

# Метод минимизации, использующий операцию растяжения пространства в направлении разности двух последовательных градиентов

*Н. З. Шор, Н. Г. Журбенко*  
*Кибернетика. – 1971. – № 3. – С. 51–59.*

В работах [1], [2] описан класс алгоритмов оптимизации градиентного типа с использованием операции растяжения пространства в направлении градиента (или его аналога) (ОГСРП-алгоритмы). Серьезной проблемой при построении такого рода алгоритмов был вопрос выбора на каждой итерации величины шага спуска, который сравнительно просто разрешался в том случае, когда было заранее известно значение функции в точке минимума. В более общем случае приходилось усложнять алгоритмы [2]. В данной статье предлагается новый класс алгоритмов, основанный на использовании операции растяжения пространства в направлении разности двух последовательных градиентов. В отличие от вышеупомянутых алгоритмов типа ОГСРП этот класс позволяет применить способ выбора шага, близкий к применяемому в методе наискорейшего спуска. При этом получаются алгоритмы, обеспечивающие монотонность или, в некотором смысле, "почти" монотонность спуска.

Дадим описание общей структуры алгоритмов с растяжением пространства в направлении разности двух последовательных градиентов. Алгоритмы этого класса будем сокращенно называть  $r$ -алгоритмами. Затем для одного предельного варианта  $r$ -алгоритмов докажем, при определенных условиях, квадратичную скорость сходимости. Будут рассмотрены вопросы сходимости других вариантов  $r$ -алгоритмов и дан анализ проведенных численных экспериментов.

## 1. Общая структура $r$ -алгоритмов

Пусть  $f(x)$  – непрерывно дифференцируемая функция, определенная в  $n$ -мерном евклидовом пространстве  $E_n$ , и выполняется условие

$$\lim_{\|x\| \rightarrow \infty} f(x) = +\infty, \quad (1)$$

$g_f(x)$  – градиент функции  $f(x)$  в точке  $x$ . Рассмотрим следующий итеративный процесс минимизации  $f(x)$ .

Первый шаг задается начальным значением  $x_0 \in E_n$ ; вычисляем  $g_f(x_0)$ , выбираем  $h_1 > 0$  и находим

$$x_1 = x_0 - h_1 g_f(x_0).$$

Принимаем  $g_f(x_0) = \tilde{g}_1$ ;  $B = E$  (единичная матрица). Переходим к второму шагу.

Пусть в результате вычислений после  $k$  шагов процесса ( $k = 1, 2, \dots$ ) получены определенные значения векторов  $x_k, \tilde{g}_k \in E_n$  и матрицы  $B_k$ . Опишем  $(k + 1)$ -й шаг процесса.

Вычисляем следующие величины:

1.  $g_f(x_k)$  – градиент функции  $f(x)$  в точке  $x_k$ .

2.  $B_k^* g_f(x_k) = g_k^*$ .

$g_k^*$  – градиент функции  $\varphi_k(y) = f(B_k y)$  в точке  $y = A_k x_k$ , где  $A_k = B_k^{-1}$ .

$$3. \quad r_k = g_k^* - \tilde{g}_k. \quad (2)$$

$r_k$  – разность двух градиентов от функции  $\varphi_k(y)$ , вычисленных в точках  $y_k = A_k x_k$  и  $\tilde{y}_k = A_k x_{k-1}$ .

$r_k$  можно вычислить и другим способом при  $k = 1, 2, \dots$ :

$$r_k = B_k^* [g_f(x_k) - g_f(x_{k-1})], \quad (3)$$

однако использование формулы (2) дает некоторую экономию вычислений в целом.

$$4. \quad \xi_{k+1} = \frac{r_k}{\|r_k\|}.$$

Нормировка вектора  $r_k$  нужна для подготовки очередной операции растяжения пространства в направлении, определяемом вектором  $r_k$ .

5.  $\beta_{k+1}$  – величина, обратная коэффициенту растяжения пространства на  $(k + 1)$ -ом шаге.

$$6. \quad B_{k+1} = B_k \cdot R_{\beta_{k+1}}(\xi_{k+1}).$$

$B_{k+1} = A_{k+1}$ , где  $A_{k+1} = R_{\frac{1}{\beta_{k+1}}}(\xi_{k+1})A_k$  – матрица преобразования пространства после  $(k + 1)$ -го шага; здесь  $R_\alpha(\xi)$  – оператор растяжения пространства в направлении  $\xi$  с коэффициентом  $\alpha$  ( $\alpha \geq 0, \|\xi\| = 1$ ).

Подробно свойства этого оператора описаны в [1]. Отметим основную формулу:

$$R_\alpha(\xi)x = x + (\alpha - 1)(x, \xi)\xi.$$

**7.**  $h_{k+1}$  – шаговый множитель в формуле спуска в заданном направлении.

$$\mathbf{8.} \quad \tilde{g}_{k+1} = R_{\beta_{k+1}}(\xi_{k+1}) g_k^*$$

$$\begin{aligned} \tilde{g}_{k+1} = R_{\beta_{k+1}}(\xi_{k+1}) g_k^* &= R_{\beta_{k+1}}(\xi_{k+1}) B_k^* g_f(x_k) = \\ &= \left( B_k R_{\beta_{k+1}}(\xi_{k+1}) \right)^* g_f(x_k) = B_{k+1}^* g_f(x_k). \end{aligned}$$

Отсюда  $\tilde{g}_{k+1}$  – значение градиента функции  $\varphi_{k+1}(y) = f(B_{k+1}y)$  в точке  $\tilde{y}_{k+1} = A_{k+1} x_k$ .

$$\mathbf{9.} \quad x_{k+1} = x_k - h_{k+1} B_{k+1} \tilde{g}_{k+1}. \tag{4}$$

Применим к обеим частям формулы (4) оператор  $A_{k+1}$ . Тогда

$$y_{k+1} = A_{k+1} x_{k+1} = A_{k+1} x_k - h_{k+1} \tilde{g}_{k+1} = \tilde{y}_{k+1} - h_{k+1} \tilde{g}_{k+1}.$$

Таким образом, формула (9) фактически реализует шаг градиентного спуска для функции  $\varphi_{k+1}(y)$ .

