. Phys.*, 9(4), 94-112.
- [4] Fletcher, R., (2013). Practical methods of optimization. John Wiley & Sons.
- [5] Liu, Y., Storey, C., (1991). Efficient generalized conjugate gradient algorithms, part 1: theory. 69(1), 129-137.
- [6] Dai, Y. H., Yuan, Y., (1999). A nonlinear conjugate gradient method with a strong global convergence property. 10(1), 177-182.
- [7] Andrei, N., (2007). Numerical comparison of conjugate gradient algorithms for unconstrained optimization. *Stud. Informatics Control*, 16(4), 333-352.
- [8] Dai, Y.H., Liao, L.Z., (2001). New conjugacy conditions and related nonlinear conjugate gradient methods. *Appl. Math. Optim.*, 43(1), 87-101.
- [9] Babaie-Kafaki, S., Ghanbari, R., (2014). The Dai--Liao nonlinear conjugate gradient method with optimal parameter choices. *Eur. J. Oper. Res.*, 234(3), 625-630.
- [10] Babaie-Kafaki, S., Ghanbari, R., (2014). A descent family of Dai--Liao conjugate gradient methods. *Optim. Methods Softw.*, 29(3), 583-591.
- [11] Andrei, N., (2018). A Dai-Liao conjugate gradient algorithm with clustering of eigenvalues. *Numer. Algorithms*, 77(4), 1273-1282.
- [12] Dai, Y. H., Kou, C. X., (2013). A nonlinear conjugate gradient algorithm with an optimal property and an improved Wolfe line search. *SIAM J. Optim.*, 23(1), 296-320.
- [13] Yabe, H., Takano, M., (2004). Global convergence properties of nonlinear conjugate gradient methods with modified secant condition. *Comput. Optim. Appl.*, 28(2), 203-225.
- [14] Fatemi, M., (2015). A new efficient conjugate gradient method for unconstrained optimization. *J. Comput. Appl. Math.*, 300, 207-216.
- [15] Dolan, E. D., Moré, J. J., (2002). Benchmarking optimization software with performance profiles. *Math. Program.*, 91(2), 201-213.
- [16] Zhang, J. Z., Deng, N. Y., Chen, L. H., (1999). New quasi-Newton equation and related methods for unconstrained optimization. *J. Optim. Theory Appl.*, 102(1), 147-167.
- [17] Zhang, J., Xu, C., (2001). Properties and numerical performance of quasi-{N}ewton methods with modified quasi-{N}ewton equations. *J. Comput. Appl. Math.*, 137(2), 269-278.
- [18] Li, G., Tang, C., Wei, Z., (2007). New conjugacy condition and related new conjugate gradient methods for unconstrained optimization. *J. Comput. Appl. Math.*, 202(2), 523-539.
- [19] Babaei, S., Arazm, M., (2018). An extension of a three-term conjugate gradient method based on the objective function values with guaranteeing global convergence without convexity

- assumption. *Journal of Operational Research and Its Applications.*, 15 (1), 19-28.
- [20] Andrei, N., (2009). Accelerated conjugate gradient algorithm with modified secant condition for unconstrained optimization. *Stud. Informatics Control*, 18(3), 211-232.
- [21] Babaie-Kafaki, S., (2014). Two modified scaled nonlinear conjugate gradient methods. *J. Comput. Appl. Math.*, 261, 172-182.
- [22] Babaie-Kafaki, S., Ghanbari, R., Mahdavi-Amiri, N., (2010). Two new conjugate gradient methods based on modified secant equations. *J. Comput. Appl. Math.*, 234(5), 1374-1386.
- [23] Babaie-Kafaki, S., Fatemi, M., Mahdavi-Amiri, M., (2011). Two effective hybrid conjugate gradient algorithms based on modified BFGS updates. *Numer. Algorithms*, 58(3), 315-331.
- [24] Narushima, Y., Yabe, H., (2012). Conjugate gradient methods based on secant conditions that generate descent search directions for unconstrained optimization. *J. Comput. Appl. Math.*, 236(17), 4303-4317.
- [25] Akbari, Z., (2017). A Conic Trust Region Method for Locally Lipschitz Optimization Problems. *Journal of Operational Research and Its Applications.* 14(2), 95-109.
- [26] Hager, W. W., Zhang, H., (2005). A new conjugate gradient method with guaranteed descent and an efficient line search. *SIAM J. Optim.*, 16(1), 170-192.
- [27] Hager, W. W., Zhang, H., (2006). Algorithm 851:  $\{CG\}_{DESCENT}$ , a conjugate gradient method with guaranteed descent. *ACM Trans. Math. Softw.*, 32(1), 113-137.
- [28] Gould, N. I. M., Orban, D. M., Toint, P. L., (2003). CUTER and SifDec: A constrained and unconstrained testing environment, revisited. *ACM Trans. Math. Softw.*, 29(4), 373-394.