

# Nemlineáris programozás

- Feltételmentes optimalizálás: egyenes menti keresés, a keresési tartomány fogalma, konvex függvények szélsőértékeinek tulajdonságai, nemdifferenciálható függvények minimumának megadása dichotóm kereséssel, differenciálható függvények minimumának megadása bináris kereséssel
- Többdimenziós feltételmentes minimumkeresés, a legmeredekebb irányok módszere
- Nemlineáris programok általános megoldása, belső és külső büntetőfüggvények alkalmazása, a büntetőfüggvények leggyakoribb megválasztása, a két módszer összehasonlítása

# Emlékeztető: megengedett javítóirányok

- Adott a  $\min f(\mathbf{x}) : \mathbf{x} \in X$  nemlineáris program, ahol  $X = \{\mathbf{x} : g_i(\mathbf{x}) \leq 0, i \in \{1, \dots, m\}\}$  és  $f$  és  $g_i$  folytonosan differenciálható az egész megengedett tartományon
- Felhasználjuk a tényt, hogy ha  $\bar{\mathbf{x}}$  lokális minimum, akkor  $\bar{\mathbf{x}}$ -ben nincs  $\mathbf{d}$  megengedett javítóirány, melyre  $\exists \delta > 0$  hogy

$$\forall \lambda \in (0, \delta) : \quad f(\bar{\mathbf{x}} + \lambda \mathbf{d}) < f(\bar{\mathbf{x}})$$
$$\bar{\mathbf{x}} + \lambda \mathbf{d} \in X$$

- Csak szükséges feltétel, de például konvex program esetén elégséges is
- A nemlineáris programot megengedett javítóirányok mentén tett iteratív lépésekkel oldjuk meg

# Emlékeztető: megengedett javítóirányok

- Keressünk pontot, melyben nincs megengedett javítóirány
- Legyen  $J \subseteq I$  az  $\bar{\mathbf{x}}$  pontban éles feltételek halmaza

$$\forall i \in J : g_i(\bar{\mathbf{x}}) = 0, \quad \forall i \in I \setminus J : g_i(\bar{\mathbf{x}}) < 0$$

- Például megengedett javítóirány a következő (ha létezik)

$$\mathbf{d} : \nabla f(\bar{\mathbf{x}})^T \mathbf{d} < 0, \quad \nabla g_i(\bar{\mathbf{x}})^T \mathbf{d} < 0 \quad \forall i \in J$$

- Ilyen  $\mathbf{d}$  irány például az alábbi optimalizálási probléma megoldásával kereshető

$$\min \nabla f(\bar{\mathbf{x}})^T \mathbf{d} : |\mathbf{d}| \leq 1, \quad \nabla g_i(\bar{\mathbf{x}})^T \mathbf{d} < 0 \quad \forall i \in J$$

- Lineáris célfüggvény, lineáris/linearizálható feltételek
- Szukcesszív lineáris programozás

# Emlékeztető: egyenes menti keresés

- Ha az optimum  $\sim 0$ , akkor jó eséllyel  $\bar{x}$  lokális minimum
  - patológikus esetekben a feltétel sajnos nem elégséges
- Ha az optimum negatív, akkor  $d$  megengedett javítóirány
- Keresés a  $\bar{x} + \lambda d : \lambda > 0$  félegyenes mentén úgy, hogy
  - ne lépjünk ki a megengedett tartományból
  - a célfüggvény minimumát keressük  $d$  irányban
- Egyváltozós nemlineáris program, ahol a megengedett tartomány egy egyszerű intervallum (vagy  $\mathbb{R}$ )