**10.** Переход к  $(k+2)$ -му шагу с запоминанием  $x_{k+1}$ ,  $\tilde{g}_{k+1}$  и  $B_{k+1}$  или окончание работы алгоритма при выполнении некоторого критерия остановки.

Приведенное описание класса алгоритмов градиентного типа с изменяемой метрикой порождает конкретные алгоритмы при уточнении способа выбора последовательностей  $\{h_{k+1}\}$  и  $\{\beta_{k+1}\}$  и критерия остановки. Такие алгоритмы мы будем называть  $r$ -алгоритмами. Имеется еще одна возможность модификации  $r$ -алгоритмов – использование так называемой операции восстановления, когда периодически после заданного числа итераций происходит "восстановление" матрицы  $B_k$ , т. е. она заменяется единичной матрицей. Вопрос о сходимости алгоритмов с монотонным изменением значения минимизирующей функции и с восстановлением решается сравнительно просто, так как он фактически сводится к вопросу о сходимости обычного градиентного спуска без изменения метрики, который подробно исследован в некоторых работах [3]. В частности, если  $f(x)$  непрерывно дифференцируема и  $h_{k+1}$  в формуле

(4) выбирается из условия минимума по направлению, то при использовании  $r$ -алгоритмов с восстановлением множество предельных точек последовательности  $\{x\}$  состоит из стационарных точек функции  $f(x)$  с одинаковым значением  $f(x)$ . Доказательство этого факта практически ничем не отличается от доказательства аналогичного результата для метода наискорейшего спуска.

В случае, когда восстановление не предполагается, вопрос о сходимости  $r$ -алгоритма требует специальных исследований.

Мы рассмотрим более подробно один предельный вариант  $r$ -алгоритма с восстановлением, в котором  $\beta_k$ ,  $k = 1, 2, \dots$ , выбирается равным нулю, а  $h_{k+1}$  выбирается из условия минимума выражения

$$f(x_k - h_{k+1} B_{k+1} \tilde{g}_{k+1}).$$

При этом, как легко заметить, либо после некоторого числа  $k^* < n$  шагов  $g_{k^*+1}$  станет равным 0, либо  $B_{n+1} = 0$ . В самом деле, оператор  $R_0(\eta)$  означает проектирование на подпространство, ортогональное вектору  $\eta$ .

Произведение операторов  $\prod_{i=1}^k R_0(\eta_i)$  не зависит от порядка сомножителей, является самосопряженным оператором и осуществляет проекцию на подпространство, являющееся ортогональным дополнением к линейной оболочке векторов  $\eta_i$ ,  $i = 1, 2, \dots$

Запишем цепочку равенств

$$r_1 = g_f(x_1) - g_f(x_0); \dots$$

$$r_k = R_0\left(\frac{r_{k-1}}{\|r_{k-1}\|}\right) \cdot R_0\left(\frac{r_{k-2}}{\|r_{k-2}\|}\right) \cdots R_0\left(\frac{r_1}{\|r_1\|}\right) \cdot [g_f(x_k) - g_f(x_{k-1})];$$

$$k > 1.$$

Мы видим, что векторы  $r_1, \dots, r_k$  получаются в результате процесса последовательной ортогонализации, примененной к векторам

$$g_f(x_1) - g_f(x_0), \quad g_f(x_2) - g_f(x_1), \dots, g_f(x_k) - g_f(x_{k-1}),$$

$k = 1, 2, \dots$ . Если  $r_1, \dots, r_n$  отличны от нуля, то оператор  $B_{n+1} = 0$ , так как он означает проекцию на подпространство, ортогонально дополняющее всё пространство. Если для некоторого  $k \leq n$ ,  $r_k = 0$ , то это означает, что

$$B_{k-1}^* [g_f(x_k) - g_f(x_{k-1})] = 0,$$

а это возможно лишь при условии

$$B_k^* g_f(x_{k-1}) = \tilde{g}_k = 0 \text{ и } x_k = x_{k-1}.$$

Таким образом, в предлагаемом варианте  $r$ -алгоритма с необходимостью нужно применять восстановление при условии  $B_k^* g_f(x_{k-1}) = 0$ . Этот вариант можно рассматривать как модификацию метода сопряженных градиентов. Легко показать, что для неотрицательно определенной квадратичной формы решение получается за число шагов, не превышающее  $n$ . Для произвольной достаточно гладкой функции можно доказать теорему о квадратичной скорости сходимости. Отметим, что доказательство аналогичной теоремы для других модификаций метода сопряженных градиентов встречает серьезные трудности [4].

