

ПРОСТЫЕ И СЛОЖНЫЕ ЗАДАЧИ ГЛОБАЛЬНОЙ ОПТИМИЗАЦИИ

О. В. Хамисов

(Институт систем энергетики им. Л.А. Мелентьева СО РАН, Иркутск)

МФТИ, 19 октября 2018

ОПТИМИЗАЦИЯ: ОСНОВНЫЕ МОМЕНТЫ

- ▶ ДИФФЕРЕНЦИРУЕМОСТЬ
- ▶ СТРУКТУРНЫЕ СВОЙСТВА

ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Задача безусловной минимизации

$$f(x) \rightarrow \min,$$

$$x \in \mathbb{R}^n.$$

Необходимое условие оптимальности (теорема Ферма)

$$f'(x) = 0 \quad (\nabla f(x) = 0).$$


⇓

Необходима дифференцируемость (=гладкость) f

ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Пример.

$$f(x) = \begin{cases} 2x^2 + x^2 \sin\left(\frac{1}{x}\right), & x \neq 0, \\ 0, & x = 0. \end{cases}$$



$$x^* = 0, f(x^*) = 0$$

ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Пример. Производная

$$f'(x) = \begin{cases} 4x + 2x \sin\left(\frac{1}{x}\right) - \cos\left(\frac{1}{x}\right), & x \neq 0, \\ 0, & x = 0. \end{cases}$$

Две последовательности, сходящиеся к решению,


$$x_k = \frac{1}{\pi + 2\pi k} \rightarrow 0, \quad y_k = \frac{1}{2\pi k} \rightarrow 0.$$

Тем не менее:

$$f'(x_k) \rightarrow 1 \neq 0, \quad f'(y_k) \rightarrow -1 \neq 0!$$

ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Пример. Геометрическая интерпретация $f'(x)$



$$f'(x_k) \rightarrow 1, f'(y_k) \rightarrow -1$$

ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Пример. f дифференцируема, но f' не является непрерывной.

ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Пример. f дифференцируема, но f' не является непрерывной.



С методической точки зрения f должна быть *непрерывно дифференцируемой*, $f \in C^1$.

ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Пример. f дифференцируема, но f' не является непрерывной.



С методической точки зрения f должна быть непрерывно дифференцируемой, $f \in C^1$.



Любая предельная точка метода наискорейшего спуска для $f \in C^1$ является стационарной (удовлетворяет теореме Ферма)

ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Задача безусловной минимизации

$$f(x) \rightarrow \min,$$

$$x \in \mathbb{R}^n,$$

$$f \in C^1.$$

Методический подход

Итеративная информация: $f(x^k), f'(x^k), k = 0, 1, \dots$

Гарантия: нахождение стационарной точки x^* : $f'(x^*) = 0$ ¹.

Вопрос: на сколько сильно отличается значение $f(x^*)$ от (глобально) минимального значения?

¹Если такая точка существует.

ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Задача безусловной минимизации

$$f(x) \rightarrow \min,$$

$$x \in \mathbb{R}^n,$$

$$f \in C^1.$$

Методический подход


Итеративная информация: $f(x^k), f'(x^k), k = 0, 1, \dots$


Гарантия: нахождение стационарной точки x^* : $f'(x^*) = 0$ ¹.


Вопрос: на сколько сильно отличается значение $f(x^*)$ от (глобально) минимального значения?


Ответ: на сколько угодно!!!


¹Если такая точка существует.





























ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Задача безусловной минимизации

$$f(x) \rightarrow \min,$$

$$x \in \mathbb{R}^n.$$

Изменится ли ситуация, если предположить $f \in C^k$, $k > 1$?

Ответ: Нет!!!

Теорема Уитни. Пусть $A \subset \mathbb{R}^n$ — замкнутое множество. Тогда существует функция $h \in C^\infty$ такая, что

$$A = \{x \in \mathbb{R}^n : h(x) = 0\}.$$

ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Задача безусловной минимизации

$$f(x) \rightarrow \min,$$

$$x \in \mathbb{R}^n.$$

Изменится ли ситуация, если предположить $f \in C^k$, $k > 1$?

Ответ: Нет!!!

Теорема Уитни. Пусть $A \subset \mathbb{R}^n$ — замкнутое множество. Тогда существует функция $h \in C^\infty$ такая, что

$$A = \{x \in \mathbb{R}^n : h(x) = 0\}.$$



$$h^2(x) \rightarrow \min.$$


ОПТИМИЗАЦИЯ: ДИФФЕРЕНЦИРУЕМОСТЬ

Теорема Уитни. Пусть $A \subset \mathbb{R}^n$ — замкнутое множество. Тогда существует функция $h \in C^\infty$ такая, что


$$A = \{x \in \mathbb{R}^n : h(x) = 0\}.$$



H. Whitney



Ковёр Серпинского



В. Серпинский

ОПТИМИЗАЦИЯ: СТРУКТУРИРУЕМОСТЬ

Главный вывод: необходима дополнительная информация (структурные свойства)

Например:

- ▶ линейность
- ▶ квадратичность
- ▶ выпуклость
- ▶ ...?



