

1 Minsta-kvadratproblem (MK-problem)

Betrakta ett ekvationssystem $\mathbf{Ax} = \mathbf{b}$, med $\mathbf{b} \in \mathbb{R}^m$, $\mathbf{x} \in \mathbb{R}^n$ och $\mathbf{A} \in \mathbb{R}^{m \times n}$. I många tillämpningar kan det vara så att $\mathbf{b} \notin \mathcal{R}(\mathbf{A})$, varvid ekvationssystemet saknar lösning. Ofta vill man då i stället bestämma en punkt $\mathbf{x} \in \mathbb{R}^n$ som "så nära som möjligt" uppfyller $\mathbf{Ax} = \mathbf{b}$. Ett naturligt mått på att \mathbf{x} "nästan" uppfyller $\mathbf{Ax} = \mathbf{b}$ är att $\|\mathbf{Ax} - \mathbf{b}\|^2 = (\mathbf{Ax} - \mathbf{b})^\top (\mathbf{Ax} - \mathbf{b})$ är "liten". Därmed leds man till följande minsta-kvadratproblem (MK-problem):

$$\text{minimera } \frac{1}{2}(\mathbf{Ax} - \mathbf{b})^\top (\mathbf{Ax} - \mathbf{b}) \text{ då } \mathbf{x} \in \mathbb{R}^n. \quad (1.1)$$

Man vill alltså minimera längden i kvadrat på "felvektorn" $\mathbf{Ax} - \mathbf{b}$. Faktorn $\frac{1}{2}$ är instoppad bara för att förenkla vissa uttryck längre fram.

1.1 Ett modellanpassningsexempel

Antag att s är en storhet som beror av variabeln t , säg $s = g(t)$ där g är en inte helt känd funktion. Antag vidare att man baserat på givna mätdata ska skatta funktionen g . Mätdata består av m stycken givna punkter $(t_1, s_1), \dots, (t_m, s_m)$, där s_i är ett uppmätt värde på s för $t = t_i$. Ett vanligt angreppssätt är då att man gör en ansats på formen

$$g(t) \approx \alpha_1 \psi_1(t) + \alpha_2 \psi_2(t) + \dots + \alpha_n \psi_n(t) = \sum_{j=1}^n \alpha_j \psi_j(t), \quad (1.2)$$

där $\psi_j(t)$ är givna "basfunktioner" medan α_j är okända koefficienter. Basfunktionerna kan exempelvis vara polynom, $\psi_j(t) = t^{j-1}$, trigonometriska funktioner, $\psi_j(t) = \sin \frac{2\pi jt}{T}$, etc. Idealt skulle man vilja välja koefficienterna α_j så att

$$\sum_{j=1}^n \alpha_j \psi_j(t_i) = s_i, \text{ för } i = 1, \dots, m, \quad (1.3)$$

men eftersom det typiskt gäller att

1. antalet mätpunkter är större än antalet koefficienter α_j , dvs $m > n$,
2. approximationen i (1.2) inte är exakt, och
3. mätningarna av s innehåller mätfel,

så kan man normalt inte lösa ekvationssystem.(1.3). Man söker då istället de värden på koefficienterna α_j som gör följande kvadratsumma så liten som möjligt:

$$\frac{1}{2} \sum_{i=1}^m \left(\sum_{j=1}^n \alpha_j \psi_j(t_i) - s_i \right)^2. \quad (1.4)$$

Genom att införa följande matris och vektorer:

$$\mathbf{A} = \begin{bmatrix} \psi_1(t_1) & \cdots & \psi_n(t_1) \\ \psi_1(t_2) & \cdots & \psi_n(t_2) \\ \vdots & & \vdots \\ \psi_1(t_m) & \cdots & \psi_n(t_m) \end{bmatrix}, \quad \mathbf{b} = \begin{pmatrix} s_1 \\ s_2 \\ \vdots \\ s_m \end{pmatrix}, \quad \mathbf{x} = \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_n \end{pmatrix}, \quad (1.5)$$

så kan ekvationssystemet (1.3) skrivas på formen $\mathbf{Ax} = \mathbf{b}$, medan problemet att minimera kvadratsumman (1.4) kan skrivas på formen (1.1) ovan.