$$\min f(\bar{x} + \lambda d) : \bar{x} + \lambda d \in X, \lambda \geq 0$$

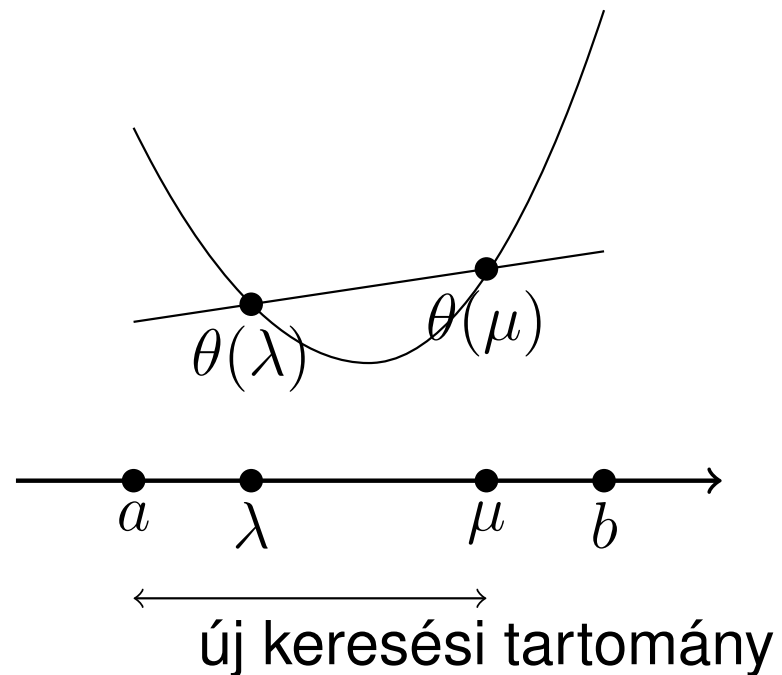
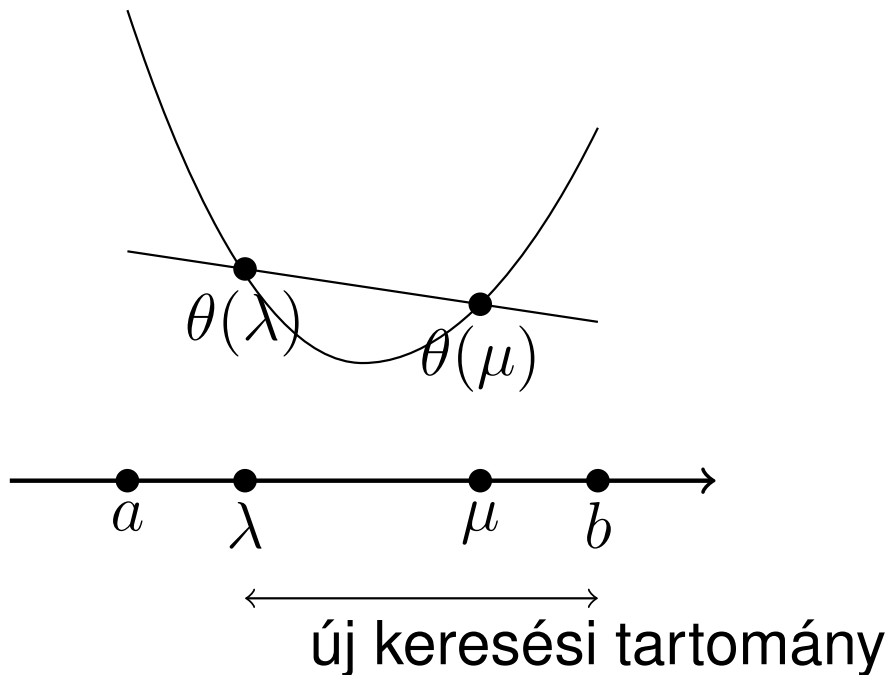
- Sok algoritmus működik a fenti séma szerint: találj egy javítóirányt majd egyenes menti keresés
- Hatékony egyenes menti kereső algoritmus szükséges

# Egyenes menti keresés

- Keressük a  $\min \theta(\lambda) : \lambda \in [a, b]$  **konvex** program optimális megoldását
  - csak konvex függvényekkel foglalkozunk
  - de az ötletek nemkonvex függvényekre is általánosíthatók
- A  $[a, b]$  intervallum neve **keresési intervallum**
- Az algoritmusok ötlete, hogy a keresési intervallum bizonyos részeiről belátjuk, hogy nem tartalmazzák a minimumot, így ezeket elhagyjuk
- Ehhez felhasználjuk a konvex függvények tulajdonságait
- Először egy nemdifferenciálható konvex függvényeken is működő algoritmust mutatunk

# Dichotóm keresés

- **Tétel:** legyen  $\theta$  az  $[a, b]$  keresési intervallumon konvex  $\mathbb{R} \mapsto \mathbb{R}$  függvény, és legyen  $\lambda, \mu \in [a, b]$  úgy, hogy  $\lambda < \mu$ . Ekkor
  - ha  $\theta(\lambda) > \theta(\mu)$ , akkor  $\forall z \in [a, \lambda) : \theta(z) \geq \theta(\mu)$
  - ha  $\theta(\lambda) < \theta(\mu)$ , akkor  $\forall z \in (\mu, b] : \theta(z) \geq \theta(\lambda)$



# Dichotóm keresés

- **Biz.:** tegyük fel először, hogy  $\theta(\lambda) > \theta(\mu)$  és legyen  $z \in [a, \lambda)$
- Tegyük fel, hogy  $\theta(z) < \theta(\mu)$ , és lássuk be, hogy így ellentmondásra jutunk
- Mivel  $z < \lambda < \mu$ , ezért  $\lambda$  felírható  $z$  és  $\mu$  konvex kombinációjaként
- A konvexitás miatt  $\theta(\lambda) \leq \max\{\theta(z), \theta(\mu)\} = \theta(\mu)$ , ami ellentmond a feltevésnek, hogy  $\theta(\lambda) > \theta(\mu)$
- A másik eset hasonlóan látható be □
- A tétel felhasználható arra, hogy két mintavétel után a keresési tartomány egy részét elhagyjuk

