

20. Нелинейно оптимизиране

Общата задача на нелинейното оптимизиране се определя като задача за намирането на максимума (минимума) на целевата функция $f(x_1, x_2, \dots, x_n)$ върху множеството D , определено от ограниченията

$$D = \left\{ x \in \mathbb{R}^n \mid \begin{array}{l} g_i(x_1, x_2, \dots, x_n) \leq 0, i = 1, 2, \dots, l \\ g_i(x_1, x_2, \dots, x_n) = 0, i = l+1, \dots, m \end{array} \right\}$$

Отвѣдно е, че типът оптимизация не е определена; затова за напред ще разглеждаме задачи за \max . Който и в ЗЛО, векторът $x^* = (x_1^*, x_2^*, \dots, x_n^*) \in D$ ще наричаме допустим план; а в слуга, че за $\forall x \in D$ е изпълнено $f(x^*) \geq f(x)$ - x^* е оптимален план.

Задачата за нелинейното оптимизиране е толкова обща, че за нея не съществува общ метод за решаване.

20.1. Решение на задачата за условна оптимизация по метода на Лагранж.

Едно е, че с въвеждане на фиктивни променливи (както в ЗЛО) множеството D може да бъде описано само чрез уравнения.

Методът на Лагранж (известен от курса по математически анализ) се състои в свеждането на задачата за условен екстремум

$$\begin{aligned} f(x_1, x_2, \dots, x_n) &\rightarrow \max \\ g_1(x_1, x_2, \dots, x_n) &= 0 \\ g_2(x_1, x_2, \dots, x_n) &= 0 \\ &\vdots \\ g_m(x_1, x_2, \dots, x_n) &= 0 \end{aligned}$$

към задачата за безусловна оптимизация на функцията на Лагранж

$$L(x_1, x_2, \dots, x_n; \lambda_1, \lambda_2, \dots, \lambda_m) = f(x_1, x_2, \dots, x_n) + \sum_{i=1}^m \lambda_i g_i(x_1, \dots, x_n),$$

където $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_m) \in \mathbb{R}^m$ е вектор, състоящ се от та-

ка частотните множители на Лагранж.

В случай на гладкост (диференцируемост) на функциите $f(x)$ и $g_i(x)$, $i=1, 2, \dots, m$, е справедлива следната

Теорема 1. (Необходимо условие за условен екстремум). Ако $x^* = (x_1^*, x_2^*, \dots, x_n^*)$ е точка на условен екстремум и рангът на матрицата от първите частни производни

$$\left\| \frac{\partial g_i(x^*)}{\partial x_j} \right\|_{m \times n}$$

е равен на m , то съществуват такива $\lambda_1^*, \lambda_2^*, \dots, \lambda_m^*$, не равни едновременно на нули при които

$$\nabla \Phi(x^*, \lambda^*) = \nabla f(x^*) + \sum_{i=1}^m \lambda_i^* \nabla g_i(x^*) = 0$$

Заб.: $\nabla \Phi, \nabla f$ сме означили градиентите на Φ и f съответно, т.е. горното равенство ако го разпишем, добива вида:

$$\frac{\partial \Phi}{\partial x_1} = \frac{\partial f}{\partial x_1} + \sum_{i=1}^m \lambda_i^* \frac{\partial g_i}{\partial x_1} = 0$$

$$\frac{\partial \Phi}{\partial x_2} = \frac{\partial f}{\partial x_2} + \sum_{i=1}^m \lambda_i^* \frac{\partial g_i}{\partial x_2} = 0$$

$$\frac{\partial \Phi}{\partial x_n} = \frac{\partial f}{\partial x_n} + \sum_{i=1}^m \lambda_i^* \frac{\partial g_i}{\partial x_n} = 0$$

От Теорема 1 произлиза метод за търсене на условен екстремум (метод на Лагранж). Той се състои от следните стъпки:

1. Съставяне на функцията на Лагранж $\Phi(x, \lambda)$;
2. Намиране на частните производни от първи ред по всички променливи, т.е.

$$\frac{\partial \phi(x, \lambda)}{\partial x_j} \quad (j=1, 2, \dots, n) \quad \text{и} \quad \frac{\partial \phi(x, \lambda)}{\partial \lambda_i} \quad (i=1, 2, \dots, m)$$

