



پاسه تعالی

## تئوری تخمین و فیلترهای بهینه

### Lecture 5

#### تخمین بازگشتی و فیلتر کالمن

#### مقدمه

- در فصل قبل فیلتر وینر و طراحی آن در سه نوع ارائه گردید.

- FIR Wiener filter
- Non-Causal Wiener filter
- Causal Wiener filter

که هر یک مشکلات خاص خود را دارند و در عمل امکان استفاده از فیلتر FIR بیشتر از سایرین وجود خواهد داشت. ولیکن مشکل فیلتر نیز این است که در هر مرحله تعداد محدودی از مشاهدات را در تخمین به کار می گیرد و این امر موجب می گردد که بخشی از داده ها به مرور زمان در تخمین بی تاثیر می گرددند. به عبارت دیگر مشاهدات پیشین حذف می گردند.

## مقدمه

- لذا اگر بتوان روشی را ارائه نمود که مشاهدات قبلی را در تخمین بکار گیرد امکان تخمین بهتر فراهم می گردد.
- دو ایده عمده را می توان در این خصوص ارائه نمود:
  - حل معادلات فیلتر وینر با اضافه شدن مشاهدات که نیاز حجم حافظه زیاد و محاسبات پیچیده دارد.
  - ارائه یک فرم بازگشتی که امکان به روز شدن تخمین در حین اضافه شدن اطلاعات را داشته باشد.

Estimation Theory  
by Dr B. Moaveni

3

## مقدمه

### LMMSE Estimation

- معادلات یک فیلتر LMMSE نامتغیر با زمان:
$$\hat{s}(n) = \sum_{i=0}^{n-1} h(i)z(n-i), \quad (5.1)$$
و در صورتیکه در مساله تخمین نیاز به تخمینگرهایی باشد که نسبت به زمان متغیرند، لذا می توان معادله (5.1) را به صورت معادله (5.2) بازنویسی نمود:
$$\hat{s}(n) = \sum_{i=0}^{n-1} h_{\text{r}}(i)z(n-i), \quad (5.2)$$
که حل آن با استفاده از قاعده MSE منجر به معادله Wiener-Hopf متغیر با زمانی به صورت زیر می شود:

$$\sum_{j=0}^n h_n(j)R_z(n-i, n-j) = R_{zz}(n, n-i), \quad 0 \leq i \leq n \quad (5.3)$$

Estimation Theory  
by Dr B. Moaveni

4

## مقدمه

### LMMSE Estimation

- استفاده از معادله (۵.۳) در مساله تخمین به صورت زیر امکان پذیر خواهد بود:

$$\sum_{j=0}^n h_n(j) R_z(n-i, n-j) = R_{sz}(n, n-i), \quad 0 \leq i \leq n \quad (5.3)$$

در هر زمان  $n$ , معادله (۵.۳) شامل  $n$  معادله خطی است که لازم است برای محاسبه  $n$  ضرایب ثابت فیلتر حل شوند.

$$\{h_n(i) : 0 \leq i \leq n-1\}$$

با استفاده از ضرایب حاصل معادله (۵.۲):

$$\{z(i) : 1 \leq i \leq n\} \xrightarrow{\text{Causal Wiener Filter}} \hat{s}(n)$$

## مقدمه

### LMMSE Estimation

- پر واضح است که در این فیلتر لازم است تمامی مشاهدات ذخیره گردند، لازم است تمامی ضرایب ذخیره گردند و همچنین لازم است  $n$  معادله خطی حل گردند که در صورتی که  $n$  بزرگ باشد این مشکل مضاعف می گردد. در نتیجه پیاده سازی این فیلتر نیازمند حافظه زیادی است (به این دسته از فیلترها، فیلتر *growing-Memory LMMSE* می گویند) و امکان پیاده سازی واقعی ندارد.

## مقدمه

### Estimation based on a State model

- **ML estimators:**  $f_z(z | s = s)$
- **MAP estimators:**  $f_s(s | z = z)$

اگر اطلاعات کافی در خصوص تولید سیگنال  $s(n)$  وجود داشته باشد  
امکان محاسبه  $f_s(s | z = z)$  و  $f_z(z | s = s)$  وجود دارد و در  
نتیجه امکان استفاده از تخمین های **MAP** و **ML** نیز وجود دارد.  
– اگر سیگنال  $s(n)$  را بتوان به صورت یک مدل فضای حالت بیان نمود:

$$x(n+1) = \Phi x(n) + \omega(n)$$

$$s(n) = Cx(n),$$

## مقدمه

### Estimation based on a State model

- **ML estimators:**  $f_z(z | s = s)$
- **MAP estimators:**  $f_s(s | z = z)$

اگر اطلاعات کافی در خصوص تولید سیگنال  $s(n)$  وجود داشته باشد  
امکان محاسبه  $f_s(s | z = z)$  و  $f_z(z | s = s)$  وجود دارد و در  
نتیجه امکان استفاده از تخمین های **MAP** و **ML** نیز وجود دارد.

اگر سیگنال  $s(n)$  را بتوان به صورت یک مدل فضای حالت بیان نمود:

$$x(n+1)_{N \times 1} = \Phi_{N \times N} x(n) + \omega(n)_{N \times 1}$$

$$s(n) = C_{1 \times N} x(n)$$

$$z(n) = s(n) + v(n)$$

## مقدمه

### Estimation based on a State model

- مساله جدید تخمین متغیر حالت  $x(n)$  است که با استفاده از آن امکان تخمین سیگنال  $s(n)$  به سادگی وجود دارد که فرم کلی آن به صورت زیر است:

$$\hat{x}(n) = \alpha_n(\hat{x}(0), \hat{P}(0), Z_n) \quad (5.4)$$

where,

$\hat{x}(0)$  = a guess of  $E[x(0)]$

$\hat{P}(0)$  = a guess of  $\text{Cov}[x(0)]$

$$Z_n = \begin{bmatrix} z(1) \\ z(2) \\ \vdots \\ z(n) \end{bmatrix}$$

- لذا هدف یافتن تخمین  $\hat{x}(n)$  است که یک ضابطه را بهینه می نماید.

Estimation Theory  
by Dr B. Moaveni

9

## مقدمه

### ML Estimation

$$\text{For simplicity: } \omega(n) = 0 \Rightarrow \begin{cases} x(n+1) = \Phi x(n) & (5.5) \\ s(n) = Cx(n) & (5.6) \end{cases}$$

با فرض معکوس پذیر بودن ماتریس  $\Phi$

$$x(n) = \Phi^{-1}x(n+1) \quad \text{and} \quad x(n-1) = \Phi^{-1}x(n) \quad (5.7)$$

$$\Rightarrow z(i) = s(i) + v(i) = C\Phi^{-n+i}x(n) + v(i), \quad i=1,2,\dots,n.$$

$$\Rightarrow Z_n = \begin{bmatrix} z(1) \\ z(2) \\ \vdots \\ z(n) \end{bmatrix} = \begin{bmatrix} C\Phi^{-n+1} \\ C\Phi^{-n+2} \\ \vdots \\ C \end{bmatrix} x(n) + \begin{bmatrix} v(1) \\ v(2) \\ \vdots \\ v(n) \end{bmatrix}, \quad \Rightarrow z_n = U_n x(n) + V_n,$$

Estimation Theory  
by Dr B. Moaveni

10

## مقدمه

### ML Estimation

در صورتیکه  $v(n)$  نویز سفید گوسی با میانگین صفر باشد در نتیجه:

$$f_{v_n}(V_n) = \frac{1}{(2\pi)^{n/2} |R_n|^{1/2}} \exp\left(-\frac{1}{2} V_n^T R_n^{-1} V_n\right), \quad (5.8)$$

$$R_n = Cov(V_n) \quad \text{که در آن}$$

$$\begin{aligned} f_{z_n}(Z_n | x(n) = x) &= f_{v_n}(V_n) \Big|_{v_n = z_n - U_n x} = \\ &= \frac{1}{(2\pi)^{n/2} |R_n|^{1/2}} \exp\left[-\frac{1}{2} (Z_n - U_n x)^T R_n^{-1} (Z_n - U_n x)\right] \end{aligned} \quad (5.9)$$

$$\max f_{z_n}(Z_n | x(n) = x) \Rightarrow \min \left[ (Z_n - U_n x)^T R_n^{-1} (Z_n - U_n x) \right]$$

$$\xrightarrow{\text{Least Square}} \hat{x}_{ML}(n) = [U_n^T R_n^{-1} U_n]^{-1} U_n^T R_n^{-1} Z_n. \quad (5.10)$$

Estimation Theory  
by Dr B. Moaveni

11

## مقدمه

### ML Estimation

همانگونه که از رابطه (5.10) مشخص است تخمین ML نیازمند اطلاعات زیادی از مشاهدات است.