1.2 Existens av optimala lösningar till MK-problemet

Kalla målfunktionen till MK-problemet (1.1) för f , dvs

$$f(\mathbf{x}) = \frac{1}{2}(\mathbf{Ax} - \mathbf{b})^\top(\mathbf{Ax} - \mathbf{b}) = \frac{1}{2}\mathbf{x}^\top\mathbf{A}^\top\mathbf{Ax} - \mathbf{b}^\top\mathbf{Ax} + \frac{1}{2}\mathbf{b}^\top\mathbf{b}. \quad (1.6)$$

Vi ser att f är en kvadratisk funktion med $\mathbf{H} = \mathbf{A}^\top\mathbf{A}$, $\mathbf{c} = -\mathbf{A}^\top\mathbf{b}$ och $c_0 = \frac{1}{2}\mathbf{b}^\top\mathbf{b}$.

Ett trevligt faktum är att det alltid finns minst en minimalpunkt $\hat{\mathbf{x}}$ till f . Enligt ett tidigare avsnitt har den kvadratiske funktionen f minst en minimalpunkt om \mathbf{H} är positivt semidefinit och $\mathbf{c} \in \mathcal{R}(\mathbf{H})$, vilket är uppfyllt här eftersom $\mathbf{H} = \mathbf{A}^\top\mathbf{A}$ alltid är positivt semidefinit och $\mathbf{c} = -\mathbf{A}^\top\mathbf{b} = \mathbf{A}^\top(-\mathbf{b}) \in \mathcal{R}(\mathbf{A}^\top) = \mathcal{R}(\mathbf{A}^\top\mathbf{A}) = \mathcal{R}(\mathbf{H})$.

1.3 Normalekvationerna till MK-problemet

Varje minimalpunkt \mathbf{x} till en kvadratisk funktion erhålls enligt ett tidigare avsnitt som lösning till ekvationssystemet $\mathbf{Hx} = -\mathbf{c}$, som här får utseendet

$$\mathbf{A}^\top\mathbf{Ax} = \mathbf{A}^\top\mathbf{b}. \quad (1.7)$$

Detta ekvationssystem brukar kallas *normalekvationerna* för MK-problemet (1.1).

Eftersom \mathbf{x} är en lösning till ekvationssystemet (1.7) om och endast om \mathbf{x} är en optimal lösning till MK-problemet (1.1), och vi ovan konstaterade att MK-problemet alltid har minst en optimal lösning, så betyder det att systemet (1.7) alltid har minst en lösning! Alternativt följer detta av att högerledsvektorn i systemet (1.7) faktiskt tillhör $\mathcal{R}(\mathbf{A}^\top\mathbf{A})$, eftersom $\mathcal{R}(\mathbf{A}^\top) = \mathcal{R}(\mathbf{A}^\top\mathbf{A})$.

Även om det i vissa fall finns oändligt många olika lösningar \mathbf{x} till normalekvationerna så gäller att vektorn \mathbf{Ax} är densamma för samtliga dessa lösningar. Om nämligen både $\mathbf{A}^\top\mathbf{Ax} = \mathbf{A}^\top\mathbf{b}$ och $\mathbf{A}^\top\mathbf{A}\bar{\mathbf{x}} = \mathbf{A}^\top\mathbf{b}$ så är $\mathbf{A}^\top\mathbf{A}(\hat{\mathbf{x}} - \bar{\mathbf{x}}) = \mathbf{0}$, dvs $\hat{\mathbf{x}} - \bar{\mathbf{x}} \in \mathcal{N}(\mathbf{A}^\top\mathbf{A})$.

Men eftersom $\mathcal{N}(\mathbf{A}^\top\mathbf{A}) = \mathcal{N}(\mathbf{A})$ så erhålls att $\mathbf{A}(\hat{\mathbf{x}} - \bar{\mathbf{x}}) = \mathbf{0}$, dvs $\mathbf{A}\hat{\mathbf{x}} = \mathbf{A}\bar{\mathbf{x}}$.

