

ОСТАВЕ-ПРОГРАМА `ralgb5a` – $r(\alpha)$ -АЛГОРИТМ
З АДАПТИВНИМ КРОКОМ

ПОСІБНИК КОРИСТУВАЧА

АНОТАЦІЯ

“Octave-програма **ralgb5a** – $r(\alpha)$ -алгоритм з адаптивним кроком”

Документ містить першу редакцію посібника користувача, необхідну для роботи з дослідницькою програмою **ralgb5a**, яка призначена для мінімізації гладких та негладких опуклих функцій.

Програма **ralgb5a** реалізує подану нижче модифікацію r -алгоритмів Шора – субградієнтних методів з розтягом простору в напрямку різниці двох послідовних субградієнтів. Ця модифікація використовує адаптивний спосіб регулювання кроку в напрямі антисубградієнта у перетвореному просторі змінних.

Програма розроблена на некомерційній мові GNU Octave.

ЗМІСТ

1. Про $r(\alpha)$-алгоритми та octave-функцію <code>ralgb5a</code>.....	4
1.1 Що таке $r(\alpha)$ -алгоритми?	4
1.2 Регулювання кроку.	5
1.3 Octave-функція <code>ralgb5a</code>	7
2. Опис програми <code>ralgb5a</code>.....	9
2.1 Код програми <code>ralgb5a</code>	9
2.2 Тестовий приклад.....	10
2.3 Протокол роботи програми.....	11
3. Вимоги до програми	12
ЛІТЕРАТУРА.....	12

1. Про $r(\alpha)$ -алгоритми та Octave-функцію `ralgb5a`

Для мінімізації гладких та негладких опуклих функцій можна використовувати подану нижче модифікацію r -алгоритмів Шора – субградієнтних методів з розтягом простору в напрямку різниці двох послідовних субградієнтів [1 – 3]. Ця модифікація відома як $r(\alpha)$ -алгоритми, де α – коефіцієнт розтягу простору ($\alpha > 1$), який є одним і тим самим на кожній ітерації r -алгоритмів. Опис $r(\alpha)$ -алгоритмів наведемо згідно [3].

1.1 Що таке $r(\alpha)$ -алгоритми? Розглянемо задачу пошуку точки мінімуму опуклої функції $f(x)$, $x \in R^n$. Мінімальне значення функції позначимо $f^* = f(x^*)$, де $x^* \in X^*$. Будемо вважати, що множина мінімумів X^* є обмеженою, тобто виконується умова $\lim_{\|x\| \rightarrow \infty} f(x) = +\infty$, яка забезпечує коректність адаптивного регулювання кроку в r -алгоритмах.

Означення. $r(\alpha)$ -Алгоритмом мінімізації функції $f(x)$ називається ітеративна процедура знаходження послідовності n -вимірних векторів $\{x_k\}_{k=0}^{\infty}$ та послідовності $n \times n$ -матриць $\{B_k\}_{k=0}^{\infty}$ за таким правилом:

$$x_{k+1} = x_k - h_k B_k \xi_k, \quad B_{k+1} = B_k R_\beta(\eta_k), \quad k = 0, 1, 2, \dots, \quad (1)$$

де

$$\xi_k = \frac{B_k^T g_f(x_k)}{\|B_k^T g_f(x_k)\|}, \quad h_k \geq h_k^* = \arg \min_{h \geq 0} f(x_k - h B_k \xi_k), \quad (2)$$

$$\eta_k = \frac{B_k^T r_k}{\|B_k^T r_k\|}, \quad r_k = g_f(x_{k+1}) - g_f(x_k). \quad (3)$$

Тут x_0 – стартова точка; $B_0 = I_n$ – одинична $n \times n$ -матриця¹; h_k^* – величина кроку до точки мінімуму функції $f(x)$ у напрямку нормованого антисубградієнта в перетвореному просторі змінних; $R_\beta(\eta) = I_n + (\beta - 1)\eta\eta^T$ – оператор стиснення простору субградієнтів у нормованому напрямку η з

¹В якості матриці B_0 часто вибирають діагональну матрицю D_n з додатними коефіцієнтами на діагоналі, за допомогою якої здійснюється масштабування змінних.