Классы (так называемых) хорошо структурированных задач

ОПТИМИЗАЦИЯ: СТРУКТУРИРУЕМОСТЬ

Задача безусловной минимизации

$$f(x) \rightarrow \min,$$

$$x \in \mathbb{R}^n,$$

$f \in C^2, \exists! x^* : \nabla f(x^*) = 0, \nabla^2 f(x^*) \succ 0$, является ли x^* точкой глобального минимума?

ОПТИМИЗАЦИЯ: СТРУКТУРИРУЕМОСТЬ

Задача безусловной минимизации

$$f(x) \rightarrow \min,$$

$$x \in \mathbb{R}^n,$$

$f \in C^2$, $\exists! x^* : \nabla f(x^*) = 0, \nabla^2 f(x^*) \succ 0$, является ли x^* точкой глобального минимума?

- ▶ Да, если $n = 1$.
- ▶ Нет, если $n > 1$.


ОПТИМИЗАЦИЯ: СТРУКТУРИРУЕМОСТЬ

ПРИМЕР.

$$f(x_1, x_2) = e^{3x_2} - 3x_1 e^{x_2} + x_1^3,$$

$$x^* = (1, 0), \nabla f(x_1^*, x_2^*) = 0,$$

$$f(x_1, 0) = 1 - 3x_1 + x_1^3.$$



Одноэкстремальные невыпуклые задачи

Свойство выпуклой гладкой функции

$$f(x) - f(y) \geq f'(y)^T(x - y) \quad \forall x, y \in \mathbb{R}^n.$$

Замена: $(x - y) \rightarrow \eta(x, y)$, $\eta : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}^n$



$$f(x) - f(y) \geq f'(y)^T \eta(x, y) \quad \forall x, y \in \mathbb{R}^n.$$

Тогда!

$$f'(y) = 0 \Rightarrow y \text{ — точка глобального минимума}^2$$

f — инвексная функция (invariant convex)

²Hanson M.A. *On sufficiency of the Kuhn-Tucker conditions*. Journal of Math. Analysis Appl. 80: 545-550, 1981

Одноэкстремальные невыпуклые задачи

- Как распознать инвексность?

$$f(x) = g(w(x)) = g(w_1(x), \dots, w_m(x)),$$

g — выпуклая дифференцируемая функция.

Выпуклость g : $\underbrace{g(w(x))}_{f(x)} - \underbrace{g(w(y))}_{f(y)} \geq \nabla g(w(y))^T (w(x) - w(y)).$

Инвексность: $f(x) - f(y) \geq \nabla f(y)^T \eta(x, y)$, градиент

$$\nabla f(y) = \nabla w(y)^T \nabla g(w(y))$$

Если

$$\nabla w(y) \eta(x, y) = w(x) - w(y),$$

то f — инвексная функция. Данное условие не зависит от g !


Одноэкстремальные невыпуклые задачи

- Пример.

$$f(x) = \sin^2(x), g(w) = w^2, w(x) = \sin(x).$$

Достаточное условие: $w'(x)\eta(x, y) = w(x) - w(y)$

$$\eta(x, y) = \frac{\sin(x) - \sin(y)}{\cos(y)}, \cos(y) \neq 0.$$



Одноэкстремальные невыпуклые задачи

Функция Розенброка

$$f(x_1, x_2) = 100(x_2 - x_1^2)^2 + (x_1 - 1)^2,$$

$$g(w) = w_1^2 + w_2^2, w_1(x) = 10(x_2 - x_1^2), w_2(x) = x_1 - 1.$$

достаточное условие $\nabla w(y)\eta(x, y) = w(x) - w(y)$ ($\det(w(y)) \neq 0$) :

$$\begin{pmatrix} -20y_1 & 10 \\ 1 & 0 \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} = \begin{pmatrix} 10(x_2 - x_1^2) - 10(y_2 - y_1^2) \\ x_1 - y_1 \end{pmatrix}$$

⇓

$$\eta_1(x, y) = x_1 - y_1,$$

$$\eta_2(x, y) = x_2 - y_2 - (x_1 - y_1)^2.$$

Одноэкстремальные невыпуклые задачи

Теорема (Hanson, 1981). Пусть $f : \mathbb{R}^n \rightarrow \mathbb{R}$ — дифференцируемая функция. Тогда f является инвексной функцией тогда и только тогда, когда каждая стационарная точка f есть точка глобального минимума.



Следствие. Если f не имеет стационарных точек, то f — инвексная функция.