**Теорема.** Пусть функция  $f(x)$ , определенная в  $E_n$ , дважды непрерывно дифференцируема в некоторой окрестности  $S$  точки минимума  $x^*$ , причем в этой окрестности матрица вторых производных (гессиан)  $H(x)$  удовлетворяет условию Липшица

$$\|H(x) - H(x')\| \leq L \|x - x'\|; \quad x, x' \in S. \quad (5)$$

Кроме того,  $H(x^*)$  – положительно определенная матрица. Тогда найдется такая окрестность точки  $x^*$   $S' \subseteq S$ , что если  $x_0 \in S'$ , то найдется такое число  $c > 0$ , что

$$\|x_n - x^*\| \leq c \|x_0 - x^*\|^2,$$

где  $x_n$  – точка, получаемая после  $n$  шагов работы приведенного выше алгоритма (если для некоторого  $\bar{k} < n \tilde{g}_{\bar{k}}$ , то примем  $x_n = x_{\bar{k}}$ ).

**Доказательство.** Без ограничения общности будем считать  $x^* = 0$  и  $f(0) = 0$ . Доказательство проведем методом индукции по размерности пространства  $E_n$ . При  $n = 1$  теорема доказывается тривиально. Пусть теорема справедлива для  $n = p$ . Докажем ее справедливость для  $n = p + 1$  ( $p \geq 1$ ). Обозначим максимальное собственное число оператора  $H(0)$  символом  $M_0$  и минимальное – символом  $m_0$ . В силу положительной определенности  $H(0)$   $m_0 > 0$ . Исходя из непрерывности гессиана  $H(x)$ , получаем, что найдется такая окрестность нуля  $S_\delta = \{x : \|x\| < \delta\}$  и такие положительные числа  $M$  и  $m$ , что при  $x \in S_\delta$  максимальное собственное число оператора  $H(x)$  не будет превышать  $M$ , а минимальное будет не меньше  $m$ .

Пусть  $e$  – вектор,  $\|e\| = 1$ . Примем  $x_0 = \varepsilon e$ ,  $0 < \varepsilon < \delta$ .

$$g_f(x_0) = \int_0^\varepsilon H(\mu e) e d\mu = \int_0^\varepsilon [H(0) + G(\mu e)] e d\mu.$$

Используя условие (5), получаем

$$\|G(\mu e)\| \leq \mu L,$$

откуда

$$g_f(x_0) = \varepsilon \left[ H(0)e + r(x_0) \right], \quad (6)$$

причем

$$\|r(x_0)\| \leq \frac{1}{\varepsilon} \int_0^\varepsilon \mu L d\mu = \frac{L\varepsilon}{2}. \quad (7)$$

Определим  $x_1$  в соответствии с исследуемым алгоритмом:

$$x_1 = x_0 - h^* \frac{g_f(x_0)}{\|g_f(x_0)\|},$$

где  $h^*$  – минимальный положительный корень уравнения

$$\left( g_f(x_0), g_f \left( x_0 - h^* \frac{g_f(x_0)}{\|g_f(x_0)\|} \right) \right) = 0.$$

Легко видеть, что при достаточно малом  $\varepsilon$

$$h^* \leq \frac{\|g_f(x_0)\|}{m} \leq \frac{M\varepsilon}{m}.$$

В самом деле, пусть

$$x(h) = x_0 - h \frac{g_f(x_0)}{\|g_f(x_0)\|}, \quad \varepsilon < \frac{\delta}{\frac{M}{m} + 1}.$$

Рассмотрим функцию  $\varphi(h) = f(x(h))$ . При  $0 \leq h \leq \frac{M\varepsilon}{m}$   $x(h) \in S_\delta$ . Тогда в силу свойств гессиана  $H(x)$  в области  $S_\delta$

$$\frac{d^2\varphi(h)}{dh^2} \geq m,$$

откуда

$$\frac{d\varphi}{dh} \leq \|g_f(x_0)\| - mh \leq M\varepsilon - mh.$$

Значит,  $h^* \leq \frac{M\varepsilon}{m}$ , что и требовалось доказать.

Далее,

$$\begin{aligned}
 g_f(x_1) &= g_f\left(x_0 - h^* \frac{g_f(x_0)}{\|g_f(x_0)\|}\right) = \\
 &= g_f(x_0) - \int_0^{h^*} H\left(x_0 - \mu \frac{g_f(x_0)}{\|g_f(x_0)\|}\right) \frac{g_f(x_0)}{\|g_f(x_0)\|} d\mu = \\
 &= g_f(x_0) - \int_0^{h^*} \left[ H(x_0) + G_1\left(\mu \frac{g_f(x_0)}{\|g_f(x_0)\|}\right) \right] \frac{g_f(x_0)}{\|g_f(x_0)\|} d\mu,
 \end{aligned}$$

причем  $\left\| G_1\left(\mu \frac{g_f(x_0)}{\|g_f(x_0)\|}\right) \right\| \leq L\mu$ . Отсюда

$$\begin{aligned}
 g_f(x_1) &= g_f\left(x_0 - h^* \frac{g_f(x_0)}{\|g_f(x_0)\|}\right) = \\
 &= g_f(x_0) - h^* H(x_0) \frac{g_f(x_0)}{\|g_f(x_0)\|} + h^* r_1(x_0), \quad (8)
 \end{aligned}$$

причем

$$\|r_1(x_0)\| \leq \frac{L h^*}{2} < \frac{L M_\varepsilon}{2m}. \quad (9)$$

Используя (6)–(9), получаем

$$\begin{aligned}
 &\left( g_f(x_0), g_f(x_1) \right) = \\
 &= \varepsilon^2 \left[ \left( H(0)e + r(x_0), H(0)e + r(x_0) \right) - \frac{h^*}{\|g_f(x_0)\|} \times \right. \\
 &\quad \times \left. \left( \left( H(0) + G(x_0) \right) \left( H(0)e + r(x_0) \right), H(0)e + r(x_0) \right) \right] + \\
 &\quad + \varepsilon h^* \left( H(0)e + r(x_0), r_1(x_0) \right) = \\
 &= \varepsilon^2 \left[ \left( H(0)e, H(0)e \right) - \frac{h^*}{\|g_f(x_0)\|} \left( H^2(0)e, H(0)e \right) \right] + r_2(x_0),
 \end{aligned}$$

