

3 Minimointitehtävän ratkaisusta

3.1. Johdanto

Minimointitehtävä : (Malliprobleema)

$$\min_{\eta \in \mathbb{R}^M} f(\eta), \quad (M)$$

missä $f: \mathbb{R}^M \rightarrow \mathbb{R}$ on kvadraattinen funktio

$$f(\eta) = \frac{1}{2} \eta \cdot A \eta - b \cdot \eta \quad \left(= \frac{1}{2} \eta^T A \eta - b^T \eta \right),$$

missä A on harva, positiividefiniitti matriisi $(M \times M)$ ja $b \in \mathbb{R}^M$.

Suoran ratkaisun $(Ax = b)$ sijaan tarkastelemme iteratiivisia menetelmiä.

Määritelmä 3.1.1. Minimointialgoritmi malliprobleemalle

Olkoon tarkka ratkaisu (M) :lle ξ . Olkoon alkuarvo ξ^0 ; etsi approksimaatiot ξ^k , $k = 1, 2, \dots$, muotoa

$$\xi^{k+1} = \xi^k + \alpha_k d^k, \quad k = 0, 1, 2, \dots$$

missä d^k on suunta $\in \mathbb{R}^M$ ja $\alpha_k > 0$ on askelpituus.

Eri menetelmät eroavat suunnan ja askelpituiden valinnan osalta; tässä tarkastelemme gradienttimenetelmää ja (pohjustettua) konjugaattigradienttimenetelmää.

Hieman notatiota: $g: \mathbb{R}^M \rightarrow \mathbb{R}$ (sileä)

$$g' = \nabla g = \left(\frac{\partial g}{\partial \eta_1} \quad \dots \quad \frac{\partial g}{\partial \eta_M} \right)$$

$$g'' = \begin{pmatrix} \frac{\partial^2 g}{\partial^2 \eta_1} & \dots & \frac{\partial^2 g}{\partial \eta_1 \partial \eta_M} \\ \vdots & & \vdots \\ \frac{\partial^2 g}{\partial \eta_M \partial \eta_1} & \dots & \frac{\partial^2 g}{\partial^2 \eta_M} \end{pmatrix} \quad \text{on Hessian matriisi.}$$

Malliprobleman kvadraattiselle funktiolle:

$$f'(\eta) = A\eta - b$$

$$f''(\eta) = A$$

Applrimaatioille ξ^k saadaan Taylorin kaavasta

$$g(\xi^{k+1}) = g(\xi^k) + \alpha_k g'(\xi^k) \cdot d^k + \frac{\alpha_k^2}{2} d^k \cdot g''(\eta) d^k$$

Jos Hessian matriisin alkiot ovat rajoitettuja $(\eta$ vuvalla ξ^k , ξ^k in ympäristönä, saadaan

$$g(\xi^{k+1}) = g(\xi^k) + \alpha_k g'(\xi^k) \cdot d^k + \Theta(\alpha_k^2), \text{ kun } \alpha_k \rightarrow 0.$$

Havaitaan, että jos $g'(\xi^k) \cdot d^k < 0$, niin $g(\xi^{k+1}) < g(\xi^k)$, mikäli α_k on riittävän pieni.

Erityisesti, valitsemalla $d^k = -g'(\xi^k)$, $g'(\xi^k) \neq 0$, saadaan gradienttimenetelmä.

Askelpituus α_k saadaan minimoimalla: $\min_{\alpha \geq 0} g(\xi^k + \alpha d^k)$, jolloin saadaan optimaalinen askelpituus α_k .

Suoritetaan 1D-riivahaku: $\frac{d}{d\alpha} g(\xi^k + \alpha d^k) = 0$,
minä optimaaliselle α : $g'(\xi^{k+1}) \cdot d^k = 0$.