Omvänt gäller att om $\bar{\mathbf{x}}$ är en lösning till (1.7) och $\mathbf{A}\hat{\mathbf{x}} = \mathbf{A}\bar{\mathbf{x}}$ så gäller att även $\hat{\mathbf{x}}$ är en lösning till (1.7) eftersom $\mathbf{A}^\top\mathbf{A}\hat{\mathbf{x}} = \mathbf{A}^\top(\mathbf{A}\hat{\mathbf{x}}) = \mathbf{A}^\top(\mathbf{A}\bar{\mathbf{x}}) = \mathbf{A}^\top\mathbf{A}\bar{\mathbf{x}} = \mathbf{A}^\top\mathbf{b}$.

1.4 Geometrisk tolkning av MK-problemet och normalekvationerna

Det finns en naturlig geometrisk tolkning av MK-problemet (1.1) och tillhörande normalekvationer (1.7). Problemet (1.1) kan tolkas som att man vill bestämma den punkt i underrummet

$\mathcal{R}(\mathbf{A})$ som ligger närmast punkten $\mathbf{b} \in \mathbb{R}^m$, ty problemet kan ekvivalent skrivas

$$\begin{aligned} \text{minimera } & \frac{1}{2} \|\mathbf{y} - \mathbf{b}\|^2 \\ \text{då } & \mathbf{y} \in \mathcal{R}(\mathbf{A}). \end{aligned} \tag{1.8}$$

Normalekvationerna (1.7) kan skrivas $\mathbf{A}^\top(\mathbf{b} - \mathbf{Ax}) = \mathbf{0}$, vilket är ekvivalent med att $\mathbf{b} - \mathbf{Ax} \in \mathcal{N}(\mathbf{A}^\top)$, vilket i sin tur är ekvivalent med att $\mathbf{b} - \mathbf{Ax} \in \mathcal{R}(\mathbf{A})^\perp$.

Normalekvationerna säger alltså att "felvektorn" $\mathbf{b} - \mathbf{Ax}$ ska vara *ortogonal* mot $\mathcal{R}(\mathbf{A})$.

Den optimala punkten $\hat{\mathbf{y}} (= \mathbf{Ax})$ till problemet (1.8) bestäms alltså av att $\hat{\mathbf{y}} \in \mathcal{R}(\mathbf{A})$ och $\mathbf{b} - \hat{\mathbf{y}} \in \mathcal{R}(\mathbf{A})^\perp$, dvs av att $\mathbf{b} - \hat{\mathbf{y}}$ är ortogonal mot $\mathcal{R}(\mathbf{A})$.

Som vi såg ovan är punkten $\hat{\mathbf{y}} = \mathbf{Ax}$ unik, även om inte $\hat{\mathbf{x}}$ är det.

1.5 Specialfallet att kolonnerna i \mathbf{A} är linjärt oberoende

Om kolonnerna i matrisen \mathbf{A} är linjärt oberoende så är matrisen $\mathbf{A}^\top\mathbf{A}$ positivt definit och därmed icke-singulär. Då har normalekvationerna (1.7) en *unik* lösning $\hat{\mathbf{x}}$.

1.6 Minsta-normlösningen vid linjärt beroende kolonner i \mathbf{A}

Om \mathbf{A} har linjärt beroende kolonner så är $\mathbf{A}^\top\mathbf{A}$ positivt semidefinit men *inte* positivt definit, och då finns det oändligt många lösningar \mathbf{x} till normalekvationerna (1.7). Ett vanligt sätt att välja ut *en* av alla dessa lösningar är att ta den "kortaste", dvs den med "minst norm".

Låt $\bar{\mathbf{x}} \in \mathbb{R}^n$ vara *en* lösning till (1.7). Enligt avsnitt 1.3 ges då samtliga lösningar till normalekvationerna av lösningarna \mathbf{x} till ekvationssystemet $\mathbf{Ax} = \mathbf{Ax}$. Därmed kan problemet att bestämma minsta-normlösningen till normalekvationerna skrivas på formen

$$\begin{aligned} \text{minimera } & \frac{1}{2} \|\mathbf{x}\|^2 \\ \text{då } & \mathbf{Ax} = \mathbf{Ax}. \end{aligned} \tag{1.9}$$

Detta är ett QP-problem med likhetsbivillkor, med $\mathbf{H} = \mathbf{I}$, $\mathbf{c} = \mathbf{0}$, $\mathbf{A} = \mathbf{A}$, $\mathbf{b} = \mathbf{Ax}$.

