

## מערכות דינמיות ובקרה

לביא שפיגלמן

EM במערכת לינארית גאוסיאנית

- אלגוריתם EM

• מערכת Linear Gaussian

• צעד ה-M במערכת LG

• צעד ה-E במערכת GE

### אלגוריתם ה-EM

אלגוריתם ה-EM מתמודד עם הבעיה הבאה:

נתונות הצפיות  $\{y_i\}_{i=1}^T = y$ . נניח כי קיימים מצבים חביים  $\{x_i\}_{i=1}^T = x$  וכי ההסתפל-גות של  $y$  ידועה לנו עד כדי המשתנים החביים וסט פרמטרים  $\theta$ . כלומר, אנו יודעים לחשב את  $(\theta|x, y)$  ומכאן גם את ההסתפלוגיות החלקיות והmontonיות. ברצונינו למצוא שיעורן ניראות מירבית של הפרמטרים  $(\theta|x, y) = \arg \max_{\theta} p(y|\theta|x)$ . אלגוריתם ה-EM מסתפק במקסימום מקומי.

במקרה של מערכת דינמית, ניתן ובידינו הצפיות אך איננו יודעים את מצביו המערכת וברצונינו לבצע system identification (למודד מודל גנרטיבי של המערכת) כך שה-מערכת שנלמדה מסבירת את בתכויות בצורה טובה.

במקרה של מערכת לינארית עם רעשה הצפיות ומצב גאוסיאניים אנו יודעים למצוא את התפלגות המצבים בהינתן המערכת וסדרת הצפיות (ע"י Kalman Smoothing). כמו כן אנו יודעים למצוא את הפרמטרים של המודל מתוך סדרות של מצבים ותצפיות (מייפור שגיאות ריבועיות). אלגוריתם EM מבצע איטרציות של "השלמות" הנתונים החסרים,  $x$  (צעד E) ו- $\theta$  (צעד M).

---

#### Algorithm 1 EM

---

- Guess  $\theta^{(0)}$
  - at step  $k$ 
    - E step:  $\tilde{p}(x) = p(x|y, \theta^{(k-1)})$
    - M step:  $\theta^{(k)} = \arg \max_{\theta} E_{\tilde{p}(x)}[\log p(x, y|\theta)]$
-

האלגוריתם (ראה אלג. 1) פועל באופן הבא: באיתחול מנהכים סט פרמטרים  $\theta$ . לאחר מכן מבצעים איטרציות המורכבות משני שלבים. בשלב ראשון מוצאים את ההתפלגות של המשתנים החבויים בהינתן סט הפרמטרים והתציפות. בשלב שני מוצאים את סט הפרמטרים שמקסם את תוחלת לוג ההתפלגות המשותפת כשהתוחלת היא על המשתנים החבויים שמתפלגים לפי ההתפלגות שמצאנו בשלב הראשון של האיטרציה.

אנו נוכחים שהאלגוריתם מתכנס למינימום מקומי של הhursticity  $p(\mathbf{y}|\theta)$  באו-פונCTION: נגידר פונקציה  $f(\tilde{p}, \theta)$ , נראה ששלבי ה-E- $M$ -M מוצעים צעדי- $f$ : צעד ה-E-משפר ביחס ל- $\tilde{p}$  וצעד ה-M-משפר ביחס ל- $\theta$ . כמו כן נראה כי לאחר צעד E מקבלים ש  $f(\tilde{p}, \theta) = p(\mathbf{y}|\theta)$  ולכן ביצוע צעדי גודיאנט (חלקי) על  $f$  שקול למציאת מינימום מקומי של  $p(\mathbf{y}|\theta)$ .