причем при достаточно малом  $\varepsilon$ , как легко видеть,  $|r_2(x_0)| \leq d\varepsilon^3$ , где  $d$  – некоторое положительное число. Приравняв  $\left( g_f(x_0), g_f(x_1) \right)$  нулю,

получаем

$$1 - \frac{d\varepsilon}{\|H(0)e\|^2} q \leq h^* \leq 1 + \frac{d\varepsilon}{\|H(0)e\|^2} q,$$

где

$$q = \frac{\|H(0)e\|^2 \|g_f(x_0)\|}{(H^2(0)e, H(0)e)}.$$

Теперь покажем, что расстояние от начала координат до гиперплоскости, проходящей через точку  $x_1$  и с нормалью, задаваемой вектором

$$\Delta = g_f(x_0) - g_f(x_1),$$

имеет порядок  $\varepsilon^2$ .

Запишем уравнение этой гиперплоскости:

$$(x - x_1, g_f(x_0) - g_f(x_1)) = 0.$$

Расстояние от начала координат до гиперплоскости вычисляется по формуле

$$s = \frac{|(g_f(x_0) - g_f(x_1), x_1)|}{\|g_f(x_0) - g_f(x_1)\|},$$

$$x_1 = x_0 - h^* \frac{g_f(x_0)}{\|g_f(x_0)\|} = x_0 - \frac{\|H(0)e\|^2 g_f(x_0)}{(H^2(0)e, H(0)e)} - \frac{\nu q g_f(x_0)}{\|g_f(x_0)\|}, \quad (10)$$

где

$$-\frac{d\varepsilon}{\|H(0)e\|^2} \leq \nu \leq \frac{d\varepsilon}{\|H(0)e\|^2}. \quad (11)$$

Далее, используя (8)–(11), получаем

$$\begin{aligned} & (g_f(x_0) - g_f(x_1), x_1) = \\ & = \frac{h^* \varepsilon^2}{\|g_f(x_0)\|} \left( (H(0) + G(x_0)) (H(0)e + r(x_0)), \right. \\ & \quad \left. e - \frac{\|H(0)e\|^2}{(H^2(0)e, H(0)e)} (H(0)e + r(x_0)) \right) - \end{aligned}$$



$$\begin{aligned}
& - \frac{1}{\|g_f(x_0)\|} \left( \nu q g_f(x_0), g_f(x_0) - g_f(x_1) \right) - \left( h^* r_1(x_0), x_1 \right) = \\
& = \varepsilon^2 \frac{h^*}{\|g_f(x_0)\|} \left( H^2(0)e, e \right) - \left( H(0)e, H(0)e \right) + r_3(x_0) = r_3(x_0),
\end{aligned}$$

где  $|r_3(x_0)| \leq c_1 \varepsilon^3$ , а  $c_1$  — положительное число, которое легко вычисляется с использованием оценок (7), (9), (11). Так как

$$\left( g_f(x_0), g_f(x_1) \right) = 0$$

то

$$\|g_f(x_1) - g_f(x_0)\| \geq \|g_f(x_0)\| \geq m\varepsilon.$$

Отсюда

$$s \leq \frac{c_1}{m} \varepsilon^2 = c_2 \varepsilon^2, \quad \text{где } c_2 = \frac{c_1}{m}. \quad (12)$$

Рассмотрим функцию  $\psi(x)$ , определенную в  $p$ -мерной гиперплоскости

$$L(x_0) = \left\{ x : \left( g_f(x_1) - g_f(x_0), x - x_1 \right) = 0 \right\}$$

и равную  $f(x)$  для точек этой гиперплоскости.

Покажем, что  $\min \psi(x) = \min_{x \in L(x_0)} f(x)$  достигается в точке такой, что

$$\|x_1^*\| \leq c_3 \varepsilon^2.$$

где  $c_3$  — положительная величина, не зависящая от  $\varepsilon$  при достаточно малом  $\varepsilon$ .

Рассмотрим точку  $\bar{x}_1$ , лежащую в  $L(x_0)$  на кратчайшем расстоянии от начала координат. Из (12) получаем

$$s = \|\bar{x}_1\| \leq c_2 \varepsilon^2,$$

откуда

$$\min_{x \in L(x_0)} f(x) \leq f(\bar{x}_1) \leq \frac{M\varepsilon^4 c_2^2}{2} = c_4 \varepsilon^4,$$

С другой стороны,

$$f(x_1^*) \geq \frac{m \|x_1^*\|}{2}.$$

Получаем

$$\frac{m \|x_1^*\|^2}{2} \leq c_4 \varepsilon^4, \quad \|x_1^*\| \leq \sqrt{\frac{2c_4}{m}} \varepsilon^2 = c_3 \varepsilon^2,$$

Заметим, что  $c_3$  определяется константами  $L$ ,  $M$  и  $m$ . Так как дальнейший спуск будет проходить в гиперплоскости  $L(x_0)$  размерности  $p$ , а по предположению индукции рассматриваемая теорема справедлива для функции, определенной в  $p$ -мерном пространстве, то справедливо соотношение

$$\|x_n\| = \|x_{p+1}\| \leq \|x_1^*\| + \|x_{p+1} - x_1^*\| \leq c_3 \varepsilon^2 + c_p \|x_1 - x_1^*\|, \quad (13)$$

где  $c_p$  – число, определяемое по предположению индукции только константами  $L$ ,  $M$ ,  $m$  и  $p$  при достаточно малом значении  $\|x_1 - x_1^*\|$ . Оценим  $\|x_1 - x_1^*\|$ .

