

Del III Ikke-lineær optimering

$$\text{La } f: \mathbb{R}^n \rightarrow \mathbb{R} \quad f(\vec{x}) = f(x_1, \dots, x_n)$$

f kalles objektifunksjonen, denne skal minimeres.


x^* kalles et lokalt minimum hvis det finnes en $\varepsilon > 0$
 s.o. $f(x^*) \leq f(x)$ for alle $\vec{x} \in \underbrace{B(x^*, \varepsilon)}_{\text{alle punkter } z \text{ s.o. } \|z - x^*\| < \varepsilon}$

x^* er globalt minimum hvis $f(x^*) \leq f(x)$ alle x . $\bar{B}(x^*, \varepsilon) = \{z \mid \|z - x^*\| \leq \varepsilon\}$
 $(x \text{ er min for } f(x) \iff x \text{ er maks for } -f(x))$

Skal senere ta med betingelser.

Eksempel der vi ikke trenger å regne for å finne min:

$$\begin{aligned} \min \quad & (x_1 - 3)^2 + (x_2 - 2)^2 \\ & x_1 + x_2 \leq 1 \\ & x_1 \geq 0, x_2 \geq 0 \end{aligned} \quad \left. \begin{array}{l} \rightarrow \text{kvadratet av avstanden til } (3, 2) \\ \end{array} \right\}$$



å minimere kvadratet av avstanden er det samme som å
 minimere avstanden (siden $f(x) = x^2$ er voksende på $[0, \infty)$)
 $h(x) = (g(x))^2 \quad h'(x) = 2g(x)g'(x) = 0 \quad \text{når } g'(x) = 0$

$(1, 0)$ er punktet med minst ^{avstand} avstand, siden normalen fra $(3, 2)$
 ned på linjen $x_1 + x_2 = 1$ treffer linjen i $(1, 0)$.

Teorem 11.1

Anta f kont. på en lukket og begrenset delmængde C .

Da har f både maks. og min. på C , dvs. det finnes $x^{(1)}, x^{(2)} \in C$

$$\text{s.o.} \quad f(x^{(1)}) \leq f(x) \leq f(x^{(2)}) \quad \text{for alle } x \in C$$

11.2 Anvendelser

Portefølgioptimering (mått i verdi)

x_i er her andelen av aksje i av en aksjeportefølje

$$0 \leq x_i \leq 1 \quad \sum_{i=1}^n x_i = 1$$

$$\min \alpha \sum_{1 \leq i, j \leq n} C_{ij} x_i x_j - \sum_{j=1}^n \mu_j x_j$$

$$0 \leq x_i \leq 1$$

$$\sum_{i=1}^n x_i = 1$$

fra statistikk: forventning

$$\int_{-\infty}^{\infty} R_j(t) dt$$

forventet avkastning av aksje j

R_j = avkastning av aksje j , og $\mu_j = E(R_j)$

forventet avkastning av hele porteføljen:

$$E\left(\sum x_j R_j\right) = \sum_j x_j E(R_j) = \sum_j \mu_j x_j$$

Vi vil finne maks av denne

II

finne min av $-\sum_j \mu_j x_j$

For enkel modell. La oss prøve å redusere risiko ved å spre investeringene

kovarians mellom R_i og R_j er definert ved

$$C_{ij} = E\left((R_i - \mu_i)(R_j - \mu_j)\right)$$

kovarians til hele porteføljen: $\left(\sum x_i R_i, E(\sum x_i R_i) = \sum \mu_i x_i\right)$

$$E\left(\left(\sum x_i R_i - \sum x_i \mu_i\right)\left(\sum x_j R_j - \sum x_j \mu_j\right)\right) = \dots = \sum_{i,j} x_i x_j E\left((R_i - \mu_i)(R_j - \mu_j)\right)$$

= $\sum C_{ij} x_i x_j$
som er første del av objektiofunksjonen


maximum likelihood (ML)

X "kontinuerlig" random variabel, sannsynlighetstetthet $p(x; \alpha)$

Der α er en ukjent parameter.

X Gaussfordelt: $p(x; \alpha) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\alpha)^2}{2}}$

α forventning
varians 1.