Estimation Theory  
by Dr B. Moaveni

12

## مقدمه

### MAP Estimation

Similar to ML estimator:  $\omega(n) = 0 \Rightarrow \begin{cases} x(n+1) = \Phi x(n) \\ s(n) = Cx(n) \end{cases}$

$$\Rightarrow z(i) = s(i) + v(i) \quad i=1,2,\dots,n.$$

$$f_{v_n}(V_n) = \frac{1}{(2\pi)^{n/2} |R_n|^{1/2}} \exp\left(-\frac{1}{2} V_n^T R_n^{-1} V_n\right), \quad (5.8)$$

با توجه به ویژگی فیلتر MAP که نیازمند اطلاعاتی از سیگنال است، برای حالت ها فرض توزیع گوسی با میانگین  $\bar{x}(n)$  و کوواریانس  $P(n)$  در نظر گرفته می شود.

$$f_{x(n)}(x) = \frac{1}{(2\pi)^{n/2} |P(n)|^{1/2}} \exp\left[-\frac{1}{2} (x - \bar{x}(n))^T P^{-1}(n) (x - \bar{x}(n))\right] \quad (5.11)$$

Estimation Theory  
by Dr B. Moaveni

13

## مقدمه

### MAP Estimation

با توجه به آنچه پیش از این در مورد تخمین MAP گفته شده است:

$$\begin{aligned} f_{x(n)}(x | Z_n = Z_n) &= \frac{f_{Z_n}(Z_n | x(n) = x) f_{x(n)}(x)}{f_{Z_n}(Z_n)} \\ \Rightarrow f_{z_n}(Z_n | x(n) = x) f_{x(n)}(x) &= \frac{1}{(2\pi)^n |R_n|^{1/2} |p(n)|^{1/2}} \exp\left[-\frac{1}{2} (Z_n - U_n x)^T R_n^{-1} (Z_n - U_n x)\right. \\ &\quad \left.-\frac{1}{2} (x - \bar{x}(n))^T p^{-1}(n) (x - \bar{x}(n))\right] \end{aligned}$$

که برای ماکزیمم نمودن آن لازم است عبارت زیر می نیمم باشد:

$$\Psi = (Z_n - U_n x)^T R_n^{-1} (Z_n - U_n x) + (x - \bar{x}(n))^T p^{-1}(n) (x - \bar{x}(n))$$

Estimation Theory  
by Dr B. Moaveni

14

## مقدمه

### MAP Estimation

با مشتقگيري از  $\Psi$  نسبت به  $x$ :

$$-2U_n^T R_n^{-1} Z_n + 2U_n^T R_n^{-1} U_n x - 2P^{-1}(n) \bar{x}(n) + 2P^{-1}(n)x = 0$$

$$\Rightarrow \hat{x}_{MAP}(n) = [U_n^T R_n^{-1} U_n + P^{-1}(n)]^{-1} [P^{-1}(n) \bar{x}(n) + U_n^T R_n^{-1} Z_n] \quad (5.12)$$

لازم به ذكر است که ماتریس  $U_n^T R_n^{-1} U_n + P^{-1}(n)$  همواره معکوس پذیر است چرا که  $P^{-1}(n) > 0$ .

$$\bar{x}(n) = \Phi^n \bar{x}(0) \quad (5.13)$$

$$P(n) = \Phi^n P(0) (\Phi^T)^n \quad (5.14)$$

همچنین:

15

Estimation Theory  
by Dr B. Moaveni

## مقدمه

### MAP Estimation

لذا

$$\hat{x}_{MAP}(n) = \left[ U_n^T R_n^{-1} U_n + \Phi^n P^{-1}(0) (\Phi^T)^n \right]^{-1} \times \left[ (\Phi^T)^{-n} P^{-1}(0) \bar{x}(0) + U_n^T R_n^{-1} Z_n \right] \quad (5.15)$$

پر واضح است که تخمین MAP نیز به تمامی مشاهدات گذشته نیاز دارد.

16

Estimation Theory  
by Dr B. Moaveni

## تخمین یک سیگنال ثابت

در این بخش به تخمین یک سیگنال ثابت با استفاده از تخمین بازگشته خواهیم پرداخت که مساله growing-Memory در آن حل شده است.

$$s(n) = s$$

لذا تخمین LMMSE با استفاده از مشاهدات  $z(1), z(2), \dots, z(n)$  عبارت است از:

$$\hat{s}(n) = \sum_{i=0}^{n-1} h_n(i) z(n-i)$$

$$MSE = E \left[ \left( s(n) - \sum_{i=0}^{n-1} h_n(i) z(n-i) \right)^2 \right].$$

## تخمین یک سیگنال ثابت

فرض کنید

$$E[s^2] = P > 0,$$

$$R_s(i-j) = E[s(i)s(j)] = E[s^2] = P, \quad \forall i, j \in \mathbb{Z}.$$

که مقدار واقعی  $P$  نامشخص است. همچنین

$$z(n) = s(n) + v(n) = s + v(n)$$

$s(n)$  &  $v(n)$ : JWSS

$v(n)$ : white noise with known variance  $\sigma_v^2$

$$R_v(i-j) = E[v(i)v(j)] = \sigma_v^2 \delta(i-j),$$

$$\Rightarrow R_z(i-j) = R_s(i-j) + R_v(i-j) = P + \sigma_v^2 \delta(i-j).$$

## تخمین یک سیگنال ثابت

به منظور محاسبه ضرایب فیلتر:

$$\frac{\partial MSE}{\partial h_n(i)} = -2E[s(n)z(n-i)] + 2 \sum_{j=0}^{n-1} h_n(j)E[z(n-i)z(n-j)] = 0$$

در نتیجه:

$$\sum_{j=0}^{n-1} h_n(j)R_z(j-i) = R_{sz}(i) = R_s(i) = P, \quad i=0,1,\dots,n-1.$$

که در فرم ماتریسی:

$$\begin{bmatrix} P + \sigma_v^2 & P & \dots & P \\ P & P + \sigma_v^2 & \dots & P \\ \vdots & \vdots & \ddots & \vdots \\ P & P & \dots & P + \sigma_v^2 \end{bmatrix} \begin{bmatrix} h_n(0) \\ h_n(1) \\ \vdots \\ h_n(n-1) \end{bmatrix} = \begin{bmatrix} P \\ P \\ \vdots \\ P \end{bmatrix}$$

Estimation Theory  
by Dr B. Moaveni

19

## تخمین یک سیگنال ثابت

با توجه به متقارن بودن ماتریس ضرایب و شکل معادله:

$$h_n(0) = h_n(1) = \dots = h_n(n-1) = \textcolor{blue}{h}_n \quad (5.16)$$

$$= \frac{P}{nP + \sigma_v^2} = \frac{1}{n + \sigma_v^2 / P} \quad . \quad (5.17)$$

لذا:

$$\hat{s}(n) = \sum_{i=0}^{n-1} h_n z(n-i) = \textcolor{blue}{h}_n \sum_{i=0}^{n-1} z(n-i) \quad (5.18)$$

معادله (5.18) نشان می دهد که با افزایش  $n$  (  $n \rightarrow \infty$  ), حافظه مورد نیاز به سمت بی نهایت میل خواهد نمود.

Estimation Theory  
by Dr B. Moaveni

20

## تخمین یک سیگنال ثابت

$$\hat{s}(n+1) = h_{n+1} \sum_{i=0}^n z(n+1-i), \quad (5.19)$$

از معادله (5.18) داریم:

$$h_{n+1} = \frac{P}{(n+1)P + \sigma_v^2} = \frac{1}{n+1 + \sigma_v^2 / P} \quad (5.20)$$

که

اگر  $j = i - 1$  باشد رابطه (5.19) را می توان به صورت زیر بازنویسی نمود:

$$\hat{s}(n+1) = h_{n+1} \sum_{j=-1}^{n-1} z(n-j) = h_{n+1} z(n+1) + h_{n+1} \sum_{j=0}^{n-1} z(n-j) \quad (5.21)$$

از مقایسه رابطه (5.18) و (5.21) خواهیم داشت:

$$\hat{s}(n+1) = \frac{h_{n+1}}{h_n} \hat{s}(n) + h_{n+1} z(n+1). \quad (5.22)$$

Estimation Theory  
by Dr B. Moaveni

21

## تخمین یک سیگنال ثابت

رابطه (5.22) نشان می دهد که در تخمین  $\hat{s}(n+1)$  به مقدار آخرین تخمین و آخرین مشاهده نیاز است و دیگری نیازی به ذخیره سازی اطلاعات نیست. به عبارت دیگر رابطه (5.22) یک تخمین بازگشتی را در اختیار می گذارد.

حال می توان سعی کرد ضرایب فیلتر را نیز به صورت برگشتی محاسبه نمود

$$\left. \begin{aligned} h_n &= \frac{P}{nP + \sigma_v^2} = \frac{1}{n + \sigma_v^2 / P} \\ h_{n+1} &= \frac{P}{(n+1)P + \sigma_v^2} = \frac{1}{n+1 + \sigma_v^2 / P} \end{aligned} \right\} \Rightarrow \frac{h_{n+1}}{h_n} = \frac{n + \sigma_v^2 / P}{n+1 + \sigma_v^2 / P} = 1 - h_{n+1} \quad (5.17) \quad (5.20)$$

Estimation Theory  
by Dr B. Moaveni

22

## تخمین یک سیگنال ثابت

در نتیجه:

$$h_{n+1} = \frac{h_n}{1+h_n} = h_n (1+h_n)^{-1} \quad (5.24)$$

و با استفاده از آن می توان رابطه (۵.۲۲) را به صورت زیر بازنویسی نمود:

$$\hat{s}(n+1) = \hat{s}(n) + h_{n+1} [z(n+1) - \hat{s}(n)] \quad (5.25)$$

*filter gain*

:MSE محاسبه

محاسبه MSE با توجه به تغییر سیگنال تخمینی  $\hat{s}(n)$  ، لازم است به  $MSE(n)$  ازای هر بار تخمین مجددا محاسبه گردد. لذا داریم:

