

Тема 16 Методы минимизации с переменной метрикой

- Исходные предпосылки*
- Общий алгоритм методов с
переменной метрикой*
- Основные методы*

Недостатки и достоинства метода Ньютона

- Описанный в предыдущей лекции **метод Ньютона** на каждой итерации **требует вычисления вектора градиента и матрицы вторых производных**. Их приходится вычислять на основе разделенных разностей, а это требует значительных затрат.

$$x^{k+1} = x^k - z_m G^{-1} \left(x^k \right) \nabla f \left(x^k \right)$$

- Из-за этого **трудоемкость каждой итерации** метода Ньютона становится **непомерно большой**, хотя **количество самих итераций** в этом методе теоретически **меньше, чем в других методах**.
- Возникает вопрос – а возможно ли построить метод минимизации, который по количеству итераций не уступал бы методу Ньютона, но затраты на каждой итерации на вычисление нужного направления были бы значительно меньшими.

Основные предпосылки

- С другой стороны привлекательной является *идея адаптивного управления спуском к минимуму*. Как известно, система адаптивного управления имеет свойство *накапливать информацию о предыдущем поведении управляемого объекта* и, используя эту информацию, *совершенствовать* заложенный в ней *алгоритм управления*.
- В приложении к рассматриваемой нами задаче оптимизации *адаптивный алгоритм поиска* минимума должен как-то *накапливать информацию*, полученную в результате выполненных начальных спусков таким образом, чтобы *постепенно приближаться к теоретически оптимальному выбору очередного направления* обоснованного в методе второго порядка Ньютона.

Идея алгоритмов

- В рассмотренном ниже классе методов с переменной метрикой реализована **идея адаптивного управления**.
- **Информация** о предыдущих итерациях **накапливается в специальной матрице H** , которая по мере накопления информации **постепенно превращается в обратную матрицу Гессе**

$$H^k \xrightarrow[k \rightarrow \infty]{} G^{-1}(x^k)$$

- При этом матрица вторых производных на каждом шаге не пересчитывается.

Многообразиие и перспективность алгоритмов

- Процесс обработки и накопления информации, получаемой на каждой новой итерации **можно реализовать разными способами**. Поэтому на сегодняшний день было предложено множество различных методов, которые мы рассмотрим ниже.
- Следует так же отметить, что на сегодняшний день **предложен метод сходящийся за меньшее число итераций, чем метод Ньютона**, хотя и использующий только матрицу вторых производных Гессе.
- [Хромова Л.Н. Об одном методе минимизации с кубической скоростью сходимости. – Вестник Моск. ун-та Сер. Вычислит. Матем. и кибернетика, 1980, №3].
- Поэтому **возможно построение методов с переменной метрикой** имеющих кубическую скорость сходимости, т. е. **значительно более быстрых, чем метод Ньютона**.

Общий алгоритм методов с переменной метрикой

- Методами с переменной метрикой называется широкий класс эффективных градиентных методов, в которых направление очередного спуска вычисляется по формуле

$$d^k = -H_k g^k$$

$$g^k = \nabla f(x^k) = \begin{bmatrix} g_1^k \\ \dots \\ g_n^k \end{bmatrix} = \begin{bmatrix} \frac{\partial f(x^k)}{\partial x_1} \\ \dots \\ \frac{\partial f(x^k)}{\partial x_n} \end{bmatrix}$$

$$H_k = H_{k-1} + A_k$$

- H - положительно определенная симметричная матрица

Сравните с методом Ньютона

$$d^k = -H_k g^k \qquad d^k = -G_k^{-1} g^k$$

$$H_k = H_{k-1} + A_k$$

- A_k — корректирующая матрица, рассчитываемая по результатам предыдущих спусков таким образом, чтобы обеспечить сходимость

$$H^k \xrightarrow[k \rightarrow \infty]{} G^{-1}(x^k)$$

Последовательность вычислений

- На 1-м шаге следует положить $H_0 = E$ $\mathbf{g}^0 = \nabla f(\mathbf{x}^0)$
- Делаем очередной одномерный спуск в направлении
$$\mathbf{d}^k = -H_k \mathbf{g}^k \quad \mathbf{x}^{k+1} = \mathbf{x}^k + z_m \mathbf{d}^k$$

- делается пересчет корректирующей матрицы

$$A_{k+1}(\mathbf{v}, \mathbf{u}, H) \quad \mathbf{v} = z_m \mathbf{d}^k, \quad \mathbf{u} = \mathbf{g}^{k+1} - \mathbf{g}^k$$

- Если $|z_m| + |\mathbf{g}^{k+1}| > \varepsilon$ то производится вычисление нового направления спуска $H_{k+1} = H_k + A_{k+1}$;

$$\mathbf{d}^{k+1} = -H_{k+1} \mathbf{g}^{k+1}$$

$x^0 \quad \varepsilon$

Вычислить $H=E \quad g^0 = \nabla f(x^0); \quad d = -g^0$

Найти z_m , минимизирующее одномерную функцию
Начальное $z_0=0$
$$\varphi(z) = f(x^0 + zd)$$