Так как

$$f(x_0) > f(x_1) \geq f(x_1^*) \geq f(0) = 0$$

то

$$f(x_1) - f(x_1^*) < f(x_0) \leq \frac{M\varepsilon^2}{2}.$$

С другой стороны,

$$\frac{m \|x_1 - x_1^*\|^2}{2} \leq f(x_1) - f(x_1^*).$$

Получаем

$$\|x_1 - x_1^*\|^2 \leq \frac{M}{m} \varepsilon^2.$$

Окончательно имеем

$$\|x_n\| \leq \left( c_3 + c_p \frac{M}{m} \right) \varepsilon^2 = c \|x_0\|^2,$$

где  $c$  – величина, зависящая только от  $L$ ,  $M$ ,  $m$  и  $n$ . Доказательство теоремы закончено.

## 2. Варианты алгоритмов без восстановления. Численные эксперименты

Ниже приводится вариант  $r$ -алгоритма без восстановления. Хотя строгие результаты о сходимости этих алгоритмов и скорости сходимости пока не получены, численные эксперименты показывают высокую скорость сходимости по сравнению с достигаемой в различных модификациях алгоритмов с изменяемой метрикой или метода сопряженных градиентов [4], [6]. Существенная особенность, однако, состоит в том, что определенные модификации  $r$ -алгоритмов применимы для минимизации негладких функций, в то время как другие методы, обладающие ускоренной сходимостью, требуют во всяком случае непрерывности градиента.

$r$ -алгоритм с постоянным коэффициентом растяжения был реализован программой для вычислительной машины БЭСМ-6. Опишем кратко программу. Так как общая схема алгоритма описана, то остановимся лишь на алгоритме одномерного поиска минимума функции  $f(x)$  в направлении  $\eta$ , с помощью которого осуществляется выбор шага  $h_{k+1}$ . Для реализации наискорейшего спуска с высокой точностью приходится производить большое количество вычислений значений функции. В разработанном алгоритме поиск минимума по направлению производится таким образом, что точность поиска минимума увеличивается в процессе счета.

Во всех приведенных числовых примерах одномерный поиск минимума производится следующим образом.

Выбираем числа  $\mu \geq 1$ ,  $0 < \gamma < 1$  и целое число  $L$ . Выбираем число  $h$  — начальный пробный шаг.

На  $(k + 1)$ -ой итерации определены:

$x_k$  — точка, полученная на  $k$ -ой итерации;

$\eta$  — вектор, в направлении которого необходимо осуществить спуск из точки  $x_k$ ;

$h$  — пробный шаг.

Из точки  $x_k$  делаем шаг длины  $h$  в направлении  $\eta$ :  $z_1 = x_k + h\eta$ . Вычисляем  $f(z_1)$ . Если  $f(z_1) < f(x_k)$ , то из точки  $z_1$  снова делаем шаг длины  $h$  в направлении  $\eta$ :  $z_2 = z_1 + h\eta$ . Вычисляем  $f(z_2)$ . Если  $f(z_2) < f(z_1)$ , то из точки  $z_2$  опять делаем шаг по  $\eta$  и т. д. до тех пор, пока на некотором шаге значение функции не возрастает. Эту последнюю точку и принимаем за  $x_{k+1}$ . Пусть  $l$  — число шагов при этой процедуре. Тогда, если оказалось, что  $l > L$ , то за новый пробный шаг принимаем число

$\left(\mu \frac{l}{L} h\right)$ . Если оказалось, что функция возрастает на первом шаге, то за новый шаг принимаем число  $(\gamma h)$ , во всех остальных случаях пробный шаг  $h$  не изменяем.

При счете всех приведенных задач  $\gamma$ ,  $\mu$  и начальный шаг  $h$  принимались равными соответственно 0.1, 5/4, 0.1. Вышеописанная процедура не гарантирует монотонного убывания функции, однако, как показали эксперименты, возрастание функции происходит очень редко.

В программе производится контроль малости элементов  $b_{ij}$  матрицы  $B$  ( $B = A^{-1}$ , где  $A$  – матрица преобразования пространства переменных). Через каждые  $k$  итераций вычисляется величина  $d = \max_i |b_{ii}|$  и если  $d < \varepsilon$ , то матрицу  $B$  умножаем на число  $\varrho$ . При счете  $k = 10$ ,  $\varepsilon = 1$ ,  $\varrho = 10^3$ .

Остановимся на вопросе трудоемкости программы. Основными дополнительными операциями в программе являются операции умножения матрицы на вектор, требующий  $2n^2$  операций умножения и сложения ( $n$  – размерность пространства переменных), и операция умножения матрицы  $B$  на матрицу оператора растяжения  $R_\alpha(\eta)$ .

Благодаря тому, что  $R_\alpha(\eta)$  – матрица специального вида, операция  $B \cdot R_\alpha(\eta)$  требует  $5n^2$  операций умножения и сложения.

Основной массив необходимой дополнительной памяти занимает матрица  $B$ , для хранения которой необходимо  $n^2$  ячеек. Поэтому, используя лишь оперативную память машины БЭСМ-6, мы можем решать задачи с числом переменных до 140.