коефіцієнтом $\beta = 1/\alpha < 1$; $g_f(x_k)$ і $g_f(x_{k+1})$ – субградієнти функції $f(x)$ в точках x_k та x_{k+1} . Якщо на ітерації k процесу (1) – (3) виконані деякі критерії (умови) зупинки, то вважаємо $k^* = k$, $x_k^* = x_k$ і закінчуємо роботу алгоритму.

Коментар. На кожній ітерації r -алгоритмів реалізується субградієнтний спуск для опуклої функції $\varphi(y) = f(B_k y)$ в перетвореному просторі змінних $y = A_k x$, де $A_k = B_k^{-1}$. Дійсно, якщо обидві частини формули $x_{k+1} = x_k - h_k B_k \xi_k$ домножити зліва на матрицю A_k , то отримаємо

$$y_{k+1} = A_k x_{k+1} = A_k x_k - h_k \xi_k = y_k - h_k \frac{B_k^T g_f(x_k)}{\|B_k^T g_f(x_k)\|} = y_k - h_k \frac{g_\varphi(y_k)}{\|g_\varphi(y_k)\|}, \quad (4)$$

де вектор $g_\varphi(y_k) = B_k^T g_f(x_k)$ є субградієнтом функції $\varphi(y) = f(B_k y)$ в точці $y_k = A_k x_k$ простору змінних $y = A_k x$. Дійсно, субградієнт $g_f(x_k)$ для опуклої функції $f(x)$ задовільняє нерівності

$$f(x) \geq f(x_k) + (g_f(x_k))^T (x - x_k) \quad \forall x \in E^n,$$

звідки, здійснюючи заміну змінних $x = B_k y$, отримаємо нерівність

$$\varphi(y) \geq \varphi(y_k) + (B_k^T g_f(x_k))^T (y - y_k) = \varphi(y_k) + (g_\varphi(y_k))^T (y - y_k) \quad \forall y \in E^n$$

для субградієнта $g_\varphi(y_k)$ опуклої функції $\varphi(y) = f(B_k y)$.

Сімейство $r(\alpha)$ -алгоритмів визначається коефіцієнтом розтягу простору $\alpha > 1$ (допускається $\alpha = \infty$, що відповідає $\beta = 0$) і послідовністю величин кроків $\{h_k\}_{k=0}^\infty$, які визначають ті два послідовні субградієнти $g_f(x_k)$ і $g_f(x_{k+1})$, розтягування за різницею яких (див. формулу (3)) зменшує степінь витягнутості функції в перетвореному просторі змінних. Вибір коефіцієнта $\alpha > 1$ та величин $\{h_k\}_{k=0}^\infty$ у поєднанні з вибором критеріїв зупинки визначають той чи інший варіант $r(\alpha)$ -алгоритмів.

1.2 Регулювання кроку. Регулювання величини h_k задає певний спосіб реалізації одновимірного спуску в напрямку нормованого антисубградієнта функції $\varphi(y) = f(B_k y)$, який здійснюється в перетвореному просторі змінних

$y = A_k x$ (див. формулу (4)). В r -алгоритмах використовуються два способи регулювання кроку [2, 4].

При першому способі величина h_k вибирається з умови $h_k = h_k^*$ ($h_k \approx h_k^*$), що означає точний (чи наближений) одновимірний пошук мінімуму функції, який гарантує, що r -алгоритми є монотонними (майже монотонними) по функції, яка мінімізується. Таке регулювання кроку використовується в теоретично обґрунтованих модифікаціях $r(\alpha)$ -алгоритмів, коли коефіцієнт α можна вибрати досить великим. Це дозволило показати, що граничний варіант r -алгоритмів (при $\beta = 0$) є проєктивним методом спряжених градієнтів, та обґрунтувати для граничного варіанту r -алгоритмів з відновленням квадратичну швидкість збіжності до точки мінімуму опуклої двічі неперервної диференційовної функції при деяких умовах гладкості і регулярності. Знайдено також такі умови для кусково-гладких опуклих функцій, при яких $r_\mu(\alpha)$ -алгоритм збігається до точки мінімуму.