23

Estimation Theory  
by Dr B. Moaveni

## تخمین یک سیگنال ثابت

$$\begin{aligned} MSE(n) &= E[(s - \hat{s}(n))^2] \\ &= E[s^2] - 2E[s\hat{s}(n)] + E[\hat{s}^2(n)] \quad (5.26) \\ &= P - 2h_n \sum_{i=0}^{n-1} E[sz(n-i)] + h_n^2 E\left[\left(\sum_{i=0}^{n-1} z(n-i)\right)\left(\sum_{j=0}^{n-1} z(n-j)\right)\right] \end{aligned}$$

که

$$\begin{aligned} E[sz(n-i)] &= E[s(s+v(n-i))] = E[s^2] + E[sv(n-i)] \\ &= P + E[s]E[v(n-i)] = P \end{aligned}$$

24

Estimation Theory  
by Dr B. Moaveni

## تخمین یک سیگنال ثابت

همچنین

$$E[z(n-i)z(n-j)] = E[(s+v(n-i))(s+v(n-j))] = p + \sigma_v^2 \delta(i-j),$$

که نتیجه می دهد:

$$h_n^2 E \left[ \left( \sum_{i=0}^{n-1} z(n-i) \right) \left( \sum_{j=0}^{n-1} z(n-j) \right) \right] = h_n^2 (n^2 P + n \sigma_v^2)$$

و در نتیجه:

$$MSE(n) = P - 2nh_n P + h_n^2 (n^2 P + n \sigma_v^2) \quad (5.27)$$

Estimation Theory  
by Dr B. Moaveni

25

## تخمین یک سیگنال ثابت

با فرض معلوم بودن  $P$  و با استفاده از (5.17)

$$MSE(n) = \frac{P \sigma_v^2}{nP + \sigma_v^2} = h_n \sigma_v^2 \quad (5.28)$$

و در نتیجه می توان مقدار  $MSE$  را نیز به صورت بازگشتی محاسبه نمود:

$$MSE(n+1) = h_{n+1} \sigma_v^2 = \frac{h_{n+1}}{h_n} MSE(n) = (1 - h_{n+1}) MSE(n) \quad (5.29)$$

Estimation Theory  
by Dr B. Moaveni

26

## تخمین یک سیگنال ثابت

ارائه یک الگوریتم بازگشتی به منظور تخمین سیگنال ثابت:

$$n = 0 \quad \hat{s}(0) = \begin{cases} E[s] \\ \vee \\ 0 \end{cases} \quad 1 - \text{مقدار دهی اولیه:}$$

$$P = V : \text{a guess} \quad h_0 = \frac{V}{\sigma_v^2} \quad MSE(0) = V$$

$z(n+1)$  ۲- دریافت مشاهده

Estimation Theory  
by Dr B. Moaveni

27

## تخمین یک سیگنال ثابت

ارائه یک الگوریتم بازگشتی به منظور تخمین سیگنال ثابت:

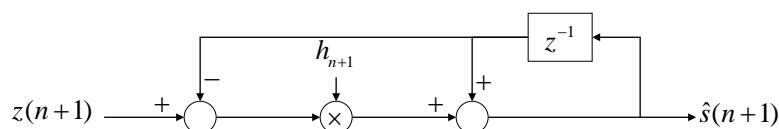
۳- محاسبه روابط (۵.۲۴)، (۵.۲۵) و (۵.۲۹)

$$h_{n+1} = h_n (1 + h_n)^{-1}$$

$$\hat{s}(n+1) = \hat{s}(n) + h_{n+1} [z(n+1) - \hat{s}(n)],$$

$$MSE(n+1) = (1 - h_{n+1})MSE(n).$$

۴- افزایش مقدار  $n$  و بازگشت به مرحله ۲.



Estimation Theory  
by Dr B. Moaveni

28

## تخمین یک سیگنال ثابت

ارائه یک الگوریتم بازگشتی به منظور تخمین سیگنال ثابت:

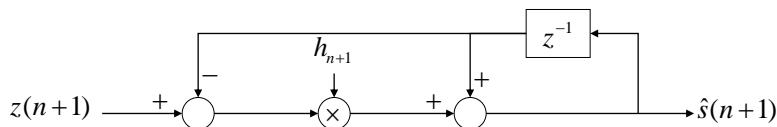
۳- محاسبه روابط (۵.۲۴)، (۵.۲۵) و (۵.۲۹)

$$h_{n+1} = h_n (1 + h_n)^{-1}$$

$$\hat{s}(n+1) = \hat{s}(n) + h_{n+1} [z(n+1) - \hat{s}(n)],$$

$$MSE(n+1) = (1 - h_{n+1}) MSE(n).$$

۴- افزایش مقدار  $n$  و بازگشت به مرحله ۲.



Estimation Theory  
by Dr B. Moaveni

29

## تخمین یک سیگنال ثابت

بررسی وضعیت تخمین:

$$\begin{aligned}
 E[\hat{s}(n)] &= E\left[h_n \sum_{i=0}^{n-1} z(n-i)\right] = h_n \sum_{i=0}^{n-1} E[z(n-i)] \\
 &= h_n \sum_{i=0}^{n-1} (E[s] + E[v(n-i)]) = h_n \sum_{i=0}^{n-1} E[s] \\
 &= nh_n E[s] = \frac{n}{n + \sigma_v^2/V} E[s]. \quad (5.31)
 \end{aligned}$$

مشخص است که این تخمینگر در حالت کلی **unbiased** نیست ولیکن

$$\lim_{n \rightarrow \infty} E[\hat{s}(n)] = E[s] \quad (5.32)$$

Estimation Theory  
by Dr B. Moaveni

30

## تخمین یک سیگنال ثابت

بررسی وضعیت تخمین:

$$\begin{aligned} MSE(n) &= P - (2nP)h_n + (n^2P + n\sigma_v^2)h_n^2 \\ &= p - (2nP)\frac{V}{nV + \sigma_v^2} + (n^2P + n\sigma_v^2)\left(\frac{V}{nV + \sigma_v^2}\right)^2 \\ &= \frac{(nV + \sigma_v^2)^2 P - 2nP V (nV + \sigma_v^2) + (n^2P + n\sigma_v^2) V^2}{(nV + \sigma_v^2)^2} = \frac{nV^2\sigma_v^2 + P\sigma_v^2}{(nV + \sigma_v^2)^2} \end{aligned}$$

$$\lim_{n \rightarrow \infty} MSE(n) = \lim_{n \rightarrow \infty} \frac{nV^2\sigma_v^2 + P\sigma_v^2}{n^2V^2 + 2nV\sigma_v^2 + \sigma_v^4} = \lim_{n \rightarrow \infty} \frac{nV^2\sigma_v^2}{n^2V^2} = \lim_{n \rightarrow \infty} \frac{\sigma_v^2}{n} = 0 \quad (5.33)$$

در نتیجه تخمین بازگشتی ارائه شده برای  $n \rightarrow \infty$  یک تخمین کامل است.

## مساله تخمین بازگشتی

مساله تخمین بازگشتی محاسبه  $\hat{s}(n+1)$  با استفاده از مشاهدات  $z(n+1)$  و  $\hat{s}(n)$  است.

$$\hat{s}(n+1) = \alpha_{n+1}(\hat{s}(n), z(n+1)). \quad (5.34)$$

توجه کنید که تخمینگر حاصل میتواند غیرخطی و/یا متغیر با زمان باشد.  
در ادامه به دنبال تخمین خطی با شرط بھینه سازی MMSE خواهیم بود.

## مدل سیگنال / مشاهدات

در این بخش فرضیات لازم برای سیگنال و مشاهدات برای استفاده در مساله تخمین ارائه می شود:

- در این بخش سیگنال و مشاهدات به صورت متغیرهای حالت و خروجی از یک مدل فضای حالت در نظر گرفته می شوند.
- فرض کنید  $s(n)$  و  $z(n)$  بردار فرایندهای تصادفی با ابعاد  $p$  باشند:

$$s(n) = \begin{bmatrix} s_1(n) \\ s_2(n) \\ \vdots \\ s_p(n) \end{bmatrix}, \quad \text{and} \quad z(n) = \begin{bmatrix} z_1(n) \\ z_2(n) \\ \vdots \\ z_p(n) \end{bmatrix}. \quad (5.35)$$

## مدل سیگنال / مشاهدات

- بطور کلی  $s(n)$  یک نویز رنگی است که با عبور نویز سفید از یک سیستم خطی حاصل می شود.

$$x(n+1) = \Phi_{N \times N} x(n) + \Gamma_{N \times m} \omega(n), \quad x(0) = x_0 \quad (5.36)$$

$$s(n) = C_{p \times N} x(n), \quad (5.37)$$

$$z(n) = s(n) + v(n) \quad (5.38)$$

$\omega(n)$ : zero mean white noise

$$E[\omega(i)\omega^T(j)] = Q_{m \times m} \delta(i-j); \quad (5.39)$$

where,  $Q$ : covariance matrix

## مدل سیگنال / مشاهدات

$v(n)$ : zero mean white noise

$$E[v(i)v^T(j)] = R_{p \times p} \delta(i-j); \quad (5.40)$$

where,  $R$ : covariance matrix

- همچنین  $x_0$ ،  $\omega(n)$  و  $v(n)$  متغیرهای مستقلی هستند.
- ماتریس های  $Q$  و  $R$ ، ماتریس های کوواریانس، متقارن و مثبت معین هستند.
- توجه: خواص و فرضیات فوق در خصوص سیگنال و مشاهدات کمک می کند فیلتر کالمون در موقعیت هایی کار کند که فیلتر وینر قابلیت لازم را ندارد.