Malliproblemalle (M):

$$\begin{aligned} 0 &= f'(\xi^k + \alpha_k d^k) \cdot d^k = (A(\xi^k + \alpha_k d^k) - b) \cdot d^k \\ &= (A\xi^k - b) \cdot d^k + \alpha_k d^k \cdot A d^k \end{aligned}$$

$$\Rightarrow \alpha_k = - \frac{(A\xi^k - b) \cdot d^k}{d^k \cdot A d^k}$$

Suppenemisrauhki (tai -nopeus)

Olemme kiinnostuneita arvioimaan alkuarvauksen virheen
s.o. $\|f - f^0\|$:n pienemistä iteration edetenä.

Osoittautuu, että suppenemisnopeutta voi arvioida
matriisin häiriöalttiuden, $K(A)$, avulla. Tällöin

$$K(A) = \frac{\lambda_{\max}}{\lambda_{\min}}.$$

Tyypillisesti: Poisson: $K(A) = \mathcal{O}\left(\frac{1}{h^2}\right)$
Laplace: $K(A) = \mathcal{O}\left(\frac{1}{h^4}\right)$

Muistetaan: $\lambda_{\min} = \min_{\substack{\eta \in \mathbb{R}^M \\ \eta \neq 0}} \frac{\eta \cdot A \eta}{\|\eta\|^2}$; $\lambda_{\max}$ vastaavasti

Matriisinnormi: $|B| = \max_{\substack{\eta \in \mathbb{R}^M \\ \eta \neq 0}} \frac{\|B\eta\|}{\|\eta\|}$ (tässä $|B| = \max_j |B_j|$)

3.2. Gradienttimenetelmä

Analysoidaan suppenemistä, kun askelpituus α on vakio.

$$\begin{cases} f^{k+1} = f^k + \alpha d^k, & k=0,1,\dots \\ d^k = -f'(f^k) = -(A f^k - b) \end{cases}$$

$\alpha > 0$ ja riittävästi pieni.

Mitä riittävästi pieni tarkoittaa?

Olkoon f tarkka ratkaisu eli $Af = b$. Tällöin $f = f - \alpha(Af - b)$
joten virheelle $e^k = f - f^k$ saadaan ehto:

$$e^{k+1} = (I - \alpha A) e^k, \quad k=0,1,\dots$$

eli
$$\|e^{k+1}\| \leq \|I - \alpha A\| \|e^k\|$$

Jotta iteratio suppenisi, tarvitaan ehto

$$|I - \alpha A| \equiv \rho < 1.$$

Matritulman mukaan: $|I - \alpha A| = \max_j |1 - \alpha \lambda_j|$

Koska A on pos. def. on välttämättä $\lambda_j > 0$

$$1 - \alpha \lambda_j > -1, \quad j = 1, \dots, M.$$

α on valittava s.e. $\alpha \lambda_{\max} < 2$; valitaan $\alpha = \frac{1}{\lambda_{\max}}$, jolloin

$$|I - \alpha A| = 1 - \frac{\lambda_{\min}}{\lambda_{\max}} = 1 - \frac{1}{\kappa(A)}.$$

Virheelle: $\|e^{k+1}\| \leq \rho \|e^k\|$, $\rho = 1 - \frac{1}{\kappa(A)}$

$$\text{eli } \|e^{k+1}\| \leq \rho^k \|e^0\|.$$

Montako askelta tarvitaan?

Olkoon toleranssi $\varepsilon > 0$. Edellisen nojalla siis

$$\left(1 - \frac{1}{\kappa(A)}\right)^n \leq \varepsilon$$

$$\text{eli } -n \log\left(1 - \frac{1}{\kappa(A)}\right) \geq \log \frac{1}{\varepsilon} \quad \left(-\log(1-x) > x, x < 1\right)$$

$$\text{eli } n \geq \kappa(A) \log \frac{1}{\varepsilon}$$

Jos tyylisellä Poisson-tyyppisellä tehtävällä on $\kappa(A) = \mathcal{O}\left(\frac{1}{h^2}\right)$, on myöskin $n = \mathcal{O}\left(\frac{1}{h^2}\right)$ eli varsin suuri.