ОДНОЭКСТРЕМАЛЬНЫЕ НЕВЫПУКЛЫЕ ЗАДАЧИ

ПРИМЕР. $X = \{(x_1, x_2) : x_2 > 0\}$


$$f(x_1, x_2) = x_2(x_1^2 - 1)^2$$

f — invex on X

$$\{x : \nabla f(x) = 0\} =$$

$$= \{(1, x_2), x_2 > 0\} \cup$$

$$\{(-1, x_2), x_2 > 0\}$$



Множество стационарных точек не является выпуклым

Одноэкстремальные невыпуклые задачи

Задачи инвексного программирования

$$f_0(x) \rightarrow \min,$$

$$f_i(x) \leq 0, \quad i = 1, \dots, m,$$

$$f_i(x) - f_i(y) \geq \nabla f_i(y)^T \eta(x, y), \quad i = 0, 1, \dots, m.$$

η — одна и та же для все f_i !

Теорема. Пусть x^* — точка, в которой выполняется какое-либо условие регулярности и необходимые условия первого порядка. Тогда x^* — точка глобального минимума задачи инвексного программирования.

Одноэкстремальные невыпуклые задачи

Пример.

$$f_0(x_1, x_2) = x_1 - \sin(x_2) \rightarrow \min,$$

$$f_1(x_1, x_2) = \sin(x_1) - 4 \sin(x_2) \leq 0,$$

$$f_2(x_1, x_2) = 2 \sin(x_1) + 7 \sin(x_2) + x_1 - 6 \leq 0,$$

$$f_3(x_1, x_2) = 2x_1 + 2x_2 - 3 \leq 0,$$


$$f_4(x_1, x_2) = 4x_1^2 + 4x_2^2 - 9 \leq 0,$$

$$f_5(x_1) = -\sin(x_1) \leq 0.$$

$$\eta(x, y) = \begin{pmatrix} \frac{\sin(x_1) - \sin(y_1)}{\cos(y_1)} \\ \frac{\sin(x_2) - \sin(y_2)}{\cos(y_2)} \end{pmatrix}$$

Одноэкстремальные невыпуклые задачи

Пример.



Одноэкстремальные невыпуклые задачи

Пессимистический результат.

Теорема.³ Если все функции $f_i, i = 1, \dots, m$ аффинны, то такая задача будет задачей инвексного программирования в том и только том случае, когда целевая функция f_0 есть выпуклая дифференцируемая функция.

³Martin D. *The essence of invexity*. JOTA, v. 47, №1, p.65-76, 1982

ОДНОЭКСТРЕМАЛЬНЫЕ НЕВЫПУКЛЫЕ ЗАДАЧИ

Mishra S.K. , Giorgi G. *Invexity and Optimization*. – Springer-Verlag, Berlin, 2008. – 266 p.

- Задачи глобальной оптимизации как правило **NP**-трудны.

$$x^T Qx + c^T x \rightarrow \min,$$

$$x \in X = \{x \in \mathbb{R}^n : Ax \leq b\},$$

Q имеет хотя бы одно отрицательное собственное число.

Пример 1. (“простая” **NP**-трудная задача)⁴

$$x_1 - x_2^2 \rightarrow \min,$$

$$x \in X = \{x \in \mathbb{R}^n : Ax \leq b\}.$$

⁴P.M. Pardalos, S.V. Vavasis *Quadratic programming with one negative eigenvalue is NP-hard* // JOGO. – 1991. – Vol.1, №1 . – P.15-22

- Задачи глобальной оптимизации как правило **NP**-трудны.

$$x^T Qx + c^T x \rightarrow \min,$$

$$x \in X = \{x \in \mathbb{R}^n : Ax \leq b\},$$

Q имеет хотя бы одно отрицательное собственное число.

Пример 2. (“простая” **NP**-трудная задача)⁵

$$x_1 x_2 \rightarrow \min,$$

$$x \in X = \{x \in \mathbb{R}^n : Ax \leq b\}.$$

⁵T. Matsui **NP**-hardness of linear multiplicative programming and related problems // JOGO. – 1996. – Vol.9, №2. – P.113-119

Пример 3. (“простая” **NP**-трудная задача)⁶

$$x_1 - \frac{1}{x_2} \rightarrow \min,$$

$$x \in X = \{x \in \mathbb{R}^n : Ax \leq b, x_2 > 0\}.$$

Пример 4. (“простая” **NP**-трудная задача)⁶

$$\frac{1}{x_1} + \frac{1}{x_2} \rightarrow \max,$$

$$x \in X = \{x \in \mathbb{R}^n : Ax \leq b, x_1 > 0, x_2 > 0\}.$$

⁶T. Matsui **NP**-hardness of linear multiplicative programming and related problems // JOGO. – 1996. – Vol.9, №2. – P.113-119

Пример 5. ("стандартная" NP-трудная задача)⁷

$$x^T Q x + c^T x \rightarrow \min,$$

$$x \in S = \{x \in \mathbb{R}_+^n : \sum_{j=1}^n x_j = 1\},$$

Q имеет хотя бы одно отрицательное собственное число.