הגדרה:

$$\begin{aligned} f(\tilde{p}, \theta) &= E_{\tilde{p}}[\log p(\mathbf{x}, \mathbf{y}|\theta)] + H(\tilde{p}) \\ H(\tilde{p}) &= - \int \tilde{p}(\mathbf{x}) \log \tilde{p}(\mathbf{x}) d\mathbf{x} \end{aligned}$$

כלומר,  $f$  היא סכום של התוחלת שמקסימים בצד ה- $M$  ושל האנטרופיה של ההתפל-גות  $\tilde{p}$ . אנו נניח כי  $p(\mathbf{x}, \mathbf{y}|\theta) > 0$  תמיד כדי שה- $\log p(\mathbf{x}, \mathbf{y}|\theta)$  יהיה מוגדר (ניתן לוותר על הנחה זו). ניתן לראות גם כי

$$f(\tilde{p}, \theta) = -D_{KL}(\tilde{p}(\mathbf{x}), p(\mathbf{x}|\mathbf{y}, \theta)) + \log p(\mathbf{y}|\theta)$$

כש-  $D_{KL}$  היא האנטרופיה היחסית. ביטוי זה, בשילולו, ידוע בשם אנרגיה חופשית (variational free energy) בפיזיקה סטטיסטית. מינימיזציה של  $f$  היא מינימיזציה של האנרגיה החופשית.

הוכחת השקילות:

$$\begin{aligned} -D_{KL}(\tilde{p}(\mathbf{x}), p(\mathbf{x}|\mathbf{y}, \theta)) + \log p(\mathbf{y}|\theta) &= - \int \tilde{p}(x) \log \frac{\tilde{p}(\mathbf{x})}{p(\mathbf{x}|\mathbf{y}, \theta)} dx + \log p(\mathbf{y}|\theta) \\ &= H(\tilde{p}) + \int \tilde{p}(x) \log p(\mathbf{x}|\mathbf{y}, \theta) dx + \log p(\mathbf{y}|\theta) \\ &= H(\tilde{p}) + \int [\tilde{p}(x) \log p(\mathbf{x}|\mathbf{y}, \theta) + \log p(\mathbf{y}|\theta)] dx \\ &= H(\tilde{p}) + \int \tilde{p}(x) \log (p(\mathbf{x}|\mathbf{y}, \theta)p(\mathbf{y}|\theta)) dx \\ &= H(\tilde{p}) + \int \tilde{p}(x) \log p(\mathbf{x}, \mathbf{y}|\theta) dx \\ &= f(\tilde{p}, \theta) \end{aligned}$$

**טענה 1:**  $\arg \max_{\tilde{p}} f(\tilde{p}, \theta) = p(\mathbf{x}|\mathbf{y}, \theta)$   
**הוכחה:** נובע מכך ש  $D_{KL}(p|q) \geq 0$  ו-  $D_{KL}(p|q) = 0$  מתקיים רק  $q = p$ . במקורה הנ"ל  $\tilde{p} = p(\mathbf{x}|\mathbf{y}, \theta)$  ו-  $p = q$ .

לכן צעד ה-E של EM שקול לביצוע  $\tilde{p} = \arg \max_{\tilde{p}'} f(\tilde{p}', \theta)$

**טענה 2:**  $\arg \max_{\theta} f(\tilde{p}, \theta) = \arg \max_{\theta} E_{\tilde{p}(\mathbf{x})} [\log p(\mathbf{x}, \mathbf{y} | \theta)]$

הוכחה: נובע מיידית לכך ש- $H(\tilde{p})$  אינו תלוי ב- $\theta$ .  
 לכן צעד ה-M של EM שකול לביצוע  $\arg \max_{\theta} f(\tilde{p}, \theta)$ .  
 עד כאן ראיינו שצעדי partial gradient ascent על  $f$  שקולים לאלגוריתם EM. יותר להראות כי המקסימה של  $f$  הם מקסימה של  $p(\mathbf{y} | \theta)$ .

**טענה 3:** לאחר שלב  $E$   $f(\tilde{p}, \theta) = \log p(\mathbf{y} | \theta)$   
 הוכחה: עפ"ג טענה 1, לאחר שלב  $E$   $f(\tilde{p}, \theta) = p(\mathbf{x} | \mathbf{y}, \theta)$  נכון  $D_{KL}$  שבഗדרה השוקלה מתאפס ונותר  $f(\tilde{p}, \theta) = \log p(\mathbf{y} | \theta)$ .  
 לשיכום צעדי EM מקטינים את האנרגיה החופשית אשר המינימום שלו מזדהים עם המקסימה של  $p(\mathbf{y} | \theta)$ .