Enligt ett tidigare avsnitt är $\hat{\mathbf{x}} \in \mathbb{R}^n$ en optimal lösning till detta problem (1.9) om och endast om $\hat{\mathbf{x}}$ utgör "x-delen" av en lösning till följande linjära ekvationssystem i \mathbf{x} och \mathbf{u} :

$$\begin{aligned} \mathbf{Ix} - \mathbf{A}^\top\mathbf{u} &= \mathbf{0} \\ \mathbf{Ax} &= \mathbf{Ax} \end{aligned} \tag{1.10}$$

De övre ekvationerna ger att $\mathbf{x} = \mathbf{A}^\top\mathbf{u}$, som insatt i de undre ekvationerna ger att

$$\mathbf{AA}^\top\mathbf{u} = \mathbf{Ax}. \tag{1.11}$$

Eftersom $\mathbf{Ax} \in \mathcal{R}(\mathbf{A}) = \mathcal{R}(\mathbf{AA}^\top)$, så har systemet (1.11) alltid minst en lösning $\hat{\mathbf{u}}$. Motsvarande $\hat{\mathbf{x}} = \mathbf{A}^\top\hat{\mathbf{u}}$ är då en optimal lösning till problemet (1.9).

Även om det i vissa fall finns oändligt många olika lösningar \mathbf{u} till systemet (1.11) så gäller att vektorn $\mathbf{A}^\top\mathbf{u}$ är densamma för samtliga dessa lösningar. Om nämligen både $\mathbf{AA}^\top\hat{\mathbf{u}} = \mathbf{Ax}$ och $\mathbf{AA}^\top\bar{\mathbf{u}} = \mathbf{Ax}$ så är $\mathbf{AA}^\top(\hat{\mathbf{u}} - \bar{\mathbf{u}}) = \mathbf{0}$, dvs $\hat{\mathbf{u}} - \bar{\mathbf{u}} \in \mathcal{N}(\mathbf{AA}^\top)$. Men eftersom $\mathcal{N}(\mathbf{AA}^\top) = \mathcal{N}(\mathbf{A}^\top)$ så erhålls att $\mathbf{A}^\top(\hat{\mathbf{u}} - \bar{\mathbf{u}}) = \mathbf{0}$, dvs $\mathbf{A}^\top\hat{\mathbf{u}} = \mathbf{A}^\top\bar{\mathbf{u}}$.

Det betyder att $\hat{\mathbf{x}} = \mathbf{A}^\top\hat{\mathbf{u}}$ är den *unika* optimala lösningen till problemet (1.9), även om lösningen $\hat{\mathbf{u}}$ till systemet (1.11) inte är unik!

1.7 Pseudoinversen till en matris

Antag att man ska bestämma MN-lösningen till ett MK-problem enligt avsnitt 1.6 ovan, och att matrisen \mathbf{A} har *singulärvärdesfaktorisering* (se Gula häftet), dvs faktoriserats på formen

$$\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^T = [\mathbf{U}_1 \quad \mathbf{U}_2] \begin{bmatrix} \mathbf{S}_1 & \mathbf{O} \\ \mathbf{O} & \mathbf{O} \end{bmatrix} \begin{bmatrix} \mathbf{V}_1^T \\ \mathbf{V}_2^T \end{bmatrix} = \mathbf{U}_1\mathbf{S}_1\mathbf{V}_1^T, \quad (1.12)$$

där såväl $n \times r$ -matrisen \mathbf{U}_1 som $m \times r$ -matrisen \mathbf{V}_1 har ortonormala kolonner, dvs $\mathbf{U}_1^T\mathbf{U}_1 = \mathbf{I}$ och $\mathbf{V}_1^T\mathbf{V}_1 = \mathbf{I}$, medan $r \times r$ -matrisen \mathbf{S}_1 är diagonal med strikt positiva diagonalelement.

