

Kompletteringar till föreläsning i Täthetsskattning. I

2nd November 2005

1 ML-skattning av väntevärdesvektor i en normalfördelning

Vi antar att vi har ett antal \mathbf{x} som är dragna oberoende från varandra från en multivariat normalfördelning med okänd väntevärdesvektor, \mathbf{m} , och inverterbar (och känd) kovariansmatris \mathbf{C} . Vi ska här se hur vi ska ta fram en bra skattning av \mathbf{m} .

Låt \mathcal{X} beteckna vår mängd med N st. exempel, dvs $\mathcal{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$. Om \mathbf{x}_n är normalfördelad $\mathbf{x} \sim N(\mathbf{m}, \mathbf{C})$ så har den täthetsfunktionen

$$p(\mathbf{x}_n|\mathbf{m}, \mathbf{C}) = \frac{1}{(2\pi)^{d/2}|\mathbf{C}|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x}_n - \mathbf{m})^T \mathbf{C}^{-1}(\mathbf{x}_n - \mathbf{m})\right) \quad (1)$$

Per definition ges ML-skattningen av

$$\hat{\mathbf{m}}_{ML} = \arg \max_{\mathbf{m}} p(\mathcal{X}|\mathbf{m}, \mathbf{C}) = \arg \max_{\mathbf{m}} p(\mathbf{x}_1, \dots, \mathbf{x}_N|\mathbf{m}, \mathbf{C}) = \arg \max_{\mathbf{m}} \prod_{n=1}^N p(\mathbf{x}_n|\mathbf{m}, \mathbf{C}) \quad (2)$$

Den sista likheten fås pga av att exemplen är oberoende. Observera att vi ser $p(\mathcal{X}|\mathbf{m}, \mathbf{C}) = p(\mathbf{x}_1, \dots, \mathbf{x}_N|\mathbf{m}, \mathbf{C})$ som en funktion av \mathbf{m} . Vektorerna $\mathbf{x}_1, \dots, \mathbf{x}_N$ är däremot fixa.

Då vi endast är intresserade av vilken vektor \mathbf{m} som maximerar $p(\mathcal{X}|\mathbf{m}, \mathbf{C})$ så kan vi lika gärna söka den vektor som minimerar negativa logaritmen samt bortse från eventuella termer som inte beror av \mathbf{m} . Efter förenkling av $-\ln p(\mathbf{x}_n|\mathbf{m}, \mathbf{C})$ får vi

$$\hat{\mathbf{m}}_{ML} = \arg \min_{\mathbf{m}} \underbrace{\frac{1}{2} \sum_{n=1}^N (\mathbf{x}_n - \mathbf{m})^T \mathbf{C}^{-1} (\mathbf{x}_n - \mathbf{m})}_{J(\mathbf{m})} \quad (3)$$

För minimat till $J(\mathbf{m})$ gäller att $\frac{\partial J}{\partial \mathbf{m}} = 0$. Vi utvecklar först J som

$$\begin{aligned} J &= \frac{1}{2} \sum_{n=1}^N (\mathbf{x}_n - \mathbf{m})^T \mathbf{C}^{-1} (\mathbf{x}_n - \mathbf{m}) = \frac{1}{2} \sum_{n=1}^N \mathbf{x}_n^T \mathbf{C}^{-1} \mathbf{x}_n - \sum_{n=1}^N \mathbf{m}^T \mathbf{C}^{-1} \mathbf{x}_n + \frac{1}{2} \sum_{n=1}^N \mathbf{m}^T \mathbf{C}^{-1} \mathbf{m} = \\ &= \frac{1}{2} \sum_{n=1}^N \mathbf{x}_n^T \mathbf{C}^{-1} \mathbf{x}_n - \mathbf{m}^T \left(\sum_{n=1}^N \mathbf{C}^{-1} \mathbf{x}_n \right) + \frac{N}{2} \mathbf{m}^T \mathbf{C}^{-1} \mathbf{m} \end{aligned} \quad (4)$$

Gradienten finner vi sen enkelt genom att utnyttja våra deriveringsregler för vektoruttryck: (Observera att vi kan skriva, mest som en hjälp för minnet, $\text{tr}(\mathbf{x}_n^T \mathbf{C}^{-1} \mathbf{m}) = \text{tr}(\mathbf{x}_n^T \mathbf{C}^{-1} \mathbf{m})$.)