Другий спосіб регулювання кроку називається адаптивним і використовується в практичних реалізаціях r -алгоритмів. Він полягає у тому, що величина h_k налаштовується (адаптується) в процесі виконання одновимірного спуску, який завершується, як тільки знайдено субградієнт, що утворює негострий кут з субградієнтом, який визначає напрямок одновимірного спуску (умова завершення спуску за напрямком). Налаштування величини кроку h_k здійснюється за допомогою чотирьох параметрів: $h_0 > 0$ — величина початкового кроку (використовується на першій ітерації, а на кожній наступній — уточнюється); q_1 ($q_1 \leq 1$) — коефіцієнт зменшення кроку (якщо умова завершення спуску за напрямком виконується за перший крок); q_2 ($q_2 \geq 1$) — коефіцієнт збільшення кроку. Через кожні n_h кроків одновимірного спуску ($h_h > 1$) величина кроку збільшується в q_2 раз. Оскільки припускається, що $\lim_{\|x\| \rightarrow \infty} f(x) = +\infty$, то після скінченної кількості кроків адаптивного спуску в напрямку нормованого

антисубградієнта обов'язково виконується умова завершення спуску за напрямом.

Для адаптивного регулювання кроку коефіцієнт α не рекомендується вибирати великим. Він повинен бути узгодженим з коефіцієнтом q_1 , тому що вони обидва, хоча і по різному, впливають на зменшення величини кроку h_k . В результаті визначаються ті два послідовні субградієнти, розтягування за різницею яких зменшує степінь витягнутості функції в перетвореному просторі змінних. Цим пояснюється пришвидшена збіжність $r(\alpha)$ -алгоритмів для яружних (з витягнутими поверхнями рівня) функцій. Кількість ітерацій $r(\alpha)$ -алгоритму, необхідна для знаходження точки x_{k^*} , для якої $f(x_{k^*}) - f^* \leq \varepsilon$, емпірично оцінюється як $k^* = O(n \log(1/\varepsilon))$, де n – кількість змінних.

1.3 Octave-функція `ralgb5a` [4]. Програма **`ralgb5a`** є спрощеною (для зручності використання) версією програми **`ralgb5`** [2, с. 383–386], в якій використовується метод (1)–(3). Тут аббревіатура "**b5**" означає, що в основу програми покладено r -алгоритм у B -формі, де коректується $n \times n$ -матриця B , а кожна ітерація методу (1)–(3) вимагає $5n^2$ арифметичних операцій множення, які визначають обчислювальну трудомісткість ітерації (операції додавання враховувати не будемо через їх малий вклад у трудомісткість ітерації). З них $3n^2$ операцій множення потрібно для обчислення векторів $B_k \xi_k$, $B_k^T g_f(x_k)$ і $B_k^T r_k$ (множення матриці на вектор), а $2n^2$ операцій множення вимагає однорангова корекція матриці $B_{k+1} = B_k R_\beta(\eta_k)$. Дійсно, корекція матриці B_{k+1} виконується за формулою

$$B_{k+1} = B_k R_\beta(\eta_k) = B_k (I_n + (\beta - 1)\eta_k \eta_k^T) = B_k + (\beta - 1)(B_k \eta_k) \eta_k^T,$$

звідки легко бачити, що обчислення вектора $\eta = B_k \eta_k$ вимагає n^2 операцій множення, і стільки ж операцій множення вимагає побудова тимчасової однорангової матриці $\eta \eta_k^T$.