## مدل سیگنال / مشاهدات

فیلتر وینر نیازمند سیگنال WSS و نویز فرایند با میانگین صفر و سیستم پایدار می باشد. در حالیکه فیلتر کالمون چنین محدودیت هایی وجود ندارد. به عبارت دیگر فیلتر کالمون می تواند برای یک سیستم ناپایدار و همچنین برای حالت های با میانگین غیر صفر بکار رود. همچنین امکان استفاده از کالمون فیلتر برای یک سیستم متغیر با زمان با نویز non-stationary نیز وجود دارد.

توجه: از سوی دیگر **فیلتر وینر** به مشخصات استاتیک سیگنال و نویز نیاز دارد و فقط تابع های همبستگی و یا چگالی طیفی لازم هستند. در حالیکه در **فیلتر کالمون** به شناخت کامل **مدل سیستم** به صورت فضایی حالت نیاز است.

## تخمین *a priori* و *a posteriori*

<i>a priori</i>	<i>a posteriori</i>
Available measurements:	Available measurements:
$Z^- = \{z(1), \dots, z(n-1)\}$	$Z = \{z(1), \dots, z(n)\}$
Estimate of $x(n)$ : $\hat{x}^-(n)$	Estimate of $x(n)$ : $\hat{x}(n)$
Estimation Error: $\tilde{x}^-(n)$	Estimation Error: $\tilde{x}(n)$
Error covariance: $P^-(n)$	Error covariance: $P(n)$
MSE: $E[\tilde{x}^-(n)(\tilde{x}^-(n))^T]$ $= \text{trace}(P^-(n))$	MSE: $E[\tilde{x}(n)(\tilde{x}(n))^T]$ $= \text{trace}(P(n))$
$P^-(n) = \text{Cov}[\tilde{x}^-(n)] = E[\tilde{x}^-(n)(\tilde{x}^-(n))^T]$	$P(n) = \text{Cov}[\tilde{x}(n)] = E[\tilde{x}(n)(\tilde{x}(n))^T]$
$\tilde{x}^-(n) = x(n) - \hat{x}^-(n)$	$\tilde{x}(n) = x(n) - \hat{x}(n)$
Estimation Theory by Dr B. Moaveni	37

## استخراج معادلات فیلتر کالمن

فرض کنید:

$\hat{x}(n-1)$ : as a LMMSE is available

GOAL:  $\hat{x}(n) = ?$  from  $Z^-$

در نتیجه ما به دنبال یافتن تخمین  $\hat{x}^-(n)$  (*a priori*) با استفاده از تخمین  $\hat{x}(n-1)$  (*a posteriori*) هستیم.

## استخراج معادلات فیلتر کالمن

### The *a priori* Estimate

از آنجایی که  $\hat{x}^-(n)$  لازم است یک تخمین بهینه LMMSE باشد لذا باید شرط تعامل را برآورده نماید:

$$E[(x(n) - \hat{x}^-(n))z^T(i)] = 0 \quad i = 1, 2, \dots, n-1 \quad (5.45)$$

و با تعریف

$$Z_{n-1} = \begin{bmatrix} z(1) \\ z(2) \\ \vdots \\ z(n-1) \end{bmatrix}$$

میتوان رابطه (5.45) را به صورت زیر بازنویسی نمود:

$$E[(x(n) - \hat{x}^-(n))Z_{n-1}^T] = 0_{N \times n-1} \quad (5.46)$$

Estimation Theory  
by Dr B. Moaveni

39

## استخراج معادلات فیلتر کالمن

### The *a priori* Estimate

$$(5.36) \quad \left. \begin{aligned} x(n-1) &= \hat{x}(n-1) + \tilde{x}(n-1) \end{aligned} \right\} \rightarrow x(n) = \Phi \hat{x}(n-1) + \Phi \tilde{x}(n-1) + \Gamma \omega(n-1)$$

$$(5.46) \rightarrow E[(\Phi \hat{x}(n-1) - \hat{x}^-(n))Z_{n-1}^T] + \Phi E[\tilde{x}(n-1)Z_{n-1}^T] + \Gamma E[\omega(n-1)Z_{n-1}^T] = 0$$

0
Orthogonal principle
0
Independency and zero mean noise

$$\Rightarrow E[(\Phi \hat{x}(n-1) - \hat{x}^-(n))Z_{n-1}^T] = 0 \Rightarrow \hat{x}^-(n) = \Phi \hat{x}(n-1) \quad (5.47)$$

Estimation Theory  
by Dr B. Moaveni

40

## استخراج معادلات فیلتر کالمن

### The *a priori* Error Covariance

به منظور استخراج ارتباط ماتریس خطای کوواریانس  $P(n-1)$  با  $P(n)$  داریم:

$$\begin{aligned} P^-(n) &= \text{Cov}[x(n) - \hat{x}^-(n)] \\ &= \text{Cov}[\Phi x(n-1) + \Gamma \omega(n-1) - \Phi \hat{x}(n-1)] \\ &= \text{Cov}[\Phi \tilde{x}(n-1) + \Gamma \omega(n-1)] \end{aligned} \quad (5.48)$$

همچنین با توجه به استقلال  $\tilde{x}(n-1)$  و  $\omega(n-1)$

$$E[\tilde{x}(n-1)\omega^T(n-1)] = 0$$

## استخراج معادلات فیلتر کالمن

### The *a priori* Error Covariance

در نتیجه:

$$P^-(n) = \Phi P(n-1) \Phi^T + \Gamma Q \Gamma^T \quad (5.49)$$

$$\left. \begin{aligned} \hat{x}^-(n) &= \Phi \hat{x}(n-1) \\ P^-(n) &= \Phi P(n-1) \Phi^T + \Gamma Q \Gamma^T \end{aligned} \right\} \rightarrow \text{time update} \quad (5.47) \quad (5.49)$$

## استخراج معادلات فیلتر کالمن

### Measurement Update

مساله دیگری که لازم است حل شود، نحوه استفاده از مشاهده  $(n)z$  در تصحیح تخمین  $(n)x$  است. به عبارت دیگر نحوه به روز شدن مقدار  $(n)\hat{x}$  با استفاده از  $(n)z$  لازم است ارائه گردد. که در این مسیر ماتریس  $P(n)$  نیز می بایستی که محاسبه گردد:

### The *a posteriori* Estimation

$\hat{x}(n-1)$ : known

$$E[(x(n-1) - \hat{x}(n-1))Z_{n-1}^T] = 0 \quad (5.50)$$

## استخراج معادلات فیلتر کالمن

### The *a posteriori* Estimation

$$\xrightarrow{\text{LMMSE estimation}} \hat{x}(n-1) = \sum_{j=0}^{n-1} H_{n-1}(j)z(j) = J(n-1)Z_{n-1} \quad (5.51)$$

where

$$J(n-1) = [H_{n-1}(1) \ H_{n-1}(2) \ \dots \ H_{n-1}(n-1)].$$

حال برای یافتن  $\hat{x}(n)$ :

$$\hat{x}(n) = \sum_{j=1}^n H_n(j)z(j) \quad (5.52)$$

## استخراج معادلات فیلتر کالمن

### The *a posteriori* Estimation

که لازم است شرط تعامد را برآورده نماید، لذا:

$$E[(x(n) - \hat{x}(n)) z^T(i)] = 0 \quad i = 1, 2, \dots, n$$

و/یا:

$$E[(x(n) - \hat{x}(n)) Z_n^T] = 0, \quad (5.53)$$

where  $Z_n = \begin{bmatrix} z(1) \\ z(2) \\ \vdots \\ z(n) \end{bmatrix} = \begin{bmatrix} Z_{n-1} \\ z(n) \end{bmatrix}$ .

Estimation Theory  
by Dr B. Moaveni

45

## استخراج معادلات فیلتر کالمن

### The *a posteriori* Estimation

در نتیجه رابطه (۵.۵۲) را می توان به صورت زیر نوشت:

$$\hat{x}(n) = K(n)z(n) + G(n)Z_{n-1} \quad (5.54)$$

where

$$K(n) = H_n(n)$$

$$G(n) = [H_n(1), H_n(2), \dots, H_n(n-1)].$$

حال نیاز به محاسبه  $K(n)$  و  $G(n)$  است.

$$\hat{x}(n) = \underbrace{K(n)}_{?} z(n) + \underbrace{G(n)}_{?} Z_{n-1} \quad (5.54)$$

Estimation Theory  
by Dr B. Moaveni

46

## استخراج معادلات فیلتر کالمن

### The *a posteriori* Estimation

$$(5.54) \xrightarrow{(5.37) (5.38)} \hat{x}(n) = K(n)[Cx(n) + v(n)] + G(n)Z_{n-1} \\ = K(n)C\Phi x(n-1) + K(n)C\Gamma\omega(n-1) \\ + K(n)v(n) + G(n)Z_{n-1} \quad (5.55)$$

همچنین با استفاده از رابطه (۵.۳۶) و

$$x(n) = \Phi\hat{x}(n-1) + \Phi\tilde{x}(n-1) + \Gamma\omega(n-1). \quad (5.56)$$

## استخراج معادلات فیلتر کالمن

### The *a posteriori* Estimation

$$(5.55) \left. \begin{aligned} \tilde{x}(n) &= x(n) - \hat{x}(n) \\ &= [I - K(n)C]\Phi\hat{x}(n-1) + [I - K(n)C]\Phi\tilde{x}(n-1) \\ &\quad + [I - K(n)C]\Gamma\omega(n-1) - K(n)v(n) - G(n)Z_{n-1} \end{aligned} \right\} \quad (5.57)$$

$$(5.57) \xrightarrow{\hat{x}(n-1)=J(n-1)Z_{n-1}} \tilde{x}(n) = [I - K(n)C]\Phi J(n-1)Z_{n-1} + [I - K(n)C]\Phi\tilde{x}(n-1) \\ + [I - K(n)C]\Gamma\omega(n-1) - K(n)v(n) - G(n)Z_{n-1}. \quad (5.58)$$