$$\frac{\partial J}{\partial \mathbf{m}} = 0 - \left(\sum_{n=1}^N \mathbf{C}^{-1} \mathbf{x}_n \right) + \frac{N}{2} (\mathbf{C}^{-1} + \mathbf{C}^{-T}) \mathbf{m} = - \left(\sum_{n=1}^N \mathbf{C}^{-1} \mathbf{x}_n \right) + N \mathbf{C}^{-1} \mathbf{m} \quad (5)$$

där \mathbf{C}^{-T} betyder transponatet av inversen. Pga att \mathbf{C} är symmetrisk är även \mathbf{C}^{-1} symmetrisk och därför gäller alltså att $\mathbf{C}^{-T} = \mathbf{C}^{-1}$.

Löser vi $\frac{\partial J}{\partial \mathbf{m}} = 0$ så får vi till slut

$$\hat{\mathbf{m}}_{ML} = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n, \quad (6)$$

dvs det gamla hederliga medelvärdet. Notera f.ö. att lösningen inte beror av \mathbf{C} .

2 MAP-skattning

Om vi har en a priori-fördelning för \mathbf{m} som är Gaussisk med väntevärde \mathbf{m}_0 och kovariansmatris \mathbf{C}_m , dvs

$$p(\mathbf{m}) = \frac{1}{(2\pi)^{-d/2} |\mathbf{C}_m|^{1/2}} \exp \left(-\frac{1}{2} (\mathbf{m} - \mathbf{m}_0)^T \mathbf{C}_m^{-1} (\mathbf{m} - \mathbf{m}_0) \right) \quad (7)$$

så går det efter en stunds räknande att visa att MAP-skattningen av \mathbf{m} ges av

$$\hat{\mathbf{m}}_{MAP} = (N \mathbf{C}^{-1} + \mathbf{C}_m^{-1})^{-1} \left(\mathbf{C}^{-1} \sum_{n=1}^N \mathbf{x}_n + \mathbf{C}_0 \mathbf{m}_0 \right) \quad (8)$$

Vi kan se flera samband med ML-skattningen:

- Låt $N \rightarrow \infty$, dvs antalet exempel växer mot oändligheten. Vi kan skriva om MAP-skattningen ovan som

$$\begin{aligned} \hat{\mathbf{m}}_{MAP} &= \left(\mathbf{C}^{-1} + \frac{1}{N} \mathbf{C}_m^{-1} \right)^{-1} \left(\mathbf{C}^{-1} \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n + \frac{1}{N} \mathbf{C}_0 \mathbf{m}_0 \right) \\ &\rightarrow (\mathbf{C}^{-1})^{-1} (\mathbf{C}^{-1} \hat{\mathbf{m}}_{ML}) = \hat{\mathbf{m}}_{ML} \end{aligned} \quad (9)$$

Alltså, MAP- och ML-skattningarna är asymptotiskt identiska då antalet exempel växer mot oändligheten.

- Om \mathbf{C}_m är "stor"¹, alternativt, \mathbf{C} är "liten", så kan MAP- och ML-skattningarna vara mycket nära varandra. Tex, sätt $\mathbf{C}_m = \sigma_m^2 \mathbf{I}$, där \mathbf{I} är enhetsmatrisen och σ_m^2 är ett

¹I detta sammanhang betyder detta att matrisens egenvärden alla är stora

stort tal. Vi får då återigen

$$\begin{aligned}\hat{\mathbf{m}}_{MAP} &= \left(\mathbf{C}^{-1} + \frac{1}{N} \mathbf{C}_m^{-1} \right)^{-1} \left(\mathbf{C}^{-1} \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n + \frac{1}{N} \mathbf{C}_0 \mathbf{m}_0 \right) \\ &\rightarrow (\mathbf{C}^{-1})^{-1} \left(\mathbf{C}^{-1} \frac{1}{N} \hat{\mathbf{m}}_{ML} \right) = \hat{\mathbf{m}}_{ML}\end{aligned}\tag{10}$$