Пример 6. ("стандартная" NP-трудная задача)⁷

$$x^T Q x + c^T x \rightarrow \min,$$

$$x \in \Pi = \{x \in \mathbb{R}^n : 0 \leq x_j \leq 1, j = 1, \dots, n\},$$

$Q \neq I$ имеет хотя бы одно отрицательное собственное число.

⁷S. Vavasis *Nonlinear optimization. Complexity issues* Oxford University Press, 1991.

- Минимизация квадратичной функции на шаре

$$\begin{aligned} x^T Q x + c^T x &\rightarrow \min, \\ \|x\| &\leq r. \end{aligned} \tag{1}$$

Пусть $U : U^T Q U = \text{diag}(\lambda_1, \dots, \lambda_n)$, $p = U^T c$. Тогда (1) эквивалентна задаче **выпуклого программирования**⁸:

$$\begin{aligned} \sum_{j=1}^n \lambda_j y_j - 2|p_j| \sqrt{y_j} &\rightarrow \min, \\ \sum_{j=1}^n y_j &\leq r, \quad y_j \geq 0, \quad j = 1, \dots, n. \end{aligned} \tag{2}$$

Соотношения: $x_j^* = \text{sign}(p_j) \sqrt{y_j^*}$, $j = 1, \dots, n$.

⁸A. Ben-Tal, M. Teboulle *Hidden convexity in some nonconvex quadratically constrained quadratic programming problems* // Mathematical Programming. – 1996. – Vol.72. – P.51-63

- Минимизация квадратичной функции при одном квадратичном ограничении

$$\begin{aligned} q_0(x) &= x^T A x + c^T x \rightarrow \min, \\ q_1(x) &= x^T B x + p^T x + r \leq 0. \end{aligned} \tag{3}$$

Теорема I⁹. Пусть $B \neq 0$ и $-\infty \leq \inf_{x \in \mathbb{R}^n} q_1(x) < 0$. Точка $\bar{x} : q_1(\bar{x}) \leq 0$ будет точкой глобального минимума тогда и только тогда, когда существует $\bar{\lambda} \geq 0$:

- ▶ $2(A + \bar{\lambda}B)\bar{x} + c + \bar{\lambda}p = 0$;
- ▶ $\bar{\lambda}q_1(\bar{x}) = 0$;
- ▶ $A + \bar{\lambda}B$ положительно полуопределенна.

⁹ J.J. More *Generalization of the trust region problem* // Optim. Meth. and Software. – 1993. – Vol.2. – P.189-209

- Минимизация квадратичной функции при двух квадратичных ограничениях

$$\begin{aligned} q_0(x) &= x^T A x + c^T x \rightarrow \min, \\ q_1(x) &= x^T B x + p^T x + r \leq 0, \\ q_2(x) &= x^T Q x + d^T x + s \leq 0. \end{aligned} \tag{4}$$

Существует разрыв между необходимыми и достаточными условиями глобальной оптимальности.

Теорема II (достаточные условия)¹⁰. Пусть $\bar{x} : q_1(\bar{x}) \leq 0, q_2(\bar{x}) \leq 0$ и существуют $\bar{\lambda}_1 \geq 0$ и $\bar{\lambda}_2 \geq 0$:

- ▶ $\nabla q_0(\bar{x}) + \bar{\lambda}_1 \nabla q_1(\bar{x}) + \bar{\lambda}_2 \nabla q_2(\bar{x}) = 0$;
- ▶ $\bar{\lambda}_1 q_1(\bar{x}) = \bar{\lambda}_2 q_2(\bar{x}) = 0$;
- ▶ $A + \bar{\lambda}_1 B + \bar{\lambda}_2 Q$ положительно полуопределенa.

Тогда \bar{x} – глобальный минимум задачи (4).

Теорема III (необходимые условия)¹⁰. Пусть \bar{x} – глобальный минимум в задаче (4), $q_1(\bar{x}) = 0, q_2(\bar{x}) = 0$ и градиенты $\nabla q_1(\bar{x}), \nabla q_2(\bar{x})$ линейно независимы. Тогда существуют единственные $\bar{\lambda}_1 \geq 0$ и $\bar{\lambda}_2 \geq 0$:

- ▶ $\nabla q_0(\bar{x}) + \bar{\lambda}_1 \nabla q_1(\bar{x}) + \bar{\lambda}_2 \nabla q_2(\bar{x}) = 0$;
- ▶ $A + \bar{\lambda}_1 B + \bar{\lambda}_2 Q$ имеет не более одного отрицательного собственного числа.