## استخراج معادلات فیلتر کالمن

### The *a posteriori* Estimation

حال با استفاده از شرط (۵.۵۳) :

$$(5.53): \quad E[\tilde{x}(n)Z_n^T] = E\left[\tilde{x}(n)\begin{bmatrix} Z_{n-1} \\ z(n) \end{bmatrix}^T\right] = 0.$$

$$\Rightarrow \begin{cases} E[\tilde{x}(n)Z_{n-1}^T] = 0 & (5.59) \\ E[\tilde{x}(n)z^T(n)] = 0 & (5.60) \end{cases}$$

در نتیجه:

$$E[\tilde{x}(n)Z_{n-1}^T] = [I - K(n)C]\Phi J(n-1)E[Z_{n-1}Z_{n-1}^T] - G(n)E[Z_{n-1}Z_{n-1}^T] = 0$$

$$\Rightarrow G(n)E[Z_{n-1}Z_{n-1}^T] = [I - K(n)C]\Phi J(n-1)E[Z_{n-1}Z_{n-1}^T] \quad (5.61)$$

## استخراج معادلات فیلتر کالمن

### The *a posteriori* Estimation

که:

$R > 0 \rightarrow E[Z_{n-1}Z_{n-1}^T]$  is invertible

$$\Rightarrow G(n) = [I - K(n)C]\Phi J(n-1) \quad (5.62)$$

$$\hat{x}(n) = \textcolor{red}{K(n)} z(n) + [I - K(n)C]\Phi J(n-1)Z_{n-1} \quad (5.54)$$

$$\hat{x}(n) = \textcolor{red}{K(n)} z(n) + [I - K(n)C]\Phi \hat{x}(n-1) \quad (5.54)$$

$$\hat{x}(n) = \Phi \hat{x}(n-1) + K(n)[z(n) - C\Phi \hat{x}(n-1)] \quad (5.63)$$

در نتیجه:

$$\xrightarrow{(5.47)} \hat{x}(n) = \hat{x}^-(n) + K(n)[z(n) - C\hat{x}^-(n)]. \quad (5.64)$$

## استخراج معادلات فیلتر کالمن

### The *Kalman* gain

$$\left. \begin{array}{l} (5.36) \\ (5.63) \end{array} \right\} \rightarrow \tilde{x}(n) = \Phi x(n-1) + \Gamma \omega(n-1) - \Phi \hat{x}(n-1) - K(n)z(n) + K(n)C\Phi \hat{x}(n-1)$$

(5.65)

همچنین:

$$\left. \begin{array}{l} (5.37) \\ (5.38) \end{array} \right\} \rightarrow z(n) = C\Phi x(n-1) + C\Gamma \omega(n-1) + v(n) \quad (5.66)$$

$$= C\Phi \tilde{x}(n-1) + C\Phi \hat{x}(n-1) + C\Gamma \omega(n-1) + v(n) \quad (5.67)$$

با جایگذاری معادله (5.66) در (5.65)

$$\begin{aligned} \tilde{x}(n) &= \Phi x(n-1) + \Gamma \omega(n-1) - \Phi \hat{x}(n-1) + K(n)C\Phi \hat{x}(n-1) \\ &\quad - K(n) \{ C\Phi \tilde{x}(n-1) + C\Phi \hat{x}(n-1) + C\Gamma \omega(n-1) + v(n) \} \end{aligned}$$

## استخراج معادلات فیلتر کالمن

### The *Kalman* gain

$$\tilde{x}(n) = [I - K(n)C]\Phi \tilde{x}(n-1) + [I - K(n)C]\Gamma \omega(n-1) - K(n)v(n) \quad (5.68)$$

با جایگزینی معادله (5.67) و (5.68) در شرط (5.60) خواهیم داشت:

$$\begin{aligned} E[\tilde{x}(n)z^T(n)] &= \Phi P(n-1)\Phi^T C^T + \Gamma Q \Gamma^T C^T \\ &\quad - K(n)C\Phi P(n-1)\Phi^T C^T - K(n)C\Gamma Q \Gamma^T C^T - K(n)R = 0, \end{aligned} \quad (5.69)$$

$$(5.49) \rightarrow P^-(n)C^T = K(n)[CP^-(n)C^T + R],$$

$$\Rightarrow \textit{Kalman Gain: } K(n) = P^-(n)C^T[CP^-(n)C^T + R]^{-1} \quad (5.70)$$

## استخراج معادلات فیلتر کالمن

### The *a posteriori* Error Covariance

$$P^-(n) \xleftarrow{\text{ok}} P(n-1) \quad P(n) \xleftarrow{?} P^-(n)$$

$$P(n) = \text{Cov}[x(n) - \hat{x}(n)].$$

با استفاده از معادلات (۵.۳۷) و (۵.۳۸) و (۵.۷۰) خواهیم داشت:

$$\begin{aligned} P(n) &= \text{Cov}\left[x(n) - \hat{x}^-(n) - K(n)[Cx(n) + v(n) - C\hat{x}^-(n)]\right] \\ &= \text{Cov}\left[\left[(I - K(n)C)\tilde{x}^-(n)\right] - K(n)v(n)\right] \\ &= P^-(n) - K(n)CP^-(n) - P^-(n)C^T K^T(n) \\ &\quad + K(n)[CP^-(n)C^T + R]K^T(n) \end{aligned} \tag{5.71}$$

## استخراج معادلات فیلتر کالمن

### The *a posteriori* Error Covariance

با جایگزینی رابطه (۵.۷۰) در (۵.۷۱) خواهیم داشت:

$$-P^-(n)C^T K^T(n) + K(n)[CP^-(n)C^T + R]K^T(n) \stackrel{(5.70)}{=} 0$$

$$\Rightarrow P(n) = P^-(n) - K(n)CP^-(n) \tag{5.72}$$

## استخراج معادلات فیلتر کالمن

### The *a posteriori* Error Covariance

با جایگزینی رابطه (۵.۷۰) در (۵.۷۱) خواهیم داشت:

$$-P^-(n)C^T K^T(n) + K(n) \left[ CP^-(n)C^T + R \right] K^T(n) \stackrel{(5.70)}{=} 0$$

$$\Rightarrow P(n) = P^-(n) - K(n)CP^-(n) \quad (5.72)$$

## جمع بندی معادلات فیلتر کالمن

در استفاده از معادلات فیلتر کالمن ابتدا لازم است مقادیر اولیه پارامترهای برگشتی انتخاب گردند. به این منظور:

$$\hat{x}^-(0) = E[x(0)] \quad (5.73)$$

$$P^-(0) = E \left[ (x(0) - \hat{x}^-(0))(x(0) - \hat{x}^-(0))^T \right], \quad (5.74)$$

با توجه به اینکه مقادیر فوق (امید ریاضی ها) در اختیار ما نیستند:

$$\hat{x}^-(0) = \text{guess of the value of } \hat{x}^-(0) \text{ or of } E[x(0)] \quad (5.75)$$

$$P^-(0) = \text{guess of } E \left[ (x(0) - \hat{x}^-(0))(x(0) - \hat{x}^-(0))^T \right], \quad (5.76)$$

## جمع بندی معادلات فیلتر کالمن

ولیکن (۵.۷۶) تاحدودی دور از دسترس است. اما  $P^{-}(0)$  ماتریسی متقارن و مثبت معین است و در بسیاری از موقع انتخاب زیر کفايت می نماید:

$$P^{-}(0) = \lambda I \quad \lambda > 0, \quad (5.77)$$

یا

$$P^{-}(0) = \text{diag}([\lambda_1 \quad \lambda_2 \quad \dots \quad \lambda_m]), \quad \lambda_i > 0 \quad \text{for } i = 1, 2, \dots, m \quad (5.78)$$

## معادلات فیلتر کالمن

*Measurement Update :*

$$K(n) = P^{-}(n)C^T \left[ CP^{-}(n)C^T + R \right]^{-1} \quad (5.80)$$

$$\hat{x}(n) = \hat{x}^{-}(n) + K(n) [z(n) - C\hat{x}^{-}(n)] \quad (5.81)$$

$$P(n) = P^{-}(n) - K(n)CP^{-}(n) \quad (5.82)$$

*Time Update :*

$$\hat{x}^{-}(n+1) = \Phi\hat{x}(n) \quad (5.83)$$

$$P^{-}(n+1) = \Phi P(n)\Phi^T + \Gamma Q \Gamma^T \quad (5.84)$$

کالمن فیلتر ارائه شده برای  $(\hat{x}(n))$  *filtering* یک مرحله است که به در کل با نام فیلتر کالمن شناخته می شود.