# Dichotóm keresés

- Például ha valamely  $\lambda < \mu$  pontokra  $\theta(\lambda) > \theta(\mu)$ , akkor az  $[a, \lambda)$  pontokban már biztos nem lehet  $\theta$  minimuma
- Az új keresési tartomány tehát  $[\lambda, b]$
- Ha ellenben  $\theta(\lambda) < \theta(\mu)$  adódik, akkor a  $(\mu, b]$  intervallum elhagyható, és az új keresési tartomány  $[a, \mu]$
- Fennállhat még  $\theta(\lambda) = \theta(\mu)$ , de erre a gyakorlatban nagyon kicsi az esély (például a véges pontosságú számábrázolás miatt)
- Az új keresési tartomány nagysága vagy  $b - \lambda$ , vagy  $\mu - a$
- Azt szeretnénk, ha az új keresési tartomány nagysága  $\max\{b - \lambda, \mu - a\}$  a legkisebb legyen
- Ehhez a  $\lambda = \mu = \frac{1}{2}(a + b)$  választás lenne a legjobb
- Nekünk viszont két, egymástól különböző  $\lambda$  és  $\mu$  pont kell



# Dichotóm keresés

- A megoldás, hogy az ideális  $\frac{1}{2}(a + b)$  pont körül szimmetrikusan  $\epsilon$  távolságra mérünk

$$\lambda = \frac{1}{2}(a + b) - \epsilon, \quad \mu = \frac{1}{2}(a + b) + \epsilon$$

- Az  $\epsilon$  konstanst úgy választjuk meg, hogy
  - a két mérési pont  $\lambda$  és  $\mu$  már kellően távol legyen ahhoz, hogy  $\theta(\lambda)$  és  $\theta(\mu)$  számottevően különbözzön
  - de a kapott új intervallum  $\frac{1}{2}(a + b) + \epsilon$  hossza ne nőjön meg túlzottan az optimális  $\frac{1}{2}(a + b)$  értékről
- Miután meghatároztuk  $\lambda$  és  $\mu$  értékét, kiértékeljük a függvényt ezekben a pontokban, és  $\theta(\lambda)$  és  $\theta(\mu)$  értéke szerint új keresési tartományt kapunk
- A keresés vége, ha keresési tartomány már elég kicsi

# Dichotóm keresés

- Konvex  $\theta$  függvény minimalizálása egy  $[a, b]$  keresési tartományban
  - Inicializálás: válasszunk  $\epsilon > 0$  konstanst és egy  $l > 0$  keresési pontosságot. Legyen  $a_1 = a$ ,  $b_1 = b$ , a kezdeti keresési tartomány  $[a_1, b_1]$  és legyen  $k = 1$
1. Ha  $b_k - a_k < l$ , akkor kiszállás: a minimum pont az  $[a_k, b_k]$  tartományban van
    - Ellenkező esetben állítsuk be  $\lambda_k$  és  $\mu_k$  értékét az alábbiak szerint
$$\lambda_k = \frac{1}{2}(a_k + b_k) - \epsilon, \quad \mu_k = \frac{1}{2}(a_k + b_k) + \epsilon$$
  2. Ha  $\theta(\lambda_k) < \theta(\mu_k)$ , akkor  $a_{k+1} = a_k$  és  $b_{k+1} = \mu_k$ , ellenkező esetben  $a_{k+1} = \lambda_k$  és  $b_{k+1} = b_k$ 
    - $k = k + 1$  és vissza az 1. lépésre

# Dichotóm keresés: példa

- A keresési tartomány hossza a  $k$ -adik lépésben

$$b_k - a_k = \frac{1}{2^k} (b - a) + 2\epsilon \left(1 - \frac{1}{2^k}\right)$$

- Ebből megadható az adott  $l$  pontosság eléréséhez szükséges lépésszám
- Például a  $\theta(\lambda) = \lambda^2$  függvény minimuma a  $[-5, 15]$  tartományon  $\epsilon = 10^{-2}$  és  $l = 2\epsilon$  választás mellett


$k$	$a$	$b$	$\lambda$	$\mu$	$\theta(\lambda)$	$\theta(\mu)$	$b - a$
1	-5.0000	15.0000	4.9900	5.0100	24.9001	25.1001	20.0000
2	-5.0000	5.0100	-0.0050	0.0150	0.0000	0.0002	10.0100
3	-5.0000	0.0150	-2.5025	-2.4825	6.2625	6.1628	5.0150
4	-2.5025	0.0150	-1.2538	-1.2338	1.5719	1.5221	2.5175
⋮	...	...	...	...	...	...	...
18	-0.0100	0.0101	-0.0100	0.0100	0.0001	0.0001	0.0201

# Differenciálható függvény minimalizálása

- Ha a minimalizálandó függvény nemcsak konvex, de differenciálható is, akkor az egyenes menti keresés egyszerűbb
- **Tétel:** egy folytonosan differenciálható  $f$  függvény akkor és csak akkor konvex egy  $X$  tartományon, ha

$$\forall \mathbf{x}, \mathbf{y} \in X : f(\mathbf{y}) \geq f(\mathbf{x}) + \nabla f(\mathbf{x})^T (\mathbf{y} - \mathbf{x}) \quad (1)$$

- Egy  $x$  pontba húzott érintő alsó becslést  $f$  értékére  $X$ -en



# Differenciálható függvény minimalizálása

- **Biz.:** először tegyük fel, hogy  $f$  konvex, majd belátjuk, hogy az (1) feltétel teljesül
- $f$  konvex: az  $f(\mathbf{x})$  és  $f(\mathbf{y})$  közötti vonalszakasz a függvényt felülről becsli  $\mathbf{x}$  és  $\mathbf{y}$  között

$$\forall \lambda \in [0, 1] : f(\lambda \mathbf{y} + (1 - \lambda) \mathbf{x}) \leq \lambda f(\mathbf{y}) + (1 - \lambda) f(\mathbf{x})$$