При описании результатов счета приняты следующие обозначения:

$f = f(x_1, \dots, x_n)$  – минимизируемая функция;

$x^*$  – истинная точка минимума  $f(x)$ ;

$f^*$  – истинный минимум  $f(x)$ ;

$x_0$  – начальная точка – точка на нулевой итерации;

$\tilde{x}_N$  – точка, полученная в результате счета;

$k$  – счетчик итерации;

$f$  – значение функции;

$\alpha$  – коэффициент растяжения;

$d$  – величина градиента в точке  $\tilde{x}$  :  $d = \|\nabla f(\tilde{x})\|$ ;

$\delta = \max_i |\tilde{x}_i - x_i^*|$ ;

$l$  – среднее количество вычислений значений функции на одной итерации.

Условием прекращения счета во всех примерах являлось выполнение

одного из следующих неравенств:

$$\|\Delta f(x_k) < 10^{-6}\|, \quad \|x_k - x_{k-1}\| < 10^{-7}, \quad \|B^* \nabla f(x_k)\| < 10^{-18}.$$

$N$  – номер итерации, при которой произошел останов.

**Пример 1** [5], [6].

$$\begin{aligned} f(x) &= (x_1^2 - x_2)^2 + (x_1 - 1)^2; \\ x^* &= (1; 1); \quad f^* = 0; \quad x_0 = (-1, 2; 1); \quad \text{при } \alpha, \text{ равном 2 и 3,} \\ \tilde{x}_N &= (1, 000000; 1, 000000). \end{aligned}$$

**Пример 2** [4].

$$\begin{aligned} f(x) &= \sum_{i=1}^{10} (e^{-0,2i} + 2e^{-0,4i} - x_1 e^{-0,2x_2 i} - x_3 e^{-0,4x_4 i})^2; \\ x^* &= (1; 1; 2; 1); \quad f^* = 0; \quad x_0 = (0; 0; 0; 0); \\ \alpha = 2; \quad \tilde{x}_{83} &= (0, 999999; 1, 000000; 2, 000000; 1, 000000); \\ \alpha = 3; \quad \tilde{x}_{90} &= (0, 999999; 0, 999999; 2, 000001; 1, 000000). \end{aligned}$$

**Пример 3** [4].

$$\begin{aligned} f(x) &= 10^{-3} \sum_{i=1}^{10} (10^3 e^{-0,2i} + 210^3 e^{-0,4i} - x_1 e^{-0,2x_2 i} - x_3 e^{-0,2x_4 i})^2; \\ x^* &= (1000; 1; 2000; 2); \quad f^* = 0; \quad x_0 = (500; 0; 2500; 3); \\ \alpha = 2; \quad \tilde{x}_{100} &= (1000, 000; 1, 000000; 2000, 000; 2, 000000); \\ \alpha = 3; \quad \tilde{x}_{72} &= (1000, 001; 1, 000000; 1999, 999; 2, 000000). \end{aligned}$$

**Пример 4** [6].

$$\begin{aligned} f(x) &= 100(x_1^2 - x_2) + (x_1 - 1)^2 + 90(x_3^2 - x_4)^2 + (x_3 - 1)^2 + \\ &\quad + 10,1((x_2 - 1)^2 + (x_4 - 1)^2) + 19,8(x_2 - 1)(x_4 - 1); \\ x^* &= (1; 1; 1; 1); \quad f^* = 0; \quad x_0 = (-3; -1; -3; -1); \\ \alpha = 2; \quad \tilde{x}_{99} &= (0, 999999; 0, 999999; 1, 000000; 1, 000000); \\ \alpha = 3; \quad \tilde{x}_{76} &= (1, 000000; 1, 000000; 1, 000000; 1, 000000). \end{aligned}$$

**Пример 5** [6].

$$\begin{aligned} f(x) &= (e^{x_1} - x_2)^4 + 100(x_2 - x_3)^6 + th^4(x_3 - x_4) + x_1^8 + (x_4 - 1)^2; \\ x^* &= (0; 1; 1; 1); \quad f^* = 0; \quad x_0 = (1; 2; 2; 2); \end{aligned}$$

$$\begin{aligned}\alpha = 2; \quad \tilde{x}_{36} &= (0, 0006; 1, 0005; 1, 0000; 1, 0000); \\ \alpha = 3; \quad \tilde{x}_{32} &= (-0, 0004; 0, 9996; 1, 0000; 1, 0000).\end{aligned}$$

**Пример 6** [6].

$$\begin{aligned}f(x) &= (x_1 + 10x_2)^2 + 5(x_3 - x_4)^2 + (x_2 - 2x_3)^2 + 10(x_1 - x_4)^4; \\ x^* &= (0; 0; 0; 0); \quad f^* = 0; \quad x_0 = (10; 10; 10; -10); \\ \alpha = 2; \quad \tilde{x}_{50} &= (4_{10^{-7}}; -2_{10^{-7}}; 6_{10^{-7}}; 7_{10^{-7}}); \\ \alpha = 3; \quad \tilde{x}_{46} &= (3, 8_{10^{-5}}; 0, 4_{10^{-5}}; -4, 6_{10^{-5}}; -4, 6_{10^{-5}}).\end{aligned}$$

Более подробная информация о результатах численных экспериментов содержится в таблице.