¹⁰ J.M. Peng, Y. Yuan *Optimality conditions for the minimization of a quadratic with two quadratic constraints* // SIAM J. Optimization. – 1997. – Vol.7, №3. – P.579-594

- ▶ В общем случае задачи глобальной оптимизации не поддаются эффективному решению.
- ▶ Тем не менее, некоторые (специальные) задачи глобальной (многоэкстремальной) оптимизации обладают свойством “*скрытой выпуклости*”.
- ▶ Термин “*скрытая выпуклость*” введен В.М. Тихомировым в 1989 г.
- ▶ В настоящее время многоэкстремальные задачи, обладающие свойством “*скрытой выпуклости*”, поддаются эффективному решению. Для этих задач
 - ▶ найдены критерии глобальной оптимальности;
 - ▶ характерно отсутствие разрыва классической (лагранжевой) двойственности;

- ▶ И в задаче с одним квадратичным ограничением и в задаче с двумя квадратичными ограничениями *разрыв двойственности равен нулю!*
- ▶ Возможная схема в \mathbb{R}^n

Условия оптимальности



Теоремы об альтернативе



Теоремы об отделимости

Классическая двойственность: f^* - оптимальное значение прямой задачи

$$f_0(x) \rightarrow \min,$$

$$f_i(x) \leq 0, \quad i = 1, \dots, m,$$

$$x \in X \subset \mathbb{R}^n.$$

Θ^* - оптимальное значение двойственной задачи

$$\Theta^* = \sup_{\lambda \geq 0} \min_{x \in X} \{ f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) \}.$$

Слабая теорема двойственности: $\Theta^* \leq f^*$.

Разрыв двойственности (duality gap): $f^* - \Theta^* \geq 0$.

Теорема (Фана)¹¹. Пусть X – выпуклое множество в \mathbb{R}^n , f_1, \dots, f_k – выпуклые функции на X . Предположим, что система

$$f_i(x) < 0, i = 1, \dots, k$$

не имеет решения на X . Тогда существуют $\lambda_1 \geq 0, \dots, \lambda_k \geq 0$, не равные нулю одновременно:

$$\sum_{i=1}^k \lambda_i f_i(x) \geq 0 \quad \forall x \in X.$$

Доказательство основано на разделении плоскостью выпуклых множеств в “пространстве образов”

$$U_1 = \{u \in \mathbb{R}^k : f_i(x) \leq u_i \text{ при некотором } x \in X\}$$

$$U_2 = \{u \in \mathbb{R}^k : u_i < 0, i = 1, \dots, k\}.$$

¹¹А.Г. Сухарев, А.В. Тимохов, В.В. Фёдоров *Курс методов оптимизации*. – М.: Наука, 1996. – 328 с.

Задача

$$f_0(x) \rightarrow \min,$$

$$f_i(x) \leq 0, i = 1, \dots, m,$$

$$x \in X$$

называется задачей *“с выпуклым образом”*¹² если $\forall x^1, x^2 \in X, \forall \alpha \in [0, 1] \exists x_\alpha \in X$:


$$f_i(x_\alpha) \leq (1 - \alpha)f_i(x^1) + \alpha f_i(x^2), \quad i = 0, \dots, m.$$

Зарубежный аналог: *convexlike – выпуклоподобная*

*Выпуклоподобные задачи и только они допускают разделение плоскостью “образа задачи” с отрицательным ортантом*¹³.

¹²В.М. Тихомиров *Теория экстремума и экстремальные задачи классического анализа* // Итоги науки и техники. Тематические обзоры. – М.: ВИНИТИ, 1998. – Т.60. – С.188-258

¹³F. Gianessi *Constrained Optimization and Image Space Analysis. Volume 1: Separation of Sets and Optimality Conditions.* - Springer, 2005. - 396 p.





$$f^* - \theta^* > 0$$

$$f^* - \theta^* = 0$$

f^* – оптимальное значение прямой задачи

θ^* – оптимальное значение двойственной задачи




- ▶ Работы Якубовича В.А. и Фрадкова А.Л.
- ▶ Polyak B.T. *Convexity of quadratic transformations and its use in control and optimization.* - JOTA, 1998, vol. 99, No. 3, pp. 553-583
- ▶ Поляк Б.Т. *Локальное программирование.* - ЖВМиМФ, 2001, т.41, №9, с. 1324-1331

B&B

WHY B&B?

Example 1. Shubert function

$$f(x_1, x_2) = \left(\sum_{i=1}^5 i \cos [(i+1)x_1 + i] \right) \cdot \left(\sum_{i=1}^5 i \cos [(i+1)x_2 + i] \right),$$




760 local minima, 18 global minima

WHY B&B?

Example 2.

$$f(x_1, x_2) = 4x_1^2 - 2.1x_1^4 + \frac{x_1^6}{6} + x_1x_2 - 4x_2^2 + 4x_2^4,$$
$$-3 \leq x_1 \leq 3, -1.5 \leq x_2 \leq 1.5.$$




6 local minima, 2 global minima

CONVEX ENVELOPES

- Univariate concave function


$$-ax_1^2 \geq l_1(x) = -a(\bar{x}_1 + \underline{x}_1)x + a\bar{x}_1\underline{x}_1, \quad \underline{x}_1 \leq x_1 \leq \bar{x}_1.$$