В програмі **ralgb5a** зафіксовані два найбільш часто використовувані параметри $q_2 = 1.1$ і $n_h = 3$. При цьому величина початкового кроку для чергової ітерації може максимально збільшуватися в 10^6 раз. У програмі **ralgb5a** використовується параметр **intp** (**interval for print**), який забезпечує друк інформації про хід процесу мінімізації через кожні **intp** ітерацій. Цей параметр дозволяє скоротити протокол роботи програми при мінімізації функції для сотень і тисяч змінних, коли кількість ітерацій оцінюється тисячами і десятками тисяч. Програма використовує параметри ε_x і ε_g для зупинки ітераційного процесу в точці $x_{k^*} \in [x_k, x_{k+1}]$, де $\|x_{k+1} - x_k\| \leq \varepsilon_x$ (зупинка за аргументом), або $\|g_f(x_{k^*})\| \leq \varepsilon_g$ (зупинка за нормою градієнта, яка використовується для гладких функцій). Використовуються також стандартна зупинка, якщо перевищено задану максимальну кількість ітерацій **maxitn**, та аварійна зупинка, яка сигналізує про те, що або функція $f(x)$ не є обмеженою знизу, або початковий крок h_0 занадто малий, і його треба збільшити.

Якщо ітераційний процес запускається зі стартової точки x_0 , то параметри $r(\alpha)$ -алгоритму рекомендується вибирати наступними: $\alpha \in [2, 4]$, $q_1 = 1.0$ (для негладких функцій), $q_1 = 0.8 \div 0.95$ (для гладких функцій), $h_0 \approx \|x_0 - x^*\|$ – оцінка відстані від стартової точки x_0 до точки мінімуму x^* . Як правило, використовуються такі параметри зупинки: $\varepsilon_x \approx 10^{-6}$, $\varepsilon_g \approx 10^{-12}$, **maxitn** $\approx 20n$. Тут параметр ε_g використовується для гладких функцій, а параметр ε_x для негладких функцій. Якщо програма **ralgb5a** завершує роботу за умовою $\|x_{k+1} - x_k\| \leq \varepsilon_x = 10^{-8}$, то цього цілком достатньо, щоб на 14–15 порядків зменшити різницю між знайденим рекордним значенням квадратичної функції f_r і її мінімальним значенням f^* .

2. Опис програми `ralgb5a`

Нижче наведемо короткий опис програми `ralgb5a`, який буде включати короткий код Octave-функції `ralgb5a` та його застосування до тестового прикладу `sabs(100,1.2)`, який полягає у мінімізації кусочно-лінійної функції

$$f(x) = \sum_{i=1}^{100} (1.2)^{i-1} |x_i - 1|, \quad f^* = f(x^*) = 0, \quad x^* = (1, 1, \dots, 1)^T, \quad (5)$$

де $|a|$ – абсолютна величина числа a . Функція (4) є яружною, так як коефіцієнти при $|x_i - 1|$, $i = 1, \dots, 100$ утворюють геометричну прогресію з показником $q = 1.2$, де мінімальний коефіцієнт дорівнює $(1.2)^0 = 1$, а максимальний – $(1.2)^{99} \approx 6.9015e+07$.