3. Решаване на системата от уравнения

$$\left| \begin{array}{l} \frac{\partial \phi(x, \lambda)}{\partial x_j} = 0, \quad (j=1, 2, \dots, n) \\ \frac{\partial \phi(x, \lambda)}{\partial \lambda_i} = g_i(x) = 0, \quad (i=1, 2, \dots, m) \end{array} \right.$$

($n+m$ на брой уравнения за $n+m$ на брой неизвестни $x_1, x_2, \dots, x_n; \lambda_1, \lambda_2, \dots, \lambda_m$) и намери-
раме на критичните стойности $x_1^*, x_2^*, \dots, x_n^*;$
 $\lambda_1^*, \lambda_2^*, \dots, \lambda_m^*$.

4. Изследване на тези критични стойности с по-
мощта на някакво достатъчно условие за екстре-
муми.

Заб.: Присъствието на последното етап се обясня-
ва с това, че Теорема 1 е необходимо (но не и дос-
татъчно) условие за наличието на условен екст-
ремум. Такива достатъчни условия съществу-
ват, но обхващат тесни класове функции.

20.2. Оптимизационни задачи за изпъкнали функ-
ции.

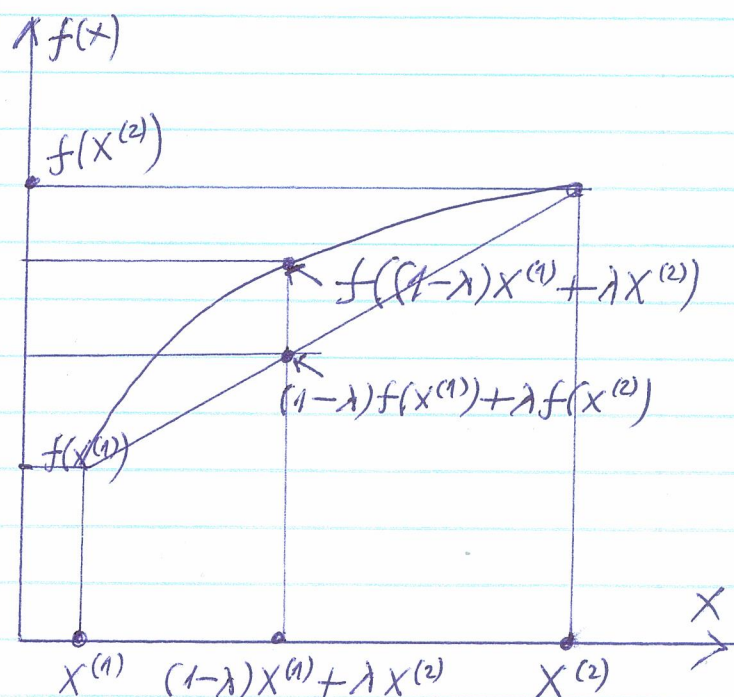

Определяме: функцията $f(x) = f(x_1, x_2, \dots, x_n)$ се нари-
та изпъкнала (вдлъбната) в областта D , ако за
 $\forall \lambda \in [0, 1]$ е изпълнено неравенството

$$f((1-\lambda)x^{(1)} + \lambda x^{(2)}) \leq (1-\lambda)f(x^{(1)}) + \lambda f(x^{(2)})$$

$$(f((1-\lambda)x^{(1)} + \lambda x^{(2)}) \geq (1-\lambda)f(x^{(1)}) + \lambda f(x^{(2)})),$$

където $x^{(1)}, x^{(2)} \in D$ (произволни).

Геометрически смисъл на понятието изпъкналост
(вдлъбнатост) може да се види на картинката по-долу.
Важда се, че графиката на изпъкналата (вдлъбната-
та) функция лежи под (над) правата линия, свързва-
ваща точките $(x^{(1)}, f(x^{(1)}))$ и $(x^{(2)}, f(x^{(2)}))$.



Може да се докаже, че достатъчно условие за изпъкналост на функцията $f(x) = f(x_1, x_2, \dots, x_n)$ е положителната дефинитност на хесиана (матрицата на Хесе)

$$H(f) = \left\| \frac{\partial^2 f(x)}{\partial x_i \partial x_j} \right\|_{n \times n} \quad \text{за } \forall x \in D$$

Съответно, достатъчното условие за вдлъбнатост на $f(x)$ е отрицателната определителност на хесиана $H(f)$.