Приведенные выше данные о решении с помощью  $r$ -алгоритма ряда задач минимизации с ярко выраженными овражными особенностями говорят о том, что этот алгоритм является эффективным средством решения такого рода задач. По числу итераций, требуемых для достижения определенной точности, он близок к наиболее удачным модификациям алгоритмов типа Давидона–Флетчера–Пауэлла и метода сопряженных градиентов [6], [4]. Алгоритм устойчив по отношению к неточностям определения минимума по направлению (в алгоритме был использован заведомо грубый способ локализации минимума по направлению). Как показал опыт вычислений, коэффициент растяжения пространства  $\alpha$  целесообразно выбирать между 2 и 3 (мы приводим лишь результаты экспериментов для  $\alpha$ , равных 2 и 3, но опыты проводились и для множества других значений коэффициента растяжения), так как в большинстве случаев при дальнейшем увеличении  $\alpha$  количество итераций если и уменьшается, то незначительно, но зато заметно увеличивается среднее число вычислений функции при поиске минимума по направлению (конечно, эти рекомендации относятся лишь к той конкретной модификации алгоритма, которую мы применяли).

Были проведены также эксперименты, в которых счет производился по несколько измененному алгоритму. Изменение состояло в том, что минимум по направлению находился с высокой точностью. При этом наблюдалось уменьшение числа итераций на 20–30% при сохранении прежних критериев остановки.

| $\alpha$ | I                     |                       | II                     |                       | III                   |                       | IV                    |                       | V                     |                       | VI                    |                       |
|----------|-----------------------|-----------------------|------------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|
|          | $f(x_k)$              | $f'(x_k)$             | $f(x_k)$               | $f'(x_k)$             | $f(x_k)$              | $f'(x_k)$             | $f(x_k)$              | $f'(x_k)$             | $f(x_k)$              | $f'(x_k)$             | $f(x_k)$              | $f'(x_k)$             |
| 0        | 2.4 <sub>10</sub> +1  | 2.4 <sub>10</sub> +1  | 1.0 <sub>10</sub> +1   | 5.4 <sub>10</sub> +2  | 5.4 <sub>10</sub> +2  | 1.9 <sub>10</sub> +4  | 1.9 <sub>10</sub> +4  | 2.3 <sub>10</sub> +0  | 2.3 <sub>10</sub> +0  | 1.6 <sub>10</sub> +6  | 1.6 <sub>10</sub> +6  | 1.6 <sub>10</sub> +6  |
| 10       | 1.5 <sub>10</sub> +0  | 9.2 <sub>10</sub> -1  | 1.5 <sub>10</sub> -3   | 6.7 <sub>10</sub> -2  | 4.8 <sub>10</sub> -2  | 4.0 <sub>10</sub> +0  | 3.8 <sub>10</sub> +0  | 1.5 <sub>10</sub> -4  | 1.5 <sub>10</sub> -4  | 6.3 <sub>10</sub> +0  | 6.3 <sub>10</sub> +0  | 1.5 <sub>10</sub> +1  |
| 20       | 2.5 <sub>10</sub> -1  | 8.8 <sub>10</sub> -3  | 2.7 <sub>10</sub> -4   | 1.9 <sub>10</sub> -2  | 1.3 <sub>10</sub> -2  | 2.4 <sub>10</sub> +0  | 2.2 <sub>10</sub> +0  | 1.3 <sub>10</sub> -4  | 1.3 <sub>10</sub> -4  | 2.2 <sub>10</sub> -4  | 2.2 <sub>10</sub> -4  | 4.8 <sub>10</sub> -3  |
| 30       | 1.6 <sub>10</sub> -1  | 5.5 <sub>10</sub> -3  | 3.5 <sub>10</sub> -5   | 1.5 <sub>10</sub> -2  | 3.6 <sub>10</sub> -3  | 1.3 <sub>10</sub> +0  | 5.5 <sub>10</sub> +0  | 4.0 <sub>10</sub> -9  | 4.2 <sub>10</sub> -9  | 2.3 <sub>10</sub> -4  | 2.3 <sub>10</sub> -4  | 1.6 <sub>10</sub> -3  |
| 40       | 2.8 <sub>10</sub> -7  | -                     | 8.2 <sub>10</sub> -6   | 5.6 <sub>10</sub> -3  | 1.6 <sub>10</sub> -3  | 4.6 <sub>10</sub> -1  | 1.8 <sub>10</sub> -1  | 2.2 <sub>10</sub> -13 | 2.2 <sub>10</sub> -13 | 5.1 <sub>10</sub> -8  | 5.1 <sub>10</sub> -8  | 1.6 <sub>10</sub> -7  |
| 50       | 1.9 <sub>10</sub> -10 | -                     | 2.1 <sub>10</sub> -7   | 1.1 <sub>10</sub> -5  | 1.3 <sub>10</sub> -7  | 4.3 <sub>10</sub> -3  | 4.5 <sub>10</sub> -2  | -                     | -                     | -                     | -                     | 2.4 <sub>10</sub> -11 |
| 60       | 3.4 <sub>10</sub> -10 | -                     | 5.79 <sub>10</sub> -11 | 1.9 <sub>10</sub> -5  | 2.7 <sub>10</sub> -7  | 2.2 <sub>10</sub> -4  | 4.0 <sub>10</sub> -5  | -                     | -                     | -                     | -                     | 4.6 <sub>10</sub> -13 |
| 70       | 3.4 <sub>10</sub> -13 | -                     | 1.2 <sub>10</sub> -12  | 2.6 <sub>10</sub> -5  | 5.3 <sub>10</sub> -14 | 3.3 <sub>10</sub> -6  | 3.2 <sub>10</sub> -8  | -                     | -                     | -                     | -                     | -                     |
| 80       | -                     | -                     | 6.0 <sub>10</sub> -15  | 1.1 <sub>10</sub> -10 | -                     | 3.0 <sub>10</sub> -6  | -                     | -                     | -                     | -                     | -                     | -                     |
| 90       | -                     | -                     | -                      | 1.9 <sub>10</sub> -13 | -                     | 3.2 <sub>10</sub> -7  | -                     | -                     | -                     | -                     | -                     | -                     |
| $N$      | 63                    | 39                    | 83                     | 100                   | 72                    | 99                    | 76                    | 36                    | 32                    | 46                    | 50                    | 50                    |
| $f(x_N)$ | 1.5 <sub>10</sub> -14 | 2.3 <sub>10</sub> -15 | 8.5 <sub>10</sub> -17  | 9.0 <sub>10</sub> -16 | 3.7 <sub>10</sub> -12 | 5.7 <sub>10</sub> -12 | 3.7 <sub>10</sub> -12 | 5.4 <sub>10</sub> -16 | 1.2 <sub>10</sub> -14 | 3.4 <sub>10</sub> -14 | 4.6 <sub>10</sub> -13 | 4.6 <sub>10</sub> -13 |
| $\delta$ | 10 <sup>-7</sup>      | 10 <sup>-7</sup>      | 10 <sup>-7</sup>       | 10 <sup>-4</sup>      | 10 <sup>-3</sup>      | 10 <sup>-6</sup>      | 10 <sup>-6</sup>      | 10 <sup>-3</sup>      | 10 <sup>-3</sup>      | 10 <sup>-6</sup>      | 10 <sup>-4</sup>      | 10 <sup>-4</sup>      |
| $d$      | 5.4 <sub>10</sub> -6  | 7.7 <sub>10</sub> -7  | 2.8 <sub>10</sub> -8   | 3.5 <sub>10</sub> -8  | 8.6 <sub>10</sub> -7  | 2.1 <sub>10</sub> -5  | 4.0 <sub>10</sub> -5  | 4.8 <sub>10</sub> -8  | 2.5 <sub>10</sub> -7  | 3.0 <sub>10</sub> -6  | 1.1 <sub>10</sub> -5  | 1.1 <sub>10</sub> -5  |
| $l$      | 4.3                   | 7.6                   | 4.8                    | 4.7                   | 5.7                   | 4.4                   | 6.9                   | 4.1                   | 3.8                   | 10                    | 13.9                  | 13.9                  |