2.1 Код програми `ralgb5a`. Octave-функція `ralgb5a` знаходить x_r^* – наближення до точки мінімуму опуклої функції $f(x)$ від n змінних. Програма використовує octave-функцію `function [f, g] = calcfg (x)`, яка обчислює значення функції $f = f(x)$ і її субградієнта $g = g_f(x)$ в точці x . Ця програма готується користувачем та може мати довільне ім'я, яке підтримує синтаксис octave. Код програми, що включає і короткі англійські коментарі для вхідних та вихідних параметрів, наведено нижче.

```
# Input parameters:
#   calcfg - name of the function calcfg(x) for calculation of f and g
#   x - the starting point, x0(1:n) (it is modified in the program)
#   alpha - the value of coefficient of space dilation
#   h0, q1 - parameters of the adaptive step adjustment
#   epsx, epsg, maxitn - stop parameters
#   intp - print information every intp iteration
# Output parameters:
#   xr - a minimum point, which was found by the program, xr(1:n)
#   fr - the value of the function f at the point xr
#   itn - the number of iterations used by the program
#   nfg - the number of function calcfg calls
#   istop - exit code (2 = epsg, 3 = epsx, 4 = maxitn, 5 = error)
function [xr,fr,itn,nfg,istop] = ralgb5a(calcfg,x,alpha,h0,q1, #row001
                                     epsg,epsx,maxitn,intp);
itn = 0; B = eye(length(x)); hs = h0; lsa = 0; lsm = 0; #row002
xr = x; [fr,g0] = calcfg(xr); nfg = 1; #row003
printf("itn %4d f%15.6e fr%15.6e nfg %4d\n",itn,fr,fr,nfg); #row004
if(norm(g0) < epsg) istop = 2; return; endif #row005
for (itn = 1:maxitn) #row006
```

```

dx = B * (g1 = B' * g0)/norm(g1); #row007
d = 1; ls = 0; ddx = 0; #row008
while (d > 0) #row009
    x -= hs * dx; ddx += hs * norm(dx); #row010
    [f, g1] = calcfg(x); nfg ++; #row011
    if (f < fr) fr = f; xr = x; endif #row012
    if(norm(g1) < epsg) istop = 2; return; endif #row013
    ls ++; (mod(ls,3) == 0) && (hs *= 1.1); #row014
    if(ls > 500) istop = 5; return; endif #row015
    d = dx' * g1; #row016
endwhile #row017
(ls == 1) && (hs *= q1); lsa=lsa+ls; lsm=max(lsm,ls); #row018
if(mod(itn,intp)==0) #row019
    printf("itn %4d f %14.6e fr %14.6e", itn, f, fr); #row020
    printf(" nfg %4d lsa %3d lsm %3d\n", nfg, lsa, lsm); #row021
    lsa=0; lsm=0; #row022
endif #row023
if(ddx < epsx) istop = 3; return; endif #row024
xi = (dg = B' * (g1 - g0) )/norm(dg); #row025
B += (1 / alpha - 1) * B * xi * xi'; #row026
g0 = g1; #row027
endfor #row028
istop = 4; #row029
endfunction #row030

```

При мінімізації негладких функцій рекомендується вибирати: $\alpha=2 \div 3$, $h_0=1.0$, $q_1=1.0$. При мінімізації гладких функцій рекомендується використовувати $q_1=0.8 \div 0.95$. При правильному підборі цих параметрів можна значно скоротити кількість ітерацій для виконання одних і тих же критеріїв зупинки. Це залежить від конкретного виду функції, що мінімізується, ступеня її яружності і масштабу змінних.

2.2 Тестовий приклад. Для тестового прикладу використовується кусково-лінійна функція (5). Обчислення значення функції (5) та її субградієнта реалізовано Octave-функцією

```

function [f,g] = sabs(x)
global w
temp=x-ones(length(x),1); f=sum(abs(w.*temp)); g=w.*sign(temp);
endfunction

```

для якої значення коефіцієнтів w встановлюються за допомогою операторів

```

global w
n=100; temp=[0:(n-1)]'; w=1.2.**temp;

```

Ітераційний процес запускається зі стартової точки $x_0 = (0, 0, \dots, 0)^T$, для якої значення функції $f(x_0) = 4.140899e+08$. Параметри $r(\alpha)$ -алгоритма

вибираються такими: $\alpha = 4$ (рекомендується $\alpha \in [2, 4]$), $q_1 = 1.0$ (рекомендується для негладких функцій), $h_0 = 10$ (дорівнює $\|x_0 - x^*\|$ – відстані від стартової точки x_0 до точки мінімуму x^*). Використовуються параметри зупинки: $\varepsilon_x = 10^{-8}$, $\varepsilon_g = 10^{-12}$, **maxitn=5000**. Тут параметр ε_g ролі не відіграє (він використовується для гладких функцій), а параметр ε_x вибраний таким, щоб программа **ralgb5a** закінчувала роботу за критерієм $\|x_{k+1} - x_k\| \leq 10^{-8}$, чого цілком достатньо, щоб на 14-15 порядків зменшити різницю між знайденим рекордним значенням функції f_r та її мінімальним значенням $f^* = 0$.