- Használjuk fel, hogy  $\mu a + (1 - \mu) b = b + \mu(a - b)$

$$f(\mathbf{x} + \lambda(\mathbf{y} - \mathbf{x})) \leq f(\mathbf{x}) + \lambda(f(\mathbf{y}) - f(\mathbf{x}))$$

- $f(\mathbf{x})$ -et a bal oldalra rendezve és osztva  $\lambda$ -val

$$\frac{f(\mathbf{x} + \lambda(\mathbf{y} - \mathbf{x})) - f(\mathbf{x})}{\lambda} \leq f(\mathbf{y}) - f(\mathbf{x})$$

# Differenciálható függvény minimalizálása

- Innen  $\lambda \rightarrow 0$  közelítéssel a kívánt egyenlőtlenséget kapjuk

$$\nabla f(\mathbf{x})^T (\mathbf{y} - \mathbf{x}) \leq f(\mathbf{y}) - f(\mathbf{x})$$

ugyanis  $f$  függvény  $(\mathbf{y} - \mathbf{x})$  irány menti deriváltja

$$\lim_{\lambda \rightarrow 0} \frac{f(\mathbf{x} + \lambda(\mathbf{y} - \mathbf{x})) - f(\mathbf{x})}{\lambda} = \nabla^T f(\mathbf{x})(\mathbf{y} - \mathbf{x})$$

- Megfordítva: lássuk be, hogy  $f$  konvexitása következik az (1) feltételből
- Legyen  $\mathbf{x}_1, \mathbf{x}_2 \in X$  az  $X$  halmaz két tetszőleges pontja és legyen  $\mathbf{x}$  a két pont bármely konvex kombinációja

$$\mathbf{x} = \lambda \mathbf{x}_1 + (1 - \lambda) \mathbf{x}_2, \quad \lambda \in [0, 1]$$

# Differenciálható függvény minimalizálása

- Írjuk fel (1) feltételt arra az esetre, ha  $\mathbf{y} = \mathbf{x}_1$

$$f(\mathbf{x}_1) \geq f(\mathbf{x}) + \nabla f(\mathbf{x})^T (\mathbf{x}_1 - \mathbf{x}) \quad (2)$$

- Írjuk fel a feltételt arra az esetre is, ha  $\mathbf{y} = \mathbf{x}_2$

$$f(\mathbf{x}_2) \geq f(\mathbf{x}) + \nabla f(\mathbf{x})^T (\mathbf{x}_2 - \mathbf{x}) \quad (3)$$

- Szorozzuk be (2)-t  $\lambda$ -val és (3)-at  $1 - \lambda$ -val, majd a két egyenlőtlenséget összeadva

$$\lambda f(\mathbf{x}_1) \geq \lambda f(\mathbf{x}) + \lambda \nabla f(\mathbf{x})^T (\mathbf{x}_1 - \mathbf{x})$$

$$(1 - \lambda) f(\mathbf{x}_2) \geq (1 - \lambda) f(\mathbf{x}) + (1 - \lambda) \nabla f(\mathbf{x})^T (\mathbf{x}_2 - \mathbf{x})$$

---

$$\lambda f(\mathbf{x}_1) + (1 - \lambda) f(\mathbf{x}_2) \geq f(\mathbf{x}) + \nabla f(\mathbf{x})^T (\lambda \mathbf{x}_1 + (1 - \lambda) \mathbf{x}_2 - \mathbf{x})$$

# Differenciálható függvény minimalizálása

- Mivel  $x$  az  $x_1$  és  $x_2$  pontok konvex kombinációja
  - egyrészt  $f(x) = f(\lambda x_1 + (1 - \lambda)x_2)$  helyettesíthető a jobb oldal első tagjában
  - másrészt a gradiens mögötti zárójeles tagra

$$\lambda x_1 + (1 - \lambda)x_2 - x =$$

$$\lambda x_1 + (1 - \lambda)x_2 - (\lambda x_1 + (1 - \lambda)x_2) = 0$$

- Így pont a konvexitás feltételét kapjuk

$$\lambda f(x_1) + (1 - \lambda)f(x_2) \geq f(\lambda x_1 + (1 - \lambda)x_2) \quad \square$$