## מערכת Linear Gaussian

נניח כי נתונים הפרמטרים של מערכת לינארית גאוסיאנית

$$\theta = \{\mathbf{A}, \mathbf{C}, \mathbf{Q}, \mathbf{R}, \bar{\mathbf{x}}_1, \mathbf{Q}_1\}$$

כך ש

$$\begin{aligned}\mathbf{x}_t &= \mathbf{A}\mathbf{x}_{t-1} + \boldsymbol{\nu} \\ \mathbf{y}_t &= \mathbf{C}\mathbf{x}_t + \boldsymbol{\omega} \\ \boldsymbol{\nu} &\sim \mathcal{N}(0, \mathbf{Q}) \\ \boldsymbol{\omega} &\sim \mathcal{N}(0, \mathbf{R})\end{aligned}$$

נזכור כי

$$\begin{aligned}p(\mathbf{y}_t | \mathbf{x}_t) &= \frac{1}{(2\pi)^{m/2} |\mathbf{R}|^{1/2}} e^{-\frac{1}{2} (\mathbf{y}_t - \mathbf{C}\mathbf{x}_t)' \mathbf{R}^{-1} (\mathbf{y}_t - \mathbf{C}\mathbf{x}_t)} \\ p(\mathbf{x}_t | \mathbf{x}_{t-1}) &= \frac{1}{(2\pi)^{n/2} |\mathbf{Q}|^{1/2}} e^{-\frac{1}{2} (\mathbf{x}_t - \mathbf{A}\mathbf{x}_{t-1})' \mathbf{Q}^{-1} (\mathbf{x}_t - \mathbf{A}\mathbf{x}_{t-1})} \\ p(\mathbf{x}_1) &= \frac{1}{(2\pi)^{n/2} |\mathbf{Q}_1|^{1/2}} e^{-\frac{1}{2} (\mathbf{x}_1 - \bar{\mathbf{x}}_1)' \mathbf{Q}_1^{-1} (\mathbf{x}_1 - \bar{\mathbf{x}}_1)}\end{aligned}$$

וכן

$$\begin{aligned}p(\mathbf{x}_{1:T}, \mathbf{y}_{1:T}) &= p(\mathbf{x}_1) \prod_{t=2}^T p(\mathbf{x}_t | \mathbf{x}_{t-1}) \prod_{t=1}^T p(\mathbf{y}_t | \mathbf{x}_t) \\ \log p(\mathbf{x}, \mathbf{y}) &= - \sum_{t=1}^T \left[ \frac{1}{2} (\mathbf{y}_t - \mathbf{C}\mathbf{x}_t)' \mathbf{R}^{-1} (\mathbf{y}_t - \mathbf{C}\mathbf{x}_t) \right] - \frac{T}{2} \log |\mathbf{R}|\end{aligned}$$

$$\begin{aligned}
& - \sum_{t=1}^T \left[ \frac{1}{2} (\mathbf{x}_t - \mathbf{Ax}_{t-1})' \mathbf{Q}^{-1} (\mathbf{x}_t - \mathbf{Ax}_{t-1}) \right] - \frac{T-1}{2} \log |\mathbf{Q}| \\
& - \frac{1}{2} (\mathbf{x}_1 - \bar{\mathbf{x}}_1)' \mathbf{Q}_1 (\mathbf{x}_1 - \bar{\mathbf{x}}_1) - \frac{1}{2} \log |\mathbf{Q}_1| - \frac{T(m+n)}{2} \log 2\pi
\end{aligned}$$

נסמן

$$q = E_{\tilde{p}(\mathbf{x})} \log p(\mathbf{x}, \mathbf{y} | \theta)$$

## צעד ה-M

בצעד זה (ובשלב  $k$ ) אנו נדרשים למצוא

$$\arg \max_{\theta} E_{\tilde{p}(\mathbf{x})} [\log p(\mathbf{x}, \mathbf{y} | \theta)]$$

כש

$$\tilde{p}(x) = p(\mathbf{x} | \mathbf{y}, \theta^{(k-1)})$$

נעsha זאת ע"י מציאת הנגירות והשווואן לאפס.