От друга страна, от курса по линейна алгебра е известен критерият на Силвестър (за положителна и отрицателна дефинитност на произволна квадратна матрица). Образоваме всички главни минори на матрицата, в случай на хесиан те са:

главен минор от ред 1 : $\frac{\partial^2 f}{\partial x_1^2}$

главен минор от ред 2 :

$$\begin{vmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} \end{vmatrix}$$

главен минор
от ред 3:

$$\begin{vmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \frac{\partial^2 f}{\partial x_1 \partial x_3} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \frac{\partial^2 f}{\partial x_2 \partial x_3} \\ \frac{\partial^2 f}{\partial x_3 \partial x_1} & \frac{\partial^2 f}{\partial x_3 \partial x_2} & \frac{\partial^2 f}{\partial x_3^2} \end{vmatrix}$$

и т. н.

(с $| \cdot |$ е означена детерминанта на квадратна матрица)

Критерият на Силвестър гласи, че

1. Една матрица е положително дефинитна \Leftrightarrow всички главни минорци са положителни (в случай на хесиан - изпъкнала функция);

2. Една матрица е отрицателно дефинитна \Leftrightarrow ~~не~~ главните минорци от нечетен ред са отрицателни, а тези от четен ред - положителни (в случай на хесиан - вдлъбната функция).

За изпъкналите (вдлъбнатите) функции е справедливо следното достатъчно условие:

Теорема 2. Ако $f(x)$ е изпъкнала (вдлъбната) функция и $\nabla f(x^*) = 0$, то x^* е точка на глобален минимум (максимум).

Доказателство:

То ще се проведе в случай на вдлъбната функция, за противоположния случай то ще бъде аналогично с тогност до знака.

Нека x е произволна точка, различна от x^* . Тогава за $\forall \lambda \in (0; 1]$ по силата на вдлъбнатостта ще бъде изпълнено неравенството

$$f((1-\lambda)x^* + \lambda x) \geq (1-\lambda)f(x^*) + \lambda f(x)$$

изваждаме от двете страни на неравенството $f(x^*)$; тогава за лявата страна ползваме

$$f((1-\lambda)x^* + \lambda x) - f(x^*) = f(x^* - \lambda x^* + \lambda x) - f(x^*) = \\ = f(x^* + \lambda(x - x^*)) - f(x^*);$$

а за дясната

$$(1-\lambda)f(x^*) + \lambda f(x) - f(x^*) = f(x^*) - \lambda f(x^*) + \\ + \lambda f(x) - f(x^*) = \lambda(f(x) - f(x^*))$$

Така последното неравенство добива вида

$$f(x^* + \lambda(x - x^*)) - f(x^*) \geq \lambda(f(x) - f(x^*))$$

Ако вземем вектор $e = x - x^*$ и обозначим $\Delta x = \lambda(x - x^*) = \lambda e$, то дължината на вектора Δx ще бъде $\|\Delta x\| = \lambda \|e\|$.
Следователно,

$$f(x) - f(x^*) \leq \frac{f(x^* + \Delta x) - f(x^*)}{\lambda} = \frac{f(x^* + \Delta x) - f(x^*)}{\|\Delta x\|} \|e\|$$

Нека $\lambda \rightarrow 0$. Тогава (отчитайки, че векторите Δx и e са колинеарни) ще имаме

$$f(x) - f(x^*) \leq \frac{\partial f(x^*)}{\partial e} \|e\|$$

По условие $\nabla f(x^*) = 0$. Това означава, че за всеки вектор e (а това ще рече и за всяка точка x) съгласно формулата, изразяваща производната по направление чрез градиента

$$\frac{\partial f(x^*)}{\partial e} = P_{\tau_e} \nabla f(x^*) = 0$$

(с други думи: производната по направление на вектор e е проекцията върху e на градиента $\nabla f(x^*) =$

$$= \left(\frac{\partial f}{\partial x_1}(x^*), \frac{\partial f}{\partial x_2}(x^*), \dots, \frac{\partial f}{\partial x_n}(x^*) \right)$$

Така ще получиме, че за произволна $x, x \neq x^*$ е в сила $f(x) - f(x^*) \leq 0 \Rightarrow f(x) \leq f(x^*)$, т.е. x^* е точка на глобален максимум.