Вычислить $x^1 = x^0 + z_m d; \quad v = z_m d; \quad x^0 = x^1$

Вычислить $g^1 = \nabla f(x^1); \quad u = g^1 - g^0; \quad g^0 = g^1$

Вычислить $H = H + A(v, u, H); \quad d = -Hg^1$

$|v| + |g^1| < \varepsilon$

$x^1; f(x^1), g^1$

Общая характеристика методов

- В результате методы получаются *асимптотически второго порядка*.
- Матрица Гессе не пересчитывается на каждом спуске, и в результате *вычислительные затраты на итерацию аналогичны как и в простых градиентных методах*.
- Однако, в отличие от метода Ньютона, в котором минимум квадратичной функции находится за один спуск, методы с переменной метрикой *гарантируют нахождение минимума квадратичной функции за n спусков* (n – размерность вектора).

Рекомендация

- Обычно при реализации одномерного спуска используется метод кубической или квадратичной параболы. При этом, для уменьшения вычислительных затрат, **рекомендуется делать только одну - две итерации, обеспечивая лишь получение улучшенного значения функции.**
- Оказывается дополнительная работа, выполняемая для **полного завершения** одномерного спуска (с большой точностью) **не оправдывает себя.**
- Теоретически это означает, что метод как бы утрачивает свойство сходимости за n шагов для квадратичной функции, но практически остается эффективным и быстрым для произвольных функций

Метод ДАВИДОНА-ФЛЕТЧЕРА-ПАУЭЛЛА

- Один из первых и эффективных методов с переменной метрикой, на основе выше сформулированных Давидоном принципов предложен Флетчером и Пауэллом (1963).
- Матрица A_k рассчитывается по формулам

$$A = \frac{\begin{matrix} \boxtimes & \boxtimes^T \\ \mathbf{v} & \mathbf{v}^T \end{matrix}}{\begin{matrix} \boxtimes^T & \boxtimes \\ \mathbf{v}^T & \mathbf{u} \end{matrix}} - \frac{\begin{matrix} \boxtimes & \boxtimes^T \\ H \mathbf{u} & \mathbf{u}^T H \end{matrix}}{\begin{matrix} \boxtimes^T & \boxtimes \\ \mathbf{u}^T & H \mathbf{u} \end{matrix}}$$

$$\mathbf{v} = z_m \mathbf{d}^k, \quad \mathbf{u} = \mathbf{g}^{k+1} - \mathbf{g}^k$$

Поясним вычисление матрицы A на примере двух переменных

$$\mathbb{R}^1 \mathbf{v} = \begin{bmatrix} v_1 \\ v_2 \end{bmatrix}; \quad \mathbb{R}^1 \mathbf{v}^T = \begin{bmatrix} v_1 & v_2 \end{bmatrix}; \quad \mathbb{R}^1 \mathbf{u} = \begin{bmatrix} u_1 \\ u_2 \end{bmatrix}; \quad \mathbb{R}^1 \mathbf{u}^T = \begin{bmatrix} u_1 & u_2 \end{bmatrix};$$

$$\mathbb{R}^1 \mathbb{R}^1 \mathbf{v} \mathbf{v}^T = \begin{bmatrix} v_1 \\ v_2 \end{bmatrix} \begin{bmatrix} v_1 & v_2 \end{bmatrix} = \begin{bmatrix} v_1 v_1 & v_1 v_2 \\ v_2 v_1 & v_2 v_2 \end{bmatrix} \quad \text{Получается матрица}$$

$$\mathbb{R}^1 \mathbf{v}^T \mathbf{u} = \begin{bmatrix} v_1 & v_2 \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} = v_1 u_1 + v_2 u_2 \quad \text{Получается число}$$

Вычисление матрицы A на примере двух переменных

$$H = \begin{bmatrix} h_{11} & h_{12} \\ h_{21} & h_{22} \end{bmatrix}$$

$$Hu = \begin{bmatrix} h_{11} & h_{12} \\ h_{21} & h_{22} \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} = \begin{bmatrix} h_{11}u_1 + h_{12}u_2 \\ h_{21}u_1 + h_{22}u_2 \end{bmatrix}$$

$$u^T H = \begin{bmatrix} u_1 & u_2 \end{bmatrix} \begin{bmatrix} h_{11} & h_{12} \\ h_{21} & h_{22} \end{bmatrix} = \begin{bmatrix} h_{11}u_1 + h_{12}u_2 & h_{21}u_1 + h_{22}u_2 \end{bmatrix}$$

$$Hu u^T H = \begin{bmatrix} h_{11}u_1 + h_{12}u_2 \\ h_{21}u_1 + h_{22}u_2 \end{bmatrix} \begin{bmatrix} h_{11}u_1 + h_{12}u_2 & h_{21}u_1 + h_{22}u_2 \end{bmatrix}$$

$$u^T Hu = \begin{bmatrix} h_{11}u_1 + h_{12}u_2 & h_{21}u_1 + h_{22}u_2 \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \end{bmatrix}$$