Для вказаних параметрів головна Octave-програма має такий вигляд:

```
global w
n=100; temp=[0:(n-1)]'; w=1.2.**temp; # w(1,1), w(100,1),
x = zeros(n,1); alpha = 4.0, h0 = 10.0, q1 = 1.0,
epsx = 1.e-8, epsg = 1.e-12, maxitn = 5000, intp=500;
[xr,fr,itn,nfg,istop] = ralgb5a(@sabs,x,alpha,h0,q1,epsg,epsx,maxitn,intp);
printf("itn %4d fr %23.15e istop %d nfg %4d\n", itn, fr, istop,nfg);
dx = norm(xr-ones(n,1)),
```

2.3 Протокол роботи програми. Обчислення проводились на комп'ютері Pentium 3GHz в системі Windows7/32 за допомогою GNU Octave версії 3.6.4.

Протокол роботи програми **ralgb5a** при **intp=500** має вигляд:

```
alpha = 4 h0 = 10 q1 = 1
epsx = 1.0000e-008 epsg = 1.0000e-012 maxitn = 5000
itn 0 f 4.140899e+008 fr 4.140899e+008 nfg 1
itn 500 f 1.718525e+003 fr 1.273433e+003 nfg 532 lsa 531 lsm 4
itn 1000 f 1.409472e+000 fr 1.192802e+000 nfg 1032 lsa 500 lsm 1
itn 1500 f 1.258921e-003 fr 1.258921e-003 nfg 1532 lsa 500 lsm 1
itn 2000 f 1.422859e-006 fr 1.224438e-006 nfg 2032 lsa 500 lsm 1
itn 2046 fr 6.340398755873688e-007 istop 3 nfg 2078
dx = 1.9497e-008
```

Тут вхідні параметри $r(\alpha)$ -алгоритма зібрано в два перших рядки. Із протоколу видно, що кількість ітерацій відповідає емпіричній оцінці, тобто на одну ітерацію в середньому затрачено $2078/2046 < 3$ обчислень значення функції (5) та її субградієнта. Якщо вибрати параметр $q_1 = 0.95$, то кількість ітерацій зменшується до **920** при **1539** викликах функції **sabs**.

3. Вимоги до програми

Програма **ralgb5a** працює під управлінням тих операційних систем, які допускають установку Open Source-пакета для математичних обчислень GNU Octave. Програма використовує версії Octave 3.0.0 і вище. Для неї не потрібно ніяких спеціальних конфігурацій комп'ютера.

ЛІТЕРАТУРА

1. Шор Н.З. Методы минимизации недифференцируемых функций и их приложения. – Киев: Наукова думка, 1979. – 200 с.
2. Стецюк П.И. Методы эллипсоидов и r -алгоритмы. – Эврика: Кишинэу, 2014. – 488 с.
3. Стецюк П.И. Теория и программные реализации r -алгоритмов Шора // Кибернетика и системный анализ. – 2017. – № 5. – С. 43–57.
4. Стецюк П.И., Фишер А. r -Алгоритмы Шора и octave-функция `ralgb5a` // Тези міжнародної наукової конференції «Сучасна інформатика: проблеми, досягнення та перспективи розвитку», що присвячена 60-річчю заснування Інституту кібернетики імені В.М.Глушкова НАН України (м. Київ, 13-15 грудня 2017 р.). – К.: Ін-т кібернетики ім. В.М.Глушкова НАН України, 2017. – С. 143–146.
5. Octave [Электронный ресурс]: <http://www.octave.org> – Режим доступа: свободный.