Тъй като изпъкналите функции имат много "полезни" оптимизационни качества, те заемат изключително важно място в математическото оптимизиране. Съответният раздел е получил името изпъкнало оптимизиране и се състои в намирането на максимум на вдлъбнатата (минимум на изпъкналата) функции върху изпъкнало множество.

20.3. Двойственост в нелинейното оптимизиране

Разглеждаме задачата

$$f(x) \rightarrow \max$$

$$D = \{x \in \mathbb{R}^n \mid g_i(x) \leq 0, i = 1, 2, \dots, m\}$$

Съставяме функцията на Лагранж

$$\Phi(x; \lambda) = f(x_1, x_2, \dots, x_n) - \sum_{i=1}^m \lambda_i g_i(x_1, x_2, \dots, x_n)$$

Двойката вектори $(\bar{x}; \bar{\lambda})$ се наричат седлова точка за функцията $\Phi(x; \lambda)$ ~~в $\mathbb{R}^n \times \mathbb{R}^m$~~ , ако за $\forall x$ и $\forall \lambda$ е изпълнено

$$\Phi(x; \bar{\lambda}) \leq \Phi(\bar{x}; \bar{\lambda}) \leq \Phi(\bar{x}; \lambda)$$

В качеството на пример за седлова точка може да се разгледа точката $(0, 0)$ за функцията $\Phi(x; \lambda) = -x^2 + \lambda^2$, определена върху множеството $\mathbb{R} \times \mathbb{R}$. И наистина $\Phi(0; 0) = 0$; $\Phi(x, 0) = -x^2$, а $\Phi(0, \lambda) = \lambda^2$.

Теорема 3 (Кун - Такер). Ако $(\bar{x}; \bar{\lambda})$ е седлова точка за функцията на Лагранж при $\lambda \geq 0$, то \bar{x} е оптимален план на задачата и е изпълнено условието

$$\sum_{i=1}^m \bar{\lambda}_i g_i(\bar{x}) = 0$$

Тази централна в нелинейното оптимизиране теорема представлява достатъчно условие за условен екстремум.

Тъй като за $\forall i$ $\lambda_i \geq 0$ и $g_i(x) \leq 0$, то ще имаме

$$\bar{\lambda}_i g_i(\bar{x}) \leq 0$$

Тогава горната сума от m на ф-ци събирани е нула, когато всички те са нули, т.е.:

$$\bar{\lambda}_1 g_1(\bar{x}) = \bar{\lambda}_2 g_2(\bar{x}) = \dots = \bar{\lambda}_m g_m(\bar{x}) = 0$$

Това означава следното:

1. Ако за някое i $\bar{\lambda}_i > 0$, то тогава $g_i(\bar{x}) = 0$;
2. Ако за някое j $g_j(\bar{x}) < 0$, то $\bar{\lambda}_j = 0$.

Доказателство:

По определение за седлова точка ще имаме

$$f(x) - \sum_{i=1}^m \bar{\lambda}_i g_i(x) \leq f(\bar{x}) - \sum_{i=1}^m \bar{\lambda}_i g_i(\bar{x}) \leq f(\bar{x}) - \sum_{i=1}^m \lambda_i g_i(\bar{x}) \quad (*)$$

за $\forall x$ и $\lambda \geq 0$.

От второто неравенство следва, че

$$\sum_{i=1}^m \lambda_i g_i(\bar{x}) \leq \sum_{i=1}^m \bar{\lambda}_i g_i(\bar{x}) \quad \text{за } \lambda_i \geq 0$$

Обаче такво неравенство може да е изпълнено само при $g_i(\bar{x}) \geq 0, i=1, 2, \dots, m$. Действително, ако съществува този номер k , че да е изпълнено $g_k(\bar{x}) > 0$, то ако положим $\lambda_i = 0$ за $i \neq k$

и изберем достатъчно голямо $\lambda_k > 0$, то изразът от лявата страна на горното неравенство

$$\sum_{i=1}^m \lambda_i g_i(\bar{x}) = \lambda_k g_k(\bar{x})$$

може да стане по-голям от фиксираната дясна страна на неравенството

$$\sum_{i=1}^m \bar{\lambda}_i g_i(\bar{x})$$

От това, че за $\forall i = 1, 2, \dots, m$ имаме $g_i(\bar{x}) \leq 0$ следва, че \bar{x} е допустим план на задачата.