Программная реализация вычисления матриц $H+A$

- Procedure PREOBR;
- var
- hu,uh,u,v: array[1..n] of real;
- vu,uhu,uh:real;
- begin
- vu:=0;for i:=1 to n do begin
- v[i]:=zm*d[i];
- u[i]:=g1[i]-g0[i]; //
- vu:=vu+v[i]*u[i]
- end;
- uhu:=0; for i:=1 to n do begin
- uh:=0;
- for j:=1 t n do
- uh:=uh+u[j]*H[j,i]; //
- uhu:=uhu+uh*u[i]
- end;

$$\begin{matrix} \boxtimes & T & \boxtimes \\ v & & u \end{matrix}$$

$$\begin{matrix} \boxtimes & T & \boxtimes \\ u & & H & & u \end{matrix}$$

Программная реализация (продолжение)

- for i:=1 to n do begin
- hu[i]:=0; uh[i]:=0;
- for k:=1 to n do begin
- hu[i]:=hu[i]+H[i,k]*u[k];
- uh[i]:=uh[i]+u[k]*H[k,i];
- end
- end;
- for i:=1 to n do
- for j:=1 to n do begin
- Aij:=v[i]*v[j]/vu-hu[i]*uh[j]/uhu;
- H[i,j]:=H[i,j]+Aij;
- end
- end;

$$\begin{matrix} H & \underline{u} \\ \underline{u}^T & H \end{matrix}$$

Общий вид матрицы A

- В 1979г. Гринсдайт Дж. предложил общее выражение, задающее в зависимости от выбираемой произвольной симметричной матрицы **M** семейство методов с переменной метрикой

$$A = \frac{1}{u^T H u} \left\{ \begin{array}{l} v^T M + M u v^T - H u u^T M - M u u^T H - \\ \left[\frac{u^T v - u^T H u}{u^T H u} \right] H u u^T H \end{array} \right\}$$

- В последствии исходя из него были предложены различные методы с переменной метрикой, наиболее эффективным зарекомендовал себя метод Гольдфарба

Метод ГОЛЬДФАРБА (1970)

$$A = \frac{-\mathbf{v} \mathbf{u}^T H + H \mathbf{u} \mathbf{v}^T + \left(1 + \frac{\mathbf{u}^T H \mathbf{u}}{\mathbf{u}^T \mathbf{v}} \right) \mathbf{v} \mathbf{v}^T}{\mathbf{u}^T \mathbf{v}}$$

Он более устойчив к ошибкам вычислений, чем ДФП

Метод ПРОЕКТИВНОГО ГРАДИЕНТА

$$A = - \frac{\begin{pmatrix} H & u \\ u^T & N \end{pmatrix}}{u^T N u}$$

После N шагов матрица должна
восстанавливаться: $N=E$.

Метод менее громоздок

Метод МАК-КОРМИКА 1

$$A = \frac{\left(\begin{matrix} \square \\ v \end{matrix} - H \begin{matrix} \square \\ u \end{matrix} \right) \begin{matrix} \square \\ v^T \end{matrix}}{\begin{matrix} \square \\ v^T \end{matrix} \begin{matrix} \square \\ u \end{matrix}}$$

Метод МАК-КОРМИКА 2

$$A = \frac{\begin{pmatrix} \overset{\square}{v} - H \overset{\square}{u} \end{pmatrix} \begin{pmatrix} \overset{\square}{u} & H \end{pmatrix}}{\overset{\square}{u}^T H \overset{\square}{u}}$$

Метод ГРИНСТАДТА

$$A = \frac{\begin{matrix} \boxed{} & \boxed{}^T & H & + & H & u & v^T \\ v & u^T & & & & & \end{matrix} - \left(1 + \frac{\begin{matrix} \boxed{}^T & \boxed{} \\ u^T & v \end{matrix}}{\begin{matrix} \boxed{}^T & \boxed{} \\ u^T & H & u \end{matrix}} \right) \begin{matrix} \boxed{} & \boxed{}^T \\ H & u & u^T & H \end{matrix}}{\begin{matrix} \boxed{}^T & \boxed{} \\ u^T & H & u \end{matrix}}$$

Сравнение методов по эффективности

- Среди методов нулевого порядка наибольшей эффективностью обладают *метод Розенброка* и *метод Нелдера Мида*
- Если же функция гладкая, т.е. имеет непрерывные производные, то наиболее эффективным себя зарекомендовали *метод Гольдфарба* и *метод ДФП* (они в 2-6 раз эффективнее по быстродействию чем метод Розенброка).
- На самом деле многое зависит от вида конкретной оптимизируемой функции. Особенно если количество оптимизируемых переменных больше 4-5 нужно иметь в запасе несколько разнообразных методов, а процесс оптимизации строить на основе интерактивных программ.

Конец