CONVEX ENVELOPES


- Bilinear function

$$x_1 x_2 \geq b(x_1, x_2) = \max(\underline{x}_2 x_1 + \underline{x}_1 x_2 - \underline{x}_1 \underline{x}_2, \bar{x}_2 x_1 + \bar{x}_1 x_2 - \bar{x}_1 \bar{x}_2)$$




BOUNDING

$$\begin{aligned}f(x_1, x_2) &= 4x_1^2 - 2.1x_1^4 + \frac{x_1^6}{6} + x_1x_2 - 4x_2^2 + 4x_2^4 \geqslant \\&\geqslant 4x_1^2 + \frac{x_1^6}{6} + 4x_2^4 + l_1(x_1) + l_2(x_2) + b(x_1, x_2).\end{aligned}$$



BOUNDING



B&B

$$4x_1^2 - 2.1x_1^4 + \frac{x_1^6}{6} + x_1x_2 - 4x_2^2 + 4x_2^4 \rightarrow \min,$$


$$x_1x_2 \leq 2,$$

$$0.5(x_1 + 2)^2 + 1.8(x_2 + 0.5)^2 \geq 1,$$



$$-3 \leq x_1 \leq 3, \quad -1.5 \leq x_2 \leq 1.5.$$

$$f^* = -20.98$$



1






$$f^* = -20.98$$






$$f^* = -20.98$$






$$f^* = -20.98$$






$$f^* = -20.98$$






$$f^* = -20.98$$



$$f^* = -20.98$$



$$f^* = -20.98$$



B&B

- Main points
 - ▶ Lower bounding
 - ▶ Partition
 - ▶ Upper bounding
 - ▶ Selection rule
 - ▶ Fathoming
- Global continuous optimization put strong assumption on B&B methods in order to guarantee convergence.


LIPSCHITZ OPTIMIZATION

$$|f(x) - f(y)| \leq L\|x - y\|$$


⇓

$$\underbrace{f(y) - L\|x - y\|}_{\text{support minorant}} \leq f(x) \leq \underbrace{f(y) + L\|x - y\|}_{\text{support majorant}}$$


LIPSCHITZ OPTIMIZATION




LIPSCHITZ OPTIMIZATION



LIPSCHITZ OPTIMIZATION



D.C. OPTIMIZATION ($f(x) = p(x) - q(x)$)



1. Reduction to Concave Programming Problem:


$$p(x) - q(x) \rightarrow \min,$$

$$x \in X.$$



$$z - q(x) \rightarrow \min,$$

$$p(x) \leq z, \quad x \in X.$$




2. Convex minorants:


$$p(x) - q(x) \geq \underbrace{p(x) - l(x)}_{\text{convex function}},$$

$$-q(x) \geq l(x), \quad l(x) = a^T x + b, \quad x \in S,$$


S is a simplex or parallelepiped.




B&B with convex majorants



B&B with convex majorants



B&B with convex majorants



- ▶ Horst R., Tuy H. *Global Optimization. (Deterministic Approaches)*, 3rd, revised and enlarged edition. – Berlin: Springer-Verlag, 1996.
- ▶ Horst R., Pardalos P.M., Thoai N.V. *Introduction to Global Optimization*. – Dordrecht: Kluwer Academic Publishers, 1995.

- Not very often used underestimator¹⁴:

Assumption A1

$$\|\nabla^2 f(x) - \nabla^2 f(y)\| \leq N\|x - y\|$$

then

$$\left| f(x) - f(y) - \nabla f(y)^T(x - y) - \frac{1}{2}(x - y)^T \nabla^2 f(y)(x - y) \right| \leq \frac{N}{6} \|x - y\|^3$$

and 2-minorant

$$\psi_2(x, y) = f(y) + \nabla f(y)^T(x - y) + \frac{1}{2}(x - y)^T \nabla^2 f(y)(x - y) - \frac{N}{6} \|x - y\|^3$$

¹⁴ Khamisov O.V. *Optimization with quadratic support functions in nonconvex smooth optimization*. — Numerical Computations: Theory and Algorithms (NUMTA–2016), AIP Conf. Proc. 1776, 050010-1–050010-4, 2016; doi: 10.1063/1.4965331

- Modification: from 2-minorant to q-minorant

Determine d : $\|x - y\| \leq d \ \forall x, y \in X$, then

$$\psi_2(x, y) = f(y) + \nabla f(y)^T(x - y) + \frac{1}{2}(x - y)^T \nabla^2 f(y)(x - y) - \frac{N}{6} \|x - y\|^3 \geq$$

$$\geq f(y) + \nabla f(y)^T(x - y) + \frac{1}{2}(x - y)^T \nabla^2 f(y)(x - y) - \frac{N \cdot d}{6} \|x - y\|^2 =$$

$$\geq f(y) + \nabla f(y)^T(x - y) + \frac{1}{2}(x - y)^T [\nabla^2 f(y) - \frac{N \cdot d}{3} \cdot I](x - y) = \psi_q(x, y),$$

I — unit matrix.