ראשית נשים לב כי ניתן לבצע את הניגורת לפני ליקחת התוחלת

$$\frac{\partial}{\partial \theta} E_{\tilde{p}(\mathbf{x})} [\log p(\mathbf{x}, \mathbf{y} | \theta)] = E_{\tilde{p}(\mathbf{x})} \left[ \frac{\partial}{\partial \theta} \log p(\mathbf{x}, \mathbf{y} | \theta) \right]$$

ונסמן

$$\begin{aligned}
\hat{\mathbf{x}}_t &= E_{\tilde{p}}[\mathbf{x}_t] \\
\mathbf{P}_t &= E_{\tilde{p}}[\mathbf{x}_t \mathbf{x}'_t] = cov(\mathbf{x}_t, \mathbf{x}_t) + \hat{\mathbf{x}}_t \hat{\mathbf{x}}'_t \\
\mathbf{P}_{t,t-1} &= E_{\tilde{p}}[\mathbf{x}_t \mathbf{x}'_{t-1}] = cov(\mathbf{x}_t, \mathbf{x}_{t-1}) + \hat{\mathbf{x}}_t \hat{\mathbf{x}}'_{t-1}
\end{aligned}$$

: $\mathbf{C}$  עברו

$$\begin{aligned}
\frac{\partial q}{\partial \mathbf{C}} &= E_{\tilde{p}(\mathbf{x})} \left[ - \sum_{t=1}^T \mathbf{R}^{-1} \mathbf{y}_t \mathbf{x}'_t + \sum_{t=1}^T \mathbf{R}^{-1} \mathbf{C} \mathbf{x}_t \mathbf{x}'_t \right] \\
&= - \sum_{t=1}^T \mathbf{R}^{-1} \mathbf{y}_t E_{\tilde{p}(\mathbf{x})} [\mathbf{x}'_t] + \sum_{t=1}^T \mathbf{R}^{-1} \mathbf{C} E_{\tilde{p}(\mathbf{x})} [\mathbf{x}_t \mathbf{x}'_t] \\
&= -\mathbf{R}^{-1} \sum_{t=1}^T \mathbf{y}_t \hat{\mathbf{x}}_t + \mathbf{R}^{-1} \mathbf{C} \sum_{t=1}^T \mathbf{P}_t = 0 \\
\mathbf{C} &= \left( \sum_{t=1}^T \mathbf{y}_t \hat{\mathbf{x}}'_t \right) \left( \sum_{t=1}^T \mathbf{P}_t \right)^{-1}
\end{aligned}$$

: $\mathbf{A}$  עבורה

$$\begin{aligned}\frac{\partial q}{\partial \mathbf{A}} &= E_{\tilde{p}(\mathbf{x})} \left[ -\sum_{t=2}^T \mathbf{Q}^{-1} \mathbf{x}_t \mathbf{x}'_{t-1} + \sum_{t=2}^T \mathbf{Q}^{-1} \mathbf{A} \mathbf{x}_{t-1} \mathbf{x}'_{t-1} \right] \\ &= -\mathbf{Q}^{-1} \sum_{t=2}^T \mathbf{P}_{t,t-1} + \mathbf{Q}^{-1} \mathbf{A} \sum_{t=2}^T \mathbf{P}_{t-1} \\ \mathbf{A} &= \left( \sum_{t=2}^T \mathbf{P}_{t,t-1} \right) \left( \sum_{t=2}^T \mathbf{P}_{t-1} \right)^{-1}\end{aligned}$$