Jatketaan analyysia ominaisarvojen avulla:

$$A \psi_j = \lambda_j \psi_j, \quad j = 1, \dots, M.$$

Ominaisvektorit ψ_j muodostavat kannan, missä virheen eritys on

$$e^k = \sum_{j=1}^M e_j^k \psi_j, \quad e_j^k = e^k \cdot \psi_j$$

Komponentittain: $e_j^{k+1} = \left(1 - \frac{\lambda_j}{\lambda_{\max}}\right) e_j^k$, $j = 1, 2, \dots, M$, $\alpha = \frac{1}{\lambda_{\max}}$

Havainto: Suhteellisesti suurille λ , virheenvaimennuskerroin on suuri, kun taas pienille vaimennus on pieni (≈ 1).

Gradienttimenetelmälle on ominaista, että korkean taajuuksien virheet "hioutuvat" nopeasti, mutta matalat taajuuksien virheet hyvin hitaasti. Tätä käytetään usein hyvään ja aivan erityisesti ns. multi-grid menetelmänä.

3.3. Konjugaattigradiennimetelmä

Idea: askelpituus α_k on optimaalinen ja suunnat d^k ovat A -konjugaattija, ts. $d^i \cdot A d^j = 0$, $i \neq j$.

Määritellään sisätulo $\langle \xi, \eta \rangle = \xi \cdot A \eta$, A pos.-def, $\xi, \eta \in \mathbb{R}^M$, joten edullisena ehto on $\langle d^i, d^j \rangle = 0$, $i \neq j$.

Energianormi: $\|\eta\|_A = \langle \eta, \eta \rangle^{1/2}$, $\eta \in \mathbb{R}^M$.

Algoritmi 3.3.1.

Olkoon $f' \in \mathbb{R}^M$ annettu ja $d^0 = -r^0$. Etsi f^k ja d^k , $k=1,2,\dots$, s.e.

$$f^{k+1} = f^k + \alpha_k d^k \quad (a)$$

$$\alpha_k = - \frac{r^k \cdot d^k}{\langle d^k, d^k \rangle} \quad (b)$$

$$d^{k+1} = -r^{k+1} + \beta_k d^k \quad (c)$$

$$\beta_k = \frac{\langle r^{k+1}, d^k \rangle}{\langle d^k, d^k \rangle} \quad (d)$$

missä $r^k = f'(\xi^k) = A \xi^k - b$.

Aputuloksia

Lemma 3.3.2 $\text{span} \{d^0, d^1, \dots, d^m\} = \text{span} \{r^0, \dots, r^m\}$
 $= \text{span} \{r^0, Ar^0, \dots, A^m r^0\}$

Lemma 3.3.3 $\langle d^i, d^j \rangle = 0, \quad i \neq j.$
 $r^i \cdot r^j = 0, \quad i \neq j.$

Lemma 3.3.4 On olemassa $m \leq M$ s.e. $A \xi^m = b.$

Huomaa, että tarkassa aritmetikassa konjugaattigradienhti-menettelmaa voi ajatella suorana menetelmänä.

Analysoidaan menetelmää samoin kuin edellä gradienttimenetelmä

Kaikille $k=0,1,\dots$, pätee $\xi^k - \xi^0 = \sum_{j=0}^{k-1} \alpha_j d^j$, Lemma 3.3.3 antaa

$$\langle \xi^k, d^k \rangle = \langle \xi^0, d^k \rangle, \quad k=0,1,2,\dots$$

Tämä on hyödyllinen aputuloks, sillä koska $A\xi = b$, pätee

$$-r^k \cdot d^k = -(A\xi^k - A\xi) \cdot d^k = \langle \xi - \xi^k, d^k \rangle = \langle \xi - \xi^0, d^k \rangle$$

mistä

$$\alpha_k = \frac{\langle \xi - \xi^0, d^k \rangle}{\langle d^k, d^k \rangle}.$$

d_k -iden avulla saadaan siis identiteetti:

$$\langle \xi^k - \xi^0, d^j \rangle = \langle \xi - \xi^0, d^j \rangle, \quad j=0,1,\dots,k-1.$$