- Main property of **q-minorant**:

$$\psi_q(x, y) = f(y) + \nabla f(y)^T(x - y) + \frac{1}{2}(x - y)^T[\nabla^2 f(y) - \frac{N \cdot d}{3} \cdot I](x - y)$$

Let $y \in X$ be a local minimum:

1. $f(y)^T(x - y) \geq 0 \quad \forall x \in X;$
2. $\nabla^2 f(y) \succ 0.$

If d is small enough then

$$\nabla^2 f(y) - \frac{N \cdot d}{3} \cdot I \succcurlyeq 0$$

and $\psi_q(x, y)$ is convex in x .

- Main property of **q-minorant**:
 - As soon as $d \searrow 0$ $\psi_q(x, y)$ transforms from concave to convex in x function
 - If


$$\nabla^2 f(y) - \frac{N \cdot d}{3} \cdot I \succcurlyeq 0$$

then y is global minimum over

$$S_d = \{x \in \mathbb{R}^n : \|x - y\| \leq d\}.$$

- Sufficient d can be calculated

$$d = \frac{3 \cdot \lambda_{\min}(\nabla^2 f(y))}{N}.$$



Simplifying the objective (a trick)¹⁵

¹⁵ Khamisov O.V. *Objective Function Decomposition in Global Optimization*. in: R. Battiti, D.E. Kvasov, Y.D. Sergeyev (Eds.) LION 2017, LNCS 10556, pp. 338-344, 2017,
https://doi.org/10.1007/978-3-319-69404-7_28

Statement of the problem:

$$\min g(x), x \in X, \quad (5)$$

where g is a continuous composite function

$$g(x) = F(f_1(x), \dots, f_p(x)),$$

$F : \mathbb{R}^p \rightarrow \mathbb{R}$, $f_i : X \rightarrow \mathbb{R}$ are continuous functions, $X \subset \mathbb{R}^n$ is a compact set.

Obvious reduction:

$$\min F(y),$$

$$y_i = f_i(x), \quad i = 1, \dots, p, \quad x \in X.$$

For the reduced problem

$$\min F(y), \quad (6)$$

$$y_i = f_i(x), \quad i = 1, \dots, p, \quad (7)$$

$$x \in X. \quad (8)$$

we assume

- F is "less complicated" (or $p < n$);
- Equations (7) are computationally tractable in x for fixed y .

Reduced problem:

$$\min F(y),$$

$$y_i = f_i(x), \quad i = 1, \dots, p, \quad x \in X.$$

For $f(x) = (f_1(x), \dots, f_p(x))$ define

$$Y = \{y \in \mathbb{R}^p : y = f(x) \text{ for some } x \in X\}, \quad (9)$$

$$\underline{y}_i \leq \underline{f}_i = \min_{x \in X} f_i(x), \quad \max_{x \in X} f_i(x) = \bar{f}_i \leq \bar{y}_i, \quad i = 1, \dots, p. \quad (10)$$

Problem in y

$$\min F(y), \quad (11)$$

$$\underline{y}_i \leq y_i \leq \bar{y}_i, \quad i = 1, \dots, p, \quad (12)$$

$$y \in Y. \quad (13)$$

Inclusion (13) - Induced Constraint.

Reduced problem:

$$\min F(y),$$

$$y_i = f_i(x), \quad i = 1, \dots, p, \quad x \in X.$$

Agreed decomposition

$$g(x) = F(f_1(x^1), \dots, f_p(x^p)), \quad (14)$$

$$x^i \in X^i \subset \mathbb{R}^{n_i}, \quad i = 1, \dots, p, \quad (15)$$

$$X^1 \times \dots \times X^p = X. \quad (16)$$

↓

$$\min F(y),$$

$$\underline{f}_i \leq y_i \leq \bar{f}_i, \quad i = 1, \dots, p,$$

$$y_i = f_i(x^i), \quad x^i \in X^i, \quad i = 1, \dots, p.$$

Reduced agreed problem:

$$\min F(y), \quad (17)$$

$$\underline{f}_i \leq y_i \leq \bar{f}_i, \quad i = 1, \dots, p, \quad (18)$$

$$y_i = f_i(x^i), \quad x^i \in X^i, \quad i = 1, \dots, p. \quad (19)$$

Three stage approach

- I. Bounding stage. Determine \underline{f}_i and \bar{f}_i through (10).
- II. Optimality stage. Solve the problem (17)-(18) and find optimal point y^* .
- III. Feasibility stage. Solve the feasibility problem (19) for $y = y^*$ and obtain (all) optimal point(s) x^* for the initial problem.