## معادلات فیلتر کالمن

نوع دیگری از پیاده سازی فیلتر کالمن با انتخاب شرایط اولیه به صورت زیر صورت می گیرد:

$$\hat{x}(0) = \text{guess of } \hat{x}(0) \quad (5.87)$$

$$P(0) = \text{guess of } E\left[\left(x(0) - \hat{x}(0)\right)\left(x(0) - \hat{x}(0)\right)^T\right] \quad (5.88)$$

set :  $n = 1$

*Time Update :*

$$\hat{x}^-(n) = \Phi \hat{x}(n-1)$$

*Measurement Update :*

$$P^-(n) = \Phi P(n-1) \Phi^T + \Gamma Q \Gamma^T$$

$$K(n) = P^-(n) C^T \left[ C P^-(n) C^T + R \right]^{-1}$$

$$\hat{x}(n) = \hat{x}^-(n) + K(n) \left[ z(n) - C \hat{x}^-(n) \right]$$

$$P(n) = P^-(n) - K(n) C P^-(n)$$

## معادلات فیلتر کالمن

نوع دیگری از پیاده سازی فیلتر کالمن با انتخاب شرایط اولیه به صورت زیر صورت می گیرد:

$$\hat{x}(0) = \text{guess of } \hat{x}(0) \quad (5.87)$$

$$P(0) = \text{guess of } E\left[\left(x(0) - \hat{x}(0)\right)\left(x(0) - \hat{x}(0)\right)^T\right] \quad (5.88)$$

set :  $n = 1$

*Time Update :*

$$\hat{x}^-(n) = \Phi \hat{x}(n-1)$$

*Measurement Update :*

$$P^-(n) = \Phi P(n-1) \Phi^T + \Gamma Q \Gamma^T$$

$$K(n) = P^-(n) C^T \left[ C P^-(n) C^T + R \right]^{-1}$$

$$\hat{x}(n) = \hat{x}^-(n) + K(n) \left[ z(n) - C \hat{x}^-(n) \right]$$

$$P(n) = P^-(n) - K(n) C P^-(n)$$

## خواص فیلتر کالمن

### General Properties:

۱- فیلتر کالمن یک سیستم متغیر بازمان است.

۲- با دسته بندی معادلات فیلتر کالمن، دو دسته معادله مستقل را می توان ارائه نمود:  
*estimate recursion :*

$$K(n) = P^-(n)C^T \left[ CP^-(n)C^T + R \right]^{-1} \quad (5.80)$$

$$\hat{x}(n) = \hat{x}^-(n) + K(n) \left[ z(n) - C\hat{x}^-(n) \right] \quad (5.81)$$

$$\hat{x}^-(n+1) = \Phi\hat{x}(n) \quad (5.83)$$

### Covariance Recursion:

$$K(n) = P^-(n)C^T \left[ CP^-(n)C^T + R \right]^{-1} \quad (5.80)$$

$$P(n) = P^-(n) - K(n)CP^-(n) \quad (5.82)$$

$$P^-(n+1) = \Phi P(n)\Phi^T + \Gamma Q\Gamma^T \quad (5.84)$$

Estimation Theory  
by Dr B. Moaveni

61

## خواص فیلتر کالمن

### General Properties:

۳- توجه به معادلات *Recursion Estimate* نشان دهنده این نکته است که این معادلات وابسته به مشاهدات نیستند و امکان پیش محاسبه کوواریانس خطأ و بهره کالمن بدون هیچگونه مشاهده ای وجود دارد.

### Riccati Equation:

$$\left. \begin{array}{l} (5.84) \\ (5.82) \end{array} \right\} \rightarrow P^-(n+1) = \Phi P^-(n)\Phi^T - \Phi K(n)CP^-(n)\Phi^T + \Gamma Q(n)\Gamma^T$$

### Riccati Equation:

$$\Rightarrow P^-(n+1) = \Phi \left\{ P^-(n) - P^-(n)C^T \left[ CP^-(n)C^T + R \right]^{-1} CP^-(n) \right\} \Phi^T + \Gamma Q(n)\Gamma^T \quad (5.89)$$

Estimation Theory  
by Dr B. Moaveni

62

## خواص فیلتر کالمن

### Error Systems

به منظور بررسی پایداری فیلتر کالمن از بررسی خطای تخمین استفاده می شود. لذا:

$$\begin{aligned}
 E[\tilde{x}(n)] &= E[x(n) - \hat{x}(n)] \\
 &= E[\Phi x(n-1) + \Gamma(n-1)\omega(n-1) - \Phi \hat{x}(n-1) - K(n)[z(n) - C\Phi \hat{x}(n-1)]] \\
 &= E[\Phi x(n-1) + \Gamma(n-1)\omega(n-1) - \Phi \hat{x}(n-1) \\
 &\quad - K(n)\{C[\Phi x(n-1) + \Gamma(n-1)\omega(n-1)] + v(n) - C\Phi \hat{x}(n-1)\}] \\
 &= [I - K(n)C]\Phi E[\tilde{x}(n-1)]
 \end{aligned} \tag{5.90}$$

$$\text{Estimation Error } E[\tilde{x}(n)] = [I - K(n)C]\Phi E[\tilde{x}(n-1)]$$

$$\begin{aligned}
 \Phi E[\tilde{x}(n)] &= \Phi[I - K(n)C]\Phi E[\tilde{x}(n-1)] \\
 \longrightarrow E[\tilde{x}^-(n+1)] &= \Phi[I - K(n)C]E[\tilde{x}^-(n)] \\
 \longrightarrow E[\tilde{x}^-(n)] &= \Phi[I - K(n-1)C]E[\tilde{x}^-(n-1)]
 \end{aligned} \tag{5.92}$$

Estimation Theory  
by Dr B. Moaveni

63

## فرم معادل فیلتر کالمن

با استفاده از لم معکوس سازی ماتریس می توان معادلات فیلتر کالمن را به نحو دیگری ارائه نمود که بر اساس آن بتوان *Kalman Smoother* را ساده تر بیان کرده و پایداری فیلتر کالمن را اثبات نمود.

*Matrix Inversion Lemma :*

$$(A_{11}^{-1} + A_{12}A_{22}A_{21})^{-1} = A_{11} - A_{11}A_{12}(A_{21}A_{11}A_{12} + A_{22}^{-1})^{-1}A_{21}A_{11} \tag{5.93}$$

$$\begin{aligned}
 \xrightarrow{(5.81)} \hat{x}(n) &= [I - k(n)C]P^-(n)(P^-(n))^{-1}\hat{x}^-(n) + K(n)z(n) \\
 &= P(n)\left((P^-(n))^{-1}\Phi \hat{x}(n-1)\right) + K(n)z(n) \\
 &= P(n)\left[(P^-(n))^{-1}\Phi \hat{x}(n-1) + P^{-1}(n)K(n)z(n)\right]
 \end{aligned} \tag{5.94}$$

Estimation Theory  
by Dr B. Moaveni

64

## فرم معادل فیلتر کالمن

از طرفی:

$$P(n) = P^-(n) - P^-(n)C^T[CP^-(n)C^T + R]^{-1}CP^-(n)$$

با استفاده از لم معکوس سازی ماتریس:

$$\begin{aligned} P^{-1}(n) &= (P^-(n))^{-1} + (P^-(n))^{-1}P^-(n)C^T \times \\ &\quad \left[ -CP^-(n)(P^-(n))^{-1}P^-(n)C^T + (CP^-(n)C^T + R) \right]^{-1} CP^-(n)(P^-(n))^{-1}. \end{aligned}$$

$$P^{-1}(n) = (P^-(n))^{-1} + C^T \times [R]^{-1} C.$$

با ضرب معادله فوق در  $K(n)$ :

$$\begin{aligned} \xrightarrow{5.80} P^{-1}(n)K(n) &= \left[ (P^-(n))^{-1} + C^T R^{-1} C \right] P^-(n)C^T \left[ CP^-(n)C^T + R \right]^{-1} \\ &= C^T [I + R^{-1} CP^-(n)C^T] [CP^-(n)C^T + R]^{-1} \\ &= C^T R^{-1} [R + CP^-(n)C^T] [CP^-(n)C^T + R]^{-1} \\ &= C^T R^{-1}. \end{aligned}$$

Estimation Theory  
by Dr B. Moaveni

65

## فرم معادل فیلتر کالمن

در نتیجه معادله (۵.۹۴) را می توان به صورت زیر بازنویسی نمود:

$$\hat{x}(n) = P(n) \left[ (P^-(n))^{-1} \Phi \hat{x}(n-1) + C^T R^{-1} z(n) \right] \quad (5.95)$$

همچنین:

$$P(n) = P^-(n) - P^-(n)C^T[CP^-(n)C^T + R]^{-1}CP^-(n)$$

با استفاده از لم معکوس سازی ماتریس:

$$P(n) = [(P^-(n))^{-1} + C^T R^{-1} C]^{-1} \quad (5.96)$$

Estimation Theory  
by Dr B. Moaveni

66

## معادلات جدید فیلتر کالمن

$$\hat{x}^-(n) = \Phi \hat{x}(n-1) \quad (5.97)$$

$$P(n) = \left[ (P^-(n))^{-1} + C^T R^{-1} C \right]^{-1} \quad (5.98)$$

$$\hat{x}(n) = P(n) \left[ (P^-(n))^{-1} \Phi \hat{x}(n-1) + C^T R^{-1} z(n) \right] \quad (5.99)$$

$$P^-(n+1) = \Phi P(n) \Phi^T + \Gamma Q(n) \Gamma^T \quad (5.100)$$

## The Steady State Kalman Filter (SSKF)

فیلتر کالمن با توجه به تغییر و به روز شدن  $P(n)$ ،  $P^-(n)$  و  $K(n)$  ذاتاً یک سیستم متغیر با زمان است در هر مرحله به روز می گردد.

در حالیکه برای مدل های سیگنال/مشاهدات نامتغیر بازمان با نویز این مقادیر به حالت ماندگاری می رسند و **steady state kalman filter** ایجاد می گردد.