- A konvex programozás egyik legfontosabb tétele



# Differenciálható függvény minimalizálása

- **Következmény:** legyen  $f$  egy folytonosan differenciálható konvex függvény és legyen  $\bar{\mathbf{x}} \in \mathbb{R}^n$ . Ekkor  $f(\bar{\mathbf{x}})$  akkor és csak akkor globális minimuma  $f$ -nek, ha  $\nabla f(\bar{\mathbf{x}}) = \mathbf{0}$
- **Biz.:** korábban láttuk, hogy  $\nabla f(\bar{\mathbf{x}}) = \mathbf{0}$  szükséges ahhoz, hogy  $f(\bar{\mathbf{x}})$  minimum legyen
- Azonban általános esetben  $\nabla f(\bar{\mathbf{x}}) = \mathbf{0}$  nem elégséges, mert inflexiós pontokban, illetve nyeregpontokban is teljesül
- Konvex függvényekre azonban a feltétel elégséges
- Tegyük fel, hogy  $\nabla f(\bar{\mathbf{x}}) = \mathbf{0}$  és alkalmazzuk az iménti tételt  $\bar{\mathbf{x}}$  pontra és egy tetszőlegesen választott  $\mathbf{y}$  pontra

$$f(\mathbf{y}) \geq f(\bar{\mathbf{x}}) + \nabla f(\bar{\mathbf{x}})^T (\mathbf{y} - \bar{\mathbf{x}}) = f(\bar{\mathbf{x}}) + 0$$

- Tehát  $f(\bar{\mathbf{x}})$  globális minimum



# Differenciálható függvény minimalizálása

- Egyváltozós esetben a tételek lényegesen egyszerűsödnek
- A  $\theta(\lambda) : \mathbb{R} \mapsto \mathbb{R}$  függvény akkor és csak akkor konvex, ha

$$\forall \mu, \nu : \quad \theta(\mu) \geq \theta(\nu) + \theta'(\nu)(\mu - \nu) \quad (4)$$

- A minimumpont feltétele pedig egyszerűen  $\theta'(\lambda) = 0$
- A két tétel segítségével differenciálható  $f$  függvény minimuma gyorsabban kereshető
- A dichotóm keresés esetében a keresési tartomány megfelezéséhez minden iterációban két, eltérő pontban kellett kiértékelni a függvényt
- Ha azonban  $\theta$  differenciálható, akkor elég egy pontban kiértékelni a deriváltját  $\theta'$ -t
- Egyszerű bináris kereséssel megoldható a feladat

# Differenciálható függvény minimalizálása

- Keressük a  $\min \theta(\lambda) : \lambda \in [a, b]$  **konvex** program optimális megoldását, ahol  $\theta$  **differenciálható**  $[a, b]$  halmazon
- Tegyük fel, hogy valamely  $\lambda \in [a, b]$  pontban ismerjük a derivált értékét,  $\theta'(\lambda)$ -t. Három eset lehetséges
  - $\theta'(\lambda) = 0$ : ekkor a fentiek miatt  $\theta$  a  $\lambda$  pontban éri el a minimumát
  - $\theta'(\lambda) > 0$ : ekkor minden  $\mu > \lambda$  esetén  $\theta'(\lambda)(\mu - \lambda) > 0$ , ezért (4) miatt  $\theta(\mu) > \theta(\lambda)$  adódik. Következésképp a minimumpont nem lehet a  $[\lambda, b]$  tartományban, így a keresési tartomány a  $[a, \lambda]$  intervallumra szűkíthető
  - $\theta'(\lambda) < 0$ : pont megfordítva, ebben az esetben  $\mu < \lambda$  pontokra kapjuk a  $\theta(\mu) > \theta(\lambda)$  becslést. Ugyanis  $\theta'(\lambda)(\mu - \lambda) > 0$ , mert  $\theta'(\lambda) < 0$  és  $\mu - \lambda < 0$ . Az új keresési tartomány  $[\lambda, b]$

# Differenciálható függvény minimalizálása

- A  $\lambda$  pontot úgy kell kiválasztanunk, hogy az új keresési tartomány  $\max\{\lambda - a, b - \lambda\}$  mérete a legrosszabb esetet feltételezve is a minimális legyen
- Könnyű látni, hogy ez az  $[a, b]$  intervallum felezőpontjában következik be, vagyis  $\lambda = \frac{1}{2}(a + b)$
- Egyszerű bináris keresés:
  - Inicializálás: válasszunk  $l > 0$  keresési pontosságot. Legyen  $a_1 = a$ ,  $b_1 = b$ , és legyen  $k = 1$
  - 1. legyen  $\lambda_k = \frac{1}{2}(a_k + b_k)$  és tekintsük  $\theta'(\lambda_k)$  értékét
  - 2. ha  $\theta'(\lambda) = 0$  vagy  $b_k - a_k < l$ , akkor kiszállás: a minimum pont az  $[a_k, b_k]$  tartományban van
  - 3. ha  $\theta'(\lambda) > 0$ , akkor  $a_{k+1} = a_k$  és  $b_{k+1} = \lambda_k$ , különben  $a_{k+1} = \lambda_k$  és  $b_{k+1} = b_k$ , és vissza az 1. lépésre

# Differenciálható függvény minimalizálása

- A  $k$ -adik lépésben a keresési tartomány nagysága  $\frac{1}{2^k}(b - a)$
- Ebből becsülhető az adott  $l$  keresési pontosság eléréséhez szükséges lépésszám
- Keressük a  $\theta(\lambda) = \lambda^2 + 2\lambda$  függvény minimumát a  $[-5, 15]$  tartományon, az  $l = 2 \cdot 10^{-2}$  választás mellett