: $\mathbf{R}$  עבורה

$$\begin{aligned}\frac{\partial q}{\partial \mathbf{R}^{-1}} &= E_{\tilde{p}(\mathbf{x})} \left[ \frac{T}{2} \mathbf{R} - \sum_{t=1}^T \left( \frac{1}{2} \mathbf{y}_t \mathbf{y}'_t - \mathbf{C} \mathbf{x}_t \mathbf{y}'_t + \frac{1}{2} \mathbf{C} \mathbf{x}_t \mathbf{x}'_t \mathbf{C} \right) \right] \\ &= \frac{T}{2} \mathbf{R} - \sum_{t=1}^T \left( \frac{1}{2} \mathbf{y}_t \mathbf{y}'_t - \mathbf{C} \hat{\mathbf{x}}_t \mathbf{y}'_t + \frac{1}{2} \mathbf{C} \mathbf{P}_t \mathbf{C}' \right) \\ &= \frac{T}{2} \mathbf{R} - \frac{1}{2} \sum_{t=1}^T (\mathbf{y}_t \mathbf{y}'_t) - \mathbf{C} \sum_{t=1}^T \hat{\mathbf{x}}_t \mathbf{y}'_t + \frac{1}{2} \left( \sum_{t=1}^T \mathbf{y}_t \hat{\mathbf{x}}'_t \right) \left( \sum_{t=1}^T \mathbf{P}_t \right)^{-1} \left( \sum_{t=1}^T \mathbf{P}_t \right) \mathbf{C}' \\ &= \frac{T}{2} \mathbf{R} - \frac{1}{2} \sum_{t=1}^T (\mathbf{y}_t \mathbf{y}'_t) - \mathbf{C} \sum_{t=1}^T \hat{\mathbf{x}}_t \mathbf{y}'_t + \frac{1}{2} \mathbf{C} \left( \sum_{t=1}^T \hat{\mathbf{x}}_t \mathbf{y}'_t \right) \\ &= \frac{T}{2} \mathbf{R} - \frac{1}{2} \sum_{t=1}^T (\mathbf{y}_t \mathbf{y}'_t) - \frac{1}{2} \mathbf{C} \left( \sum_{t=1}^T \hat{\mathbf{x}}_t \mathbf{y}'_t \right) = 0 \\ \mathbf{R} &= \frac{1}{T} \sum_{t=1}^T \mathbf{y}_t \mathbf{y}'_t - \frac{\mathbf{C}}{T} \sum_{t=1}^T \hat{\mathbf{x}}_t \mathbf{y}'_t\end{aligned}$$

: $\mathbf{Q}$  עבורה

$$\begin{aligned}\frac{\partial q}{\partial \mathbf{Q}^{-1}} &= E_{\tilde{p}(\mathbf{x})} \left[ \frac{T-1}{2} \mathbf{Q} - \frac{1}{2} \sum_{t=2}^T (\mathbf{x}_t \mathbf{x}'_t - \mathbf{A} \mathbf{x}_{t-1} \mathbf{x}'_t - \mathbf{x}_t \mathbf{x}'_{t-1} \mathbf{A}' + \mathbf{A} \mathbf{x}_{t-1} \mathbf{x}'_{t-1} A) \right] \\ &= \frac{T-1}{2} \mathbf{Q} - \frac{1}{2} \sum_{t=2}^T (\mathbf{P}_t - \mathbf{A} \mathbf{P}_{t-1,t} - \mathbf{P}_{t,t-1} \mathbf{A}' + \mathbf{A} \mathbf{P}'_{t-1,t} A) \\ &= \frac{T-1}{2} \mathbf{Q} - \frac{1}{2} \left( \sum_{t=2}^T \mathbf{P}_t - \mathbf{A} \sum_{t=2}^T \mathbf{P}_{t-1,t} \right) \\ \mathbf{Q} &= \frac{1}{T-1} \left( \sum_{t=2}^T \mathbf{P}_t - \mathbf{A} \sum_{t=2}^T \mathbf{P}_{t-1,t} \right)\end{aligned}$$

: $\bar{\mathbf{x}}_1$  עבורה

$$\frac{\partial q}{\partial \mathbf{x}_1} = (\hat{\mathbf{x}}_1 - \bar{\mathbf{x}}_1) \mathbf{Q}_1^{-1}$$

$$\bar{\mathbf{x}}_1 = \hat{\mathbf{x}}_1$$

מעבר:  $\mathbf{Q}_1$

$$\begin{aligned}\frac{\partial q}{\partial \mathbf{Q}_1^{-1}} &= \frac{1}{2} \mathbf{Q}_1 - \frac{1}{2} (\mathbf{P}_1 - \bar{\mathbf{x}}_1 \hat{\mathbf{x}}'_1 - \hat{\mathbf{x}}_1 \bar{\mathbf{x}}'_1 + \hat{\mathbf{x}}_1 \hat{\mathbf{x}}'_1) \\ \mathbf{Q}_1 &= \mathbf{P}_1 - \hat{\mathbf{x}}_1 \hat{\mathbf{x}}'_1 = cov(\mathbf{x}_1, \mathbf{x}_1)\end{aligned}$$