Example 1.

$$g(x) = -(x_1 - 1)(x_1 + 2)(x_2 + 1)(x_2 - 2)x_3^2,$$

$$X = [-2, 2] \times [-2, 2] \times [-2, 2].$$

Let

$$F(y_1, y_2, y_3) = -y_1 y_2 y_3,$$

$$f_1(x_1) = (x_1 - 1)(x_1 + 2),$$

$$f_2(x_2) = (x_2 + 1)(x_2 - 2),$$

$$f_3(x_3) = x_3^2,$$

$$X^i = [-2, 2], \quad i = 1, 2, 3.$$

I. Bounding stage. Each function f_i is convex, so

$$\underline{f}_1 = \underline{f}_2 = -2.25, \underline{f}_3 = 0, \bar{f}_1 = \bar{f}_2 = \bar{f}_3 = 4.$$

II. Optimality stage.

$$\begin{aligned} \min\{F(y) = -y_1 y_2 y_3\}, \\ -2.25 \leq y_1 \leq 4, -2.25 \leq y_2 \leq 4, 0 \leq y_3 \leq 4, \end{aligned}$$

$$y^* = (4, 4, 4), F(y^*) = -64.$$

III. Feasibility stage.

$$\begin{aligned} (x_1 - 1)(x_1 + 2) = 4, -2 \leq x_1 \leq 2, \Rightarrow x_1^* = 2, \\ (x_2 + 1)(x_2 - 2) = 4, -2 \leq x_2 \leq 2, \Rightarrow x_2^* = -2, \\ x_3^2 = 4, -2 \leq x_3 \leq 2, \Rightarrow x_3^* = 2 \vee -2. \end{aligned}$$


Two global minimum points: $(2, -2, 2)$, $(2, -2, -2)$.

Example 2. (Schubert function).

$$g(x_1, x_2) = f_1(x_1) \cdot f_2(x_2) =$$

$$= \left(\sum_{i=1}^5 i \cos [(i+1)x_1 + i] \right) \cdot \left(\sum_{i=1}^5 i \cos [(i+1)x_2 + i] \right),$$

$$X = X_1 \times X_2, \quad X_1 = X_2 = [-10, 10].$$



It is obvious that

$$F(y_1, y_2) = y_1 y_2,$$

$$y_1 = f_1(x_1), \quad y_2 = f_2(x_2).$$

Additional assumption: we can efficiently solve (explicit) univariate global optimization problems.

I. Bounding stage.


$$\underline{f}_1 = \underline{f}_2 = -12.87088549, \bar{f}_1 = \bar{f}_2 = 14.50800793.$$

II. Optimality stage.

$$\min\{F(y_1, y_2) = y_1 y_2\},$$


$$-12.87088549 \leq y_i \leq 14.50800793,$$

$$i = 1, 2.$$



Two global minimum points $y^{*,1} = (y_1^{*,1}, y_2^{*,1}) = (-12.87088549, 14.50800793)$,
 $y^{*,2} = (y_2^{*,1}, y_1^{*,1}) = (14.50800793, -12.87088549)$,
 $F(y^{*,1}) = F(y^{*,2}) = -186.7309088$.

III. Feasibility stage. For every $i = 1, 2$ each equation $y_j^{*,i} = f_j(x_j)$, $j = 1, 2$ has three solutions in x_j . Hence, for every $i = 1, 2$ we have 9 solutions that gives 18 global minimum points in total.



In this way we can fight against multiplicity of global minima.

Example 3. (Goldstein-Price function), (using linear transformation).

$$g(x_1, x_2) = \left(1 + (x_1 + x_2 + 1)^2 (19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)\right) \times \\ \times \left(30 + (2x_1 - 3x_2)^2 (18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)\right),$$

$$X = [-2, 2] \times [-2, 2].$$

By linear transformation of variables, g can be rewritten:

$$g(x_1, x_2) = \left(1 + (x_1 + x_2 + 1)^2 (3(x_1 + x_2 + 1)^2 - 20(x_1 + x_2 + 1) + 36)\right) \times \\ \times \left(30 + (2x_1 - 3x_2)^2 (3(2x_1 - 3x_2) - 16(2x_1 - 3x_2) + 18)\right).$$

Then

$$y_1 = x_1 + x_2 + 1, \quad y_2 = 2x_1 - 3x_2. \quad (20)$$

For fixed (y_1, y_2) system (20) always has a unique solution in (x_1, x_2) .

Example 3. (Goldstein-Price function), (using linear transformation).

$$F(y_1, y_2) = (1 + y_1^2 (3y_1^2 - 20y_1 + 36)) \cdot (30 + y_2^2 (3y_2^2 - 16y_2 + 18))$$

— product of two univariate functions.

I. Bounding stage.

$$\underline{y}_1 = -3, \underline{y}_2 = -10, \bar{y}_1 = 5, \bar{y}_2 = 10.$$

II. Optimality stage.

$$\min F(y_1, y_2),$$

$$-3 \leq y_1 \leq 5, -10 \leq y_2 \leq 10.$$

Global minimum $y^* = (0, 3)$.

III. Feasibility stage.

$$x_1 + x_2 + 1 = 0 = y_1^*,$$

$$2x_1 - 3x_2 = 3 = y_2^*,$$

Solution $x^* = (0, -1)$.

Thank you for attention