Eftersom $\mathbf{A}^T = \mathbf{V}_1\mathbf{S}_1\mathbf{U}_1^T$, så blir

$$\mathbf{A}^T\mathbf{A} = \mathbf{V}_1\mathbf{S}_1^2\mathbf{V}_1^T \quad \text{och} \quad \mathbf{A}\mathbf{A}^T = \mathbf{U}_1\mathbf{S}_1^2\mathbf{U}_1^T. \quad (1.13)$$

Normalekvationerna (1.7) får då utseendet

$$\mathbf{V}_1\mathbf{S}_1^2\mathbf{V}_1^T\mathbf{x} = \mathbf{V}_1\mathbf{S}_1\mathbf{U}_1^T\mathbf{b}, \quad (1.14)$$

som är ekvivalent med ekvationssystemet

$$\mathbf{V}_1^T\mathbf{x} = \mathbf{S}_1^{-1}\mathbf{U}_1^T\mathbf{b}. \quad (1.15)$$

Om $\bar{\mathbf{x}}$ är en lösning till (1.15) så blir ekvationssystemet (1.11) nu

$$\mathbf{U}_1\mathbf{S}_1^2\mathbf{U}_1^T\mathbf{u} = \mathbf{U}_1\mathbf{S}_1\mathbf{V}_1^T\bar{\mathbf{x}}, \quad (1.16)$$

som är ekvivalent med ekvationssystemet

$$\mathbf{S}_1\mathbf{U}_1^T\mathbf{u} = \mathbf{V}_1^T\bar{\mathbf{x}}. \quad (1.17)$$

Om $\hat{\mathbf{u}}$ är en lösning till (1.17) så ges MN-lösningen till MK-problemet således av

$$\hat{\mathbf{x}} = \mathbf{A}^T\hat{\mathbf{u}} = \mathbf{V}_1\mathbf{S}_1\mathbf{U}_1^T\hat{\mathbf{u}} = \mathbf{V}_1\mathbf{V}_1^T\bar{\mathbf{x}} = \mathbf{V}_1\mathbf{S}_1^{-1}\mathbf{U}_1^T\mathbf{b} = \mathbf{A}^+\mathbf{b}, \quad (1.18)$$

där matrisen $\mathbf{A}^+ = \mathbf{V}_1\mathbf{S}_1^{-1}\mathbf{U}_1^T$ kallas för *pseudoinversen* till matrisen $\mathbf{A} = \mathbf{U}_1\mathbf{S}_1\mathbf{V}_1^T$.

1.8 Sammanfattning av resultaten i detta kapitel

MK-problemet består i att minimera $\frac{1}{2}\|\mathbf{A}\mathbf{x} - \mathbf{b}\|^2 = \frac{1}{2}(\mathbf{A}\mathbf{x} - \mathbf{b})^T(\mathbf{A}\mathbf{x} - \mathbf{b})$.

Vektorn $\hat{\mathbf{x}}$ är en optimal lösning till MK-problemet om och endast om $\hat{\mathbf{x}}$ är en lösning till *normalekvationerna* $\mathbf{A}^T\mathbf{A}\mathbf{x} = \mathbf{A}^T\mathbf{b}$ som alltid har minst en lösning.

Om kolonnerna i \mathbf{A} är linjärt oberoende så har normalekvationerna en *unik* lösning $\hat{\mathbf{x}}$.

Om kolonnerna i \mathbf{A} är linjärt beroende så har normalekvationerna oändligt många lösningar. Bland alla dessa lösningar finns det en unik vektor $\hat{\mathbf{x}}$ med minst norm (dvs kortast längd).

Denna minsta-normlösning ges av $\hat{\mathbf{x}} = \mathbf{A}^T\hat{\mathbf{u}}$, där $\hat{\mathbf{u}}$ är en lösning till systemet $\mathbf{A}\mathbf{A}^T\mathbf{u} = \mathbf{A}\bar{\mathbf{x}}$.

Här är $\bar{\mathbf{x}}$ en godtycklig lösning till normalekvationerna.