## E-ה-צעד

$$\begin{aligned}p(\mathbf{x}_t | \mathbf{y}_{1:t}) &\sim \mathcal{N}(\bar{\mathbf{x}}_t, \Sigma_{t|t}) \\ \text{נסמן ב } \Sigma_{t|t} &= var(\mathbf{x}_t | \mathbf{y}_{1:t})\end{aligned}$$

$$\begin{aligned}\bar{\mathbf{x}}_{t|t-1} &= \mathbf{A} \bar{\mathbf{x}}_t \\ \Sigma_{t|t-1} &= \mathbf{A} \Sigma_{t-1|t-1} \mathbf{A}^T + \mathbf{Q} \\ \mathbf{K}_t &= \Sigma_{t|t-1} \mathbf{C}^T (\mathbf{C} \Sigma_{t|t-1} \mathbf{C}^T + \mathbf{R})^{-1} \\ \bar{\mathbf{x}}_t &= \bar{\mathbf{x}}_{t|t-1} + \mathbf{K}_t (\mathbf{y}_t - \mathbf{C} \bar{\mathbf{x}}_{t|t-1}) \\ \Sigma_{t|t} &= (I - \mathbf{K}_t \mathbf{C}) \Sigma_{t|t-1}\end{aligned}$$

כש  $\bar{\mathbf{x}}_1$  ו  $\mathbf{Q}_1$  נתונים כפרמטרים של המודל.

$$\Sigma_{s|T} = var(\mathbf{x}_s | \mathbf{y}_{1:T})$$

על מנת למצוא את  $p(\mathbf{x}_t | \mathbf{y}_{1:T}) \sim \mathcal{N}(\hat{\mathbf{x}}_t, \Sigma_{t|T})$  (backward pass)

$$\begin{aligned}\mathbf{J}_{t-1} &= \Sigma_{t-1|t-1} \mathbf{A}' (\Sigma_{t|t-1})^{-1} \\ \hat{\mathbf{x}}_{t-1} &= \bar{\mathbf{x}}_{t-1} + \mathbf{J}_{t-1} (\hat{\mathbf{x}}_t - \mathbf{A} \bar{\mathbf{x}}_{t-1})\end{aligned}$$

וכן

$$\Sigma_{t-1|T} = \Sigma_{t-1|t-1} + \mathbf{J}_{t-1} (\Sigma_{t|T} - \Sigma_{t|t-1}) \mathbf{J}'_{t-1}$$

כשותנאי ההתחלה:  $\Sigma_{T|T} = \bar{\mathbf{x}}_T$  זה שתמקבל ממבחן קלמן

לצורך צעד ה- $M$  נעזר גם ב

$$\begin{aligned}\mathbf{P}_t &= \Sigma_{t|T} + \hat{\mathbf{x}}_t \hat{\mathbf{x}}'_t \\ \mathbf{P}_{t,t-1} &= \Sigma_{t,t-1|T} + \hat{\mathbf{x}}_t \hat{\mathbf{x}}'_{t-1}\end{aligned}$$

כש מקיים את נוסחת הנסיגת הבאה:

$$\begin{aligned}\Sigma_{t-1,t-2|T} &= \Sigma_{t-1|t-1} \mathbf{J}'_{t-2} + \mathbf{J}_{t-1} (\Sigma_{t,t-1|T} - \mathbf{A} \Sigma_{t-1|t-1}) \mathbf{J}'_{t-1} \\ \Sigma_{T,T-1|T} &= (I - \mathbf{K}_T \mathbf{C}) \mathbf{A} \Sigma_{T-1|T-1}\end{aligned}$$