$k$	$a$	$b$	$\lambda$	$\theta'(\lambda)$	$\theta(\lambda)$	$b - a$
1	-5.0000	15.0000	5.0000	12.0000	35.0000	20.0000
2	-5.0000	5.0000	0.0000	2.0000	0.0000	10.0000
3	-5.0000	0.0000	-2.5000	-3.0000	1.2500	5.0000
⋮	...	...	...	...	...	...
11	-1.0156	-0.9961	-1.0059	0.0118	-1.0000	0.0195

- A  $\theta'(\lambda) = 2\lambda + 2 = 0$  egyenletet kielégítő pontot keressük, de  $\theta'(\lambda) = 0$  sokszor nem oldható meg zárt alakban

# Többdimenziós szélsőérték-keresés

- A gyakorlatban sokszor kell  $\mathbb{R}^n \mapsto \mathbb{R}$  függvények minimumát keresni egy adott tartományon
- Tehát adott a  $\min f(\mathbf{x}) : \mathbf{x} \in X$  nemlineáris program, és legyen most  $X = \mathbb{R}^n$
- Tegyük fel, hogy  $f$  folytonosan differenciálható és konvex
- A minimum abban az  $\bar{\mathbf{x}}$  pontban áll elő, melyre  $\nabla f(\bar{\mathbf{x}}) = \mathbf{0}$
- Ez az egyenlet bonyolult  $f$  függvényekre analitikusan nem oldható meg, ezért numerikus módszereket kell bevetnünk
- Konvex program minimumának keresésére van módszerünk: a megengedett irányok módszere
- Itt most jelentősen egyszerűsödik, mert minden irány megengedett irány ( $X = \mathbb{R}^n$ )
- Csak arról kell gondoskodnunk, hogy javítóirány is legyen

# Legmeredekebb irányok módszere

- Valamely  $\bar{\mathbf{x}}$  pontban egy  $\mathbf{d}$  irány javítóirány akkor és csak akkor, ha  $\nabla f(\bar{\mathbf{x}})^T \mathbf{d} < 0$
- Keressük azt az egység abszolút értékű  $\mathbf{d}$  irányt, amely mentén a legmeredekebb a célfüggvény

- **Tétel:**

$$\operatorname{argmin}_{\mathbf{d}: \|\mathbf{d}\|=1} \nabla f(\bar{\mathbf{x}})^T \mathbf{d} = \frac{-\nabla f(\bar{\mathbf{x}})}{\|\nabla f(\bar{\mathbf{x}})\|}$$

- **Biz.:** a Cauchy–Schwarz egyenlőtlenségből, illetve  $\|\mathbf{d}\| = 1$  miatt

$$\nabla f(\bar{\mathbf{x}})^T \mathbf{d} \geq -\|\nabla f(\bar{\mathbf{x}})\| \|\mathbf{d}\| \geq -\|\nabla f(\bar{\mathbf{x}})\|$$

- Egyenlőség akkor és csak akkor, ha  $\mathbf{d} = \frac{-\nabla f(\bar{\mathbf{x}})}{\|\nabla f(\bar{\mathbf{x}})\|}$  □

# Legmeredekebb irányok módszere

- A tétel értelmében a  $d = \frac{-\nabla f(\bar{x})}{\|\nabla f(\bar{x})\|}$  a legmeredekebb megengedett javítóirány
- Vagyis ebben az irányban egységnyit haladva csökken a leginkább a célfüggvény értéke
- A lépésköz meghatározásához keresés a  $\frac{-\nabla f(\bar{x})}{\|\nabla f(\bar{x})\|}$  irány mentén
- Célszerű a bináris keresést használni



# Legmeredekebb irányok módszere

- Oldjuk meg a  $\min f(\mathbf{x}) : \mathbf{x} \in \mathbb{R}^n$  feltételmentes nemlineáris programot, ahol  $f$  folytonosan differenciálható konvex függvény
- Inicializálás: válasszunk  $\epsilon > 0$  pontosság határt,  $\mathbf{x}_1$  kezdeti pontot és legyen  $k = 1$
- 1 Ha  $\|\nabla f(\mathbf{x}_k)\| < \epsilon$ , akkor kiszállás,  $\mathbf{x}_k$  minimumpont
- 2 Egyébként  $\mathbf{d}_k = -\nabla f(\mathbf{x}_k)$
- 3 Egyenes menti keresés: oldjuk meg a

$$\min f(\mathbf{x}_k + \lambda \mathbf{d}_k) : \lambda \geq 0$$

feltételmentes egyenes menti keresési feladatot, és legyen az optimális megoldás  $\lambda_k$

- 4 Legyen  $\mathbf{x}_{k+1} = \mathbf{x}_k + \lambda_k \mathbf{d}_k$  és ugrás vissza az 1. lépésre

# Legmeredekebb irányok módszere

- Egyszerű és könnyen implementálható módszer
- Elméletben véges lépésben konvergál, a gyakorlatban azonban kevésbé használható
- Az algoritmus az optimum közelében egyre rövidebb, a legutóbbi lépésre majdnem merőleges irányban egyre kisebb lépéseket tesz meg: cikk-cakk
- Ez az összes elsőrendű módszerre érvényes, amelyet tárgyaltunk
- A jelenség kiküszöböléséhez általában másodrendű módszereket használnak
- Newton módszer, konjugált gradiens módszer, stb.
- Itt nem tárgyaljuk