با فرض رسیدن به حالت ماندگار و عدم تغییر  $: P^-(n)$

$$P_\infty^- = \lim_{n \rightarrow \infty} P^-(n) \quad (5.102)$$

*Algebraic Riccati Equation(ARE):*

$$(5.89) \implies P_\infty^- = \Phi \left[ P_\infty^- - P_\infty^- C^T \left( C P_\infty^- C^T + R \right)^{-1} C P_\infty^- \right] \Phi^T + \Gamma Q \Gamma^T \quad (5.103)$$

## The Steady State Kalman Filter (SSKF)

در نتیجه برای  $P_{\infty}^-$  حاصل از حل معادله جبری ریکاتی، بهره کالمن و ماتریس کوواریانس خطأ به صورت زیر خواهد بود:

$$K_{\infty} = P_{\infty}^- C^T (C P_{\infty}^- C^T + R)^{-1} \quad (5.104)$$

$$P_{\infty} = P_{\infty}^- - K_{\infty} C P_{\infty}^- \quad (5.105)$$

$$= P_{\infty}^- - P_{\infty}^- C^T (C P_{\infty}^- C^T + R)^{-1} C P_{\infty}^- \quad (5.106)$$

## The Steady State Kalman Filter (SSKF)

مثال ۵.۱) (یافتن مدل فضای حالت):  
سیگنال WSS،  $s(n)$  با تابع خودهمبستگی:

$$R_s(n) = 0.5\delta(n+1) + \delta(n) + 0.5\delta(n-1), \quad (5.107)$$

$$\xrightarrow{\text{power spectral density}} S_s(z) = 0.5z + 1 + 0.5z^{-1} \quad (5.108)$$

اندازه گیری سیگنال نیز با حضور نویز سفید  $\omega(n)$  با واریانس  $\sigma_{\omega}^2 = 2$  انجام می پذیرد. همچنین سیگنال و نویز غیرهمبسته هستند.

یکی از روش های تعیین مدل فضای حالت، استفاده از تابع چگالی طیفی به صورت

$$S_s(z) = S_s^+(z) S_s^+(z^{-1})$$

## The Steady State Kalman Filter (SSKF)

ادامه مثال (۵.۱) (یافتن مدل فضای حالت):

و می توان  $S_s^+(z)$  را به صورت یک سیستم LTI با ورودی نویز سفید با واریانس واحد در نظر گرفت و با تحقق آن می توان به یک مدل فضای حالت دست یافت.

لذا:

$$S_s(z) = 0.5z + 1 + 0.5z^{-1} = a(1 - bz)a(1 - bz^{-1}) = a^2[-bz + (1 + b^2) - bz^{-1}].$$

درنتیجه:

$$\left. \begin{array}{l} a^2(1+b^2)=1 \\ -a^2b=0.5 \end{array} \right\} \Rightarrow 4a^4 - 4a^2 + 1 = 0 \Rightarrow S_s^+(z) = \frac{1+z^{-1}}{\sqrt{2}} = \frac{1}{\sqrt{2}} + \frac{1}{\sqrt{2}}z^{-1}$$

## The Steady State Kalman Filter (SSKF)

ادامه مثال (۵.۱) (یافتن مدل فضای حالت):

$$\left. \begin{array}{l} x'(n+1) = 0x'(n) + \frac{1}{\sqrt{2}}\omega'(n) \\ s(n) = x'(n) + \frac{1}{\sqrt{2}}\omega'(n) \end{array} \right\} \quad \text{با استفاده از تحقق رویتگر:}$$

که  $\omega'(n)$  نویز سفید با میانگین ثابت و واریانس واحد را نشان می دهد.

با تعریف بردار حالت جدید به صورت:

$$X(n) \stackrel{\Delta}{=} \begin{bmatrix} s(n) \\ x'(n+1) \end{bmatrix},$$

$$X(n+1) = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} X(n) + \begin{bmatrix} 1/\sqrt{2} \\ 1/\sqrt{2} \end{bmatrix} \omega'(n+1)$$

## The Steady State Kalman Filter (SSKF)

ادامه مثال (۵.۱) (یافتن مدل فضای حالت):

$$X(n+1) = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} X(n) + \begin{bmatrix} 1/\sqrt{2} \\ 1/\sqrt{2} \end{bmatrix} \omega(n) \quad : \quad \omega(n) = \omega'(n+1)$$

$$s(n) = [1 \ 0] X(n).$$

$$z(n) = [1 \ 0] X(n) + v(n)$$

که  $R_v(n) = 2\delta(n)$  است،  $v(n)$  و  $\omega(n)$  ناهمبسته هستند.

Estimation Theory  
by Dr B. Moaveni

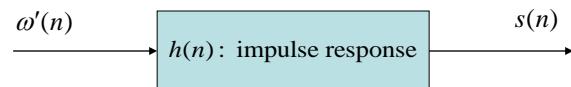
73

## The Steady State Kalman Filter (SSKF)

مثال (۵.۲) (یافتن مدل فضای حالت-۲):

در اینجا روش دوم استخراج یک مدل فضای حالت با استفاده از اطلاعات تابع خود همبستگی و تئوری سیستم های خطی ارائه می گردد.

$$R_s(n) = 0.5\delta(n+1) + \delta(n) + 0.5\delta(n-1), \quad (5.107)$$



$$\omega' : \begin{cases} \text{white noise} \\ \sigma_\omega^2 = 1 \end{cases}$$

$$\Rightarrow R_s(n) = h(n) * h(-n)$$

Estimation Theory  
by Dr B. Moaveni

74

## The Steady State Kalman Filter (SSKF)

ادامه مثال (۵.۲) (یافتن مدل فضای حالت-۲) :  
اگر  $h(n)$  از مرتبه  $N$  باشد،  $R_s(n)$  از مرتبه  $2N-1$  خواهد بود.

$$(5.107) \rightarrow N = 2 \Rightarrow s(n) = a\omega'(n) + b\omega'(n-1)$$

$$\Rightarrow R_s(n) = \begin{cases} a^2 + b^2 = 1, & n=0 \\ ab = 1/2 & n=\pm 1 \\ 0 & \text{otherwise} \end{cases} \Rightarrow a = b = \frac{1}{\sqrt{2}}$$

$$x(n) \triangleq \begin{bmatrix} s(n) \\ \omega'(n) \end{bmatrix} \Rightarrow \begin{cases} x(n+1) = \begin{bmatrix} 0 & 1/\sqrt{2} \\ 0 & 0 \end{bmatrix} x(n) + \begin{bmatrix} 1/\sqrt{2} \\ 1 \end{bmatrix} \omega'(n+1) \\ s(n) = [1 \ 0] x(n). \end{cases}$$

## The Steady State Kalman Filter (SSKF)

ادامه مثال (۵.۲) (یافتن مدل فضای حالت-۲) :

$$\text{assume: } \omega'(n+1) = \omega(n)$$

$$x(n+1) = \begin{bmatrix} 0 & 1/\sqrt{2} \\ 0 & 0 \end{bmatrix} x(n) + \begin{bmatrix} 1/\sqrt{2} \\ 1 \end{bmatrix} \omega(n) \quad (5.109)$$

$$s(n) = [1 \ 0] x(n) \quad (5.110)$$

$$z(n) = [1 \ 0] x(n) + v(n) \quad (5.111)$$

## The Steady State Kalman Filter (SSKF)

:مثال (۵.۳) (محاسات در SSKF)

برای مثال SMM (۵.۲) :

$$\left\{ \begin{array}{l} x(n+1) = \begin{bmatrix} 0 & 1/\sqrt{2} \\ 0 & 0 \end{bmatrix} x(n) + \begin{bmatrix} 1/\sqrt{2} \\ 1 \end{bmatrix} \omega(n) \end{array} \right. \quad (5.109)$$

$$s(n) = [1 \ 0] x(n) \quad (5.110)$$

$$z(n) = [1 \ 0] x(n) + v(n) \quad (5.111)$$

$$R_v(n) = 2\delta(n)$$

$$\left. \begin{aligned} P_{\infty}^- &= \begin{bmatrix} a & c \\ c & b \end{bmatrix} \end{aligned} \right\} \Rightarrow \begin{bmatrix} a & c \\ c & b \end{bmatrix} = \begin{bmatrix} (a+2)b - c^2 & 0 \\ 2(a+2) & 0 \end{bmatrix} + \begin{bmatrix} 1/2 & 1/\sqrt{2} \\ 1/\sqrt{2} & 1 \end{bmatrix}. \quad (5.103)$$

Estimation Theory  
by Dr B. Moaveni

77

## The Steady State Kalman Filter (SSKF)

:ادامه مثال (۵.۳) (محاسات در SSKF)

$$b = 1$$

$$c = 1/\sqrt{2}$$

$$a = \frac{(a+2)(1) - (1/\sqrt{2})^2}{2a+4} \Rightarrow 2a^2 + 2a - 7/2 = 0 \Rightarrow a = -0.5 \pm \sqrt{2}$$

$$\xrightarrow{P_{\infty}^- > 0} a = -0.5 + \sqrt{2}$$

$$\Rightarrow P_{\infty}^- = \begin{bmatrix} \sqrt{2} - 0.5 & 1/\sqrt{2} \\ 1/\sqrt{2} & 1 \end{bmatrix} \approx \begin{bmatrix} 0.9142 & 0.7071 \\ 0.7071 & 1 \end{bmatrix} \quad (5.112)$$