Nähdään, että $\xi^k - \xi^0$ on alkenavaruuden $W_k = \text{span} \{d^0, \dots, d^{k-1}\}$ projektiio

Vierheelle pätee siis:

$$\|\xi - \xi^k\|_A \equiv \|\xi - \xi^0 - (\xi^k - \xi^0)\|_A \leq \|\xi - \xi^0 - \eta\|_A$$

$\forall \eta \in W_k$

Lopulta, $r^0 = A\zeta^0 - A\zeta = -A(\zeta - \zeta^0)$, joten

$$W_k = \text{span} \{ r^0, Ar^0, \dots, A^{k-1}r^0 \} = \text{span} \{ A(\zeta - \zeta^0), \dots, A^k(\zeta - \zeta^0) \}$$

Lause 3.3.8

$$\|\zeta - \zeta^k\|_A \leq \|P_k(A)(\zeta - \zeta^0)\|_A \leq \max_j |p_k(\lambda_j)| \|\zeta - \zeta^0\|_A$$

p_k polynomi j - kerron $\beta_j = 1$.

$$\text{Vierenvaimennuskerron } \gamma_k = \left(\frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right)^k, \quad k = 0, 1, 2, \dots, \quad (*)$$

ja iteratioaskelten lukumääräksi annetulla toleranssilla ε :

$$n \geq \frac{1}{2} \sqrt{\kappa(A)} \log \frac{2}{\varepsilon}.$$

Poissonille siis $\kappa(A) = \Theta(\frac{1}{h^2})$ antaa askelille $n = \Theta(\frac{1}{h})$.

(*) minimoidaan $\max_{z \in [\lambda_1, \lambda_n]} |p_k(z)|$ Tšebyševin polynomien avulla

3.4. Pohjustus

Tehdään muuttujanvaihto malliprobleemassa (M):

$$\zeta = E\eta \quad \text{s.e.} \quad \eta = E^{-1}\zeta, \quad \text{jolloin alkuperäinen tehtävä saa}$$

muodon:

$$\tilde{f}(\zeta) = f(\eta) = f(E^{-1}\zeta) = \frac{1}{2} (E^{-1}\zeta)^T A (E^{-1}\zeta) - b^T E^{-1}\zeta$$

$$= \frac{1}{2} \zeta^T E^{-T} A E^{-1} \zeta - E^{-T} b^T \cdot \zeta = \frac{1}{2} \zeta^T \tilde{A} \zeta - \tilde{b}^T \cdot \zeta,$$

$$\text{missä } \tilde{A} = E^{-T} A E^{-1}, \quad \tilde{b} = E^{-T} b.$$

$$\text{Uusi tehtävä: } \min_{\zeta \in \mathbb{R}^M} \left(\frac{1}{2} \zeta^T \tilde{A} \zeta - \tilde{b}^T \cdot \zeta \right)$$

$$\text{Gradienttimenetelmä: } \zeta^{k+1} = \zeta^k - \alpha (\tilde{A} \zeta^k - \tilde{b}) \quad \text{eli}$$

$$\eta^{k+1} = \eta^k - \alpha E^{-1} E^{-T} (A \eta^k - b)$$

$$\text{Olemaan } C = E^T E : \quad \eta^{k+1} = \eta^k - \alpha C^{-1} (A \eta^k - b)$$

Edellinen versio on pohjustettu gradienttimenetelmällä ja C on pohjustin. Jokaisella askella on ratkaistava systeemi

$$C_d = A\eta^k - b.$$

Varaditaan:

- (i) $\chi(E^{-T}AE^{-L}) \ll \chi(A)$
- (ii) $C_d = e$ on helppo ratkaista

Choleskyn hajotelma $C = L^T L$ kelpaa, mutta tällöin tehtävä redusoidun suorakri ja tilantarve voi muodostua ongelmaksi. Eräs ratkaisu: Epätäydellinen Cholesky, tehdään paras mahdollinen approksimaatio rajoitetussa tilassa, esim. ilman täyttymistä.