# Büntetőfüggvények módszere

- Az egy- és többváltozós feltételmentes optimalizálási algoritmusok segítségével megoldhatók feltételeket is tartalmazó nemlineáris programok
- Az ötlet az, hogy a feltételeket „beépítjük” a célfüggvénybe büntetőfüggvényeken keresztül: a megváltoztatott feltételmentes optimalizálási feladat a feltételes program optimumába konvergál
- A feltételek megsértése erősen növeli a célfüggvény értékét, így a minimalizálás során a megoldó algoritmusok törekednek majd a feltételek kielégítésére
  - külső büntetőfüggvények: a megengedett tartományból való kilépést büntetjük, így nem megengedett megoldások sorozatán keresztül jutunk az optimumba
  - belső büntetőfüggvények: a generált pontok nem léphetnek ki a megengedett tartományból

# Külső büntetőfüggvények

- Tekintsük az alábbi egyszerű formájú nemlineáris programokat

$$\min f(\mathbf{x}) : h(\mathbf{x}) = 0$$

ahol  $f$  és  $h$  két  $\mathbb{R}^n \mapsto \mathbb{R}$  függvény és  $\mathbf{x} \in \mathbb{R}^n$

- Helyettesítsük a fenti feltételes optimalizálási feladatot egy feltételmentes feladattal

$$\min f(\mathbf{x}) + \mu h^2(\mathbf{x}) : \mathbf{x} \in \mathbb{R}^n$$

ahol  $\mu > 0$  valamilyen nagy skalár

- Intuitívan látható, hogy az optimumban a  $\mu h^2(\mathbf{x})$  **külső büntetőfüggvény** értéke közel lesz zéróhoz, ellenkező esetben ez a tag erősen megnöveli a célfüggvény értékét
- Elég nagy  $\mu$  értéket választva általában biztosítható, hogy a két feladat optimuma ugyanoda essen

# Külső büntetőfüggvények

- Egyenlőtlenség feltételt tartalmazó nemlineáris programok esetében másfajta külső büntetőfüggvény kell

$$\min f(\mathbf{x}) : g(\mathbf{x}) \leq 0$$

- Ekkor ugyanis  $\mu g^2(\mathbf{x})$  mind a  $g(\mathbf{x}) < 0$  és a  $g(\mathbf{x}) > 0$  megoldásokat büntetné, holott nekünk csak a másodikat kell
- Helyettesítsünk az alábbi feltételmentes feladattal

$$\min f(\mathbf{x}) + \mu \max\{0, g(\mathbf{x})\} : \mathbf{x} \in \mathbb{R}^n$$

- Értelemszerűen csak akkor jelenik meg plusz tag a célfüggvényben, ha  $g(\mathbf{x}) > 0$ , ha  $g(\mathbf{x}) < 0$ , akkor  $\max\{0, g(\mathbf{x})\} = 0$  és nincs büntetés
- Még jobb a  $\mu(\max\{0, g(\mathbf{x})\})^2$  büntetőfv.: differenciálható

# Külső büntetőfüggvények

- Általános esetben a nemlineáris program több egyenlőség és egyenlőtlenség típusú feltételt is tartalmaz

$$\begin{aligned} \min \quad & f(\mathbf{x}) \\ \text{s.t.} \quad & g_i(\mathbf{x}) \leq 0 && i \in \{1, \dots, m\} \\ & h_i(\mathbf{x}) = 0 && i \in \{1, \dots, n\} \end{aligned}$$

- Ekkor a külső büntetőfüggvény formája

$$\alpha(\mathbf{x}) = \sum_{i=1}^m \Phi(g_i(\mathbf{x})) + \sum_{i=1}^n \Psi(h_i(\mathbf{x}))$$
$$\Phi(y) = (\max\{0, y\})^p, \quad \Psi(y) = |y|^p$$

valamilyen  $p > 0$  egész számra

# Külső büntetőfüggvények

- Ekkor az alábbi feltételmentes nemlineáris programot kell megoldani

$$\min f(\mathbf{x}) + \mu \left( \sum_{i=1}^m (\max\{0, g_i(\mathbf{x})\})^p + \sum_{i=1}^n |h_i(\mathbf{x})|^p \right) : \\ \mathbf{x} \in \mathbb{R}^n$$

- Megoldható a korábban ismerttetett módszerekkel
- Tetszőleges, akár nem megengedett kezdőpontból is indítható
- Hátránya, hogy csak az optimum közelében ér a megengedett tartományba
- A jó működéshez nagy  $\mu$  kell: numerikus instabilitás

# Külső büntetőfüggvények: példa

- Tekintsük a feltételes (nem)lineáris programot

$$\min x$$


$$\text{s.t. } -x + 2 \leq 0$$

- Az optimum a  $\bar{x} = 2$  pontban  $f(\bar{x}) = 2$
- Oldjuk meg külső büntetőfüggvény használatával
- Írjuk fel az  $\alpha(x) = (\max\{0, g(x)\})^2$  külső büntetőfüggvény segítségével feltételmentes nemlineáris programként

$$\alpha(x) = \begin{cases} 0 & \text{ha } x \geq 2 \\ (-x + 2)^2 & \text{ha } x < 2 \end{cases}$$