\*Римскими цифрами в первой строке указаны номера примеров

### 3. Возможность применения $r$ -алгоритмов к задачам минимизации негладких функций

Пусть мы имеем кусочно-гладкую выпуклую функцию вида

$$f(x) = \max_{1 \leq i \leq l} \varphi_i(x),$$

где  $\varphi_i(x)$  – выпуклые гладкие функции, и пусть мы находимся в точке  $x_0$  такой, что  $\varphi_i(x_0) = f(x_0)$  при  $i \in I^*$ , где  $I^*$  – некоторое подмножество целочисленного интервала  $[1, l]$ , и в некоторой окрестности этой точки существует гладкая гиперповерхность

$$S^* = \left\{ x : f(x) = \varphi_i(x), \quad i \in I^* \right\}.$$

Эту гиперповерхность можно рассматривать, как "русло оврага" в том случае, когда

$$(g_{\varphi_i}(x), g_{\varphi_j}(x)) < 0, \quad i, j \in I^*, \quad i \neq j.$$

Из определения гиперповерхности  $S^*$  следует, что для любого касательного к этой гиперплоскости в точке  $x$  вектора  $r(x)$  справедливо соотношение

$$(r(x), g_{\varphi_i}(x) - g_{\varphi_j}(x)) = 0, \quad i, j \in I^*.$$

Таким образом, растяжение пространства в направлении  $g_{\varphi_i}(x) - g_{\varphi_j}(x)$  уменьшает составляющие обобщенных градиентов, направленные ортогонально "руслу оврага", и оставляет без изменения составляющие, направленные вдоль "русла оврага".

Эти эвристические соображения показывают, что последовательное применение операций растяжения пространства в направлении разности двух последовательных обобщенных градиентов при определенном способе выбора шага (когда мы идем до минимума в выбранном направлении и переходим его с пробным шагом, чтобы вычислить градиент по другую сторону от "русла оврага") приближенно соответствует операции проектирования градиента на "русло оврага".

Были проведены численные эксперименты, которые показывают, что применение операции растяжения пространства в направлении разности двух последовательных градиентов значительно ускоряет сходимость обобщенного градиентного спуска. По материалам исследования применимости  $r$ -алгоритмов к задачам минимизации негладких функций готовится отдельная статья.



## Литература

1. ШОР Н.З. Использование операций растяжения пространства в задачах минимизации выпуклых функций // Кибернетика. – 1970. – № 1. – С. 6–12.
2. Н. З. ШОР, О скорости сходимости метода обобщенного градиентного спуска с растяжением пространства // Кибернетика. – 1970. – № 2. – С. 80–85.
3. Любич Ю.И. Общая теория релаксационных процессов для выпуклых функционалов // Успехи математических наук. – 1970. – № 1.
4. Поляк Б.Т. Метод сопряженных градиентов, Труды II Зимней школы по математическому программированию и смежным вопросам (Дрогобыч), вып. 1, М., 1969.
5. РОЗЕНБРОК Х., СТОРИ С. Вычислительные методы для инженеров–химиков. – М.: "Мир", 1968.
6. HUANG H.I., LEVY A.V. Experiments on Quadratically Convergent Algorithms for Function Minimization // Journal of Optimization Theory and Applications. – 1970. – 3, v. 6.