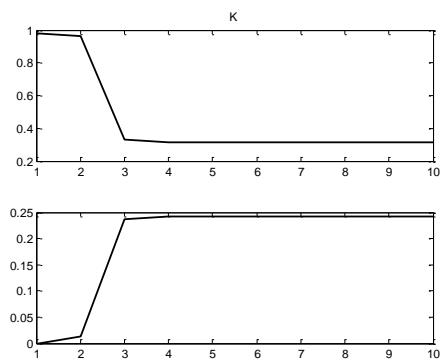
Estimation Theory  
by Dr B. Moaveni

78

## The Steady State Kalman Filter (SSKF)

ادامه مثال (۵.۳) (محاسبات در SSKF)

$$\xrightarrow{(5.104)} K_{\infty} = \begin{bmatrix} \frac{\sqrt{2}-1/2}{\sqrt{2}+3/2} \\ \frac{1/\sqrt{2}}{\sqrt{2}+3/2} \end{bmatrix} \approx \begin{bmatrix} 0.3137 \\ 0.2426 \end{bmatrix}. \quad (5.113)$$

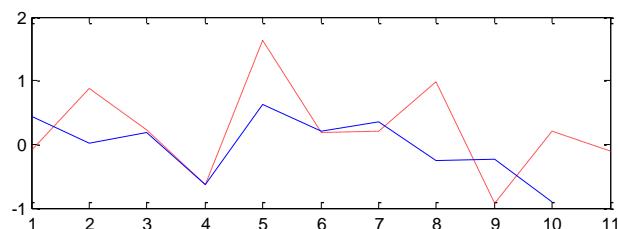
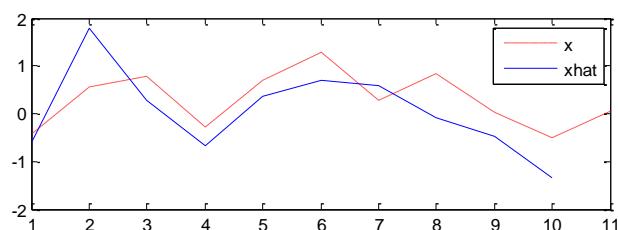


Estimation Theory  
by Dr B. Moaveni

79

## The Steady State Kalman Filter (SSKF)

ادامه مثال (۵.۳) (محاسبات در SSKF)



Estimation Theory  
by Dr B. Moaveni

80

## Input-Output form of Kalman Filter

برای SSKF، که یک سیستم خطی است:

$$\left. \begin{array}{l} (5.81) \\ (5.83) \\ (5.86) \end{array} \right\} \Rightarrow \begin{cases} \hat{x}^-(n+1) = \Phi [I - K_\infty C] \hat{x}^-(n) + \Phi K_\infty z(n) \\ \hat{s}^-(n) = C \hat{x}^-(n). \end{cases} \quad (5.114)$$

$$(5.115)$$

$$\Rightarrow H_{SSKF\_predictor}(z) = C(zI - \Phi[I - K_\infty C])^{-1} \Phi K_\infty. \quad (5.116)$$

$$\Rightarrow H_{SSKF\_filtering}(z) = C(zI - [I - K_\infty C]\Phi)^{-1} K_\infty$$

## Causal Wiener filter and SSKF

لازم به ذکر است که یک تخمینگر خطی و causal منحصر به فرد است.  
لذا، می‌توان گفت دو تخمینگر بالا تقریباً یکی هستند. ولیکن:

*SSKF*: (5.115)  $\rightarrow \hat{s}^-(n) = C \hat{x}^-(n) + 0z(n),$

$$\rightarrow \hat{s}^-(n) = \sum_{i=1}^n b(i)z(n-i) \quad (5.117)$$

$$\text{Causal Wiener Filter}: \hat{s}(n) = \sum_{i=0}^n a(i)z(n-i). \quad (5.118)$$

$$\left. \begin{array}{l} (5.117) \\ (5.118) \end{array} \right\} \Rightarrow \begin{cases} b(0) = 0 \\ a(0) \neq 0 \\ \text{SSKF: one-step prediction} \\ \text{C. Wiener F.: filtering} \end{cases}$$

## Causal Wiener filter and SSKF

مثال (۵.۵) (مقایسه دو تخمینگر در پیش بینی):

برای SMM مثال (۵.۳) دو تخمینگر SSKF و Causal Wiener Filter به صورت زیر خواهند بود:

:SSKF - ۱

$$(5.114) \rightarrow \hat{s}^-(n+1) = C\hat{x}^-(n+1) = C\Phi[I - K_\infty C]\hat{x}^-(n) + C\Phi K_\infty z(n).$$

$$\Rightarrow H_{SSKF,pred}(z) = C\Phi(I - K_\infty C)[zI - \Phi(I - K_\infty C)]^{-1}\Phi K_\infty + C\Phi K_\infty$$

$$\xrightarrow[(5.113)]{(5.112)} H_{SSKF,pred}(z) = \frac{0.1716}{1 + 0.1716z^{-1}},$$

## Causal Wiener filter and SSKF

ادامه مثال (۵.۵) (مقایسه دو تخمینگر در پیش بینی):

:Causal Wiener Predictor-۲

$$H_{Wiener,pred}(z) = \frac{1}{S_z^+(z)} \left[ \frac{zS_{sz}(z)}{S_z^-(z)} \right]_+$$

$$S_z^+(z) = 1.7071(1 + 0.1716z^{-1})$$

$$\begin{aligned} \left[ \frac{zS_{sz}(z)}{S_z^-(z)} \right]_+ &= \left[ \frac{0.5z + 1 + 0.5z^{-1}}{1.7071(1 + 0.1716z)} \right]_+ \\ &= \left[ 0.2929 + 1.7029z - \frac{1.1714}{z^{-1} + 0.1716} \right]_+ = 0.2929 \end{aligned}$$

## Causal Wiener filter and SSKF

ادامه مثال (۵.۵) (مقایسه دو تخمینگر در پیش بینی):

**Causal Wiener Predictor-۲**

$$\Rightarrow H_{Wiener,pred}(z) = \frac{1}{1.7071(1+0.1716z^{-1})} \times 0.2929 = \frac{0.1716}{1+0.1716z^{-1}}.$$

مقایسه دوتابع تبدیل  $H_{Wiener,pred}(z)$  و  $H_{SSKF,pred}(z)$  نشان از معادل بودن این دو تخمینگر دارد.

## Causal Wiener filter and SSKF

مثال (۵.۶) (مقایسه دو تخمینگر در حالت filtering:

**SSKF-۱**

$$\left. \begin{array}{l} (5.83) \\ (5.114) \end{array} \right\} \Rightarrow \hat{x}(n) = (I - K_\infty C) \hat{x}^-(n) + K z(n).$$

$$\Rightarrow \hat{s}(n) = C \hat{x}(n) = C(I - K_\infty C) \hat{x}^-(n) + CK_\infty z(n),$$

$$\Rightarrow H_{SSKF,filt}(z) = C(I - K_\infty C)[zI - \Phi(I - K_\infty C)]^{-1} \Phi K_\infty + CK_\infty$$

$$Example(5.3) \xrightarrow[(5.113)]{(5.112)} H_{SSKF,filt}(z) = 1 - \frac{0.6863}{1+0.1716z^{-1}}$$

## Causal Wiener filter and SSKF

مثال (۵.۶) مقایسه دو تخمینگر در حالت :  
Causal Wiener Filter-۱

$$\begin{aligned} H_{SSKF,filt}(z) &= \frac{1}{S_z^+(z)} \left[ \frac{S_{sz}(z)}{S_z^-(z)} \right]_+ = \frac{1}{S_z^+(z)} \left[ \frac{0.5z+1 - 0.5z^{-1}}{1.7071(1+0.1716z)} \right]_+ \\ &= \frac{1}{S_z^+(z)} \left[ 0.2929z^{-1} + 0.5355 + \frac{0.2010}{z^{-1} + 0.1716} \right]_+ \\ &= \frac{1}{1.7071(1+0.1716z^{-1})} \times (0.2929z^{-1} + 0.5355) \\ &= 1 - \frac{0.6863}{1+0.1716z^{-1}}. \end{aligned}$$

## The SSKF estimator:

دو قضیه ای که در ادامه ارائه می گردند، جایگاه استفاده از SSKF را در SMM های نامتغیر بازمان و با حضور نویز Stationary روشن می کنند:

- قضیه ۵.۱: اگر  $\sqrt{Q}$  ماتریسی باشد که  $\sqrt{Q}\sqrt{Q}^T = Q > 0$  و زوج  $(\Phi, \Gamma\sqrt{Q})$  پایدارپذیر باشند. آنگاه زوج  $(\Phi, C)$  آشکارپذیر خواهد بود اگر و فقط اگر:
- وجود دارد.
  - SSKF بدون بایاس خواهد بود.
  - $P_\infty^-$  یک حل محدود منحصر به فرد مثبت نیمه معین برای معادله ریکاتی (۵.۱۰۳) خواهد بود.
  - مقدار  $P_\infty^-$  مستقل از  $0 \geq P^-(0)$  خواهد بود.

## The SSKF estimator:

نتیجه قضیه فوق را به منظور سادگی در استفاده از آن به صورت زیر می‌توان استفاده کرد:

- قضیه ۵.۲:** اگر  $\mathcal{Q} > 0$  و زوج  $(\Phi, \Gamma \sqrt{\mathcal{Q}})$  کنترل پذیر باشد و زوج  $(P_{\infty}^-, P_{\infty}^-)$  رویت پذیر باشد آنگاه:
- SSKF وجود دارد.
  - SSKF بدون بایاس خواهد بود.
  - یک حل محدود منحصر به فرد مثبت نیمه معین برای معادله ریکاتی (۵.۱۰۳) خواهد بود.
  - مقدار  $P_{\infty}^-$  مستقل از  $0 \geq P_{\infty}^-(0)$  خواهد بود.