Ако в лявата страна на въпросното неравенство поставим $\lambda_1 = \lambda_2 = \dots = \lambda_m = 0$, то получаваме, че

$$\sum_{i=1}^m \bar{\lambda}_i g_i(\bar{x}) \geq 0$$

Обаче, от $\bar{\lambda}_i \geq 0$ и $g_i(\bar{x}) \leq 0$ следва, че

$$\sum_{i=1}^m \bar{\lambda}_i g_i(\bar{x}) \leq 0$$

Така получаваме, че е изпълнено равенството

$$\sum_{i=1}^m \bar{\lambda}_i g_i(\bar{x}) = 0$$

Като заместим това равенство в първото неравенство от (*) получаваме

$$f(\bar{x}) \geq f(x) - \sum_{i=1}^m \bar{\lambda}_i g_i(x)$$

За всеки допустим план x е изпълнено неравенството $g_i(x) \leq 0$. В съгласие с $\bar{\lambda}_i > 0$ можем да твърдим, че

$$\sum_{i=1}^m \bar{\lambda}_i g_i(x) \leq 0,$$

следователно

$$f(x) - \sum_{i=1}^m \lambda_i g_i(x) \geq f(x)$$

Окончателно получаваме, че за всеки допустим план е в сила неравенството $f(\bar{x}) \geq f(x)$, следователно \bar{x} е оптимален план.

Твърдение, обратно на Теорема 2, т.е. достатъчни условия за екстремум на общата задача на линейното оптимиране се оказват възможни само ако се наложат допълнителни условия. Най-важното от тези условия е условието на Слейтър.

Определение. Ограничителната функция $g_i(x)$ на задачата на линейното оптимиране е регулярна по Слейтър, ако съществува такъв допустим план \tilde{x} , че

$$g_i(\tilde{x}) < 0,$$

т.е. \tilde{x} е вътрешна точка относно околността $g_i(x)$.

Съществуват много различни варианти на необходимо условие на Кун-Твкър. Ще приведем едно от тях:

Теорема 4. Ако (D, f) е зададена изпъкналото оптимиране с решение \bar{x} ; целевата функция $f(x)$ и ограничителните функции $g_i(x)$, $i=1, 2, \dots, m$ са диференцируеми, нелинейните ограничения са регулярни по Слейтър, то съществува такъв вектор $\bar{\lambda} \geq 0$, че точката $(\bar{x}, \bar{\lambda})$ е седлова точка на функцията на Лагранж.

Няма да привеждаме доказателство, защото то е доволно сложно.

Значението на теоремата на Кун-Твкър се състои в това, че тя позволява да се свърже оптимизационната задача с търсенето на сед-

лови точки на функцията на Лагранж, което означава максимализиране на тази функция по x и минимализиране по λ .

Определяме $F(x)$ като функция, поставяща в съответствие на $\forall x$ минималното значение на $\phi(x; \lambda)$ по λ :

$$F(x) = \min_{\lambda \geq 0} \phi(x; \lambda)$$

и по аналогия

$$G(\lambda) = \max_{x \in D} \phi(x; \lambda)$$

Да разгледаме задачата за максимализиране на $F(x)$

$$F(x) = \min_{\lambda \geq 0} \phi(x; \lambda) \rightarrow \max; x \in D$$

и задачата за минимализиране на $G(\lambda)$

$$G(\lambda) = \max_{x \in D} \phi(x; \lambda) \rightarrow \min; \lambda \geq 0$$

Очевидно е, че $F(x) = \min_{\lambda \geq 0} \phi(x; \lambda) = f(x)$, така

и задачата за максимализиране на $F(x)$ е равносилна на задачата за максимализиране на $f(x)$ при $x \in D$. Аналогични изводи могат да се направят и за $G(\lambda)$. Горните две задачи представляват дуална двойка. Това е едно обобщение на теорията на двойствеността в линейното оптимиране. Съответно, при определени условия дуалната двойка има свойства, аналогично с тези от линейното оптимиране. В частност, при произволни x и λ е изпълнено неравенството

$$F(x) \leq G(\lambda)$$