# Külső büntetőfüggvények: példa



- Az  $f(x) + \mu\alpha(x)$  konvex, így minimumpontja kereshető

- A derivált, ha  $x < 2$ :

$$(f(x) + \mu\alpha(x))' = 1 + 2\mu(x - 2) = 0$$

- Ebből a minimumpont

$$\bar{x} = 2 - \frac{1}{2\mu}$$

- Közelíti az eredeti probléma optimumát, ahogy  $\mu \rightarrow \infty$

- Általában is igaz

# Külső büntetőfüggvények: példa

- Oldjuk meg a feltételes nemlineáris programot

$$\min x_1^2 + x_2^2 : x_1 + x_2 - 1 = 0$$

- Az optimális megoldás  $\begin{bmatrix} x_1 & x_2 \end{bmatrix}^T = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} \end{bmatrix}^T$ , az optimum  $\frac{1}{2}$
- Alkalmazzuk az  $\alpha(y) = |y|^2$  külső büntetőfüggvényt

$$\min x_1^2 + x_2^2 + \mu(x_1 + x_2 - 1)^2 : x_1, x_2 \in \mathbb{R}$$

- $\forall \mu \geq 0$  esetén konvex, így a gradiensből adódik a minimum

$$2x_1 + 2\mu(x_1 + x_2 - 1) = 0$$

$$2x_2 + 2\mu(x_1 + x_2 - 1) = 0$$

- A két egyenletből  $x_1 = x_2 = \frac{1}{2 + \frac{1}{\mu}}$ ,  $\mu \rightarrow \infty$  esetén optimális

# Belső büntetőfüggvények

- A külső büntetőfüggvények módszere nem megengedett pontok sorozatán keresztül konvergál az optimumba
- A belső büntetőfüggvények módszerénél a generált pontok nem léphetnek ki a megengedett tartományból
- Adva van a nemlineáris program egyenlőtlenség feltételekkel

$$\begin{array}{ll} \min & f(\mathbf{x}) \\ \text{s.t.} & g_i(\mathbf{x}) \leq 0 \quad i \in \{1, \dots, m\} \end{array}$$

- Ehelyett oldjuk meg a feltételmentes optimalizálási problémát

$$\min f(\mathbf{x}) + \mu\beta(\mathbf{x}) : \mathbf{x} \in \mathbb{R}^n$$

# Belső büntetőfüggvények

- A  $\beta$  belső büntetőfüggvény a megengedett tartományon valamilyen nemnegatív értéket vesz fel, míg a megengedett tartomány határához közelítve tart a végtelenbe

$$\beta(\mathbf{x}) = \sum_{i=1}^m \Phi(g_i(\mathbf{x}))$$

ahol a  $\Phi$  függvénynek az alábbi tulajdonságai vannak

$$\Phi(y) \geq 0 \text{ ha } y < 0, \quad \lim_{y \rightarrow 0^-} \Phi(y) = \infty$$

- A belső büntetőfüggvény megtiltja a megengedett tartomány határának átlépését
- Egyenlőségfeltételek nehezen kezelhetőek ilyen módon

# Belső büntetőfüggvények

- Tipikus belső büntetőfüggvények

$$\beta(\mathbf{x}) = \sum_{i=1}^m \frac{-1}{g_i(\mathbf{x})}, \quad \beta(\mathbf{x}) = - \sum_{i=1}^m \ln(\min\{1, -g_i(\mathbf{x})\})$$

- A kiegészített célfüggvény feltételmentes optimalizálással minimalizálható, és a folyamat során sosem lépünk ki a megengedett tartományból
- Hátránya, hogy az optimum pontban minden feltétel jelentkezik a célfüggvényben, nemcsak az aktívak
- Továbbá feltétlenül megengedett pontból kell indítani, különben a büntetőfüggvény „rossz oldalára” kerülünk
- Akkor működik jól, ha  $\mu$  értéke kicsi, ez azonban rosszul kondicionáltsághoz és numerikus instabilitáshoz vezethet

# Belső büntetőfüggvények: példa

- Tekintsük a nemlineáris programot

$$\begin{aligned} \min \quad & x \\ \text{s.t.} \quad & -x + 1 \leq 0 \end{aligned}$$

- Az optimum 1, amit a célfüggvény az  $\bar{x} = 1$  pontban vesz fel
- Legyen a belső büntetőfüggvény a következő

$$\beta(x) = \frac{-1}{-x + 1} = \frac{1}{x - 1} \quad x \neq 1$$

- A kapott feltételmentes optimalizálási feladat

$$\min x + \frac{\mu}{x - 1} : x \in \mathbb{R}$$

# Belső büntetőfüggvények: példa

- A  $\min x + \frac{\mu}{x-1} : x \in \mathbb{R}$  feladat csak akkor ad értelmes megoldást, ha  $x > 1$ , erről külön kell gondoskodnunk
- A célfüggvény konvex, minimuma a  $\frac{d}{dx}(f(x) + \mu\beta(x)) = 0$  egyenletből  $\bar{x} = 1 + \sqrt{\mu}$ , optimális ha  $\mu \rightarrow 0$