Vi vil finne α ved $\hat{\alpha}$ for utgangspunktet: "utfall" x_1, \dots, x_n
sannsynligheten for disse utførelse, (gitt at de er uavhengige), er

$$\prod_{i=1}^n p(x_i; \alpha) \quad (\text{kalls likelihood-funksjonen})$$

ML finner et estimat for α ved $\hat{\alpha}$ maksimere likelihood-funksjonen.

$$\max \prod_{i=1}^n p(x_i; \alpha) \Leftrightarrow \max \ln \left(\prod_{i=1}^n p(x_i; \alpha) \right) = \max \sum_{i=1}^n \ln(p(x_i; \alpha))$$

$$\min - \sum_{i=1}^n \ln(p(x_i; \alpha))$$

Eksempel: $p(x; \alpha) = \frac{1+\alpha x}{2}$, $x \in [-1, 1]$.

objektifunksjonen blir nå $f(\alpha) = \sum_{i=1}^n \ln \left(\frac{1+\alpha x_i}{2} \right)$

$$f'(\alpha) = - \sum_{i=1}^n \frac{x_i}{(1+\alpha x_i)/2} = - \sum_{i=1}^n \frac{x_i}{1+\alpha x_i}$$

$$f''(\alpha) = \sum_{i=1}^n \frac{x_i^2}{(1+\alpha x_i)^2} \geq 0$$

11.3 Flervariabel analyse. A kvadratisk.

$$\begin{aligned}
 A \text{ pos. semidefinit} &\Leftrightarrow x^T A x \geq 0 \quad \text{alle } x \\
 &\Leftrightarrow \text{alle egenverdier} \geq 0 \\
 &\Leftrightarrow A = W^T W \text{ for en matrise } W.
 \end{aligned}$$

$$\begin{aligned}
 A \text{ pos. definit} &\Leftrightarrow x^T A x > 0 \quad \text{alle } x \neq 0 \\
 &\Leftrightarrow \text{alle egenverdier} > 0 \\
 &\Leftrightarrow A = W^T W \text{ for en } \underline{\text{invertierbar}} \text{ matrise } W
 \end{aligned}$$

Gradienten til en funksjon f i n variabler (spaltevektor)

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

Hessematrisen: $\nabla^2 f(x) = \left(\frac{\partial^2 f}{\partial x_i \partial x_j} \right)$ kont. 2. ordens part. der.
 \Downarrow
 symmetrisk

$F(x) = \begin{bmatrix} F_1(x) \\ \vdots \\ F_n(x) \end{bmatrix}$ vektorverdi funksjon med komponenter F_i

$$f'(x) = \begin{pmatrix} \frac{\partial F_1}{\partial x_1} & \dots & \frac{\partial F_1}{\partial x_n} \\ \vdots & & \vdots \\ \frac{\partial F_n}{\partial x_1} & \dots & \frac{\partial F_n}{\partial x_n} \end{pmatrix}$$

Taylorteoremer:

11.2 Førsteordens Taylor

$f: \mathbb{R}^n \rightarrow \mathbb{R}$ kont. part. der. i $B(x; r)$

For alle $h \in \mathbb{R}^n$ med $\|h\| < r$, finnes en $t \in (0, 1)$ s.a.

$$f(x+h) = f(x) + \underbrace{\nabla f(x+th)^T}_{\text{restledd}} h$$

11.3 Andreordens Taylor

$f: \mathbb{R}^n \rightarrow \mathbb{R}$ kont. part. 2. ordens der. i $B(x; r)$

For alle $h \dots$ finnes en $t \in (0, 1)$ s.a.

$$f(x+h) = f(x) + \nabla f(x)^T h + \underbrace{\frac{1}{2} h^T \nabla^2 f(x+th) h}_{\text{restledd}}$$

11.4 Andreordens Taylor, del 2

samme betingelser for f som i 11.3

Finnes funksjon $\varepsilon: \mathbb{R}^n \rightarrow \mathbb{R}$ s.a.

$$f(x+h) = f(x) + \nabla f(x)^T h + \frac{1}{2} h^T \nabla^2 f(x) h + \varepsilon(h) \|h\|^2$$

der $\varepsilon(y) \rightarrow 0$ når $y \rightarrow 0$

11.5 Førsteordens Taylor for vektorvalerte funksjoner

Anta $F: \mathbb{R}^n \rightarrow \mathbb{R}^m$ kont. deriverbar i omegn N om x . Da er

$$F(x+h) = F(x) + F'(x)h + \mathcal{O}(\|h\|)$$

Kjernerregelen: $H'(x) = F'(G(x)) G'(x)$

$\underbrace{\text{går mot } 0 \text{ som } \|h\|}_{H(x) = F(G(x))}$

Lineær konvergens av X_k til x^*

$$\|X_{k+1} - x^*\| \leq \gamma \|X_k - x^*\| \quad (\gamma < 1)$$

Superlineær konvergens hvis i tillegg

$$\frac{\|X_{k+1} - x^*\|}{\|X_k - x^*\|} = 0$$

Kvadratisk konvergens

$$\|X_{k+1} - x^*\| \leq \gamma \|X_k - x^*\|^2 \quad \gamma < 1.$$